IÖR Schriften

Herausgegeben vom
Leibniz-Institut für ökologische
Raumentwicklung

RHOMBOS-VERLAG BERLIN

Bibliografische Information der Deutschen Nationalbibliothek

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind im Internet über http://dnb.d-nb.de abrufbar

Impressum

Herausgeber

Leibniz-Institut für ökologische Raumentwicklung e. V. (IÖR)
Direktor: Prof. Dr. Dr. h. c. Bernhard Müller
Weberplatz 1
01217 Dresden
Tel.: (0351) 4679-0
Fax: (0351) 4679-212
E-Mail: info@ioer.de
Homepage: http://www.ioer.de

Verlag

RHOMBOS-VERLAG
Kurfürstenstraße 17
10785 Berlin
E-Mail: verlag@rhombos.de
Homepage: http://www.rhombos.de
VK-Nr. 13597

Druck: dbusiness.de GmbH, Berlin

Printed in Germany

© 2014 RHOMBOS-VERLAG, Berlin

Alle Rechte vorbehalten.
Nachdruck, auch auszugsweise, verboten.
Kein Teil dieses Werkes darf außerhalb der engen Grenzen des Urheberrechtsgesetzes ohne schriftliche Einwilligung des Verlages in irgendeiner Form (Fotokopie, Mikrofilm oder ein anderes Verfahren) reproduziert oder unter Verwendung elektronischer Systeme gespeichert, verarbeitet, vervielfältigt oder verbreitet werden.

Titelbild: Ergebnis der automatisierten Ableitung von Gebäude- und Baublockklassifikation Dresden unter Verwendung von ATKIS Basis-DLM und den amtlichen Hausumringen ©GeoBasis-DE / BKG 2010 (Autor: R. Hecht)

ISBN: 978-3-944101-63-7

IÖR Schriften Band **63 · 2014**

Robert Hecht

Automatische Klassifizierung von Gebäudegrundrissen

Ein Beitrag zur kleinräumigen Beschreibung der Siedlungsstruktur

Dissertation zur Erlangung des akademischen Grades
Doktor-Ingenieur (Dr.-Ing.)
an der Fakultät Umweltwissenschaften der Technischen Universität Dresden

vorgelegt von
Dipl.-Ing. Robert Hecht

Gutachter:
Prof. Dr. phil. habil. Manfred F. Buchroithner
Professur für Kartographie
Institut für Kartographie, Fakultät Umweltwissenschaften, Technische Universität Dresden

Prof. Dr. habil. Nguyen Xuan Thinh
Fachgebiet Raumbezogene Informationsverarbeitung und Modellbildung
Fakultät Raumplanung, Technische Universität Dortmund

Prof. Dr.-Ing. habil. Dirk Burghardt
Professur für Kartographische Kommunikation
Institut für Kartographie, Fakultät Umweltwissenschaften, Technische Universität Dresden

Verteidigt am 10. Juni 2013

Vorwort

Unsere Siedlungsstrukturen werden vor allem durch den Bestand an Gebäuden mit deren unterschiedlichen Nutzungen geprägt. Gemessen an dem immensen ökonomischen Wert, der Langlebigkeit von Gebäuden und der Bedeutung des Gebäudebestandes für eine nachhaltige Entwicklung ist das Wissen zum Gebäudebestand und dessen räumlicher Verteilung noch viel zu lückenhaft. Neue Anforderungen wie beispielsweise Szenarienanalysen des Klimawandels benötigen jedoch gesicherte Datengrundlagen zum Gebäudebestand, um mögliche Transitionspfade hin zu einer Low-Carbon-Gesellschaft zu beschreiben. Das vorliegende Buch – Dissertationsergebnis von Dr. Robert Hecht – liefert einen Beitrag, diese bestehende Informationslücke zu schließen, in dem es in topographischen Karten bzw. digitalen Geodaten impliziert enthaltene Gebäudeinformationen erschließt und mittels räumlicher Analyse zugänglich macht. Erstmals werden grundlegende und systematische Untersuchungen zur automatischen Erkennung von Gebäudetypen auf Basis ihrer Grundrisse, ihrer Verortung und ihrer Nachbarschaftsbeziehungen vorgelegt. Diese beruhen auf der Nutzung von Methoden der Mustererkennung und des maschinellen Lernens sowie eines Vergleichs verschiedener Klassifikationsverfahren. An praktischen Beispielen werden mit Hilfe von Referenzinformationen erreichbare Klassifikationsgenauigkeiten unter Berücksichtigung verschiedener Eingangsdatenquellen ermittelt und bewertet.

Die Arbeit ist eine ausgezeichnete Grundlage für weitere theoretische und praktische Arbeiten in der Gebäudeklassifikation. Durch die systematische Themenbearbeitung liefert sie dem Leser eine Fülle neuer Detailinformationen. Da das entwickelte Verfahren ausschließlich fortschreibungspflichtige Geobasisdaten verarbeitet, ist es praxistauglich und flächendeckend in Deutschland anwendbar. Darüber hinaus könnten gescannte analoge topographische Karten analysiert werden, was Gebäudebestandsanalysen früherer Zeiten ermöglicht. Allerdings weisen die Untersuchungen auch darauf hin, dass der Random-Forest-Klassifikator umso genauer arbeitet, je besser er auf den jeweiligen regionalen Gebäudebestand trainiert wurde.

Die in dem Buch veröffentlichten Untersuchungsergebnisse und das entwickelte *Building Footprint Classification Tool* sind ein überaus wichtiger Beitrag hin zu einer Beschreibung der Siedlungsstruktur und deren Entwicklung in Deutschland. Neben Verfahrensentwicklungen ist dieses erklärtes Ziel des Forschungsbereichs „Monitoring der Siedlungs- und Freiraumentwicklung“ des Leibniz-Instituts für ökologische Raumentwicklung. Erste Ergebnisse zum Gebäudebestand sind schon jetzt dem internetbasierten Monitor der Siedlungs- und Freiraumentwicklung (www.ioer-monitor.de) zu entnehmen.

Möge das Buch einen breiten Leserkreis finden und die beginnende Forschung auf diesem hoch interdisziplinären Arbeitsfeld zwischen Kartographie, Geoinformatik, Mathematik, Statistik, Bildverarbeitung, Geographie und Raumwissenschaft nachhaltig befördern.

Dresden, im März 2014

Dr. Gotthard Meinel, Forschungsbereichsleiter, IÖR

Danksagung

Das vorliegende Werk wäre ohne die Unterstützung einer Reihe von Menschen nicht möglich gewesen. Daher möchte ich an dieser Stelle die Gelegenheit nutzen, mich bei all jenen zu bedanken.

Zunächst gilt der Dank meinen Gutachtern/Betreuern Herrn Prof. Dr. phil. habil. Manfred F. Buchroithner (TU Dresden, Institut für Kartographie) und Herrn Prof. Dr. habil. Nguyen Xuan Thinh (TU Dortmund, Raumbezogene Informationsverarbeitung und Modellbildung), die die Arbeit von Beginn an begleitet und wertvolle Hinweise und Anregungen gegeben haben. Ein großer Dank richtet sich ebenfalls an Herrn Prof. Dr.-Ing. habil. Dirk Burghardt (TU Dresden, Institut für Kartographie) für die Übernahme der Rolle des dritten Gutachters und Prüfers im Promotionsverfahren.

Persönlich möchte ich mich besonders bei Dr. Gotthard Meinel (IÖR) bedanken, der mir als Fachbetreuer mit allzeit offenem Ohr zur Seite stand, neue Impulse gab und das Vertrauen schenkte, neue Ideen zu verfolgen und umzusetzen. Dem IÖR danke ich für die Unterstützung im Rahmen der wissenschaftlichen Nachwuchsförderung und insbesondere Herrn Dr. Gerd Lintz als Doktorandenbeauftragter. Darüber hinaus möchte ich mich bei allen Kolleginnen und Kollegen am IÖR für die konstruktive Zusammenarbeit bedanken. Erst die kritischen Diskussionen haben die Arbeit zu dem gemacht, was sie ist.

Dem Bundesamt für Kartographie und Geodäsie (BKG) und dem Staatsbetrieb Geobasisinformation und Vermessung Sachsen (GeoSN) danke ich für die Bereitstellung aller verwendeter Geobasisdaten. Für die Unterstützung beim Aufbau der Referenzdatenbasis bedanke ich mich besonders bei Jörg Hennersdorf, Anne Bräuer, Benjamin Richter und Michel Kaden.

Die Abschlussphase einer Dissertation ist immer auch eine Zeit des Leidens. Meinem Kollegen Dr. Martin Behnisch bin ich deshalb sehr dankbar, dass er mir als Motivator und Zeitmanagement-Coach auf der Zielgeraden die richtigen Tipps und Anstöße gab, damit sich diese Phase nicht unnötig in die Länge zog. Frau Sieglinde Sauer, Reinhard Beger, Claudia Gedrange, Sebastian Muhs und Manuela Hahn danke ich für die kostbare Zeit, die sie für das Korrekturlesen aufgeopfert haben.

Weiterhin danke ich allen Mitarbeiterinnen und Mitarbeitern des IÖR, denen es gelingt, eine ausgezeichnete Infrastruktur für Wissenschaftler bereitzustellen, angefangen von dem IT-Service (Jörg Gössel, Carsten Hantzsch), der DTP-Unterstützung (Sabine Witschas, Margitta Wahl), dem komfortablen Bibliotheks-Service (Anja Heller, Albrecht Rostoski) bis hin zu einer stets sauberen Arbeitsumgebung (Claudia Lankau, Ilona Gerö). Für das täglich nette Arbeitsklima und so manche verrückte Idee danke ich Hendrik Herold sowie den RB/RB45-Mitstreitern für die schöne Zeit im Beutler oder der Terrasse mit BO XAO XA.

Nicht zuletzt danke ich meiner Familie, meinen Freunden und meiner Partnerin für die allgegenwärtige Unterstützung, das Verständnis und die große Geduld.

Dresden, im Mai 2014

Robert Hecht

Kurzfassung und Thesen

Für die Beantwortung wissenschaftlicher und planerischer Fragestellungen im Siedlungsraum werden kleinräumige Informationen zur funktionalen, morphologischen und sozioökonomischen Siedlungsstruktur benötigt. Gebäude spielen eine zentrale Rolle, da sie die physische Struktur der Stadt prägen und durch deren Nutzung sich Verteilungsmuster von Wohnungen, Arbeitsstätten und Infrastrukturen ergeben. Trotz ihrer großen Bedeutung stehen der Wissenschaft und Praxis oftmals nur wenig aktuelle, räumlich stark aggregierte oder nur schwer zugängliche Informationen zur Verfügung.

Gebäude werden im Liegenschaftskataster und in topographisch-kartographischen Informationssystemen der Landesvermessung geführt und in Form von Geodaten, Karten und Diensten angeboten. Der erfasste Gebäudegrundriss besitzt allerdings nur selten explizite semantische Informationen zur Gebäudefunktion, Wohnform, Baualter oder der Stockwerkszahl. Bundesweit einheitliche Festlegungen der Arbeitsgemeinschaft der Vermessungsverwaltungen der Länder (AdV) sehen im Liegenschaftskataster lediglich eine funktionale Unterscheidung von „Wohngebäuden", „öffentlichen Gebäuden" und „Gebäuden für Industrie und Gewerbe" zwingend vor. Gebäudedatensätze wie die amtlichen Hausumringe sowie aus Luft-/Satellitenbildern, Laserscannerdaten, Karten und Plänen gewonnene Gebäudeobjekte besitzen hingegen gar keine attributive Beschreibung. Datennutzer sind darum häufig mit der reinen Gebäudegeometrie konfrontiert, auf deren Grundlage zunächst nur wenige Erkenntnisse über die Siedlungsstruktur gewonnen werden können. Zweckmäßig klassifizierte Gebäudegrundrisse erlauben es hingegen, verschiedene siedlungsstrukturelle Indikatoren zu der Bebauungsdichte, der Geschossflächendichte sowie der Anzahl an Wohnungen und Bewohnern unter Nutzung moderner GIS-Technologie abzuleiten und in thematischen Karten zu visualisieren.

In dieser Arbeit werden Methoden zur automatischen Klassifizierung von Gebäudegrundrissen erarbeitet, analysiert und bewertet mit dem Ziel, diese für die gebäudebasierte Analyse der Siedlungsstruktur zu nutzen. Die automatische Klassifizierung der Gebäudegrundrisse erfolgt im Sinne eines datengetriebenen Mustererkennungsansatzes auf Grundlage von Trainingsdaten mit bekannter Klassenzugehörigkeit und objektbeschreibender Merkmale. Im Kern werden methodische Fragen der Datenintegration, der Datenvorverarbeitung, der Merkmalsextraktion und -selektion erörtert sowie verschiedene Klassifikationsverfahren hinsichtlich ihrer Genauigkeit untersucht.

Der aktuelle Forschungsstand belegt, dass nur wenige Arbeiten vorliegen, die den Einsatz von Verfahren der Mustererkennung und des Maschinellen Lernens für die Gebäudeklassifikation verfolgen. Viele Ansätze stützen sich auf wissensbasierte Modelle, die wenig flexibel bzgl. einer Änderung der Datengrundlage oder der Gebäudezielklassen sind. Ferner fehlt es den meisten Ansätzen an einer kritischen Genauigkeitsbetrachtung unter Nutzung unabhängiger Testdaten. Deswegen wurde bei der Entwicklung eines Verfahrens zur automatischen Gebäudeklassifizierung besonderer Wert auf eine hohe Flexibilität, Automation sowie eine zuverlässige Validierung gelegt. Der entwickelte Ansatz beschränkt sich auf die Nutzung ausgewählter topographischer Objekte: den Gebäudegrundrissen, georeferenzierten

Gebäudeadressen und den Baublöcken. Damit wird eine flächendeckende Anwendbarkeit des Verfahrens in Deutschland und Ländern mit vergleichbarer Datenlage abgesichert.

Aus der Menge amtlicher Geobasisdaten zum Gebäudegrundriss in Deutschland konnten fünf verschiedene Eingangsdatentypen identifiziert werden, die sich in der Datenstruktur (Raster oder Vektor), der geometrischen Modellierung (Einzelgebäude oder Gebäuderegionen) und dem semantischen Informationsgehalt (mit oder ohne Information zur Gebäudenutzung) unterscheiden. Für jeden Eingangsdatentyp wurde ein umfangreiches Merkmalsset erarbeitet, mit dem Objekte und Relationen auf verschiedenen räumlichen Ebenen (z. B. Einzelgebäude, Gebäudekomplex, Baublock, Umgebung) beschrieben werden. Die Merkmale werden unter Anwendung von Methoden der Bildverarbeitung und der räumlichen Analyse im GIS berechnet. Mit einem filterbasierten Ansatz wurde das Merkmalsset von hochkorrelierten Merkmalen befreit. Zum Training eines Klassifikators wurde eine überwachte Lernstrategie bevorzugt, da die gesuchten Gebäudetypen im Kontext der Siedlungsstrukturanalyse als bekannt vorausgesetzt werden können. Gleichzeitig erlauben überwachte maschinelle Lernverfahren im Gegensatz zu den unüberwachten eine direkte Abschätzung des Vorhersagefehlers, ohne das eine aufwändige Dateninterpretation nötig ist.

Für die Genauigkeitsuntersuchung wurde eine Referenzdatenbank mit über 800 000 Gebäudegrundrissen aufgebaut, für die jeweils der Gebäudetyp entsprechend einer Gebäudetypologie gegeben ist. In der Datenbank sind die Gebäude nach 11 städtebaulichen Typen differenziert. Dabei werden diverse Siedlungstypen (Stadt, Kleinstadt, Dörfer) und verschiedene amtliche Datengrundlagen zum Gebäudegrundriss (DTK25-V, DTK25, ATKIS®, ALK, 3D-Gebäudemodelle) berücksichtigt, was eine differenzierte Bewertung der Genauigkeit möglich macht.

In einer Modellselektion wurden 16 verschiedene überwachte Klassifikationsverfahren anhand ausgewählter Datensätze getestet und deren Generalisierungsfähigkeit mittels 10-facher Kreuzvalidierung geschätzt. Zum Einsatz kamen unter anderem lineare Modelle, nichtparametrische Verfahren, Support Vector Machines, Künstliche Neuronale Netze, Entscheidungsbaumverfahren und Ensemble-Methoden. Der Ensemble-basierte Random-Forest-Algorithmus zeigte die höchste Generalisierungsfähigkeit und Effizienz und wurde als bester Klassifikator ausgewählt. Der Algorithmus besitzt auch aus praktischer Sicht Vorteile gegenüber den anderen Verfahren, da weder Datenskalierung noch Merkmalsselektion zwingend nötig ist, kategoriale Merkmale direkt verarbeitet werden können und dieser Maße bereitstellt, mit dem die Relevanz der Merkmale quantifiziert werden kann.

Nach Auswahl des besten Klassifikationsverfahrens erfolgte eine detaillierte Genauigkeitsuntersuchung auf Grundlage aller Datensätze in der Referenzdatenbank. Durch Berechnung von Konfusionsmatrizen und daraus abgeleiteten Gütemaßen wurde die Genauigkeit nach Eingangsdatentyp und Untersuchungsgebiet differenziert quantifiziert und bewertet. Für Gebäudegrundrisse im Vektormodell, speziell den Gebäuden aus der ALK, dem ALKIS® oder dem ATKIS® Basis-DLM sowie den amtlichen Hausumringen und 3D-Gebäudemodellen, konnte für alle städtischen Gebiete eine Klassifikationsgenauigkeit zwischen 90 % und 95 % erreicht werden. Die Genauigkeit bei Nutzung von Gebäudegrundrissen extrahiert aus digitalen topographischen Rasterkarten war mit 76 % bis 88 % geringer. In einer Simulation

wurde gezeigt, dass die Trainingsdatenmenge einen großen Einfluss auf die Genauigkeit besitzt. Eine Herausforderung stellen allerdings regionale baukulturhistorische Differenzen zwischen Städten dar. Versuche eines gegenseitigen Trainierens und Anwendens auf Städte unterschiedlicher regionaler Baukultur legten die Grenzen der Übertragbarkeit eines erlernten Klassifikators offen. Eine überregionale Anwendung des Verfahrens wird deshalb mit einer regionalen Abgrenzung und Erhebung individueller Trainingsdaten einhergehen müssen.

Die automatische Klassifizierung von Gebäudegrundrissen leistet einen wichtigen Beitrag zur Gewinnung von Information für die kleinräumige Beschreibung der Siedlungsstruktur. Neben der Relevanz in den Forschungs- und Anwendungsfeldern der Stadtgeographie und Stadtplanung sind die Ergebnisse auch für die kartographischen Arbeitsfelder der Kartengeneralisierung, der automatisierten Kartenerstellung und der Geovisualisierung relevant.

Thesen:

(1) Die Bearbeitung raumwissenschaftlicher und -planerischer Fragestellungen verlangt räumlich und sachlich hochauflösende Information zur Siedlungsstruktur. In der Regel ist derartige Geoinformation nur für größere Städte verfügbar. Für überregionale Anwendungen und vergleichende Untersuchungen fehlt es oftmals an homogenen Geodaten. Problematisch ist, dass flächendeckend verfügbare Geobasisdaten sowie amtliche statistische Daten die Siedlungsstruktur in einer zu geringen thematischen und/oder zu geringen räumlichen Auflösung abbilden.

(2) Gebäudedaten sind hochrelevant für die kleinräumige Beschreibung der Siedlungsstruktur. Digitale Geobasisdaten des Liegenschaftskatasters und der Landesvermessung bilden die Gebäude in ihrem Grundriss ab. Attributive Sachinformationen zur Nutzung, Wohnform, Stockwerkszahl oder zum Baujahr sind in den Daten derzeit nur selten enthalten. Vor diesem Hintergrund ist ein geeignetes Verfahren zur automatischen Klassifizierung der Gebäudegrundrisse nötig, auf deren Grundlage diese Sachinformation abgeschätzt werden kann.

(3) Es steht ein breites Spektrum an Methoden der Mustererkennung und des Maschinellen Lernens zur Verfügung, deren Einsatz für die automatische Klassifizierung von Gebäudegrundrissen bislang nur in wenigen Arbeiten systematisch untersucht wurde. Durch Kombination dieser Methoden mit Techniken der räumlichen Analyse kann ein flexibles Verfahren zur automatischen Klassifizierung von Gebäudegrundrissen entwickelt werden, das für verschiedene Gebäudetypologien und Datengrundlagen anwendbar ist und eine realistische Abschätzung der Klassifikationsgenauigkeit erlaubt.

(4) Für die automatische Klassifizierung von Gebäudegrundrissen werden gebäudebeschreibende Merkmale benötigt. Von Bedeutung sind geometrische, topologische, statistische und semantische Merkmale, die mithilfe der digitalen Bildverarbeitung und der räumlichen Analyse gewonnen werden können. Geometrieinformationen von Baublöcken und Hauskoordinaten sowie weitere Sachinformationen unterstützen die Merkmalsberechnung.

(5) Eine kleinräumige Beschreibung der Siedlungsstruktur verlangt eine differenzierte Sicht auf den Gebäudebestand nach verschiedenen städtebaulichen Kriterien. Bisherige Ansätze zur automatischen Gebäudeklassifikation berücksichtigen oft nur wenige Zielklassen (5 Gebäudetypen und weniger). Mit nichtlinearen Klassifikationsverfahren, insbesondere Ensemble-Methoden, können 11 städtebauliche Gebäudetypen automatisch klassifiziert werden. Ein besonders effizientes Klassifikationsverfahren ist der Random-Forest-Algorithmus. Im Vergleich zu 15 weiteren getesteten Algorithmen des Maschinellen Lernens zeigt dieser die höchste Generalisierungsfähigkeit und die kürzeste Laufzeit.

(6) Die Genauigkeit einer automatischen Gebäudeklassifizierung wurde im Hinblick auf die Anwendung für siedlungsstrukturelle Analysen noch zu wenig empirisch untersucht. Sie hängt von der verwendeten Datengrundlage (Eingangsdatentyp), dem betrachteten Untersuchungsraum (Siedlungstyp), der Anzahl der zur Verfügung stehenden Trainingsobjekte und der Qualität der Datengrundlage ab. Bei der Nutzung von Gebäudegrundrissen aus dem Liegenschaftskataster kann eine deutlich höhere Klassifikationsgenauigkeit erzielt werden als bei der Nutzung von Gebäudegrundrissen, die aus topographischen Rasterkarten extrahiert werden.

(7) Automatisch klassifizierte Gebäudegrundrisse bilden eine wichtige Grundlage für die GIS-gestützte Erhebung und Analyse der Siedlungsstruktur. Durch eine Klassifizierung nach einer zweckgebundenen Gebäudetypologie können unter Annahme gebäudetypischer Kenngrößen und der Nutzung von Methoden der räumlichen Aggregation und Disaggregation verschiedene Indikatoren zur Siedlungsstruktur (u. a. Geschossflächendichte, Wohnungszahl, Einwohnerzahl, Energieverbrauch) abgeleitet werden. Diese Informationen sind auf verschiedenen räumlichen Ebenen für die Wissenschaft, Planung, Politik und Wirtschaft von hohem Interesse.

Abstract and Theses

Small-scale information on functional, morphological and socio-economic structure is necessary to provide answers for research and planning issues in urban and rural areas. Buildings are of key importance here, since they determine the physical structure of a settlement. Moreover, their types of occupancy creates the distribution pattern of housing, workplaces and infrastructure. Despite their significance both for researchers and planners, such data is often not up to date, strongly spatially aggregated or only very locally available.

Building footprints are registered and maintained in the real estate cadastre and in topographic-cartographic information systems by the ordnance survey. They are available to the public in the form of geospatial data, maps and online services. However, semantic information on building function, type of housing, building age or numbers of floors is sparse. The Working Committee of the Surveying Authorities of the States of the Federal Republic of Germany (AdV) specifies only a mandatory differentiation between "residential", "public" and "industrial/commercial" buildings in the cadastre. Some official building data, like the nationwide product "Amtliche Hausumringe" (official building footprints) as well as buildings extracted from maps, laser scanner data, aerial photographs or satellite imagery, contain initially no attributes at all. Therefore users are often faced with a pure building geometry, on the basis of which only little knowledge about the settlement structure can be obtained. However, appropriately classified building footprints would allow them to obtain additional indicators of the settlement structure, such as building density, floor area, and number of housings and residents, all of which can be derived and visualized by means of GIS technology.

In this thesis, methods for the automatic classification of building footprints are developed, analyzed and assessed, with the aim to use them for a small-scale description of the settlement structure. The procedure presented follows a data-driven pattern recognition approach using training samples with known classes and features of buildings. The work addresses issues of data integration, data processing, feature extraction, and feature selection and investigates the accuracy of various classification methods.

Currently, as is shown, there are only a few scientific studies that pursue the use of pattern recognition and machine learning for building classification. Many approaches rely on knowledge-based models which are not very flexible when the data input or the desired target classes change. Moreover, for many approaches, there is no critical accuracy assessment by means of independent test data. Therefore, when developing a procedure for automatic building classification, particular attention has been paid to flexibility, automation and reliable validation. The developed approach makes use of basic topographic objects only: building footprints, official building coordinates and urban blocks. Thus, a nationwide applicability of the method is ensured for Germany and countries with comparable data.

Out of the stock of spatial base data on buildings available in Germany, five different input data types have been identified, which differ in structure (raster or vector), geometric modelling (individual buildings or building-regions), and semantic information content (with or without information on building use). For each input data type, an extensive set of features

has been developed, with which all objects and relations are described at various spatial levels (e.g., single building, building complex, urban block, or a defined neighbourhood). The features are calculated using methods of digital image processing and spatial analysis within a GIS environment. Highly correlated features are removed from these sets by using a filter-based feature selection. Since it can be assumed that the building typology will be known in the context of the settlement structure analyses, a supervised learning strategy has been preferred for training the classifier. At the same time, supervised machine learning procedures, unlike unsupervised ones, allow an immediate assessment of the prediction error, with no necessity for any "sophisticated" data interpretation.

A reference database with over 800,000 building footprints has been created for the accuracy assessment, in which the building type for each building is provided, which corresponds to a defined building typology. The typology distinguishes between eleven classes according to urban planning criteria. Various types of settlement (city, town or village) and several administrative data bases (DTK25-V, DTK25, ATKIS®, ALK, 3D building models) are considered, which enables a differentiated evaluation of accuracy.

In a model selection process, 16 different supervised classification methods are tested on selected data sets, and their generalization capabilities have been evaluated based on a ten-fold cross-validation. The following models are used: linear models, non-parametric models, support vector machines, artificial neural networks, decision trees and ensemble methods. Non-linear models, like the ensemble-based random-forest algorithm, show the highest degree of generalization capability and efficiency. Random forest has been chosen as the best classifier, since it also has a number of other practical advantages over other methods, as it does not absolutely require either data scaling nor feature selection. Moreover, categorical features can be processed directly and the algorithm provides measurements to quantify the importance of the features.

After the selection of a classification procedure, a detailed accuracy assessment based on all data sets in the reference data base is performed. Based on confusion matrices and quality measures derived from them, the classifier is evaluated and assessed separately according to input data type and study area. For vector-based building footprints, especially buildings from ALK/ATKIS®, ATKIS® or official building footprints and 3D building models, an overall accuracy between 90 % and 95 % could be achieved. The accuracy when using building footprints extracted from digital topographic raster maps was less – only 76 % to 88 %. In a simulation, it was shown that the sizes of training data have a major impact on the classification accuracy. One challenge in particular can be found in regional differences in the cultural-historic architectural structure between cities. Attempts to train and test a random forest classifier between cities of different architectural characteristics have shown the limitations of the transferability. A nationwide application of the method will therefore necessarily require regional delimitation and the collection of separate training data in each of the regions.

The automatic classification of building footprints provides an important contribution to the acquisition of new information for the small-scale description of settlement structures. In addition to its relevance for research and application areas of urban geography and urban

planning, the results are also relevant for cartographic disciplines such as map generalization, automated mapping and geo-visualization.

Theses:

(1) The handling of spatial scientific and spatial planning issues requires high resolution spatial and thematic information on settlement structures. As a rule, such geo-information is available only for major cities. There is often a lack of homogeneous geo-data for nationwide application and comparative studies. The problem is that comprehensively available spatial base data and official statistical data portray the settlement structure with insufficient thematic and/or spatial resolution.

(2) Building data are highly relevant for the small-scale description of settlement structures. Digital spatial base data from the real estate cadastre and the ordnance survey describe the buildings in terms of their footprints. Attributive thematic information on uses, types of residents, numbers of stories, or years of construction are only rarely included in the data existing to date. In this context, a suitable procedure for the automatic classification of building footprints is necessary, on the basis of which this thematic information can be acquired.

(3) There is a broad spectrum of methods of pattern recognition and machine learning available, the use of which for the automatic classification of building footprints has to date been systematically investigated only in a few studies. By combining these methods with spatial analysis techniques, a flexible procedure for the automatic classification of building footprints can be developed which can be usable for various building typologies and data bases, and will allow a realistic evaluation of classification accuracy.

(4) For the automatic classification of building footprints, features describing the buildings will be necessary. The geometric, topological, statistical and semantic features, which can be obtained by means of digital image processing and spatial analysis, are important. Geometric information of urban blocks and official building coordinates, as well as other thematic information, can support the calculation of features.

(5) A small-scale description of settlement structures requires a differentiated view of the stock of buildings according to various urban planning criteria. Approaches to date on the automatic classification of buildings often take only a few target classes (five building types or less) into account. With a non-linear classification procedure, especially an ensemble-based classifier, eleven building types can be automatically classified. A particularly efficient classification procedure is the random-forest algorithm. A comparison with 15 other machine learning algorithms has shown that random forest has the highest degree of generalization capability, and the shortest run time.

(6) The accuracy of automatic building classification has to date received too little empirical investigation. The accuracy depends on the database used (input data type), the area under investigation (settlement type), the number of available training objects, and the data quality. The use of building footprints from digital cadastral data allows the classifi-

cation with a considerably higher degree of accuracy than does the use of building footprints extracted from topographic raster maps.

(7) The automatic classification of building footprints constitutes an important basis for the GIS-based acquisition and analysis of settlement structures. By means of classification according to a use-related building typology, various indicators on settlement structure, including floor area densities, numbers of flats, numbers of residents, and energy uses, can be obtained assuming typical standard building sizes, and by the use of spatial aggregation and disaggregation methodology. This information is of great scientific, planning, policy and business interest at various spatial levels.

Für Manu und Erbse

Inhaltsverzeichnis

Vorwort ..... **I**

Danksagung ..... **III**

Kurzfassung und Thesen ..... **V**

Abstract and Theses ..... **IX**

Inhaltsverzeichnis ..... **XV**

1 Einleitung

1.1 Hintergrund 1
1.2 Problemstellung 2
1.3 Forschungsstand 4
1.4 Zielsetzung und Forschungsfragen 6
1.5 Thematische Einordnung 7
1.6 Aufbau der Arbeit 9

2 Grundlagen zur Siedlungsstruktur

2.1 Begriffe und Konzepte 11
2.1.1 Raumbegriffe 11
2.1.2 Strukturbegriffe 12
2.1.3 Raumebenen der Siedlungsstruktur 13
2.1.4 Siedlungsstrukturelle Merkmale 15
2.1.5 Strukturtypen 17
2.1.6 Gebäude als Element des Siedlungsraums 19
2.1.7 Baublock als räumliche Siedlungseinheit 21
2.2 Raumbezogene Modellierung der Siedlungsstruktur 22
2.2.1 Abstraktion der Realität 22
2.2.2 Kartographische Modellbildung 23
2.2.3 Modellbildung in der digitalen Kartographie 25
2.2.4 Geobasisdaten 30
2.2.5 Geofachdaten 33
2.2.6 Geodateninfrastruktur (GDI) 34
2.3 Kartographische Darstellung der Siedlungsstruktur 34
2.3.1 Topographische Karten 34
2.3.2 Thematische Karten 37

2.4 Räumliche Analyse von Siedlungsstrukturen ... 43
2.4.1 Innerstädtische Gliederung ... 43
2.4.2 Stadtmorphologische Analyse ... 46
2.4.3 Computerbasierte Analyse der Siedlungsstruktur ... 49

3 Methodische Grundlagen der Mustererkennung
3.1 Visuelle Wahrnehmung und Bildverstehen ... 57
3.1.1 Menschliche Wahrnehmung ... 57
3.1.2 Theorien der visuellen Wahrnehmung ... 58
3.1.3 Bildverstehen ... 60
3.2 Mustererkennung und maschinelles Lernen ... 63
3.2.1 Mustererkennung ... 63
3.2.2 Maschinelles Lernen ... 65
3.3 Aufbau eines Mustererkennungssystems ... 67
3.3.1 Musteraufnahme ... 68
3.3.2 Vorverarbeitung ... 68
3.3.3 Merkmalsextraktion ... 68
3.3.4 Merkmalsselektion ... 69
3.3.5 Klassifizierung ... 70
3.3.6 Trainieren, Testen, Validieren ... 71
3.4 Klassifikationsverfahren ... 72
3.4.1 Klassifikation via Bayes-Theorem ... 74
3.4.2 Klassifikation mittels Trennfunktion ... 79
3.4.3 Fuzzy-Systeme ... 87
3.5 Bewertung von Klassifikatoren ... 87
3.5.1 Fehlerrate und Genauigkeit ... 87
3.5.2 Bewertung der Generalisierungsfähigkeit ... 87
3.5.3 Strategien der Aufteilung der Lerndaten ... 89
3.5.4 Bewertung der thematischen Genauigkeit ... 90

4 Forschungsstand
4.1 Allgemeine Aspekte ... 95
4.1.1 Ziele einer automatischen Klassifizierung der Siedlungsstruktur ... 95
4.1.2 Datengrundlagen und Methoden ... 97
4.1.3 Interpretationsebenen ... 99
4.2 Klassifizierung siedlungsraumbezogener Strukturen ... 100

4.2.1 Abgrenzung und Typisierung von Siedlungsstrukturen ... 100
4.2.2 Beschreibung städtischer Strukturen ... 101
4.2.3 Klassifizierung städtischer Strukturen auf Baublockebene ... 101
4.2.4 Erkennung von Gebäudemustern für die Generalisierung ... 102
4.3 Klassifizierung individueller Gebäude ... 103
4.3.1 Bisherige Ansätze nach Klassifikationsstrategie ... 103
4.3.2 Wissensbasierte Ansätze ... 105
4.3.3 Datengetriebene Ansätze ... 107
4.3.4 Kombinierte Ansätze ... 109
4.4 Bewertung der bisherigen Ansätze ... 110

5 Konzeptionelle Vorüberlegungen
5.1 Ziel der Verfahrensentwicklung ... 113
5.2 Gebäudeklassifizierung im Kontext der Siedlungsstrukturanalyse ... 113
5.3 Anforderung an das Verfahren ... 116
5.3.1 Adaptive Gebäudetypologie ... 116
5.3.2 Interoperabilität ... 116
5.3.3 GIS-Kopplung und Nutzerfreundlichkeit ... 117
5.3.4 Robustheit ... 117
5.3.5 Genauigkeitsabschätzung ... 117
5.3.6 Laufzeit ... 118
5.3.7 Flexibilität ... 118
5.4 Anforderungen an die Eingangsdaten ... 119
5.4.1 Gebäuderepräsentation ... 119
5.4.2 Anforderung an den Abstraktionsgrad ... 120
5.4.3 Homogenität ... 121
5.4.4 Metainformationen ... 121
5.5 Methodische Vorüberlegungen ... 122
5.5.1 Interpretationsebene ... 122
5.5.2 Klassifikationsstrategie ... 122
5.5.3 Merkmalsberechnung ... 123
5.5.4 Lernverfahren ... 124
5.6 Konzepte der Modellierung ... 124
5.6.1 Gebäudegrundrisse im Siedlungsraum ... 124
5.6.2 Objektbeziehung ... 126

6 Mögliche Datenquellen zum Gebäudegrundriss

6.1 Gebäudegrundrisse aus objektstrukturierten Datenmodellen ... 127
6.1.1 Gebäudegrundrisse aus der ALK ... 127
6.1.2 Gebäudegrundrisse aus dem ALKIS® ... 128
6.1.3 Gebäudegrundrisse aus ATKIS® Basis-DLM ... 129
6.1.4 Amtliche Hausumringe ... 130
6.1.5 3D-Gebäudemodelle (3D-Gebäudestrukturen) ... 130
6.1.6 Gebäudegrundrisse aus OpenStreetMap ... 131
6.2 Gebäudegrundrisse aus topographischen Karten ... 132
6.2.1 Gebäuderepräsentation in topographischen Karten ... 132
6.2.2 Gebäudeextraktion aus gescannten topographischen Karten ... 134
6.2.3 Maßstabsanforderungen an topographische Karten ... 134
6.2.4 Scandichte topographischer Karten ... 135
6.2.5 Topographische Karten der amtlichen Vermessung ... 136
6.3 Gebäudegrundrisse aus Fernerkundungsdaten ... 139
6.3.1 Anforderung an die geometrische Auflösung ... 139
6.3.2 Gebäudeextraktion aus Fernerkundungsdaten ... 140

7 Entwicklung des Verfahrens

7.1 Methodisches Design ... 143
7.2 Definition einer Gebäudetypologie ... 145
7.2.1 Kriterien und Gebäudetypologien ... 145
7.2.2 Gebäudetypologie für siedlungsstrukturelle Analysen ... 147
7.3 Eingangsdaten ... 149
7.3.1 Eingangsdaten zum Gebäudegrundriss ... 149
7.3.2 Definition von Eingangsdatentypen ... 152
7.3.3 Unterstützende Geometriedaten ... 153
7.4 Datenaufbereitung ... 155
7.4.1 Aufbereitung der Eingangsdaten ... 155
7.4.2 Erfassung von Klassenlabels ... 158
7.5 Merkmalsberechnung ... 160
7.5.1 Charakterisierung der Gebäudetypen ... 160
7.5.2 Merkmalstypen ... 164
7.5.3 Ebenen der Merkmalsberechnung ... 169
7.5.4 Methoden der Merkmalsgewinnung ... 170
7.5.5 Workflow der Merkmalsberechnung ... 171

7.5.6 Merkmale in Abhängigkeit der Eingangsdaten ... 173
7.5.7 Erkennung kleiner Nebengebäude ... 174
7.6 Vorverarbeitung der Merkmalsdaten ... 176
7.6.1 Konsistenzprüfung und Datenbereinigung ... 177
7.6.2 Skalierung der Merkmale ... 177
7.6.3 Transformation kategorialer Merkmale ... 177
7.6.4 Ersetzen fehlender Werte ... 178
7.7 Merkmalsselektion ... 178
7.7.1 Filterbasierte Merkmalsreduktion ... 179
7.7.2 Merkmalsselektion während des Trainings ... 182
7.8 Entwicklung des Klassifikators ... 183
7.8.1 Wahl der Klassifikationsverfahren ... 183
7.8.2 Vorstellung der getesteten Klassifikationsverfahren ... 185
7.8.3 Tuning ... 192
7.8.4 Modellselektion ... 194
7.9 Genauigkeitsanalyse ... 196
7.10 Programmtechnische Umsetzung ... 196
7.10.1 Verwendete Software ... 197
7.10.2 Programme und deren Kopplung ... 198

8 Ergebnisse und Diskussion

8.1 Untersuchungsgebiete und verwendete Daten ... 201
8.1.1 Vorstellung der Untersuchungsgebiete ... 202
8.1.2 Datengrundlagen der Untersuchungsgebiete ... 204
8.2 Ergebnisse der Datenaufbereitung ... 206
8.2.1 Datenintegration ... 206
8.2.2 Erfassung der Klassenlabels ... 208
8.2.3 Diskussion der Datenaufbereitung ... 215
8.3 Ergebnisse der Merkmalsberechnung und Merkmalsreduktion ... 215
8.3.1 Schwellwertermittlung zur Detektion kleiner Nebengebäude ... 216
8.3.2 Klassenbedingte Verteilungsdichten der Merkmale ... 219
8.3.3 Vorverarbeitung und Merkmalsreduktion ... 221
8.3.4 Diskussion der Merkmalsberechnung und Merkmalsreduktion ... 224
8.4 Ergebnisse der Modellselektion ... 225
8.4.1 Datensätze ... 225
8.4.2 Ergebnisse des Modelltunings ... 225

8.4.3 Genauigkeit der getesteten Klassifikatoren ... 227
8.4.4 Evaluierung der Laufzeit ... 233
8.4.5 Wahl des besten Klassifikators ... 235
8.4.6 Diskussion der Modellselektion ... 235
8.5 Ergebnisse der Modellvalidierung ... 236
8.5.1 Besonderheiten von Random Forest ... 237
8.5.2 Klassengenauigkeit nach Untersuchungsgebieten ... 238
8.5.3 Bewertung der Untersuchungsgebiete ... 241
8.5.4 Einfluss des Eingangsdatentyps auf die Klassengenauigkeit ... 244
8.5.5 Einfluss der Anzahl der Trainingsobjekte nach Eingangsdatentyp ... 248
8.5.6 Kreuzweises Trainieren und Testen ... 249
8.5.7 Diskussion der Modellvalidierung ... 251
8.6 Ergebnisse der Merkmalswichtigkeit ... 253
8.6.1 Merkmalswichtigkeit nach Eingangsdaten ... 253
8.6.2 Merkmalsselektion über Merkmalswichtigkeit ... 255
8.6.3 Diskussion der Merkmalswichtigkeit ... 257

9 Schlussfolgerungen und Ausblick
9.1 Beantwortung der Forschungsfragen ... 259
9.2 Praktische Bedeutung ... 266
9.2.1 Bedeutung der Ergebnisse für die Praxis ... 266
9.2.2 Werkzeug für die Wissenschaft und Praxis ... 266
9.2.3 Potenzielle Anwendungen ... 267
9.3 Ausblick ... 272

Literatur ... 275

Abkürzungsverzeichnis ... 311

Abbildungsverzeichnis ... 320

Tabellenverzeichnis ... 323

Anhang
A Datengrundlagen zur Siedlungsstruktur
A.1. Daten der amtlichen Statistik ... 327
A.2. Daten zur Flächenbedeckung und Flächennutzung ... 334
A.2.1 Amtliche Geobasisdaten ... 335

A.2.2 Fernerkundungsbasierte Erhebungen ... 340
A.2.3 Fazit ... 341

B Gebäudetypologie

B.1. Klassenbeschreibung der Gebäudetypologie ... 343
B.2. Kenngrößen und Baualtersklassen der Gebäudetypen ... 346

C Merkmale

C.1. Übersicht zu den Merkmalen ... 349
C.2. Verteilungsdichte der Merkmale ... 353
C.3. Merkmalsreduktion ... 358
C.4. Merkmalswichtigkeit mit Random Forest ... 360
C.5. Merkmalsselektion mit Random Forest ... 363

D Entwicklung des Klassifikators

D.1. Tuning der SVM ... 365
D.2. Klassifikationsgenauigkeit der getesteten Klassifikationsverfahren ... 366
D.2.1 Overall Accuracy und Kappa in tabellarischer Darstellung ... 366
D.2.2 Overall Accuracy und Kappa in Diagramm ... 367
D.2.3 Mittelwert und Streuung der Overall Accuracy ... 369
D.2.4 Variation der Trainingsdatenmenge ... 370
D.3. Laufzeitmessung der besten Klassifikationsverfahren ... 372

E Genauigkeitsuntersuchung

E.1. Konfusionsmatrizen der Genauigkeitsuntersuchung ... 375
E.2. Produzenten- und Nutzergenauigkeit nach Eingangsdatentyp ... 384
E.3. Ergebnisse der automatischen Klassifizierung am Beispiel von Halle ... 385

F Exemplarische Anwendung von BFClassTool

F.1. Gebäudebasierte Analyse der Siedlungsstruktur ... 395
F.1.1 Grundlagen der Berechnung ... 395
F.1.2 Beispielrechnung Krefeld ... 398
F.2. Ableitung von Bebauungsstrukturtypen ... 404

1 Einleitung

1.1 Hintergrund

Der Gebäudebestand wird als größtes physisches, wirtschaftliches und kulturelles Kapital angesehen (Kohler & Bradley, 2007) und besitzt eine außerordentliche gesellschaftliche Bedeutung. Ist dieser einmal geschaffen, besteht er oft unverändert über mehrere Jahrzehnte und bestimmt die Struktur und das äußere Erscheinungsbild von Siedlungen. Der Gebäudebestand selbst ist als kulturelles Gut nach einem Abriss oder einer Zerstörung nicht reproduzierbar, da sich Handwerkstechniken und Verfügbarkeit der Baustoffe ändern oder dies aus ökonomischen Gründen nicht mehr sinnvoll ist. Vor diesem Hintergrund kommt dem langfristigen Erhalt, der Instandhaltung und der Denkmalpflege eine besondere Bedeutung zu (Hassler, 2011). Gebäude und die dazugehörige Infrastruktur unterliegen einem komplexen Beziehungsgeflecht sozio-kultureller, ökologischer und ökonomischer Ziele. Mit der Gebäudenutzung werden grundlegende Bedürfnisse des Menschen (u. a. Wohnen, Arbeiten, Bilden, Freizeit etc.) erfüllt, die ein soziales Miteinander, Integration und Identifikation ermöglichen. Aus ökonomischer Sicht ist der Gebäudebestand ebenfalls sehr bedeutsam, da durch die Bauwirtschaft viele Arbeitsplätze zur Verfügung gestellt werden und Gebäude eine lukrative Kapitalanlage sind. Der Anteil an in Immobilien gebundenem Volksvermögen wird in Deutschland auf über 50 % geschätzt[1] (Behnisch & Meinel, 2011) und das Bauvolumen ist mit jährlichen 228,5 Mrd. Euro das größte in Europa (BBSR, 2010). Neben der ökonomischen Komponente sind Gebäude auch aus ökologischer Sicht bedeutsam, da mit jedem Bau Ressourcen verbraucht und die Umwelt belastet wird. So sind etwa 40 % des globalen Energieverbrauchs und ein Drittel der globalen Treibhausgasausstrahlungen dem Gebäudebestand bzw. den Menschen, die sie nutzen, zuzuschreiben (UNEP, 2009). Gleichzeitig werden begrenzte Flächenressourcen beansprucht. Amtliche Zahlen der Flächenstatistik legen offen, dass an einem Tag durchschnittlich 87 Hektar landwirtschaftliche und naturbelassene Flächen für Siedlungs- und Verkehrszwecke in Anspruch genommen werden (Destatis, 2011e).

Zur Lösung der Zielkonflikte aller Dimensionen (sozio-kulturell, ökologisch, ökonomisch) legte 1998 die Enquete-Kommission „Schutz des Menschen und der Umwelt“ Grundlagen einer nachhaltigen und zukunftsfähigen Entwicklung des Bereichs Bauen und Wohnen fest, die eine ökologische Verträglichkeit, soziale Gerechtigkeit und wirtschaftliche Leistungsfähigkeit gewährleisten sollen (BMU, 2012). Vor diesem Hintergrund wurden verschiedene ökologische Ziele (Reduktion der Flächeninanspruchnahme und der Bodenversiegelung, Beendigung der Zersiedlung, Minderung der Kohlendioxid-Emmission), soziale Ziele (Sicherung bedarfgerechten Wohnraums mit erträglichen Ausgaben, soziale Integration, Vernetzung von Funktionen) und ökonomische Ziele (Minimierung der Lebenszykluskosten von Gebäuden, Verbilligung von Umbau und Erhaltungsinvestitionen) festgelegt (Enquete-Kommission,

[1] Behnisch & Meinel (2011) nehmen Bezug auf die amtlichen Zahlen des Statistischen Bundesamtes (Destatis, 2011d)

1998). Diesem Interessensausgleich zu begegnen, stellt eine große gesellschaftliche und globale Herausforderung des 21. Jahrhunderts dar (Wallbaum et al., 2011).

Im aktuellen Spannungsfeld zwischen demographischem Wandel, Klimaschutz und Ressourcenknappheit liegt die Zukunft in Deutschland weniger in der Stadterweiterung, sondern in der ressourcenschonenden Erneuerung, Modernisierung und Revitalisierung bestehender Gebäudestrukturen. Unter diesen Bedingungen ist besonders energieeffizientes und nachhaltiges Bauen gefordert. Die Planung, Politik, Wirtschaft und die angewandten Raumwissenschaften beschäftigen sich daher mit Fragen nach energieeffizienten Siedlungsstrukturen (z. B. Thinh et al., 2011; Schiller et al., 2012), Stoffströmen und Ressourcenschonungspotenzialen (z. B. Buchert et al., 2004), ökonomischen Fragen von Infrastrukturfolgekosten (z. B. Ecoplan, 2000; Preuß & Floeting, 2009; Schiller & Siedentop, 2010), Fragen nach neuen Raumordnungsinstrumenten (z. B. Bizer et al., 2011) sowie Fragen der Beherschbarkeit von Risiken (z. B. Naumann et al., 2011). Auch im Hinblick auf den Klimawandel werden morphologische Baustrukturen gesucht, die diesem am besten standhalten (z. B. Satterthwaite et al., 2007; Curdes, 2010; Mathey et al., 2011).

Die wichtigste Voraussetzung, all diese Themen im großen und kleinen Maßstab beantworten zu können, ist das Vorhandensein von Wissen über den Gebäudebestand sowie dessen Struktur (z. B. Funktion, Alter, Größe, Form, Anordnung, stoffliche Zusammensetzung), Nutzungsparameter (z. B. Wohneinheiten, Bewohner, Energieverbrauch) und Dynamik (z. B. Abriss, Neubau, Umnutzung, Sanierung). Dies setzt das Vorhandensein räumlicher Informationen (Daten) voraus, auf deren Grundlage mithilfe von Modellen neue Erkenntnisse (Wissen) gewonnen werden können. Erst eine kleinräumige Beschreibung der Siedlungsstruktur erlaubt es, Hyphothesen zu prüfen, neue Muster zu finden und Prozesse zu modellieren. Die gewonnenen Erkenntnisse dienen dann als Grundlage für Entscheidungen in der Planungspraxis.

1.2 Problemstellung

Trotz der großen Bedeutung des Gebäudebestandes stehen der Wissenschaft und Praxis nur wenig aktuelle, oftmals räumlich stark aggregierte oder sehr kostenintensive Daten zur Siedlungsstruktur und deren Historie zur Verfügung. Das Wissen über den deutschen Gebäudebestand hinsichtlich Umfang, stofflicher Zusammensetzung, Dynamik und seiner Lokalisierung ist dabei äußerst gering (Bader et al., 2001; Gruen et al., 2009). So ist die kleinste räumliche Bezugseinheit der amtlichen Flächen- und Gebäudestatistik in Deutschland die Gemeindeebene, deren jährlich aktualisierte Zahlen auf einer Fortschreibung der letzten Vollerhebung von 1987 (Alte Bundesländer) und 1995 (Neue Bundesländer) beruhen. Mit Fokus auf den Wohnbau liefert die amtliche Stastistik eine eingeschränkte und wenig differenzierte Sicht auf den Bestand. Die Daten sind deshalb nur für regionale oder überregionale Fragenstellungen mit geringem Anspruch auf räumliche und thematische Kleinteiligkeit geeignet.

Einige kommunale Informationssysteme bieten ein breites thematisches Spektrum von Informationen auf kleinräumiger Ebene an. Es sei an dieser Stelle exemplarisch auf das umfangreiche Datenangebot vom Umweltatlas Berlin (Senatsverwaltung für Stadtentwicklung, 2012) verwiesen. Nach Ergebnissen einer Online-Befragung deutscher Groß- und Mittelstädte besteht allerdings auch auf kommunaler Ebene Nachholebedarf hinsichtlich der Datenverfügbarkeit zur Gebäudenutzung (68 %), Einwohnerzahl (68 %), Strukturtyp (65 %), Wohnungszahl (60 %) und Gebäudezahl (53 %) (Wolfram, 2010). Kleinräumige statistische Daten liegen überwiegend nur für stark verstädterte Räume vor, weshalb die Datenlandschaft einem „Flickenteppich" gleicht (Haußmann, 2012). Fehlende Suchdienste, der schwierige Datenzugang und die äußerst große Heterogenität stellen weitere Hürden bei einer kommunalübergreifenden Nutzung dieser Daten dar.

Dem Mangel an kleinräumigen Daten zur Siedlungsstruktur steht ein großes Angebot von Karten, Geodaten und Geodiensten gegenüber, die das Gebäude im Grundriss abbilden. Die rasante Entwicklung der Luftbild- und Satellitenfernerkundung sowie das flugzeuggetragene Laserscanning erlauben heutzutage eine effiziente Erfassung von 2D-Gebäudegrundrissen oder die Generierung von 3D-Gebäudemodellen (Baltsavias et al., 2001; Gruen et al., 1995, 1997). Weiterhin können Gebäudegrundrisse auch aus gescannten analogen topographischen Karten gewonnen und in ein Geographisches Informationssystem (GIS) integriert werden (u. a. Frischknecht & Kanani, 1998; Kwon, 2000; Maderlechner & Mayer, 1994; Stengele, 1995; Suzuki & Yamada, 1990; Tuia & Kaiser, 2007; Meinel et al., 2009). Dies ermöglicht die Analyse der Dynamik des Gebäudebestandes. Mit Einführung neuer Produkte der amtlichen Vermessung (Hausumringe) stehen mit den amtlichen Hausumringen nunmehr auch flächendeckend homogenisierte Gebäudegrundrissdaten aus dem Liegenschaftskataster zur Verfügung.

Ein Problem der meisten digitalen Gebäudedatensätze ist, dass diese keine expliziten semantischen Informationen zum Gebäudetyp, der Geschossanzahl oder dem Baualter enthalten. Diese Information ist jedoch besonders wichtig, um verschiedene Merkmale zur Beschreibung der Siedlungsstruktur abzuleiten. Internetbasierte Bilddienste wie Google Maps, Google Street View oder Bing Maps erlauben zwar die Betrachtung einzelner Gebäude aus verschiedenen Perspektiven, von Interesse ist jedoch häufig die Verteilung, Anordnung und Struktur der Gebäude für ein gesamtes Stadtgebiet oder eine Region. Um an diese Information zu gelangen, sind sehr zeit- und kostenintensive Kartierungen mittels Luftbildinterpretation und Begehungen vor Ort nötig. Zur Verringerung des Erfassungsaufwandes und der Komplexität erfolgt die Interpretation häufig auf einer höheren Abstraktionsebene, wie den Stadtstrukturtypen. Diese stellen eine stadträumliche Gliederung nach Merkmalen der Flächennutzung und der Bebauungsstruktur auf Baublockebene dar. Mit dieser Abstraktion nimmt man jedoch einen größeren Informationsverlust in Kauf, da wichtige Detailinformationen der Abstraktion zum Opfer fallen.

Der Mensch ist in der Lage, charakteristische morphologische Formen der Bebauung in topographischen Karten mithilfe des Sehens und Verstehens zu identifizieren. Grundlegende Voraussetzung ist das Wissen über die Objekte und deren Abbildung im Grundriss. So kann bereits ein Laie ein Einfamilienhaus allein anhand der Größe und Form von einer Zeilenbebauung unterscheiden. Städtebauer, Kunsthistoriker, Architekten, Stadtmorphologen sind mit ihrem Expertenwissen hingegen in der Lage, typische Bebauungsmuster einer Epoche zuzuordnen und Rückschlüsse auf das mögliche Baualter, die Geschosszahl, das verwendete Baumaterial oder die aktuelle Gebäudenutzung zu machen. Dies ist möglich, da die urbane Form in ihrer historisch bedingten Entwicklung bestimmten architektonischen Gestaltungsleitsätzen folgt, die sich in ihrer physiognomischen Form abzeichnen (Batty & Longley, 1994). Somit lässt sich die Geschichte der Stadtplanung und deren entwickelten Leitbilder und Instrumente auch in der Grundrissgestalt ablesen, da Gebäudegrundrisse eine Menge impliziter Information (z. B. Größe, Form und räumliche Anordnung) besitzen.

Da eine manuelle Interpretation einzelner Gebäudegrundrisse sehr zeitaufwändig und oft durch subjektive Einflüsse geprägt ist, wird mittels Computertechnologie versucht, diesen Prozess zu simulieren. Methoden der Bildanalyse, Mustererkennung und des Bildverstehens erlauben es, Objekte und Muster automatisch in Bildern oder Vektordaten zu erkennen und zu klassifizieren. Die vorliegende Dissertation beschäftigt sich deshalb mit der Frage nach Methoden zur Klassifizierung von Gebäudegrundrissen mit dem Ziel, kleinräumige Informationen zur Siedlungsstruktur, wie etwa zur Bebauungsstruktur, der Geschossflächendichte oder der räumlichen Verteilung von Wohnungen und Einwohnern, automatisch abzuleiten.

1.3 Forschungsstand

Mit der automatisierten Klassifizierung von Gebäuden und Bebauungsstrukturtypen haben sich im Wesentlichen zwei Gruppen beschäftigt. Zum einen Forscher der (quantitativen) Stadtgeographie, die das Ziel verfolgen, neue Erkenntnisse über die Siedlungsstruktur und ihren zugrundeliegenden Prozessen zu gewinnen. Auf der anderen Seite spielt die Klassifizierung von Gebäudegrundrissen in der digitalen Kartographie eine bedeutende Rolle, da mit dieser Information Prozesse bei der Kartengeneralisierung zielgerichteter gesteuert werden können. Eine umfassende Darstellung des Forschungsstandes ist gesondert im Kapitel 4 zu finden. An dieser Stelle werden nur die wichtigsten Aussagen zusammengefasst.

Die ersten Forschungsarbeiten zur Untersuchung der Stadtstruktur basieren auf Fernerkundungsdaten. Die sehr niedrige Bodenauflösung ließ anfangs nur eine spektrale Beschreibung und Klassifizierung der Bodenbedeckung auf Pixelebene zu. Mit Entwicklung hochauflösender Fernerkundungssysteme beschäftigte sich die Forschung mit der Klassifikation von Landnutzungstypen. Dies führte auch zur Entwicklung objektbasierter Methoden in der Fernerkundung, mit denen das Bild zunächst über einen Segmentierungsprozess in homogene Bildregionen zerlegt, mit diversen Objektmerkmalen (z. B. Farbe, Textur, Struktur, Topologie, Kontext etc.) beschrieben und anschließend klassifiziert wurde. Damit wurde der Grundstein für eine automatische Ableitung städtebaulicher Strukturtypen geschaffen. Forschungsarbeiten dazu dauern bis heute an. Der Umstieg von der analogen zur digitalen Kartenherstellung und das damit verbundene Verfügbarwerden digitaler topographischer Vektordaten führte

zur Entwicklung der rechnergestützten Generalisierung. Insbesondere für die Generalisierung topographischer Karten spielt die automatische Erkennung von Gebäudetypen und Siedlungsmustern eine bedeutende Rolle, um Gebäude zielgerichtet unter Wahrung typischer Formen zu generalisieren. Die in diesem Zusammenhang entwickelten Mustererkennungsansätze gewinnen in jüngster Zeit auch bei der Modellierung von Städten in der quantitativen Geographie an Bedeutung (Steiniger et al., 2008). Dabei ist eine Annäherung der beiden Disziplinen erkennbar und es kommen sowohl bildbasierte Ansätze der Fernerkundung als auch Methoden der Mustererkennung in Vektordaten zum Einsatz. Die zugrundeliegenden theoretischen Grundlagen werden in dem jungen Forschungsfeld Geographic Information Science (GIScience) erarbeitet.

Die Interpretation der Bebauungsmuster kann auf verschiedenen räumlichen Ebenen wie dem Baublock, einer Gebäudegruppe oder dem einzelnen Gebäude erfolgen. Die Klassifizierung einzelner Gebäude ist dabei ein recht junges Thema, da die fehlende Verfügbarkeit digitaler Daten dies bisher nicht zuließ. Folglich gibt es nur eine geringe Anzahl an Publikationen, die sich mit der Klassifizierung individueller Gebäudegrundrisse beschäftigt. Aus dem Forschungsstand geht hervor, dass die modellbasierten (wissensbasierten) Ansätze den datengetriebenen Ansätzen gegenüberstehen. Mit zunehmender Komplexität der Fragestellung und größeren Anforderungen an die semantische Auflösung gewinnen die datengetriebenen Ansätze der Mustererkennung immer mehr an Bedeutung. Bei den modellbasierten Ansätzen besteht die große Herausforderung, das nötige Wissen über die Gebäudetypen und deren Zusammenhänge zu erlangen und in einem Modell zu formalisieren. Liegt kein oder nur sehr wenig Wissen vor, kommen datengetriebene Ansätze zum Einsatz, mit denen das Wissen automatisch mit Methoden des maschinellen Lernens erlernt werden können.

Aus dem aktuellen Forschungsstand lassen sich folgende Defizite erkennen (vgl. Kapitel 4):

- geringe thematische Auflösung bei der Modellierung
- wenig Erfahrungen zum Einsatz maschineller Lernverfahren
- unzureichende Genauigkeitsabschätzung
- begrenzte Anzahl verwendeter Merkmale
- fehlende Operationalisierung für großflächige Anwendungen
- geringe Flexibilität
- wenig Erfahrung bei der Anwendung auf Geobasisdaten in Deutschland

Aus diesen Defiziten und der praktischen Problemstellung (vgl. 1.2) ergibt sich die im nächsten Abschnitt formulierte Zielsetzung.

1.4 Zielsetzung und Forschungsfragen

Allgemeines Ziel ist die automatische Informationsgewinnung aus geotopographischen Daten. Im Speziellen beschäftigt sich die vorliegende Arbeit mit der Entwicklung und Untersuchung methodischer Bausteine zur automatischen Klassifizierung von Gebäudegrundrissen für die Ableitung siedlungsstruktureller Kennzahlen. Dabei werden die aktuellen Defizite aus dem Forschungsstand berücksichtigt.

Im Rahmen der Arbeit sollen Methoden der Datenintegration und der Gewinnung von Merkmalen erarbeitet sowie Klassifikationsverfahren der Mustererkennung und des maschinellen Lernens angewendet werden. Dabei ist zunächst konzeptionell eine geeignete Erkennungsstrategie zu erarbeiten, die allein auf Grundlage automatisch abgeleiteter Merkmale beruht. Das entwickelte Verfahren sollte möglichst flexibel sein, um eine Übertragbarkeit auf andere Daten und Fragestellungen zu ermöglichen. Es sollte auch in einer GIS-Umgebung eingebettet werden können und eine Anwendung auf große Untersuchungsgebiete erlauben. Anhand verschiedener Untersuchungsgebiete und unter Nutzung verschiedener Eingangsdaten sollen die entwickelten methodischen Bausteine getestet und bewertet werden. In diesem Zusammenhang soll auch geprüft werden, welchen Einfluss verschiedene Faktoren auf die Genauigkeit haben.

Aus dem oben genannten allgemeinen Ziel ergeben sich folgende Forschungsfragen, die im Rahmen dieser Arbeit beantwortet werden sollen.

- Welche Anforderungen werden an Gebäudegrundrisse gestellt und welche Datengrundlagen sind geeignet?
- Welche gebäudebeschreibenden Merkmale können automatisch aus den Daten abgeleitet werden?
- Welche Merkmale sind wichtig für die Klassifizierung?
- Welche Klassifikationsverfahren der Mustererkennung und des maschinellen Lernens sind geeignet?
- Welche Klassifikationsgenauigkeit kann erreicht werden?
- Welche Faktoren haben Einfluss auf die Klassifikationsgenauigkeit?
- Ist ein erlernter Klassifikator übertragbar?
- Wie kann das Verfahren flexibel gehalten werden?

Eine Beantwortung der Fragen hat auch große praktische Relevanz. Würde es gelingen, Gebäudegrundrisse automatisch mit semantischer Information zum Gebäudetyp anzureichern, wäre dies eine wichtige Grundlage zur Schaffung kleinräumiger Grundlagendaten für die Planung, die aktuell nicht zur Verfügung stehen. Aus den gewonnenen Erkenntnissen können demnach auch Handlungsempfehlungen zur Nutzung von Geobasisdaten für siedlungsstrukturelle Analysen abgeleitet werden.

1.5 Thematische Einordnung

In der Arbeit werden Konzepte und Methoden verschiedener Disziplinen wie der Kartographie, der Stadtmorphologie, der Geoinformatik oder der Mustererkennung angewendet. Aufgrund dieses interdisziplinären Charakters ist eine eindeutige Zuordnung nicht möglich. Die Graphik in Abb. 1-1 stellt eine wissenschaftliche Verortung der Arbeit aus kartographischer Sicht dar.

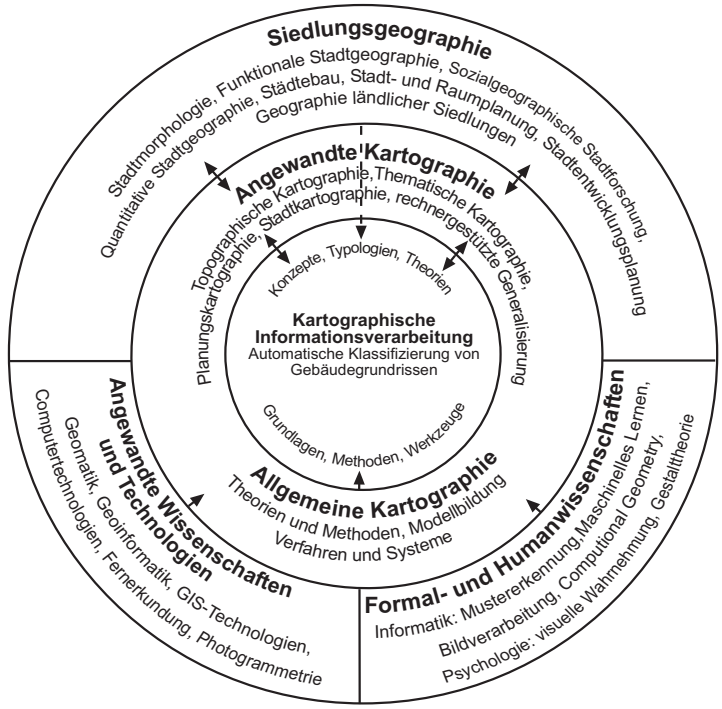

Abb. 1-1: Wissenschaftliche Einordnung der Arbeit

Die automatische Klassifizierung von Gebäudegrundrissen wird als Teilprozess einer Verarbeitungskette der kartographischen Informationsverarbeitung betrachtet mit dem Ziel, neue siedlungsraumbezogene Informationen zu gewinnen und kartographisch zu visualisieren. Die Forschungsarbeit ist deshalb im weitesten Sinne der Kartographie und im engeren Sinne der angewandten Kartographie zugeordnet.

Die allgemeine Kartographie, insbesondere die digitale Kartographie, liefert die Grundlagen und Methoden für die räumliche Informationsverarbeitung. Dabei macht die Kartographie als interdiziplinäre Wissenschaft auch Gebrauch von den Formal- und Humanwissenschaften sowie den angewandten Wissenschaften und Technologien (vgl. Buchroithner & Fernández, 2011). Eine entscheidende Rolle spielt dabei die Geoinformatik und die Technologie der Geo-Informationssysteme (GIS), da erst mit ihr eine computerbasierte Verarbeitung der raumbezogenen Daten in einem GIS möglich wird. Auf der anderen Seite spielen in dieser

Arbeit auch Methoden der Informatik wie die Mustererkennung, das maschinelle Lernen und die Bildverarbeitung eine wichtige Rolle.

Die Siedlungsgeographie als Teil der Humangeographie (Anthropogeographie) bestimmt das Thema und stellt die nötigen Konzepte und Typologien zur Beschreibung der Siedlungsstruktur, wie etwa die Gebäude und Baublöcke als Elemente des Siedlungsraumes, bereit. Sie schließt im Sinne von Borsdorf & Bender (2010) sowohl die interdisziplinäre Stadtgeographie (Lichtenberger, 1998; Heineberg, 2006c) als auch die Geographie ländlicher Siedlungen (Henkel, 2004) ein.

Eine wichtige Rolle in der Siedlungsgeographie spielen thematische Karten, die der Vermittlung neuer raumbezogener Erkenntnisse dienen. Die angewandte Kartographie, insbesondere die Thematische Kartographie (Witt, 1967; Arnberger, 1977), die Planungskartographie (ARL, 1991; Chudy, 2007) oder die Stadtkartographie (Gorki & Pape, 1987) halten nutzergerechte Darstellungsmethoden und Techniken für die Visualiserung raumbezogener Informationen bereit. Die Topographische Kartographie spielt hingegen eine wichtige Rolle bei der Wahl geeigneter Datengrundlagen, da sie Hintergrundwissen zur Herstellung topographischer Daten und Karten sowie der Gebäudeabbildung und -darstellung liefert (vgl. Hake et al., 2002). Auch aus dem Arbeitsfeld der automationsgestützten Generalisierung können Erkenntnisse genutzt werden. So ist die Klassifizierung von Objekten und das Erkennen von Mustern ein wichtiger Baustein für die zielgerichtete Steuerung von Generalisierungsprozessen (Brassel & Weibel, 1988).

Die Arbeit leistet sowohl für die angewandte Kartographie als auch indirekt für die Siedlungsgeographie einen Beitrag, was mit den radial nach außen gerichteten Pfeilen angedeutet werden soll. Mit der Entwicklung von Verfahren zur automatischen Klassifizierung von Gebäudegrundrissen können insbesondere kartographische Informationsverarbeitungsprozesse zur automatisierten Ableitung thematischer Karten zur Siedlungsstruktur unterstützt werden. Mit der Bereitstellung neuer Werkzeuge zur Gewinnung kleinräumiger Informationen zur Siedlungsstruktur leistet die Arbeit indirekt auch einen Beitrag für verschiedene Bereiche der Siedlungsgeographie. Durch kartographische Visualisierung der gewonnenen Informationen über kartographische Medien können diese u. a. zum Erkenntnisgewinn, der Bewertung oder als Entscheidunsgrundlage in der raumbezogenen Planung und Forschung genutzt werden. Gleichfalls können die gewonnenen Informationen weiterverarbeitet und in Monitoring- und Entscheidungsunterstützungssystemen sowie Szenarien-, Vorhersage- oder Simulationsmodellen verwendet werden.

Die Einordnung der Arbeit im Kontext der Kartographie spiegelt nur eine mögliche Sicht wider. Sie könnte gleichwohl dem interdiziplinären Forschungsfeld der Geoinformatik zugeordnet werden, in dem die Informationsgewinnung mittels räumlicher Datenanalyse eine zentrale Rolle spielt. Die Geoinformatik (engl. *Spatial Informatics*, *Geoinformatics* oder *Spatial Information Science*) „widmet sich der Entwicklung und Anwendung von Methoden und Konzepten der Informationstechnologie auf raumbezogene Fragestellungen“ (Bill, 2010: S. 18). Im angloamerikaischen Raum ist sie mit dem Forschungsfeld *Geographic Information Science*, kurz GIScience (Goodchild, 2010), vergleichbar, das sich mit der Entwicklung und Anwendung von Theorien, Methoden, Technologien und Daten auseinan-

dersetzt, um geographische Prozesse, Beziehungen und Muster zu verstehen[2] (Mark, 2003; Goodchild, 2010). Auch in der Geographie gewinnen mit dem enormen Fortschritt der Geoinformationstechnologie quantitative Methoden für die Lösung komplexer Fragestellungen wieder an Bedeutung (Thinh et al., 2011). So könnte die Arbeit ebenfalls im Forschungsfeld der quantitativen Geographie (engl. *quantitaive geography*) angesiedelt sein, dessen Aufgabenfeld die Analyse nummerischer Geodaten, die Entwicklung räumlicher Theorien und die Entwicklung und Prüfung mathematischer Modelle zur Beschreibung räumlicher Prozesse umfasst (Fotheringham et al., 2000).

1.6 Aufbau der Arbeit

Nach der Einleitung im *Kapitel 1* werden im *Kapitel 2* zunächst die theoretischen Grundlagen zur Siedlungsstruktur und deren raumbezogene Modellierung dargestellt. Die methodischen Grundlagen der Mustererkennung und des maschinellen Lernens sind im *Kapitel 3* wiedergegeben. Anschließend erfolgt im *Kapitel 4* eine ausführliche Vorstellung und Bewertung des aktuellen Forschungsstandes zur automatischen Klassifizierung der Siedlungsstruktur auf Grundlage räumlicher Daten. Im *Kapitel 5* werden die Anforderungen an das zu entwickelnde Verfahren und die Datengrundlagen im Hinblick auf die Zielstellung gestellt und Vorüberlegungen hinsichtlich der Methodik getroffen. Im *Kapitel 6* werden mögliche Datengrundlagen zum Gebäudegrundriss vorgestellt, die für das Verfahren in Betracht kommen. Anschließend werden im *Kapitel 7* das Gesamtverfahren sowie die methodischen Bausteine am Beispiel flächendeckend verfügbarer Geobasisdaten in Deutschland vorgestellt. Das entwickelte Verfahren wird anhand verschiedener Untersuchungsgebiete und unter Nutzung unterschiedlicher Eingangsdaten getestet. Die Ergebnisse werden im *Kapitel 8* vorgestellt und im Einzelnen diskutiert. Abschließend werden im *Kapitel 9* die eingangs formulierten Forschungsfragen beantwortet und die praktische Bedeutung der Ergebnisse diskutiert. In einem Ausblick werden die im Zusammenhang mit der Arbeit aufgeworfenen neuen Fragen und ungelösten Herausforderungen dargestellt.

[2] GIScience wurde vom *University Consortium for Geographic Information Science* (UCGIS) definiert als "the development and use of theories, methods, technology, and data for understanding geographic processes, relationships, and patterns." (UCGIS, 2002 zitiert in Mark, 2003)

2 Grundlagen zur Siedlungsstruktur

2.1 Begriffe und Konzepte

2.1.1 Raumbegriffe

Die Siedlungsstruktur ist ein häufig verwendeter Begriff der Raumwissenschaft, der zugleich eine erhebliche Bedeutungsvielfalt besitzt. Um diesen Begriff zu schärfen, bedarf es zunächst einer Konkretisierung des Raumkonzeptes auf das sich die Siedlungsstruktur bezieht.

In der Geographie wird der „Raum" sehr unterschiedlich gedeutet. Er kann beispielsweise als erdräumliche Adressierung, physischer Raum, Containerraum, relationaler Raum, Wahrnehmungsraum oder Handlungsraum aufgefasst werden (vgl. Blotevogel, 1995; Weichhart, 1999; Baumgärtner et al., 2009). In dieser Arbeit wird Bezug auf den physischen Raum genommen, bei dem es sich um einen „konkretisierbaren Ausschnitt der materiellen Welt im Sinne eines kontingenten Teilbereiches der Erdoberfläche handelt" (Weichhart, 1999: S. 76). In einer weiteren Betrachtung führt Weichhart das physisch-relationale Raumkonzept ein, mit dem „Relationen zwischen physisch-materiellen Dingen und Körpern" gemeint sind (Weichhart, 1999: S. 78). Damit ist der Raum nicht nur eine „leere" flächenbezogene Adressierung (z. B. die Stadt als Raum), sondern ergibt sich dieser erst aus dem Lage- und Beziehungsgefüge physisch-materieller Elemente. Dieses Raumkonzept spielt in der ökologischen Raumforschung, mit der Wirkungszusammenhänge zwischen dem Menschen und seiner natürlichen Umwelt untersucht werden, eine bedeutende Rolle. So definiert das Leibniz-Institut für ökologische Raumentwicklung Raum u. a. als „konkreter Ausschnitt der Erdoberfläche im Sinne des physischen Raums in seiner materiellen Beschaffenheit" (IÖR, 2010: S. 7).

Der Raum lässt sich in den *Siedlungsraum* und den *Freiraum* aufteilen (vgl. Tab. 2-1). Der Siedlungsraum, oft auch als die „gebaute Umwelt" bezeichnet, meint hier sowohl die städtischen als auch die ländlichen Siedlungen. Der Freiraum als Gegenbegriff zum Siedlungsraum „ist der Teil der Erdoberfläche, der in naturnahem Zustand ist oder dessen Nutzung mit seiner ökologischen Grundfunktion überwiegend verträglich ist" (Ritter, 2005: S. 315). Mit Fokus auf den Siedlungsraum, setzt sich dieser weiter aus Raumelementen (Siedlungsraumelementen) der Kategorie „Bebauung", „Infrastruktur" und „Freiflächen" zusammen. Die Siedlungsraumelemente werden durch Linien (z. B. Verkehrsnetz), Flächen (z. B. Fläche einer bestimmten Nutzung) oder Körper (z. B. Gebäude) repräsentiert.

Tab. 2-1: Gliederung des Raumes nach Ebenen und Elementen in Anlehnung an Arlt et al. (2010)

	Raum auf definierter Raumebene *(z. B. Quartier, Stadt, Gemeinde, Region)*			
Kategorien	Siedlungsraum			Freiraum
	Bebauung	Infrastruktur	Freifläche	
Raumelemente	• Wohngebäude • Öffentliche Gebäude • Industrie-/Gewerbegebäude	• Verkehrswegenetze • Netze der Ver- und Entsorgung • Netze der Information und Kommunikation • Einrichtungen, Leistungen und Dienste des Bildungs-, Gesundheits- und Sozialwesens	• Sportanlagen • Freizeitanlagen • Erholungsanlagen • öffentliche Grünanlagen • private Grünanlagen • Friedhöfe • künstliche Wasseranlagen	• Acker • Weide • Wiese • Wald • Moor • Wasser

2.1.2 Strukturbegriffe

Die Elemente des Siedlungsraums stehen nach gewissen Ordnungsprinzipien in Beziehung zueinander und bilden auf unterschiedlichen räumlichen Ebenen (z. B. Quartier, Stadt, Region) eine Struktur. Im Allgemeinen versteht man unter Struktur (von lat.: structura = Ordnung, Bau) ein „nach Regeln aus Elementen zu einer komplexen Ganzheit aufgebautes Ordnungsgefüge" (Brockhaus, 2005, Stichwort: Struktur). In Bezug auf den Siedlungsraum wird Struktur als die Art und Weise beschrieben, „wie unterschiedliche bauliche und nichtbauliche Elemente innerhalb der Siedlungsräume zusammengesetzt und miteinander verknüpft sind" (Arlt et al., 2010: S. 27). In diesem Zusammenhang führen die Autoren mit Bezug auf die Gliederung des Raumes in Tab. 2-1 spezifizierte Strukturbegriffe ein, die im Folgenden kurz erläutert werden.

Die „Raumstruktur" ist die übergeordnete Struktur, welche die räumliche und funktionale Ordnung der gesellschaftlich geprägten Siedlungs- und Freiraumelemente sowie auch der natürlichen Erscheinungen (z. B. Topographie, Geologie, Naturraum) beschreibt. Unter der „Siedlungsstruktur" versteht man Strukturen, die sich aus einem Ordnungsgefüge von baulichen und nichtbaulichen Elementen der Siedlungsraumkategorien Bebauung, Infrastruktur und der Freifläche zusammensetzen. Eine spezielle Betrachtung von Einzelbauten und Baugruppen innerhalb des Siedlungsraumes (z. B. nach unterschiedlichen Funktionen, Formen, Konstruktionen und Baustoffen) führt zum Begriff der „Bebauungsstruktur". Werden hingegen linienhafte Netze für Verkehr und Kommunikation oder punktbezogene soziale Angebote des Bildungs-, Gesundheits- und Sozialwesens innerhalb des Siedlungsraumes betrachtet, so spricht man von der „Infrastruktur". Mit der „Freiflächenstruktur" werden hingegen

die unbebauten Flächen in ihrer Anordnung im Siedlungsraum betrachtet. Gleiches gilt für die Elemente des Freiraums, welche die „Freiraumstruktur" charakterisieren.

Es sei erwähnt, dass der Begriff Siedlungsstruktur in der Forschungspraxis nicht immer konsequent verwendet wird. So sind besonders im städtischen Kontext auch die Begriffe „Stadtstruktur", „Städtebauliche Struktur" oder „urbane Struktur" geläufig.

2.1.3 Raumebenen der Siedlungsstruktur

Die Siedlungsstruktur kann als System aufgefasst werden, dessen Elemente durch Raumebenen im Sinne von Raummaßstabsebenen definiert sind (Arlt et al., 2010). Raumebenen weisen unterschiedliche Untersuchungsschwerpunkte in der Forschung auf. Auf Baublockebene stehen z. B. die Stadtgestalt, Bodenversiegelung oder die Energieeffizienz von Gebäuden im Fokus, wohingegen auf Stadtbezirksebene häufig Sozialstrukturen, funktionale Strukturen oder Suburbanisierungsprozesse untersucht werden. Auf gesamtstädtischer Ebene sind Wohnungsmarktanalysen von Bedeutung und auf regionaler Ebene werden Versorgungsstrukturen oder ökonomische Strukturen zum Untersuchungsschwerpunkt. In der Theorie wird der Betrachtungsmaßstab durch die jeweilige Fragestellung bestimmt, in der Praxis ist dieser jedoch häufig durch unzureichende Verfügbarkeit kleinräumiger Daten oder anderer Ressourcen limitiert.

Mit den Elementen der Siedlungsstruktur und deren Bezug zum Maßstab beschäftigen sich u. a. Arlt et al. (2010) und Blum et al. (2012), die hierfür die raumbezogenen Skalenebenen Mikro-, Meso- und Makroebene im Kontext der Siedlungsstruktur erörtern. Diese Skalenebenen werden unter Angabe von Maßstabsbereichen im Allgemeinen dazu verwendet, um klein-, mittel- und großräumige Phänomene der Umwelt zu beschreiben (vgl. Gibson et al., 2000). Auch in der Stadtmorphologie sind diese Begriffe im Hinblick auf die stadtmorphologischen Maßstabsebenen Parzelle, Block, Stadtteil und Region geläufig (Curdes, 1997). Im Folgenden werden die drei Ebenen am Beispiel konkreter, ausgewählter statistisch-administrativer Raumebenen vorgestellt (Tab. 2-2).

Auf Mikroebene werden die nicht mehr teilbaren Siedlungsraumelemente (Basisraumelemente) der Bebauung, Infrastruktur und der Freifläche charakterisiert. Das sind beispielsweise Gebäudekörper, Linien des Wegenetzes oder Freiflächen. Die Basisraumelemente sind durch Merkmale gekennzeichnet und können einem Typen zugewiesen werden. So können Gebäude nach ihrer Nutzung, Größe, Form oder dem verwendeten Baumaterial klassifiziert sein. Prinzipiell können Gebäude jedoch weiter in ihre Bestandteile (z. B. Garage, Haus, Treppen, Balkon oder Stockwerke) zerlegt werden (vgl. Gröger et al., 2004). Mit der standardisierten Beschreibung von 3D-Stadtmodellen mit CityGML[3] in höchster Detaillierungsstufe LoD 4 (Level of Detail 4) ist es beispielsweise möglich, Gebäude bis auf begehbare Innenräume und deren Objekte (Heizungsanlage, Möbel) aufzulösen (Kolbe, 2008). Bei einer

[3] *City Geography Markup Language* (CityGML) ist ein von der *Special Interest Group 3D* (SIG 3D) entwickeltes Anwendungsschema zur Speicherung und zum Austausch virtueller 3D-Stadtmodelle und gehört zum internationalen Standard des *Open Geospatial Consortium* (OGC). Siehe hierzu auch www.citygml.org.

derartig kleinräumigen Betrachtung werden die kleinsten Gebäudebestandteile dann zum Basiselement (Mikroebene), dessen Gefüge wiederum Strukturen auf Gebäudeebene (Mesoebene) bilden.

Tab. 2-2: Skalenebenen und administrative Raumebenen der Siedlungsstruktur (in Anlehnung an Wu, 1999; Arlt et al., 2010; Schiller et al., 2012)

	Skalenebene	Beschreibung	Raumebenen	Beispiel
Makroebene < 1:25 000	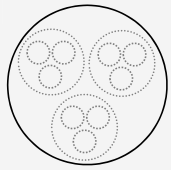	*Regionale Siedlungsstruktur* der räumlich-funktionalen Ordnung städtischer und gemeindlicher Siedlungsräume *in Bezug auf Siedlungsverband*	Regionen, Gemeinden, Länder	Siedlungsstrukturelle Region- bzw. Gebietstypen, Stadttypen
Mesoebene 1:25 000 - 1:100 000	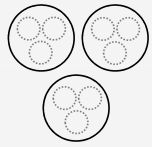	*Siedlungsstruktur* gebildet aus den strukturierenden Siedlungsraumelementen der Kategorien (Bebauung, Infrastruktur, Freifläche) *in Bezug auf Siedlungseinheiten*	Baublöcke, Quartiere, statistische Bezirke, Ortsteile, Stadtteile	Bebauungsstrukturtypen, Innerstädtische Zonierung, Segregationsmuster
Mikroebene > 1:25 000	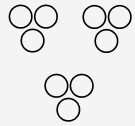	Betrachtung der individuellen *Siedlungsraumelemente*	Gebäudekörper, lineare Infrastruktur, Freifläche	Gebäudetypen, Straßentypen, Bodenbedeckungsart

Auf Mesoebene wird die Siedlungsstruktur aus der räumlichen und funktionalen Ordnung der Siedlungsraumelemente in Bezug auf Siedlungseinheiten gebildet. Je nach Betrachtungsmaßstab können die Siedlungseinheiten Baublöcke, Quartiere, Stadtteile oder die gesamte Stadt sein. Die verschiedenen Mesoebenen stehen dabei hierarchisch zueinander in Beziehung. Auf höchster Ebene kann ein Gefüge aus Struktureinheiten einer niederen Ebene gebildet werden, wie etwa einem Gefüge aus Baublöcken auf Ebene von Stadtteilen. Bei Verkleinerung des Betrachtungsmaßstabes treten dann die strukturierenden Raumelemente (Gebäude) zugunsten übergeordneter Einheiten (Baublöcke) in den Hintergrund (Schiller et al., 2012). Die Siedlungseinheit der betrachteten Raumebene wird auf übergeordneter Ebene dann selbst zum Siedlungsraumelement. Neben den Eigenschaften der Siedlungsraumelemente besitzt die aus den Elementen gebildete Struktur Eigenschaften (z. B. Dichte, Lage, Ausrichtung), die wiederum genutzt werden können, um neue Siedlungsraumelemente auf höherer räumlicher Ebene zu bilden. Zum theoretischen Verständnis komplexer hierarchischer Phänomene sei auf die aus der Systemtheorie bekannten Hierarchie-Konzepte verwiesen, mit denen eine vom absoluten Maßstab losgelöste Erklärung von Zusammenhängen zwischen Elementen unterschiedlicher Ebenen möglich wird (u. a. Levin, 1992; O'Neill, 1986; Ahl & Allen, 1996; Sheppard & McMaster, 2004).

Bei der Siedlungsstruktur auf Makroebene spricht man von „regionaler Siedlungsstruktur", die sich auf eine gesamte Region und somit einem Verband mehrerer Siedlungskörper be-

zieht (Arlt et al., 2010). Dabei wird die räumlich-funktionale Ordnung städtischer und gemeindlicher Siedlungsräume sowie die Verteilung und Vernetzung von Standorten in einer definierten Region verstanden. Als Beispiel seien in diesem Zusammenhang die siedlungsstrukturellen Gebietstypen vom BBSR auf Gemeinde-, Kreis- oder Regionsebene genannt (BBSR, 2012a).

In dieser Arbeit liegt der Fokus auf der Siedlungsstruktur mit Bezug auf der räumlichen Ebene der Gebäude und Baublöcke. Diese Ebene spielt besonders im Kontext der städtebaulichen Strukturplanung (Stadtstrukturplanung) eine wichtige Rolle (vgl. Albers & Ofen, 1995; Streich, 2005).

2.1.4 Siedlungsstrukturelle Merkmale

Siedlungsstrukturen lassen sich durch quantitative und qualitative Merkmale in Bezug auf administrative (z. B. Baublöcke, Stadtbezirke) oder geometrische Einheiten (z. B. Rasterzellen) beschreiben. Bevor die Merkmale genauer betrachtet werden, sollen zunächst verschiedene Sichtweisen der Siedlungsstruktur erörtert werden.

In der Stadtforschung werden sozio-ökonomische, funktionale und morphologische (morphogenetische) Strukturen unterschieden[4] (Heineberg, 2006c). Aus sozio-ökonomischer Sicht ist beispielsweise die räumliche Verteilung der Wohnungen und der Bevölkerung bedeutsam, aus funktionaler Sicht stehen hingegen Flächennutzungsarten sowie deren Funktionsräume (z. B. Einzugsbereiche lokaler Geschäftszentren, Schuleinzugsbereiche) im Vordergrund. Die morphologische Struktur ergibt sich aus der Grundriss-, Aufrissgestaltung und dem äußeren Erscheinungsbild der Siedlungselemente (z. B. Gebäude, Grundstücke, Straßen, Freiflächen). Bei einer morphogenetischen Betrachtung spielen neben der aktuell vorliegenden Grundriss- und Aufrissgestaltung auch historische Phänomene der Stadtentstehung eine Rolle (Heineberg, 2006c).

Morphologische und funktionale Strukturen einer Siedlung werden direkt durch die Stadtplanung bestimmt, wohingegen man auf sozio-ökonomische Strukturen nur indirekt (z. B. mit Sanierungskonzepten oder Wohnungsbauprogrammen) Einfluss nehmen kann (Streich, 2005). Die Strukturen sind Ergebnis einer zeitlichen Entwicklung und stehen in Beziehung zueinander. Neben den unter verschiedenen Einflüssen geprägten Wachstumsprozessen über die Zeit spielt die funktionale Komponente eine bedeutende Rolle bei der Formung der morphologischen Struktur. Zusammenhänge zwischen der Morphologie und der Funktion können dabei ausgenutzt werden, um von der Bebauungsform oder der Bodenbedeckungsstruktur auf die Flächennutzung zu schließen (Barnsley & Barr, 1997; Batty & Longley, 1994), wohlgleich Longley (2002) festhält, dass diese Zusammenhänge weiter untersucht werden müssen. Jüngste Arbeiten belegen außerdem einen Zusammenhang zwischen der Bebauungsstruktur und der Nutzung von Kraftfahrzeugen (Vance & Hedel, 2008). Ebenso haben

[4] Weitere sind u. a. funktions- und aktionsräumliche Strukturen, Wahrnehmungsstrukturen, Grün- und Freiflächenstrukturen, ökologische Strukturen (Heineberg, 2006c).

bestimmte funktionale Strukturen (z. B. Verkehrsanbindung, Industrie) Einfluss auf sozio-ökonomische Strukturen. Die drei Strukturkategorien sind demnach gegenseitigen Wechselwirkungen ausgesetzt (vgl. Abb. 2-1).

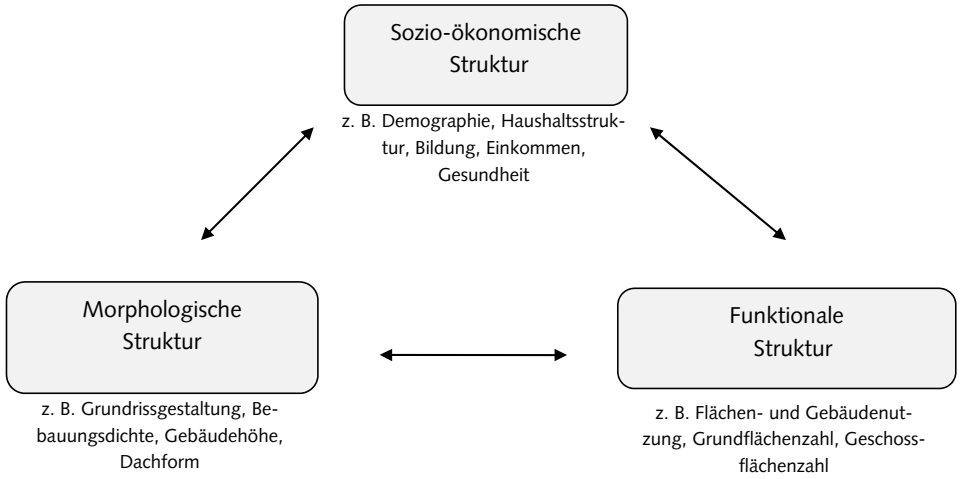

Abb. 2-1: Sichtweisen der Siedlungsstruktur

Möglichkeiten, die Siedlungsstruktur mit Merkmalen zu charakterisieren, sind sehr weit gefächert. Für die Beschreibung der funktionalen Struktur spielen qualitative Merkmale zur Flächen- und Gebäudenutzung eine bedeutende Rolle. Eine quantitative Beschreibung kann über städtebauliche Kenngrößen zur Nutzungsintensität, wie der Grundflächenzahl oder der Geschoßflächenzahl erfolgen. Für die Beschreibung der morphologischen Struktur sind Merkmale zur Größe, Form, Dichte und Anordnung von Gebäuden, der Netzdichte oder der Verteilung und Form der Freiflächen üblich (vgl. Curdes, 1997). Diese lassen sich aus Plänen, topographischen Karten und Luftbildern erschließen. Mit der Nutzung von Fernerkundungsdaten in der Stadtforschung werden zunehmend aus der Landschaftsökologie bekannte Strukturmaße (engl. *landscape metrics*) in den städtischen Kontext übernommen und zu stadtmorphologischen Strukturmaßen (engl. *urban metrics*) adaptiert (u. a. Herold et al., 2002, 2005; Jaeger et al., 2010a; Vanderhaegen & Canters, 2010; Yoshida & Omae, 2005). Mit ihnen kann insbesondere die räumliche Komposition und Konfiguration der Siedlungselemente quantitativ beschrieben werden. Zur Charakterisierung der Freiflächenstruktur sind Maße zum Grad der Bodenversiegelung (Versiegelungsgrad), Nutzung, Oberflächenbedeckung, Vegetationsanteil oder die Grünvolumenausstattung eine gängige Größe. Eine Beschreibung der Siedlungsstruktur mit sozio-ökonomischen Merkmalen ist sehr vielfältig. Typische Kenngrößen sind beispielsweise die Einwohnerdichte, die Anzahl der Haushalte mit bestimmten Altersgruppen, das mittlere Einkommen der Bewohner oder die Arbeitsplatzdichte.

Die morphologischen, funktionalen und sozio-ökonomischen Merkmale können unter dem Begriff der „siedlungsstrukturellen Merkmale" zusammengefasst werden. Die morphologischen und funktionalen Merkmale spielen in der Praxis die bedeutendere Rolle, da diese leichter zu erheben sind als Merkmale zur sozio-ökonomischen Struktur.

2.1.5 Strukturtypen

Zum Erforschen räumlicher Strukturen werden methodische Ansätze des typologischen Ordnens verwendet, um homogene, räumlich zusammenhängende Einheiten in Form von Strukturtypen zu bilden. Dazu werden Typologien eingesetzt, mit denen spezifische Erscheinungsformen von anderen Formen abgegrenzt werden können. In der Wissenschaft sind Typologien von zentraler Bedeutung, wenn es um die Strukturierung, Gruppierung und Benennung von Objekten der komplexen Wirklichkeit geht. Blum et al. (2010) setzen sich hierzu mit der Typenbildung in der Stadtforschung auseinander. Nach deren Auffassung können Typen auf Grundlage theoretisch-konzeptioneller Vorüberlegungen gebildet (Idealtypen) oder mithilfe eines empirischen Ansatzes, wie der Clusteranalyse, direkt aus Daten gewonnen werden. In der raumwissenschaftlichen Praxis bedient man sich häufig einem kombinierten empirisch-theoretischen Ansatz, in dem zunächst empirisch ermittelte Realtypen in einem weiteren wissensbasierten Schritt interpretiert, organisiert und mit einem Begriff bezeichnet werden und zu sogenannten „konstruierten Typen" führen (Blum et al., 2010).

Der „allgemeine Strukturtyp" und der „siedlungsraumbezogene Strukturtyp" sind in der Literatur in folgender Weise definiert:

- Der *allgemeine Strukturtyp* ist eine „auf ein Ordnungsgefüge bezogene Grundform bzw. eine Grundform bezüglich der Anordnung der Teile oder Elemente eines Systems und deren Beziehungen. Diese Grundform ist durch charakteristische, für das Forschungsvorhaben relevante Merkmale bestimmt und durch die Merkmalsausprägungen deutlich von anderen Grundformen abgegrenzt" (Arlt et al., 2010: S. 28).
- Der *siedlungsraumbezogene Strukturtyp* nimmt Bezug auf den Siedlungsraum und ist ein „spezifisches Ordnungs- und Beziehungsgefüge baulich-räumlicher Elemente als Objekt raumwissenschaftlicher Untersuchung" (Arlt et al., 2010: S. 28).

Die Bildung von Strukturtypen auf Grundlage festgelegter Merkmale kann auf unterschiedlicher Maßstabsebene erfolgen. Wichtig hierbei ist, dass jeder eingeführte Typ mindestens ein Merkmal besitzt, das sich von den anderen Typen unterscheidet. Das Forschungsgebiet der Stadtmorphologie beschäftigt sich dabei intensiv mit der morphologischen Gestalt von Siedlungen und deren Typisierung. Die Typologien reichen von morphologischen Grundformen von Gebäuden (Curdes, 1997), Typen der städtischen Wohnbebauung (Larkham & Jones, 1991), Straßennetztypen (Marshall, 2005) bis hin zu Archetypen von Städten (Jonas, 2009). In diesem Zusammenhang sei auch auf die einflussreiche Arbeit von Alexander (1977) verwiesen. In dieser wird eine formale „Mustersprache" (engl. *pattern language*) vorgestellt, mit der architektonische Prototypen (Entwurfsmuster) auf verschiedenen Maßstabsebenen (Städte, Gebäude, Konstruktionen) beschrieben und konsistent in Beziehung gesetzt werden.

Für die Beantwortung raumwissenschaftlicher Fragestellungen haben sich Strukturtypen als nützliches Werkzeug bewährt (Wickop et al., 1998; Pauleit & Duhme, 1999; Arlt et al., 2010). Auf Grundlage topographischer Karten sowie Luft- und Satellitenbildmaterial wird dabei die Siedlungsfläche in physiognomisch homogene Einheiten untergliedert. Wesentliche Kriterien für die Abgrenzung sind im Bild oder der Karte wahrnehmbare Merkmale zur Bebauungsdichte, dem Versieglungs- und Grünflächenanteil oder der Flächennutzung. In der Regel werden Baublöcke als Siedlungseinheiten verwendet, da diese eine administrative Einheit darstellen und sich besonders gut zur Beschreibung der städtebaulichen Struktur eignen. Strukturtypen dienen als methodisches Instrument, um sozio-ökonomische Fragestellungen in baulich-räumlichen Kategorien abzubilden (z. B. Wohnqualität, Stoffströme, stadtökologische und ökonomische Aspekte) (vgl. Streich, 2005). Dabei werden sie zur Schnittstelle inter- bzw. transdisziplinärer Untersuchungen, um die morphologische Struktur als Projektionsfläche verschiedener Fragestellungen anderer Teildisziplinen zu nutzen (Arlt et al., 2010). Die wichtigste Grundhypothese beim Einsatz des Stadtstrukturtypenansatzes ist, dass in städtebaulich und gebäudetypologisch ähnlichen Gebieten ebenfalls eine ähnliche, spezifische Nutzungsausprägung vorliegt (Schiller, 2010).

Der Strukturtypenansatz findet breite Anwendung in der Stadt-, Regional- und Infrastrukturplanung, wie etwa für die Modellierung von Stoffströmen, Wohnungsmärkten, Bodenversiegelung, Grünausstattung oder zur Schätzung zukünftiger Infrastrukturkosten (Blum & Gruhler, 2010). Die Tab. 2-3 zeigt die Bebauungsleittypen von Buchert et al. (2004), die auf Grundlage von Merkmalen wie der Gebäudegröße, Gebäudeform, Baualter, Überbauungsgrad und Stellung der Gebäude erarbeitet wurden und typische Gebäudemuster in Deutschland repräsentieren. Für weitere Ausführungen zu verschiedenen Typologien der Bebauung sei auf Kap. 7.2 verwiesen.

Tab. 2-3: Bebauungsleittypen des Wohngebäudebestandes (Quelle: Buchert et al., 2004: S. 26)

Strukturtyp	Erscheinungsform	Strukturtyp	Erscheinungsform
Freistehende Ein- und Zweifamilienhäuser	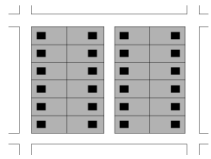	Zeilenstrukturen	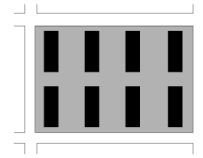
Ein- und Zweifamilienhäuser als Doppelhäuser	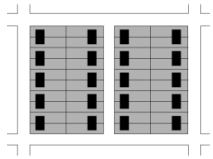	Geschosswohnungsbau in offener Baustruktur	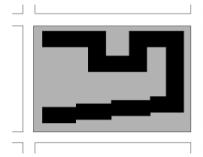
Ein- und Zweifamilienhäuser in Reihenhaus- und Gartenhofbauweise	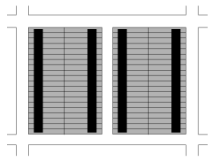	Aufgelockerte Blockstrukturen	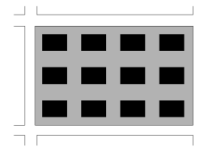
Verdichtete Blockstrukturen	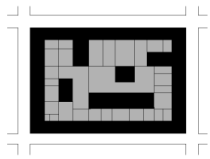		

2.1.6 Gebäude als Element des Siedlungsraums

Das Gebäude ist neben der Infrastruktur das bedeutendste physische Siedlungselement, da es das äußere Erscheinungsbild und die physische Struktur einer Stadt maßgeblich prägt und sich aus deren Nutzung räumliche Verteilungsmuster von Wohnungen und Arbeitsstätten ergeben. Wegen der zentralen Bedeutung für die Arbeit muss darum näher auf den Gebäudebegriff eingegangen werden.

Gebäude sind eine Untermenge der Bauwerke und werden umgangssprachlich auch als Häuser bezeichnet. Der Oberbegriff „Bauwerk" (auch bauliche Anlage) steht für „größere, standortgebundene und meist dauerhafte Konstruktionen", die durch konstruktive Festigkeit und relative Beständigkeit ausgezeichnet sind (Seidl, 2006: S. 69). Gebäude sind nach der Musterbauordnung[5] (MBO) „selbstständig benutzbare, überdeckte bauliche Anlagen, die von Menschen betreten werden können und geeignet oder bestimmt sind, dem Schutz von Menschen, Tieren oder Sachen zu dienen." (MBO, 2002: S. 5). Diese Definition entspricht weitestgehend der Definition der Bautätigkeitsstatistik (Destatis, 2011c) sowie den Vermes-

[5] Die Musterbauordnung ist eine Standard- und Mindestbauordnung, die den Ländern als Grundlage für deren jeweilige Landesbauordnungen dient. Diese wurde zuletzt am 8. November 2002 überarbeitet, um eine Vereinfachung des Verfahrens- und materiellen Bauordnungsrechts der Länder zu erreichen.

sungs- und Katastergesetzen der Länder (z. B. VermKatG NRW, 2005). Ein Gebäude besitzt in diesem Sinne nicht zwingend Wände oder Keller, jedoch immer ein Dach. Ansonsten treffen alle Eigenschaften eines Bauwerks auch auf ein Gebäude zu. Unterirdische Bauwerke, die von Menschen betreten werden können und dem Schutz von Menschen, Tieren oder Sachen dienen, werden nach dem Begriffsverständnis der Bautätigkeitsstatistik und Musterbauordnung ebenfalls zu den Gebäuden gezählt. Gleiches gilt für Ferien-, Sommer- und Wochenendhäuser mit einer Mindestwohnfläche von 50 m² (Destatis, 2011c). Keine in der Statistik geführten Gebäude sind hingegen behelfsmäßige Nichtwohnbauten, freistehende selbständige Konstruktionen und Unterkünfte mit begrenzter Nutzungsdauer oder von geringem Wohnwert (z. B. Baracken, Gartenlauben, Behelfsheime, Baustelleneinrichtungen, Wohncontainer, Schacht- und Stollenbauten des Bergbaus).

Aus bauordnungsrechtlicher Sicht werden Gebäude nach *Wohngebäuden* und *Nichtwohngebäuden* untergliedert. Wohngebäude sind Gebäude, deren Nutzfläche mindestens zur Hälfte zu Wohnzwecken dient, der Rest wird den Nichtwohngebäuden zugeordnet. Der Wohnflächenanteil wird am Anteil der Wohnfläche nach Wohnflächenverordnung (WoFlV) gemessen. Die Nutzungsarten für Gebäude sind in der DIN 277 festgelegt (Destatis, 2011b). Mithilfe dieser Norm werden Grundflächen und Rauminhalte genau festgehalten, um z. B. die Wirtschaftlichkeit eines Gebäudes zu messen oder Heizkosten abzuschätzen. Gebäude lassen sich jedoch nach einer Vielzahl von Kriterien typisieren, wie beispielsweise nach der Nutzung (Wohngebäude, Nichtwohngebäude), der Wohnform (Einfamilienhäuser, Zweifamilienhäuser oder Mehrfamilienhäuser), der Bauform und -art (Flach- oder Hochbau, Atriumhaus, Bungalow, Hof-Haus, Wohnblock, Wohnturm), den Baustoffen (Backstein-, Holz-, Glashaus), der Bauweise (Fachwerkhaus, Plattenbauweise) oder nach sozialer Bedeutung (Schloss, Hütte, Baracke) (Seidl, 2006).

Nach dem Begriffsverständnis der Gebäude- und Wohnungsstatistik gilt „jedes freistehende Gebäude oder bei zusammenhängender Bebauung (z. B. Doppel- und Reihenhäuser) jedes Gebäude, das durch eine vom Dach bis zum Keller reichende Brandmauer von anderen Gebäuden getrennt ist“ als *einzelnes Gebäude* (Destatis, 2011c: S. 4). Aus den Erläuterungen Gebäude- und Wohnungsstatistik geht weiter hervor, dass selbst zusammenhängende Gebäudeeinheiten ohne Brandmauer als einzelne Gebäude zählen, „wenn sie ein eigenes Erschließungssystem (eigener Zugang und eigenes Treppenhaus) besitzen und für sich benutzbar sind“ (Destatis, 2011c: S. 4). Häuserzeilen des Mehrfamilienhausbaus oder Reihenhäuser bestehen somit aus mehreren aneinandergereihten Einzelgebäuden (mit je einem Hauseingang). In der Literatur, insbesondere aus dem Bereich der Fernerkundung, werden häufig extrahierte Gebäuderegionen, die zum Teil ganze Häuserzeilen- und Blocks mit mehreren Einzelgebäuden repräsentieren, fälschlicherweise auch als Gebäude bzw. „building“ bezeichnet (Dey et al., 2011; Lee et al., 2003). Bei der Interpretation von Daten sollte deshalb stets die dahinterliegende Gebäudedefinition hinterfragt werden.

Christopher Alexander unterscheidet in seiner formalen „Muster-Sprache" (Alexander, 1977) explizit Einzelgebäude und Gebäudekomplexe[6], wie beispielsweise Reihenhäuser. In Anlehnung daran wird in dieser Arbeit der Begriff *Gebäuderegion* eingeführt, der für eine Gruppe unmittelbar benachbarter Einzelgebäude steht. Der Begriff *Einzelgebäude* wird nach Lesart der in der amtlichen Statistik verwendeten Definition zum „einzelnen Gebäude" verstanden.

2.1.7 Baublock als räumliche Siedlungseinheit

Aus städtebaulicher Sicht ist der Baublock, oft auch nur „Block" bezeichnet, die kleinste städtebauliche Einheit. Curdes definiert diesen als „eine von Straßen allseitig umschlossene Gruppe von Parzellen [...] auf denen die Gebäude mit der Frontseite zu Straßen orientiert sind, und die mindestens auf zwei, häufig auf vier gegenüberliegenden Seiten mit Gebäuden bebaut sind." (Curdes, 1997: S. 207). Diese Definition wird einer Modellierung des gesamten Siedlungsraumes nicht ganz gerecht, da in peripherer und besonders ländlicher Lage eine Parzelle nicht immer allseitig von Straßen umschlossen ist. Eine in dieser Hinsicht weichere Definition gibt Conzen (1960), nach der ein Baublock (engl. *street block*) eine Parzelle oder eine Gruppe benachbarter Parzellen ist, die teilweise oder ganz von Straßen umgrenzt ist.

Eine für den europäischen Raum zutreffende Definition gibt das Lexikon der Geoinformatik. Demnach ist der Baublock „Teil eines überwiegend bebauten Baugebietes, der in der Regel allseits von topographischen Linien, insbesondere von Straßen oder Wegen, umschlossen ist." (Bill & Zehner, 2001; mit Bezug auf Luft & Bender, 1998). Analog dazu ist die Modelldefinition im Amtlichen Liegenschaftskatasterinformationssystem (ALKIS®), in dem der Baublock als ein Teil der Erdoberfläche beschrieben ist, „der von einer festgelegten Grenzlinie umschlossen ist und Teile einer Gemeinde definiert" (AdV, 2008b: S. 478). Nach dieser Auffassung muss der Baublock weder bebaut und noch unmittelbar von einer Straße umsäumt sein, sondern kann von anderen linearen Elementen (z. B. Fluss, Eisenbahn oder einer definierten Flurstücksgrenze) begrenzt sein.

Aus den Empfehlungen zur kommunalen Gebietsgliederung (Deutscher Städtetag, 1991) geht hervor, Baublöcke und Blockseiten als kleinräumige Bezugseinheit zur Erfassung kommunaler statistischer Daten (z. B. Bevölkerung, Haushalte, etc.) zu nutzen. Im Informationssystem des Statistischen Amtes München ist der Baublock beispielsweise „ein zusammenhängender Komplex von Grundstücken, der möglichst allseitig durch Straßen, Wege, Eisenbahnlinien, Wasserläufe oder sonstige markante topographische Linien begrenzt – nicht aber durchschnitten – wird." (StatAmt München, 2011).

Der Baublock besteht damit nur aus Grundstücken und schließt keine Verkehrsflächen ein. In räumlichen Informationssystemen werden Straßen jedoch teilweise nur linienhaft model-

[6] „Bei Gebäudekomplexen in dichter Bebauung besteht der einfachste Weg, ihre menschlichen Teile ablesbar zu machen, darin, sie aus Einzelgebäuden mit schmalen Fronten zusammenzusetzen, jedes mit eigener innerer Stiege. Das ist die Grundstruktur des städtischen Reihenhauses." (Alexander et al., 1995: S. 507–508).

liert. Aus dem Straßengeviert können dann Baublöcke in grober Annäherung abgeleitet werden (vgl. Meinel et al., 2008a). In Anlehnung an die begriffliche Unterscheidung des Netto- und Bruttowohnbaulandes (Müller & Korda, 1999) werden die Begriffe *Bruttobaublöcke* und *Nettobaublöcke* eingeführt. Bruttobaublöcke haben im Gegensatz zu den Nettobaublöcken die Flächen der Erschließungsstraßen enthalten, was bedeutet, dass die Kanten der Baublocke gleichzeitig die Straßenachsen repräsentieren aus denen das Verkehrsnetz aufgespannt ist. Die Baublöcke der Münchner Kommunalstatistik sind demnach Nettobaublöcke. Im ALKIS® sind hingegen beide Modellierungsarten möglich, dessen Art über ein Attribut spezifiziert werden kann (AdV, 2008b: S. 478). In dieser Arbeit ist mit dem Begriff Baublock von nun an stets der Bruttobaublock gemeint.

2.2 Raumbezogene Modellierung der Siedlungsstruktur

2.2.1 Abstraktion der Realität

Für die Beschreibung der Realität, wie beispielsweise den Siedlungsraum mit seinen baulichen und nichtbaulichen Elementen, werden Modelle eingesetzt. Mit einem Modell wird der Versuch unternommen, „die komplexe Wirklichkeit verständlich und anschaulich darzustellen", in dem die „reale Welt und die darin auftretenden Zusammenhänge und Prozesse" abstrahiert und idealisiert werden (Bill & Zehner, 2001: S. 179). Sie können je nach Zweck unterschiedliche Formen, wie z. B. physische Modelle, logische Ausdrücke, mathematische Gleichungen, graphische Darstellungen, Datenmodelle oder Algorithmen annehmen. Ferner kann ein Modell ein abstrahiertes Abbild eines realen Objektes, einer ganzen Gruppierung von Einzelobjekten oder eines Ablaufes bzw. einer Strategie sein und umfasst Objekte, Begriffe und Prozesse (Sester, 1995). Wichtig ist, dass Modelle immer einen zielgerichteten und zweckgebundenen Ausschnitt der Realität repräsentieren. Erst diese zweckmäßige Sicht auf die Dinge bestimmt die Art der Modellierung und den Grad der Abstraktion.

In einem Modellbildungsprozess wird festgelegt, welcher Ausschnitt der Realität abgebildet und in welcher Form das Wissen repräsentiert wird (Sester, 1995). Eine menschliche Form der Repräsentation wäre die natürliche Sprache, mit der die Umwelt beschrieben und mittels audio-visueller Zeichen kommuniziert wird. Bei computerbasierten Modellen erfolgt die Repräsentation in Form einer Beschreibungssprache (z. B. objektorientierte Darstellung in einer Datenbank). Eine wichtige graphische Repräsentationsform sind kartographische Modelle, die der Kommunikation räumlicher Sachverhalte unter Nutzung eines definierten Zeichenvorrats dienen.

2.2.2 Kartographische Modellbildung

Kartographische Modelle sind für die Wissenschaft, Politik, Planung und Gesellschaft ein wichtiges Mittel, um raum-, sach- und zeitbezogene Informationen zu gewinnen, in Entscheidungsprozessen einzubinden und mithilfe kartographischer Darstellungen zu kommunizieren. Die kartographische Modellierung von Siedlungen erfährt bereits eine lange Tradition und geht mit dem womöglich ältesten maßstabstreuen Stadtplan der Welt – dem in Ton geritzten Plan von Nippur – bis näherungsweise auf das Jahr 1 500 v. Chr. zurück (Harley & Woodward, 1987). Die verstärkte wissenschaftliche Beschäftigung mit dem Erdbild, die Seefahrt, die Entwicklungen von Druck- und Vervielfältigungstechnologien sowie gesellschaftliche Bedürfnisse (insb. militärisch, wissenschaftlich, wirtschaftlich) führten dazu, dass bereits Ende der 1960er Jahre von der Karte als „modernes Massenerzeugnis" gesprochen wurde (Witt, 1967: S. 11). Die Kartographie hat sich darum im letzten Jahrhundert als eigene Wissenschaft, Technik und Kunst der Herstellung von Karten und kartenverwandten Darstellungen etabliert (ICA, 1973).

Technologische Veränderungen führten zum Paradigmenwechsel in der Kartographie, wie z. B. die Automatisierung der Analogkartenproduktion, der Einzug geographischer Informationssysteme (GIS) und Bildschirmkarten, die Demokratisierung von Datennutzung oder die Multimediakartographie (Hruby & Guerrero, 2008). Mit Einzug der Web 2.0 Kartographie und der Möglichkeit privater Personen, auf freiwilliger Basis zur Geodatenaufnahme beizutragen, erfährt die Kartographie einen neuen Wandel. Mit den nutzergenerierten Geodaten (engl. *Volunteered geographic information,* VGI), wie beispielsweise beim OpenStreetMap Projekt, verschmelzen Kartenproduzent und Kartenkonsument zunehmend (Glasze, 2009).

Allgemein befasst sich die Kartographie als Fachgebiet „mit dem Sammeln, Verarbeiten, Speichern und Auswerten raumbezogener Informationen sowie in besonderer Weise mit deren Veranschaulichung durch kartographische Darstellungen" (Hake et al., 2002)[7]. Dabei ist sie durch andere geowissenschaftliche Disziplinen wie der Geodäsie, Geoinformatik, Photogrammetrie und Fernerkundung aber auch mit den Informations- und Kommunikationswissenschaften verflochten bzw. ist sie durch diese geprägt. Für weitere Ausführungen zur Kartographie im Kontext der Wissenschaften sei auf Buchroithner & Fernández (2011) verwiesen.

Die Karte als bedeutendste Kartographische Darstellung[8] ist ein „maßgebundenes und strukturiertes Modell räumlicher Bezüge. Sie ist im weiteren Sinne ein digitales, graphikbezogenes Modell, im engeren Sinne ein graphisches (analoges) Modell" (Hake 1988 zitiert in Hake et al., 2002: S. 25). Karten sind Ergebnis eines kartographischen Modellbildungs- und Kommunikationsprozesses und dienen der Erkenntnisgewinnung (näheres hierzu in Ogrissek, 1987). In der kartographischen Modelltheorie werden in der Regel die drei Modellarten Pri-

[7] Die Definition der *International Cartographic Association* (ICA) lautet: "Cartography is the discipline dealing with the conception, production, dissemination and study of maps." (NZCS, 1995).

[8] Unter einer kartographischen Darstellung werden Karten und andere kartenverwandte Darstellungen verstanden.

mär-, Sekundär- und Tertiärmodell unterschieden, die sich durch deren Entstehung und den Gebrauch ergeben (vgl. Hake et al., 2002; Lange, 2005).

Die Modellfolge des kartographischen Modellbildungsprozesses ist in Abb. 2-2 dargestellt. Die Objekte der Landschaft, wie beispielsweise die Siedlungsraumelemente Gebäude, Flurstücke und Straßen, werden durch den Topographen mittels terrestrischer oder photogrammetrischer Aufnahme in einem *Primärmodell* erfasst. Während der Erfassung erfolgt eine Abstraktion durch Objektklassenbildung und Generalisierung. So wird beispielsweise bei der topographischen Aufnahme die Geometrie des Gebäudes bereits in geringem Maße vereinfacht erfasst und der Objektklasse „Gebäude" zugeordnet. In der klassischen analogen Kartenherstellung erfolgte die Erfassung in Messprotokollen, Feldbüchern sowie -skizzen der topographischen Landesaufnahme. Die Primärmodelle werden heute überwiegend digital in Geoinformationssystemen gehalten.

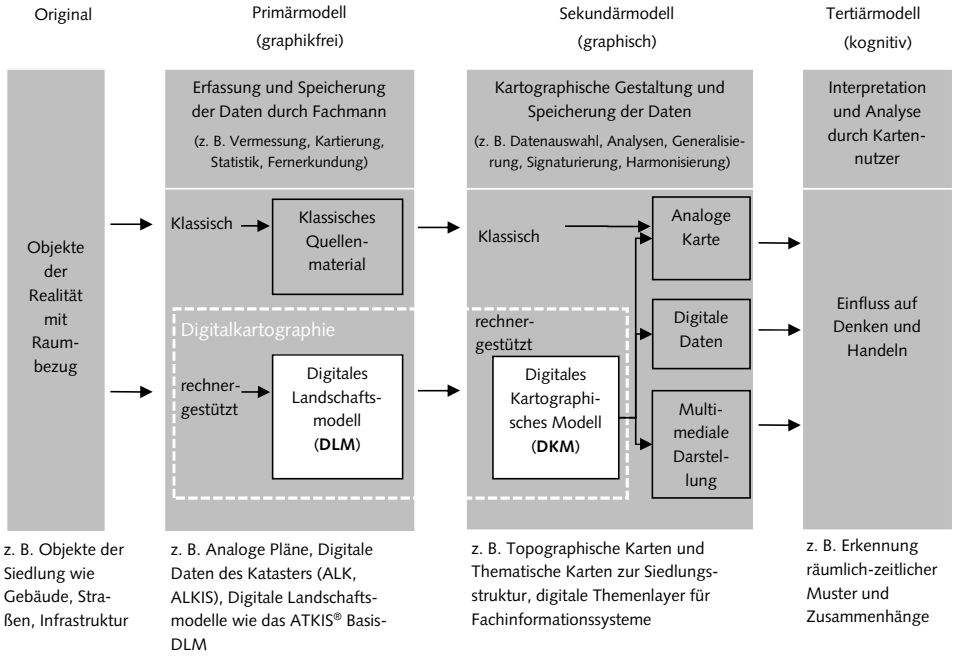

Abb. 2-2: Modellarten im kartographischen Modellbildungsprozess (in Anlehnung an Hake et al. 2002; Siemer 2004; Lechthaler & Stadler 2006)

Das erfasste Primärmodell liefert die Ausgangsbasis für die Umsetzung des *Sekundärmodells*, dem kartographischen Modell. Dabei finden kartographische Generalisierungs- und Modellierungsmaßnahmen statt, die durch den Kartographen oder von ihm entwickelte und implementierte Transformationsprozesse in einem Geoinformationssystem umgesetzt werden. In einem Gestaltungsprozess werden vorab die Gestaltungsmittel festgelegt (z. B. Zeichensystem, kartographische Darstellungsmethode, graphische Variablen, Generalisierungsregeln), die sich aus dem Zweck, dem Ausgabemaßstab bzw. dem Ausgabemedium ergeben. Der Modellbildungsprozess ist in der digitalen Kartographie zweistufig. Zunächst wird ein

virtuelles Digitales Kartographisches Modell (DKM) erzeugt und anschließend in eine vom Menschen wahrnehmbare kartographische Darstellung (z. B. Papierkarte, Bildschirmkarte) überführt (Hake et al., 2002).

Das *Tertiärmodell* ist das Vorstellungsmodell (engl. *mental map*) des Kartennutzers, das durch betrachten des Sekundärmodells mental entsteht, in dem die kartographischen Symbole vom Nutzer dekodiert werden. Das Tertiärmodell ist somit subjektiv und hängt von den Erfahrungen, der Ortskenntnis oder dem Bildungsstand des Betrachters ab. Für eine Vertiefung der Prozesse der kartographischen Informations- und Kommunikationstheorie sei auf Kolacny (1969), Ogrissek (1987) oder Tainz (2001) verwiesen.

2.2.3 Modellbildung in der digitalen Kartographie

In der Digitalkartographie erfolgt die Erfassung, Modellierung, Verwaltung, Analyse sowie Visualisierung raumbezogener Informationen, kurz *Geoinformation,* mithilfe computergestützter Systeme, den Geographischen Informationssystemen (GIS). Hierzu hat sich in den letzten Jahrzehnten die Geoinformatik als eigene Disziplin etabliert, die sich „systematisch mit dem Wesen und der Funktion der Geoinformation, mit ihrer Bereitstellung in Form von Geodaten und mit den darauf aufbauenden Anwendungen“ auseinandersetzt (Bartelme, 2005: S. 1). Wird die Geoinformation durch Zeichen kodiert und in eine für Computer lesbare Form gebracht, so spricht man von *Geodaten*, die in Geodatenbanken gehalten werden. *Geoobjekte* (engl. *geographical feature*) sind die elementaren Einheiten der Geodaten, die für jedes Phänomen der realen Welt gebildet werden und aus fachlicher Sicht ein Eigenleben führen (vgl. Bollmann & Koch, 2001).

Geodaten sind Ergebnis geometrischer und semantischer Abstraktionsvorgänge und dadurch gekennzeichnet, dass sie einen räumlichen, semantischen und zeitlichen Bezug besitzen. Der räumliche Bezug wird über Koordinaten (Punkte) bzw. Koordinatenfolgen (Linien, Flächen) in einem festgelegten Raumbezugssystem hergestellt. Hieraus ergeben sich topologische Beziehungen, wie z. B. Nachbarschaften oder Überlappungen von Objekten. Der sachliche Bezug wird durch objektbezogene Angaben in Form von Attributen hergestellt, mit denen Quantitäten (z. B. Gebäudefläche, Gebäudehöhe) und Qualitäten (Gebäudefunktion, Straßenname) beschrieben werden. Der zeitliche Bezug wird bei statischem Objektverhalten durch einen Zeitstempel, bei Dynamik durch Veränderungen des Objektes in Bezug auf einen festgelegten Zeitabschnitt (Ortswechsel, Objektausdehnung, Änderung des Merkmals) hergestellt. In der Regel sind Geoobjekte in einer Geodatenbank über einen entsprechenden Schlüssel eindeutig gekennzeichnet.

Die digitale Kartenherstellung gewann ab Ende der 1970er an Bedeutung. Großbritannien war 1995 das erste Land, das alle Kartenwerke digital in einem GIS erfasste (Longley & Mesev, 2000). In Deutschland ist der Umstieg von der analogen zur digitalen Kartenproduktion in einigen Bundesländern teilweise noch im Gange.

2.2.3.1 Digitales Landschaftsmodell

Das Digitale Landschaftsmodell[9] (DLM) ist ein Primärmodell, das durch Abstraktion und Typisierung der Realität, in diesem Fall der Landschaft, entsteht (Bill & Zehner, 2001). Um zu einem zweckmäßigen Abbild der Landschaft zu gelangen, erfordert es eine geeignete Strukturierung der Geoobjekte auf Grundlage semantischer und logischer Kriterien. Im Modell wird festgelegt, welche realen Objekte in das Modell aufgenommen, wie sie geometrisch modelliert (z. B. punkt- oder flächenhaft) und welche semantischen Informationen geführt werden. Aus Datenbanksicht entspricht diese Sicht dem *konzeptionellen Schema* der Drei-Schema-Architektur[10] und beschreibt den Aufbau der Datenstruktur (Bartelme, 2005).

Der überaus große Strukturreichtum von Geodaten erfordert übersichtliche Konzepte zu deren Organisation. Die bekanntesten Konzepte sind das Entity-Relationship-Konzept (ER-Konzept), das Layer-Konzept und das objektorientierte Konzept (Bartelme, 2005). Häufig liegt jedoch das ER-Konzept vor, mit dem eindeutig identifizierbare Objekte der Wirklichkeit über Entitäten (z. B. Gebäude) und zugehörige Attribute (z. B. Straße, Hausnummer) beschrieben sind. Im ER-Konzept stehen diese zu anderen Entitäten (z. B. Baublock) in Beziehung (Relation). Das konkrete Beispiel einer Entität, wie etwa das Gebäude mit der Adresse „Weberplatz 1“, wird als Instanz bezeichnet. Die Entitäten lassen sich auf Grundlage ihrer Eigenschaften und Beziehungen zu höheren Einheiten (Entitätsklassen) zusammenfassen. So lassen sich „Gebäude“ zu „Gebäudekomplexe“ zusammenfassen, die selbst eine Entität bilden.

Auf konzeptioneller Ebene unterscheidet man diskrete Objekte (engl. *discrete objects*) und Kontinua (engl. *continuous fields*) (Skupin, 2009), die mit den zwei geometrischen Basismodellen, dem Vektormodell und dem Rastermodell, modelliert werden können. Bei Vektormodellen werden Geoobjekte mithilfe diskreter Entitäten beschrieben, die sich aus geometrischen Elementen (z. B. Punkte, Linien oder Flächenpolygone) ergeben, untereinander in Beziehung stehen und Attribute aufweisen. Beim Rastermodell wird der betrachtete Teil der Erdoberfläche in regelmäßige Rasterzellen aufgegliedert, wobei jede Zelle mit einem numerischen Wert (Zellwert, Grauwert) versehen ist (Bartelme, 2005). Die Elemente der Siedlungsstruktur (Gebäude, Baublock, Straße) werden üblicherweise in einem Vektormodell beschrieben. Allerdings kann z. B. die dichtemäßige Verteilung von Wohnungen oder die Erreichbarkeit als abstrakte kontinuierliche Erscheinung in einem Rastermodell abgebildet werden.

Die DLM bilden eine wichtige Quelle für analytische Auswertungen und die Herstellung kartographischer Darstellungen. Sie können sich hinsichtlich struktureller, geometrischer und thematischer Eigenschaften stark unterscheiden. Einen entscheidenden Einfluss bei der Mo-

---

[9] An dieser Stelle ist das Digitale Landschaftsmodell (engl. *digital landscape model*) nicht zu verwechseln mit der gleichnamigen ATKIS® Modellkomponente Basis-DLM.

[10] Eine Beschreibung von Datenbanken (Schema) erfolgt üblicherweise in der Drei-Schema-Architektur (drei Abstraktionsebenen), die zwischen internem Schema (physische Gruppierung der Daten und Speicherplatzbelegung), konzeptionellem Schema (Aufbau der Datenstruktur) und dem externen Schema (Struktur aus Anwendersicht) unterscheidet, wobei mehrere anwenderspezifische externe Schemata zulässig sind (Bartelme, 2005).

dellierung hat dabei die Skalierung in Bezug auf den Raum, die Semantik und die Zeit. Jede Modellierung erfolgt deshalb in einer festgelegten räumlichen Auflösung (z. B. gegeben durch den Erfassungsmaßstab), einer thematischen Auflösung (z. B. die Anzahl der Klassen) und in einer zeitlichen Auflösung (z. B. das Zeitintervall bei dynamischen Sachverhalten).

2.2.3.2 Digitales kartographisches Modell

Das Digitale Kartographische Modell (DKM) bildet die Grundlage für die analoge Ausgabe in Form von Papierkarten, der Darstellung am Bildschirm und mobilen Endgeräten oder der Weitergabe in Form von digitalen Karten. Es beinhaltet eine graphisch kodierte Beschreibung der Geoobjekte durch Kartenobjekte (Kartengraphik). Der kartographischen Modellbildung folgend (vgl. Abb. 2-2) wird das graphische DKM (Sekundärmodell) vom graphikfreien DLM (Primärmodell) abgeleitet. Zu visualisierende Geoobjekte des DLM werden dabei ausgewählt, generalisiert und im DKM durch Kartenobjekte bzw. -zeichen (Signaturen) repräsentiert. Hierzu hat sich eine eigene kartographische Zeichentheorie (Kartosemiotik) herausgebildet. Für den Gestaltungsprozess wurden grundlegende Lösungsprinzipien für die Anwendung bestimmter graphischer Gefüge, wie den kartographischen Darstellungsmethoden von Koch (2001) oder für die Signaturgestaltung, wie den graphischen Variablen von Bertin (1974), erarbeitet. Die Kartenobjekte sind im DKM unter Berücksichtigung semantischer und graphikbedingter Bewertungen einer kartographischen Generalisierung unterzogen (Hake et al., 2002).

2.2.3.3 Generalisierung

Eine zentrale Aufgabe der Kartographie ist die Generalisierung zur Reduzierung und Verallgemeinerung raumbezogener Information. Ziel dieser ist es, reduzierte Information „maßstabsbedingt einer größenreduzierten Kartenfläche anzupassen oder sie vereinfacht bzw. fragestellungsorientiert in digitaler oder graphischer Form, z. B. im Rahmen von Geoinformationssystemen, zur Verfügung zu stellen" (Bollmann, 2001: S. 21). Dazu werden im Wesentlichen die Generalisierungsvorgänge Vereinfachen, Vergrößern, Verdrängen, Zusammenfassen, Auswählen, Klassifizieren und Bewerten angewendet (Hake et al., 2002). Die Anwendung der Generalisierungsvorgänge ergibt sich aus einer Vielzahl von Bedingungen (engl. *constraints*), wie etwa graphischen Bedingungen, die an die Minimaldimensionen von Kartenzeichen[11] gekoppelt sind, geometrischen Bedingungen (z. B. Streckentreue, Parallelität) oder anderen methodischen Festlegungen, die sich aus Nutzeranforderungen ergeben.

Man unterscheidet zwischen der *semantischen* und der *geometrischen* Generalisierung[12] (Hake et al., 2002). Bei der semantischen Generalisierung finden begriffliche und sprachliche Verallgemeinerungsprozesse in Bezug auf die semantische Information (qualitative und quantitative Merkmale) statt. Die wichtigsten Vorgänge sind das Auswählen, Klassifizieren

[11] Minimaldimensionen von Kartenzeichen sind „Mindestwerte zur Wahrnehmung (Auffassbarkeit, Lesbarkeit) eines Kartenzeichens bzw. eines graphischen Elements in Bezug auf seine Größe und seinen Abstand von einem anderen Kartenzeichen unter normalen Wahrnehmungsbedingungen" (Bollmann & Koch, 2001; Stichwort: Minimaldimensionen von Kartenzeichen).

[12] Eine weitere nicht genannte Form ist die temporale Generalisierung (Hake et al., 2002).

und Zusammenfassen von Objektklassen. Die geometrische Generalisierung bezieht sich auf die Geometrie der punkt-, linien- oder flächenhaften Objekte, wobei alle oben genannten Generalisierungsvorgänge eingesetzt werden können. Diese reichen von rein geometrischen Vorgängen (z. B. Vereinfachung von Gebäudegrundrissen, die Zusammenfassung mehrerer Siedlungsflächen) bis hin zu Generalisierungsvorgängen mit begrifflich-geometrischem Charakter (z. B. beim Geometrietypwechsel von flächenhaft modellierten Siedlungen zu punktbezogenen Ortssignaturen). Für maßstabsgebundene geometrische Generalisierungen bemüht man sich um mathematisch-gesetzmäßige Lösungen (Arnberger, 1977). So kann beispielsweise mit dem Gesetz von Töpfer (1974) die Anzahl der noch darzustellenden Kartenobjekte in der Folgekarte berechnet werden, die sich durch eine formale Beziehung zwischen Ausgangsmaßstab und Folgemaßstab ergeben.

2.2.3.4 Generalisierung in der Digitalkartographie

War die Generalisierung in der klassischen Kartographie hauptsächlich ein wichtiger Bestandteil der graphischen Gestaltung, so wird diese heute breiter angewendet. In der digitalen Kartographie unterscheidet man (nach Schürer, 2002):

- Erfassungsgeneralisierung,
- Modellgeneralisierung

} Objektgeneralisierung

- und die kartographische Generalisierung.

Bei der Erfassung originärer Daten erfolgt die Umsetzung realer Objekte in abstrakte Geoobjekte im Primärmodell. Dieser Modellierungsschritt unterliegt einer *Erfassungsgeneralisierung*, in dem Objekte ausgewählt, nach Begriffen in Gruppen zusammengefasst werden und die Geometrie während der Modellierung vereinfacht wird. Die zu modellierenden Objekte und Erfassungsuntergrenzen sind üblicherweise in einem Objektartenkatalog (OK) des DLM festgelegt. Von einer *Modellgeneralisierung* spricht man, wenn ein hochaufgelöstes DLM in ein neues DLM mit niedriger semantischer und/oder geometrischer Auflösung überführt wird (Schürer, 2002). In der Praxis wird dies bereits automatisiert getan, indem beispielsweise das Digitale Landschaftsmodell 50 (DLM50) durch Modellgeneralisierung aus dem ATKIS® Basis-DLM abgeleitet wird (Birth, 2003). Die *kartographische Generalisierung* führt zum DKM und umfasst die Generalisierung im klassischen Sinne mit dem Fokus auf eine maßstabs- und dem Ausgabemedium gerechte gestalterische Signaturierung unter Nutzung geeigneter kartographischer Darstellungsmethoden (Koch, 2001). Die Modellgeneralisierung wird damit von der kartographischen Generalisierung losgelöst betrachtet (vgl. Brassel & Weibel, 1988). In Abb. 2-3 sind die Arten der Generalisierung zusammengefasst dargestellt.

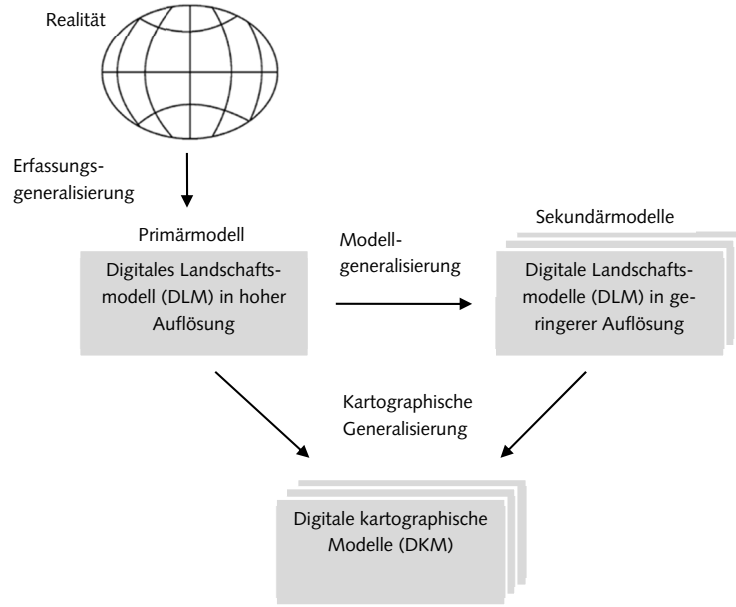

Abb. 2-3: Arten der Generalisierung in der digitalen Kartographie (Mackaness & Chaudhry 2008)

Die vollautomatisierte Generalisierung stellt die digitale Kartographie vor große Herausforderungen. Automatisierte Generalisierungsalgorithmen sind nur in Teilen vorhanden, so dass diese in der praktischen Herstellung topographischer Karten bisher nur unterstützend eingesetzt werden. Topographische Kartenprodukte werden deshalb häufig nur halbautomatisch über ein Zwischen-DKM, dem „Roh-DKM", und einer anschließenden interaktiven Bearbeitung abgeleitet (Siemer, 2004). Eine zusammenfassende Übersicht über aktuelle Entwicklungen und Forschungsergebnisse zur automatisierten Generalisierung sind in den Arbeiten von Weibel (2004), Bobzien (2006), Sester et al. (2008) und Ostrau (2010) oder im Sammelband von Mackaness et al. (2007) zu finden. Einen Überblick über die bereits in einer GIS-Software-Umgebung implementierten Generalisierungsoperatoren geben Regnauld & McMaster (2007).

Mit steigendem Bedarf an dreidimensionalen Visualisierungen spielt in jüngster Zeit die 3D-Generalisierung eine immer bedeutendere Rolle (vgl. Kada, 2007; Meng & Forberg, 2007). Eine schnelle Visualisierung in verschiedenen Zoomstufen, wie es Internetkarten oder Karten für mobile Geräte benötigen, kann über eine geschlossene Haltung unterschiedlicher Maßstäbe in Multirepräsentationsdatenbanken (engl. *Multiple Representation Database*, MRDB) realisiert werden (u. a. Haunert, 2005; Bobzien, 2006). Eine vertikale Zuordnung homologer Objekte unterschiedlicher Auflösungsstufen erlaubt dann eine gleichzeitige Fortführung der Datenbestände aller Maßstäbe. Aufgrund der Bedeutung von MRDB in der Generalisierung

und den damit verbundenen Herausforderungen bei der vertikalen Zuordnung homologer Objekte widmen sich aktuell verschiedene Arbeitsgruppen[13] diesem Forschungsthema.

2.2.4 Geobasisdaten

Geobasisdaten bezeichnen Geodaten, welche die Landschaft (Geotopographie) und die Liegenschaften der Erdoberfläche interessenneutral beschreiben (Bill & Zehner, 2001). Die Erfassung, Haltung und Verbreitung der Daten erfolgt in der Regel auf Grundlage gesetzlicher Bestimmungen. Damit sind sie standardisiert und flächendeckend verfügbar und in ihrer Fortführung gesichert. In dieser Arbeit werden Geobasisdaten stets auf die in Deutschland verfügbaren geotopographischen Informationssysteme des Kataster- und Landesvermessungswesens und den daraus abgeleiteten Karten bezogen. Im Folgenden werden die automatisierte Liegenschaftskarte[14] (ALK) sowie das Amtliche Topographisch-Kartographische Informationssystem (ATKIS®) etwas genauer betrachtet.

2.2.4.1 Automatisierte Liegenschaftskarte

Das zumeist von kommunalen Katasterbehörden geführte digitale Liegenschaftskataster dient als großmaßstäbiger Nachweis aller Liegenschaften und erfüllt die Bedürfnisse des Rechtsverkehrs, der Verwaltung, Wirtschaft und Statistik (Bill & Zehner, 2001). Es besteht aus einem vermessungs- und kartentechnischen Teil (Automatisierte Liegenschaftskarte, kurz ALK) und einem beschreibenden Teil (Automatisiertes Liegenschaftsbuch, ALB). Im ALB werden die Flurstücke, Eigentümer und die Nutzung in nichtgraphischer Form beschrieben. In der ALK wird hingegen die geometrische Lage baulicher Anlagen und Liegenschaften, die Art der Nutzung und die Größe in einem objektstrukturierten Modell beschrieben.

Die Daten sind Grundlage für die Herstellung großmaßstäbiger topographischer Grundkarten, wie der Liegenschaftskarte (üblicherweise 1: 500 bis 1: 2 500) oder der Deutschen Grundkarte 1: 5 000 (DGK), in der die topographischen Objekte durch kartographische Zeichen dargestellt und mit Schriftzusätzen näher erläutert sind. Im Wesentlichen gibt sie die natürlichen Gegebenheiten (Gewässer, Geländeformen, Vegetation) und alle durch menschliches Handeln geprägten Erscheinungsformen der Erdoberfläche (Bebauungen, Flurstücke, Verkehrsfläche) grundrisstreu wieder und ist dementsprechend für die Anwendung im großmaßstäbigen Bereich geeignet.

[13] Als Beispiel sei die ISPRS Commission II/2 Working group on "Multiscale Representation of Spatial Data" und die ICA Commission on "Generalisation and Multiple Representation" genannt.

[14] in Bayern als Digitale Flurkarte (DFK) bezeichnet

Abb. 2-4: Automatisierte Liegenschaftskarte (a) und Deutsche Grundkarte 1: 5 000 (b) (Quelle: TIM-Online NRW, www.tim-online.nrw.de)

2.2.4.2 Amtliches Topographisch-Kartographisches Informationssystem

Das Geoinformationssystem der Landesvermessung ist das Amtliche Topographisch-Kartographische Informationssystem (ATKIS®), mit dem die Topographie der Erdoberfläche in unterschiedlicher Form (objekt-, punkt-, graphik- oder bildbasiert) beschrieben ist. Es beinhaltet die folgenden Produkte:

- Digitale Landschaftsmodelle (DLM)
- Digitale Geländemodelle (DGM)
- Digitale Topographische Karten (DTK)
- Digitale Orthophotos (DOP)

Die groß- und mittelmaßstäbigen Geobasisdaten im Maßstabsbereich von 1: 25 000 bis 1: 100 000 werden von der Landesvermessung, die Geobasisdaten im Maßstab 1: 100 000 und kleiner vom Bundesamt für Kartographie und Geodäsie (BKG) aufbereitet. Eine bundeseinheitliche Bereitstellung der Geobasisdaten erfolgt für alle Produkte ab einem Maßstab von 1: 25 000 und kleiner zentral über das Geodatenzentrum des BKG. Die Objektmodelle sind durch die Arbeitsgemeinschaft der Vermessungsverwaltungen der Länder der Bundesrepublik Deutschland (AdV) standardisiert. Entsprechende Objektkataloge (OK), Signaturenkataloge (SK), festgelegte einheitliche Datenbankschnittstellen bis hin zu bundeseinheitlichen Gebührenrichtlinien dienen den zuständigen Einrichtungen als Grundlage für die Realisierung der öffentlichen Aufgaben des amtlichen Vermessungswesens.

Tab. 2-4: Digitale Landschaftsmodelle in Deutschland und die daraus abgeleiteten Digitalen Topographischen Karten (Quelle: Zusammenstellung aus Produktblättern der AdV, www.adv-online.de)

Vektorbasierte Digitale Landschaftsmodelle (DLM)		Rasterbasierte Digitale Topographische Karten (DTK)		
		aus DLM abgeleitete Digitale Topographische Karte (DTK)	durch Scannen analoger Kartenwerke gewonnene DTK in vorläufiger Ausgabe (DTK-V)	
Bezeichnung	Datengrundlage für die Ersterfassung des DLM	Bezeichnung	Bezeichnung	Grundlage für den Scan
Basis-DLM im Maßstab 1: 25 000	Digitale Grundkarte 1: 5 000 (DGK5)**, Topographische Karte 1: 10 000 (TK10)*, Topographische Karte 1: 25 000 (TK25), Luftbilder und andere Quellen	DTK10*, DTK25	DTK10-V*, DTK25-V	TK10*, TK25
DLM 50 im Maßstab 1: 50 000	Ableitung aus Basis-DLM, meist zweistufig über DLM50.1 (automationsgestützte Modellgeneralisierung) und DLM50.2 (interaktive kartographische Überarbeitung)	DTK50, DTK100	DTK50-V, DTK100-V	TK50
DLM 250 im Maßstab 1: 250 000	Ersterfassung auf Grundlage des Datenbestandes der Joint Operations Graphic 1: 250 000 (JOG250) der Serie 1501, Aktualisierung mit verschiedenen Daten	DTK250	DTK200-V	TÜK200
DLM 1000 im Maßstab 1: 1 Mio.	Übersichtskarte der Bundesrepublik Deutschland 1 : 500 000 (ÜK500)	DTK1000	DTK1000-V	D1000

*nur in einigen Bundesländern

** nur alte Bundesländer

Digitale Landschaftsmodelle stehen in unterschiedlichen Detailierungsgraden zur Verfügung, die wiederum die Grundlage für die Ableitung topographischer Karten bilden. Neben der Herstellung topographischer Karten dienen sie vor allem als Raumbezugsbasis für die Integration von Geofachdaten. Von den DLM besitzt das Basis-DLM den höchsten Detailierungsgrad. Der Inhalt orientiert sich weitgehend an dem der Topographischen Karte 1: 10 000 bzw. 1: 25 000 und ist im ATKIS®-Objektartenkatalog (ATKIS®-Basis-OK) festgelegt (AdV, 2008c). Es bildet zusammen mit dem DGM den Nachweis der Topographischen Landesaufnahme. Für den Aufbau des Basis-DLM wurde die Deutsche Grundkarte 1: 5 000 (alte Bundesländer), die Topographische Karte 1: 10 000 (neue Bundesländer), terrestrische Vermessungen sowie Luftbildmaterial hinzugezogen. Heute werden die Digitalen Topographischen Karten 1:10 000 (DTK10) sowie 1: 25 000 (DTK25) rechnergestützt aus

dem Basis-DLM abgeleitet. Das Basis-DLM ist aber auch Grundlage für die Ableitung von Folgemodellen in kleinere Maßstäbe, wie z. B. dem Landschaftsmodell 50 (DLM50), das wiederum der Herstellung der Digitalen Topographischen Karten 1: 50 000 und 1: 100 000 dient (AdV, 2009). Das kleiner maßstäbige DLM250 und DLM1000 wird vom BKG erstellt und geführt, aus denen weitere topographische Produkte abgeleitet werden. Für die Zukunft ist eine automatische Ableitung aller DLM mittels Modellgeneralisierung angedacht.

Die Tab. 2-4 gibt einen Überblick über die Digitalen Landschaftsmodelle, den daraus abgeleiteten Digitalen Topographischen Karten (DTK) sowie den vorläufigen Digitalen Topographischen Karten (DTK-V), die durch Scannen analoger topographischer Karten (TK) gewonnen werden. Es zeigt zudem die Grundlagen, die für die Ersterfassung der DLM zugrunde lagen. Nach dem Aufbau der DLM erfolgt die Aktualisierung unter Nutzung verschiedener Quellen (Topographische Karten, Luftbilder, Ortsbegehungen), deren Vielfalt in dieser Tabelle nicht mehr dargestellt werden kann. An dieser Stelle sei auf das Metainformationssystem des BKG verwiesen (www.geodatenzentrum.de).

2.2.5 Geofachdaten

Anwendungsspezifische, thematische Daten mit Ortsbezug, die in integrierten Fachinformationssystemen, wie zum Beispiel Raum- oder Umweltinformationssystem, gehalten werden, werden als Geofachdaten bezeichnet. Meist wird der Ortsbezug über eine Verknüpfung der Information mit Geobasisdaten hergestellt. Geofachdaten bedienen ein großes Spektrum an Themen und sind in raumplanerischen Informationssystemen (Raumordnungskataster, Flächennutzungs- und Bebauungspläne), in Biotoptypenkatastern, Netzinformationssystemen von Ver- und Entsorgungsunternehmen, kommunalen Fachinformationssystemen (z. B. Lärmkataster, Bodenkataster, Grünflächenkataster, Baumkataster) oder statistischen Informationssystemen zu finden.

Zu den Geofachdaten zählen auch Merkmale zu sozio-ökonomischen oder demographischen Daten der amtlichen Statistik (Eschwege & Heidrich-Riske, 2006), wie beispielsweise zu Beruf, Bildung, Einkommen, Eigentumsverhältnissen usw. Der Ortsbezug wird bei statistischen Informationssystemen häufig indirekt über den amtlichen Gemeinde-, Landkreis- oder Landesschlüssel hergestellt. Kleinräumige statistische Daten, die sich auf die Blockseite oder Baublöcke beziehen, werden nur auf kommunaler Ebene verwaltet. Eine Arbeitsgemeinschaft Kommunalstatistik (KOSTAT) sammelt in Deutschland diese kleinräumig gegliederten Daten der Kommunalstatistik und stellt sie für öffentliche, private und wissenschaftliche Zwecke zentral bereit (Schönheit, 2011). Um Daten über die Fachbereiche und Gemeinden hinweg vergleichbar zu machen, wurde vom Deutschen Städtetag der Standard MERKIS (Maßstabsorientierte Einheitliche Raumbezugsbasis für Kommunale Informationssysteme) entwickelt (Deutscher Städtetag, 1991).

2.2.6 Geodateninfrastruktur (GDI)

Um einen breiten Zugang zu der großen Vielzahl verschiedener Geodaten zu gewährleisten, müssen Strukturen geschaffen werden, die es erlauben, gezielt nach Daten zu suchen, diese Anhand von Metainformationen zu beurteilen und auf sie zuzugreifen. Um eine ebene- und fachübergreifende Bereitstellung von Geoinformationen zu gewährleisten, wird eine Geodateninfrastruktur (GDI) geschaffen. Das Lexikon der Geoinformatik definiert GDI als „eine aus technischen, organisatorischen und rechtlichen Regelungen bestehende Bündelung von Geoinformationsressourcen, in der die Anbieter von Geodatendiensten mit Nachfragern solcher Dienste kooperieren" (Bill, 2012, Stichwort: Geodateninfrastruktur). Dem Autor folgend besteht eine GDI aus einer Geodatenbasis (z. B. Geobasisdaten und Geofachdaten) und deren Metadaten, einem Geoinformationsnetzwerk (Geodatenportale), Diensten (z. B. zur Konvertierung und Transformation von Daten) und Standards (z. B. Datenstruktur, -format, Koordinatensystem).

Die Geodateninfrastruktur Deutschland (GDI-DE) ist eine Initiative von Bund, Ländern und Kommunen und wird vom Interministeriellen Ausschuss für Geoinformationswesen (IMAGI) koordiniert (IMAGI, 2002). Der Aufbauprozess bestand aus der Erstellung eines Metainformationssystems, der Harmonisierung und der schrittweisen Implementierung der nationalen Geodatenbestände in ein Geoportal Deutschland (*Geoportal.de*, ehemals *GeoPortal.Bund*). Auf Europäischer Ebene wird mit der Initiative *Infrastructure for Spatial Information in the European Community* (INSPIRE) an Standards gearbeitet, die eine Grundlage für eine GDI auf nationaler Ebene bilden. Mit ISO Standards für Geoinformation wird hingegen eine globale Standardisierung realisiert (Kresse & Fadaie, 2004; Kresse, 2004).

2.3 Kartographische Darstellung der Siedlungsstruktur

Georäumliches Wissen zur Siedlungsstruktur wird in Karten und kartenverwandten Darstellungen repräsentiert. Im Folgenden wird auf die Darstellung der Siedlungsstruktur in topographischen und thematischen Karten eingegangen.

2.3.1 Topographische Karten

Topographische Karten bilden die Siedlung und ihre Elemente in ihrer topographischen Sicht zweidimensional ab. Hauptgegenstand der Karte sind Siedlungen, Verkehrswege und -objekte, Gewässer, Geländeformen, Bodenbewuchs und weitere Elemente, die der Orientierung dienen (Hake et al., 2002). Eine scharfe Abgrenzung zu thematischen Karten ist streng genommen nicht in aller Hinsicht gegeben, da diese auch thematische Elemente, wie die Stadtgrenze oder Informationen zur Flächennutzung, beinhalten. Im engeren Sinne sind topographische Karten solche, „die das Gelände und die mit ihm verbundenen Gegenstände in großen und mittleren Maßstäben mit maßstabsbedingter Vollständigkeit abbilden" (Hake et al., 2002: S. 417).

Topographische Karten werden üblicherweise in folgende Maßstabsbereiche gegliedert (Bollmann & Koch, 2001; nach Hake et al., 2002):

- Topographische Grundkarten (1: 10 000 und größer)
- Topographische Spezialkarten (1: 20 000 bis 1: 75 000)
- Topographische Übersichtskarten (1: 100 000 bis 1: 300 000)
- Geographischen Karten[15] (ab ca. 1: 300 000 und kleiner)

Heissler und Haake (1970) beschreiben die Siedlungsdarstellung in topographischen Karten für verschiedene Maßstäbe und unterscheiden die grundrisstreue Darstellung, die grundrissähnliche Darstellung sowie die Darstellung durch Ortssignatur (Tab. 2-5).

Tab. 2-5: Übersicht der Darstellungsarten der Siedlung in topographischen Karten in Anlehnung an Heissler und Haake (1970)

		Topogr. Grundkarten		Topogr. Spezialkarten		Topogr. Übersichtskarten			Geographische Karten			
	Maßstab	1:5000 und größer	1:10 000	1:25 000	1:50 000	1:100 000	1:200 000	1:300 000	1:500 000	1:1 Mio.	1:5 Mio.	1:10 Mio. und kleiner
Grundrisstreu		■	■									
Grundrissähnlich	Einzeldarstellung			■	■	■	■					
	Teilblockdarstellung			■	■	■	■	■	■			
	Gesamtumriss							■	■	■	■	
Ortssignaturen								■	■	■	■	■

Bei Betrachtung des Kartenbildes topographischer Karten lassen sich Bebauungsstrukturen, Nutzungsstrukturen, Infrastrukturen (Straßen, Wege, Versorgungseinrichtungen) und Freiflächenstrukturen erkennen. Die Siedlungsdarstellung wird im Folgenden anhand der eingeführten Klassifizierung topographischer Karten näher erläutert.

2.3.1.1 Topographische Grundkarten

Topographische Grundkarten sind durch eine hohe geometrische Genauigkeit gekennzeichnet. Sie dienen einerseits als großmaßstäbige Grundlage für die örtliche Planung und andererseits als Basiskarte für die Erstellung von Folgekarten.

[15] Geographische Karten als raumbeschreibende Karten sind im weiteren Sinne Topographische Karten ab einem Maßstab von 1: 300 000 (Hake et al., 2002). In dieser Arbeit werden jedoch erst topographische Karten ab einem Maßstab von 1: 500 000 als Geographische Karten bezeichnet (vgl. Tab. 2-5).

Abb. 2-5: Stadtplan von Rom (1748) von Giambattista Nolli im Maßstab 1:2 900 (Quelle: University of Oregon, 2005)

Ein beeindruckendes historisches Beispiel einer frühen Grundkarte ist der Stadtplan von Rom (*Nolli Map of Rome*) aus dem Jahr 1748, in dem Gebäude, Straßen und öffentliche Plätze grundrisslich dargestellt sind (Abb. 2-5). Verglichen mit anderen kartographischen Darstellungen dieser Zeit ist diese Karte durch einen besonders hohen topographischen Detaillierungsgrad ausgezeichnet. Diese wurde von der römischen Stadtverwaltung bis in die 1970er Jahre als Planungsgrundlage verwendet (University of Oregon, 2005).

Bei topographischen Grundkarten erfolgt die Visualisierung der Elemente der Siedlung (Gebäude, Verkehrsflächen) bis zu einem Maßstab 1: 5 000 in einer grundrisstreuen Darstellung. Bei einer Minimaldimension einzelner Objekte von 0,3 mm in der Karte können im Maßstab 1: 5 000 kleine Erker oder Treppenaufgänge ab einer Größe von 1,5 m in der Natur abgebildet werden. Der Maßstab 1: 10 000 gilt als Grenzmaßstab für eine grundrisstreue Darstellung, da sich nur noch Häuserdetails im Ausmaß von 3 m wiedergeben lassen (Hake et al., 2002). In diesem Maßstabsbereich wird die Gebäudenutzung (z. B. Wohnen, Wirtschaft, Industrie) häufig durch Schraffuren oder Einfärbungen gekennzeichnet. In Deutschland zählen die Deutsche Grundkarte 1: 5 000 (DGK5) bzw. die Topographischen Karten im Maßstab 1: 10 000 (TK10, DTK10), die Stadtgrundkarten (meist 1: 500 oder 1: 1 000) sowie die Automatisierte Liegenschaftskarte (bzw. die Digitale Flurkarte in Bayern) zu den wichtigsten Topographischen Grundkarten.

2.3.1.2 Topographische Spezialkarten

Mit kleiner werdendem Maßstab (ab ca. 1: 10 000) sind bereits Generalisierungsmaßnahmen notwendig. In topographischen Spezialkarten, wie der Topographischen Karte im Maßstab 1: 25 000 oder 1: 50 000, spricht man deshalb von einer grundrissähnlichen Darstellung der Situation. Details und Objekte, welche die Minimaldimensionen unterschreiten, werden bereits weggelassen oder vergrößert dargestellt. Bei Siedlungen in offener Bauweise werden Gebäudedetails (Lichtschächte, Anbauten etc.) vernachlässigt oder Gebäude zusammengefasst, da der Zwischenraum nicht mehr darstellbar ist. Mit Vergrößerung der Straßensignaturen geht auch eine Verdrängung der Gebäude einher.

Bei sehr eng bebauten Stadtteilen, wie der geschlossenen Bauweise im Stadtzentrum, werden bebaute Flächen in einer „Teilblockdarstellung" (Siedlungsblöcke) repräsentiert. Die Siedlungsblöcke ergeben sich aus den Straßenzügen, wobei innere Freiflächen und Zwischenstraßen vernachlässigt werden (Heissler & Hake, 1970). Die Dimension der überbauten Fläche bleibt jedoch gewahrt, da die Verbreiterung der umschließenden Straßen kompensierend wirkt. Die Schweizer Gesellschaft für Kartographie liefert in diesem Zusammenhang ausführliche, bebilderte Arbeiten zur kartographischen Generalisierung topographischer Karten der Schweiz (u. a. SGK, 1980; Spiess, 2002).

2.3.1.3 Topographische Übersichtskarten

In topographischen Übersichtskarten werden mit wenigen Ausnahmen keine einzelnen Gebäude mehr dargestellt. Grundrissähnliche Einzeldarstellungen sind nur bis höchstens 1: 200 000 üblich (Heissler & Hake, 1970). Die Bebauung kann ab diesem Maßstab nur noch über eine flächenhafte Darstellung der Siedlung visualisiert und ggf. nach verschiedenen Flächennutzungstypen differenziert werden. Bei sehr kleinen Maßstäben (ab ca. 1: 300 000 und kleiner) lässt sich die innere Struktur der Siedlung nicht mehr zum Ausdruck bringen. Die Darstellung beschränkt sich dann nur noch auf den Umriss einzelner Ortschaften. Haben diese eine zu geringe Größe, so ist auch diese Fläche nicht mehr darstellbar. Ortschaften werden dann nur noch über eine punktbezogene Ortssignatur repräsentiert. Zu diesen Karten zählt in Deutschland die Topographische Übersichtskarte 1: 200 000 (TÜK200), die Übersichtskarte 1: 500 000 (ÜK500) oder die Karte „Bundesrepublik Deutschland 1: 1 000 000" (D1000) (vgl. Tab. 2-4).

2.3.2 Thematische Karten

Karten, in denen „Erscheinungen und Sachverhalte zur Erkenntnis ihrer selbst dargestellt sind" gehören nach der Internationalen Kartographische Vereinigung (ICA, 1973) zur Gruppe der Thematischen Karten[16] (zitiert in Hake et al., 2002: S. 461). Diese bilden „Objekte oder Sachverhalte (Themen) nicht topographischer Art aus der natürlichen Umwelt und aus dem Wirtschafts- und Sozialbereich der menschlichen Gesellschaft" ab (Bollmann & Koch,

[16] Hierunter werden auch die Sonderformen Kartogramme und Kartodiagramme gezählt.

2001, Stichwort: thematische Karte). Die dargestellten Themen sind meist abstrakte, raumbezogene Erscheinungen oder Sachverhalte, wie etwa die Bevölkerungsdichte, die Altersstruktur oder räumlich-funktionale Zusammenhänge. Thematische Geoinformation ist Ergebnis einer thematischen Aufnahme (z. B. einer Luftbildkartierung der Bebauungsstruktur), einer Übernahme von Informationen aus anderen Quellen (Karten, Statistik, Fachinformationssystemen) oder einer rechnergestützten Analyse im GIS (z. B. Ableitung aus vorhandenen Datenbeständen). Für die geographische Verortung der thematischen Information ist diese stets in Kombination mit einem geeigneten topographischen Kartengrund dargestellt.

2.3.2.1 Gliederung thematischer Karten

Thematische Karten sind durch eine enorme Vielfalt[17] gekennzeichnet. Einige Autoren versuchen, diese anhand verschiedener Merkmale wie Maßstabsgruppe, Inhaltsstruktur, Thema, Zweckbestimmung, Merkmalsausprägung, Kartographische Darstellungsmethode oder Medium zu sortieren (u. a. Arnberger, 1966; Bollmann & Koch, 2001; Hake et al., 2002; Imhof, 1972; Witt, 1967). Eine für diese Arbeit sinnvoll erscheinende Gliederung ergibt sich aus einer objektbezogenen Betrachtung nach Hake et al. (2002). Demnach können thematische Karten nach folgenden Gesichtspunkten gruppiert werden:

- nach der Art des Raumbezuges (Diskreta oder Kontinua)
- nach der Art des sachlichen Bezuges (qualitative Karten, quantitative Karten)
- nach dem temporalen Bezug (statisch, dynamisch)

Nach der Art des Raumbezuges werden Diskreta und Kontinua unterschieden. *Diskreta* sind eindeutig zu ermittelnde Darstellungsgegenstände, wie lineare oder flächenhafte Geoobjekte, die in der Karte durch punkt-, linien- oder flächenbezogene Signaturen dargestellt werden. Bei den flächenhaften Diskreta kann man weiter zwischen Objektflächen (absolutes Vorkommen), Verbreitungsflächen (relatives Vorkommen) und Bezugsflächen unterscheiden (Hake et al., 2002). Bezugsflächen können einerseits administrative Flächen (Baublock, Gemeinde etc.) oder auch geometrische, koordinatengebundene Gitternetze, wie z. B. quadratische, dreieckige oder hexagonale Gitter, sein (Witt, 1967). *Kontinua* sind hingegen räumlich oder flächenhaft unbegrenzte Erscheinungen mit stetigem Verlauf, die durch Wertefelder (z. B. Geländehöhe, Erreichbarkeit) beschrieben werden.

Nach dem Sachbezug lassen sich qualitative und quantitative Karten unterscheiden (Witt, 1967). *Qualitative Karten* geben Objektqualitäten (z. B. Typen, Klassen, Arten) wieder, wie etwa Karten zu Bebauungsstrukturtypen oder der Baualtersklasse. *Quantitative Karten* bringen hingegen Werte (Mengen, Größen oder andere Maße) zum Ausdruck, wobei man zwischen relativen Werten (Dichten, Anteile etc.) und absoluten Werten unterscheidet (Hake et al., 2002). Bei der Darstellung quantitativer Sachverhalte liegt eine rechnerische Bezugsfläche zugrunde (Arnberger, 1977). Diese kann größer (z. B. Einwohnerdichte pro Gemeinde,

[17] Arnberger spricht von einer „unerhörte[n] Vielfalt kartographischer Ausdrucksformen entsprechend der Verschiedenartigkeit ihrer Gestaltprinzipien, der verwendeten Maßstäbe, der Zweckbestimmung und der dargestellten Sachinhalte." (Arnberger, 1966: S. 52).

dargestellt auf Ebene der bebauten Flächen), gleichgroß (z. B. Einwohnerdichte im Baublock, dargestellt auf Ebene des Baublocks) oder kleiner (z. B. Einwohner pro Einheit zur Verfügung stehender Erholungsflächen, dargestellt auf Ebene der Gemeinde) als der tatsächliche Verbreitungsraum sein.

Nach Art des temporalen Bezuges unterscheidet man zwischen Karten, die statisches und dynamisches Verhalten darstellen (statische und dynamische Karten). Die meisten thematischen Karten sind statische Karten, die als Momentaufnahme den Zustand zu einem definierten Zeitpunkt beschreiben. In dynamischen Karten werden Veränderungen dargestellt, die sich auf einen definierten Zeitraum beziehen. Man unterscheidet Veränderungen diskreter Objekte (Bewegungen des Objekts, Veränderung des Objekts nach Gestalt und Inhalt) und Veränderung kontinuierlicher Objekte (z. B. Gletscherbewegung, dargestellt mit Geschwindigkeitsvektoren). In thematischen Karten zur Siedlungsstruktur spielen insbesondere Veränderungen in der Objektgestalt (z. B. bei Karten zur Siedlungsgenese) oder des Objektinhaltes (Zunahme der Bevölkerung durch quantitative Flächenfärbung) eine Rolle.

Die eben beschriebenen Unterscheidungsmerkmale bestimmen die kartographischen Gestaltungsmittel, wie punkt-, linien- und flächenbezogene Signaturen und Diagramme sowie Halbtöne und die Schrift (Hake et al., 2002). In diesem Zusammenhang identifizierte Bertin (1974) sechs verschiedene graphische Variablen (Form, Größe, Helligkeit, Muster, Farbe, Richtung), die für die Gestaltung von Signaturen in statischen Karten in Frage kommen[18]. Eine weitere systematische Auseinandersetzung mit der Kartengestaltung führt zu kartographischen Darstellungsmethoden. Diese sind Grundstrukturen der Kartengraphik (kartographische Gefüge) und ihre Anwendungsprinzipien „mit denen der Karteninhalt unter Verwendung geeigneter Kartenzeichen und deren methodisch-regelgesteuerter Variation nach graphischen Variablen gestaltet bzw. modelliert wird" (Koch, 2001: S. 16). In Anlehnung an Arbeiten der Kartographen Salistschew, Pillewizer, Stams u. a. stellt Koch zehn kartographische Darstellungsmethoden[19] vor, mit denen Geodaten aller Art in statischen Karten umgesetzt werden können. Für die Darstellung mehrerer Themen (komplexe Karten) ist eine Kombination dieser Methoden möglich. Eine weitere systematische, graphikbezogene Gliederung kann beispielsweise nach den Gestaltungsprinzipien[20] von Arnberger (1977) oder den Gefügetypen von Imhof (1972) erfolgen.

[18] Für Multimediapräsentationen (3D-Darstellungen am Computer) sind weitere Variablen, wie Transparenz, Bewegung, etc., möglich (vgl. MacEachren, 1995).

[19] Kartographische Darstellungsmethoden (Koch, 2001): Punktbezogene Methoden: a) Methode der Positionssignaturen, b) Methode der Diagrammsignaturen in Form punktbezogener Diagrammfiguren, c) Punktmethode; Linienbezogene Methoden: d) Methode der Linearsignaturen, e) Vektorenmethode; Flächenbezogene Methoden: f) Flächenmethode oder Arealmethode, g) Flächenmittelwertmethode (Methode der qualitativen Flächenfüllung, Gattungsmosaik), h) Flächenkartogramm-Methode (Choroplethendarstellung, Dichtedarstellung), i) Diakartogrammm-Methode (Diakartogramm, Kartodiagramm); Oberflächenbezogene Methoden: j) Isolinienmethode (Isarithmenmethode)

[20] Lage- oder topographisches Prinzip, Diagrammprinzip, bildstatistisches Prinzip und bildhaftes Prinzip

2.3.2.2 Thematische Karten zur Siedlungsstruktur

Nach Einführung der Gruppierungsmerkmale werden in Tab. 2-6 mögliche Themen der morphologischen, funktionalen, sozio-ökonomischen Siedlungsstruktur vorgestellt, die sich in thematischen Karten umsetzen lassen. Es werden dabei nur diskrete Erscheinungen berücksichtigt (Kontinua werden nicht näher beleuchtet.) Wegen des großen Themenspektrums ist der Einsatz vieler Darstellungsmethoden möglich. Flächenbezogene Methoden sind allerdings am geläufigsten, da die zu visualisierenden Merkmale in der Regel einen Bezug zu diskreten Objektflächen haben, wie etwa administrativen (Baublock, Gemeinde etc.) oder geometrischen Einheiten (regelmäßige Raster, Hexagone etc.). Baublockbezogene Quantitäten (Überbauungsgrad, Geschossflächendichte etc.) werden mit der Flächenkartogramm-Methode, Qualitäten (Baublocktyp, Nutzungsart etc.) mit der Arealmethode realisiert. Bei der Darstellung von Quantitäten auf Gemeindeebene kommen häufig Kartodiagramme zum Einsatz. Mit Kreissektorenkartodiagrammen können insbesondere Strukturen visualisiert werden, wie etwa die Zusammensetzung von Nutzungsarten oder Bevölkerungsgruppenanteilen pro Siedlungseinheit.

Tab. 2-6: Beispiele zur Beschreibung der Siedlungsstruktur mit Fokus auf die Bebauung nach sachlichem und temporalem Objektbezug

		Mikro-Ebene Flächenhafte diskrete Objektfläche (Gebäude)	**Meso-Ebene** Flächenhafte Siedlungseinheit (Baublock, Quartier, Bezirk, PLZ, Stadtteil)	**Makro-Ebene** Bezugsflächen größer als der Siedlungsraum (Gemeinde, Landkreis, Region)
Qualitativ (Typen, Arten, Gruppen)	statisch	Gebäudetyp nach Baualtersklasse oder Nutzung	Städtebaulicher Strukturtyp, Überwiegendes Baualter, Flächennutzungstyp	Siedlungsstrukturelle Gebietstypen, Verdichtungsräume, Raumstrukturtypen, Regionstypen
	dynamisch	Zustandsänderung (Abriss, Neubau)	Zustandsänderung (Änderung der Flächennutzung), Siedlungserweiterung nach Jahr	Qualitative Änderung, Geometrische Änderung (neue Abgrenzung), Wachsende und schrumpfende Gemeinde
Quantitativ (siedlungsstrukturelle Merkmale)	statisch	Bevölkerungszahl, Energiebedarf, A/V-Verhältnis, Größe, Gebäudehöhe	Bevölkerungsdichte, Überbauungsgrad, Energiebedarf	Zerschneidungsindex, Fraktale Dimension, Anteil SuV, Kompaktheit der Siedlung, Bevölkerungsdichte pro Gebietsfläche, Bevölkerungsstruktur, Nutzungsstruktur
	dynamisch	Änderung des Leerstands, Änderung des Abstands zur nächsten Haltestelle	Änderung der Bevölkerungsdichte, Änderung des Überbauungsgrades	Änderung der Siedlungs- und Verkehrsfläche (SuV) in der Gemeinde, Änderung der Bevölkerungszahl
Praktische Anwender (Kartennutzer)		Örtliche Planung zum Denkmalschutz oder Stadtgestaltung	Stadtstrukturplanung, Regionalplanung, Fachplanung	Raumbeobachtung, Politik, Wirtschaft

2.3.2.3 Planungskarten

Die meisten thematischen Karten sind zugleich Planungskarten. Die Planungskartographie, als eine der breitesten Anwendungsbereiche der thematischen Kartographie, befasst sich mit der „Konzeption, Herstellung und Nutzung von Karten in der raumbezogenen Planung" (Bollmann & Koch, 2001, Stichwort: Planungskartographie). Die Erzeugnisse in Form von Planungskarten gelten als die am häufigsten erstellten Karten und werden sowohl bei der örtlichen (Stadt- und Gemeindeebene) als auch bei der überörtlichen Planung (Regional-, Landes- und Bundesplanung) eingesetzt. Planungskarten lassen sich nach der Planungsphase wie folgt unterscheiden (ARL, 1991):

- Planungsgrundlagenkarten
- Planungsbeteiligungskarten
- Planungsfestlegungskarten

Grundvoraussetzung jeder Planung sind *Planungsgrundlagenkarten*, auch Bestandskarten genannt, in denen planerisch relevante Geoinformation abgebildet ist. Für die Erstellung können geotopographische Basisdaten sowie thematische Fachinformationen hinzugezogen werden. Die Fachdaten können aus statistischen Informationssystemen (z. B. sozioökonomische Daten) übernommen oder durch räumliche Analysen im GIS (z. B. auf Grundlage von Fernerkundungsdaten) gewonnen werden. Auf städtischer Ebene sind das beispielsweise baublockbezogene Informationen zur Dichte der Bebauung oder der Bevölkerung, zur Verkehrsinfrastruktur oder zur Ver- und Entsorgungsstruktur. Auf Bundesebene könnte die Grundlage auch eine Raumabgrenzung bzw. Gebietstypisierungen sein, wie z. B. die siedlungsstrukturellen Gebietstypen der laufenden Raumbeobachtung am Bundesinstitut für Bau-, Stadt- und Raumforschung (BBSR, 2012a).

Die *Planungsbeteiligungskarten* vermitteln die konzeptionellen Ideen und sind Arbeitsmittel während der kreativen Phase einer Planung. Heutzutage spielen in diesem Zusammenhang interaktive Karten, kartenverwandte Darstellungen bis hin zu virtuellen 3D-Landschaften, in denen die zukünftige Planung virtuell modelliert ist, eine zunehmende Rolle. Nach Abschluss der Planung münden die Ergebnisse des Entscheidungsprozesses in rechtsverbindliche *Planungsfestlegungskarten*, in denen die kartographische Gestaltung festgelegt ist. Bekannte Planungsfestlegungskarten sind der Bebauungsplan (Maßstab 1: 1 000), der Flächennutzungsplan (Maßstab 1: 10 000) oder Regional- und Landesentwicklungspläne.

2.3.2.4 Thematische Stadtkarten

Beschränkt man Karten auf die Darstellung der inneren Differenzierung städtischer Räume, was einer Fokussetzung auf die Darstellung siedlungsstruktureller Merkmale auf Mikro- und Mesoebene gleichkommt (vgl. Abb. 2-6), so spricht man von thematischen Stadtkarten. Hierzu hat sich in den 1980er Jahren die Stadtkartographie als eigener, anerkannter Darstellungszweig der Kartographie herausgebildet (Gorki & Pape, 1987). Mit Betonung auf innerstädtische Gliederung werden jene Karten ausgeblendet, welche die räumliche Verteilung von Städten darstellen. Der Begriff der Stadt als Kartengegenstand kann dabei sehr unterschiedlich betrachtet werden. Einerseits gehört das geographische Phänomen Stadt „in die Gruppe der Siedlungen, d. h. der menschlichen Niederlassungen, deren Umfang vom Ein-

zelwohnplatz über kleine und größere bis zu größten Verbänden von Wohn- und Arbeitsstätten reicht" (Gorki & Pape, 1987: S. 10). Die Herausforderung bei einer solchen Betrachtung liegt in der klaren Abgrenzung der Stadt von ländlichen Siedlungen (Borsdorf & Bender, 2010; vgl. Hofmeister, 1993). Andererseits umfasst die Stadt aus administrativer Sicht das gesamte Gemeindegebiet „Stadt". Bei dieser streng administrativen Sicht beinhaltet die Stadtfläche im peripheren Raum meist auch Gebiete mit völlig ländlichem Charakter. Verwaltungsreformen, wie die Zusammenschließung von Gemeinden, verstärken diesen Effekt in Deutschland besonders, so dass man faktisch sowohl städtische als auch ländliche Siedlungen stadtkartographisch betrachten kann und muss.

In Abb. 2-6 ist die Gliederung thematischer Stadtkarten nach Gorki & Pape (1987) dargestellt. Demnach kann die Herstellung sowohl behördlich als auch nichtbehördlich erfolgen. Die behördliche Stadtkartographie erstreckt sich grundsätzlich auf das gesamtstädtische Gemeindegebiet, während nichtbehördliche Karten mit freier Gestaltung im Umfang der dargestellten Räume und Gestaltung sehr vielfältig sein können (lokale Betrachtung des Zentrums, Stadt-Umland-Betrachtung etc.). Karteninhalt und Entwurf behördlicher Karten unterliegen Normen, wie z. B. einheitlichen Gestaltungsgrundsätzen und sind somit gleichsam Planungsfestlegungskarten.

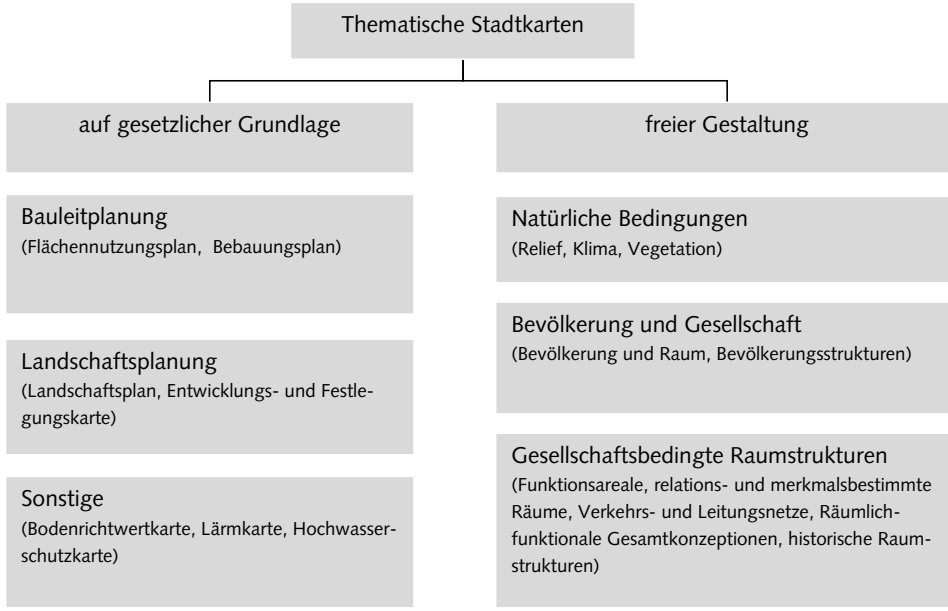

Abb. 2-6: Gliederung thematischer Stadtkarten nach Gorki & Pape (1987) mit Bezug auf Schriever (1970)

Karten zur sozio-ökonomischen Siedlungsstruktur lassen sich dem Bereich „Bevölkerung und Gesellschaft" und Karten zur funktionalen und morphologischen Siedlungsstruktur dem Bereich der „Gesellschaftsbedingten Raumstrukturen" zuordnen. Aber auch Stadtkarten auf gesetzlicher Grundlage enthalten siedlungsstrukturelle Informationen, wenn beispielsweise im Bauleitplan die Art (z. B. Wohngebiete, Mischgebiete, Kerngebiete) oder das Maß der

festgelegten baulichen Nutzung (z. B. Grundflächenzahl, Geschossflächenzahl, Bauhöhe und Anzahl der Vollgeschosse) kartographisch wiedergegeben ist. Neben einer Klassifizierung der Karten liefern Gorki & Pape in dem 2-bändigen Werk „Stadtkartographie" auch wissenschaftlich-methodische Konzepte zur kartographischen Umsetzung verschiedener Themen zur Siedlungsstruktur und bebildern dies mit anschaulichen Beispielen aus der Praxis. Die darin beschriebenen Lösungsansätze bieten eine Grundlage für die Umsetzung der kartographischen Visualisierung von Ergebnissen aus Analysen zur Siedlungsstruktur.

2.4 Räumliche Analyse von Siedlungsstrukturen

Die Siedlungsstruktur steht im Fokus verschiedener wissenschaftlicher Disziplinen der Geographie (Stadtmorphologie, Sozialgeographie, Stadt- und Raumplanung). Im Folgenden werden verschiedene Konzepte und Modelle zur Beschreibung der Siedlungsstruktur vorgestellt und im letzten Abschnitt wird auf Methoden zur automatisierten Gewinnung von Informationen zur Siedlungsstruktur eingegangen.

2.4.1 Innerstädtische Gliederung

Um Siedlungen und deren Entwicklung besser zu verstehen, werden räumliche Gliederungsansätze entwickelt. Diese reichen von stark idealisierten Modellen der Stadtgeographie, die auf qualitativen Ansätzen basieren, bis hin zu komplexen, quantitativen computerbasierten Modellen der Stadtmorphologie und Architektur, mit der eine Beschreibung räumlicher Zustände und Entwicklungsprozesse im urbanen Raum möglich werden.

Besonderes Augenmerk wird den städtischen Siedlungen beigemessen – und dies nicht nur, weil der Anteil der in Städten lebenden Weltbevölkerung im Jahr 2030 doppelt so hoch sein wird als noch im Jahr 1950 (UNO, 2011). Als komplexes urbanes System stellt die Stadt seit Jahrzehnten einen reizvollen aber auch herausfordernden Forschungsgenstand in der Geographie, der Architektur, der Planung, des Städtebaus und der räumlichen Datenanalyse dar. Der französische Ethnologe und Anthropologe Claude Lévi-Strauss bezeichnete die Stadt 1954 als „the most complex of human inventions,… at the confluence of nature and artifact" (zitiert in Moudon, 1997: S. 3). Damit wird deutlich, dass man für eine Modellierung von Städten entweder sehr komplizierte Modelle benötigt oder stark abstrahieren muss. Die Charakterisierung des Geographen Steve Pile, mit der „das Wesen der Stadt als unvollendet, ungewiss und immer im Werden begriffen" beschrieben ist (Pile, 1999; übersetzt von Simms, 2004: S. 54), zeigt hingegen den ständigen und unberechenbaren Wandel sowie die hohe Dynamik städtischer Siedlungen. Alldem zu begegnen benötigt klare Konzepte und Modelle, die in der Vergangenheit von verschiedenen Forschergruppen unterschiedlicher Disziplinen entwickelt und kommuniziert wurden.

Suburbanisierungsprozesse führen in Industriestaaten zur Verstädterung ländlicher Siedlungen und somit zu einem schwindenden Stadt-Land-Gefälle. Eine geographische Abgrenzung der Stadt wird damit immer schwieriger. Darum löst sich die Trennung der humangeographischen Disziplinen „Stadtgeographie" und „Geographie ländlicher Siedlungen" zunehmend auf, was den Fokus auf den gesamten Siedlungsraum (ländliche Siedlungen und Städte) notwendig macht (Borsdorf & Bender, 2010). Es wird in dieser Arbeit darum im Sinne der

Siedlungsgeographie[21] jede menschliche Niederlassung, angefangen bei Einzelsiedlungen, wie einzelnen Gehöften, bis hin zu Megastädten als Siedlung aufgefasst. Die folgenden Modelle weisen jedoch einen starken städtischen Bezug auf.

2.4.1.1 Stadtstrukturmodelle der funktionalen Stadtgeographie

Das Ordnen der Stadt nach der Funktion (Wohnen, Arbeiten, Erholung) gehört spätestens seit der Charta von Athen von 1993 zum Ordnungsprinzip des Städtebaus. Die stark von den Soziologen geprägte Stadtgeographie der ersten Hälfte des 20. Jahrhunderts brachte die klassischen Modelle der „Chicagoer Schule" (Abb. 2-7), wie das konzentrische Ringmodell (Zonenmodell) von Burgess (1925), das Kreissektorenmodell von Hoyt (1939) oder das Mehrkernmodell von Harris & Ullmann (1945), hervor (vgl. Hofmeister, 1980). Später entwickelte Modelle beziehen die Stadtstruktur auf einen bestimmten Kulturraum, wie etwa auf die europäische, orientalische oder lateinamerikanische Stadt (Heineberg, 2006c, 2006a; vgl. Hofmeister, 1980).

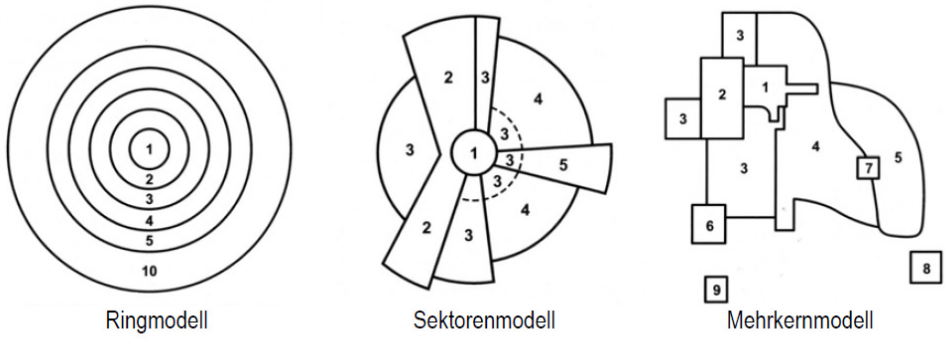

1: Innenstadt (CBD), 2: Großhandel und Leichtindustrie, 3: Wohngebiete der Unterklasse, 4: Wohngebiete der Mittelklasse, 5: Wohngebiete der Oberklasse, 6: Schwerindustrie, 7: außerhalb liegende Geschäftszentren, 8: Wohnstandorte im suburbanen Raum, 9: Industrie im suburbanen Raum, 10: Pendlerzone

Abb. 2-7: Stadtstrukturmodelle der funktionalen Stadtgeographie (Quelle: Schemionek, 2005)

Diese stark vereinfachten und idealisierten Strukturmodelle lassen sich nur schwer explizit in der realen Welt wiederfinden. Sie stellen die wesentlichen Zusammenhänge in abstrakter Weise einprägsam dar, ohne jedoch die topographischen Gegebenheiten exakt und maßstabsgetreu wiederzugeben. Aus kartographischer Sicht werden diese „Stadtmodelle" gesondert betrachtet, da sie keine konkreten Örtlichkeiten und Räume darstellen, sondern aus einer Vielzahl von Einzelbeobachtungen abstrahiert wurden (Gorki & Pape, 1987: S. 405).

[21] „Die Siedlungsgeographie erfasst, beschreibt und erklärt den Siedlungsraum im Ganzen und in seinen Teilen, den menschlichen Siedlungen, nach der Lage, Baumaterial, den Haus- und Siedlungsformen, der Siedlungsstruktur, den Kräften und Funktionen, die diesen Formen und Strukturen innewohnen beziehungsweise diese herbeiführen sowie der zeitlichen Entwicklung, die zu den gegenwärtigen Formen und Strukturen geführt hat. Als angewandte Siedlungsgeographie schreibt sie die laufenden Prozesse in Zukunft fort, bewertet die aktuellen Strukturen und Prozesse und stellt Entscheidungshilfen für die zukünftige Entwicklung des Siedlungsraumes zur Verfügung" (Borsdorf & Bender, 2010: S. 30).

2.4.1.2 Modelle der Sozialraumanalyse

Die Sozialraumanalyse geht auf Shevky und Bell (1955) zurück und stellt ein quantitatives Instrument zur sozialräumlichen innerstädtischen Gliederung dar. Im Gegensatz zu eben beschriebenen Stadtstrukturmodellen zielt dieses Modell auf eine Klassifizierung städtischer Teilräume ab. Unter Annahme einer konzentrischen oder sektoralen Entwicklung wird die Stadt auf Grundlage von Merkmalen, mit denen die wesentlichen Prozesse des sozialen Wandels beschrieben werden, differenziert (Hoffmeyer-Zlotnik, 2005). Mithilfe geeigneter Indikatoren und der Nutzung statistischer Verfahren der Faktoren- oder Clusteranalyse lassen sich verschiedene städtische Teilräume nach dem Sozialen Rang, Urbanismus und Segregation klassifizieren. Eine derartige innerstädtische Typisierung kann nach Hoffmeyer-Zlotnik (2005) am besten auf Grundlage kleinräumiger Zensusdaten (z. B. auf Wahlbezirksebene) durchgeführt werden.

Die Sozialraumanalyse bietet die Möglichkeit Städte miteinander zu vergleichen, wie etwa mit dem von Simon (1990) entwickelten Ring-Sektoren-Modell. Das Modell ist als Weiterentwicklung der Zirkelschlag-Methode zu sehen, mit der ausgehend eines definierten Stadtzentrums die Bevölkerungsdichte über konzentrische Ringe ausgewertet wird (Clark, 1951). Im Ring-Sektoren-Modell von Simon werden die konzentrischen Ringe zusätzlich mit 10 Sektoren überlagert. Die Schnittmenge bilden Zonen, die mit den Volkszählungsdaten belegt werden und eine Struktur im Ring-Sektoren-Modell bilden. Auf dieser Grundlage können Siedlungsstrukturen über die Zeit beobachtet oder verschiedene Städte miteinander verglichen werden.

2.4.1.3 Stadtbildanalyse der Wahrnehmungsgeographie

Einen wichtigen Einfluss auf die Stadtforschung hatte der Architekt, Stadtplaner und Theoretiker Kevin Lynch. Mit seinem Werk „The Image of the City" (Lynch, 1960) trug er dazu bei, kognitive Karten (engl. *mental maps*) in die Sozialgeographie einzuführen. Lynch beschreibt einen innerstädtischen Strukturierungsansatz, der allein auf Grundlage der menschlichen Wahrnehmung basiert. Das Bild der Stadt setzt sich dabei aus fünf Elementen zusammen: Wege (*paths*), Ränder (*edges*), Bereiche (*districts*), Brennpunkte (*nodes*) und Merkzeichen (*landmarks*). Wege sind jene Kanäle, durch die sich ein Beobachter bewegt (z. B. Straßen, Wege, Wasserwege, Eisenbahn). Ränder sind die linearen Elemente, die nicht als Weg benutzt, aber als lineare Grenzlinie im Sinne einer Unterbrechung (z. B. Mauern, Küstenufer) wahrgenommen werden. Bereiche sind flächenhafte Einheiten, die über eine thematische Kontinuität verfügen (z. B. Bereich mit einem bestimmten Baustil oder Nutzung). Brennpunkte sind für den Beobachter genutzte Knotenpunkte (z. B. Straßenkreuzungen, U-Bahnstationen) oder Konzentrationspunkte (z. B. Zentrum). Die Merkzeichen sind hingegen jene Bezugspunkte, die vom Beobachter nicht begangen werden können, aber visuell aus Distanz wahrgenommen werden (z. B. Schilder, markante Gebäude, Türme). In der Studie ließ Lynch am Beispiel amerikanischer Städte mehrere Probanden ihre eigenen Vorstellungsbilder mithilfe dieser Elemente kartieren. Die Elemente stehen miteinander in Beziehung und bilden zusammen das vom Menschen subjektiv wahrgenommene Stadtbild. Diese kognitiven Karten weisen meist größere Verzerrungen auf, besitzen jedoch eine starke topologische Übereinstimmung mit der Wirklichkeit. Ziel einer solchen Analyse der subjektiven Raum-

wahrnehmung kann die Beantwortung stadtplanerischer Fragestellungen (Image, Einkaufsverhalten, Verkehrsplanung etc.) oder Untersuchungen verschiedener Raumwahrnehmungsmuster auf raumspezifisches Verhalten sozialer Gruppen sein (vgl. Fichtinger et al., 1974). Lynch sah in seiner Arbeit die Chance für neue Entwurfsmethoden in der städtebaulichen Gestaltungsplanung.

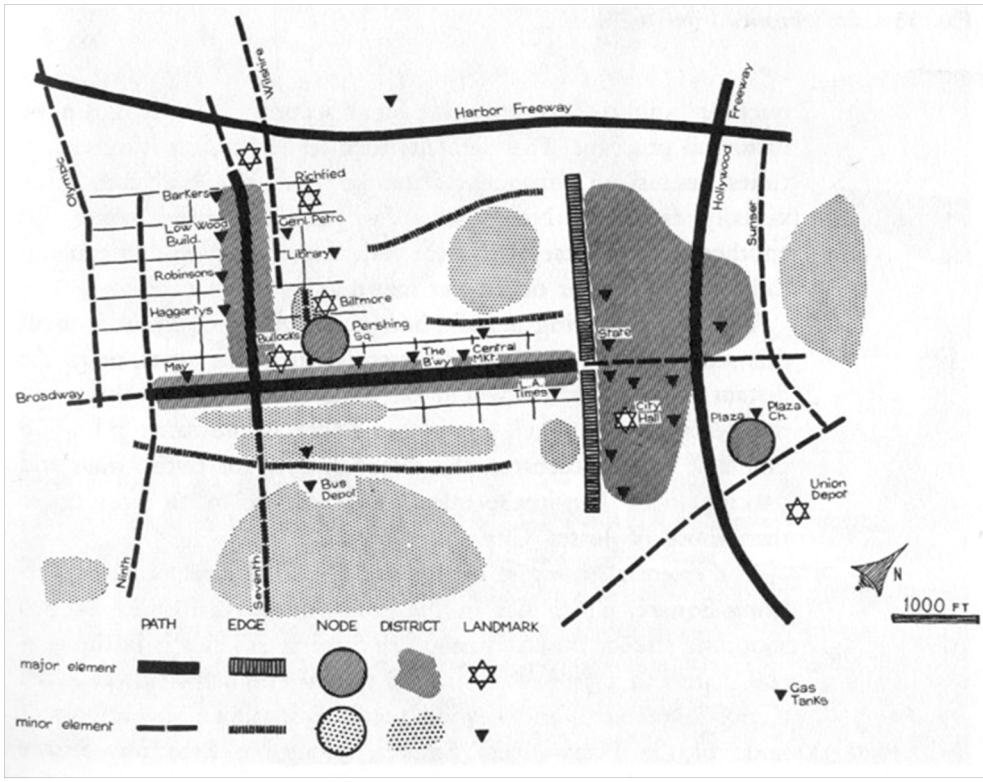

Abb. 2-8: Stadtgestalt von Los Angeles entsprechend den Aufzeichnungen geschulter Beobachter (Quelle: Lynch, 1960)

2.4.2 Stadtmorphologische Analyse

Eine sehr bedeutende und bekannte Form der innerstädtischen Gliederung ist das Ergebnis einer stadtmorphologischen Untersuchung. Nach dem Architekten und Städteplaner Gerhard Curdes ist mit Stadtmorphologie (engl. *Urban Morphology*) „der Zusammenhang von Bauten, Anlagen und Freiräumen gemeint, also das baulich räumliche Gefüge, welches das komplexe System Stadt im Kern bestimmt" (Curdes, 1997: S. VII). Forschungsgegenstand der Stadtmorphologie ist die Stadtgestalt nach dem äußeren Erscheinungsbild sowie ihrer Entwicklung. Neben der Grundriss- und Aufrissgestaltung der Städte finden hier auch historische Phänomene der Stadtentstehung Berücksichtigung, was zu dem Begriff der morphogenetischen Stadtgeographie führt (Heineberg, 2006c).

Die morphogenetische Stadtgeographie hat im deutschen Sprachraum eine lange Tradition, die mit Otto Schlüters „Über den Grundriß der Städte" (Schlüter, 1899) begann und über

die nächsten drei Jahrzehnte ihre Blütezeit hatte (u. a. Geisler, 1924; Martiny, 1928). Einen detaillierten Überblick verschaffen hierzu Hofmeister (2004) und Heineberg (2006b). Nach dem Zweiten Weltkrieg trat die Stadtmorphologie jedoch verglichen mit anderen geographischen Forschungsaktivitäten in den Hintergrund. Mit dem Fokus auf eher funktionale Ansätze verlor die Stadtmorphologie in Deutschland an Bedeutung. Bis heute hat sie eine „relativ ‚untergeordnete' Stellung [...] innerhalb der Geographie" und ist ein lange vernachlässigtes Thema (Heineberg, 2006b: S. 6). Dem Autor nach ist es auch dem Fakt geschuldet, dass sich in Deutschland keine ausgeprägte Forschergruppe oder Schule der Stadtmorphologie herausgebildet hat und es darum auch an einem aktuellen Lehr- und Handbuch fehlt. Es wird im Folgenden deshalb Bezug auf die international bedeutenden Arbeiten der britischen Stadtmorphologie genommen.

2.4.2.1 Stadtplananalyse von Conzen

Mit der Krise der Innenstädte in Europa ab den 1970er Jahren gewann die Stadtgestalt wieder an Bedeutung, was zur Entwicklung neuer Methoden und Techniken in der Stadtmorphologie führte (Simms, 2004). Mit der von Jeremy Whitehand gegründeten Urban Morphology Research Group (UMRG) der University of Birmingham entstanden seit den 1980er Jahren wichtige Arbeiten auf dem Gebiet der Stadtmorphologie. Methodologisch stützen sich die Arbeiten auf die Ideen des deutschen Geographen Michael R. G. Conzen, der 1933 naziregimebedingt die Flucht nach England ergriff und in Newcastle upon Tyne forschte. Vor allem die Stadtplananalyse von Conzen (1960) stellte erstmals einen begrifflichen Rahmen in der Stadtmorphologie auf (Simms, 2004). Bei seiner Arbeit unterschied Conzen zwischen dem Stadtplan (*town-plan*), der städtischen Landnutzung (*land-use pattern*) und der Bebauung (*building-fabric*). Der Stadtplan bildet sich aus den drei Elementen: Straßen (*streets*), Hausparzelle (*plots*) und Gebäude (*building*). Mit der städtischen Landnutzung wird die Funktion und mit der Bebauung der architektonische Stil wiedergegeben. Am Beispiel der Stadt Alnwick wurden mit der Stadtplananalyse charakteristische Phasen der urbanen Entwicklung identifiziert, die durch ökonomische und soziale Kräfte geprägt sind. In diesem Zusammenhang entwickelte Conzen zwei weitere Konzepte der Stadtmorphologie. Zum Einen den Hausparzellen-Zyklus (*burgage-cycle*), bei dem er von einer schrittweisen völligen Bebauung einer Hausparzelle ausgeht, solange bis ein neuer Wirtschaftaufschwung zum Abriss und einer totalen Neubebauung führt. Ein anderes Konzept ist die sog. Stadtrandzone (*fringe belt*), die den Übergangsbereich einer städtischen Agglomeration zu ihrer ländlichen Umgebung beschreibt. Diese beiden Konzepte beziehen sich auf die vorliegende Bebauungsintensität, die als Folge wirtschaftlichen und sozialen Wandels gesehen werden (Simms, 2004). Mithilfe einer Analyse der Stadtgrundrissgestalt lassen sich deshalb ökonomische und soziale Entwicklungen in der Morphologie ablesen.

Die Ideen von Conzen werden in der UMRG bis heute verfolgt und international transportiert (Whitehand, 2001, 2007). Insbesondere mit der Gründung des Arbeitskreises *International Seminar on Urban Form* (ISUF) und einer eigenen Zeitschrift *Urban Morphology* besitzt diese als „conzenian school" bezeichnete Stadtmorphologie in Großbritannien große internationale Anerkennung (Heineberg, 2006b).

2.4.2.2 Modell von Krüger

Das *Centre for Land Use and Built Form Studies* (CLUBFS), später umbenannt in *Martin Centre for Architectural and Urban Studies* der Cambridge Universität, bildet eine weitere wissenschaftliche Säule, die sich mit dem städtischen Raum und deren Strukturen aus architektonischer Sicht beschäftigt. Beispiele hierfür sind die Arbeiten von March & Steadman (1974) und Martin & March (1972), in denen die Form und räumliche Organisation der Bebauung untersucht, mathematisch formalisiert und Archetypen herausgearbeitet werden. Aktuelle Ergebnisse der Cambridge-Schule werden heute über das Journal *Environment an Planning B: Planning & Design* publiziert.

Im Zusammenhang mit eben erwähnter Schule, soll das Modell von Krüger (1979a, 1979b) kurz vorgestellt werden. Dieses stellt einen formalen Rahmen zur Modellierung eines urbanen Systems (engl. *urban system*) mithilfe von Objekten und Beziehungen. Über Graphen wird eine vertikale hierarchische Beziehung zwischen den Objekten „Gebäude" (*Built-Unit*), „Gebäudekomplexen" (*Built-Form Array*), „Baublock" (*Built-Form-Constellation*) und der gesamten „Siedlung" (*Built-Form Galaxy*) hergestellt. Auf der detailliertesten Ebene formen die Gebäude einen Gebäudekomplex. Auf der nächsten Ebene wird aus der Menge der Gebäudekomplexe wiederum ein Baublock gebildet usw. Wenngleich die Terminologie von Krüger etwas gewöhnungsbedürftig erscheint, so wird der graphenbasierte Ansatz auch heute noch aufgegriffen, um beispielsweise Landnutzungskategorien in Bilddaten zu erkennen (Barr & Barnsley, 1998, 2004). In diesem Anwendungsfall repräsentieren die Graphen Nachbarschaftsbeziehungen zwischen homogenen Bildregionen, die mittels Bildanalyse ermittelt werden.

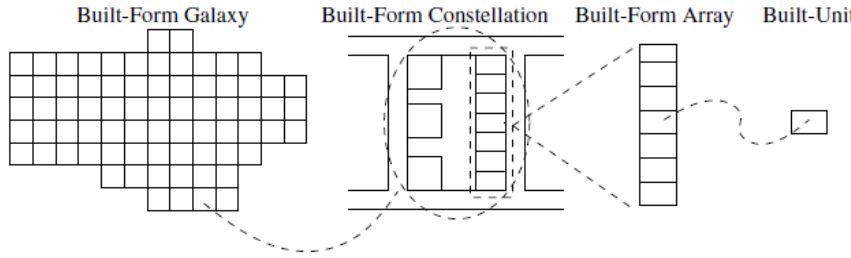

Abb. 2-9: Schematische Darstellung der Hierarchie-Level des Modells von Krüger (Quelle: Barr & Barnsley, 2004, im Original von Krüger 1979)

2.4.2.3 Space-Syntax-Theorie

Ein weiterer Forschungsansatz zur Strukturierung und Analyse von Siedlungsräumen ist die von Hillier & Hansen (1984) entwickelte Space-Syntax-Analyse (engl. *space syntax analysis*). Dieser Ansatz wurde in den 1970er Jahren an der University of London (UCL) als ein Werkzeug konzipiert, um Architekten zu helfen, soziale Effekte in bewohnten Raumstrukturen zu analysieren. Die Idee der *Space Syntax* besteht darin, den Raum in Teilräume zu zerlegen und darauf aufbauend ein topologisches Netzwerk zu konstruieren und zu analysieren. Die Teilräume können Räume in Gebäuden sowie auch öffentliche Plätze im urbanen Raum sein. Das Netzwerk als Graph repräsentiert die räumliche Ordnung. Man unterscheidet dabei zwei

analytische Konzepte: Die „convex map" und die „axial map". Durch Analyse der „convex map" ist es möglich, die Integrität und damit die Interaktion zwischen den Bewohnern zweier Teilräume zu messen. Mithilfe der „axial map", als lineare Abstraktion des urbanen Bewegungsraums, kann hingegen das Bewegungsmuster innerhalb der räumlichen Anordnung untersucht werden (Erreichbarkeit, Zentralität). Die Space-Syntax-Analyse wird bereits erfolgreich in der Planungspraxis eingesetzt, um beispielsweise Ursachen einer schlechten Verkehrsanbindung innerhalb des räumlichen Gefüges aufzudecken und optimierte Lösungsvorschläge zu entwerfen (Rose et al., 2008). Des Weiteren belegen Untersuchungen einen Zusammenhang zwischen Kenngrößen der Space Syntax-Analyse und der Fußgängeraktivität (Jiang, 1999), sozialen Daten (Anders et al., 2010; Omer & Gabay, 2007) oder der Raumwahrnehmung (Dara-Abrams et al., 2010). Aktuelle Forschungsergebnisse werden über das Journal *The Journal of Space Syntax*[22] publiziert. Eine Integration der Space-Syntax-Analyse in GIS birgt jedoch noch Herausforderungen in der automatische Erzeugung der „axial map" (Jiang & Claramunt, 2002; Liu & Jiang, 2010).

2.4.2.4 Fraktale Stadt

Mit Veröffentlichung des Buches „Fractal Cities: A Geometry of Form and Function" von Batty & Longley (1994) gewann die „fraktale Stadt" weiter an Bedeutung. Siedlungsmuster werden dabei als sich selbstorganisierende fraktale Struktur aufgefasst. Das von Mandelbrot (1983) eingeführte Konzept der „fraktalen Geometrie" wurde hierbei aufgegriffen und auf urbane Strukturen angewandt. Die Stadt wird demzufolge aus sich selbst wiederholenden Fraktalen gebildet, d. h. komplexe Strukturen setzen sich aus einfachen Bausteinen zusammen. Dieses Prinzip der Selbstähnlichkeit bildet die Ausgangsbasis für die computergestützte Generierung urbaner Stadtmodelle (u. a. König, 2010).

2.4.3 Computerbasierte Analyse der Siedlungsstruktur

Der Einzug neuer Technologien, wie Computer, GIS und Fernerkundungssysteme, hatte auch Auswirkung auf die Stadtforschung. Mithilfe der digitalen Bildverarbeitung war man bereits Anfang der 1980er Jahre in der Lage, historische Pläne und Luftbilder zu überlagern und die Entwicklung einer Siedlung zu untersuchen (Koster, 1998). Dank verbesserter Hard- und Software und dem überaus reichhaltigen Geodatenangebot an Bild- und Vektordaten können heute weitaus komplexere Phänomene untersucht werden. GIS und computerbasierte Modelle spielen darum eine immer wichtigere Rolle in der Raumwissenschaft und Stadtplanung, da sie helfen, theoretische Modelle empirisch nachzuweisen oder neue Erklärungsmuster aufzudecken. Dazu gehört beispielsweise die Untersuchung von Zusammenhängen zwischen der morphologischen Gestalt und der Funktion (Barr et al., 2004) oder die Entwicklung völlig neuer Theorien, wie etwa die der fraktalen Stadt (u. a. Batty & Longley 1994; Longley 2002). Im Folgenden werden die wichtigsten Werkzeuge der räumlichen

[22] http://www.journalofspacesyntax.org

Analyse vorgestellt und anschließend auf die Möglichkeiten der automatisierten Analyse der Siedlungsstruktur eingegangen.

2.4.3.1 Räumliche Analyse in GIS

Unter räumlichen Analysen (engl. *spatial data analysis*) werden jene Methoden zusammengefasst, mit denen auf Grundlage räumlicher Daten Muster erkannt, Anomalien entdeckt oder Theorien bzw. Hypothesen getestet werden können (Shekhar et al., 2008). Dabei werden Analyse, Synthese aber auch Simulationen und Prognosen zu einem Konglomerat vereint (Bill, 1999). Mithilfe von Funktionen in GIS können raumbezogene Daten analysiert (Analyse), deren Ergebnisse in einem Visualisierungs- oder Klassifikationsprozess kombiniert und interpretiert (Synthese) und in weiteren Schritten für Simulationen oder Vorhersagen genutzt werden. Die räumliche Analyse dient somit der Gewinnung neuer Erkenntnisse bzw. Informationen aus räumlichen Daten.

Viele Methoden der räumlichen Analyse gehen auf die räumliche Statistik der 1960er zurück, die im Buch „Spatial Analysis" von Berry & Marble (1968) zusammengetragen sind. Mit der Kommerzialisierung von GIS gewannen die Methoden schnell Bedeutung in verschiedenen angewandten Raumwissenschaften, wie der Landschaftsökologie, der Regional- oder der Stadtforschung bis hin zu Versicherungswirtschaften. Ohne Beachtung der qualitativen Verfahren der räumlichen Analyse lässt sich das Methodenspektrum der räumlichen Analyse heute dem heutigen Arbeitsgebiet der quantitativen Geographie (engl. *quantitativ geography*) zuordnen, dessen Aufgabenfeld die Analyse nummerischer Geodaten, die Entwicklung räumlicher Theorien und die Entwicklung und Prüfung mathematischer Modelle zur Beschreibung räumlicher Prozesse umfasst (Fotheringham et al., 2000).

Für die Analyse und Modellierung räumlicher Strukturen und Prozesse spielen zwei grundlegende Konzepte eine Rolle. Das sind zum einen diskrete Objekte und die kontinuierlichen Felder (Skupin, 2009), für die ein jeweils unterschiedliches Methodenspektrum bereitsteht. Die Analysemethoden können auch nach der Art des Bezugs (geometrisch-topologische, semantische sowie zeitliche) unterschieden werden, obwohl eine strikte Trennung oft nicht möglich ist, da sich beispielsweise eine Abstandsberechnung sowohl auf die Geometrie (metrischer Abstand) als auch die Semantik (semantischer Abstand) beziehen kann (Bill, 2010). In der Literatur sind verschiedene Klassifikationen der Methoden zu finden (Bill, 2010; Fotheringham et al., 2000; Longley et al., 2005; Smith et al., 2007).

Die Abb. 2-10 zeigt die Klassifikation nach Longley et al. (2005) mit der grundlegende Analysefunktionen (Abfragen, Messungen und Transformationen) und komplexere Methoden (Deskriptive Maße, Optimierung, Hypothesentests) unterschieden werden. Durch Kombination verschiedener Funktionen können weitaus komplexere Modelle entwickelt werden, um statische Erscheinungen (Flächennutzung, Bebauungsdichte etc.) oder dynamische Prozesse (Siedlungsentwicklung, Zersiedelung, Pendlerverhalten etc.) auf unterschiedlichen räumlichen Ebenen zu modellieren.

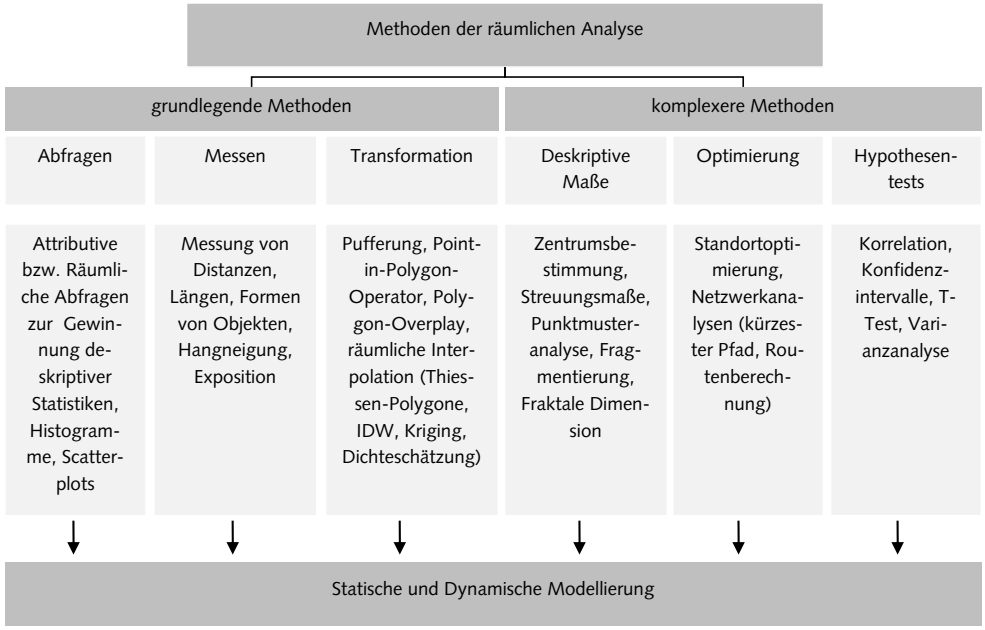

Abb. 2-10: Methoden der räumlichen Analyse nach Longley et al. (2005)

Im Zuge des Wandels zu einer Informationsgesellschaft und dem immer größer werdenden Angebot an Daten spielen Methoden der Wissensentdeckung in Datenbanken (engl. *Knowledge Discovery in Databases*, kurz KDD) und insbesondere das *Data Mining* als Teil des KDD-Prozesses eine immer bedeutendere Rolle. Mit der Technik des *Geographic Data Mining* (Miller & Han, 2001) werden beispielsweise räumliche Analysefunktionen mit Methoden des Data Mining gekoppelt, um neue Informationen zu gewinnen. Ziel ist insbesondere die Erkennung räumlicher Cluster, die Erkennung solcher Cluster verursachender Objekte und die Erklärung der für die räumliche Clusterbildung verantwortlichen Faktoren (Bill & Zehner, 2001). In der Dissertation „Urban Data Mining" (Behnisch, 2009) werden verschiedene Data Mining-Techniken (Clusterings, Kerndichteschätzung etc.) vorgestellt, um räumliche und zeitliche Ähnlichkeitsmuster zu erkennen. In den nächsten Abschnitten werden Modellierungsansätze vorgestellt, mit denen neue Informationen und Erkenntnisse zur Siedlungsstruktur gewonnen werden können.

2.4.3.2 Analyse der Siedlungsstruktur

Ziel einer Analyse der Siedlungsstruktur (Siedlungsstrukturanalyse, Stadtstrukturanalyse, engl. *urban structure analysis*) ist es, die Struktur der Siedlung sowie deren Entwicklung mithilfe objektiver Maßzahlen zu quantifizieren bzw. systematische Strukturen (Muster) zu identifizieren und zu untersuchen. Die Analyse der Siedlungsstruktur leistet dabei einen wichtigen Beitrag zur Gewinnung neuer thematischer Information, die durch kartographische Visualisierung dem Erkenntnisgewinn dient.

Die angewandten Methoden der Siedlungsstrukturanalyse sind dabei sehr vielfältig und immer maßstabs-, zweck-, und datengebunden. Der Fokus liegt oftmals auf:

- der Charakterisierung der Siedlungsstruktur mithilfe von Strukturmaßen (z. B. Kompaktheit, Größe, Anordnung der Elemente),
- der Ableitung planungsrelevanter Indikatoren für ein Monitoring (u. a. Überbauungsgrad, Bodenversieglung, Vegetationsflächenanteil, Einwohnerdichte),
- der räumlichen Abgrenzung homogener Bereiche (u. a. Stadt-Land-Abgrenzung, Zonierung der Siedlung) oder
- der Klassifizierung der Siedlungsstruktur (u. a. Gebäudetypen, Stadtstrukturtypen).

Zur Charakterisierung der Siedlungsstruktur werden quantitative Strukturmaße eingesetzt, die mithilfe der räumlichen Analyse in einem GIS automatisch abgeleitet werden können. Dies sind beispielsweise die Flächengröße und die Kompaktheit eines Siedlungskörpers oder der Anteil der überbauten Fläche in Bezug einer Siedlungseinheit. In diesem Zusammenhang spielen die aus der Landschaftsökologie bekannten Strukturmaße (engl. *landscape metrics*) eine wichtige Rolle, mit der auch die Zusammensetzung (Anzahl und Art) und Anordnung (Orientierung, Lage, Abstände) von Landschaftselementen (*patches*) im Raum beschrieben werden können. Verschiedene Algorithmen zur Bestimmung der Diversität, der Fragmentation, der Fraktalen Dimension sowie des Contagion-Index oder des Lakunaritätsmaßes sind bereits in der Software FRAGSTATS[23] implementiert (McGarigal & Marks, 1994). Untersuchungen haben gezeigt, dass einige dieser entwickelten Maße auch auf den städtischen Raum anwendbar sind. Herold et al. (2005) bezeichnet diese als städtische Strukturmaße (engl. *urban metrics*). Auf Grundlage dieser konnte beispielsweise ein Zusammenhang zwischen der Landnutzungsstruktur, die ein Flurstück umgibt, und dem zugrundeliegenden Immobilienwert festgestellt werden (Geoghegan et al., 1997). In weiteren Studien wurden die städtischen Strukturmaße zur Charakterisierung verschiedener Landnutzungstypen (Herold et al., 2003; Myint et al., 2006; Van de Voorde et al., 2011) oder städtischer Entwicklungsprozesse (Herold et al., 2002, 2005) eingesetzt.

Neben den sehr abstrakten, strukturbeschreibenden Maßzahlen verlangt die Planung aussagefähige und objektive Indikatoren zur Bewertung der Siedlungsstruktur. Diese dienen insbesondere dem raum-zeitlichen Monitoring, der Verwendung in externen Anwendungen (u. a. Simulationen, Entscheidungsunterstützungssystemen etc.) oder der kartographischen Visualisierung. Zu den wichtigsten planungsrelevanten Indikatoren auf Baublockebene zählen beispielsweise der Überbauungsgrad, die Geschossflächendichte oder die Wohnungs- und Einwohnerdichte. Nicht selten werden mehrere Indikatoren mithilfe multikriterieller Verfahren zu einem neuen Indikator zusammengefasst. Dieser dient dann dazu, die Siedlungsstruktur hinsichtlich einer konkreten Fragestellung zu bewert en (u. a. Wohnqualität, ökologische Leistung, Energieeffizienz, Solarpotenzial etc.).

[23] Spatial Pattern Analysis Program for Categorical Maps (www.umass.edu/landeco/research/fragstats/fragstats.html)

Ein weiteres Ziel der Siedlungsstrukturanalyse ist die qualitative Beschreibung des Siedlungsraumes. Mithilfe von Verfahren der Bildsegmentierung kann der Siedlungsraum unter Nutzung von Fernerkundungsdaten in homogene Einheiten typisiert werden. Ist eine Gliederung des Siedlungsraumes bereits durch eine Geometrie gegeben, kommen Klassifikationsverfahren zum Einsatz, um typische Siedlungsmuster (u. a. Muster der Bebauungsstruktur, Gebäudetypen etc.) in den Daten zu erkennen.

Der Maßstab spielt bei der Modellierung eine wesentliche Rolle (Sheppard & McMaster, 2004). Eine Betrachtung der städtischen Struktur bezieht sich darum immer auf eine räumliche Maßstabsebene (Abb. 2-11) (Banzhaf & Höfer, 2008). Auf Mikroebene stehen Gebäude (z. B. Typ, Baualter, Zustand) sowie deren Bewohner (z. B. Einwohnerzahl oder -struktur) im Vordergrund, während auf Mesoebene die blockbezogene Stadtstruktur, die Bodenversiegelung, der Überbauungsgrad sowie die Vegetationsausstattung im Fokus der Untersuchung stehen. Bei einer gesamtstädtischen Betrachtung spielen hingegen Indikatoren zur Beschreibung der Dynamik der Siedlungsentwicklung (z. B. Zersiedlungsprozesse, Innen- vor Außenentwicklung) eine wichtige Rolle (Torrens & Alberti, 2000; Siedentop, 2005; Ewing et al., 2002; Jaeger et al., 2010b). In der Verkehrsplanung werden ähnliche Planungsmaßstabsgruppen gebildet, wie beispielsweise die Ebenen Straßenraum (1: 500), Quartier (1: 5 000) oder die Stadt und Region (1: 50 000) (Krug, 2006). Bei maßstabsübergreifenden Analysen mithilfe von Aggregations- oder Dissagregationsverfahren ist das von Openshaw (1984) identifizierte Raumphänomen der „Modifiable Areal Unit Problem" (MAUP) allgegenwärtig. Es beschreibt die Anfälligkeit der Ergebnisse kartographischer Analysen gegenüber definierten Bezugsflächen und stellt eine nicht zu unterschätzende Herausforderung bei der Interpretation der visualisierten räumlichen Phänomene dar (Madelin et al., 2009).

Für die Siedlungsstrukturanalyse werden raumbezogene Informationen zu den physischen Elementen der Siedlung (Gebäude, Infrastruktur und Vegetation) benötigt und oftmals mit sozio-ökonomischen kombiniert (Aubrecht & Steinnocher, 2007). Die Siedlungselemente können aus geotopographischen Datenbanken oder mit Methoden der Fernerkundung gewonnen werden. In Bezug auf die Stadt hat sich dabei die „urbane Fernerkundung" als wichtiges Werkzeug zur Schaffung von Datengrundlagen für viele wissenschaftliche Fragestellungen aus den Bereichen der Siedlungs- und Stadtgeographie, Stadtforschung, Stadtmorphologie, Städtebau, Planung, Ökologie etc. etabliert (Taubenböck & Dech, 2010). Sie bietet ein großes Methodenspektrum, um Stadtstrukturtypen (z. B. Dogruso & Aksoy, 2007; Geiß et al., 2011; Wurm et al., 2009), Stadtbiotoptypen (Bochow, 2010; z. B. Peisker, 2006), Indikatoren der Bodenversiegelung (Esch, 2010; z. B. Weng, 2007) oder kleinräumige Daten zum Gebäudebestand und der Bevölkerung abzuleiten (z. B. Lwin & Murayama, 2009; Ural et al., 2011; Wurm et al., 2010). Für die Modellverfeinerung werden häufig geocodierte Adressen hinzugezogen (Aubrecht & Steinnocher, 2007; Mesev, 2005). Für weitere Anwendungsbeispiele sei auf verschiedene Sammelbände verwiesen (u. a. Donnay et al., 2001; Rashed & Jürgens, 2010; Taubenböck & Dech, 2010).

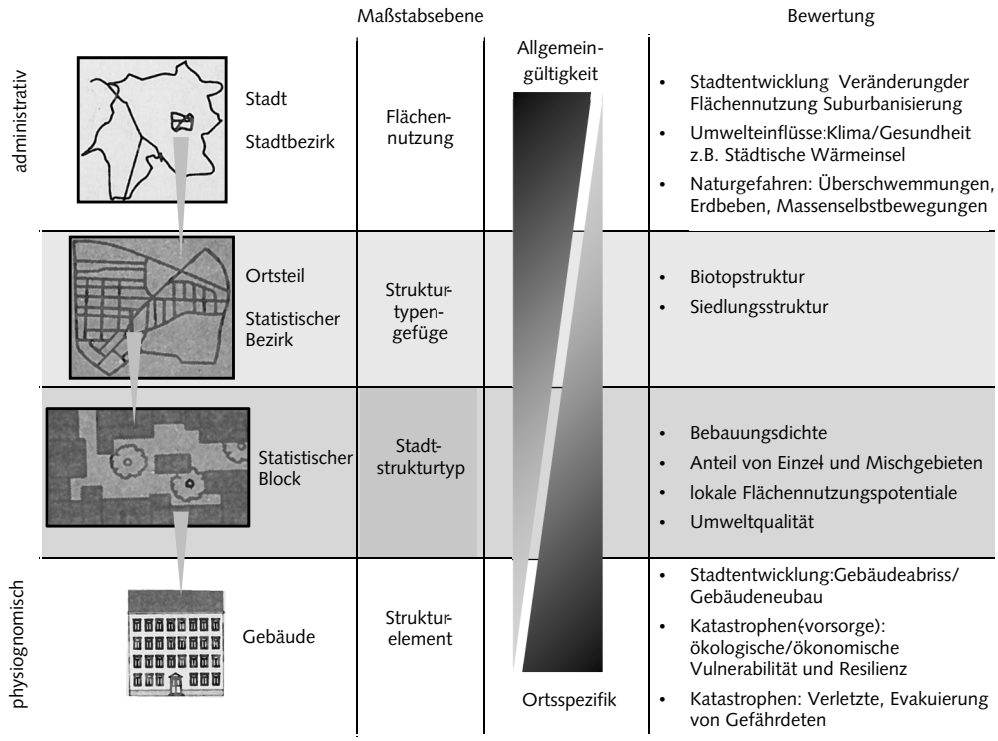

Abb. 2-11: Stadtstrukturtypen (Quelle: Banzhaf & Höfer, 2008)

Neben Fernerkundungsdaten gewinnen in jüngster Zeit auch topographische Geoinformationen zur Flächennutzung, den Gebäudeumringen und den verorteten Gebäudeadressen an Bedeutung. Mit dem automatischen Verfahren SEMENTA® (Meinel et al., 2008a) können beispielsweise auf Grundlage von ATKIS® und rasterbasierten topographischen Karten im Maßstab 1: 25 000 siedlungsstrukturelle Merkmale zum Überbauungsgrad, der Gebäudedichte, der Geschossflächendichte oder dem Gebäudevolumen automatisiert abgeleitet werden. Durch Anwendung der räumlichen Disaggregation statistischer Daten auf Gemeindeebene ist es dann möglich, Wohnungs- und Einwohnerzahlen auf Baublockebene abzuschätzen. Mit der Verfahrenserweiterung SEMENTA®-CHANGE wurden die Indikatoren ergänzt, in dem die Dynamik der Siedlungsstruktur auf unterschiedlichen Maßstabsebenen gemessen werden kann (vgl. Hecht et al., 2008; Herold et al., 2011; Meinel et al., 2009).

2.4.3.3 Simulationen

Unter Simulation versteht man die Nachbildung komplexer Systeme aus der Naturwissenschaft, Technik und Wirtschaft mithilfe programmierter dynamischer Modelle (Bill & Zehner, 2001). Es wird damit möglich, Verhaltensweisen der Realität (z. B. von Akteuren oder dynamischen Stadtentwicklungsprozessen) mithilfe von Computern möglichst wahrheitsgetreu nachzuahmen. Für die Simulation werden Automaten (engl. *automata*) eingesetzt. Grundsätzlich unterscheidet man zwischen zwei Typen, einerseits den zellulären Automaten (engl.

Cellular Automata, CA) und zum anderen Multiagentensystemen (engl. *Multi-Agent System,* MAS) (Benenson & Torrens, 2004). Bei den zellulären Automaten erfolgt die Modellierung über räumlich stationäre Zellen, wohingegen bei Multi-Agentensystemen die einzelnen Agenten frei beweglich sein können. Zelluläre Automaten werden beispielsweise eingesetzt, um Siedlungsentwicklungsprozesse zu simulieren, Multiagentensysteme hingegen eher für die Modellierung raum- und zeitabhängiger Entscheidungsprozesse einzelner Individuen, wie z. B. innerstädtische Segregationsprozesse.

Mit der Open-Source-basierten Simulationssoftware *UrbanSim* (Noth et al., 2001; Waddell et al., 2003) können urbane Prozesse auf verschiedenen Maßstabsebenen modelliert werden. Mit diesem agentenbasierten System lassen sich Landnutzungsentwicklungen, Verkehr, Haushaltbildung und Erreichbarkeit simulieren. Für die Modellierung werden häufig Grunddaten, wie synthetische Haushaltszahlen oder Landnutzung und -funktion auf Rasterebene, benötigt. Kleinräumige Daten zur Siedlungsstruktur spielen deshalb auch in Simulationsprozessen eine wichtige Rolle.

3 Methodische Grundlagen der Mustererkennung

In diesem Kapitel werden die methodischen Grundlagen der Mustererkennung erörtert, die für eine automatische Klassifizierung von Objekten benötigt werden. Da es sich bei den Objekten um Gebäudegrundrisse handelt, die durch Visualisierung vom Menschen wahrnehmbare Muster darstellen, wird zunächst auf die menschlich-visuelle Wahrnehmung eingegangen, die dem Verständnis maschineller Bilderkennungsprozesse dient, welche zu Teilen Anwendung in dem entwickelten Verfahren findet.

3.1 Visuelle Wahrnehmung und Bildverstehen

3.1.1 Menschliche Wahrnehmung

Der Mensch wird von einwirkenden Reizen in Form von externer physikalischer Energie der Umwelt ausgesetzt. Ohne diese Reize zu filtern und zu strukturieren, wäre die Welt sehr chaotisch und ein Entscheiden oder Handeln unmöglich. Erst die Wahrnehmung macht es möglich, „Objekte und Ereignisse in der Umwelt zu begreifen, sie mit Sinnen zu empfinden, zu verstehen, zu identifizieren und zu klassifizieren sowie sich darauf vorzubereiten, auf sie zu reagieren“ (Zimbardo & Gerrig, 2008: S. 108). Der Prozess der menschlichen Wahrnehmung geht weit über das reine Aufnehmen von Information hinaus und besteht aus der Empfindung, der perzeptuellen Organisation und der Identifikation und Wiedererkennung (Zimbardo & Gerrig, 2008).

Die Empfindung ist die Aufnahme von Sinnesreizen mittels Sinnesorganen sowie die Weiterleitung über Nervenzellen in die Hirnrinde. In der Stufe der perzeptuellen Organisation erfolgt die Bildung einer inneren Repräsentation auf mentaler Ebene, ohne dass wir uns dieses Prozesses bewusst sind. Dabei werden unbewusst objektbeschreibende Informationen abgeleitet und aus der Fülle der Informationen die jeweils relevanten extrahiert. Dieses können visuelle Merkmale (Größe, Form oder Farbe), auditive Merkmale (z. B. Dauer oder Höhe eines wahrgenommenen Tonreizes), haptische Merkmale (z. B. Rauigkeit oder Temperatur), Merkmale eines Geruchs (olfaktorische Merkmale) oder Geschmacks (gustatorische Merkmale) sein. Im letzten Schritt der Identifikation und Wiedererkennung erfolgt die Bedeutungszuordnung (Klassifikation, Mustererkennung), bei der höhere kognitive Prozesse nötig sind und der Abgleich mit Erinnerungen, dem Wissen, stattfindet, um dem Objekt „einen Namen“ zu geben. In dieser semantischen Phase wird die Verbindung der Information mit dem semantischen Gedächtnis hergestellt. Erst dieser Schritt der Identifikation und Wiedererkennung von Objekten in der Umwelt ermöglicht das Handeln. Der kognitive Prozess ist dabei stark subjektiv, da jeder Mensch über sein eigenes Wissen und Verständnis für die bestimmten Begriffe verfügt und damit auch ein individuelles Ziel verfolgt.

Ohne Wissen ist eine Objekterkennung nicht möglich. Erst durch Interaktion und Kommunikation mit der Umwelt kann dieses Wissen in einem Lernprozess kontinuierlich erlernt werden. Kommunikation von Wissen erfolgt über Symbole zumeist in Form hörbarer oder sichtbarer Zeichen. Die Symbole, z. B. Wörter, können je nach Kontext unterschiedliche Bedeutungen haben, genauso wie ein Objekt unterschiedlich bezeichnet werden kann. Aus diesem

Grund wird in der Sprachwissenschaft und Semiotik das semiotische Dreieck nach Ogden und Richards von 1923 herangezogen, das die Beziehung zwischen einem Symbol, dem im Gedanken hervorgerufenen Begriff und dem damit gemeinten realen Objekt darstellt. Nach dieser Theorie gibt es keine direkte Beziehung zwischen dem Symbol und dem Objekt. Das Symbol erlangt den Bezug zu dem Objekt erst indirekt über einen Begriff, der innerhalb eines Gedankens von „jemanden" gebildet wird (Straub, 2009). Für eine bessere Kommunikation von Begriffen unterschiedlicher Fachgebiete werden deshalb Ontologien (Uschold & Grüninger, 1996) eingesetzt, die der Vermittlung zwischen Symbolen und Objekten dienen. Mithilfe dieser können Objekte der Realität und ihre Beziehungen zueinander durch Konzeptualisierung (engl. *conceptualization*) aus einem Set von Begriffen (Entitäten, Attribute, Prozesse) beschrieben werden (Uschold & Grüninger, 1996).

3.1.2 Theorien der visuellen Wahrnehmung

Der menschliche Wahrnehmungsprozess ist komplex und kann bis heute in seiner Vollständigkeit noch nicht erklärt werden. Für einige Phänomene der visuellen Wahrnehmung existieren jedoch bereits Erklärungsmodelle und Gesetze. Nennenswert seien an dieser Stelle die früh publizierten gestaltpsychologischen Organisationsprinzipen von Wertheimer (1923), wie z. B. das Gesetz der Nähe, Gesetze der Ähnlichkeit oder das Gesetz der Geschlossenheit. Nach diesen Gesetzen ist der Mensch in der Lage, einzelne Objekte (einfache Muster) bei einer Figur-Grund-Wahrnehmung zu höheren Einheiten (komplexe Muster) zu organisieren. Ab den 1950er Jahren wurden Computer als eine Möglichkeit betrachtet, unerforschte Phänomene des menschlichen Verhaltens durch Modellierung aufzuklären[24]. Das führte zur Entwicklung neuer Theorien der Objekt- bzw. Mustererkennung in der Wahrnehmungspsychologie (Smith, 2001).

In der Psychologie werden zur Erklärung von Wahrnehmungsprozessen Top-down- und Bottom-up-Ansätze unterschieden. Beim Bottom-up-Ansatz erfolgt eine Analyse der Reizmerkmale (Wahrnehmungsanalyse), die auf den sensorischen Daten der Umgebung beruhen und deren Ergebnisse zu abstrakten Repräsentationen führen. Man spricht hierbei auch von einer datengesteuerten Verarbeitung. Für die Erklärung der Form- und Musterwahrnehmung werden häufig folgende Bottom-up-Theorien genannt (vgl. Humphreys & Bruce, 1989; Sternberg, 2008; Trimmel, 2003):

- Schablonentheorie (engl. *template theory*)
- Prototypentheorie (engl. *prototype theory*)
- Merkmalstheorie (engl. *feature theory*)
- Strukturelle Beschreibungstheorie (engl. *structural-description theory*)

[24] "[...] the task of a psychologist trying to understand human cognition is analogous to that of a man trying to discover how a computer has been programmed." (Neisser 1967, ziziert in Gordon, 2004: S. 185).

Die *Schablonentheorie* geht auf Selfridge und Neisser (1960) zurück. Nach ihr werden Mustererfahrungen in Form von Schablonen (engl. *templates*) im Langzeitgedächtnis gespeichert. Jedes wahrgenommene Reizmuster wird mit den im Gedächtnis abgespeicherten Schablonen verglichen und die Schablone gewählt, die perfekt mit dem Muster übereinstimmt. Diese Theorie wurde jedoch schnell kritisiert, da zum einen ein enormer Speicherplatz für die Vielzahl von Schablonen nötig wäre und zum anderen die Frage nach dem Umgang mit neuen Mustern ungeklärt ist (Banyard et al., 1995). Bei der *Prototypentheorie* wird jedes Muster durch Prototypen repräsentativ beschrieben. Prototypen sind die repräsentativsten Exemplare einer Klasse, die alle typischen Formmerkmale eines Musters integrieren. Beim Abgleich eines Reizmusters wird ein passender Prototyp über Ähnlichkeit bestimmt. Die *Merkmalstheorie* (Neisser, 1967) besagt hingegen, dass jedes Muster aus einem Set spezifischer Merkmale und Attribute besteht. Jedes neue Objekt kann mit einer bestehenden Erinnerung im Gedächtnis durch eine Merkmalsanalyse abgeglichen und in Beziehung gesetzt werden. Ein bekanntes Modell der Merkmalstheorie ist das Pandämonium-Modell, das zur visuellen Mustererkennung von Selfridge (1959) entwickelt wurde. Für die Beantwortung der Frage, wie dreidimensionale komplexe Objekte wahrgenommen werden, kann die *strukturelle Beschreibungstheorie* (auch Komponententheorie) hinzugezogen werden. Im Gegensatz zur Merkmalstheorie setzt sich bei dieser Theorie ein Muster aus einer Anordnung geometrischer Grundelemente zusammen, die zueinander in Relationen stehen. Einen einflussreichen Modellansatz lieferte hierzu Biederman (1987) mit seinen Geonen. Biederman beschreibt 36 dreidimensionale Grundkörper (Geons genannt), die sich über ansichteninvariante Eigenschaften definieren. Aus diesem endlichen Satz dreidimensionaler Grundelemente können beliebig komplexe Objekte, ähnlich wie Buchstaben zu Wörtern, zusammengesetzt und strukturell beschrieben werden. Auf weitere Ansätze, die im Zuge der Entwicklung maschineller Sehsysteme entstanden sind, sei an dieser Stelle auf das Modell von Marr verwiesen, auf das im Kap. 3.1.3 näher eingegangen wird.

Im Gegensatz zu den Bottom-up-Ansätzen werden Top-down-Ansätze für die Erklärung des Einflusses von Vorwissen oder Kontext auf die Wahrnehmung hinzugezogen. Dabei geht man davon aus, dass Kenntnisse und Erwartungen im Wahrnehmungsprozess verwendet werden und höhere mentale Prozesse das Objektverstehen beeinflussen (Zimbardo & Gerrig, 2008). Konzepte im Kopf des Empfängers und kognitive Prozesse beeinflussen was gesehen wird. Neben sensorischen Informationen als Grundlage für die Struktur werden andere Informationsquellen, wie Vorwissen oder Kontext hinzugezogen. Da das Denken eine integrierte Rolle im Wahrnehmungsprozess spielt spricht man auch von *intelligent perception* (Sternberg, 2008).

Die Top-down- und Bottom-up-Theorien stehen im Kontrast zueinander. Bei einem strengen Top-down-Ansatz bliebe die Bedeutung sensorischer Informationen unterschätzt und die Wahrnehmung wäre allein durch Erwartungen geprägt. Bei einem vollkommen datengetriebenen Ansatz würde die Wahrnehmung ohne Einfluss von Erfahrung oder Wissen auskommen und Sternberg (2008) stellt die Frage, welchen Sinn dann das Speichern von Wissen überhaupt hätte. Keines dieser Extreme ist für das Erklären der Wahrnehmung ideal und Sternberg hält fest, dass für die Entwicklung einer gesamten Theorie zur visuellen Wahrnehmung beide Ansätze berücksichtigt werden müssen. Viele Theorien der (menschlichen)

Mustererkennung entstanden durch Modellierung des Vorgangs am Computer. Sie dienen heute als Grundlage für die Simulation von Sehvorgängen am Computer, dem maschinellen Sehen.

3.1.3 Bildverstehen

Wird mithilfe von Computern versucht, den menschlich-visuellen Wahrnehmungsprozess zu simulieren und „aus Bildern zu entdecken, was in der Welt ist und wo es ist" (Marr 1982 zitiert in Jähne, 2005: S. 18), so spricht man vom maschinellen Sehen (engl. *Computer Vision*). David Marr gilt als einer der Pioniere, der mit seinem Modell einen wichtigen Beitrag auf dem Wege zum Verständnis der Objektwahrnehmung und des maschinellen Sehens leistete. Der Sehprozess funktioniert nach den Prinzipien der elektronischen Datenverarbeitung eines Computers. Durch Einführung von Betrachtungsebenen werden in dem Modell Vorgänge auf dem *computational level,* dem *algorithmic level* und dem *implementational level* unterschieden. Der visuelle Wahrnehmungsprozess wird von Marr als 4-Stufenprozess vom *retinalen Bild* auf der Netzhaut zum *ersten Entwurf,* über einen *2½-D-Entwurf* zum *3-D-Modell* beschrieben und über einen algorithmischen Ansatz simuliert (Marr, 1982).

Verfolgte man anfangs das Ziel mithilfe des maschinellen Sehens das biologische visuelle System zu verstehen, so sieht sich die Disziplin heute teilweise als reine Möglichkeit zur effizienten Lösung von Erkennungsproblemen, die durch verschiedene Anwendungsdomänen in der Industrie, der Medizin oder den Geowissenschaften geprägt sind (vgl. Caelli et al., 1993). Maschinelles Sehen wäre ohne menschliches Sehen undenkbar, da die vom Computer zu verarbeitenden Bilder nur durch Sehen beurteilt werden können und sich deren Ausgabe am Bildschirm an den Gegebenheiten der menschlichen Wahrnehmung orientieren (Jähne, 2005). Die Herangehensweise beim maschinellen Sehen erfolgt allerdings nicht notwendigerweise nach denselben Prinzipien wie bei der visuellen Mustererkennung, da Sensorik (Auge vs. bildgebendes Verfahren) und Wissensrepräsentation (Gehirn vs. Computer) andere Eigenschaften aufweisen. Über die Jahre haben sich Begriffe wie „Computer-Sehen", „Bildverstehen", „Bildanalyse", „Machine Vision"[25], „Image Analysis", „Image Understanding" etabliert, die mehr oder weniger dasselbe meinen. Der Begriff „Bildverstehen" scheint am sinnvollsten, da damit auch Muster in Bildern berücksichtigt werden, die in der Realität vom Menschen nicht visuell wahrnehmbar sind.

Bildverstehen wird als Prozess aufgefasst, der von einem Bild (oder einer Bildfolge) und einer direkten Fragestellung ausgeht und dessen Resultat eine inhaltliche zweckbestimmte Beschreibung einer aufgenommenen Szene darstellt (Steinmüller, 2008). Ein einfaches Gesamtmodell des Bildverstehens nach Pinz (1994) besteht aus sechs Repräsentationsebenen und den Prozessen, die zu diesen führen (Abb. 3-1).

[25] Machine Vision wird meist in Verbindung mit der industriellen Bildverarbeitung genutzt (z. B. zur Qualitätskontrolle auf dem Fließband oder in der Robotik).

Ausgehend von einer konkreten Fragestellung wird mit der *Szenenauswahl* festgelegt, welcher Ausschnitt der Welt wann aufgenommen werden soll. Mit der *Aufnahme* wird bestimmt, wie die Szene betrachtet und mit welchem Sensor sie aufgenommen werden soll. Hierzu stehen verschiedene bildgebende Verfahren, wie die Photographie, Fernerkundung, Röntgen oder die Tomographie zur Verfügung. Das *Bild* ist eine Matrix von Bildpunkten, dessen Zellen mit nummerischen Werten belegt sind. Mit dem Prozess der *Bildverarbeitung* wird das Bild in eine für die weitere Verarbeitung geeignetere Form transformiert. Hierzu zählen insbesondere Methoden der Bildverbesserung, wie die Farbreduzierung, die Kontrasterhöhung, die Kantenextraktion oder die Ableitung von Texturbildern durch Filterung. Darüber hinaus können mithilfe der *Segmentierung* homogene Bildbereiche zu Regionen zusammengefasst werden. Die dabei gewonnenen Segmente sind Resultat eines ersten Abstraktionsschrittes vom Pixel zum Segment und bilden die Grundlage für die Erkennung und Klassifikation von Objekten im nächsten Prozess (Bildanalyse). Im Gegensatz zur Bildanalyse liegt bei der Bildverarbeitung sowohl bei der Eingabe und Ausgabe ein Bild vor. Eine semantische Interpretation findet an dieser Stelle noch nicht statt. Der Prozess der *Bildanalyse* verfolgt im Wesentlichen das Ziel der automatischen Objekterkennung bzw. der Klassifikation. Dabei werden die Eingabebilder mithilfe verschiedener Methoden und Algorithmen in bekannte graphische Objekte (z. B. Zeichen, Gesichter, Objekte) zerlegt und in eine Beschreibung überführt. Die Objekterkennung selbst basiert auf Grundlage von Merkmalen, die mittels Merkmalsextraktion aus dem Bild abgeleitet werden. Dabei werden Verfahren der Mustererkennung und des maschinellen Lernens eingesetzt (siehe Kap. 3.2). Im Ergebnis steht eine *Szenenbeschreibung* mit der die Szenenelemente objektstrukturiert (z. B. Haus, Straße etc.) repräsentiert werden. Durch Prozesse *höherer Bilddeutung* können weitere Repräsentationsformen oberhalb der Objektebene entstehen, die zu einer umfassenden Beschreibung der Welt führen. Im letzten Prozess erfolgt die Interaktion mit der Umwelt in dem beispielsweise die Richtigkeit des bildverstehenden Systems verifiziert, die Umwelt durch die gewonnenen Erkenntnisse verändert oder ein aktiver Roboter in der Realität orientiert wird.

Grundlage für jede automatische Erkennung von Objekten in Bildern ist die Bildung von Modellen auf Grundlage von Wissen. Beim Wissen unterscheidet man Faktenwissen und Regelwissen (Bähr & Vögtle, 2005). Das Wissen kann vorab vorliegen, wenn z. B. bekannt ist, welcher Spektralkanal ein zu beobachtendes Phänomen am besten abbildet, welcher Segmentierungsalgorithmus angewandt werden soll, welche Merkmale am wichtigsten sind und nach welchen Regeln die Objekte klassifiziert werden sollen. In einem Modellierungsschritt vor der Wissensspeicherung wird deshalb auf konzeptioneller Ebene festgelegt, welcher Ausschnitt der Realität in das Modell mit aufgenommen wird. Dies beinhaltet die Form der Wissensrepräsentation und deren Struktur bis hin zur Auswahl charakteristischer Merkmale. In diesem ersten Schritt wird der Abstraktionsgrad beim Übergang vom Modell zur Realität festgelegt (Sester, 1995). So kann die Wissensrepräsentation in unterschiedlichster Form, wie z. B. durch logische Ausdrücke, einfache Regeln bis hin zu Graphen, Semantischen Netzen oder Formalen Grammatiken, erfolgen.

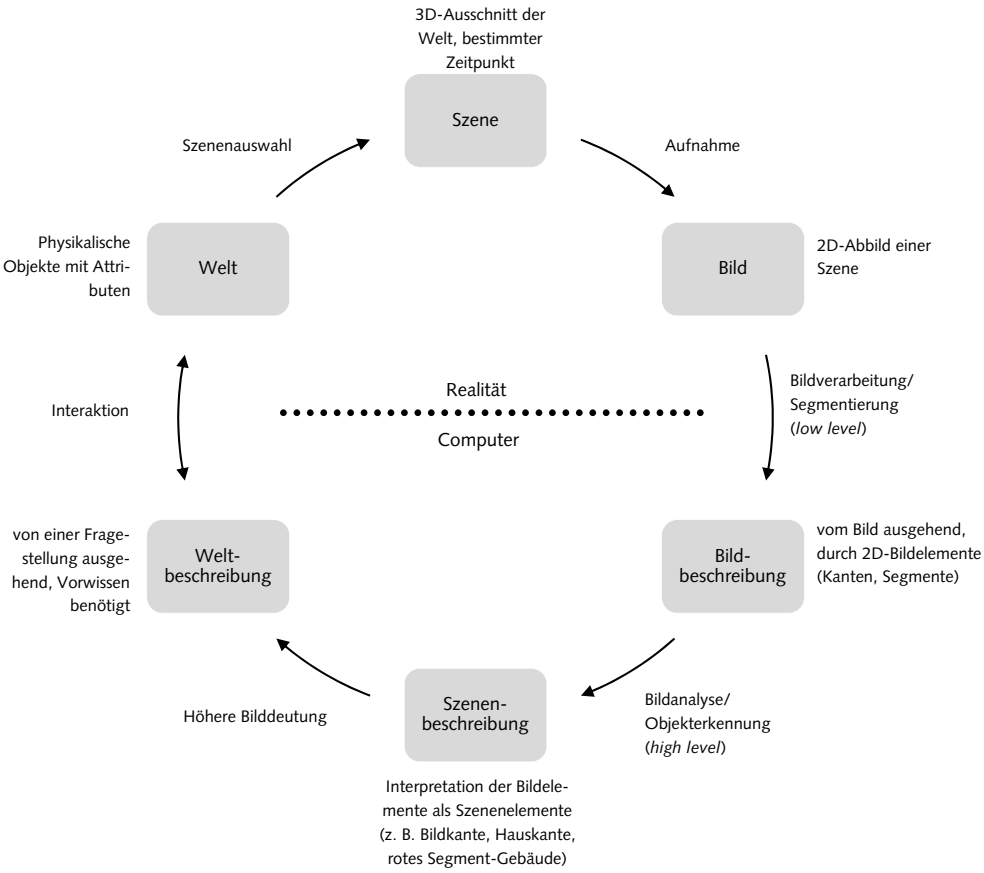

Abb. 3-1: Zyklisches Modell des Bildverstehens nach Pinz (1994) abgewandelt und ergänzt durch Gedanken von Steinmüller (2008)

Den Erklärungsansätzen des menschlich-visuellen Systems vergleichbar, unterscheidet man auch beim Bildverstehen grundsätzlich zwei Strategien der Modellbildung:

- datengetriebene Strategie (implizite, bottom-up)
- modellgetriebene Strategie (explizite, top-down)

Der Einsatz der *modellgetriebenen Strategie* eignet sich besonders dann, wenn Regelwissen *a priori* vorliegt und das Erkennungsproblem für den Menschen leicht formalisierbar ist. Man spricht dabei häufig auch vom wissensbasierten Ansatz. Das Modell und deren Modellparameter sind dem Menschen einsichtig und verständlich. Bei einer *datengetriebenen Modellbildung* wird das Wissen erst während der Modellbildung eingeführt. Das Modell besitzt Parameter, die für den Menschen schwerer interpretierbar sind und mithilfe eines Lernprozesses auf Grundlage von Trainingsbeispielen (Faktenwissen) erlernt werden. Vom Bild ausgehend werden Objektrepräsentationen abgeleitet (z. B. Objekte repräsentiert durch Merkmalsvektoren) und diese mit den in einer Wissensbasis gespeicherten Repräsentationen für bekannte Objekte verglichen. Hier wird der unmittelbare Bezug zu den Wahrnehmungstheorien (Template Matching, die Schablonen- oder Prototypentheorie, Komponententheorien)

deutlich. In der Praxis werden häufig beide Strategien eingesetzt, in dem beispielsweise wissensbasiert Merkmale gewählt und die Repräsentationsstruktur (z. B. Entscheidungsbaum) festgelegt und mithilfe eines datengetriebenen Verfahrens die Parameter (Schwellwerte des Entscheidungsbaumes) bestimmt werden.

Viele Erkennungsprobleme der Realwelt, die auf echten, nicht simulierten Daten beruhen (engl. *real-world vision problems)*, wie etwa die Erkennung handgeschriebener Wörter, haben einen datengetriebenen Charakter und sind nur selten wissensbasiert. Der Grund dafür ist, dass reale Probleme schwer mathematisch formalisierbar sind und nur selten durch statistische (probabilistische) Modelle abgebildet werden können (Rosenfeld, 2001). Die Herausforderung der Simulation menschlichen Sehens liegt u. a. darin, dass biologische visuelle Systeme viele redundante Informationen aufnehmen und verarbeiten können. Redundanzen wurden in Computersehsystemen traditionell vermieden, um Rechenleistung zu sparen. Wäre es möglich, mit zunehmender Rechenleistung der Systeme auch redundante Daten in Echtzeit zu verarbeiten, dann könnte die Leistung solcher Systeme denen biologisch-visueller Systeme vergleichbar werden (Rosenfeld, 2001).

3.2 Mustererkennung und maschinelles Lernen

Bei der automatischen Erkennung von Objekten in Bildern und räumlichen Daten spielen Methoden der Mustererkennung und des maschinellen Lernens eine wichtige Rolle, weshalb ein kurzer Einblick in diese beiden Disziplinen gegeben werden soll.

3.2.1 Mustererkennung

Die Mustererkennung (engl. *pattern recognition*) als Disziplin hat eine lange Tradition, beschränkte sich jedoch vor den 1960er Jahren vornehmlich auf theoretische Ansätze der Statistik. Erst mit der technologischen Entwicklung von Computern und einem höheren Anwendungspotenzial gewann diese an Bedeutung und wird heute nahezu in allen wissenschaftlichen und technischen Bereichen angewendet (Duda et al., 2000). Nach Niemann (2003) sind alle Forschungs- und Entwicklungsaktivitäten, die die mathematisch-technischen Aspekte der automatischen Verarbeitung und Auswertung von Mustern betreffen, dem Gebiet der Mustererkennung im weitesten Sinne zuzuschreiben. Weitere Definitionen aus der Literatur lauten:

- McGraw-Hill´s Dictionary of Scientific and Technical Terms: "The automatic identification of figures, characters, shapes, forms, and patterns without active human participation in the decision process." (Parker, 2002)
- Encyclopedia of Computer Science and Technology: "The fundamental task of turning raw data (whether from senses, instruments, or computer files) into recognizable objects or drawing inferences is called pattern recognition." (Henderson, 2003: S. 363)
- Encyclopedia of Computer Science and Engineering: "Pattern recognition (PR) concerns the description or classification (recognition) of measurements" (Schalkoff, 2008: S. 1)

- Pattern Recognition: "Pattern recognition is the scientific discipline whose goal is the classification of objects into a number of categories or classes" (Theodoridis & Koutroumbas, 2008: S. 1)
- Pattern Classification: "[…] the act of taking in raw data and taking an action based on the "category" of the pattern" (Duda et al., 2000: S. 3)

Die wesentliche Aufgabe der Mustererkennung ist demnach die automatische Klassifizierung oder Beschreibung von Mustern.

3.2.1.1 Muster

Im Allgemeinen versteht man unter Muster „eine Vorlage, nach der etwas hergestellt wird" oder „ein etwas in seiner Art Vollkommenes, Vorbild" (Brockhaus, 2005; Stichwort: Muster). In der Mustererkennung werden sie als Gegenteil von Chaos verstanden und als vage Entität aufgefasst, der man einen Namen geben kann[26] (Watanabe, 1985). Ein Muster kann beispielsweise ein einzelnes Pixel eines Bildes, eine Bildregion, ein handgeschriebenes Zeichen, ein Fingerabdruck, ein gesprochenes Wort oder ein Gesicht sein (Kpalma & Ronsin, 2007). Dabei wird jedoch nicht mit dem Muster selbst, sondern mit Merkmalen (engl. *measurements*) gearbeitet, die dieses Muster beschreiben. Eine formale Definition von Muster ist nicht trivial[27]. Man unterscheidet jedoch zwischen einfachen und komplexen Mustern (Niemann, 2003).

Einfache Muster werden als Ganzes betrachtet und mithilfe von Merkmalen beschrieben. Sie werden auch als Objekte bezeichnet (Theodoridis & Koutroumbas, 2008). Einfache Muster sind durch Regelmäßigkeiten in der Objektcharakteristik gekennzeichnet und können unabhängig von anderen Mustern einer Klasse zugeordnet werden (siehe nächster Abschnitt 3.2.1.2). Gebäude, die durch ihren Gebäudegrundriss repräsentiert und mithilfe von Objektmerkmalen (z. B. Größe, Form etc.) beschrieben werden, sind beispielsweise einfache Muster.

Komplexe Muster setzen sich aus einfachen Mustern zusammen. Die einfachen Muster bilden die Grundelemente und weisen untereinander eine strukturelle und/oder hierarchische Beziehung auf. Die komplexen Muster sind durch Regelmäßigkeiten in der Struktur gekennzeichnet. Mithilfe der Beschreibung komplexer Muster, auch Musteranalyse bezeichnet, können diese in kleinere Komponenten zerlegt werden. Ein komplexes Muster enthält mehr als nur ein zu klassifizierendes Objekt, sondern eine Gruppe von Komponenten. Ziel ist dann die Klassifikation dieser einzelnen Komponenten und die Erfassung und Beschreibung derer Relationen zueinander mithilfe einer symbolischen bzw. strukturellen Beschreibung (Schalkoff, 2008). Ein komplexes Muster wäre beispielsweise eine Gebäudegruppe, die durch eine

[26] In Watanabe wird "pattern" beschrieben als "[…] the opposite of chaos; it is an entity, vaguely defined, that could be given a name" (Watanabe, 1985: S. 2).

[27] Niemann führt an, „dass es leider immer noch keine Definition des Begriffs Muster gibt, die ähnlich präzise und mathematisch verwertbar ist, wie die Definition der Information durch Shannon" und fragt, ob es ein Hinweis darauf sei, dass es keine gibt (Niemann, 2003: S. 13).

spezifische Anordnung bzw. regelmäßige Struktur (z. B. parallel angeordnete Gebäude) gekennzeichnet ist.

In dieser Arbeit steht die Klassifizierung individueller Gebäudegrundrisse (einfache Muster) im Vordergrund, weshalb Mustererkennung im Sinne von Theodoridis und Koutroumbas (2008) verstanden werden kann, dessen Ziel die Klassifizierung von Objekten in Kategorien oder Klassen ist.

3.2.1.2 Klassifizierung

Die Klassifizierung[28] (engl. *classification*) ist die Zuordnung von Objekten (einfache Muster) in eine oder mehrere Klassen und ist der abschließende Schritt in einem Mustererkennungssystem (vgl. Kap. 3.3). Das Ergebnis einer Klassifizierung wird als „Klassifikation" bezeichnet. Mit dem Begriff „Erkennung" (engl. *recognition*) wird die Fähigkeit des Klassifizierens verstanden. Eine Klassifizierung eines Objektes erfolgt auf Grundlage von Merkmalen, die für die Zugehörigkeit zu einer Klasse charakteristisch sind. Unter Merkmalen werden alle Messungen oder Beobachtungen verstanden, die in der Regel in einem Merkmalsvektor gespeichert sind (Schalkoff, 2008).

3.2.1.3 Klassifikator

Mithilfe einer geeigneten Zuordnungsvorschrift, einem „Klassifikator" (engl. *classifier*), erfolgt die Zuordnung eines Objektes zu einer Klasse. Als Klassifikator kommen verschiedene Verfahren in Frage. Bei metrischen Merkmalen, die bspw. auf Messungen aus Bildern oder anderen Signalen beruhen, werden numerische Klassifikationsverfahren eingesetzt. Lässt sich das Klassifikationsproblem stattdessen mit einem Satz klarer logischer Regeln definieren, dann werden nichtnumerische, syntaktische Ansätze eingesetzt (Duda et al., 2000).

3.2.2 Maschinelles Lernen

Maschinelles Lernen (engl. *Machine Learning*) ist eine Technik aus dem Bereich der Künstlichen Intelligenz, die der automatischen Generierung von Wissen aus Erfahrung dient. Mithilfe eines programmierten Lernalgorithmus wird versucht, ein Gütemaß automatisch anhand von Lerndaten oder Erfahrungswerten der Vergangenheit zu optimieren (Alpaydin, 2004). Praktisches Ziel dieses automatischen Lernprozesses ist es, aus dem gegebenen Faktenwissen Gesetzmäßigkeiten und Regeln in den Lerndaten zu erkennen, um diese anschließend auf unbekannte Daten zu verallgemeinern und anzuwenden. Damit dient maschinelles Lernen der Generierung von Regelwissen und ist eng mit dem Data Mining verwandt, dessen Anliegen das Finden neuer Muster und Gesetzmäßigkeiten in großen Datensätzen ist.

Maschinelles Lernen wird häufig in einem Atemzug mit der Mustererkennung genannt (u. a. Bishop, 2007), da es mithilfe maschineller Lernverfahren möglich ist, Klassifikatoren anhand von Beispieldaten automatisch zu erlernen. Neben der automatischen Klassifizierung von

[28] Vermehrt auch analog zum englischen „Klassifikation" genannt.

Daten schließt das maschinelle Lernen auch Techniken der Regressionsanalyse, der Interpolation und der Dichteschätzung ein.

Maschinelle Lernansätze lassen sich nach verschiedenen Kriterien, wie der Lernstrategie, der Wissensrepräsentationsart oder dem Anwendungsbereich klassifizieren. Beispiele verschiedener Lernarten sind das Auswendiglernen, Lernen durch Anweisung, Lernen durch Deduktion, Lernen durch Analogie, Lernen aus Beispielen und Lernen aus Beobachtungen (Beierle & Kern-Isberner, 2006). Im Kontext der Musterkennung sind induktive Lernverfahren (Lernen aus Beispielen und Beobachtungen) geläufig. Prinzipiell werden dabei folgende drei Lernarten unterschieden (nach Lai et al., 2008):

- überwachtes Lernen (supervised learning)
- unüberwachtes Lernen (unsupervised learning)
- bestärkendes Lernen (reinforcement learning)

Beim *überwachten Lernen* ist es das Ziel, auf Grundlage einer gegebenen Menge gelabelter Beispiele ein Modell bzw. deren Modellparameter automatisch zu erlernen. Unter gelabelten Beispielen versteht man Muster, die in einem mehrdimensionalen Merkmalsvektor gespeichert sind, zu denen jeweils der Ausgabewert, wie etwa die Klassenzugehörigkeit oder eine kontinuierlicher Zielgröße, bekannt sind. Ein typisches Beispiel ist die überwachte Klassifikation oder die Regression (Bishop, 2007). Beim *unüberwachten Lernen* wird ein Modell auf Grundlage einer ungelabelten Trainingsmenge erlernt. Klassisches Beispiel sind Clustering-Algorithmen, mit denen bedeutsame homogene Gruppen (Cluster) gebildet werden können, die Grundlage in einem anschließenden Interpretations- oder Analyseschritt sind. Aber auch Algorithmen zur Dimensionsreduktion, wie z. B. selbstorganisierende Karten[29] (engl. *self-organizing maps*, SOM), gehören zu den unüberwachten Verfahren mit denen regelmäßige Strukturen (Muster) in hochdimensionalen Daten erkannt und in eine vom Menschen interpretierbare Visualisierung überführt werden können. Beim *bestärkenden Lernen* erfolgt das Lernen über einen Agenten (z. B. eines Lehrers) durch Belohnung und Bestrafung. Im Gegensatz zum überwachten Lernen werden keine Beispieldaten gegeben, sondern das Modell in einem Trial-and-Error-Prozess optimiert. Eine weitere, relativ neue Form des Lernens ist das *semi-überwachte Lernen* (engl. *semi-supervised learning*), mit dem ein Modell auf Grundlage einer kleinen Menge gelabelter Daten überwacht erlernt und auf Grundlage vieler ungelabelten Datenpunkte unüberwacht optimiert wird, wie beispielsweise beim Co-Training (Blum & Mitchell, 1998).

Die eben besprochenen Typen unterscheiden sich in dem Maß des Wissens, das dem System bereitgestellt wird. Überwachte Verfahren benötigen mehr Wissen (z. B. Klassenzugehörigkeit) als unüberwachte Verfahren. Ganz ohne Wissen kommen jedoch auch unüberwachte Lernverfahren nicht aus, da den Algorithmen Annahmen zugrunde liegen und ggf. Parameter (z. B. die Anzahl zu extrahierender Cluster beim K-Means-Algorithmus) mitgegeben

[29] nach dem Entwickler auch Kohonen-Karten genannt

werden müssen. Gleichzeitig stellt eine bewusste Wahl von Merkmalen, die dem zu erlernenden System mitgegeben werden, gewissermaßen Vorwissen dar.

Der Ablauf beim maschinellen Lernen besteht im Wesentlichen aus der Trainingsphase, der Testphase und der Bewertungsphase (Abb. 3-2). Ausgangspunkt bilden Lerndaten, die in Trainings-, Test- und Validierungsdaten aufgeteilt sind. Während der Trainingsphase wird ein Modell mit einem Lernalgorithmus auf Grundlage der Trainingsdaten erlernt. Anschließend wird dieses auf die Testdaten angewendet und dessen Güte anhand eines definierten Kriteriums (z. B. Fehlerrate) beurteilt. In dieser Testphase können auch Tuning-Parameter des zugrundeliegenden Modells oder die optimierte Merkmalsmenge in einem iterativen Prozess bestimmt werden. In der Validierungsphase erfolgt die Bewertung des Modells an unabhängigen Validierungsdaten. In dieser Phase können verschiedene erlernte Modellarten (z. B. verschiedene Klassifikationsverfahren) evaluiert und das beste Model für die entsprechende Anwendung identifiziert werden (Modelselektion).

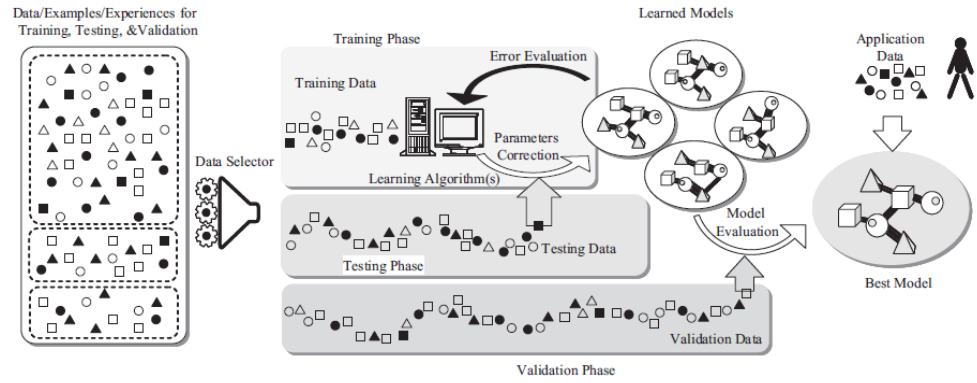

Abb. 3-2: Genereller Ablauf beim maschinellen Lernen (Quelle: Lai et al., 2008)

Maschinelles Lernen kann vielfältig eingesetzt werden. Im Kontext der Mustererkennung spielen jedoch überwachte und unüberwachte Lernverfahren die wichtigste Rolle, um bspw. eine Entscheidungsfunktion oder eine Regel für den Aufbau eines Klassifikators zu erlernen. Des Weiteren werden maschinelle Lernverfahren für die Merkmalsselektion, dem Modelltuning, der Modellselektion oder Bewertung eines erlernten Klassifikators eingesetzt.

3.3 Aufbau eines Mustererkennungssystems

Ein Mustererkennungssystem zur Klassifikation von Mustern lässt sich in mehrere Teilschritte zerlegen. Die wesentliche Grundstruktur ist in Abb. 3-3 dargestellt und findet sich in vergleichbarer Form in der Grundlagenliteratur wieder (u. a. Niemann, 2003; Schalkoff, 2008; Theodoridis & Koutroumbas, 2008). Mithilfe dieser Darstellung lassen sich die Arbeitsphase und die Lernphase unterscheiden. Die Arbeitsphase beinhaltet die Prozesse des eigentlichen Mustererkennungsvorganges. In der Lernphase erfolgt das maschinelle Lernen durch Trainieren, Testen und Validieren (vgl. Kap 3.2.2.) Im Folgenden werden die einzelnen Teilschritte näher erläutert.

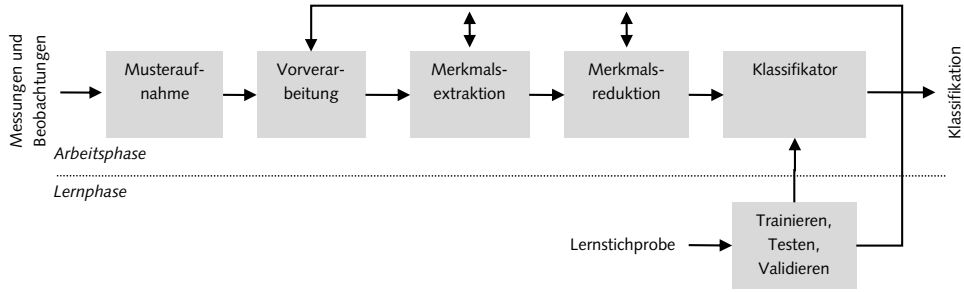

Abb. 3-3: Schema eines Mustererkennungssystems (Quelle: Eigene Darstellung in Anlehnung an Niemann 2003; Theodoridis & Koutroumbas 2008; Schalkoff 2008)

3.3.1 Musteraufnahme

Die Aufnahme physikalischer Größen (Sensordaten) eines Musters erfolgt über einen Sensor. Dieser Sensor ist in der Lage, ein Signal primärer Quelle zu digitalisieren und für die anschließende rechnerische Verarbeitung brauchbar zu machen. Bei einer Aufnahme eines Bildes mit einer Kamera erfolgt eine Wandlung der Helligkeit (Lichtintensität) in elektrische Spannung (ggf. getrennt nach den drei verschiedenen Spektralkanälen), die in einem weiteren Prozess in einer Bildmatrix gespeichert wird. Bei der Sprachaufnahme werden hingegen Geräusche oder der Schalldruck aufgenommen und in eine Sprachsequenz überführt. Ein weiteres Beispiel aus den Sozialwissenschaften sei die Aufbereitung und Überführung der Ergebnisse einer Befragung in eine digitale Datenstruktur.

3.3.2 Vorverarbeitung

Nach Aufnahme des Musters erfolgt die Vorverarbeitung (engl. *preprocessing*). Ziel dieses Arbeitsschrittes ist es, die Qualität des Musters zu verbessern, um entweder die Klassifikationsleistung zu erhöhen oder die anschließende Verarbeitung zu erleichtern. Zur Vorverarbeitung zählen Methoden zur Datenbereinigung (Ausreißereliminierung, Ersetzung fehlender Werte), zur Transformation (z. B. Grauwertspreizung, Fourier-Transformation, Filterung, Normierung) oder aber auch Verfahren zur Vereinfachung des Musters (Binarisierung, kanten- oder regionenbasierte Operatoren). Zur letzteren Gruppe zählen auch sämtliche Segmentierungsprozesse, mit denen beispielsweise ein Bild in homogene Bildbereiche zerlegt wird, die dann die zu klassifizierenden Objekte repräsentieren.

3.3.3 Merkmalsextraktion

Mit der Merkmalsextraktion (engl. *feature extraction*) werden Merkmale zur Beschreibung der Objekte gewonnen. Einige Merkmale sind bereits explizit in den Daten gegeben, wie beispielsweise die Grauwerte der Spektralkanäle eines Fernerkundungsbildes. Oftmals werden diese jedoch mittels anwendungsspezifischer Methoden errechnet, wie etwa mit der Formanalyse (optische Zeichenerkennung), der Fourier-Transformation (Spracherkennung) oder der Texturanalyse (Bilderkennung). Die Werte der Merkmale können unterschiedliche Skalenniveaus annehmen. Man unterscheidet Nominal-, Ordinal-, Intervall- oder Ratioskala

(vgl. Stevens, 1946). Aus nominalen Merkmalen kann eine Kette von Symbolen gebildet werden, die Grundlage für eine nichtmetrische (syntaktische) Klassifikation ist. Oft sind die Merkmale jedoch metrischer Natur (Intervall- oder Ratioskala) bzw. können nichtmetrische Merkmale in reelle Zahlen transformiert werden, um eine weitere Verarbeitung mit nummerischen Klassifizierungsverfahren zu gewährleisten.

Die Wahl der Merkmale hängt von dem zugrundeliegenden Klassifikationsproblem und dem Vorwissen des Modellentwicklers ab und bestimmt die Qualität des Klassifikationsergebnisses maßgeblich. Ist das Klassifikationsproblem sehr einfach, so sind dem Experten die zu erhebenden Eigenschaften bekannt, mit denen die Klassen beschrieben werden können. Oft aber sind selbst Experten nicht in der Lage, ihr Wissen in Form charakteristischer Merkmale auszudrücken. In diesem Fall werden zunächst alle sinnvoll erscheinenden Merkmale berechnet, deren Menge in einem weiteren Schritt (Merkmalsselektion) reduziert wird.

Nach Merkmalsextraktion stehen jedem Objekt m metrische Merkmale zur Verfügung. Formal lassen sich die Merkmale als Komponenten $x_1, \ldots, x_m$ eines Merkmalsvektors $\boldsymbol{x}$ auffassen. Jedes Objekt ist dann mit einem Datenpunkt in einem m-dimensionalen (von den Merkmalen aufgespannten) Merkmalsraum repräsentiert. Die Merkmalsvektoren aller n Objekte bilden im Merkmalsraum eine Punktmenge.

3.3.4 Merkmalsselektion

Ein Klassifikator wird anhand der m-dimensionalen Merkmalsvektoren automatisch erlernt. Wesentliches Ziel dieses Prozesses ist es, die Merkmalsmenge zu reduzieren, um Speicher- und Rechenzeit einzusparen, den Aufwand der Merkmalsextraktion zu minimieren, die Klassifikationsgüte zu erhöhen oder die Interpretierbarkeit der Daten zu verbessern (Guyon, 2006).

Bei einer überschaubaren Merkmalsanzahl kann die Identifizierung nicht sinnvoller oder redundanter Merkmale bereits durch Intuition oder Wissen erfolgen, das durch eine vorgeschaltete explorative Datenanalyse und Visualisierung gewonnen wurde. Oft bedient man sich jedoch analytischer Methoden der Dimensionsreduktion, wie bspw. der Hauptkomponentenanalyse (engl. *principal component analysis*, PCA). Mit der PCA kann durch Transformation der Merkmale eine geringere Anzahl neuer latenter Merkmale (Komponenten) abgeleitet werden. Diese besitzen nur eine wenig geringere Aussagekraft als die originäre Merkmalsmenge. Eine Reduktion auf zwei oder drei Komponenten erlaubt dann eine Visualisierung der Objekte in 2D- oder 3D-Merkmalsplots und ermöglicht das Sichtbarmachen von Zusammenhängen.

Bei einer großen Anzahl an Merkmalen können Auswahl-Algorithmen des maschinellen Lernens eingesetzt werden die das Ziel verfolgen, eine beste bzw. eine möglichst gute Untermenge von Merkmalen aus der gegebenen Merkmalsmenge auszuwählen. Im Gegensatz zu den Verfahren der Dimensionsreduktion werden keine neuen latenten Merkmale erzeugt.

Grundsätzlich lassen sich folgende Methoden unterscheiden (Guyon, 2006):

- Filtermethoden (engl. *filters*)
- Wrapperansatz (engl. *wrappers*)
- eingebettete Methoden (engl. *embedded methods*)

Filterverfahren werden im Rahmen einer eigenständigen Vorprozessierung eingesetzt und dienen dem Herausfiltern unwichtiger Merkmale. Meist stützen sich filterbasierte Verfahren auf einfach zu berechnende Gütemaße (u. a. Korrelation, Gini-Index, Informationsgewinn). Es ist ein von der Klassifizierung losgelöster Prozess mit vergleichsweise geringem Rechenaufwand. Bei Filtermethoden wird zur Auswahl der Merkmale eine andere Bewertungsfunktion verwendet als bei der späteren Evaluierung des Mustererkennungssystems. Mit dem *Wrapperansatz* (Kohavi & John, 1997) wird ein beliebiger Lernalgorithmus (eines Klassifikators) zusammen mit einem gewählten Merkmalsselektionsprozess zu einem Black-Box-Verfahren „zusammengewickelt". Die Wahl des Merkmalssets erfolgt an einem Gütekriterium des gewählten Lernverfahrens über ein Training. Wrapper-Verfahren sind zum Teil sehr rechenaufwändig, wie beispielsweise bei der Vorwärtsauswahl oder Rückwärts-Eliminierung (Vornholt, 2006). Bei den e*ingebetteten Methoden* ist die Merkmalsselektion, wie beim Wrapperansatz, Teil des Trainings. Die Merkmalsselektion ist jedoch Bestandteil eines spezifischen Lernverfahrens und nicht für beliebige Lernverfahren anwendbar (Lal et al., 2006). Beispiele hierfür sind der CART-Algorithmus (Breiman et al., 1984) oder der Random-Forest-Algorithmus (Breiman, 2001), mit denen eine Merkmalsselektion implizit während des Erlernens des Klassifikators erfolgt.

Jedes dieser eben genannten Verfahren hat Vor- und Nachteile. Filterverfahren sind in der Regel sehr schnell, jedoch liefern sie meist eine nicht so gute Merkmalswahl als Wrapper-Verfahren. Wrapper-Verfahren sind hingegen sehr rechenintensiv, da mit jedem Prüfen eines potenziellen Merkmalssets ein neuer Klassifikator erlernt werden muss. Lernverfahren mit eingebetteter Merkmalsselektion können teilweise sehr effizient sein, wobei das erlernte Modell häufig zur Überanpassung neigt (Lal et al., 2006). Eine im Klassifikationsalgorithmus eingebettete Merkmalsselektion hat aus Nutzersicht den Vorteil, dass bei gegebener Implementierung keine Merkmalsselektion nötig ist und das Klassifikationsverfahren auch für hochdimensionale und korrelierte Daten zu guten Klassifikationsergebnissen führt.

3.3.5 Klassifizierung

Die Klassifizierung ist der abschließende Schritt bei der Mustererkennung. Ausgangspunkt ist eine Menge von Merkmalsvektoren, die im mehrdimensionalen Merkmalsraum Punktwolken darstellen. Im Idealfall wird jede Objektklasse durch eine Punktwolke repräsentiert, die sich klar von anderen abgrenzt. Mithilfe einer geeigneten Zuordnungsvorschrift (Klassifikator) findet die Zuordnung der einzelnen Objekte zu einer Objektklasse statt. Dabei wird eine Abbildung des m-dimensionalen Merkmalsraumes auf einen Ergebnisvektor realisiert, der den Wertebereich der Klassen annimmt und den Merkmalsraum in Klassen separiert. Der Klassifikator wird in einer Lernphase trainiert, getestet und validiert. Während der Entwicklung eines Klassifikators werden meist mehrere für das Problem in Frage kommende Klassifikationsverfahren untersucht und mithilfe einer Modellselektion der beste Klassifikator identi-

fiziert. Aufgrund der Vielzahl von Klassifikationsmethoden werden diese gesondert im Kapitel 3.4 vorgestellt.

3.3.6 Trainieren, Testen, Validieren

Um mit einem Klassifikator neue Daten klassifizieren zu können, müssen die Modellparameter des jeweiligen Verfahrens über die Optimierung eines oder mehrerer Gütekriterien in einem Trainingsprozess erlernt werden. Viele Klassifikationsverfahren besitzen zudem Komplexitätsparameter (z. B. bei der *Support Vector Machine* oder Neuronale Netzen), die in einem Modelltuning, als Teil des Trainings, ermittelt werden müssen. Unter Variation der Parameterwerte wird dabei ein Klassifikator trainiert, in dem die besten Parameter ermittelt werden. Eine gute Anpassung der Parameter an die zugrunde liegenden Trainingsdaten geht allerdings in der Regel nicht mit einer guten Generalisierungsfähigkeit einher, weshalb beim Tuning eine Bewertung auf Grundlage einer unabhängigen Testdatenmenge erfolgen sollte.

Ein Mustererkennungssystem kann auch so gestaltet sein, dass während des Trainings mehrere für ein Problem anwendbare Klassifikationsverfahren trainiert, getestet und miteinander verglichen werden. Mit einer Modellselektion wird anschließend der Klassifikator aus der gegebenen Menge von Klassifikatoren identifiziert, der für das Problem am besten geeignet ist. Für die Bewertung im Modellselektionsprozess können verschiedene Gütemaße betrachtet werden. Die meisten Lernalgorithmen nutzen jedoch den Generalisierungsfehler (Fehlerrate gemessen an unabhängigen Testdaten) als das zu minimierende Kriterium. Je nach Anwendung können aber auch Kriterien, wie die Komplexität (z. B. Rechenzeit, Speicherbedarf), die Robustheit (z. B. gegenüber fehlenden Werten oder Rauschen) oder die Interpretierbarkeit des Modells eine entscheidende Rolle spielen (Alpaydin, 2004). Die verschiedenen Gütemaße (u. a. Generalisierungsfehler, Rechenzeit) können des Weiteren über ein Kostenmodell zu einem neuen Maß kombiniert werden (Turney, 2000).

In einer abschließenden Validierung erfolgt die Bewertung des erlernten Klassifikators und damit des gesamten Mustererkennungssystems. Bei überwachten Verfahren wird die Qualität auf Grundlage bisher ungesichteter Daten mit bekannter Klassenzugehörigkeit quantifiziert. Für die Messung der Genauigkeit stehen verschiedene Gütemaße zur Verfügung (Congalton, 1991; Hand, 1997; Liu et al., 2007; Richards, 1996). Als Gesamtmaß eines überwachten Klassifikators wird in der Regel die Gesamtgenauigkeit oder die Fehlerrate verwendet. Für die Beurteilung einzelner Klassen können klassenspezifische Gütemaße aus der Konfusionsmatrix abgeleitet werden. Die in der Arbeit verwendeten Bewertungsverfahren und Gütemaße für überwachte Klassifikationsverfahren werden gesondert im Kap. 3.5 vorgestellt.

Bei unüberwachten Klassifikationsverfahren können für die Bewertung intrinsische oder extrinsische Gütemaße verwendet werden (Amigó et al., 2009). Mit intrinsischen Gütemaßen wird die Ähnlichkeit innerhalb eines Clusters (z. B. über die Nähe der Elemente zum Cluster-Zentrum) oder die Unähnlichkeit zwischen verschiedenen Clustern (Distanz der Elemente eines Clusters zu Elementen anderer Cluster) gemessen (Manning et al., 2008). Deren Beurteilung ist allerdings nicht immer einfach und von der Clusterkonstellation sowie von der Größe und Anzahl der Cluster abhängig. Eine weitere Möglichkeit besteht darin,

Cluster unter Verwendung externer Daten zu validieren und über extrinsischen Gütemaße, wie Purity, F-Measure, Entropy oder den Rand Index zu bewerten (Amigó et al., 2009).

Nach der Modellbewertung und Akzeptanz der erreichten Qualität können zum Training des finalen Klassifikators alle Daten mit bekannter Klassenzugehörigkeit verwendet werden – auch die Trainingsdaten. Dieser finale Klassifikator kann dann auf neue Daten angewendet werden.

3.4 Klassifikationsverfahren

Im Folgenden werden verschiedene Klassifikationsverfahren der Mustererkennung mit Fokus auf die nummerischen (statistischen) Verfahren vorgestellt. Syntaktische Klassifikationsverfahren, mit denen komplexe Muster in Form einer strukturellen Beschreibung (Regel oder formalen Grammatik) repräsentiert werden können, werden an dieser Stelle vernachlässigt. Die nummerische Klassifizierung wird üblicherweise nach der Lernart in unüberwachte Klassifizierung und die überwachte Klassifizierung unterschieden (Duda et al., 2000; Schalkoff, 2008).

Bei der unüberwachten Klassifizierung (engl. *unsupervised classification*) werden mathematische und statistische Verfahren eingesetzt mit dem Ziel, homogene Klassen ähnlicher Objekte zu entdecken sowie eine optimale oder möglichst zweckmäßige Gruppierung der Objekte in einer gegebenen Trainingsmenge zu konstruieren (Bock, 1974). Der erlernte Klassifikator muss dabei in der Lage sein, den Merkmalsraum in sinnvolle Einheiten aufzuteilen. Zu den unüberwachten Lernverfahren zählen Methoden der Clusteranalyse (Clustering), wie etwa hierarchische Clusterverfahren (u. a. Single Linkage, Complete Linkage oder die WARD-Methode etc.), partitionierende Verfahren (u. a. K-Means-Clustering) oder aber auch unscharfe Verfahren, wie der Fuzzy C-Means-Algorithmus (Behnisch, 2009). Diese Verfahren werden insbesondere beim Data Mining eingesetzt, um Strukturen und Zusammenhänge in Daten aufzudecken. Die gefundenen Klassen müssen jedoch stets in einem weiteren Schritt hinsichtlich ihrer Bedeutung interpretiert werden.

Bei überwachten Klassifikationsverfahren (engl. *supervised classification)* erfolgt die Zuordnung der Objekte in eine von k vorab festgelegten Klassen. Gegenüber den unüberwachten Verfahren muss die Zugehörigkeit jedes Objektes zu einer Klasse im Trainingsdatensatz gegeben sein. Ein Klassifikationsproblem mit vorab bekannten Klassen tritt in vielen Bereichen, wie der Medizin, Wirtschaft, Ökonomie, Sozialwissenschaften, Bildverarbeitung, Marktforschung, auf.

In einer formalen Darstellung bestehen die Eingangsdaten (Trainingsdaten) aus n Elementen (Objekten), die jeweils mit einem Merkmalsvektor mit m Merkmalen beschrieben sind. Die Eingangsdaten sind dann $X = \{\boldsymbol{x}_1, \dots, \boldsymbol{x}_n\}$ und spannen einen Merkmalsraum $\mathcal{X}^m$ mit der Dimension m auf. Der i -te Merkmalsvektor $\boldsymbol{x}_i$ der Eingangsdaten besteht aus den Elementen $x_{i1}, \dots, x_{im}$. Ziel ist die Generierung einer Klassifikationsfunktion, die einem Merkmalsvektor $\boldsymbol{x} \in \mathcal{X}^m$ eine von k vorab definierten Klassen $\omega_i \in \Omega$ zuweist.

Die Klassifikationsfunktion lässt sich in Form einer Abbildung Φ vom Merkmalsraum $\mathcal{X}^m$ in den Ergebnisraum Ω (diskrete Menge möglicher Klassen) darstellen:

$$\Phi: \mathcal{X}^m \rightarrow \Omega \qquad (3.1)$$

Welche Form die Abbildung Φ annimmt hängt von der Wahl des Klassifikationsverfahrens ab. Das Methodenspektrum ist dabei äußerst groß. Eine Möglichkeit der Kategorisierung der Methoden zeigt die Übersicht in Abb. 3-4.

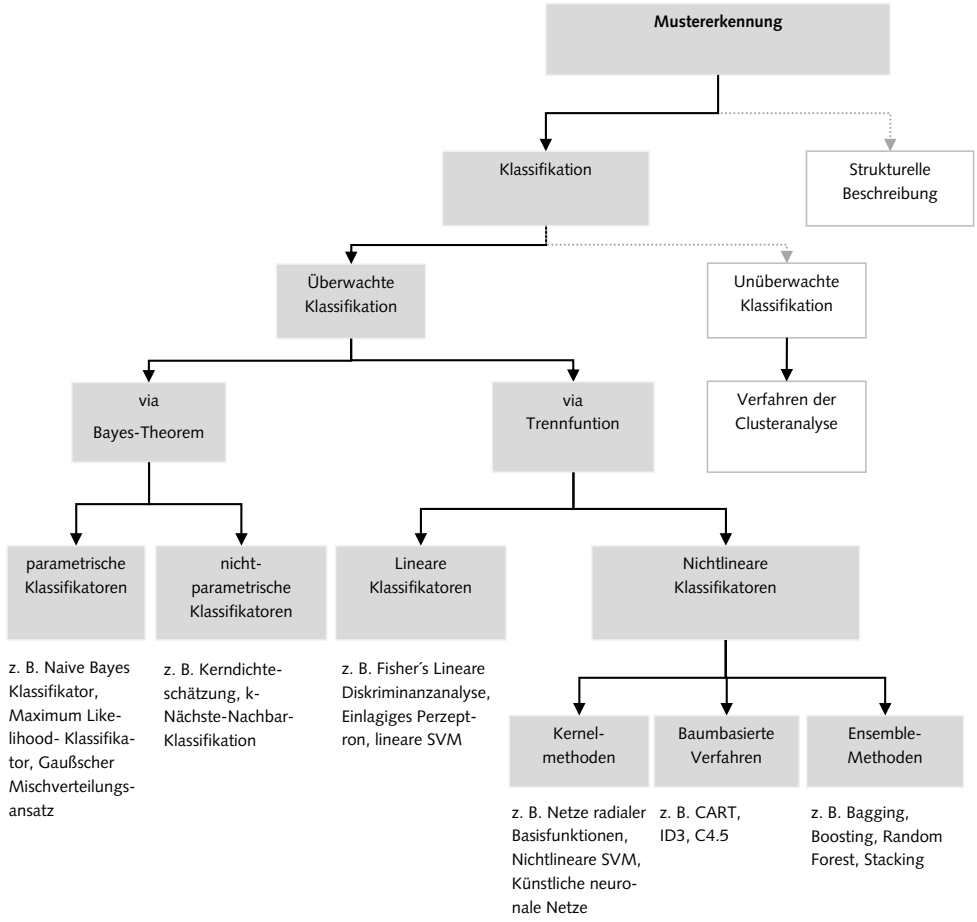

Abb. 3-4: Klassifikationsverfahren (angelehnt an A. R. Webb 2002)

Grundsätzlich wird zwischen Klassifikationsverfahren unterschieden, die auf dem *Bayes-Theorem* (statistische Entscheidungstheorie) arbeiten und diejenigen, die auf einer *Diskriminanzfunktion* basieren. Im ersten Fall wird eine Entscheidungsfunktion auf Grundlage klassenbedingter Verteilungsdichten abgeleitet. Die Zuordnung zu einer Klasse erfolgt dann über die Bayes Regel (vgl. Kap. 3.4.1). Bei der zweiten Gruppe von Verfahren ergibt sich die Entscheidungsregel durch Schätzung einer optimalen Trennfunktion – ohne Berücksichtigung expliziter Verteilungsdichten (vgl. Kap.3.4.2). Verfahren, die auf dem Bayes Theorem basieren, lassen sich weiter in *parametrische Verfahren* und *nicht-parametrische Verfahren* differenzieren, wohingegen die diskriminativen Klassifikatoren in lineare Klassifikatoren und nichtlineare Klassifikatoren unterteilt werden.

Im Folgenden werden verschiedene Gruppen überwachter Verfahren vorgestellt. Die Grundlagen wurden, soweit nicht anders gekennzeichnet, Duda et al. (2000), Alpaydin (2004) und Theodoridis & Koutroumbas (2008) entnommen.

3.4.1 Klassifikation via Bayes-Theorem

Diese Gruppe von Methoden gehen auf die Wahrscheinlichkeitstheorie des englischen Mathematikers Thomas Bayes (1702–1761) zurück (Bishop, 2007). Die Klassifizierung erfolgt auf Grundlage des Bayes-Theorems (Satz von Bayes), mit dem die Berechnung klassenbedingter Wahrscheinlichkeiten festgelegt ist. Bei einem gegebenen Klassifikationsproblem mit den Klassen ω_i mit $i \in \{1, \dots, k\} \in \Omega$ und einem unbekannten Muster, das in Form eines Merkmalsvektors $\boldsymbol{x} = [x_1, \dots x_m]^{\mathrm{T}}$ beschrieben ist, wird das Muster der Klasse zugewiesen, dessen A-posteriori-Wahrscheinlichkeit $P(\omega_i|\boldsymbol{x})$ am größten ist.

Bei einer Entscheidung auf Grundlage des Bayes-Theorems sind folgende Größen von Bedeutung:

- $p(\boldsymbol{x})$: Wahrscheinlichkeitsdichte der multivariaten Verteilung eines Musters $\boldsymbol{x}$ (Verteilungsdichte, engl. probability density function)
- $P(\omega_i)$: A-priori-Wahrscheinlichkeit für das Auftreten der Klasse ω_i (engl. a priori probabilities)
- $p(\boldsymbol{x}|\omega_i)$: Klassenbedingte Wahrscheinlichkeitsdichte für Muster $\boldsymbol{x}$ und die Klasse ω_i (klassenbedingte Verteilungsdichte, engl. class conditional probability density)
- $P(\omega_i|\boldsymbol{x})$: A-posteriori-Wahrscheinlichkeit, dass ein gegebenes Muster $\boldsymbol{x}$ aus der Klasse ω_i stammt (engl. a posteriori probabilities)

Auf Grundlage dieser Größen sieht der Satz von Bayes wie folgt aus (Theodoridis & Koutroumbas, 2008):

$$P(\omega_i|\boldsymbol{x}) = \frac{p(\boldsymbol{x}|\omega_i)P(\omega_i)}{p(\boldsymbol{x})};\quad p(\boldsymbol{x}) = \sum_{i=1}^{n} p(\boldsymbol{x}|\omega_i)P(\omega_i) \tag{3.2}$$

Mit diesem kann die gesuchte A-posteriori-Wahrscheinlichkeit $P(\omega_i|\boldsymbol{x})$ bestimmt und eine Entscheidungsregel abgeleitet werden. Die Entscheidung, zu welcher Klasse ein Muster gehört, ergibt sich aus der maximalen A-posteriori-Wahrscheinlichkeit $P(\omega_i|\boldsymbol{x})$. Für ein angenommenes Zweiklassenproblem mit ω_1 und ω_2 gehört $\boldsymbol{x}$ der Klasse ω_1, wenn $P(\omega_1|\boldsymbol{x}) > P(\omega_2|\boldsymbol{x})$ und $\boldsymbol{x}$ der Klasse ω_2, wenn $\omega_2, P(\omega_1|\boldsymbol{x}) < P(\omega_2|\boldsymbol{x})$. Da der Nenner des Satzes von Bayes unabhängig von der Klasse ist, lässt sich die Entscheidungsregel auch so darstellen:

$$\boldsymbol{x} \in \begin{cases} \omega_1, \text{wenn } p(\boldsymbol{x}|\omega_1)P(\omega_1) > p(\boldsymbol{x}|\omega_2)P(\omega_2) \\ \omega_2, \text{wenn } p(\boldsymbol{x}|\omega_1)P(\omega_1) < p(\boldsymbol{x}|\omega_2)P(\omega_2) \end{cases} \tag{3.3}$$

Im Falle gleicher A-priori-Wahrscheinlichkeiten $P(\omega_1) = P(\omega_2)$ entspricht die A-posteriori-Wahrscheinlichkeit der klassenbedingten Verteilungsdichte, so dass gilt:

$$\boldsymbol{x} \in \begin{cases} \omega_1, \text{wenn } p(x|\omega_1) > p(x|\omega_2) \\ \omega_2, \text{wenn } p(x|\omega_1) < p(x|\omega_2) \end{cases} \tag{3.4}$$

Die Entscheidungsregel ist in diesem Fall so angelegt, dass die Wahrscheinlichkeit der Fehlklassifikation minimiert wird, in dem die A-posteriori-Wahrscheinlichkeit maximiert wird. In diesem Fall spricht man vom Maximum-a-posteriori-Kriterium (MAP). Neben diesem können jedoch auch andere Kriterien definiert werden, um eine optimale Entscheidungsfunktion zu erhalten (vgl. 3.4.1.1).

Die Abb. 3-5 zeigt an dem einfachen Zwei-Klassen-Problem die klassenbedingten Verteilungsdichten eines einzigen Merkmales. Die A-priori-Wahrscheinlichkeit sei in diesem Fall für beide Klassen gleich. Die gerissene Linie markiert den optimalen Schwellwert, der den Merkmalsraum mit geringster Fehlerwahrscheinlichkeit in zwei Regionen teilt. Es ist ersichtlich, dass sich die Verteilungsdichten überlappen. Die schattierte Fläche unter der Kurve stellt die Fehlerwahrscheinlichkeit dar, die bei Verschieben des Schwellwertes größer wird. Mit einem derartigen Bayes-Klassifikator erfolgt eine vollständige Klassifikation des Merkmalsraumes.

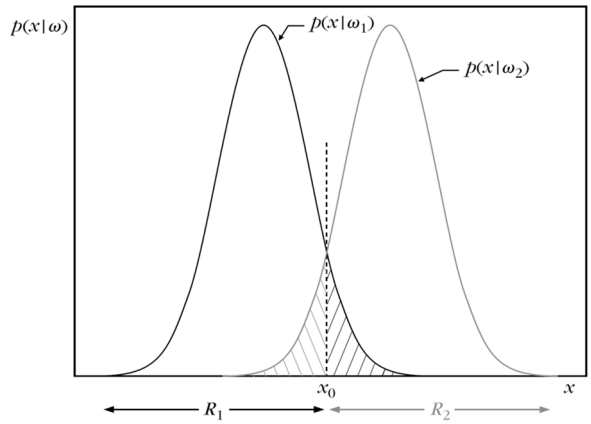

Abb. 3-5: Eindimensionale Verteilungsdichten zweier normalverteilter Klassen mit gleicher Varianz und Aufteilung des Merkmalsraums in zwei Regionen R_1 *und* R_2 *(Quelle: Theodoridis & Koutroumbas, 2008)*

Ein optimaler Bayes-Klassifikator ist meist von theoretischem Interesse und kann zur Beurteilung anderer Klassifikatoren auf simulierten Daten eingesetzt werden (Kohavi & John, 1997). Dazu werden zufällige Stichproben auf Grundlage vorab definierter klassenbedingten Verteilungsdichten und A-priori-Wahrscheinlichkeiten generiert. Anschließend wird ein zu untersuchender Klassifikator auf die Stichprobe angesetzt und das Ergebnis mit dem optimalen Bayes-Klassifikator verglichen. Im Ergebnis erhält man eine Einschätzung, wie nahe der untersuchte Klassifikator am Optimum (der unteren Schranke für die Fehlerwahrscheinlichkeit) liegt, da kein anderer Klassifikator mit demselben A-priori-Wissen besser als der optimale Bayes-Klassifikator sein kann (Theodoridis & Koutroumbas, 2008).

Bei realen Problemen liegt die Schwierigkeit darin, dass die Verteilungsdichten unbekannt sind. Deshalb wurden Verfahren zur parametrischen und nichtparametrischen Schätzung entwickelt, um die klassenbedingte Verteilungsdichte $p(\boldsymbol{x}|\omega_i)$ und die A-priori-Wahrscheinlichkeit $P(\omega_i)$ zu bestimmen. Im Folgenden wird auf parametrische und nichtparametrische Klassifikationsverfahren eingegangen, die sich auf das Bayes-Theorem stützen. Für Vertiefungen sei auf Hastie et al. (2009) und Webb (2002) verwiesen.

3.4.1.1 Parametrische Verfahren

Mit parametrischen Verfahren werden die klassenbedingten Verteilungsdichten $p(\boldsymbol{x}|\omega_i)$ über Parameter bestimmt. Das Konzept der Parameterschätzung ist ein probabilistischer Ansatz, mit dem eine Form der Verteilung angenommen und die dazugehörigen Parameter aus einer gegebenen Trainingsdatenmenge geschätzt werden.

Ein parametrischer Klassifikator ist der *optimale Bayes-Klassifikator* für normalverteilte Daten. Die strenge Annahme einer Normalverteilung ist für viele praktische Anwendungen gerechtfertigt, wenn die Merkmale auf natürliche Phänomene zurückzuführen sind. Die Parameter der multivariaten Normalverteilung sind durch die Mittelwerte und die Varianzen der Klasse (rechnerisch über den Mittelwertvektor und der Kovarianzmatrix) definiert. Diese können genauso wie die A-priori-Wahrscheinlichkeit auf Grundlage einer Trainingsdaten-

menge geschätzt werden. Durch Minimierung der Fehlerwahrscheinlichkeit (Maximum-a-posteriori-Kriterium) erhält man mit der Bayes-Regel eine Klassengrenze.

Die optimale Klassengrenze für die Separation zweier Klassen ist am Beispiel in Abb. 3-6 dargestellt. Mit einem Bayes-Klassifikator erhält man für normalverteilte Merkmalsvektoren eine optimale Klassengrenze, die sich über eine quadratische Trennfunktion beschreiben ließe (vgl. Abb. 3-6a). Das bedeutet, dass in diesem Fall keine Trennfunktion höherer Ordnung eine niedrigere Fehlerrate erzielen kann (vgl. Kap. 3.4.2). Sind die Kovarianzmatrizen der Normalverteilungen gleich, so reduziert sich die optimale Klassengrenze auf eine lineare Hyperebene (vgl. Abb. 3-6b). Liegen für jede Klasse gleiche A-priori-Wahrscheinlichkeiten sowie identische Varianzen vor, so entspricht es dem euklidischen Minimaldistanz-Klassifikator. An dieser Stelle zeigt sich die Beziehung zu den diskriminativen Klassifikatoren (vgl. 3.4.2), deren Konstruktion jedoch auf Annahmen zu einer bestimmten Form der Trennfunktion und nicht der Verteilungsdichte beruht.

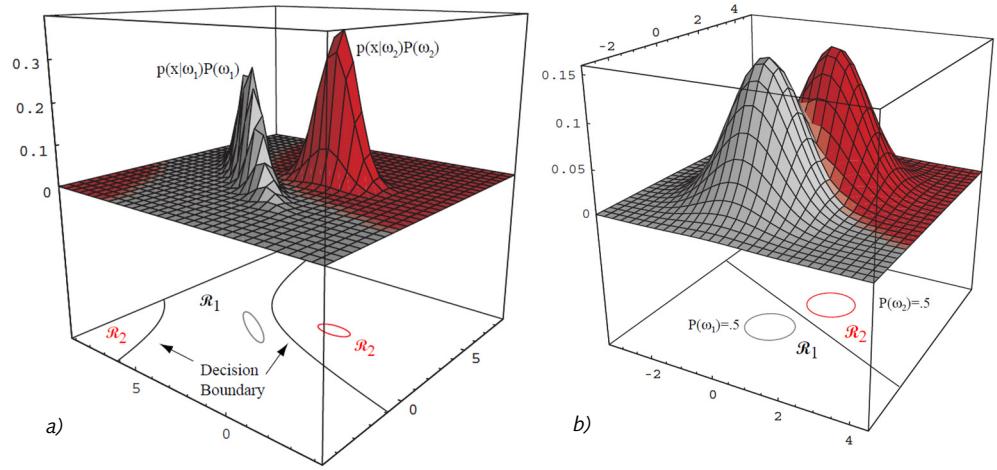

Abb. 3-6: 3D-Darstellung zweidimensionaler Verteilungsdichten und optimale Trennung nach dem Bayes-Theorem: a) normalverteilte Verteilungsdichten zweier Klassen mit unterschiedlichen Kovarianzmatrizen (optimale Trennung entspricht quadratischer Trennfunktion) b) normalverteilte Verteilungsdichten zweier Klassen mit identischen Kovarianzmatrizen (optimale Trennung durch lineare Trennfunktion) (Quelle: Duda et al., 2000)

Für die Schätzung der A-posteriori-Verteilungsdichte existieren neben der Maximum-a-posteriori-Schätzung (MAP) weitere Ansätze. Heijden (2004) nennt beispielsweise die Maximum-Likelihood-Schätzung (ML), die Schätzung nach dem kleinsten mittleren Fehlerquadrat (engl. *minimum mean square error*, MMSE) oder die Schätzung nach dem kleinsten mittleren Absolutfehler (engl. *minimum mean absolute value of error*, MAVE).

Für die Schätzung der Dichtefunktionen ist eine aussagefähige Trainingsdatenmenge nötig. Bei parametrischen Verfahren steigt der Bedarf an Trainingsobjekten exponentiell mit jeder erweiterten Dimension an. Liegen hochdimensionale Merkmalsvektoren, aber keine ausreichende Anzahl an Beobachtungen vor, so bedient man sich häufig einem relativ einfach zu implementierenden Verfahren, dem Naive Bayes Klassifikator (Theodoridis & Koutroumbas, 2008). Dieser beruht auf der Annahme, dass alle Merkmale gleichwichtig und die Merkmale statistisch unabhängig sind (d. h. die Kenntnis eines Merkmalswertes sagt nichts über den Wert eines anderen Attributs aus, wenn die Klasse bekannt ist). Trotz dieser Unabhängigkeitsannahme liefert der Klassifikator in der Praxis häufig gute Ergebnisse, wenn nicht allzu viele redundante Merkmale vorliegen.

Möchte man hingegen Abhängigkeiten zwischen Merkmalen berücksichtigen, dann werden Bayes-Netzwerke (engl. *Bayesian networks*) oder Markovnetzwerke (engl. *Markov networks*) eingesetzt (Pearl, 1988). In Bayes-Netzwerken werden die Abhängigkeiten über gerichtete azyklische Graphen (Knoten = Merkmal, Kante = bedingte Abhängigkeit) repräsentiert. Eine Änderung eines einzelnen Attributwertes kann sich auf die Wahrscheinlichkeiten aller Zustände im gesamten Netzwerk auswirken. Die probabilistischen Parameter werden anhand der Trainingsdaten erlernt. Die Struktur des Bayes-Netzes wird in der Regel vorab vom Nutzer selbst festgelegt oder mit entsprechenden Algorithmen automatisch erlernt (Friedman et al., 1997).

Ein letztes Beispiel eines parametrischen Verfahrens ist der Gaußsche Mischverteilungs-Ansatz (engl. *Bayesian Gaussian Mixture Models*). Bei diesem Verfahren wird eine kontinuierliche Dichtefunktion aus mehreren einzelnen Gaußschen Normalverteilungen (Komponenten) additiv zusammensetzt. Für die Parameterschätzung der einzelnen Komponenten wird der sog. *Expectation-Maximization*-Algorithmus (kurz EM-Algorithmus) angewendet, mit dem zunächst mit einer einzigen Normalverteilung beginnend, eine iterative Aufteilung in die gewünschten Dichtekomponenten erfolgt (Duda et al., 2000).

3.4.1.2 Nichtparametrische Verfahren

Es gibt Klassifikationsprobleme für die vorab keine Annahmen zu einer bestimmten Form der klassenbedingten Verteilungsdichte gemacht werden können. Die Idee nicht-parametrischer Verfahren basiert darauf, die klassenbezogene Wahrscheinlichkeitsdichte direkt aus einer Stichprobe zu schätzen, ohne Vorkenntnisse über deren parametrische Familie zu besitzen.

Das einfachste und auch älteste Verfahren zur Dichteschätzung ist die Histogramm-Methode, mit welcher der Merkmalsraum in gleichgroße Intervalle (z. B. Würfel) zerlegt wird. Für eine bessere Beschreibung sehr komplex angeordneter Daten erfahren Verfahren der Kerndichteschätzung (engl. *Kernel Density Estimation*, kurz KDE), auch Parzen-Fenster-Methode genannt, eine große Beliebtheit (Theodoridis & Koutroumbas, 2008). Die Schätzung erfolgt mithilfe eines definierten Kernes. Bei Wahl eines entsprechend glatten Kernes (u. a. Gaußkern) lassen sich damit beliebige multimodale Verteilungsfunktionen annähern. Die Zuordnung eines Musters zu einer Klasse erfolgt dann wieder durch Anwendung der oben beschriebenen Bayes-Regel.

Ein weiterer populärer nichtparametrischer Ansatz ist der *k*-Nächste-Nachbar-Klassifikator (kurz *k*-NN-Klassifikator). Dieses Verfahren geht auf Fix & Hodges (1951) zurück und stellt eine Technik dar, mit der die Klassenzuordnung eines Objektes unter Berücksichtigung seiner *k* nächsten Nachbarn im Merkmalsraum erfolgt. Einem neuen Objekt wird die Klasse zugewiesen, die für die *k* Nachbarn in den Trainingsdaten am häufigsten auftreten.

Mit einem *k*-NN-Klassifikator erzielt man in der Praxis eine hohe Klassifikationsgenauigkeit für viele Anwendungen. Die richtige Wahl von *k* ist jedoch essenziell, da bei zu klein gewähltem *k* der Klassifikator sehr sensibel gegenüber Ausreißern ist. Werden hingegen zu viele Nachbarn berücksichtigt, erhält man ein stark generalisiertes Modell, das sich an das Risiko eines optimalen Bayes-Klassifikators annähert (Alpaydin, 2004). Der Algorithmus arbeitet bei großem *k* jedoch sehr ineffizient, da sehr viele Anfragen an die Datenbank nötig sind. Für den Spezialfall $k = 1$ tritt die Nächste-Nachbarregel in Kraft, was zum Nächsten-Nachbar-Klassifikator (NN-Klassifikator) führt, mit dem der Merkmalsraum in Regionen (auch Thiessen-Polygone oder Voronoi-Diagramm) zerlegt wird. Dies ist zwar ein sehr schnelles Verfahren, liefert jedoch meist ein suboptimales Ergebnis. Cover und Hart (1967) bewiesen, dass jedoch bei genügend großer Fallanzahl der NN-Klassifikator maximal den doppelten Fehler des optimalen Bayes-Klassifikators besitzt. Folglich wird dieses Verfahren häufig zum Benchmarking anderer Klassifikatoren eingesetzt.

Der Vorteil nicht-parametrischer Verfahren ist, dass mit ihnen praktisch jede Art von Verteilung abbildbar ist, sofern genügende Trainingsdaten zur Verfügung stehen. Sie sind jedoch für hochdimensionale Daten sehr rechen- und speicherintensiv, da mit jeder Dimension die Komplexität des Modells exponentiell wächst und folglich eine große Trainingsdatenmenge nötig wird. Wegen diesem auch als „Fluch der Dimension" (engl. *curse of dimensionality*) benannten Phänomens sind nichtparametrische Methoden häufig nur bei geringer Merkmalsanzahl anwendbar (Duda et al., 2000).

3.4.2 Klassifikation mittels Trennfunktion

Eine weitere Form, den Merkmalsraum zu partitionieren, um unbekannte Objekte zu klassifizieren, besteht in der Konstruktion einer oder mehrerer Trennfunktionen (Diskriminanten). Der wesentliche Unterschied zu den Verfahren auf Grundlage des Bayes-Theorems ist, dass keine Annahmen über die klassenbedingte Verteilung, sondern über die Art und Form der Trennfunktion gemacht werden. Die Modellschätzung erfolgt hier ohne explizite Schätzung der zugrundeliegenden Verteilung (verteilungsfreie Klassifikatoren).

Es existieren Verfahren unterschiedlichster Komplexität. Im Allgemeinen unterscheidet man zwischen linearen und nichtlineare Verfahren (Webb, 2002), die in folgenden Abschnitten näher beschrieben werden.

3.4.2.1 Lineare Klassifikatoren

Mit linearen Klassifikatoren wird der Merkmalsraum mit einer oder mehreren linearen Trennfunktionen aufgeteilt. Ziel ist es, die Parameter einer definierten linearen Funktion zu bestimmen. Vorteil dieser Verfahren ist deren Einfachheit und die kurze Rechenzeit. Grundvoraussetzung ist jedoch, dass die Klassen im Merkmalsraum linear separierbare Regionen einnehmen.

Ein sehr einfacher linearer Klassifikator ist die Klassifizierung über die euklidische Minimaldistanz (engl. *minimum euclidean distance classification*). Ein unbekanntes Muster wird der Klasse zugeordnet, deren berechneter Klassenschwerpunkt den geringsten Abstand zum Datenpunkt im euklidischen Merkmalsraum besitzt. Es entspricht formal dem Nächste-Nachbar-Klassifikator mit einem Prototyp pro Klasse.

Das wohl bekannteste lineare Klassifikationsverfahren ist die lineare Diskriminanzanalyse (engl. *linear discriminant analysis*, kurz LDA) von Fisher (1936). Bei diesem Ansatz wird eine Hyperebene gesucht, mit der die Klassen möglichst gut voneinander getrennt werden. Es basiert auf der Verwendung einer linearen Transformation der Merkmale in einen Unterraum (mit einer Dimension der Anzahl der Klassen minus 1). Die Projektion (jene Linearkombination) wird dann so gewählt, dass ein möglichst großer Abstand zwischen den projizierten Klassenmittelpunkten entsteht (maximale Separation) und gleichzeitig eine geringe Varianz innerhalb der einzelnen Klassen in dem projizierten Unterraum vorliegt (Abb. 3-7).

Die Anwendung der LDA ist nur sinnvoll, wenn eine halbwegs gleiche Streuung in den Gruppen vorliegt bzw. die Kovarianzmatrizen der Gruppen annähernd gleich sind (Backhaus et al., 2006). Möchte man das lineare Modell flexibilisieren, so kann die LDA zu einer Quadratischen Diskriminanzanalyse (QDA) erweitert werden. Statt einer linearen wird dann eine quadratische Trennfunktion erlernt, deren Form eine optimale Trennung zweier Klassen mit ungleicher Streuung zulässt. Diese generalisierten Modelle gehören dann jedoch der Gruppe der nichtlinearen Klassifikatoren an (vgl. Kap 3.4.2.2).

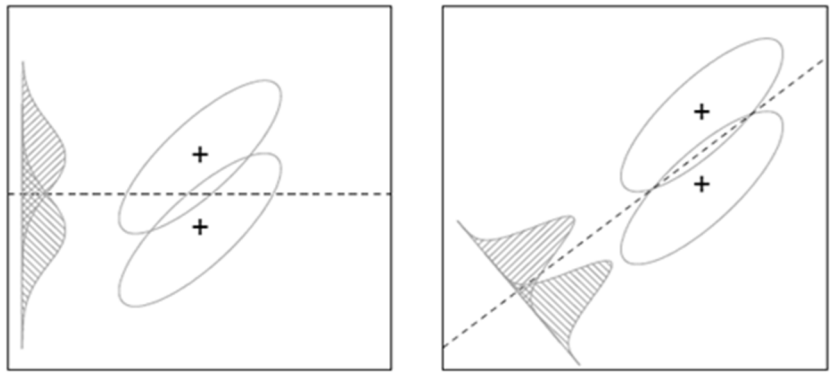

Abb. 3-7: Beste Hyperebene der LDA: a) Maximierung des Abstandes der Mittelpunkte und b) optimale Projektionsrichtung nach Fisher-Kriterium (Quelle: Hastie et al., 2009)

Ein weiteres Verfahren zur Bestimmung separierender Hyperebenen ist die Klassifizierung mit dem einlagigen Perzeptron (engl. *single layer perceptron*), dessen zugehöriges Lernverfahren der Perzeptron-Algorithmus ist. Es wurde von Rosenblatt (1958) entwickelt, um neuronale Informationsverarbeitungsvorgänge zu simulieren (Hastie et al., 2009). Ein Perzeptron ist ein einfaches künstliches neuronales Netz, das nur aus einem einzigen künstlichen Neuron mit anpassbaren Gewichtungen und einem Schwellenwert besteht. Es entspricht einem einfachen linearen Regressionsmodell (Abb. 3-8a). Werden mehrere Neuronen in einer Schicht zusammengeschaltet, spricht man vom einlagigen Perzeptron. Die Neuronen werden über mehrere Eingabegewichte gesteuert und eine Schwellwertfunktion als Aktivierungsfunktion bestimmt den Output. Der Perzeptron-Algorithmus basiert auf der iterativen Korrektur von Fehlern und läuft bei nicht linear trennbaren Problemen ins unendliche bzw. liefert dieser bei vollständiger Trennbarkeit nur eine von vielen Lösungen. Abhilfe verschafft in diesem Fall eine Approximation der Lösung mit dem LMS-Algorithmus (Least-Mean-Squares-Algorithmus) von Widrow & Hoff (1960), der auch als Delta-Regel oder Widrow-Hoff-Algorithmus bekannt ist. Durch Adaption der Gewichte mittels Minimierung der Summe quadratischer Distanzen, erhält man eine Näherungslösung, selbst wenn die Trainingsbeispiele nicht linear separierbar sind.

Ein weiteres lineares Verfahren sind lineare Support-Vektor-Maschinen (engl. *support vector machine*, kurz SVM), mit denen sich im Merkmalsraum optimal separierende Hyperebenen bestimmen lassen. Eine Hyperebene ergibt sich aus dem breitesten Korridor zwischen zwei Klassen, der frei von Objekten ist. Man spricht in diesem Fall von einem Large-Margin-Klassifikator. Bei nicht eindeutig linear trennbaren Klassen erfolgt die Einführung weicher Nebenbedingungen über Schlupfvariablen, mit denen eine definierte Anzahl an Objekten in einem definierten Korridor zugelassen werden (Soft-Margin-Klassifikator). Die zunächst nur auf Zweiklassenprobleme anwendbaren SVM können mithilfe verschiedener Aggregationsstrategien auf Mehrklassenprobleme angewendet werden.

Die eben vorgestellten linearen Verfahren, wie die LDA, das einlagige Perzeptron oder die optimale Hyperebenentrennung mit SVM, sind nur anwendbar, wenn die Klassen im Merkmalsraum linear trennbar sind (Hastie et al., 2009). Eine Anwendung dieser ist nicht sinnvoll, wenn die Daten starke nichtlineare Abhängigkeiten aufweisen. Sie können jedoch als Bausteine kombinierter Klassifikatoren dienen bzw. bilden diese die Grundlage für eine Erweiterung zu nichtlinearen Klassifikatoren, wie etwa den generalisierten linearen Verfahren Multi-Layer-Perzeptrons (Neuronale Netze) oder nichtlineare SVM.

3.4.2.2 Nicht-lineare Verfahren

Wenn die Klassen im Merkmalsraum nicht linear trennbar sind, eignet sich der Einsatz nichtlinearer Verfahren, mit denen komplexere Trennfunktionen modelliert werden können. Zu diesen zählen verallgemeinerte lineare Verfahren, Kernel-Methoden, Neuronale Netze, Baumbasierte Verfahren und Ensemble-Verfahren.

3.4.2.2.1 Verallgemeinerte lineare Diskriminanzanalyse

Unter der Gruppe der verallgemeinerten linearen Diskriminanzanalyse werden modifizierte Verfahren verstanden, mit denen Klassen durch nicht-lineare Trennfunktionen separiert werden. Zu diesen Verfahren zählt beispielsweise die bereits erörterte Erweiterung der LDA zur quadratischen Diskriminanzanalyse QDA (vgl. Kap. 3.4.2.1).

Hastie et al. (2009) stellen weitere verallgemeinerte Verfahren der linearen Diskriminanzanalyse (engl. *Generalized Discriminant Functions*) vor. So führt eine Umformulierung der LDA zu einem linearen Regressionsmodell zur flexiblen Diskriminanzanalyse (engl. *Flexible Discriminant Analysis*, FDA). Mit dieser wird ein Klassifikationsproblem in einen höher dimensionalen Raum transformiert, in dem das Problem linear trennbar wird. Dazu wird der Merkmalsvektor um gewichtete Summen nichtlinearer Basisfunktionen (z. B. Quadratische Funktion, Polynome n-ter Ordnung, Gauß-Funktion, Sigmoid-Funktion etc.) erweitert und kann als nichtlineare Abbildung aus dem originären Merkmalsraum in einen Merkmalsraum höherer Dimension betrachtet werden. Mit der Mixture Discriminant Analysis (MDA) von Hastie und Tibshirani (1996) können hingegen einzelne Klassen durch mehrere Gaußsche Mischverteilungen modelliert werden. Eine weitere Verallgemeinerung ist die penalisierte Diskriminanzanalyse (engl.: *Penalized Discriminant Analysis*, pLDA), die sich insbesondere für Klassifikationsprobleme mit vielen redundanten Merkmalen eignet (Hastie et al., 1995).

3.4.2.2.2 Künstliche Neuronale Netze

Künstliche Neuronale Netzwerke (engl. *Artificial Neural Network*, ANN) sind flexible statistische Modelle aus dem Bereich der Künstlichen Intelligenz, die den Vorteil haben, dass keine Annahme über die Struktur des zu modellierenden Zusammenhangs benötigt wird. Eine gute Einführung zu den Verfahren der Neuronalen Netze geben Bishop (1995) und Ripley (1996).

Eine verbreitete Form eines ANN ist das mehrlagige Multi-Layer-Perzeptron (MLP). Ein MLP, nach seinem Lernverfahren auch Backpropagation-Netz genannt, besteht aus einer Eingangsschicht (*input layer*), einer Ausgangsschicht (*output layer*) und einer oder mehreren Zwischenschichten (*hidden layer*), die jeweils mit Neuronen besetzt sind (Abb. 3-8b). Die Neuronen benachbarter Schichten sind ausgehend von der Eingabeschicht bis zur Ausgabeschicht vorwärtsgerichtet miteinander verbunden (*feed-forward network*). Die Stärke der Verbindung zwischen den Neuronen wird über Gewichte geregelt, die über einen iterativen Lernprozess ermittelt werden. Die Gewichte bestimmen den Eingang der verborgenen Neuronen, während die Ausgabe der Neuronen mit einer Aktivierungsfunktion gesteuert wird. Im Gegensatz zum Single-Layer Perzeptron wird beim MLP eine nichtlineare Sigmoid-Funktion als Aktivierungsfunktion verwendet, die einen weichen und differenzierbaren Übergang erlaubt.

Als Lernverfahren wird der Backpropagation-Algorithmus eingesetzt, der eine natürliche Erweiterung des Least-Mean-Squares-Algorithmus (LMS-Algorithmus) darstellt und gradientenbasiert arbeitet. Nach Duda et al. (2000) kann mit einem Neuronalen Netz mit 3 Schichten jede mögliche Verteilung abgebildet werden, wenn genügend versteckte Neuronen und passende Gewichte gewählt werden. Der Schlüssel von Neuronalen Netzen liegt in der Implementierung sehr einfacher linearer Diskriminanten, die in der Lage sind, nichtlineare Phä-

nomene aus den Trainingsdaten zu erlernen. Neuronale Netze erfahren deshalb eine ausgesprochene Beliebtheit in der Praxis, da sie auf verschiedenste reale Klassifikationsprobleme anwendbar sind. Eine Herausforderung besteht jedoch in der Anpassung der Komplexität des Netzwerkes. Werden viele Neuronen und versteckte Schichten eingeführt, besitzt auch das Modell viele freie Parameter (Gewichte) und es besteht die Gefahr einer Überanpassung.

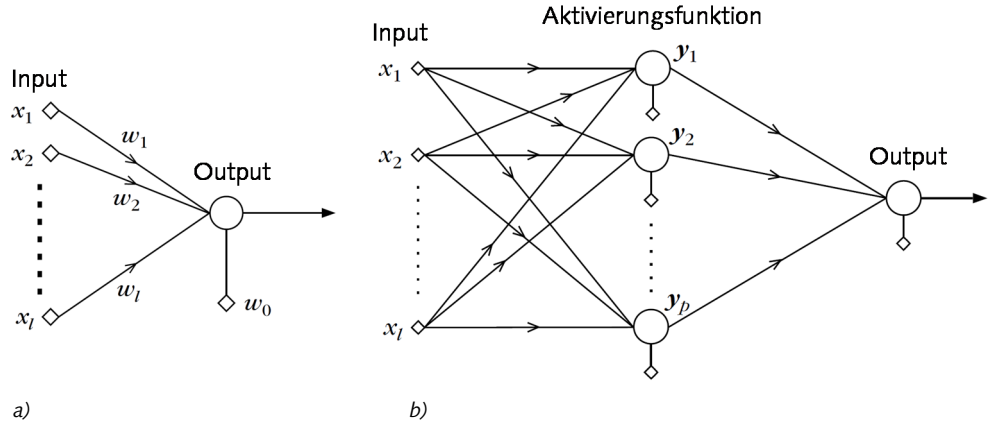

Abb. 3-8: Einlagiges Netz als einfaches lineares Regressionsmodell (links) und das Standardnetzwerk mit drei Schichten (Abgeänderte Graphik nach Theodoridis & Koutroumbas, 2008)

3.4.2.2.3 Kernel-Methoden

Kernel-Methoden sind flexible Modelle zur Konstruktion nichtlinearer Trennfunktionen. Zu den wichtigsten Verfahren zählen Netze radialer Basisfunktionen (engl. *radial basis function networks*, kurz RBF-Netze) und nichtlineare SVM. RBF-Netze sind Summen radial symmetrischer Funktionen, SVM definieren die Basisfunktionen implizit durch die Spezifizierung eines Kernels (Webb, 2002). Beide Ansätze haben die Gemeinsamkeit, dass Muster zur linearen Trennbarkeit in einen Raum höherer Dimension transformiert werden. Hierzu nutzt man das Theorem von Cover (1965), mit dem eine erhöhte Wahrscheinlichkeit der linearen Trennbarkeit gegeben ist, wenn eine Abbildung der Daten in einen höherdimensionalen Raum vorgenommen wird (Schölkopf et al., 2001).

Das RBF-Netz nach Poggio & Girosi (1990) besitzt die gleiche Netzwerkarchitektur, wie ein Multi-Layer-Perzeptron mit einer verborgenen Schicht. Im Gegensatz eines MLP sind die Aktivierungsfunktionen radialsymmetrische Basisfunktionen. Die Anzahl verborgener Neuronen mit entsprechenden Basisfunktionen entspricht der Anzahl der Trainingsdaten. Je mehr Trainingsdaten verwendet werden, desto komplexere Trennflächen können approximiert werden. Die Herausforderung beim Lernen eines RBF-Netzes besteht in der Bestimmung der optimalen Netzgröße und der Gewichte. Dafür wurden verschiedene Generalisierungsansätze entwickelt (Paetz, 2006), mit denen beispielsweise die Anzahl der Neuronen mithilfe eines Clusterverfahrens reduziert werden kann.

Ein weiterer Kernel-basierter Ansatz der Mustererkennung sind nichtlineare SVM (Bishop, 2007; Duda et al., 2000). Dabei handelt es sich um eine nichtlineare Erweiterung der linearen SVM mithilfe von Kernelfunktionen. Wesentliches Ziel ist es, die Merkmalsvektoren in einen höher dimensionierten Raum zu transformieren, in dem die Klassen linear trennbar werden. Die Rücktransformation in den originären Merkmalsraum ist sehr rechenintensiv und die transformierte Trennfläche sehr komplex. Man bedient sich darum einem Kernel-Trick, mit dem die Trennfläche über eine geeignete nichtlineare Kernel-Funktion rücktransformiert wird, ohne dass die Abbildung explizit berechnet werden muss. Die am häufigsten verwendeten Kernel sind lineare, Polynom-, Gaußsche (RBF-) oder Sigmoid-Funktionen.

3.4.2.2.4 Baumbasierte Verfahren

Baumbasierte Verfahren zur automatischen Konstruktion von Entscheidungsbäumen gibt es seit den 1960er Jahren und diese sind erst mit der erhöhten Leistungsfähigkeit von Computern ein in der angewandten Statistik anerkanntes und häufig genutztes Klassifikationsverfahren. Entscheidungsbäume setzen sich aus hierarchisch aneinandergereihten Regeln zusammen, die mithilfe eines Induktionsalgorithmus automatisch erlernt werden. Dabei wird der Merkmalsraum sukzessive partitioniert. Bei der Anwendung des erlernten Baumes erfolgt eine Klassifizierung der neuen Objekte durch den eindeutigen Pfad im Entscheidungsbaum. Vom Wurzelknoten ausgehend wird der komplette Baum über Kanten und Knoten bis zum Blatt durchlaufen und die Klasse bestimmt. Dabei wird der Merkmalsraum sukzessive partitioniert.

Für die Baumkonstruktion existieren verschiedene Algorithmen. Die am häufigsten angewandten Algorithmen sind jedoch der CART-Algorithmus (engl. *Classification and Regression Trees*) nach (Breiman et al., 1984), der CHAID-Algorithmus (engl. *Chi-square Automatic Interaction Detectors*) von Sonquist & Morgan (1964) oder der ID3-Algorithmus[30], der später zum C4.5 weiterentwickelt wurde (Quinlan, 1993). Um eine Konstruktion zu großer Bäume und damit eine Überanpassung zu vermeiden, kann der erlernte Entscheidungsbaum mittels eines *Pruning* generalisiert werden. Dabei werden die überspezialisierten Äste iterativ aus dem Baum entfernt.

Entscheidungsbäume sind aufgrund ihrer einfachen Struktur leicht zu interpretieren, da sie mit den hierarchischen Regeln dem menschlichen Modellierungsverständnis folgen. Sie dienen neben der automatischen Klassifizierung auch der Generierung expliziten Wissens. Darum spielen Entscheidungsbäume eine im Bereich des *Data Mining* und *Knowledge Discovery in Databases* (KDD) eine wesentliche Rolle.

3.4.2.2.5 Ensemble-Methoden

Grundsätzliche Idee der Ensemble-Methoden ist es, die Klassifikationsleistung durch Kombination mehrerer einfacher Klassifikatoren zu einem neuen Klassifikator zu erhöhen. Diese relativ neuen Verfahren, auch als kombinierte Klassifikationsverfahren (engl. *Multiple Clas-*

[30] ID3 (Iterative Dichotomiser 3) ist ein Entscheidungsbaumalgorithmus.

sifier Systems, MCS) bezeichnet, werden derzeit aktiv beforscht (Benediktsson & Kittler, 2010; Gayar et al., 2010; Kuncheva, 2004; Roli et al., 2004). Ein Vorteil ist die gute Parallelisierbarkeit, da die einzelnen Komponenten des Ensembles unabhängig voneinander prozessiert werden können. Man unterscheidet nach Kuncheva (2004) zwischen trainierbaren und nicht trainierbaren Ensemble-Verfahren.

Bei den *nicht trainierbaren Verfahren* wird ein Klassifikationsproblem in Teilprobleme zerlegt, die jeweils mithilfe einfacher Basisklassifikatoren (engl. *weak learner*) gelöst werden. Mithilfe einer geeigneten Aggregationsstrategie werden die Ergebnisse der einzelnen Basisklassifikatoren kombiniert und für ein Objekt die zugehörige Klasse bestimmt. Der Ansatz eignet sich insbesondere zur Erweiterung von Lernalgorithmen, die nur auf binäre Klassifikationsprobleme anwendbar sind. Somit kann eine SVM als binärer Klassifikator auch auf Mehrklassenprobleme angewendet werden. Für die Zerlegung des Mehrklassen-Problems in binäre Teilprobleme sind zwei Strategien möglich. Die *One-versus-one*- (OVO) und die *One-versus-all*- (OVA) Strategie (Galar et al., 2011). Unter der OVO-Strategie versteht man eine paarweise Zerlegung des Problems in $\frac{k(k-1)}{2}$ binäre Teilprobleme, die sich aus allen möglichen Klassenpaarkombinationen ergeben. Mit einer paarweisen Klassifizierung wird jede Klasse von jeder anderen Klasse separiert. Bei der OVA-Strategie werden k binäre Basisklassifikatoren trainiert, die jeweils eine Klasse vom gesamten Rest diskriminieren. Die Abb. 3-9 verdeutlicht die verschiedenen Strategien an einem Mehrklassenproblem.

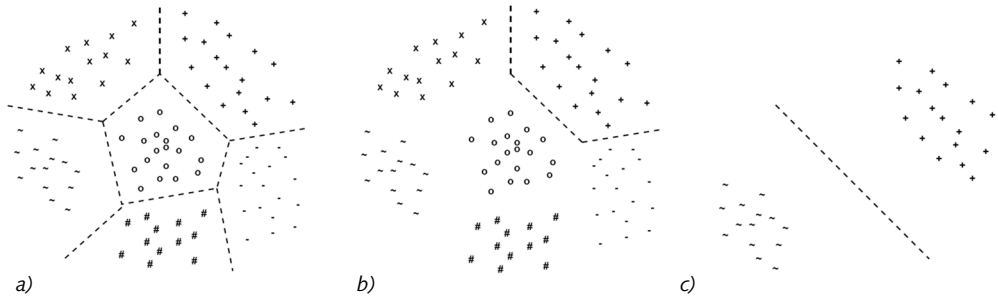

Abb. 3-9: Strategien zur Zerlegung des Mehrklassen-Problems (a) in binäre Teilprobleme nach OVO-Strategie (b) und der OVA-Strategie (c) (Quelle: Fürnkranz, 2001)

Eine Anwendung der OVO-Strategie ist im Lernvorgang schneller als die der OVA-Strategie, die für jeden Basisklassifikator stets alle Trainingsobjekte nutzt (Galar et al., 2011). Fürnkranz (2001) zeigt mit Versuchen anhand unterschiedlicher Datensätze, dass die OVO-Klassifikation nie schlechtere und meist sogar signifikant bessere Ergebnisse erzielt als eine OVA-Strategie. Die Aggregation der Ergebnisse der Basisklassifikatoren, also die schlussendliche Zuordnung eines Objektes zu einer Klasse, kann mit unterschiedlichen Ansätzen erfolgen (Galar et al., 2011; Kuncheva, 2004). Bei dichotomen Basisklassifikatoren erfolgt die Aggregation häufig über das Mehrheitsprinzip (engl. *majority vote*), bei Basisklassifikatoren mit kontinuierlichem Output mit der Softmax-Methode (Duda et al., 2000).

Die zweite Gruppe der Ensemble-Verfahren sind die *trainierbaren Verfahren*. Die Kombination mehrerer Basisklassifikatoren ergibt sich erst während des Trainings. Ein Vorteil ist, dass es die Varianz reduziert, d. h. die Ergebnisse sind weniger abhängig von den Eigenheiten einer einzigen Trainingsstichprobe. Zum anderen wird der Bias reduziert, in dem die Kombination mehrerer Klassifikatoren zum Erlernen zu einem aussagekräftigeren Modell führt. Das Ziel ist die Bildung eines Ensembles verschiedener Klassifikatoren anhand eines Trainingsdatensatzes. Kuncheva (2004) gibt einen Überblick über verschiedene trainierbare Ensemble-Methoden. Zu den wichtigsten zählen jedoch die in den letzen Jahren entwickelten Techniken des Bagging, Boosting, Random Forest und Stacking.

Das *Bagging*, ein Akronym für *Bootstrap Aggregating*, wurde erstmals von Breiman (1996a) eingeführt. Mit diesem Algorithmus wird ein Ensemble von Klassifikatoren, in diesem Fall Entscheidungsbäume, auf Grundlage von Bootstrap-Stichproben erlernt und das Ergebnis über einen Mehrheitsentscheid aggregiert. Diese Herangehensweise zeichnet sich gegenüber einem einzelnen konstruierten Baum, wie beim CART-Algorithmus, durch eine deutliche Verbesserung der Klassifikationsleistung aus.

Das *Boosting* geht auf (Valiant, 1984) zurück und ist ein Verfahren, mit dem mehrere *weak learner* zu einem einzigen starken Klassifikator (engl. *strong learner*) kombiniert werden. Die einzige Anforderung an den Basisklassifikator ist, dass dieser besser als der Zufall klassifizieren sollte. Oft ist dieser so einfach aufgebaut, dass er beispielsweise nur ein einziges Merkmal berücksichtigt. Mit einer schrittweisen Optimierung werden Gewichte für jeden Basisklassifikator so bestimmt, dass die guten Lerner mit kleinem Fehler mehr berücksichtigt werden als die schlechten mit großem Fehler. Das Ergebnis wird anschließend über eine gewichtete Mehrheitsentscheidung (engl. *weighted majority vote*) bestimmt, das die Werte von -1 bis 1 annimmt. Boosting wurde zunächst entwickelt, um Zweiklassenprobleme zu lösen. In späteren Varianten wurden mit dem AdaBoost.M1 (Freund & Schapire, 1996), AdaBoost.M2 (Freund & Schapire, 1997), arc-x4 (Breiman, 1998), MultiBoost (Webb, 2000) oder AveBoost (Oza, 2003) spezialisierte Implementierungen für Mehrklassenprobleme entwickelt.

Eine relativ junge trainierbare Ensemble-Methode ist der *Random Forest*-Algorithmus (Breiman, 2001), der darauf abzielt nicht nur einen, sondern eine Vielzahl von Klassifikationsbäumen zu erlernen. Random Forest basiert auf einem Bagging mit dem Unterschied, dass für jede Baumkonstruktion nur eine zufällige Menge an Merkmalen gewählt wird. Mit dieser Randomisierung zeigt der Algorithmus sehr gute Ergebnisse im Vergleich zu anderen modernen Klassifikationsverfahren. Breiman (2001) beweist in seiner Arbeit, dass bei einer ausreichend großen Anzahl erlernter Bäume das Gesetz der großen Zahlen gilt und mit steigender Baumanzahl ein Random Forest zu keiner Überanpassung neigt.

Ein weiterer Ansatz, der über das Erlernen schwacher Klassifikatoren hinausgeht, ist das *Stacking,* auch *stacked generalization* genannt, (Wolpert, 1992). Mit dem Stacking werden zunächst verschiedene Arten von Klassifikatoren erlernt, um Stärken zu vereinen und Schwächen zu kompensieren. Die Ergebnisse werden anschließend weiter als Trainingsdaten verwendet, um einen übergeordneten Meta-Klassifikator zu erlernen. Mit diesem werden dann Aussagen getroffen, welcher Klassifikator bei welchem Problem anzuwenden ist.

3.4.3 Fuzzy-Systeme

Fuzzy-Systeme werden eingesetzt, um nicht mathematisch beschreibbare unsichere Phänomene zu modellieren. Nach Duda et al. (2000) können diese nur begrenzt in der Mustererkennung eingesetzt werden, da sie von Trainingsdaten keinen Gebrauch machen und der Modellaufbau wissensbasiert über linguistische Terme und deren Zugehörigkeitsfunktionen erfolgt. An die Grenzen stößt man insbesondere dann, wenn komplexe Probleme im hochdimensionalen Raum modelliert werden sollen, da es schwierig ist, die vielen Eigenschaften zu modellieren. In der Praxis erzielt man mit Fuzzy-Systemen für einfache Probleme allerdings schnell gute Ergebnisse, die jedoch bestenfalls gleichwertig zur Maximum-Likehood-Methode sind. Kann mit einem Fuzzy-System ein Problem nicht ausreichend genau beschrieben werden, so wird häufig auf lernfähige Neuro-Fuzzy-Systeme mit ANN zurückgegriffen (Duda et al., 2000).

3.5 Bewertung von Klassifikatoren

Im Folgenden werden Methoden und Gütemaße für die Bewertung von Klassifikatoren vorgestellt. Dies betrifft einerseits Verfahren zur Messung der Generalisierungsfähigkeit während der Modellselektion, Strategien zur Aufteilung von Lerndaten als auch die Bewertung der thematischen Genauigkeit anhand der Konfusionsmatrix. Eine Ableitung dieser Maße setzt in jedem Fall das Vorhandensein bereits klassifizierter Datensätze voraus, die mit den Ergebnissen der automatischen Klassifizierung verglichen werden.

3.5.1 Fehlerrate und Genauigkeit

Wichtigstes Qualitätsmaß eines Klassifikators ist die Fehlerrate (Klassifikationsfehler, engl. *error rate*), die auf Grundlage der vorhergesagten und der tatsächlichen Klassenzugehörigkeit beobachtet wird. Die Fehlerrate ERR ergibt sich aus dem relativen Anteil fehlerhaft klassifizierter Objekte n_{false} im Verhältnis zur Anzahl aller Beobachtungen n_{all}:

$$ERR = \frac{n_{false}}{n_{all}} \tag{3.5}$$

Die Genauigkeit ACC (engl. *accuracy*) wird hingegen durch die richtig klassifizierten Objekte n_{true} bestimmt:

$$ACC = \frac{n_{true}}{n_{all}} = 1 - ERR \tag{3.6}$$

Die Fehlerrate und die Genauigkeit werden häufig in Prozent angegeben, in dem diese mit 100 multipliziert werden.

3.5.2 Bewertung der Generalisierungsfähigkeit

Ein erlernter Klassifikator sollte neben einer geringen Fehlerrate auch gute Generalisierungseigenschaften, d. h. Generalisierungsfähigheit, besitzen (Alpaydin, 2004). Eine gute Generalisierungsfähigheit zeichnet sich dadurch aus, das nicht nur die Trainingsdaten, sondern auch unbekannte Daten mit geringer Fehlerrate klassifiziert werden. Man muss bei der Fehlerrate

darum zwischen der Fehlerrate gemessen an den Trainingsdaten (Trainingsfehler) und gemessen an unabhängigen Testdaten (Testfehler, Generalisierungsfehler) unterscheiden, wobei letztere immer größer ist (Alpaydin, 2004).

Wie stark sich Trainings- und Testfehler unterscheiden, ist von der Modellkomplexität eines Klassifikators, d. h. der Anzahl der zu erlernenden Parameter beim Training, abhängig (Hastie et al., 2009). Bei einem parametrischen Klassifikator mit geringer Modellkomplexität müssen beispielsweise die Mittelwerte und die Varianzen der Verteilung, beim linearen Klassifikator hingegen die Parameter der optimalen Trennfunktion bestimmt werden. Beim Trainieren von Entscheidungsbäumen werden hingegen die gesamte Baumstruktur und die dazugehörigen Entscheidungsgrenzen eines Regelwerks und bei der *Support Vector Machine* indessen die Summe aller Stützvektoren erlernt. Letztgenannte besitzen daher eine höhere Modellkomplexität als die Erstgenannten.

Der Testfehler eines Klassifikators setzt sich aus einem nicht reduzierbaren Fehleranteil, einem systematischen Teil (Bias) und einem zufälligen Teil (Varianz) zusammen (Hastie et al., 2009). Der Bias ist eine „induktive Verzerrung", die mit den Modellannahmen des betrachteten Klassifikators einhergeht (Alpaydin, 2004). Bei Modellen mit geringer Komplexität (wenige Parameter, viele Annahmen) ist die Differenz des Trainingsfehlers im Vergleich zum Testfehler gering (Abb. 3-10). Damit besitzt das Modell eine hohe Generalisierungsfähigkeit (hoher Bias). Gleichzeitig ist der Testfehler durch eine geringere Varianz gekennzeichnet, was eine höhere Stabilität des Fehlers bei Änderung der Trainingsdaten bedeutet. Allerdings sind Trainings- und Testfehler eines Modells in gleichem Maße sehr hoch. Der gewählte Klassifikator ist wegen der Einfachheit offenbar nicht in der Lage, die Klassen gut im Merkmalsraum zu trennen. In diesem Fall spricht man von einer Unteranpassung (engl. *underfitting*) des Modells. Klassifikatoren mit einer hohen Modellkomplexität sind hingegen durch eine hohe Varianz (großer Unterschied bei Änderung der Trainingsdatenmenge) und einem niedrigen Bias gekennzeichnet. Ein derartiger Klassifikator ist zwar für die Trainingsdaten optimiert, bei Anwendung auf unbekannte Daten jedoch mit einer geringeren Vorhersageleistung gekennzeichnet. Man spricht in diesem Fall von einer Überanpassung (engl. *overfitting*) des Modells. Abb. 3-10 stellt den Zusammenhang zwischen dem Trainings- und Testfehler im Kontext der Modellkomplexität dar.

Bei der Wahl eines Klassifikators ist es nötig, einen möglichst guten Kompromiss[31] zwischen dem Bias und der Varianz bzw. der Über- und Unteranpassung herzustellen. Dies wird damit erreicht, in dem der Testfehler minimiert wird. Eine Bewertung der Generalisierungsfähigkeit eines Klassifikators sollte darum stets nur auf Grundlage unabhängiger, nicht beim Training verwendeter Testdaten erfolgen. Um auszuschließen, dass der gemessene Testfehler durch Ausreißer in den Trainingsdaten oder anderen zufälligen Faktoren des Lernalgorithmus beeinflusst wird, sollte dieser über eine wiederholte Messung aus zufälligen Stichproben (vgl. Kap.3.5.3) bestimmt werden (Alpaydin, 2004).

[31] In der Literatur spricht man auch von dem „bias-variance dilemma" (Duda et al., 2000).

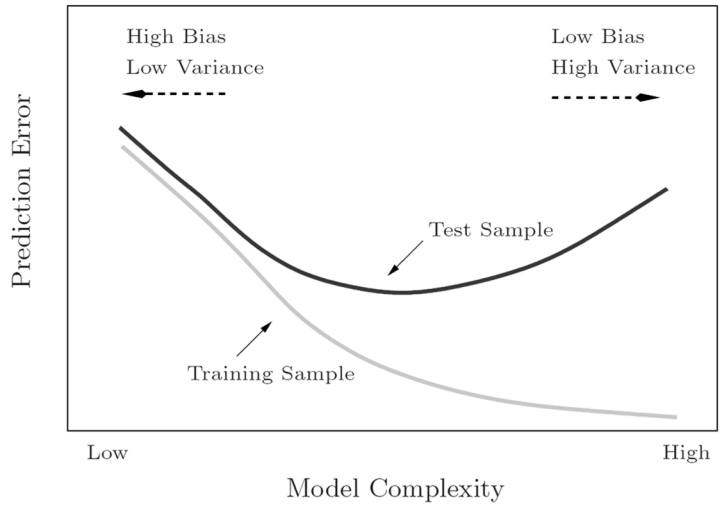

Abb. 3-10: Zusammenhang zwischen Vorhersagefehler und Modellkomplexität (Quelle: Hastie et al., 2009)

3.5.3 Strategien der Aufteilung der Lerndaten

Um den Generalisierungsfehler eines Klassifikators zu bestimmen, muss eine ausreichend große Lerndatenmenge zur Verfügung stehen. Für die Abschätzung des Generalisierungsfehlers werden in der Literatur verschiedene Ansätze zur Aufteilung der Daten vorgeschlagen, von denen an dieser Stelle nur die wichtigsten aufgeführt seien (Alpaydin, 2004; Duda et al., 2000; Hastie et al., 2009; Kohavi, 1995):

- Aufteilung in Trainings- und Testdaten (Hold-Out-Methode)
- Dreiteilung in Trainings-, Validierungs- und Testdaten
- Kreuzvalidierung
- Bootstrap-Methoden

Liegen viele Lerndaten mit bekannter Klassenzugehörigkeit vor, so ist es am einfachsten, den Datensatz mit der *Hold-Out-Methode* zufällig in Trainings- und Testdaten aufzuteilen. Auch wenn es keine allgemeingültige Regel zur relativen Aufteilung gibt, so ist ein Verhältnis von 2/3 Trainingsdaten und 1/3 Testdaten üblich (Kohavi, 1995). Mit Einführung einer stratifizierten Stichprobe kann sichergestellt werden, dass jede Klasse mit einer annähernd gleichen relativen Häufigkeit auftritt, wie in der Grundgesamtheit. Eine zuverlässigere Abschätzung des Generalisierungsfehlers kann erreicht werden, in dem die *Hold-Out-Methode* mehrfach angewendet (zufällige Stichprobe mit Zurücklegen) und der Mittelwert des Testfehlers jeder Iterationen gebildet wird.

Ist eine Modellselektion vorgesehen, so schlagen Hastie et al. (2009) eine Dreiteilung der Daten in 50 % Trainingsdaten, 25 % Validierungsdaten und 25 % Testdaten vor. Die Trainingsdaten- und Validierungsdaten werden verwendet, um verschiedene Klassifikatoren zu erlernen und deren Vorhersagefehler zu bestimmen. Mit der Modellselektion wird der Klassifikator mit dem geringsten Vorhersagefehler ausgewählt und am Ende der Generalisierungsfehler anhand der ungesichteten Testdaten abgeschätzt.

Oft reicht die Datenmenge mit bekannter Klassenzugehörigkeit nicht aus, um genügend große Teilmengen zu generieren. Es wurden darum verschiedene Techniken entwickelt, um den Generalisierungsfehler dennoch anhand einer kleinen Datenmenge verlässlich abschätzen zu können. Eine Möglichkeit besteht in einer p-fachen Kreuzvalidierung (engl. *Cross-Validation*), mit der die Menge der Lerndaten in p gleich große Partitionen zufällig aufgeteilt wird. Es werden dann jeweils $p - 1$ Teilmengen zum Training sowie die verbleibende Teilmenge zur Qualitätsbewertung des Klassifikators verwendet. Im Ergebnis erhält man den Generalisierungsfehler aus dem Mittelwert der aller p Klassifikationsfehler. Die Wahl von p hängt davon ab, wie aufwändig das Modelltraining ist. Die aus statistischer Sicht genaueste Abschätzung des Generalisierungsfehlers bei einer ausreichenden Datenmenge ist mit der *Leave-One-Out*-Kreuzvalidierung als Spezialfall gegeben, bei der die Anzahl der Partitionen p der Anzahl der Beobachtungen n entspricht. Dies führt allerdings zu einem enormen Rechenaufwand. In der wissenschaftlichen Praxis hat sich die 10-fache Kreuzvalidierung bewährt (Witten & Frank, 2005). Möchte man die Varianz des Generalisierungsfehlers weiter verringern, so bietet sich eine 10-mal wiederholte 10-fache Kreuzvalidierung an, die je nach Komplexität des Lernverfahrens und der Anzahl der betrachteten Klassifikatoren ebenfalls sehr rechenintensiv sein kann.

Weitere Verfahren zur Schätzung des Generalisierungsfehlers sehr kleiner gegebener Datenmengen sind sogenannte Bootstrap-Verfahren, die auf Efron (1979) zurückgehen, wie z. B. dem E0-Bootstrap oder der E632-Bootstrap (Jain et al., 1987). Im Gegensatz zur Kreuzvalidierung werden bei diesen Verfahren die Stichproben zurückgelegt, so dass Teile der Daten in mehrfachen Partitionen verwendet werden.

3.5.4 Bewertung der thematischen Genauigkeit

Eine Beurteilung eines Klassifikators allein auf Grundlage des Generalisierungsfehlers reicht beim Mehrklassenproblem nicht aus, da das Gesamtmaß keine Aussagen über die klassenspezifische Genauigkeit (thematische Genauigkeit) liefert. Im Kontext der Bildklassifikation und Fernerkundung haben sich verschiedene Methoden zur Bewertung von Klassifikationsverfahren etabliert. Einen guten Überblick verschaffen hierzu Congalton (1991), Congalton & Green (1998), Foody (2002) und Liu et al. (2007).

Die Konfusionsmatrix (engl. *confusion matrix*) von Congalton (1991) ist das wichtigste Konzept zur Beurteilung von Klassifikationsergebnissen (vgl. Foody, 2002). In der quadratischen Matrix werden die Häufigkeiten der Fälle aller Kombinationen von vorhergesagter Klasse (engl. *classified data*) und tatsächlicher Klasse (engl. *reference data*) eingetragen (Abb. 3-11).

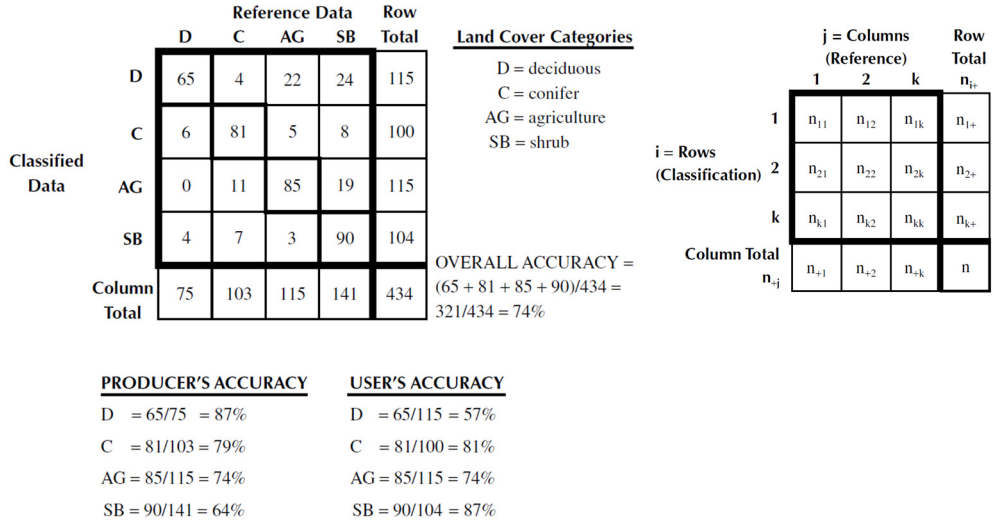

Abb. 3-11: Beispiel einer Konfusionsmatrix (links) und mathematischen Definition (rechts) (Quelle: Congalton & Green 1998)

Auf Grundlage dieser Matrix lassen sich dann verschiedene Gütemaße zur Gesamtgenauigkeit oder der individuellen Klassengenauigkeit ableiten, deren folgend dargestellte Formeln Congalton & Green (1998) entnommen sind.

Die Summe aller Objekte sei n, die Referenzklasse j und die mit einem Klassifikator vorhergesagte Klasse i. Die Anzahl der Objekte, für die mit dem Klassifikator die Klasse i vorhergesagt wurde, ist $n_{i+} = \sum_{j=1}^{k} n_{ij}$ und die Anzahl der Objekte, denen die Referenzklasse j zugeordnet ist, sei $n_{+j} = \sum_{i=1}^{k} n_{ij}$.

3.5.4.1 Overall Accuracy

Die Gesamtgenauigkeit (engl. *Overall Accuracy*, OA) liefert den Anteil der richtig klassifizierten Objekte.

$$OA = \frac{\sum_{i=1}^{k} n_{ii}}{n} \tag{3.7}$$

Die Gesamtgenauigkeit ist ein häufig angegebenes Maß zur Beurteilung einer Klassifikation. Sie liefert jedoch keine Informationen zur klassenspezifischen Genauigkeit. Häufig wird die Gesamtgenauigkeit durch Multiplikation mit 100 in Prozent angegeben. In der Fernerkundung sollte die Gesamtgenauigkeit mindestens 0,85 (entspricht 85 %) betragen (Anderson et al., 1976). Diese Grenze wird jedoch für einige Anwendungen als zu hoch, für andere als zu niedrig angesehen (Congalton & Green, 1998). Eine weitere Differenzierung nach Güteklassen geben Landis & Koch (1977).

3.5.4.2 Herstellergenauigkeit

Mit der Herstellergenauigkeit (engl. *Producer´s Accuracy*, PA) wird das Verhältnis der korrekt klassifizierten Objekte zur Gesamtanzahl der Referenzobjekte der jeweiligen Referenzklasse j angegeben. Die PA ergibt sich aus dem Wert der Hauptdiagonalen und der dazugehörigen Spaltensumme der Konfusionsmatrix.

$$PA = \frac{n_{jj}}{n_{+j}} \tag{3.8}$$

Die Herstellergenauigkeit ist ein wichtiges Maß zur Beurteilung der Vollständigkeit jeder Referenzklasse. Mit dem Maß wird der Unterlassungsfehler (engl. *omission error*) beschrieben, der sich aus $1 - PA$ ergibt. Die fälschlicherweise einer anderen Klasse zugeordneten Objekte, der Überlassungsfehler, findet in diesem Maß keine Berücksichtigung, weshalb die PA immer in Kombination mit der Nutzergenauigkeit betrachtet werden sollte.

3.5.4.3 Nutzergenauigkeit

Mit der Nutzergenauigkeit (engl. *User´s Accuracy*, UA) wird das Verhältnis der korrekt klassifizierten Objekte n_{ii} zur Gesamtzahl aller als Klasse i vorhergesagten Objekte beschrieben. Diese ergibt sich aus der dem Wert der Hauptdiagonalen und der dazugehörigen Zeilensumme.

$$UA = \frac{n_{ii}}{n_{i+}} \tag{3.9}$$

Mit der Nutzergenauigkeit wird insbesondere der Überlassungsfehler (engl. *commission error*) beschrieben. Dieser beschreibt den Anteil der fälschlich einer anderen Klasse zugewiesenen Objekte und entspricht $1 - UA$.

3.5.4.4 Kappa

Aus der Konfusionsmatrix kann eine weitere Maßzahl zur Beurteilung der Übereinstimmung der Klassifikation mit den Referenzdaten abgeleitet werden, Cohen´s Kappa, auch Kappa-Koeffizient oder KHAT-Statistik bezeichnet (Cohen, 1960). Vorteil dieses Maßes ist es, dass gegenüber der OA auch der Unter- sowie der Überlassungsfehler berücksichtigt werden kann, in dem die zufallskorrigierte Übereinstimmung gemessen wird (Congalton & Green, 1998). Das Maß ergibt sich aus der Differenz zwischen dem Anteil korrekt klassifizierter Objekte p_0 und der zufälligen Übereinstimmung (engl. *chance agreement*) p_c, die man bei vollkommener Unabhängigkeit erhält. Der Kappa-Koeffizient ist folgendermaßen definiert:

$$\kappa = \frac{p_0 - p_c}{1 - p_c} \tag{3.10}$$

Die Eins im Nenner stellt die maximal mögliche relative Häufigkeit der Übereinstimmung dar und dient der Normierung.

Die Anzahl korrekt klassifizierter Objekte p_0 wird aus der Hauptdiagonalen der Konfusionsmatrix berechnet:

$$p_0 = \frac{\sum_{i=1}^{k} n_{ii}}{n} \tag{3.11}$$

Die zufällige erwartete Übereinstimmung p_c ergibt sich aus der Zeilen- und Spaltensumme:

$$p_c = \frac{\sum_{i=1}^{k} n_{i+} n_{j+}}{n^2} \tag{3.12}$$

Der Wertebereich des Kappa-Koeffizienten liegt zwischen -1 und +1. Der Wert ist Null, wenn alle Zellen der Konfusionsmatrix den gleichen Wert besitzen (zufällige Klassifizierung) und ist Eins, wenn alle Objekte richtig klassifiziert sind (nur die Hauptdiagonale ist besetzt). Man spricht bei einem Wert größer als 0,80 von starker, zwischen 0,40 und 0,80 von mittlerer und bei einem Wert kleiner 0,40 von schlechter Übereinstimmung (Landis & Koch, 1977). Bei negativen Kappa-Werten ist die Klassifizierung schlechter als der Zufall. Die Varianz von Kappa kann mithilfe der Delta-Methode geschätzt werden (Congalton & Green, 1998).

Der Kappa-Koeffizient hat sich als Standardmaß zur Genauigkeitsbewertung in der Fernerkundung etabliert (Congalton, 1991; Congalton & Green, 1998; Foody, 2002; Liu et al., 2007) und ist in vielen Softwareprodukten zur Bildanalyse implementiert. Es existieren jedoch eine Reihe von Modifikationen und Erweiterungen, wie beispielsweise der gewichtete Kappa-Koeffizient (Cohen, 1968), der auch in der Fernerkundung Aufmerksamkeit erfährt (Næsset, 1996).

4 Forschungsstand

In diesem Kapitel werden die bisherigen Ansätze zur automatischen Klassifizierung von Siedlungsstrukturen vorgestellt. Nach einer Darstellung allgemeiner Aspekte, werden die wichtigsten Arbeiten zur Abgrenzung, Beschreibung und Klassifikation siedlungsraumbezogener Strukturen vorgestellt. Arbeiten, die das Ziel einer Klassifizierung individueller Gebäudegrundrisse haben, werden dabei gesondert dargestellt und hinsichtlich der Klassifikationsstrategie, der verwendeten Klassifikationsmethode, der verwendeten Datengrundlage und der thematischen Auflösung beschrieben. In einem Fazit werden die bisherigen Ansätze hinsichtlich einer Anwendung für eine siedlungsstrukturelle Analyse bewertet sowie aktuelle Defizite und offene Fragen aufgezeigt.

4.1 Allgemeine Aspekte

Zunächst werden allgemeine Aspekte einer automatischen Klassifizierung von Siedlungsstrukturen betrachtet und auf die Ziele, Datengrundlagen und Methoden sowie die unterschiedlichen Interpretationsebenen eingegangen.

4.1.1 Ziele einer automatischen Klassifizierung der Siedlungsstruktur

Die Motivation zur Entwicklung geeigneter Ansätze zur automatischen Klassifizierung der Siedlungsstruktur in räumlichen Daten ergibt sich aus verschiedenen wissenschaftlichen und praktischen Fragestellungen.

Klassifizierungsansätze dienen einerseits als methodischer Baustein zur Gewinnung von Datengrundlagen für die Anwendung in raumwissenschaftlichen Untersuchungen (u. a. quantitative Stadtgeographie, Stadtmorphologie, Funktionale Stadtgeographie, Stadt- und Raumplanung). Ziel ist es dabei, Informationen zur funktionalen, morphologischen und sozioökonomischen Siedlungsstruktur abzuleiten, zu analysieren und deren Zusammenhänge zu verstehen. Eine bedeutende Rolle spielen dabei Ansätze zur automatischen Klassifikation von Flächennutzungs-, Stadtstruktur- oder Biotoptypen (u. a. Barnsley & Barr, 1997; Bochow, 2010; Smith & Crooks, 2010). Die abgeleiteten Strukturtypen stellen eine wichtige Grundlage für weitere Modellierungen dar. Durch deren Visualisierung können wichtige räumliche Differenzierungsmuster einer Siedlung sichtbar gemacht werden. Oftmals besteht jedoch auch das Ziel, spezielle quantitative Maßzahlen (Indikatoren) zur Beschreibung der Siedlungsstruktur abzuleiten, um diese im Sinne eines Monitorings über die Zeit zu beobachten. Für die Modellierung von Indikatoren ist oftmals eine Klassifizierung von Objekten nötig. Aus einer Flächennutzungskarte können beispielsweise städtische Strukturmaße zur Flächenverteilung oder dem Vernetzungsgrad (einem Indikator zur Charakterisierung der Durchmischung von Nutzungen) abgeleitet werden (Thinh, 2004). Klassifizierte Gebäudegrundrisse erlauben hingegen die Berechnung kleinräumiger Indikatoren der Bebauungsstruktur (Meinel et al., 2009; Taubenböck et al., 2010), die Abschätzung von Wohnungs- und Einwohnerverteilungen (Meinel et al., 2008a; Aubrecht et al., 2009; Ural et al., 2011) sowie die Modellierung von Hauspreisen (Rengelink et al., 2000) oder des Energiebedarfs (Neidhart & Sester, 2004; Triantakonstantis & Barr, 2009).

Automatische Interpretationsansätze spielen auch eine wichtige Rolle in der Kartographie. Diese haben beispielsweise einen großen Nutzen bei der Aufbereitung objektstrukturierter digitaler Geoinformation aus gescannten analogen Karten und Plänen. Insbesondere während der Umbruchphase von der analogen Kartenherstellung zur computergestützten GIS-Kartographie wurde die Entwicklung von Verfahren der kartographischen Mustererkennung stark vorangetrieben (Ejiri et al., 1984; Kasturi & Alemany, 1988), um Kosten bei der Überführung der Kartenobjekte in ein GIS einzusparen (Stengele, 1995). Ein frühes Beispiel mit Siedlungsbezug ist der Ansatz von De Simone (1986). Auf Grundlage unstrukturierter Vektordaten, abgeleitet aus einem gescannten Plan, konnten die Objektklassen Eisenbahnen, Straßen und Flurstücke mit einer Erfolgsquote von 90 % automatisch identifiziert werden. Heute werden kartographische Mustererkennungsansätze wieder aufgegriffen, um urbane Veränderungsprozesse auf Grundlage von topographischen Karten hochauflösend zu modellieren (Hecht et al., 2008; Herold et al., 2011).

Neben der Datenerfassung aus analogen Karten spielen Mustererkennungsansätze eine weitere Rolle in der digitalen Kartographie. Ziel ist es dabei, kontextuelles Wissen abzuleiten, um dieses für die weitere Verarbeitung (z. B. Generalisierung, Visualisierung) zu nutzen. Eine automatisierte Erkennung und Charakterisierung bedeutsamer Muster können unter anderem Anwendung in der Steuerung rechnergestützter Generalisierungsprozesse finden (Brassel & Weibel, 1988; Neun et al., 2004). In diesem Zusammenhang spricht man auch von einer kontextabhängigen kartographischen Generalisierung (engl. *adaptive cartographic generalization*). Mithilfe erkannter Muster können Generalisierungsoperationen (Typisierung, Aggregation, Verdrängung, Vereinfachung, Formbetonung etc.) zielgerichtet auf bestimmte Objektklassen oder Objektgruppen angewandt werden. Die Muster können beispielsweise einzelne Gebäude, eine systematische Anordnung einer Gebäudegruppe (Gebäudemuster), ein Straßenmuster oder Siedlungstypen sein. Die rechnergestützte Generalisierung ist komplex. Der Fokus in der Forschung ist eher auf gut standardisierte topographische Kartenwerke ausgerichtet (Steiniger, 2007). Im Rahmen des europäischen Projekts AGENT zur automatischen kartographischen Generalisierung wurden eine Reihe von Verfahren zur Erkennung verschiedener Siedlungsmuster entwickelt und getestet (Gaffuri & Trévisan, 2004). Für die konsistente Haltung der Daten auf unterschiedlichen Maßstabsebenen wird aktuell an der automatischen Generalisierung in Multi-Repräsentationsdatenbanken und der Generalisierung über Web Services geforscht (Bobzien et al., 2006; Burghardt et al., 2010).

Räumliche Geodaten stehen heute in großer Vielzahl und hoher räumlicher Auflösung in Datenbanken oder im Internet zur Verfügung. Für den Kartennutzer ist das Erkennen impliziter Zusammenhänge mittels kognitiver Fähigkeiten ohne Probleme möglich. So ist ein geübter Betrachter einer topographischen Karte beispielsweise in der Lage, eine ruhige Wohnlage, einen schönen Wanderweg oder das Stadtzentrum durch Einbeziehen von Kontextinformationen zu ermitteln, obwohl diese Informationen nicht explizit in den Daten gegeben sind (Heinzle et al., 2003). Automatische Interpretationsansätze helfen dabei, genau diese Muster auf einer zumeist höheren Ebene zu erkennen und erfüllen eine wichtige Funktion bei der semantischen Anreicherung von Datenbanken. Ziel dabei ist es, implizit in den Daten enthaltene Information mit entsprechenden Interpretationsverfahren automatisch zu erkennen, um diese explizit für eine weitere Anwendung nutzbar zu machen. Durch Visualisierung

der Phänomene können dann neue Erkenntnisse über die Struktur und Zusammensetzung auf einer höheren räumlichen Ebene gewonnen werden. Als Beispiel seien an dieser Stelle Ansätze zur Erkennung von Wohnbauflächen (Anders, 2004), Großhandelsflächen (Mackaness & Chaudhry, 2011) oder Einkaufsstraßen (Chaudhry et al., 2010) in räumlichen Daten genannt. Das Internet stellt in diesem Zusammenhang eine weitere Quelle für raumbezogene semantische Informationen dar, auf deren Grundlage versucht wird, geographische Konzepte auf höherer Ebene abzuleiten, wie etwa das Stadtzentrum oder die Siedlungsgrenze (Heinzle & Sester, 2004; Heinzle et al., 2003).

4.1.2 Datengrundlagen und Methoden

Bei den Ansätzen zur automatischen Klassifizierung von Siedlungsstrukturen wird auf ein breites Methodenspektrum zurückgegriffen. Mit Blick auf die quantitative Stadtforschung spielen Technologien der urbanen Fernerkundung eine wesentliche Rolle. Aus den Bilddaten können mit Methoden der Bildanalyse, Segmentierung und der Objektklassifizierung Bodenbedeckungs-, Flächennutzungs- oder Bebauungsstrukturen automatisch abgeleitet werden. In der digitalen Kartographie stehen meist objektstrukturierte Vektordaten zur Verfügung, aus denen bedeutsame Muster identifiziert werden sollen. Für die automatische Interpretation und Ableitung von Wissen aus diesen Daten greift man dabei auf Methoden des Data Mining, des maschinellen Lernens und der algorithmischen Geometrie zurück (Anders & Sester, 1997).

In Zeiten eines rasant steigenden Angebots an Geodaten spielen integrative multisensorale Ansätze eine immer wichtigere Rolle (Aubrecht et al., 2009; Wurm et al., 2009). Es ist daher zu beobachten, dass sich die Ansätze der Fernerkundung und der digitalen Kartographie zunehmend ergänzen, da beide Disziplinen letztendlich das gleiche Ziel – eine automatische Interpretation räumlicher Daten – verfolgen. Im Folgenden werden sowohl die Bilddaten der Fernerkundung als auch objektstrukturierte Vektordaten vorgestellt, die bei der automatischen Klassifizierung der Siedlungsstruktur bisher eingesetzt wurden.

4.1.2.1 Bilddaten der Fernerkundung

Luftfahrzeug- oder satellitengestützte Bilddaten dienen seit Jahrzehnten als Grundlage der visuellen Interpretation für die Herstellung und Fortführung topographischer und thematischer Karten (Anderson et al., 1976). Automatisierte Ansätze zur Interpretation der Siedlungsstruktur werden jedoch erst seit jüngster Zeit erprobt, da dies die geometrische Auflösung anfangs nicht erlaubte. Die strukturbeschreibenden Objekte (Gebäude, Straßen etc.) müssen zunächst aus den Bildern extrahiert werden. Die automatische Gebäudeextraktion und -rekonstruktion ist eine komplexe Aufgabe und stellt seit Jahrzehnten ein zentrales Forschungsthema der Fernerkundung und Photogrammetrie dar (Kada, 2007; Gruen et al., 2009). Erst die aktiven Fernerkundungsverfahren, wie das flugzeuggetragene Laserscanning (engl. *Airborne Laserscanning*, ALS), erlauben heute eine automatisierte Ableitung der Gebäude mit hinreichender Genauigkeit.

Folgende Datengrundlagen der Fernerkundung und Photogrammetrie wurden bisher zur automatischen Interpretation der Siedlungsstruktur eingesetzt:

- analoge oder digitale Luftbilder
- sehr hochauflösende Satellitenbilder
- flugzeuggetragene Hyperspektraldaten
- Laserscannerdaten

Luftbilder wurden aufgrund ihrer sehr hohen Bildauflösung und der damit einhergehenden Komplexität der Szene nur selten allein eingesetzt. Wu et al. (2006) konnte mit einem texturbasierten Klassifizierungsansatz jedoch verschiedene Landnutzungstypen abgrenzen. Banzaf & Höfer (2008) ziehen für die Interpretation von Stadtstrukturtypen eine Baublockgeometrie hinzu. Auch die frühen analogen Spionageaufnahmen aus dem All, wie die amerikanischen Aufklärungsdaten von *CORONA* oder die russischen *KWR-* oder *KFA-*Aufnahmen mit Bodenauflösungen bis zu 2 Metern, eignen sich theoretisch für eine historische Betrachtung der Siedlungsstruktur bis in die späten 1960er Jahre (Schmitt et al., 1998). Automatische Interpretationsansätze wurden jedoch noch nicht erprobt.

Erdbeobachtungssatelliten, wie *IKONOS, SPOT-5*, *Quickbird, OrbView 3* und *RapidEye,* liefern sehr detaillierte Bildinformationen zur Bodenbedeckung. Aufgrund der großen Flächenabdeckung und der hohen spektralen Auflösung erfahren *IKONOS*-Daten eine besondere Beliebtheit bei der automatisierten Ableitung von Stadtstrukturtypen (u. a. Dogruso & Aksoy, 2007; Geiß et al., 2011; Wurm et al., 2009). Traditionelle, pixelbasierte Klassifikationsansätze sind wegen der hohen Bildauflösung und der damit einhergehenden spektralen Heterogenität der Objekte weniger geeignet (Wurm et al., 2010). Es werden daher bevorzugt Verfahren der objektbasierten Bildanalyse eingesetzt, mit denen das Bild in einem Segmentierungsschritt zunächst in homogene Regionen (Segmente) zerlegt und die Regionen anschließend auf Grundlage abgeleiteter Objektmerkmale (u. a. spektrale Eigenschaft, Form, Textur) klassifiziert werden. Erste Segmentierungsansätze sind in Haralick & Shapiro (1985) beschrieben. Seit Einführung kommerzieller Softwarepakete, die eine objektbasierte Bildanalyse unterstützen (z. B. mit *eCognition*), erfährt dieser Ansatz große Popularität in der Fernerkundung (Neubert, 2006). In diesem Zusammenhang hat sich auch eine eigenständige Disziplin *Geographic Object-Based Image Analysis* (GEOBIA) entwickelt (Hay & Castilla, 2008).

Neben den satellitengestützten Fernerkundungsdaten wird derzeit auch der Einsatz flugzeuggetragener abbildender Spektrometer, wie z. B. der HyMap-Sensor, in der urbanen Fernerkundung erprobt. In der Arbeit von Bochow (2010) konnte bereits großes Potenzial für die automatisierte Kartierung von Stadtbiotoptypen nachgewiesen werden. Hyperspektrale Daten haben gegenüber multispektralen Satellitenbildern den Vorteil, dass Oberflächenmaterialen städtischer Objekte zuverlässig und mit hoher geometrischer Genauigkeit bestimmt werden können (Heiden & Heldens, 2010).

Flugzeuggetragenes Laserscanning ist aktuell die beste Technologie zur automatisierten Gewinnung dreidimensionaler Information zur Erdoberfläche. Mithilfe des *Light Detection and Ranging* (LiDAR) werden Laserimpulse gesendet und die Laufzeit der von der Erdoberfläche rückgestreuten Signale registriert. Das Gelände und die darauf befindlichen Objekte können in einem normalisierten Oberflächenmodell (engl. *normalized Digital Surface Model, nDSM)* beschrieben werden. Aus dem nDSM extrahierte Gebäudegrundrisse und/oder daraus abgeleitete Höhen liefern in Kombination mit multispektralen Fernerkundungsdaten (Bochow, 2010; Geiß et al., 2011; Meng, 2010; Wurm et al., 2009) oder geotopographischen Vektordaten (Neidhart & Sester, 2004) eine vielversprechende Datenbasis für die automatische Klassifizierung von Gebäuden oder Stadtstrukturen.

4.1.2.2 Vektorbasierte Daten

Mustererkennungsansätze für die Generalisierung stützen sich vornehmlich auf topographische Vektordaten der Kataster- oder Landesvermessung. Mit zunehmender Verfügbarkeit von Gebäudedaten, werden diese in jüngster Zeit auch für die Beantwortung wissenschaftlicher und praktischer Fragestellungen in der Stadtforschung interessant.

Die Verteilung, Größe und Form von Gebäuden spielen eine zentrale Rolle bei der Interpretation der Siedlungsstruktur. In den meisten Ansätzen wurden die zweidimensionalen Gebäudegrundrisse aus topographischen Datenbanken der Katastervermessung entnommen (Lüscher et al., 2009; Neidhart & Sester, 2004; Steiniger et al., 2008). Werder et al. (2010) hingegen verwenden nutzergenerierte Gebäudedaten aus dem OpenStreetMap-Projekt. In aktuellen Arbeiten wurde des Weiteren der Einsatz von 3D-Gebäudemodellen im CityGML-Format erprobt (Henn et al., 2012).

Zur Beschreibung der Struktur werden häufig zusätzliche Hilfsdaten hinzugezogen (Baublöcke, Grundstücke, Straßennetz, Adressdaten, sozio-ökonomische Daten etc.). Baublöcke spielen bei der Erkennung von Stadtstrukturtypen eine besondere Rolle, da sie eine wichtige Bezugseinheit bei der Interpretation darstellen und auf deren Grundlage strukturbeschreibende Merkmale abgeleitet werden können (Meinel et al., 2009; Wurm et al., 2009; Thomson, 2009; Bochow et al., 2010). Weitere Hilfsdaten, die insbesondere der Erkennung von Gebäudetypen dienen, sind punktbezogene Adressdaten (Mesev, 2005, 2007; Rengelink et al., 2000; Smith & Crooks, 2010). In dem integrierten Ansatz von Aubrecht et al. (2009) werden zusätzlich kleinräumige sozio-ökonomische Daten zur Bevölkerung (125 m x 125 m Statistikraster) sowie privatwirtschaftliche Firmendaten zur Wirtschaftsstruktur (Aubrecht et al., 2009) hinzugezogen, um die Gebäudenutzung genauer abzubilden. Henn et al. (2012) nutzen hingegen semantische Information zur Infrastruktur aus den nutzergenerierten OSM-Daten.

4.1.3 Interpretationsebenen

Muster der Siedlungsstruktur können auf verschiedenen räumlichen Ebenen identifiziert werden (vgl. 2.1.3). Die Interpretationsebene hängt von der Zielstellung, häufig aber auch von der räumlichen Auflösung bzw. dem Maßstab der zur Verfügung stehenden Daten ab.

Man muss bei der automatischen Interpretation zunächst zwischen folgenden Formen unterscheiden:

- Klassifizierung auf Objektebene
- Erkennung und Abgrenzung von Mustern

Bei der *Klassifizierung auf Objektebene* ist der räumliche Bezug vorab festgelegt. Bei der Klassifizierung werden die Objekte als Ganzes betrachtet und anhand abgeleiteter Merkmale einer Klasse zugewiesen. Die Objekte sind beispielsweise Gebäudeteile, Gebäude, Baublöcke oder sonstige Bezüge (Quartiere, Region, Rasterzelle etc.). In vielen Ansätzen zur Klassifizierung städtebaulicher Strukturtypen wurde eine Baublockgeometrie als Interpretationsebene hinzugezogen (Bauer & Steinnocher, 2001, Banzhaf & Höfer, 2008; Bochow, 2010; Meinel et al., 2009; Wurm et al., 2009; Vanderhaegen & Canters, 2010).

Einer objektbasierten Klassifizierung stehen Ansätze zur *Erkennung und Abgrenzung von Mustern* entgegen, für die vorab kein fester Objektbezug gegeben ist. Dieser ergibt sich erst während der Interpretation. Walter und Luo (2011) sprechen in diesem Zusammenhang von komplexen Kartenobjekten und Regionen. Komplexe Kartenobjekte sind beispielsweise zu identifizierende Gebäudemuster, die sich aus einer Gruppe von Gebäuden ergeben. Bei einer Abgrenzung bzw. Zonierung der Siedlungsstruktur sind die zu extrahierenden Regionen durch eine spezifische Dichte oder Anordnung der Gebäude gekennzeichnet (Barnsley & Barr, 1996; Colaninno et al., 2011). Ansätze zur Erkennung und Abgrenzung von Mustern haben den Vorteil, dass keine zusätzliche Geometrie erforderlich ist.

4.2 Klassifizierung siedlungsraumbezogener Strukturen

In den letzten Jahren entstanden einige Arbeiten zur automatischen Klassifikation städtischer Nutzungsstrukturen bzw. städtebaulicher Strukturtypen. Erste Ansätze stützen sich auf Fernerkundungsdaten, wobei gerade in den letzten Jahren auch topographische Raster- oder Vektordaten Anwendung finden.

4.2.1 Abgrenzung und Typisierung von Siedlungsstrukturen

Erste Ansätze zur regionalen Abgrenzung und Typisierung verschiedener Landnutzungsklassen aus Fernerkundungsdaten waren sogenannte kernelbasierte Verfahren (u. a. Wharton, 1982; Gong & Howarth, 1992; Barnsley & Barr, 1996). Auf Grundlage eines nach der Bodenbedeckung vorklassifizierten Fernerkundungsbildes konnte für jedes Pixel der Kontext in einer definierten Nachbarschaft analysiert und darauf aufbauend Regionen unterschiedlicher Landnutzung abgeleitet werden. Wu et al. (2006) wendet hingegen eine Variogrammbasierte Texturanalyse an, um Landnutzungsklassen auf Grundlage digitaler CIR-Luftbilder abzugrenzen. An einem Testbild konnte eine Klassifikationsgenauigkeit von 76 % für 8 städtische Landnutzungsklassen erreicht werden.

In der Arbeit von Dogruso und Aksoy (2007) stand die Abgrenzung von Regionen mit organisierter und unorganisierter Bebauungsstruktur im Vordergrund. Auf Grundlage einer IKONOS-Szene wurden Gebäudegrundrisse extrahiert und mittels derer Centroide ein Voronoi-Diagramm abgeleitet. Durch Auswertung der Nachbarschaftsdistanzen im Voronoi-

Diagramm wurde ein minimaler Spannbaum (engl. *Minimum spanning tree*, MST) erzeugt. Durch Beschneidung des MST konnten anschließend räumliche Cluster gebildet und diese in einem weiteren Schritt über die Auswertung der Winkelstatistik klassifiziert werden.

In der Arbeit von Colaninno et al. (2011) dienen lediglich vektorbasierte Gebäudegrundrisse der Stadt Barcelona als Datengrundlage. Durch Ableitung morphologischer Merkmale und Relationen konnte eine innerstädtische Zonierung der Stadt in 7 Strukturtypen realisiert werden.

4.2.2 Beschreibung städtischer Strukturen

Mit dem von M. J. Barnsley und S. L. Barr entwickelten System *Structural Analysis and Mapping System* (SAMS) wurde ein graphenbasierter Ansatz zur Beschreibung der Landnutzungsstruktur entwickelt (Barnsley & Barr, 1997; Barr & Barnsley, 1997). Das System geht von diskreten Regionen verschiedener Bodenbedeckungstypen (Asphalt, Baum, Gras etc.) aus, die mittels Segmentierung aus Fernerkundungsdaten gewonnen werden. Die Regionen werden mithilfe morphologischer Eigenschaften (z. B. Fläche, Kompaktheit) und deren räumlichen Beziehungen (z. B. Adjazenz, Enthaltensein) strukturell beschrieben und in Form einer Graphen-Repräsentation XRAG (eXtended Relational Attribute Graph) gespeichert. Im Graphen werden die Regionen über Knoten repräsentiert, an denen die morphologischen Eigenschaften hängen. Es stellte sich heraus, dass es auf Grundlage weniger morphologischer Eigenschaften und Nachbarschaftsbeziehungen im Graphen möglich ist, verschiedene städtische Landnutzungskategorien zu unterscheiden (Barr et al., 2004). Diese und weitere Studien (u. a. Herold et al., 2003; Mesev, 2005) liefern einen wichtigen Beitrag zur empirischen Stützung der These des Zusammenhangs zwischen der städtischen Form und der Funktion (vgl. Batty & Longley, 1994).

Da siedlungsraumbezogene Forschung Analysen auf unterschiedlichen räumlichen Ebenen (Gebäude, Baublock, Stadt) verlangt, so spielen in diesem Zusammenhang Aggregationstechniken und eine konsistente multiskalige Datenhaltung sowie Visualisierungen eine wichtige Rolle. In den Arbeiten von Thomson (2009) und Smith & Crooks (2010) werden darum modellbasierte maßstabsübergreifende hierarchische Modellierungskonzepte der Siedlungsstruktur thematisiert.

4.2.3 Klassifizierung städtischer Strukturen auf Baublockebene

Städtische Strukturen können unter Zuhilfenahme einer Geometrie auf Baublockebene klassifiziert werden. Bauer und Steinnocher (2001) nutzen das von Barnsley & Barr (1997) entwickelte System SAMS, um städtische Strukturtypen auf Grundlage von aus IKONOS-Bilddaten abgeleiteten Regionen zu untersuchen. Die gewonnenen Erkenntnisse dienen dem Aufbau eines wissensbasierten Fuzzy-Logic-Regelwerkes in *eCognition*, um die städtischen Strukturtypen auf Baublockebene automatisch zu klassifizieren. Auch in der Arbeit von Wurm et al. (2009) kommen IKONOS-Daten zum Einsatz. Diese werden jedoch mit einem Digitalen Oberflächenmodell und den Baublöcken aus dem ATKIS® Basis-DLM kombiniert. Durch Anwendung eines hierarchischen objektbasierten Regelwerkes konnte jedem Baublock einer von 20 verschiedenen Stadtstrukturtypen zugewiesen werden.

Vanderhaegen und Canters (2010) nutzen hochauflösende IKONOS-Daten und kombinieren diese mit Gebäudegrundrissen aus einer geotopographischen Datenbank. Der Ansatz basiert auf einer Berechnung statistischer Merkmale auf Baublockebene und einer Klassifizierung mittels einer schrittweisen Diskriminanzanalyse. Für die 10 verschiedenen Klassen geben die Autoren eine Genauigkeit von 87,3 % an.

In der Arbeit von Banzhaf und Hofer (2008) ist die Klassifikation von Stadtstrukturtypen auf Grundlage von CIR-Luftbildern und dem ATKIS® Basis-DLM beschrieben. Anhand zweier Testgebiete in Leipzig konnten sie mit ihrem Ansatz eine Genauigkeit von 73,2 % bzw. 93,4 % erreichen.

Der Ansatz von Meinel et al. (2008a, 2009) basiert auf Grundlage von Gebäuden, die aus topographischen Karten extrahiert wurden. Durch Bildanalyse werden objektbeschreibende morphologische Merkmale abgeleitet und die Gebäude mit einem wissensbasierten Regelwerk klassifiziert. Anschließend erfolgt eine Aggregation der Information auf Baublockebene unter Zuhilfenahme der bebauten Flächen aus dem ATKIS® Basis-DLM. Für die 9 Bebauungsstrukturtypen geben die Autoren eine Klassifikationsgenauigkeit von 76 % an.

In der Dissertation von Bochow (2010) wird die automatische Ableitung einer Stadtbiotoptypenkartierung auf Grundlage hyperspektraler Daten und einem DOM untersucht. Dabei wurde ein wissensbasiertes Fuzzy-Logik-Modell (top-down) mit einem Paarweise-Maximum-Likelihood-Klassifikator (bottom-up) verglichen. Mit dem Maximum-Likelihood-Klassifikator wurde für Berlin eine thematische Genauigkeit von 81,3 % (10 Klassen) und für Dresden 84,3 % (6 Klassen) erreicht.

4.2.4 Erkennung von Gebäudemustern für die Generalisierung

Kontextuelles Wissen zur Siedlungsstruktur kann rechnergestützte kartographische Generalisierungsprozesse unterstützen. Eine wichtige Rolle spielen dabei Gebäudemuster, deren Struktur und Form beim Maßstabsübergang beispielsweise möglichst gut erhalten bleiben soll.

Der Mensch besitzt die Fähigkeit des perzeptuellen Gruppierens, in dem er ohne Vorwissen Gebäude zu Gebäudegruppen zusammenfasst, die auf höherer Ebene eine systematische Struktur (Muster) bilden. Für die Erkennung dieser Muster können Objekteigenschaften und Beziehungen abgeleitet werden, die den wahrnehmungstheoretischen Gestaltprinzipien der Organisation (z. B. Gesetz der Nähe oder Ähnlichkeit) entsprechen (Steiniger et al., 2008). Da es sich bei den kartographisch bedeutsamen Mustern um komplexe Muster handelt, erfolgt die Beschreibung oftmals über einen Nachbarschaftsgraphen mit einem anschließenden räumlichen Clustering, z. B. mit dem Ansatz von Zahn (1971).

Mit der Erkennung homogener Gebäudegruppen über einen graphenbasierten Ansatz haben sich die Autoren Anders et al. (1999) sowie Regnauld (2001) beschäftigt. Ein weiteres hierarchisches Graph-Clustering-Verfahren zur Interpretation raumbezogener Daten wird in Anders (2003, 2004) vorgestellt. Christophe & Ruas (2002), Ruas & Holzapfel (2003) sowie Burghardt & Steiniger (2005) setzen den Fokus auf die Identifikation homogener Gebäudegruppen in linearer Anordnung. Ein weiterer Ansatz zur Erkennung von Strukturen in Gebäuden auf Grundlage einer Analyse eines abgeleiteten Voronoi-Diagramms ist in Basaraner und Selcuk (2008) beschrieben.

Ein Ansatz zur Identifizierung regelmäßiger Grid-Strukturen in Gebäudedaten ist in Anders (2006) beschrieben. Dieser basiert auf der Auswertung der Anordnung der Gebäudemittelpunkte mittels Nachbarschaftsgraphen. Der Autor liefert ebenfalls eine Typologie von Gebäudemustern, in dem er lineare, kreisförmige, gitterförmige, sternförmige und unregelmäßige Muster unterscheidet. In einer aktuellen Arbeit von Zhang et al. (2010) wurde eine erweiterte Typologie für die Generalisierung ausgearbeitet mit der fünf Gebäudemuster (*collinear*, *curvilinear*, *align-along-road pattern*, *grid-like* und *unstructured*) unterschieden werden. Die Autoren stellen in diesem Zusammenhang Methoden zur Identifizierung der Gebäudemuster *align-along-road* und *unstructured* genauer vor, die an niederländischen digitalen topographischen Daten getestet wurden.

Es gibt eine Vielzahl an Arbeiten, die auf die Erkennung von Mustern anderer Objektklassen abzielen. An dieser Stelle sei beispielhaft die Mustererkennung in Straßennetzwerken (Anders, 2007; Heinzle et al., 2007) sowie zur Identifizierung des freien Kartenraums für die Platzierung von Kartenzeichen (Boffet & Serra, 2001) genannt.

4.3 Klassifizierung individueller Gebäude

Eine Abbildung der Siedlungsstruktur auf Gebäudeebene ermöglicht eine besonders kleinräumige Modellierung der Siedlung. Bisherige Klassifizierungsansätze auf Basis individueller Gebäudegrundrisse werden erst seit dem Verfügbarwerden digital modellierter topographischer Gebäudegrundrisse (z. B. in Katasterdaten, OSM etc.) bzw. der Technologie des Laserscannings verfolgt. Im Folgenden werden Forschungsarbeiten vorgestellt, die auf eine automatische Klassifizierung von Gebäudegrundrissen abzielen.

4.3.1 Bisherige Ansätze nach Klassifikationsstrategie

Im Überblick (Abb. 4-1) sind die wichtigsten Ansätze einschließlich der eingesetzten Klassifikationsverfahren, der Datengrundlagen, der Klassenanzahl und der erreichten Klassifikationsgenauigkeit zusammengetragen.

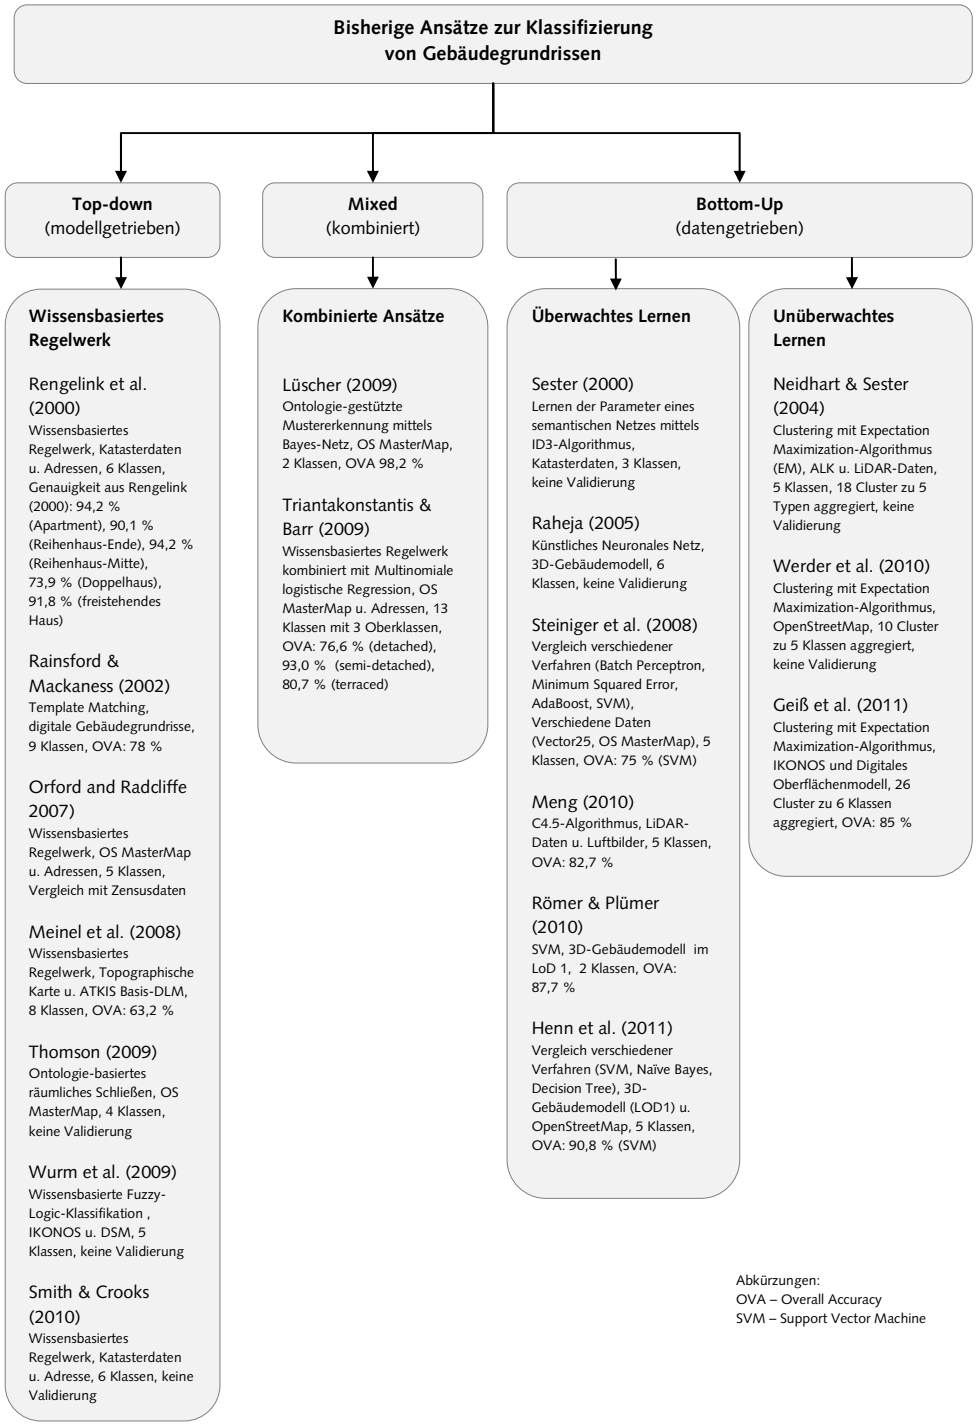

Abb. 4-1: Überblick über die Ansätze zur Klassifizierung individueller Gebäudegrundrisse

Grundlegend und analog zur Bildanalyse kann zwischen zwei Strategien für die Erkennung unterschieden werden. Zum einen die expliziten, wissensbasierten (auch modellgetriebenen) Verfahren mit einer *Top-down-Strategie* und zum anderen die impliziten, datengetriebenen Verfahren mit einer *Bottom-up-Strategie*. Zwischen den beiden Ansätzen lassen sich Verfahren verorten, die eine gemischte bzw. *kombinierte Strategie* verfolgen.

Bei den *wissensbasierten Klassifikationsverfahren* wird das Wissen vorab in einem Modellbildungsprozess vom Menschen explizit bereitgestellt. Diese Herangehensweise eignet sich besonders gut, wenn das Wissen über die Objekte eindeutig beschrieben und in eine vom Computer lesbare Form gebracht werden kann. Bei den *datengetriebenen Verfahren* erfolgt der wesentliche Teil der Modellbildung erst während eines Trainings durch Einsatz von Verfahren der Mustererkennung und maschineller Lernverfahren. Das bedeutet aber nicht, dass gar kein Vorwissen benötigt wird, denn die zu berücksichtigenden Merkmale oder die Form der Wissensrepräsentation (Entscheidungsbaum, Diskriminanzfunktion etc.) sind entscheidende Festlegungen, die vorab vom Menschen getroffen werden müssen. Je nach Lernstrategie wird im Weiteren zwischen den *überwachten* und *unüberwachten Klassifikationsverfahren* unterschieden.

4.3.2 Wissensbasierte Ansätze

Wissensbasierte Ansätze der Gebäudeklassifizierung sind in der Regel auf wenige Gebäudetypen spezialisiert. Die Modellbildung erfolgt direkt, in dem strukturiertes formalisiertes Wissen durch einen Bearbeiter explizit bereitgestellt wird. In den hier betrachteten Arbeiten wird das Wissen über ein Regelwerk (z. B. in Form eines Entscheidungsbaumes oder -netzes) repräsentiert und ist für den Fachmann und den Computer verständlich. Das Regelwerk ist häufig hierarchisch aufgebaut und wird entweder in einem konzeptionellen Prozess vorher festgelegt oder in einem „trial-and-error"-Prozess aufgebaut.

Die einfachste Form einer Klassifizierung ist die räumlich-attributive Abfrage mittels einer vom Menschen erstellten Regelbasis. Rengelink et al. (2000) klassifizieren Gebäude aus dem niederländischen Kataster unter Nutzung der Adresskoordinaten und der Flurstücke in die 6 Klassen *middle house in a row*, *end house in a row*, *free-standing house*, *two-under-a-roof*, *apartment* und *special*. Auch in der Arbeit von Orford & Radcliffe (2007) werden Gebäudegrundrisse (OS MasterMap®) von Cardiff (UK) mit Adressen verschnitten und jeweils einer von 5 Klassen (*detached*, *semi-detached*, *terrace*, *flat*, *unclassified*) zugeordnet. Ein ähnlicher Ansatz, ebenfalls unter Nutzung der OS MasterMap®, ist in Smith & Crooks (2010) beschrieben. Mithilfe eines wissensbasierten Modells konnten 6 verschiedene Wohngebäudetypen (*detached*, *semi-detached*, *terraced*, *maisonette*, *flats indiv*, *flats contig*) identifiziert werden. Das entwickelte Modell wurde anschließend für den Großraum London angewendet.

In der Arbeit von Rainsford und Mackaness (2002) wird die Regelbasis um einen Matching-Algorithmus erweitert. Eine Gebäudeklassifizierung soll den Generalisierungsprozess unterstützen, in dem Gebäude ländlicher Siedlungen im Folgemaßstab durch eine von 9 verschiedenen Grundformen repräsentiert werden sollen. Die Grundform orientiert sich an der Form der lateinischen Schriftzeichen I, F, P, G, E, L, U, O und T. Für die Erkennung der Formtypen

werden die Gebäudeumrisse zunächst formvereinfacht und anschließend über eine Regelbasis vorklassifiziert. Die Beschreibung des zu erkennenden Formtyps erfolgt über Strings, in denen die Sequenz der Richtungswechsel der Gebäudeumrisse abgespeichert ist. Nach einem Vergleich mit Prototypen, kann bei gleicher Sequenz der entsprechende Formtyp zugewiesen werden, wobei nicht eindeutig zuzuordnende Fälle unklassifiziert bleiben. Eine Ergebnisbewertung fiel den Autoren in diesem Fall schwer, da die Erstellung einer Referenz sehr subjektiv und nicht eindeutig möglich ist.

In dem von Meinel et al. (2008a) entwickelten Programmsystem SEMENTA® werden Gebäudegrundrisse aus topographischen Karten extrahiert und die vektorisierten Gebäudegrundrisse über eine Vielzahl von Merkmalen charakterisiert. Mit einem wissensbasierten hierarchischen Regelwerk werden die Gebäude nach 8 städtebaulichen Typen[32] klassifiziert. Die Autoren geben eine Genauigkeit von 63,2 % für Dresden bzw. 63,5 % für Bonn an.

Für die Klassifizierung von Gebäuden in Fernerkundungsdaten nutzen Wurm et al. (2009) ein Fuzzy-Logic-basiertes Regelwerk. Datengrundlage sind sehr hochaufgelöste Satellitenbilder und ein Oberflächenmodell. Eine Genauigkeitsbetrachtung wurde nur auf Baublockebene gemacht, in dem 100 Blöcke zufällig ausgewählt und das Ergebnis visuell bewertet wurde.

In jüngeren Arbeiten werden Ontologien eingesetzt, um die Erkennung geographischer Objekte in räumlichen Datenbanken zu unterstützen und diese für verschiedene Anwendungsbereiche zugängig zu machen. Ontologien sind in der Künstlichen Intelligenz als explizite Spezifizierung einer Konzeptualisierung[33] bekannt (Gruber, 1993) und werden über eine formale Beschreibungssprache realisiert. Durch Formalisierung aller für die Erkennung nötigen Begriffe, Eigenschaften und Beziehungen der realen Welt wird eine Wissensrepräsentation geschaffen, die der Mensch und der Computer verstehen. In dem wissensbasierten Ansatz von (Thomson, 2009) erfolgt die Erkennung verschiedener Gebäudetypen über die vom *World Wide Web Consortium* (W3C) spezifizierten Beschreibungssprache OWL-DL (*Web Ontology Language – Description Logic*). Auf Grundlage einfacher Regeln konnten die Gebäude durch Auswertung der topologischen Beziehung zu benachbarten Gebäuden in eine der vier Wohngebäudeklassen (*detached*, *endterraced*, *midterraced*, *semidetached*) klassifiziert werden. Thomson merkt an, dass derartig formale, deduktive Herangehensweisen nur begrenzt auf komplexe geographische Phänomene anwendbar sind, da es zurzeit nicht möglich ist, Geoobjekte und räumliche Beziehungen direkt in einer formalen Beschreibungslogik, wie OWL-DL, abzubilden[34] (Thomson, 2009). Dies macht es derzeit nötig, räumliche Datenanalysen in externe Anwendungen auszulagern.

---

[32] Mehrfamilienhaus (MFH) in geschlossener Bauweise, MFH in offener Bauweise, MFH in traditioneller Zeilenbebauung, MFH in Plattenbauweise, Hochhaus, Ein- und Zweifamilienhaus, Reihenhaus, Nichtwohnnutzung

[33] „An ontology is an explicit specification of a conceptualization" (Gruber, 1993: S. 1). Der Begriff der Ontologie geht ursprünglich auf Aristoteles zurück und hat in der Informatik eine lange Tradition. Derzeit blühen Ontologien mit dem Semantic Web und insbesondere den Linked Open Data enorm auf, da mit ihnen Daten standardisiert beschrieben werden können (Pellegrini & Blumauer, 2006).

[34] Thomson stellt in ihrer Dissertation fest: "Unfortunately, a logic-based approach is inherently limited because of its purely deductive nature". Sie erwähnt auch die technisch begründeten Limitationen formaler Beschreibungslogiken: "[…] it seems that currently it is not possible to achieve a complete high-level interpretation within a formal DL system" (Thomson, 2009: S. 250,252).

Lüscher et al. (2008b) beschreiben ebenfalls einen Ontologie-basierten Ansatz zur Identifikation von Reihenhäusern in OS-MasterMap®-Daten, in dem die Übereinstimmung von Eigenschaften und Beziehungen mit einem Prototypen verglichen werden. Sie erweitern ihren Ansatz später zu einem kombinierten Verfahren, in dem sie die Ontologie in ein Bayes-Netz überführen, auf dessen Grundlage die Schwellwerte erlernt werden können (Lüscher et al., 2009).

4.3.3 Datengetriebene Ansätze

Bei den datengetriebenen Ansätzen werden Verfahren der Musterkennung und des maschinellen Lernens eingesetzt, um eine Zuordnungsvorschrift automatisch anhand von Trainingsdaten zu erlernen. Die Bestimmung der für das Klassifikationsproblem gesuchten Modellparameter oder Entscheidungsgrenzen kann entweder mit einem überwachten oder unüberwachten Lernverfahren erfolgen. Dies führt zu einer weiteren Unterteilung in überwachte und unüberwachte Klassifikationsverfahren.

4.3.3.1 Überwachte Klassifikationsverfahren

Bei den überwachten Verfahren werden die Parameter oder Entscheidungsgrenzen eines gewählten Klassifikationsverfahrens auf Grundlage einer gelabelten Trainingsmenge (klassifizierte Gebäude) automatisch erlernt.

In der Dissertation von Raheja (2005) wird ein Verfahren zur Klassifizierung von 3D-Gebäudemodellen vorgestellt. Das Training erfolgt mithilfe eines künstlichen neuronalen Netzes. Ziel war die Erkennung 6 verschiedener Typen (*gable*, *hip*, *prism*, *flat*, *lean-to-wall* und *hexagon*), wobei insbesondere Formmerkmale in die Klassifikation eingingen. Der Ansatz wurde anhand von 500 Gebäuden getestet und funktionierte laut Autor von „very good“ bis „excellent“ (Raheja, 2005: S. 55).

Anwendung finden auch entscheidungsbaumbasierte Verfahren wie der C4.5-Algorithmus (Meng, 2010) oder der ID3-Algorithmus (Sester, 2000). Vorteil dieser Verfahren ist, dass auch strukturelles Regelwissen abgeleitet werden kann. In der Dissertation von Meng (2010) werden aus LiDAR-Daten abgeleitete Gebäudegrundrisse mit Merkmalen beschrieben und ein Entscheidungsbaum mittels C4.5-Algorithmus erlernt. Für die fünf Klassen (*single-family house*, *small mobile home*, *multi-family residential*, *large non-residencial* und *smaller non-residential*) konnte eine Gesamtgenauigkeit von 82,7 % erreicht werden. Die Trainings- und Testdatenmenge war mit 203 Trainingsobjekten und 179 Testobjekten relativ klein.

Der Ansatz von Sester (1995, 2000) basiert auf einem semantischen Netz, das durch Einsatz maschineller Lernmethoden (ID3) semi-automatisch erlernt wird. Ein grundlegendes Problem des ID3-Algorithmus ist jedoch, dass der Entscheidungsbaum bei zunehmender Anzahl von Trainingsobjekten sehr groß und schwer interpretierbar wird (Sester, 1995). Ein derartig komplexer Entscheidungsbaum lässt sich dann nur schwer auf unbekannte Objekte anwenden und ist schlecht generalisierbar.

In der Studie von Steiniger et al. (2008) werden verschiedene Klassifikationsverfahren, wie der Batch Perceptron-Algorithmus, Mean-Squared-Error-Algorithmus, Adaboost sowie Support Vector Machines (SVM), miteinander verglichen. Die Autoren stellen fest, dass die

Wahl des Klassifikationsverfahrens gegenüber der Wahl der richtigen Merkmale nur einen geringen Einfluss auf das Ergebnis hat. In dieser Studie war es das Ziel, digitale Gebäudegrundrisse der topographischen Karte hinsichtlich ihrer morphologischen Bebauungsstruktur in 5 Typen (*industry/commercial*, *inner city*, *urban*, *suburban* und *rural area*) zu klassifizieren. Am Beispiel topographischer Daten von Zürich (CH) und Southhampton (UK) wurde mit einem SVM-Klassifikator eine Gesamtklassifikationsgüte von 75 % bzw. 67 % erreicht. Die erkannten Strukturen werden in einem Generalisierungsansatz verwendet (Steiniger et al., 2010).

Auch in der Arbeit von Henn et al. (2012), deren Datengrundlage ein 3D-Gebäudemodell im LoD1 war, zeigte der Einsatz von SVM die beste Gesamtklassifikationsgüte gegenüber zwei anderen erlernten Klassifikatoren (Naive Bayes und Decision Trees). Die Autoren präferieren die lineare SVM, da sie mit weniger Stützvektoren bessere Generalisierungseigenschaften vermuten. Sie konnten die 5 Gebäudetypen *terraced house*, *wilhelmian style house*, *detached house*, *apartment building* und *HBG* mit einer Gesamtgenauigkeit von 90,8 % klassifizieren. Römer und Plümer (2010) trainieren einen binären SVM-Klassifikator zur automatischen Erkennung von Gebäuden im gründerzeitlichen Stil. Als Datengrundlage wurde ein 3D-Gebäudemodell verwendet. Für die Erkennung geben die Autoren eine Genauigkeit von 87,7 % an.

4.3.3.2 Unüberwachte Klassifikationsverfahren

Beim Einsatz unüberwachter Verfahren wird ausschließlich die in den Daten enthaltene Information verwendet. Diese Verfahren eignen sich dann, wenn keine gelabelten Trainingsdaten zur Verfügung stehen bzw. kein Wissen über die Zusammensetzung und Strukturen der Gebäude vorliegt.

Auf Grundlage aus den Daten abgeleiteter Objektmerkmale erfolgt unter Einsatz eines unüberwachten Lernverfahrens eine Gruppierung der Gebäude nach ihrer Ähnlichkeit. In allen bekannten Arbeiten zur unüberwachten Gebäudeklassifizierung wurde dabei der Expectation-Maximization-Algorithmus, kurz EM-Algorithmus, eingesetzt (Geiß et al., 2011; Neidhart & Sester, 2004; Werder et al., 2010). Im Unterschied zum *k-Means*-Algorithmus sind bei diesem Verfahren keine Annahmen zur Clusteranzahl und Verteilung nötig (Werder et al., 2010). Ein wesentlicher Schritt nach der Clusterbildung ist die Interpretation der Ergebnisse durch den Bearbeiter. In diesem Schritt erfolgt die Bedeutungszuordnung der Cluster in Form einer Benennung bzw. werden durch eine visuelle oder statistische Datenexploration ähnliche Cluster zu bedeutsamen Gruppen zusammengefasst.

In der Arbeit von Werder et al. (2010), deren Ziel die Klassifizierung von OSM-Gebäuden von Dortmund war, konnten zunächst 10 Cluster gebildet und in einem anschließenden Interpretationsschritt zu 5 Gruppen zusammengefasst werden. Sie führten eine Genauigkeitsbetrachtung auf Baublockebene durch, in dem sie Klassen mit den Nutzungsarten des ATKIS®-Basis-DLM gegenüberstellten.

Neidhart & Sester (2004) beschreiben bei ihrem unüberwachten Klassifikationsansatz auf Grundlage von Gebäuden aus der ALK die Extraktion von 18 Cluster. Diese werden später

zu 5 Typen (*one-family house*, *row house*, *small more-family-house*, *large more-family house* und *tower block*) aggregiert.

Geiß et al. (2011), die ihre Gebäude aus Fernerkundungsdaten gewinnen, extrahieren zunächst 26 Cluster, die zu 6 Klassen (*single detached house*, *semi-detached house*, *small multi-family house*, *large multi-family house*, *tower block* und *large non-residential building*) zusammengefasst werden. Sie geben als einzige Autoren eine Genauigkeit der Klassifizierung an (85,0 %), die sie durch einen Vergleich mit der Gebäudenutzungsinformation aus der ALK des Testgebietes Oberhaching ermitteln konnten.

4.3.4 Kombinierte Ansätze

Hierunter werden Ansätze verstanden, die zu Teilen eine Top-down und Bottom-up-Strategie verfolgen. Einen derartigen Ansatz beschreiben Lüscher et al. (2009)[35] für die automatische Ableitung urbaner Konzepte in topographischen Datenbanken. Dabei wird ein wissensbasierter ontologischer Interpretationsansatz mit einem statistischen Lern- und Klassifikationsverfahren kombiniert. Mithilfe einer Ontologie wird zunächst strukturelles Wissen über die Begriffe (engl. *concepts*) und deren gegenseitige Relationen (engl. *relations*) formalisiert bereitgestellt. Anschließend wird die Ontologie in ein Bayes-Netz überführt und anhand von Trainingsdaten die klassenbedingte Wahrscheinlichkeit mittels Kerndichteschätzung ermittelt. Durch probabilistisches Schließen (engl. *probabilistic reasoning*) im Bayes-Netz können auch begriffliche Unsicherheiten in der Modellierung berücksichtigt werden. Der Ansatz wurde für die Erkennung englischer Reihenhäuser entwickelt und an Gebäudedatensätzen der Städte Southampton, Middlesbrough, Norwich und Portsmouth (UK) getestet. Die Erkennungsrate lag zwischen 95.2 % (Portsmouth) und 98,2 % (Middlesbrough). Die Autoren sehen jedoch noch weiteren Forschungsbedarf, was eine Implementierung anderer Gebäudetypen, die Einführung neuer Konzepte sowie der Umgang mit der begrifflichen Formalisierung der Mustererkennungsprozesse betrifft.

Ein anderer kombinierter Ansatz wird in Triantakonstantis & Barr (2009) vorgestellt. Diese nutzen zunächst einen wissensbasierten Ansatz zur Klassifikation der Gebäude in die räumlich-topologischen Klassen *detached*, *semi-detached* und *terrace*. In einem zweiten Schritt werden die Gebäude mit einem überwachten statistischen Klassifikationsansatz, der Multinomialen Logistischen Regression (MLR), weiter nach dem Baualter klassifiziert. Die freistehenden Gebäude werden beispielsweise nach den Baualtersklassen *1945-1964*, *1965-1980* und *post-1980* ausdifferenziert. Die MLR ist eine Verallgemeinerung der binären logistischen Regression und erlaubt eine Analyse nominalskalierter Kriterien mit mehr als zwei Ausprägungen. Hierzu wurde für die räumlich-topologischen Klassen jeweils ein Modell erlernt. Dabei erreichen sie eine Klassifikationsgüte von 76,6 % für freistehende, 93,0 % für halbfreistehende sowie 80,7 % für gereihte Gebäude. Vorteil dieses kombinierten Ansatzes und der gewählten hierarchischen Typologie ist, dass auf dem ersten Level die Gebäude nach

[35] siehe hierzu auch diverse Vorarbeiten der Autoren (Lüscher et al., 2007; Lüscher et al., 2008b, 2008a)

eindeutigen Kriterien relativ sicher klassifiziert werden können. Für manche Anwendung spielen diese „einfachen" Typen bereits eine wichtige Rolle. Erst in einem zweiten Schritt erfolgt eine Verfeinerung der Klassifikation mit einem statistischen Klassifikator.

4.4 Bewertung der bisherigen Ansätze

Die ersten Forschungsarbeiten zur Untersuchung der Stadtstruktur basieren auf Fernerkundungsdaten, wobei deren Beschreibung auf einer höheren Interpretationsebene (Baublöcke, Regionen etc.) erfolgte. Erst mit der Verfügbarkeit objektstrukturierter digitaler topographischer Daten gewinnt die Klassifizierung individueller Gebäude an Bedeutung, da mit ihr eine hochauflösende Abbildung der Siedlungsstruktur möglich wird und Generalisierungsprozesse bei der rechnergestützten Herstellung topographischer Karten gesteuert werden können. Insgesamt gibt es nur eine überschaubare Anzahl an Publikationen, in denen Ansätze zur Gebäudeklassifizierung beschrieben werden. Zusammenfassend können folgende Aspekte festgehalten werden.

Thematische Auflösung: Die Mehrzahl der bisherigen Ansätze berücksichtigt relativ wenige Zielklassen (5 Gebäudetypen und weniger). Für die kleinräumige Siedlungsmodellierung werden häufig nur „einfache" morphologische Typen identifiziert. Modellierungen komplexer städtischer Phänomene verlangen jedoch eine hohe thematische Auflösung, wie beispielsweise eine Klassifizierung der Gebäude nach städtebaulichen Kriterien (Nutzung, Wohnform, Struktur und Alter). Eine sehr differenzierte Sicht auf die Gebäude stand bisher nur in wenigen Arbeiten im Fokus.

Maschinelle Lernverfahren: Auf Grundlage geotopographischer Daten in Vektorform können die Typen freistehende Gebäude, Doppelhäuser und gereihte Häuser unter Nutzung eines wissensbasierten Regelwerkes sicher bestimmt werden. Bei einer Klassifizierung der Gebäude in eine von sehr vielen Gebäudeklassen gestaltet sich eine explizite wissensbasierte Beschreibung oft sehr schwierig, da das nötige Wissen für die Modellierung zunächst nicht gegeben bzw. schwer zu formalisieren ist. Maschinelle Lernverfahren bieten in diesem Fall eine Alternative, deren Einsatz jedoch nur in wenigen Arbeiten tiefer untersucht wurde. Den umfangsreichsten Vergleich machen Steiniger et al. (2008), in dem vier verschiedene Lernverfahren an diversen Datensätzen untersucht werden. Sie fügen jedoch hinzu, dass weitere Forschungsarbeit u. a. in der Parametrisierung der Klassifikatoren und der Untersuchung des Einsatzes weiterer Merkmale besteht. Henn et al. (2012) vergleichen drei verschiedene maschinelle Lernverfahren an einem Datensatz. Die Informatik stellt weitere Algorithmen für die Klassifizierung und das maschinelle Lernen bereit, dessen Einsatz für die automatische Klassifizierung von Gebäudegrundrissen noch erprobt werden kann. Das Potenzial dieser Methoden für diese Anwendung ist bei weitem noch nicht ausschöpft.

Merkmale: Für die automatische Klassifizierung werden die Gebäude mithilfe automatisch abgeleiteter Merkmale und Relationen beschrieben. Dabei kommen u. a. geometrische, topologische, spektrale oder semantische Merkmale zum Einsatz. Neben diesen spielen kontextuelle Merkmale eine wichtige Rolle. Steiniger et al. (2008) zeigen beispielsweise, dass Dichtemerkmale, wie die Anzahl der Gebäude innerhalb eines Suchradius, einen großen Informationsanteil für die Charakterisierung städtischer Strukturen besitzen. Die auf die unter-

schiedlichen Datenmodelle (Raster- vs. Vektordaten) angewendeten Methoden der Merkmalsgewinnung unterscheiden sich grundlegend. Während bei Bilddaten, deren Grundelemente Bildpunkte (Pixel) sind, auf Methoden der digitalen Bildverarbeitung zurückgegriffen wird, so werden Merkmale aus Vektordatensätzen mittels der Algorithmischen Geometrie (eng. *Computational Geometry*), die mit geometrischen Strukturelementen wie Punkten, Linien, Kreisen, Polygonen und Körpern arbeitet, gewonnen (Berg et al., 2000). Für die Klassifizierung der Gebäude in eine begrenzte Anzahl, einfach beschreibbare Zielklassen, sind in der Regel wenige Merkmale ausreichend. Bei einer Gebäudetypologie mit vielen Klassen und wenig Wissen über deren Eigenschaften in den Daten, gestaltet sich die Wahl der Merkmale schwieriger. Intuitiv werden zunächst alle sinnvoll erscheinenden Merkmale berechnet und ihre Relevanz für die Klassifizierung mittels einer explorativen Datenanalyse überprüft. Von der Berechnung sehr vieler Merkmale und dem Einsatz automatisierter Verfahren der Merkmalsselektion bzw. maschinellen Lernverfahren, die hochdimensionale Klassifikationsprobleme effizient lösen können, machten bisher nur wenige Gebrauch. Vielmehr wird oftmals die Erhebung weiterer Merkmale als potenzielle Maßnahme zur Verbesserung der Klassifikationsgüte genannt (Neidhart & Sester, 2004; Steiniger et al., 2008; Werder et al., 2010).

Validierung: Eine Genauigkeitsbetrachtung anhand unabhängiger Referenzdaten ist unabdingbar für die Bewertung eines entwickelten Klassifizierungsansatzes. Für 8 der 18 betrachteten Ansätze standen keine Referenzdaten auf Gebäudeebene zur Verfügung. Eine Einschätzung der Genauigkeit konnte häufig nur durch eine visuelle Plausibilitätskontrolle bzw. auf einer höheren Interpretationsebene (Baublock, Gemeinde) erfolgen. Dies gilt sowohl für die wissensbasierten als auch für die unüberwachten Ansätze. Eine Validierung der unüberwachten Verfahren gestaltet sich noch schwieriger, da zunächst eine Interpretation der extrahierten Cluster nötig ist. Bei den überwachten Verfahren kann die Genauigkeit durch Aufteilung in Trainings- und Testdaten abgeschätzt werden. Häufig beschränkt man sich jedoch auf die Angabe der Gesamtgenauigkeit. Ein Vergleich der erreichten Genauigkeiten unterschiedlicher Arbeiten ist nicht möglich, da verschiedene Typologien und Datengrundlagen zugrunde liegen.

Operationalisierung: Viele der beschriebenen Ansätze wurden prototypisch implementiert. Die meisten Arbeiten besitzen jedoch zum Teil experimentellen Charakter. Dies zeigt sich insbesondere an den recht kleinen Untersuchungsgebieten oder Gebäudedatensätzen, an denen die Verfahren getestet wurden. Dabei beschränkt sich die Erprobung auf einzelne Städte bzw. Ausschnitte von Städten. Den dörflichen Bebauungsformen wurde bisher wenig Beachtung geschenkt. Erfahrungen im Umgang mit einer großflächigen Anwendung (z. B. landesweiten Klassifizierung von Gebäuden) gibt es bisher nicht.

Flexibilität: Viele Ansätze nutzen ein wissensbasiertes Regelwerk. Diese Ansätze haben den Nachteil, dass mit jeder Änderung der Eingangsdatenstruktur oder des Problemkreises (andere Gebäudetypologie) ein neuer Modellaufbau nötig wird. Die entwickelten Verfahren sind deshalb nicht auf andere Probleme übertragbar. Ontologie-basierte Ansätze sind ein guter Schritt in Richtung Interoperabilität. Allerdings fehlt es derzeit noch an der Formalisierung. Sester (1995) stellt auch fest, dass die vermeintlich einfachen Gebäudestrukturen in einer enormen Fülle von Formen und Größen vorkommen, was eine explizite Modellierung

unmöglich macht. Mit den maschinellen Lernverfahren kann ein Beitrag zur Erhöhung der Flexibilität der Verfahren geleistet werden. Eine Änderung der Gebäudetypologie oder die Erweiterung des Merkmalssets benötigt lediglich ein neues Training. Der Aspekt der Übertragbarkeit und der Adaptierbarkeit wurde bisher nur in wenigen Ansätzen thematisiert.

Datengrundlage: Anstrengungen zur Erforschung einer Thematik werden immer von den verfügbaren Daten geleitet. In Großbritannien und den Niederlanden, deren Landesvermessung über eine zentrale Behörde für das ganze Staatsgebiet wahrgenommen wird, lagen schon frühzeitig flächendeckend Gebäudegrundrisse und postalische Adressen vor. Erste Interpretationsansätze wurden darum insbesondere auf dieser Datengrundlage erprobt. In Deutschland standen digitale Gebäudegrundrisse lange dezentral und mit beschränktem Zugang für die raumwissenschaftliche Forschung zur Verfügung. Es gibt daher nur wenige Erfahrungen mit der Anwendung automatischer Klassifizierungsansätze auf amtliche Gebäudegrundrisse in Deutschland.

5 Konzeptionelle Vorüberlegungen

Vor der Entwicklung eines Verfahrens für die automatische Gebäudeklassifizierung wird zunächst das Ziel der Entwicklung definiert. Darauf aufbauend werden allgemeine Anforderungen an das Verfahren und den dafür benötigten Eingangsdaten beschrieben.

5.1 Ziel der Verfahrensentwicklung

Der große Bedarf an kleinteiliger Information zur Siedlungsstruktur kann mit den verfügbaren Daten in Deutschland nicht gedeckt werden (vgl. Anhang A). Strukturdaten unterhalb der Gemeindeebene liegen oft nur für wenige große Städte vor und selbst für diese ist der Datenzugriff für überregionale Planung und Wissenschaft nur eingeschränkt möglich. Mit der zunehmenden Verfügbarkeit digitaler Geobasisdaten, stehen Gebäudegrundrisse und andere strukturbeschreibende Objekte flächendeckend zur Verfügung. Mithilfe räumlicher Analysen im GIS lassen sich auf dieser Grundlage bereits einfache Indikatoren zur baulichen Dichte durch Flächenverschneidung ableiten. Wichtige Informationen zum Gebäudetyp, differenziert nach der Funktion, Bebauungsart, Wohnform, Stockwerkszahl oder Baualter, sind in den Gebäudegrundrissen jedoch häufig nicht explizit gegeben.

Das Potenzial einer automatischen Klassifizierung von Gebäudegrundrissen durch Nutzung von Methoden der Bildanalyse, der semantischen Modellierung sowie der Mustererkennung in räumlichen Daten ist gegeben. Die aktuellen Ansätze zeigen jedoch nur wenig Flexibitität im Hinblick auf unterschiedliche Zielstellungen sowie die Anwendung auf verschiedene Eingangsdaten (vgl. Kap. 4.4). Weiterhin gibt es nur wenig Erfahrung beim Einsatz maschineller Lernverfahren auf amtliche Geobasisdaten in Deutschland. Daraus ergibt sich der Bedarf nach einem geeigneten automatisierten Verfahren zur automatischen Klassifizierung von Gebäudegrundrissen, das möglichst flexibel und erweiterbar ist, die Integration externer Daten erlaubt, gut in einer GIS-Umgebung eingebettet werden kann und eine schnelle Datenverarbeitung ermöglicht. Gleichzeitig soll das entwickelte Verfahren an verschiedenen Daten zum Gebäudegrundriss und an verschiedenen Siedlungstypen in Deutschland getestet und die Genauigkeit abgeschätzt werden.

5.2 Gebäudeklassifizierung im Kontext der Siedlungsstrukturanalyse

GIS-gestützte Analysen erlauben die Untersuchung des Siedlungsraumes hinsichtlich der Struktur. Auf Grundlage von Luftbildern und topographischen Karten können durch Abgrenzung und Typisierung homogene Flächen gleicher Bebauungsstruktur (Siedlungsstrukturtypen) erfasst werden. Unter Annahme strukturtypischer Kenngrößen (u. a. Überbauungsgrad, Geschossflächendichte, Wohnungsdichte, Energieverbrauch) ist es dann möglich, räumliche Strukturen verschiedener Phänomene zu untersuchen und Verteilungsmuster durch Visualisierung sichtbar zu machen.

Die Gebäude sind die wichtigsten Elemente der Siedlung, deren Größe, Form und Anordnung die morphologische Siedlungsstruktur bestimmen und durch deren Nutzung sich funktionale sowie sozio-ökonomische Strukturen ergeben. Für einige Fragestellungen ist deshalb eine Interpretation auf Ebene der Gebäude zielführender, da mit der Abstraktion auf Bau-

blockebene wichtige Detailinformationen (insbesondere bei sehr heterogenen Strukturen) verloren gehen. Mit einer Interpretation auf Gebäudeebene können räumliche Phänomene dann viel differenzierter abgebildet werden. Allerdings ist eine manuelle Erhebung von Gebäudetypen, besonders im Hinblick auf große Untersuchungsgebiete, mit enormen Kosten verbunden.

Eine Lösung bieten dafür automatisierte Verfahren zur kleinräumigen Analyse der Siedlungsstruktur. Mit dem am IÖR entwickelten und patentierten Programmsystem SEMENTA® (Meinel et al., 2008a) können beispielsweise auf Grundlage Digitaler Topographischer Karten 1:25 000 (DTK25-V) und den bebauten Flächen aus dem ATKIS® Basis-DLM verschiedene planungsrelevante Indikatoren der Siedlungsstruktur automatisch abgeleitet werden. Dabei wird der Gebäudebestand zunächst aus dem Grundrisslayer der DTK25-V extrahiert, gebäudebeschreibende Merkmale berechnet und mithilfe eines Regelwerkes nach 9 Gebäudetypen klassifiziert. Durch Verknüpfung der klassifizierten Gebäudegrundrisse mit gebäudetypischen Kenngrößen (u. a. mittlere Geschosszahl, Geschosshöhe, Wohnungs- oder Haushaltsgröße) entsteht ein kleinräumiges Siedlungsmodell. Mithilfe räumlicher Aggregationstechniken können anschließend Bebauungsstrukturtypen und verschiedene Indikatoren (u. a. Gebäudetypenstruktur, Überbauungsgrad, Geschossflächendichte, Gebäudevolumendichte, Wohnungs- und Einwohnerdichte) auf Baublockebene oder einer beliebigen Bezugsgeometrie abgeschätzt werden. Zur Erhöhung der Modellgüte werden amtliche Statistikdaten auf höherer Ebene hinzugezogen, auf deren Grundlage Einwohner- oder Wohnungszahlen mittels räumlicher Disaggregation abgeglichen werden. Die klassifizierten Gebäudegrundrisse spielen dabei eine wichtige Rolle bei der kleinräumigen Analyse der Siedlungsstruktur. So werden diese beispielsweise auch als Projektionsfläche für die Modellierung von Heizenergiebedarfe (Geiß et al., 2011) benötigt.

Die Abb. 5-1 zeigt die Gebäudeklassifizierung im Kontext der automatisieren gebäudebasierten Siedlungsstrukturanalyse. Ausgehend von einer siedlungsraumbezogenen Fragestellung in Bezug auf die Realität werden geeignete Primär- oder Sekundärdatenquellen gewählt, aus denen die Gebäudegrundrisse sowie weitere bedeutungsvolle Objekte (z. B. Baublöcke, Hauskoordinaten) abgeleitet werden können. Anschließend werden die Gebäude mit geeigneten Merkmalen beschrieben. Für die Ableitung der Merkmale kommen, je nach zugrundeliegendem Datenmodell, Ansätze der Bildanalyse sowie GIS-basierte Analyseverfahren in Betracht. Auf Grundlage der Merkmale und einem geeigneten Klassifikator (vgl. Kap.3.4) wird mit der Gebäudeklassifizierung jedem Gebäudegrundriss ein Gebäudetyp zugewiesen. Die zu identifizierenden Gebäudetypen ergeben sich in der Regel aus der zugrundeliegenden Fragestellung und werden vom Nutzer vorab in einer Gebäudetypologie festgelegt. Über gebäudetypische Annahmen können den Gebäuden anschließend verschiedene Kenngrößen zugewiesen werden. Dabei stützt man sich auf Expertenwissen, eigene Untersuchungen oder empirischen Befunden aus der Wissenschaft. Mithilfe der räumlichen Analyse (vgl. Kap.2.4) werden die Daten anschließend fragestellungsorientiert weiterverarbeitet. Hierzu zählt zum Beispiel die Aggregation (Summenbildung) einzelner gebäudebezogener Merkmale auf eine gewählte Bezugsgeometrie. Durch spätere Visualisierung der neuen generalisierten Information können räumliche Zusammenhänge und Strukturen auf höherer Ebene sichtbar gemacht werden. Bei der räumlichen Disaggregation werden die raumbezo-

genen Informationen hingegen verfeinert, wie etwa durch Verteilung der gemeindebezogenen Einwohner auf synthetische Wohnflächen der Gebäude. Die abgeleiteten raumbezogenen Fachdaten werden anschließend kartographisch visualisiert. Aus den thematischen Karten können dann Erkenntnisse in Bezug auf die Fragestellung gewonnen werden. Die abgeleiteten Fachdaten können dabei auch für andere Nutzer interessant sein oder in externen Anwendungen genutzt werden.

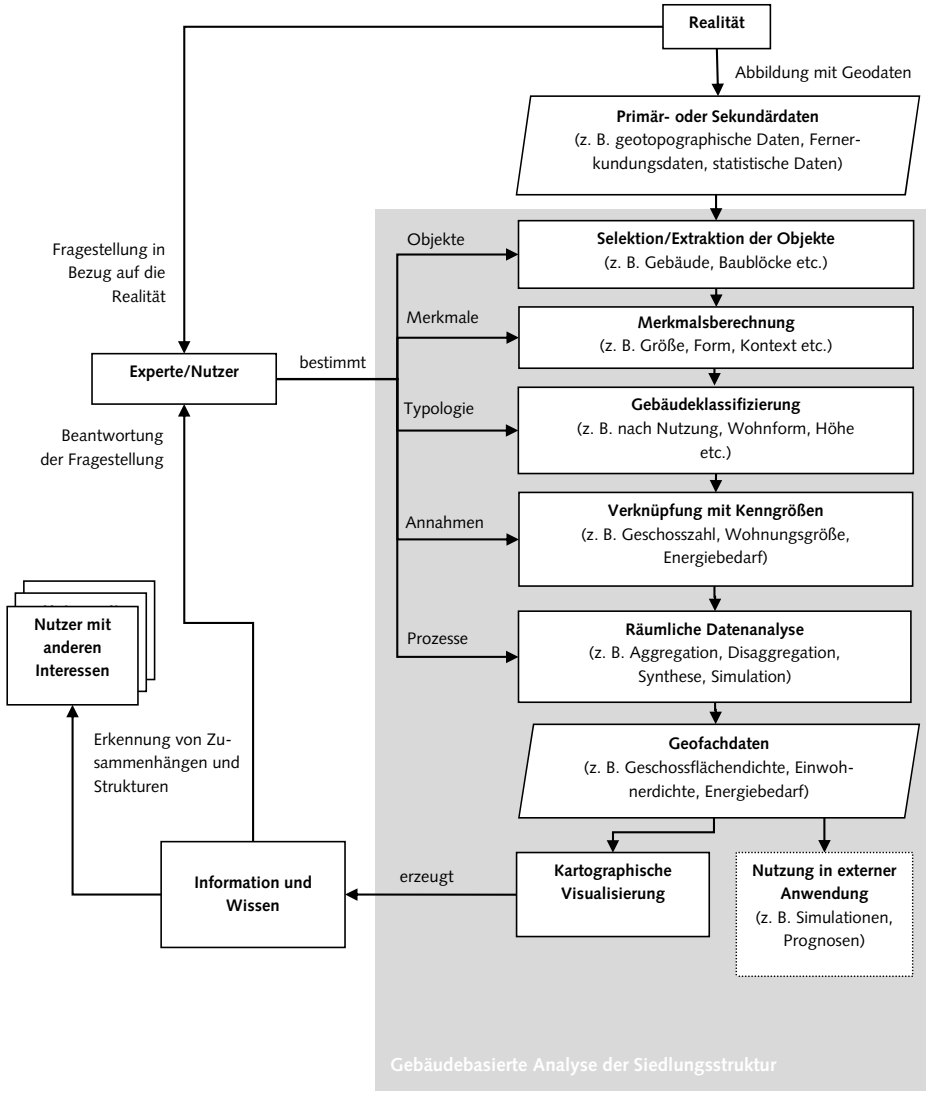

Abb. 5-1: Klassifizierung von Gebäudegrundrissen im Kontext der Siedlungsstrukturanalyse

5.3 Anforderung an das Verfahren

Im Folgenden werden verschiedene Anforderungen erörtert, die das Verfahren erfüllen sollte.

5.3.1 Adaptive Gebäudetypologie

Eine automatische Klassifizierung der Gebäudegrundrisse kann nach verschiedenen Kriterien erfolgen. Für die Ableitung planungsrelevanter Kenngrößen, wie die Geschossflächen-, Wohnungs- oder Einwohnerdichte, spielen die Kriterien der Größe, Nutzung und Geschosszahl eine bedeutende Rolle. Bei der Modellierung des Energiebedarfs sind hingegen Sanierungszustand, Baumaterial oder spezielle morphologische Eigenschaften, wie das A/V-Verhältnis, ein wichtiges Kriterium. Die Zielstellung bestimmt dabei die zu identifizierenden Gebäudetypen, die in der Regel vorab in einer Gebäudetypologie festgelegt werden. Die Gebäudetypologie hat dabei auch einen räumlichen Bezug (gültiger Untersuchungsraum). Verlässt man diesen, liegen ggf. andere charakteristische Gebäudetypen zugrunde. Eine Änderung der Fragestellung oder des Untersuchungsraumes kann deshalb eine Anpassung der Gebäudetypologie nötig machen. Um die Übertragbarkeit des Verfahrens zu gewährleisten, sollte die Gebäudetypologie deshalb adaptierbar sein.

5.3.2 Interoperabilität

Das Verfahren soll auf verschiedene Geodaten aus unterschiedlichen Datenmodellen anwendbar sein. Geodaten zum Gebäude oder zum Baublock sind Ergebnis verschiedener Erfassungen und liegen mit unterschiedlicher Genauigkeit, Abstraktionsgrad, Bezugssystem, Datenstruktur, Datenformat etc. vor. Gebäudegrundrisse können beispielsweise aus vektorbasierten digitalen Landschaftsmodellen oder rasterbasierten topographischen Karten sowie Fernerkundungsdaten gewonnen werden. Maßstabs-, modellierungs- und erfassungsbedingte Unterschiede hinsichtlich der Geometrie und der Semantik führen häufig zu Problemen bei der Datenintegration.

Bishr (1998) identifiziert auf Anwendungsebene semantische, schematische und syntaktische Heterogenitätsprobleme bei der Integration von Daten unterschiedlicher Quellen. Die Interoperabilität des Verfahrens kann dadurch erhöht werden, in dem die Geoobjekte unterschiedlicher Daten in einem gemeinsamen semantischen Modell (Anwendungsschema) abgebildet werden. Bei dieser Abstraktion müssen einheitliche Modellierungskonzepte eingeführt sowie Mindestanforderungen an die Daten hinsichtlich der Geometrie und Semantik festgelegt werden. Durch eine derartige anwendungsspezifische Datenbeschreibung ist das entwickelte Verfahren nicht nur für bestimmte Datenmodelle anwendbar. Hierzu ist lediglich eine Transformation des neuen Datenmodells in das verfahrensspezifische Datenmodell nötig.

Da Gebäudegrundrisse hinsichtlich der Semantik und Geometrie verschiedene Eigenschaften aufweisen können, sind grundlegende Eingangsdatentypen zu bilden. Auf konzeptioneller Ebene kann dann beispielsweise festgelegt werden, welche Objektmerkmale für welchen Eingangsdatentyp berechnet bzw. welche Merkmale direkt aus einem Attribut im Datenmodell übernommen werden können. Durch Einführung und Definition dieser Eingangsdatentypen ist das Verfahren einfacher auf andere Daten übertragbar.

5.3.3 GIS-Kopplung und Nutzerfreundlichkeit

Für einen späteren praktischen Einsatz sollte das entwickelte Verfahren vollständig in einer GIS-Umgebung integrierbar sein, wie beispielsweise als Erweiterung für ESRI ArcMap innerhalb der ESRI ArcGIS Desktop Anwendung. Die meisten Geodatenverarbeitungsprozesse können mithilfe von Scriptsprachen direkt in einem GI-System implementiert werden. Einzelkomponenten externer Umgebungen (z. B. Bildverarbeitungsprozesse, statistische Datenverarbeitung, implementierte Lernalgorithmen) müssen über geeignete Schnittstellen gekoppelt werden. Für den Datenaustausch bietet sich dafür eine gemeinsame Datenbank, auf die alle Komponenten zugreifen können. Für die prototypische Verfahrensentwicklung ist eine vollständige Integration im GIS nicht nötig.

Während der Verfahrensentwicklung spielen auch Aspekte der Nutzerfreundlichkeit eine wichtige Rolle. Der Parametrisierungsaufwand sollte für den Nutzer möglichst gering gehalten werden. Modellspezifische Parameter (z. B. Smoothing-Parameter, Abbruchkriterien) sollten beispielsweise automatisch in einem Tuning-Prozess optimiert werden. Im Idealfall werden vom Nutzer dann lediglich Eingangsdaten, Gebäudetypologie und entsprechende Lerndaten abverlangt. Die Merkmalsberechnung erfolgt automatisch durch vorab definierte Merkmalssets für verschiedene Eingangsdatentypen. Das Merkmalsset sollte jedoch durch den Nutzer erweiterbar sein (siehe Adaptierbarkeit).

Nach dem Erlernen des Modells sollte dem Anwender der geschätzte Klassifikationsfehler bekannt gemacht werden. Ist dieser aus Nutzersicht akzeptabel, kann das erlernte Modell gespeichert und für die entsprechende Aufgabe auf das gesamte Untersuchungsgebiet angewendet werden.

5.3.4 Robustheit

Der Klassifikator sollte möglichst robust gegenüber Ausreißern, Rauschen und fehlenden Werten sein und auch auf Eingangsdaten mit geringerer Datenqualität (z. B. extrahierte Gebäude aus Bilddaten) oder mit fehlerhaften Attributen anwendbar sein. Hierzu zählen unter anderem auch automatische Konsistenzprüfungen (z. B. Test auf konstante Merkmale, Ersetzen fehlender Werte).

5.3.5 Genauigkeitsabschätzung

Mit dem entwickelten Verfahren soll es möglich sein, das Ergebnis der Klassifizierung hinsichtlich der Genauigkeit zu quantifizieren und zu bewerten. Eine realistische Abschätzung sollte dabei ausschließlich anhand von Daten erfolgen, die nicht am Modellaufbau beteiligt sind. Erst dann kann tatsächlich ermittelt werden, wie gut der Klassifikator unter der Annahme gleicher Datenbedingungen neue Daten klassifiziert. Zur Genauigkeitsabschätzung müssen geeignete Schätzverfahren (z. B. Kreuzvalidierung, Hold-out-Methoden) eingesetzt werden. Für die Bewertung der thematischen Klassifikationsgenauigkeit eignen sich die aus der Fernerkundung bekannten Gütemaße der Konfusionsmatrix (Overall Accucary, User´s Accuracy, Producers Accuracy sowie der Kappa-Koeffizient) (Congalton, 1991).

5.3.6 Laufzeit

Das Verfahren ist vorrangig für Anwendungen in der Raumwissenschaft, insbesondere zur Beantwortung siedlungsraumbezogener Fragestellungen, gedacht. Eine Datenverarbeitung in Echtzeit, wie es beispielsweise Mustererkennungsprozesse für die On-the-fly-Generalisierung verlangen, ist in diesem Fall nicht notwendig. Dennoch wäre es aus praktischer Sicht wünschenswert, die benötigten Ressourcen so gering wie möglich zu halten. Eine schnelle Laufzeit sollte dabei nicht auf Kosten der Klassifikationsleistung gehen. Bei Wahl des Klassifikators ist deshalb dieser auszuwählen, der gegenüber Anderen mit vergleichbarer Klassifikationsleistung eine kürzere Laufzeit besitzt.

Die benötigte Laufzeit zum Trainieren eines Klassifikators hängt von einer Vielzahl von Faktoren, wie etwa von der Dimension des Merkmalsraumes, der Anzahl der Klassen, der Anzahl der Trainingsobjekte, der Komplexität des Lernalgorithmus, des eingesetzten Fehlerschätzverfahrens und natürlich auch der zugrundeliegenden Hardware (Speicher, Anzahl der Recheneinheiten etc.), ab. Bei einer im Lernprozess integrierten Modellselektion steigt die Laufzeit weiter mit jedem getesteten Klassifikator, Merkmalsselektionsverfahren und jedem neuen Tuning. Die Dimension des Merkmalsraumes hat jedoch häufig den größten Einfluss, da deren Zunahme zu einem exponentiellen Anwachsen der Komplexität eines Klassifikators führt und entsprechend eine exponentiell größere Lerndatenmenge benötigt wird (Bishop, 2007). Wegen diesem als „Fluch der Dimensionalität" („Curse of dimensionality") bekannten Phänomen, sind nichtparametrische Schätzverfahren nur bei geringer Dimensionalität anwendbar. Darum sollen möglichst effiziente maschinelle Lernverfahren eingesetzt werden, mit denen es möglich ist, aus einer limitierten Stichprobenmenge Klassifikationsprobleme im hochdimensionalen Raum zu lösen. Der Klassifikator soll damit gut skalierbar[36] sein und eine möglichst geringe Komplexität aufweisen.

Ein bisher nicht betrachteter Aspekt betrifft die Laufzeit der Merkmalsgewinnung, die durch Wahl effizienter Algorithmen möglichst gering zu halten ist. Durch Identifizierung unbedeutender Merkmale durch Merkmalsselektion kann auch die Laufzeit der Merkmalsberechnung in der praktischen Anwendung reduziert werden.

5.3.7 Flexibilität

Eine adaptive Gebäudetypologie ermöglicht bereits eine Anwendung des Verfahrens für verschiedene Fragestellungen und Untersuchungsräume. Es ist damit allerdings noch nicht garantiert, dass mit dem implementierten Merkmalset die Gebäudeklassen hinreichend diskriminiert werden können. Darum soll es möglich sein, das Merkmalsset um beliebige zusätzliche metrische oder kategoriale Merkmale zu erweitern und diese dem Mustererkennungsprozess zur Verfügung zu stellen. Diese zusätzlichen Merkmale können einerseits bereits explizit in dem Datenmodell modellierte Attribute sein, wie z. B. die Stockwerkszahl oder ein

[36] Unter einer guten Skalierbarkeit meint man im Allgemeinen, dass sich eine Erhöhung der Anzahl der Trainingsobjekte bzw. der verwendeten Merkmale nur gering auf die Zunahme der Anzahl auszuführender Operationen auswirkt.

anderes für den Klassifikationsprozess hilfreich erscheinendes Merkmal mit direktem Gebäudebezug. Andererseits sollen neue Merkmale einführbar sein, die mithilfe räumlicher Analysen unter Verwendung zusätzlicher Daten gewonnen werden (z. B. Distanzmerkmale zu anderen Objekten). Durch einen modularen Aufbau des Verfahrens und einem Klassifikator, dessen Eingangsmerkmale keinen festen Spezifizierungen unterliegen, kann eine Adaption des Verfahrens in dieser Richtung realisiert werden.

5.4 Anforderungen an die Eingangsdaten

5.4.1 Gebäuderepräsentation

Gebäude können in einem GI-System in unterschiedlicher Form repräsentiert sein, wie als georeferenzierte Gebäudeadresse, 2D-Gebäudegrundriss oder durch ein 3D-Gebäudemodell. Das hier entwickelte Verfahren nimmt Bezug auf 2D-Gebäudegrundrisse, die eine flächenhaft abstrahierte zweidimensionale Abbildung der Gebäude darstellen. Es ist die geläufigste Modellierungsform und die Basisgeometrie für die Rekonstruktion von 3D-Gebäudemodellen im Klötzchenmodell[37] (LoD1) bzw. Klötzchenmodell mit Standarddachformen (LoD2).

Gebäude können aus verschiedenen Datenquellen entnommen werden, in denen sie unterschiedlich modelliert sind. In Bezug auf Semantik und Geometrie sind zwei grundlegende Repräsentationsformen zu unterscheiden, die Einzelgebäude-Repräsentation und die Gebäuderegion-Repräsentation (Tab. 5-1).

Werden Gebäude aus Bilddaten (Orthobilder, digitale Oberflächenmodelle, topographische Karten) extrahiert, so repräsentiert in der Regel jedes extrahierte Geoobjekt eine Region, die stellvertretend für ein Gebäude oder eine Gruppe zusammenhängender Einzelgebäude steht (Gebäuderegion-Repräsentation). Auch bei der Visualisierung der Topographie in Karten werden Gebäude als Regionen zusammengefasst dargestellt. In geotopographischen Datenbanken der Landesvermessung oder des Katasters liegt hingegen meist eine Einzelgebäude-Repräsentation vor[38]. Jedes Geoobjekt repräsentiert dabei ein freistehendes Einzelgebäude oder ein nichtfreistehendes Einzelgebäude eines Gebäudekomplexes. Diese Sicht entspricht auch dem Gebäudeverständnis der amtlichen Statistik.

[37] Das 3D-Modell im Klötzchenmodell entspricht 2D-Gebäudegrundrissen mit Höheninformation.
[38] mit Ausnahme einiger Bundesländer (Burckhardt, 2012)

Tab. 5-1: Repräsentationsformen von Gebäudegrundrissen

	Repräsentationsform	
	Einzelgebäude-Repräsentation	Gebäuderegion-Repräsentation
Bildbeispiel	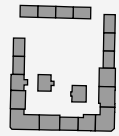	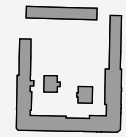
Definition	Gebäudegrundrisse repräsentieren freistehende und nichtfreistehende Einzelgebäude eines Gebäudekomplexes.	Gebäudegrundrisse repräsentieren freistehende Einzelgebäude oder Gebäudekomplexe durch die Region, die sich aus dem äußeren Umriss ergibt.
Datenbeispiel	Aus geotopographischen Datenmodellen (ALK/ALKIS®) entnommene Einzelgebäude	Aus Bilddaten extrahierte Gebäuderegionen (Fernerkundungsdaten, topographischen Rasterkarten)

Die Unterscheidung ist von zentraler Bedeutung bei der Modellierung, da dem Geoobjekt eine andere Semantik zugrunde liegt. Die zwei Repräsentationsformen haben auch unterschiedliche charakteristische Eigenschaften, was die Möglichkeiten der Merkmalsberechnung betrifft und müssen auch bei der Verfahrensentwicklung und -anwendung differenziert betrachtet werden.

5.4.2 Anforderung an den Abstraktionsgrad

An die Eingangsdaten werden geometrische Anforderungen bezüglich der Lagegenauigkeit und des Abstraktionsgrades gestellt. Die Anforderungen an die Gebäudegeometrie orientieren sich an dem internationalen 3D-Standard CityGML des *Open Geospatial Consortium* (Kolbe et al., 2008), der auch bei der INSPIRE-Umsetzung eine Rolle spielt (INSPIRE, 2011b). In Anlehnung an die Spezifikation für die 3D-Gebäudemodellierung im LOD1 ist eine absolute Lagegenauigkeit der Gebäudegrundrisse von besser als 5 m nötig. Im CityGML sind auch Erfassungsregeln festgelegt, die den Abstraktionsgrad bestimmen. Bei der Erfassung im LOD1 können beispielsweise alle Gebäude mit einer kleineren Grundfläche als 6 m x 6 m bzw. Gebäudekanten, die kürzer als 3 m sind, ignoriert werden (Kolbe et al., 2008).

Folgende zwei geometrische Anforderungen müssen demnach die 2D-Gebäudegrundrisse erfüllen:

- Absolute Lagegenauigkeit $\sigma_p \leq 5\ m$
- Aufnahme aller Gebäude mit einer Grundfläche $F_g \geq 36\ m^2$ (bzw. eine Kantenlänge $k \geq 3\ m$)

Es spielt dabei keine Rolle, ob eine Einzelgebäude- oder Gebäuderegionen-Repräsentation vorliegt.

5.4.3 Homogenität

Eine automatisierte Verarbeitung der Eingangsdaten setzt voraus, dass Gebäudegrundrisse in einem einheitlichen Datenmodell als Entität[39] modelliert sind. Die Gebäudegrundrisse eines betrachteten Untersuchungsraumes sollten dabei möglichst aus gleicher Quelle stammen bzw. mit vergleichbaren Methoden erfasst sein.

Setzen sich die Daten aus mehreren unterschiedlichen Geodatensätzen zusammen, müssen diese bei der Datenintegration geometrisch und semantisch harmonisiert werden (Bishr, 1998; Kampshoff, 2005). Semantische Heterogenitäten liegen beispielsweise vor, wenn einem Grundriss ein anderes Verständnis der Realweltobjekte zugrunde liegt (Einzelgebäude vs. Gebäuderegion). Bei syntaktischer Heterogenität sind Nutzungsattribuierungen nicht einheitlich kodiert (z. B. wird die Wohnfläche einmal mit dem String „Wbfl", ein anderes Mal mit „Wohnbaufläche" kodiert). Bei unterschiedlichem Detaillierungsgrad müssen die Daten auf ein einheitliches, meist niederaufgelöstes Datenabstraktionsniveau transformiert werden. Gebäudegrundrisse mit einer heterogenen Modellierung (Mischung von Einzelgebäude- und Gebäuderegion-Repräsentation) müssen beispielsweise zu Gebäuderegionen zusammengefasst werden. Durch Nutzung externer Daten, wie beispielsweise den Gebäudeadressen, können jedoch auch Gebäuderegionen durch Gebäudeteilung in Einzelgebäude überführt (Burckhardt, 2012) und somit auf ein höheraufgelöstes Abstraktionsniveau transformiert werden. Daten, denen ein inhomogener Erfassungsmaßstab zugrunde liegt, können mit Generalisierungsoperationen homogenisiert werden, in dem beispielsweise kleine Gebäude eliminiert werden oder die Geometrie vereinfacht wird. Genauso müssen die thematischen Informationen harmonisiert werden, die regional in unterschiedlicher semantischer Auflösung vorliegen können, wie z. B. die Gebäudefunktion der automatisierten Liegenschaftskarte. Für die semantische Harmonisierung müssen dann Aggregations- bzw. Zuordnungsregeln definiert werden, um räumliche Differenzen in der thematischen Auflösung zu beheben.

5.4.4 Metainformationen

Die verwendeten Daten müssen eine für die Aufgabenstellung angemessene Datenqualität besitzten. Die International Organisation for Standards (ISO) entwickelte Normen zur Qualitätssicherung von Geodaten. Nach der ISO 19113 sind für jeden Geodatensatz quantitative Informationen zur Vollständigkeit der Objekte und Attribute, logischen Konsistenz, Positionsgenauigkeit sowie zur zeitlichen oder thematischen Genauigkeit anzugeben (Kresse & Fadaie, 2004).

Amtliche Geobasisdaten der Länder sind gut dokumentiert, in der Regel vollständig und unterliegen regulären Fortführungszyklen, wie beispielsweise beim ATKIS® Basis-DLM, dessen Fortführung blattschnittweise alle 5 Jahre (Grundaktualität) bzw. 3 bis 12 Monaten für be-

[39] Jede Entität „Gebäudegrundriss" repräsentiert ein abstrahiertes Abbild des realen Objektes „Gebäude" hinsichtlich der räumlichen Lage und Ausdehnung (Geometrie) und zusätzlicher fachrelevanter Eigenschaften (Thematik).

stimmte Objektarten (Spitzenaktualität) erfolgt (BKG, 2011). Bei einer Nutzung der Daten müssen die entsprechenden Metainformationen mitgeführt werden, damit sie bei der Interpretation berücksichtigt werden können. Ohne entsprechende Metainformation, dies betrifft insbesondere Informationen zur Vollständigkeit und Aktualität nichtamtlicher Geodaten, kann die Datenqualität nur über eigene Validierungen abgeschätzt werden. So ist eine Vollständigkeit der Gebäudegrundrisse aus der OSM-Datenbank beispielsweise derzeit noch nicht gegeben, was Ergebnisse empirischer Arbeiten von Götz & Zipf (2012), Kunze (2012) und Hecht et al. (2013) belegen.

5.5 Methodische Vorüberlegungen

Nachdem die Anforderungen an das Verfahren und die Daten gestellt wurden, werden methodische Vorüberlegungen zur Herangehensweise getroffen. Daraus ergeben sich Rahmenbedingungen hinsichtlich der Interpretationsebene, Klassifikationsstrategie, Strategie zur Merkmalsberechnung sowie der Lernstrategie.

5.5.1 Interpretationsebene

Eine Interpretation der Bebauungsstruktur kann auf verschiedenen räumlichen Ebenen erfolgen (vgl. 4.1.3). Das hier entwickelte Verfahren zielt auf eine automatische Klassifizierung auf Ebene der Gebäudegrundrisse ab. Je nach Repräsentationsform nehmen Gebäudegrundrisse Bezug auf Einzelgebäude oder Gebäuderegionen. Die Gebäudegrundrisse werden dabei als Ganzes im Sinne eines „einfachen Musters" nach Niemann (2003) betrachtet, weshalb der Mustererkennungsprozess als Klassifizierung von Objekten in Kategorien oder Klassen aufgefasst werden kann. Unterschiedliche Repräsentationsformen führen auch zu begrifflichen Unterschieden der Zielklassen. Ein „Doppelhaus" in einer Gebäuderegion-Repräsentation muss in einer Einzelgebäude-Repräsentation streng genommen „Doppelhaushälfte" bezeichnet werden. In dieser Arbeit wird jedoch auf eine begriffliche Unterscheidung verzichtet, da sich die Bedeutung aus dem Kontext der verwendeten Datengrundlage erschließt.

5.5.2 Klassifikationsstrategie

Den wissensbasierten Ansätzen stehen datengetriebene Ansätze zur Klassifizierung von Gebäudegrundrissen gegenüber (vgl. Kap. 4.3). Bei Erstgenannten muss das Wissen über die Objekte aus Regelwerken, Handbüchern oder Expertenbeschreibungen abgeleitet und in einem Modell explizit bereitgestellt werden. Eine derartige Herangehensweise führt zwar zu einer hohen Transparenz, Nachvollziehbarkeit und Interoperabilität, diese ist jedoch nur bei leicht formalisierbaren Erkennungsproblemen mit eindeutig beschreibbaren Gebäudetypen realisierbar. Für die Erkennung von Gebäudetypen, die durch eine enorme Variabilität in Form, Größe und Struktur auf höherer Ebene geprägt sind, gestaltet sich dieser Ansatz als schwierig. Eine wissensbasierte Modellierung erfordert hierfür enormes Wissen und einen großen Aufwand bei der Formalisierung der Begriffe, Relationen und Eigenschaften, um sie in eine maschinenlesbare Form zu bringen. Weibel et al. (1995) sprechen in diesem Zusammenhang vom „knowledge acuisition bottleneck". Eine große Herausforderung besteht ins-

besondere in der Operationalisierung vager Objekte, wie beispielsweise zur Gebäudeanordnung (z. B. Ausrichtung, Regelmäßigkeit) (Lüscher et al., 2008b). Aktuell beforschte Ansätze, die wissensbasierte ontologische Interpretationsansätze mit statistischen Lern- und Klassifikationsverfahren kombinieren (Lüscher et al., 2009), zeigen am Beispiel der englischen Reihenhausbebauung ersten Erfolg. Allerdings muss für die Implementierung weiterer Typen noch viel Forschungsarbeit in die Konzeptualisierung des Wissens gesteckt werden.

Aus den Anforderungen des Verfahrens ging hervor, dass das Verfahren für die Anwendung auf verschiedene Probleme (adaptive Gebäudetypologie) und verschiedene Eingangsdaten möglich sein soll. Bei einem modellgetriebenen Ansatz müsste für jede neue Fragestellung und für jeden neuen Eingangsdatensatz das Wissen neu in Form von Merkmalen und Regeln in einem aufwändigen Modellbildungsprozess formalisiert werden. Einer derartig hohen Flexibilität kann derzeit nur mit einem datengetriebenen Ansatz begegnet werden, in dem das Wissen mit Methoden der Mustererkennung und des maschinellen Lernens automatisch aus Lerndaten abgeleitet wird. Das hat den Vorteil, dass vom Nutzer relativ wenig Vorwissen über die zu identifizierenden Gebäudeklassen abverlangt werden muss, da der Modellbildungsprozess von einer Maschine übernommen wird. In dem hier entwickelten Verfahren wird deshalb eine datengetriebene Klassifikationsstrategie verfolgt.

5.5.3 Merkmalsberechnung

Die Objektklassifizierung erfolgt auf Grundlage von Merkmalen, die automatisch aus den Daten abgeleitet werden. Die Wahl geeigneter Merkmale ergibt sich in der Regel aus dem zugrundeliegenden Klassifikationsproblem, weshalb diese in der Regel auf Grundlage von Vorwissen und Intuition gewählt werden. Bei der Klassifizierung sollte neben den Gebäudeeigenschaften auch der Kontext auf höherer räumlicher Ebene genutzt werden. Für die Beschreibung der Gebäude in topographischen Karten stützen sich Steiniger et al. (2008) auf wahrnehmungstheoretische Überlegungen und nutzen hierzu die Gestalt-Prinzipien nach Wertheimer. Darüber hinaus sollte es auch möglich sein, bereits explizit in den Daten modellierte Information (wie z. B. Attribute zur Nutzung, Gebäudehöhe etc.) zu nutzen.

In vielen Fällen gestaltet sich die Wahl eines geeigneten Merkmalssets schwierig, da der Mensch nicht in der Lage ist, die mit vagen Begriffen behafteten Gebäudeformen und deren räumliche Charakteristik zu formalisieren. In diesem Fall besteht die Möglichkeit, zunächst so viel Information wie möglich zu erheben, die für die Trennung der Klassen wichtig sein können. Mithilfe maschineller Lernverfahren zur Merkmalsselektion können dann redundante und unwichtige Merkmale identifiziert werden. Dieser Aspekt spielt insbesondere bei der praktischen Anwendung eines erlernten Klassifikators auf große Untersuchungsgebiete eine wesentliche Rolle, da damit unnötige Rechenzeit für die Merkmalsgewinnung vermieden werden kann.

5.5.4 Lernverfahren

Bei einer datengetriebenen Klassifikationsstrategie erfolgt der Modellaufbau nach dem Prinzip des „Lernens aus Beispielen", in dem anhand von Trainingsdaten eine Zuordnungsvorschrift (Klassifikator) erlernt wird. Verschiedene Arten des maschinellen Lernens wurden bereits in Kap. 3.2.2 diskutiert. Es stellt sich an dieser Stelle die Frage, ob eine überwachte oder unüberwachte Lernstrategie eingesetzt werden soll.

Unüberwachte Lernverfahren haben den Vorteil, dass keine gelabelten Trainingsdaten benötigt werden. Allerdings erfordert es nach Identifikation der Cluster eine nicht selten einfache Bedeutungszuordnung (vgl. Neidhart & Sester, 2004; Werder et al., 2010). Mit einem unüberwachten Verfahren besteht auch die Gefahr, dass seltene Klassen mit geringer Fallanzahl nicht identifiziert werden können, obwohl diese eventuell besonders wichtig für die weitere Modellierung wären. Ein weiterer Nachteil unüberwachter Verfahren ist, dass eine Qualitätsbewertung nur über intrinsische Gütekriterien durchgeführt werden kann. Ein Vergleich mit externen Referenzdaten erfordert hingegen die Zuordnung der Cluster zu den Referenzklassen.

Ein überwachtes Lernen setzt Trainingsdaten mit bekannter Klassenzugehörigkeit voraus. Dies bedeutet, dass die zu identifizierenden Gebäudeklassen bekannt sein müssen und genügend Trainingsobjekte bereitstehen. Im Falle einer Klassifizierung von Gebäudegrundrissen für die kleinräumige Modellierung hat der Nutzer häufig eine konkrete Vorstellung, welche Gebäudetypen relevant sind. Die Erhebung von Trainingsdaten ist allerdings in einem GIS einfach möglich bzw. kann auf bereits existierende Kartierungen zurückgegriffen werden.

Für das Verfahren wird eine überwachte Lernstrategie verfolgt, da nach dem Lernen keine aufwändige Interpretation der Cluster nötig ist und eine Abschätzung der Klassifikationsgenauigkeit direkt an den gegebenen Lerndaten erfolgen kann.

5.6 Konzepte der Modellierung

Um das Verfahren für verschiedene Anwendungen einsetzen zu können, werden grundlegende Konzepte und Beziehungen der Modellierung vereinbart. Als Eingangsdaten zur Beschreibung der Siedlung werden Gebäudegrundrisse, Flächennutzungsinformationen, Baublöcke und Hauskoordinaten benötigt.

5.6.1 Gebäudegrundrisse im Siedlungsraum

Gebäudegrundrisse stehen zu anderen Objekten im Siedlungsraum in Beziehung. Die wichtigsten Objekte sind in Abb. 5-2 schematisch dargestellt. Der *Untersuchungsraum* ist ein zweidimensionaler Ausschnitt der Erdoberfläche und wird vom Nutzer festgelegt. Dieser begrenzt den Raum für den der Klassifikator Gültigkeit besitzt und legt damit die Gesamtheit aller zu klassifizierenden Gebäude fest. Der Untersuchungsraum setzt sich aus *Siedlungsflächen* und *Freiraumflächen* zusammen. Zur *Siedlungsfläche* gehören alle *bebauten Flächen* und *Siedlungsfreiflächen*. Unter der *Siedlungsfreifläche* werden vorwiegend unbebaute Bereiche verstanden, die vor allem der Erholung und sportlichen Betätigung dienen (z. B.

Grünanlagen, Parks, Sportplätze, Stadien, Campingplätze, Schwimmbäder, Freizeitparks, Friedhöfe etc.). Die *bebauten Flächen* sind Grundstücke auf denen Wohn- und Geschäftsgebäude stehen, aber auch Gewerbe- und Industriegebiete sowie Flächen kirchlicher, kultureller oder sozialer Zwecke. Die Siedlungsfläche bezieht sich somit auf die besiedelte Fläche, deren Ausprägung sowohl städtisch als auch ländlich sein kann.

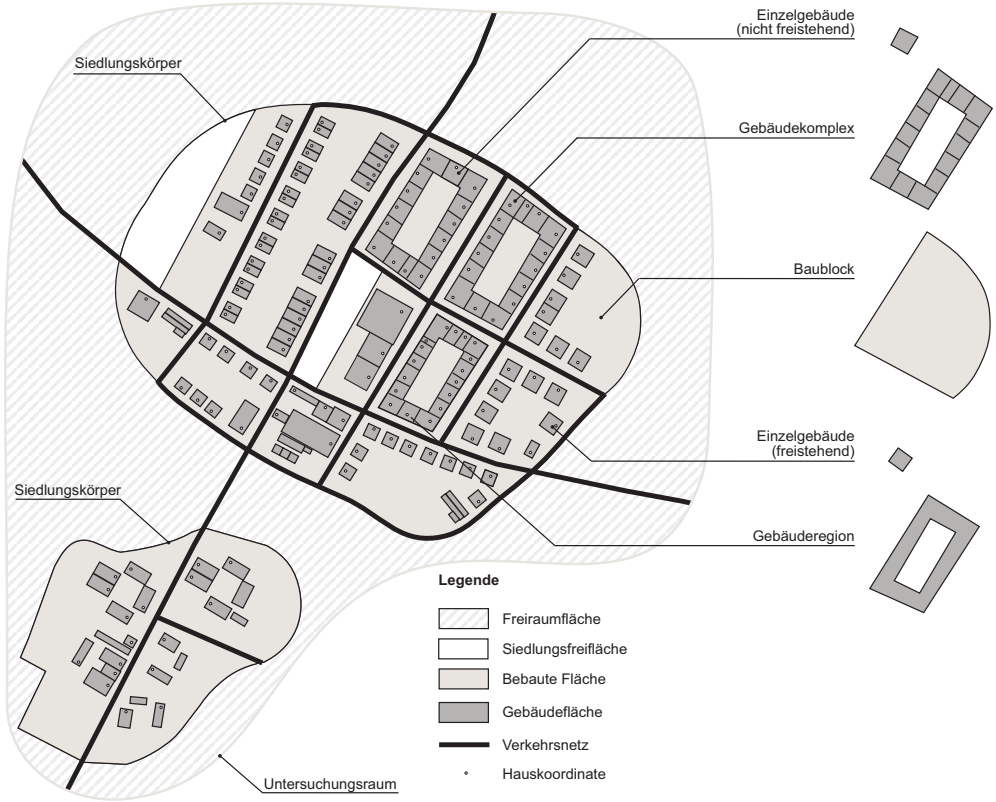

Abb. 5-2: Objekte der Modellierung

Eine räumlich zusammenhängende *Siedlungsfläche* bildet einen *Siedlungskörper*, dessen Lage und Ausdehnung sich durch eine äußere Kontur ergibt. Der Siedlungskörper wird durch das Verkehrsnetz (z. B. Straßen, Wege) und anderen topographischen Linienelementen (z. B. Gewässer) zerschnitten. Zusammen mit der Grenze der *bebauten Fläche* entsteht dabei ein Flächenmosaik aus *Baublöcken*.

Die *Baublöcke* enthalten *Einzelgebäude* als selbständig benutzbare und überdachte Bauwerke. Bei den *Einzelgebäuden* unterscheidet man *freistehende Einzelgebäude* und *nicht freistehende Einzelgebäude*. Ein *Gebäudekomplex* wird aus einer Gruppe benachbarter Einzelgebäude gebildet und steht für eine komplexe, vielgestaltige Einheit. Eine *Gebäuderegion* ergibt sich aus dem Grundriss eines *freistehenden Gebäudes* oder dem aus der inneren und äußeren Kontur gebildeten Grundrisses eines *Gebäudekomplexes*. Die *Einzelgebäude* können einen oder mehrere *Hauskoordinaten* enthalten, welche die geographische Lage eines Gebäudes über einen Koordinaten (Punkt) beschreibt.

5.6.2 Objektbeziehung

Die Gebäudegrundrisse können zusammen mit den anderen Objekten der Modellierung (z. B. Baublöcke, Siedlungskörper) in einem gemeinsamen konzeptionellen Klassendiagramm der Unified Modeling Language (UML) abgebildet werden (Abb. 5-3). Die Objektbeziehungen werden über Assoziationen entsprechend der UML-Notation (Balzert, 2005) dargestellt. In diesem Schema werden die semantisch-geometrischen Objektbeziehungen der Konzepte noch einmal deutlich. Die Oberklasse *GebäudegrundrissObjekt* wird mit den Unterklassen *Einzelgebäude* und *Gebäuderegionen* spezialisiert. Diese stehen wiederum untereinander in Beziehung. Diese konzeptionelle Sicht hilft dem Verständnis über die Begrifflichkeiten und dem Modellierungsunterschied zwischen Gebäuderegion- und Einzelgebäude-Repräsentation.

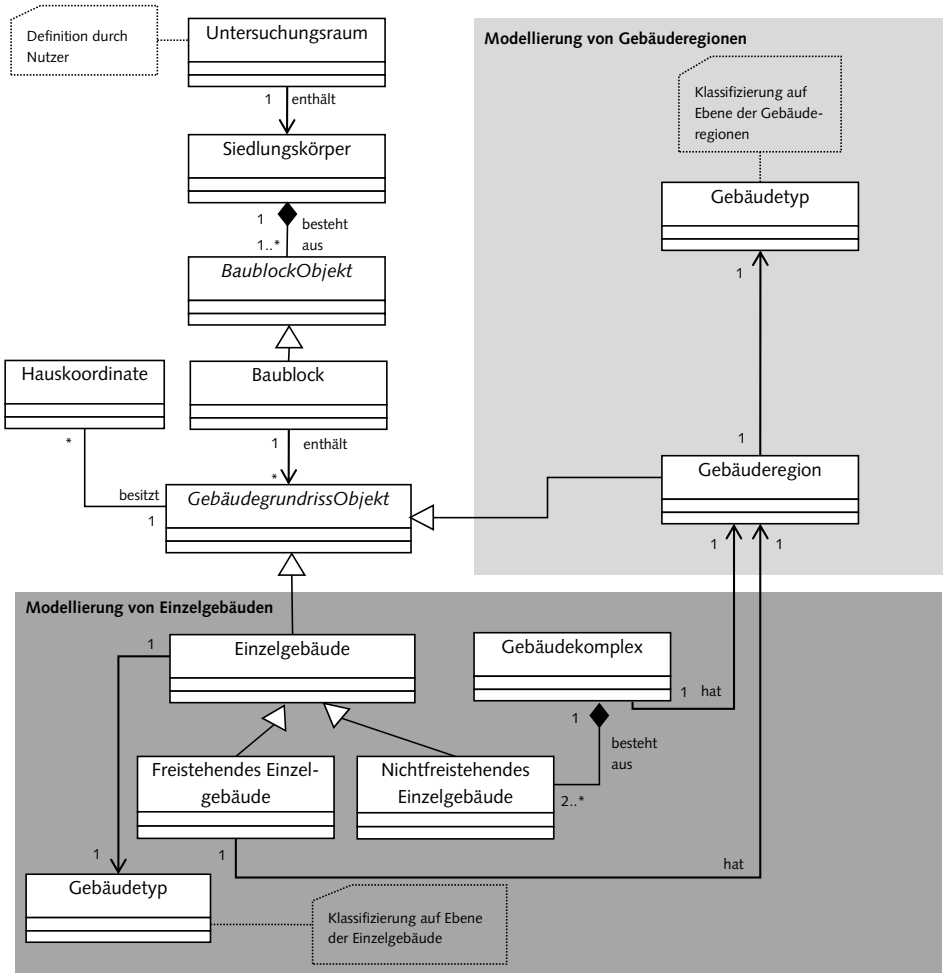

Abb. 5-3: Objekte des Siedlungsraums und deren Beziehungen im UML-Klassendiagramm

6 Mögliche Datenquellen zum Gebäudegrundriss

Mit den konzeptionellen Vorüberlegungen wurden Anforderungen an die Modellierung von Gebäuden gestellt. Im Folgenden werden verschiedene Datengrundlagen betrachtet, die diese Anforderungen erfüllen (Abb. 6-1). Dies sind einerseits Gebäudegrundrisse aus objektstrukturierten Datenmodellen (Vektordaten) und andererseits Bilddaten (Rasterdaten), im Speziellen digitale topographische Rasterkarten und Fernerkundungsdaten, die das Gebäude implizit abbilden.

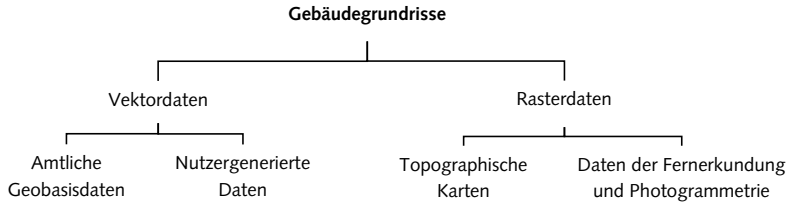

Abb. 6-1: Datengrundlage zum Gebäudegrundriss

6.1 Gebäudegrundrisse aus objektstrukturierten Datenmodellen

Im Folgenden wird die Gebäudemodellierung in objektstrukturierten Datenmodellen des amtlichen Vermessungswesens aber auch der nichtamtlichen, nutzergenerierten Geodatenbanken betrachtet.

6.1.1 Gebäudegrundrisse aus der ALK

Die Automatisierte Liegenschaftskarte[40] (ALK) ist ein Auslaufmodell des Liegenschaftskatasters und wird in Zukunft vom Amtlichen Liegenschaftskataster Informationssystem (ALKIS®) abgelöst. Die ALK enthält alle Haupt- und Nebengebäude im Grundriss. Die Erhebung, Führung und Bereitstellung der Liegenschaftskarte wird allerdings in Deutschland von insgesamt 291 verschiedenen Katasterämtern (Stand: 2011) durchgeführt (Burckhardt, 2012) und ist damit äußerst heterogen in Bezug auf die Erfassung der Geometrie und der Attribute zur Gebäudefunktion, Geschosszahl oder der Dachform. Für eine katasterübergreifende Bereitstellung werden die originären Daten über die einheitliche Datenbankschnittstelle (EDBS) auf Länderebene in einem Sekundärdatenbestand zusammengeführt. Die Verwaltungsvorschriften der Länder regeln, welche Nutzungsinformationen zum Gebäude erhoben werden. So müssen beispielsweise in Sachsen lediglich die Gebäudefunktionen *Wohnen (allgemein)*, *Wirtschaft und Gewerbe* und *Gemeinwesen* unterschieden werden, wobei auf eine Führung der Gebäudefunktion verzichtet wird, wenn das Gebäude aus Luftbilderzeugnissen (Folie 086) erfasst wurde (OBAK-LiKa SN, 2005; VwVLika, 2005). Der Objektabbildungskatalog

[40] In Bayern wird diese als Digitale Flurkarte (DFK) bezeichnet.

(OBAK) für die Liegenschaftskarte in Rheinland-Pfalz sieht hingegen eine zwingende Ausdifferenzierung der Gebäudefunktion für alle öffentlichen Gebäude sowie der Gebäude vor, die in der Karte durch Signatur dargestellt werden[41] (OBAK-LiKa RP, 2008). Inhalt und Umfang der in der ALK geführten Daten sind darum in den Ländern sehr heterogen, da der von der AdV erarbeitete Muster-OBAK lediglich eine Empfehlung darstellt und den einzelnen Ländern viel Spielraum bei der Vergabe von Attributen geboten wird (Seifert, 2004).

Die Gebäude sind in der ALK entsprechend dem Objektschlüsselkatalog (OSKA) in der Fachfolie 011 und Folie 084/086 nachgewiesen. Dabei werden die vom öffentlich bestellten Vermessungsingenieur vor Ort eingemessenen Gebäude in Folie 011 abgebildet. Die nicht katastermäßig erfassten Gebäude werden in Folie 084/086 aus Luftbilderzeugnissen der Landesvermessung ergänzt. Mit der hinterlegten Gebäudefunktion ist die zum Zeitpunkt der Erhebung vorwiegend funktionale Bedeutung des Gebäudes gemeint.

An dieser Stelle sei kurz auf den Aspekt der Aktualität der Gebäude in der ALK eingegangen. Zwischen dem Gebäudeneubau und der Aufnahme im Liegenschaftskataster vergehen in der Regel mehrere Monate. In Sachsen werden beispielsweise allein für die Fortführung etwa sechs Monate benötigt. Man geht davon aus, dass zwischen der realen Änderung und dem Niederschlag in der Datenbank durchaus ein Jahr vergehen kann (Burckhardt, 2012). Problematisch sind bauliche Veränderungen, da eine Neuvermessung nur auf Antrag durchgeführt wird, kostenpflichtig ist und auch ein berechtigtes Interesse beim Antragsteller vorliegen muss (Betzholz & Wöllper, 2010). In der Praxis finden deshalb bauliche Veränderungen kaum einen Niederschlag in den Daten, da die Motivation der Neueinmessung bei den Eigentümern wegen den damit verbundenen Kosten oft nicht sehr hoch ist und es an Überwachungsinstrumentarien fehlt. Eine regelmäßige flächendeckende Prüfung der tatsächlichen Verhältnisse vor Ort ist bei der ALK nicht gegeben.

6.1.2 Gebäudegrundrisse aus dem ALKIS®

Derzeit findet die Zusammenführung vom ALB und der ALK durch das ALKIS® statt (vgl. Anhang A.2.1.3). Im ALKIS®, dem das bundesweit einheitliche AAA-Modell zugrundeliegt, wird das Gebäude mit der flächenhaft modellierten Objektart „AX_Gebaeude“ in der Objektartengruppe „Angaben zum Gebäude“ des Objektartenbereichs „Gebäude“ modelliert. Es ist definiert als „ein dauerhaft errichtetes Bauwerk, dessen Nachweis wegen seiner Bedeutung als Liegenschaft erforderlich ist sowie dem Zweck der Basisinformation des Liegenschaftskatasters dient“ (AdV, 2008b). Die geometrische Beschreibung erfolgt durch die senkrechte Projektion des Gebäudekörpers auf die Erdoberfläche im definierten Umring und schließt alle zum Gebäude gehörenden Bauteile[42] mit ein.

[41] Ansonsten wird die Gebäudenutzung, ähnlich wie in Sachsen, „Wohn (oder öffentliches) Gebäude" oder „Wirtschafts- oder Industriegebäude" vergeben.

[42] Gebäudeteile, die gegenüber dem jeweiligen Objekt „Gebäude“ abweichende bzw. besondere Eigenschaften haben, wie beispielsweise von der dominanten Gebäudeform abweichende Geschosse, Durchfahrten und Arkaden, werden mit der Objektart „Bauteil“ als eigenständiges Objekt modelliert. Bauteile sind nicht Bestandteil des von der AdV definierten Grunddatenbestandes (AdV, 2008d).

Jedem Gebäude ist eine Gebäudefunktion mit dem Attribut „GFK“ zugewiesen. Die Gebäudefunktion ist die zum Zeitpunkt der Erhebung objektiv erkennbare vorherrschende funktionale Bedeutung des Gebäudes. Im ALKIS® müssen folgende Obergruppen von allen Bundesländern unterschieden werden (AdV, 2008b):

- Wohngebäude (GFK = 1000)
- Gebäude für Wirtschaft oder Gewerbe (GFK = 2000)
- Gebäude für öffentliche Zwecke (GFK = 3000)

Die Festlegungen zur verpflichtenden Unterscheidung dieser drei Obergruppen wurde auf Wunsch der Versorgungswirtschaft berücksichtigt und von der AdV als Grunddatenbestand definiert (AdV, 2008d). Alle anderen Nutzungsarten sowie die Vergabe weiterer Attribute, wie etwa zur Gebäudehöhe (HHO), der Geschossfläche (GFL), dem Baujahr (BJA), der Dachform (DAF), der Betriebsbereitschaft (ZUS), der Anzahl oberirdischer Geschosse (AOG) oder auch der Bauweise (BAW), sind optional und können im länderspezifisch, definierten Umfang geführt werden (AdV, 2008b). Ein Überblick über die derzeit geplanten länderspezifischen Inhalte zeigt jedoch ein äußerst heterogenes Bild (AdV, 2012b). Eine flächendeckende Homogenität und Vollständigkeit der Attribute ist deshalb nur für Inhalte gegeben, die dem von der AdV verabschiedeten Grunddatenbestand angehören. Die Kosten für Gebäude sind mit 1,80 € pro Objekt sehr hoch.

Mit Einführung des AAA-Modells und deren Versionierungsschema können in Zukunft Gebäudedaten auch multitemporal ausgewertet werden. Durch Historisierung wird bei jedem Gebäudeobjekt der Zeitpunkt der Entstehung und des Untergangs mitgeführt. Durch Ergänzung des ALKIS®-Basisschemas um optionale 3D-Basisklassen (entwickelt von der AG ALKIS® 3D) steht auch der Modellierung der dritten Dimension nichts im Wege (AdV, 2008d).

6.1.3 Gebäudegrundrisse aus ATKIS® Basis-DLM

Im ATKIS® Basis-DLM der Landesvermessung werden bundeseinheitliche Daten zur Geotopographie bereitgestellt. Das ATKIS® Basis-DLM sieht auch eine flächenhafte oder punkthafte Modellierung der Gebäude mit der Objektart 2315 vor (AdV, 2008c). Dem Gebäude kann entsprechend dem Objektartenkatalog auch eine Nutzung zugewiesen werden, wobei in der Regel lediglich zwischen Wohn-, Gewerbe- und öffentlichen Gebäuden unterschieden wird.

Gebäude im ATKIS® Basis-DLM sind häufig nicht Bestandteil der von den Landesvermessungsämtern herausgegebenen Daten. Aktuell bieten nur die neuen Bundesländer die Gebäude im ATKIS® an, da deren Datenqualität bedeutend höher ist als in der ALK und dem Produkt deshalb eine erhöhte Nachfrage zugrundeliegt[43].

[43] Die Datenqualität der ALK ist in den Bundesländern Sachsen und Mecklenburg-Vorpommern aufgrund der vernachlässigten Einmessungspflicht in den 1990er Jahren teilweise geringer als die aus Luftbild erfassten Gebäudedaten der Landesvermessung im ATKIS Basis-DLM (Burckhardt, 2012).

Mit der Einführung vom ATKIS® (AAA) im integrierten AAA-Modell ist das Gebäude in Zukunft mit der Objektart *AX_Gebaeude* definiert und besitzt ein Attribut zur Gebäudefunktion. Gebäude im ATKIS® gehören im Gegensatz zum ALKIS® nicht zum Grunddatenbestand (AdV, 2008c). Die Realisierung und Herausgabe der Gebäude bleibt den einzelnen Landesbehörden freigestellt. Einige Länder übernehmen im ATKIS® die Gebäude direkt aus dem ALKIS®, andere führen weiterhin zwei verschiedene Datensätze in den harmonisierten Modellen. Im ATKIS® werden zwar auch alle Gebäude vollständig modelliert, bei der Erfassung untergeordneter Gebäude, wie etwa Lagerschuppen, Einzelgaragen, Gartenhäuser, ist jedoch gegenüber dem ALKIS® eine Erfassungsgrenze von 50 m² angesetzt (AdV, 2008c).

6.1.4 Amtliche Hausumringe

Eine neue Form der Verbreitung gebäudescharfer Geoinformation wurde mit der Gründung der Gemeinschaft zur Verbreitung der Hauskoordinaten (GVHK), nun umbenannt in Zentrale Stelle für Hauskoordinaten und Hausumringe und 3D-Gebäudemodelle (ZSHH), gelegt. Die in der Bezirksregierung Köln eingerichtete ZSHH stellt flächendeckende, harmonisierte Datensätze zu Gebäuden in Form von Hauskoordinaten, Hausumringen und ab 2013 auch in Form von 3D-Gebäudemodellen bereit.

Mit dem angebotenen Produkt „amtliche Hausumringe" (HU) werden georeferenzierte Umringpolygone von Gebäudegrundrissen beschrieben. Es handelt sich dabei um die vereinigte und homogenisierte Menge aller Haupt- und Nebengebäude aus der Liegenschaftskarte (ALK/ALKIS®) (AdV, 2008a). Derzeit stehen für Deutschland ca. 47,6 Mio. Haupt- und Nebengebäude in amtlicher Qualität zur Verfügung. Semantische Informationen (z. B. zur Gebäudenutzung) wurden aus der Liegenschaftskarte nicht übernommen. Die Daten sind lediglich mit einem Attribut zum Amtlichen Gemeindeschlüssel (AGS) ausgestattet. Die Kosten für Hausumringe belaufen sich auf 0,12 € pro Objekt, wobei ein Bundesdeckel von 100 000 € festgelegt ist (AdV, 2010b).

6.1.5 3D-Gebäudemodelle (3D-Gebäudestrukturen)

Lärmkartierungen, Solarenergiepotenziale, Funknetzplanung und die Immobilienwirtschaft sind an der dritten Dimension der Gebäude interessiert. In einzelnen Bundesländern werden deshalb bereits flächendeckend 3D-Gebäudemodelle angeboten. Die Produktion basiert auf vorhandenen Datensätzen zum Gebäudegrundriss aus dem Liegenschaftskataster, Laserscannerdaten oder daraus abgeleiteten digitalen Gelände- und Oberflächenmodellen sowie zusätzlichen Adressdaten.

Ein landesweites 3D-Gebäudemodell wurde im Rahmen der von der EU verabschiedeten „Richtlinie über die Bewertung und Bekämpfung von Umgebungslärm" erstmalig im Jahr 2007 für Nordrhein-Westfalen erhoben und als „3D-Gebäudestrukturen" in die offizielle Produktpalette der Landesvermessung Geobasis NRW aufgenommen (Lämmel-Klevenhaus 2010). Zur Ermittlung der Gebäudehöhe wurden das Digitale Gelände- und Oberflächenmodell sowie die Höhe der Last-Pulse-Bodenpunkte verwendet. Bei fehlenden Laserdaten wurde die Höhe üblicherweise über die katastermäßig erfasste Geschossangabe und einer angenommenen mittleren Geschosshöhe von 3,20 m abgeschätzt. Bei fehlender Stock-

werksangabe wurde für die Gebäude eine pauschale Höhe von 9 m bzw. 3 m für kleine Gebäude unter 25 m² (Garagen, Gartenhäuser) angewendet. Für den Regierungsbezirk Düsseldorf liegen die 3D-Gebäudestrukturen bereits für das Jahr 2007, 2009 und 2011 vor.

In Sachsen wird derzeit ein 3D-Gebäudemodell im LOD2 aufgebaut (Kempe 2012). Die automatische Ableitung erfolgt jedoch auf Grundlage der Gebäudegeometrie aus dem ATKIS® Basis-DLM und den Laserpunkten einer landesweiten Befliegung. Grund für die Wahl der ATKIS®-Gebäudegeometrie ist die derzeitig lückenhafte Gebäudeerfassung in der ALK[44] in Sachsen. Wegen notwendiger manueller Nachbearbeitungen – die automatische Dacherkennung und Gebäuderekonstruktion ist nur zu 75 % erfolgreich – wird das Gebäudemodell Ende 2012 zunächst als LOD1 und später als LOD2 herausgegeben.

In einem Beschluss durch die AdV ist bis 2013 in einer ersten Realisierungsstufe eine Bereitstellung der 3D-Gebäudemodelle im Klötzchenmodell (LOD1) durch alle Länder vorgesehen. Eine zweite Realisierungsstufe im LOD2, die eine Modellierung der Dachformen beinhaltet, wird in Aussicht gestellt (AdV, 2010c). Damit werden in Zukunft 3D-Gebäudemodelle zum Produktportfolio des amtlichen Vermessungswesens gehören (Heitmann, 2011)

6.1.6 Gebäudegrundrisse aus OpenStreetMap

Nutzergenerierte Geodaten, auch als „Volunteered Geographic Information" (VGI) bezeichnet (Goodchild, 2007), werden für viele Anwendungen bereits als alternative oder zusätzliche Datenquelle verwendet. Mit dem populären Projekt OpenStreetMap (OSM) ist eine derartige Plattform gegeben. Mithilfe geeigneter Editoren, wie beispielsweise dem Java OpenStreetMap Editor (JOSM), können freiwillige Nutzer Daten auf Grundlage eingebetteter Luftbilder oder gemessener GPS-Tracks erzeugen, die anschließend in einer zentralen OSM-Datenbank veröffentlicht werden. OSM bietet ein breites Spektrum an Daten und Kartenanwendungen zu verschiedenen Themen an. Dabei werden unter anderem auch die Gebäude in ihrem Grundriss erfasst und mit einem „building"-Tag versehen. Der Gebäudedatenbestand aus OSM ist jedoch derzeit für flächendeckende Analysen noch nicht geeignet. Aktuelle Untersuchungen zeigen, dass zum Zeitpunkt Januar 2012 nur 5,461,059 Gebäude in OSM modelliert sind (Götz & Zipf, 2012). Gegenüber dem Gebäudebestand der amtlichen Statistik entspricht das einem Anteil von ca. 30 %. Eine entsprechende Attributierung der Gebäude zur Gebäudehöhe, Dachform, Stockwerkszahl oder Dachmaterial mithilfe der „keys" war nur in äußerst seltenen Fällen gegeben. Eine objektbasierte Vollständigkeitsanalyse anhand der amtlichen Hausumringe zeigte, dass sogar nur etwa 25,5 % (Nordrhein-Westfalen) bzw. 15,3 % (Sachsen) aller amtlichen Gebäude in OSM enthalten sind (Kunze, 2012; Hecht et al. 2013). Die Vollständigkeit ist dabei in urbanen Gebieten deutlich höher als in ländlichen Räumen.

[44] Nach Information der datenführenden Stelle (GeoSN) sind in der ALK von Sachsen ca. 10 % weniger Gebäude als im ATKIS enthalten. Dies ist einer vernachlässigten Einmeßpflicht der Gebäudebesitzer geschuldet.

Die OSM-Gebäudedaten sind für die Beschreibung der Siedlungsstruktur nur dann einsetzbar, wenn für den betrachteten Untersuchungsraum eine Vollständigkeit gegeben ist. Dies ist beispielsweise für die Stadt Rostock der Fall, deren Gebäude von der Stadtregierung dem OSM-Projekt zur Verfügung gestellt wurden (Stengel & Sascha Pomplun, 2010). Wegen der hohen Dynamik ist deshalb in Zukunft mit einer Verbesserung der Datenqualität zu rechnen, so dass diese eine kostenlose Alternative gegenüber den meist teuer zu erwerbenden Geobasisdaten darstellen.

6.2 Gebäudegrundrisse aus topographischen Karten

Bisher wurden Datengrundlagen betrachtet, in denen die Gebäude explizit im Vektormodell modelliert sind. Die amtliche Vermessung und Kartographie stellt jedoch verschiedene kartographische Produkte bereit, die das Gebäude implizit abbilden. Diese Daten sind insbesondere auch in der Hinsicht interessant, da auf deren Grundlage der Gebäudebestand der „vordigitalen" Zeit rekonstruiert werden kann.

6.2.1 Gebäuderepräsentation in topographischen Karten

Topographische Karten gibt es vorwiegend in Form von amtlichen topographischen Kartenwerken unterschiedlicher Maßstäbe. Bei der klassischen Herstellung dienten Zeichenvorschriften und Musterblätter als Grundlage für eine einheitliche Gestaltung. So wurde 1939 mit dem „Musterblatt für die Topographische Karte 1:25 000" (MBI 39) eine Vorschrift für die Ausführung topographischer Karten im Reichsgebiet erarbeitet (Krauss, 1969). Im Auftrag der AdV und unter Zuständigkeit des Landesvermessungsamtes Nordrhein-Westfalen wurde auf dieser Grundlage das Musterblatt MBI 67 erstellt und über die Jahre weiter überarbeitet (Landesvermessungsamt NRW 1967, 1981, 1993, 1998). Es diente als Grundlage für die Ausführung der Karten in den einzelnen Bundesländern. In der ehemaligen DDR galt eine vom Ministerium des Innern erarbeitete „Zeichenvorschrift, Instruktion und Redaktionsanweisung" (ACD13-16) als rechtsverbindliches Dokument (MdI, 1984). In der heutigen digitalen Herstellung wird die einheitliche kartographische Modellierung durch Signaturenkataloge (SK) gewährleistet, in dem die Gestaltung der Objektarten des DLM sowie Kriterien zur Generalisierung definiert sind.

Die Gebäude sind die wichtigsten Elemente topographischer Grund- und Spezialkarten. Die Abb. 6-2 zeigt die Darstellung verschiedener Bebauungsformen in deutschen topographischen Karten. Mit Verkleinerung des Maßstabes nimmt der Grad der Gebäudegeneralisierung zu. Bei einem Maßstab von 1: 25 000 werden nur kleinere Nebengebäude weggelassen und die Grundfläche etwas vergrößert. Mit kleiner werdendem Maßstab werden die Gebäude jedoch immer weiter vereinfacht, in dem Objektdetails weggelassen, Gebäude zusammengefasst oder vergrößert werden. Im innerstädtischen Bereich werden die Gebäude in der TK100 nur noch in einer Teilblockdarstellung repräsentiert. Die in Abb. 6-2 dargestellten Gebäude sind Ergebnis einer Digitalisierung (Körner, 2011). In der originalen TK10 wird der Gebäudeumriss von Einzelgebäuden dargestellt, während die Gebäude ab einem Maßstab 1: 25 000 im Vollton und damit in einer Gebäuderegion-Repräsentation abgebildet sind.

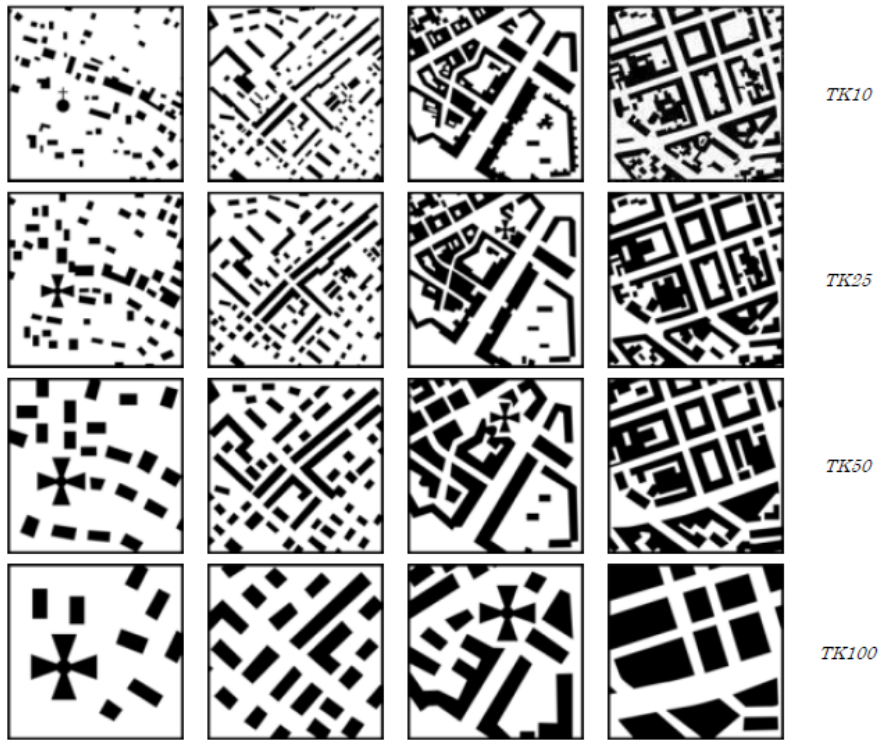

Abb. 6-2: Gebäudedarstellung in den topographischen Karten unterschiedlichen Maßstabs (TK10, TK25, TK50, TK100) für verschiedene Regionen: a) ländlich: Carlsfeld; b) vorstädtisch: Aue; c) städtisch: Dresden; d) innerstädtisch: Leipzig (Quelle: Körner, 2011)

6.2.2 Gebäudeextraktion aus gescannten topographischen Karten

Eine Möglichkeit zur Gewinnung räumlicher Informationen von Gebäudegrundrissen bieten Ansätze der kartographischen Mustererkennung (Stengele, 1995). Diese Verfahren erlauben die automatisierte Erfassung von Geoobjekten auf Grundlage analoger Kartenwerke und bieten daher auch einen Zugang zum historischen Gebäudebestand. Die Motivation, kartographische Muster automatisch zu erkennen, liegt in dem Wechsel der analogen Kartenherstellung zur computergestützten GIS-Kartographie und der damit einhergehenden automatischen Überführung aller Objekte in ein GIS. Die Entwicklung geeigneter Verfahren wurde bereits in den 1980er und 1990er Jahren vorangetrieben, als das Speichermedium Karte durch eine vermehrte digitale Datenhaltung abgelöst wurde. Erste Systeme zur automatischen Karteninterpretation waren beispielsweise die von Ejiri et al. (1984) oder Kasturi und Alemany (1988). Diese abfragebasierten Ansätze erlauben es, räumliche Objekte, wie Flächen, Linien aber auch Symbole und Schriften, in gescannten Karten zu erkennen.

Den Gebäudeobjekten wurde eine erhöhte Aufmerksamkeit geschenkt, da eine manuelle Digitalisierung dieser Objektklasse gegenüber anderen sehr zeit- und kostspielig war. Darum wurden Ansätze zur Gewinnung von Gebäudegrundrissen auf Grundlage topographischer Karten (Brügelmann, 1996; Frischknecht & Kanani, 1998; Frischknecht, 1999; Graeff, 2002; Stengele, 1995) oder Katasterkarten und großmaßstäbigen Plänen (Bringmann, 2003; Illert, 1991; Maderlechner & Mayer, 1994) entwickelt. Eine gute Übersicht zur bisherigen Entwicklung dieser Forschungslinie ist in Dhar & Chanda (2006) beschrieben.

Im Zuge der Wissensdigitalisierung besteht auch aktuell vermehrtes Interesse, historische Karten automatisiert auszuwerten, um Landnutzungsänderungen zu analysieren (Leyk & Zimmermann, 2006), die Entwicklung der Forstflächen zu beobachten (Leyk et al., 2006) oder die Siedlungsentwicklung der letzten Jahrzehnte zurückzuverfolgen (Hecht et al., 2008; Meinel et al., 2009). Mit einer Dissertation wird aktuell die Anwendung der kartographischen Mustererkennung für die gebäudebasierte Modellierung der Siedlungsentwicklung untersucht (Herold et al., 2010).

6.2.3 Maßstabsanforderungen an topographische Karten

Bei der Ableitung von Gebäuden aus topographischen Karten ist zu beachten, dass den abgebildeten Objekten bereits eine fachspezifische und maßstabsbedingte Generalisierung zugrundeliegt. Voraussetzung an die extrahierte Gebäudegeometrie ist, dass sie das Gebäude mindestens grundrißtreu bzw. grundrissähnlich wiedergibt, damit die für die Aufgabenstellung relevanten Gebäudeobjekte mithilfe objektbeschreibender Merkmale beschrieben und klassifiziert werden können. Kleine Gebäude erfahren bereits im Maßstab 1: 25 000 eine geringe Vergrößerung in der Fläche. Ab einem Maßstab von 1: 50 000 muss man bereits mit einer 1,5- bis 2-fachen Vergrößerung, im Maßstab 1: 100 000 mit bis zu 4-facher Vergrößerung der Gebäude rechnen (Müller, 1990).

Dass der Maßstab 1: 25 000 einen Grenzmaßstab für die Anwendung darstellt, kann durch eine analytische Betrachtung der Kartengenauigkeit hergeleitet werden. Der Maßstab bestimmt die noch wahrnehmbare graphische Mindestgröße (Minimaldimension) sowie die Lagegenauigkeit der dargestellten Kartenobjekte. Bei der Herstellung topographischer Kar-

ten wird in der Regel eine absolute Lagegenauigkeit von 0,2 mm angestrebt (Bollmann & Koch, 2001). Die Lagegenauigkeit σ_p von 5 Meter kann demzufolge nur mit topographischen Karten im Maßstab 1: 25 000 und größer garantiert werden. Die Mindestgrundflächengröße zur Darstellung von Gebäuden ist mit 7,5 m x 7,5 m etwas größer als die vom Verfahren geforderte Erfassungsuntergrenze von 6 m x 6 m. Wegen der Vergrößerung der Kartenobjekte bei geringfügiger Unterschreitung der Minimaldimension ist jedoch davon auszugehen, dass auch die kleinen Gebäude der Größe von 6 m x 6 m in der Karte dargestellt werden.

In Abb. 6-3 ist ein Ausschnitt eines Wohngebietes mit kleinen Gebäuden dargestellt. Dabei wird deutlich, dass kleine Wohngebäude zwischen 30 m² und 40 m² Grundfläche in der Digitalen Topographischen Karte im Maßstab 1: 25 000 (DTK25-V) noch dargestellt sind, kleine Nebengebäude jedoch bereits weggelassen wurden. Der Maßstab stellt damit einen Grenzmaßstab dar, weshalb prinzipiell alle topographischen Karten im Maßstab 1: 25 000 und größer für die Anwendung im Verfahren eingesetzt werden können.

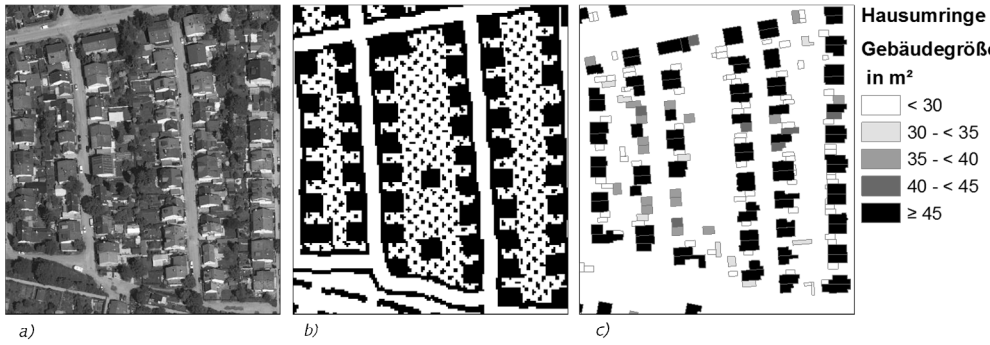

Abb. 6-3: Darstellung kleiner Wohngebäude: a) Digitales Ortholuftbild, b) DTK25-V und c) amtliche Hausumringe mit farbcodierter Gebäudegrundfläche (Quelle: Eigene Darstellung auf Grundlage der DTK25-V, DOP40 und amtlichen Hausumringen ©GeoBasis-DE/BKG (2011))

6.2.4 Scandichte topographischer Karten

Topographische Karten oder Originalfolien müssen mit einem Scanprozess einer Analog-Digital-Wandlung unterzogen werden, wobei der Informationsverlust durch Wahl einer entsprechenden Auflösung möglichst gering zu halten ist. In der Regel wird für die automatische Interpretation topographischer Karten eine Scandichte von 50 µm (500 dpi) als ausreichend erachtet (vgl. Deseilligny et al. 1998; Illert, 1991).

Die geometrische Anforderung an die Scandichte lässt sich auch theoretisch herleiten. Dem Abtasttheorem folgend wird zur Rekonstruktion eines Signals ein Digitalisierungsintervall *T* benötigt, das kleiner als die halbe Wellenlänge des kurzwelligsten Anteiles des Signals λ_{min} ist (Bollmann, 2001).

Daraus ergibt sich das Abtasttheorem:

$$T < \frac{\lambda_{min}}{2} \qquad (6.1)$$

Beim Scannen topographischer Karten ergibt sich die Größe λ_{min} aus den graphischen Mindestgrößen der Gebäudedarstellung (vgl. Abb. 6-4). Gebäude in topographischen Karten müssen eine Ausdehnung von mindestens 0,3 mm bzw. einen Zwischenraum zwischen zwei Gebäuden von mindestens 0,15 mm aufweisen (Hake et al., 2002). Bei einem Kartenmaßstab von 1: 25 000 entspricht das 7,5 Meter bzw. 3,75 Meter in der Realität. Der Zwischenraum als kleinste Größe bestimmt das kurzwelligste Signal λ_{min}. Aus dem Abtasttheorem ergibt sich damit ein Digitalisierungsintervall T < 0,075 mm (75 µm), was einer Scanauflösung von mindestens 134 Linien pro cm (ca. 340 dpi) entspricht.

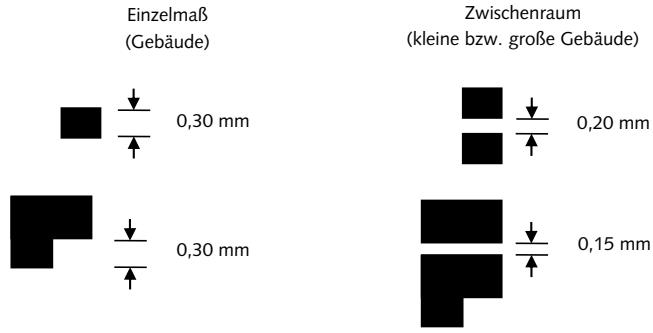

Abb. 6-4: Graphische Mindestgrößen von Gebäuden in topographischen Karten bei maximalem Kontrast (Quelle: Eigene Darstellung in Anlehnung an Hake et al. (2002))

Digitale topographische Rasterdaten werden üblicherweise georeferenziert in einheitlichen Rasterauflösungen von 100 bzw. 200 Linien pro cm (entspricht 254 bzw. 508 dpi) gescannt und erfüllen damit die Anforderungen. Beim Scan einer TK25 mit 508 dpi entspricht die Rasterweite dann 1,25 m in der Natur. Mit Blick auf eine automatisierte Gebäudeextraktion spielt neben der Scandichte auch der Tonwertumfang eine Rolle. Beim Scannen farbiger Karten empfiehlt sich das Speichern als 24-bit RGB-Farbbild.

6.2.5 Topographische Karten der amtlichen Vermessung

Im Folgenden werden Produkte der amtlichen Vermessung vorgestellt, die den festgelegten Datenanforderungen an den Maßstab entsprechen und prinzipiell für eine Anwendung im Verfahren geeignet sind. Dabei handelt es sich um topographische Karten mit einem Maßstab von mindestens 1: 25 000 und größer.

6.2.5.1 Digitale Stadtkarten (DSK)

Digitale Stadtkarten im Maßstab 1: 500 bis 1: 1 000 bilden die Einzelgebäude in einer Umrißsignatur und mit hoher geometrischer Genauigkeit ab. Diese Karten werden von städtischen Vermessungsämtern erfasst, fortgeführt und angeboten und sind deshalb häufig nur für größere Städte verfügbar (Meinel et al., 2008a). Wegen der dezentralen Erfassung und der fehlenden Flächendeckung sind Digitale Stadtkarten – gleiches gilt auch für digitale Ortspläne – nur für lokale städtische Betrachtungen relevant. Diese sollen aber an dieser Stelle der Vollständigkeit halber mit aufgeführt sein.

6.2.5.2 Digitale Grundkarten 1: 5 000 (DGK5)

Die Rasterdaten der Deutschen Grundkarte 1: 5 000 (DGK5) sind eine kleinmaßstäbige Planungsunterlage. In den alten Bundesländern war sie Grundlage für die Ableitung von Folgekarten. In der ehemaligen DDR wurde die DGK5 vom eigenständigen Kartenwerk im Maßstab 1: 10 000 abgelöst und wird heute in den neuen Bundesländern nicht geführt. Die Zeichenerklärung der DGK5 sieht eine Einzelgebäuderepräsentation vor, wobei der Gebäudetyp durch Schraffuren in Wohngebäude, Wirtschafts- und Industriegebäude, öffentliche Gebäude, Hochhaus, Gewächshaus differenziert wird. Kirchen werden durch eine entsprechende Signatur repräsentiert (Landesvermessungsamt NRW, 1995). Die wenigen Bundesländer, die dieses Kartenwerk oder vergleichbare Produkte anbieten, leiten dieses aus Vektordatenbeständen automatisch ab und stellen diese in Form von Rasterdaten zur Verfügung[45]. Von einer deutschlandweit flächendeckenden Verfügbarkeit kann bei der DGK5 nicht gesprochen werden.

6.2.5.3 Digitale Topographische Karte 1: 10 000 (DTK10)

Die Digitale Topographische Karte (DTK10) im Maßstab 1: 10 000 ist ein Produkt der amtlichen Landesvermessung und enthält die vollständige Darstellung der Einzelgbäude. Derzeit werden diese Karten nur in den neuen Bundesländern (Berlin, Brandenburg, Mecklenburg-Vorpommern, Sachsen, Sachsen-Anhalt und Thüringen) geführt. Die anderen Bundesländer stellen bezüglich des Inhaltes und der Spezifikation nur vergleichbare Produkte[46] bereit (AdV, 2010a). Entsprechend dem Signaturenkatalog (ATKIS-SK10) werden öffentliche und nicht öffentliche Gebäude hinsichtlich ihrer Nutzung farblich in einer Volltondarstellung unterschieden. Hochhäuser werden durch eine gesonderte Konturdarstellung gekennzeichnet. Die Karten werden aus dem Basis-DLM automatisch abgeleitet. In einigen Ländern wird jedoch eine vorläufige Ausgabe in Form der DTK10-V angeboten, die durch Scannen der analogen Topographischen Karte 1: 10 000 gewonnen wird. In der ehemaligen DDR wurden die Gebäude jedoch durch ihren Umriß und einer Flächenschraffur zur Unterscheidung der Funktion dargestellt. Demzufolge ist das Kartenbild in den einzelnen Bundesländern noch sehr he-

[45] z. B.Geobasis NRW in Nordrhein-Westfalen

[46] Beispielsweise wird in Bayern ein vergleichbarer Datensatz in Form der Digitalen Ortskarte (DOK), in Schleswig-Holstein in Form der Rasterkarte 1: 10 000 (RK10) im Saarland die Arbeitskarte 1: 10 000 (AK10) oder in Bremen mit der Digitalen Straßenkarte 1: 10 000 (DSK10) geführt (AdV, 2010a).

terogen. Die DTK10(-V) wird in separierten Inhaltdateien oder in einer Rasterdatei als mehrfarbige Ebenenkombination mit einer Auflösung von 508 dpi von den einzelnen Bundesländern bereitgestellt.

6.2.5.4 Digitale Topographische Karte 1: 25 000 – vorläufige Version (DTK25-V)

Die Digitale Topographische Karte in der vorläufigen Version (DTK25-V) ist ein durch Scannen einzelner analoger Farbfolien der analogen Karte erzeugter Rasterdatensatz und ist als vorläufige Version der DTK25 angedacht. Diese Rasterdaten werden in unterschiedlicher Auflösung von 100 bzw. 200 Punkten/cm (entspricht 254 bzw. 508 dpi) flächendeckend in Form von Einzelblättern angeboten. Die Rasterdaten bestehen aus maximal 6 Inhaltsebenen (Einzellayer). Der Grundrisslayer (Inhaltsebene 1) enthält die topographischen Elemente Gebäude, Schrift, Grenzlinien, Verkehrswege und Vegetationssignaturen. Zur weiteren Differenzierung kann der Grundrisslayer in weitere Kanäle aufgegliedert sein. Im Kanal 1, dem Grundriss im engeren Sinne, sind die grundrissprägenden Inhalte wie Gebäude, Straßen und Grenzlinien enthalten. Im Kanal 3 kann die Schrift separiert abgespeichert sein. Aus einer deutschlandweiten Untersuchung zur Belegung der Kanäle des Grundrisslayers der DTK25-V ging hervor, dass starke länderspezifische Unterschiede vorherrschen (Meinel et al., 2008b). In dieser Studie wird neben der Kanalbelegung auch auf die unterschiedlichen Schriftfreistellungsvarianten, die Gebäudedarstellung (Gebäuderegion vs. Teilblockdarstellung) und insbesondere auf die Kartenqualität eingegangen. Es hat sich gezeigt, dass die Gebäude in den meisten Fällen zusammen mit anderen schwarzen Kartenelementen, wie Straßen-, Vegetations- und Schriftsignaturen, im Grundrisslayer vorgehalten werden. Aktuelle Kartenblätter der DTK25-V liegen für die gesamte Bundesrepublik flächendeckend vor und werden von den Landesvermessungsämtern oder zentral über das Bundesamt für Kartographie und Geoodäsie vertrieben. In der Regel wurden sie aller 5 Jahre aktualisiert. Ältere Karten werden von einigen Landesvermessungsämtern als digitale Rasterkarte in der Form einer DTK25-V aufbereitet und für verschiedenste Zeitstände zur Verfügung gestellt.

6.2.5.5 Digitale Topographische Karte 1: 25 000 (DTK25)

Derzeit ist in den Ländern die Umstellung auf den digitalen Kartenherstellungsprozess fast abgeschlossen und die vorläufige digitale Version DTK25-V wird durch die Digitale Topographische Karte 1: 25 000 (DTK25) in neuer Kartengraphik abgelöst. In der DTK25 sind die Gebäudeflächen in einem separaten Layer mit der Bezeichnung *Haus* gespeichert, was eine Extraktion der Gebäude nicht erforderlich macht und diese mittels Raster-Vektor-Konvertierung gewonnen werden können. Dieses Kartenprodukt wird weitgehend automatisiert aus den objektstrukturierten Daten des ATKIS® Basis-DLM abgleitet. Dabei erfolgt eine Modell- sowie kartographische Generalisierung unter Einsatz verschiedener Programmsysteme. Bekanntestes Programmsystem zur automatischen Generalisierung von Gebäuden ist das an der Universität Hannover entwickelte Programm CHANGE, dass u. a. zur Herstellung der DTK25 in Niedersachsen und Brandenburg verwendet wird (Schulz, 2000; Theile, 2002). Gegenüber der alten Kartengraphik TK25 bzw. DTK25-V unterliegen die Gebäude der neuen DTK25 nach Einschätzung des Autors einer etwas stärkeren kartographischen Generalisierung. Umfang und Einsatz von Generalisierungsprogrammen und deren

Parametrisierung wird von den Ländern gestaltet, was zu länderspezifischen Eigenschaften in der Gebäudedarstellung führt. Auch befinden sich derzeit noch einige Länder in der Umbruchphase und bieten die DTK25 nur in Form der DTK25-V an.

6.2.5.6 Historische Kartenwerke

Die Topographische Karte 1: 25 000 ist seit der preußischen Uraufnahme und spätestens seit Beginn des 20. Jahrhunderts ein Standardprodukt der topographischen Vermessung. Ältere Ausgaben dieser Karten werden bei den Landesbehörden archiviert und können bei Bedarf in Form einzelner Kartendrucke reproduziert werden. Dabei werden die archivierten Kartendrucke mit präzisen Scannern digitalisiert (Scanauflösung von 1016 dpi oder 508 dpi) und als Farbkopie auf Papier oder in Form von georeferenzierten Rasterdateien in RGB mit 8-bit pro Kanal gegen Entgelt[47] vertrieben.

Dass die digitale Verfügbarkeit historischer Karten in Zukunft steigen wird, zeigen auch Projekte wie das Kartenforum (Buchroithner et al., 2006). In diesem von der Deutschen Fotothek[48] betreuten und der Deutsche Forschungsgemeinschaft (DFG) geförderten Informationsportal wurden bereits 12 000 historische Karten und Ansichten der Sächsischen Landesbibliothek – Staats- und Universitätsbibliothek Dresden (SLUB) und anderer Einrichtungen digitalisiert (Link & Wiegand, 2011). Mit Großformatscannern wurden ca. 6 000 Messtischblätter im Maßstab 1: 25 000 (Sächsische Landesaufnahmen der Jahre 1860-1935) hochaufgelöst eingescannt und stehen der wissenschaftlichen Nutzung online zur Verfügung, allerdings unrefererenziert.

6.3 Gebäudegrundrisse aus Fernerkundungsdaten

Neben den digitalen topographischen Vektor- und Rasterdaten eignen sich für die Anwendung auch Gebäudegrundrisse, die mit Methoden der Fernerkundung und Photogrammetrie gewonnen werden. Der kleine aber wesentliche semantische Unterschied ist, dass diese Gebäudegrundrisse in den meisten Fällen nicht den Grundriss, sondern eine orthogonale Projektion der Dachfläche (häufig auch mehrerer Dächer in einer Region) repräsentieren. Bei einer weiteren Modellierung muss darum der Dachüberstand berücksichtigt und von der Dachfläche abgezogen werden, um die Grundfläche rechnerisch zu ermitteln.

6.3.1 Anforderung an die geometrische Auflösung

Aus der Verfahrensanforderung geht hervor, dass die zugrundliegenden Gebäudegrundrisse mindestens alle Gebäude beinhalten sollten, die das Maß von 6 m x 6 m nicht unterschreiten. Bei der Gewinnung von Gebäuden aus Fernerkundungsdaten muss eine entsprechend hohe geometrische Auflösung vorliegen, die es erlaubt, selbst kleine Gebäude zu erkennen. Hierfür wäre theoretisch eine Bodenauflösung von mindestens 3 m nötig. Allerdings muss

[47] Die Kosten belaufen sich bei farbigen Plots zwischen € 3,75 (Sachsen-Anhalt) und € 30,00 (Niedersachsen) und bei digitalen Scans der Fortführungsoriginale zwischen € 15,00 und € 300,00.

[48] Deutsche Fotothek: www.deutschefotothek.de

auch sichergestellt sein, dass eng beieinanderstehende Gebäude voneinander getrennt wahrnehmbar sind. Darum ergibt sich die nötige Bodenauflösung aus dem kleinsten theoretischen Abstand der Gebäude in der Realität. In Deutschland legt die Abstandsflächenregelung der Musterbauordnung den einzuhaltenden Mindestabstand von 3 m zwischen Gebäuden fest (MBO, 2002)[49]. Nach dem Abtasttheorem wäre dann eine Bodenauflösung kleiner als 1,5 m nötig, um zwei benachbarte Gebäude getrennt voneinander wahrzunehmen. Eine derartige Auflösung ist nur mit sehr hoch bzw. extrem hoch auflösenden Fernerkundungssystemen gegeben, deren abgeleitete Bilddaten eine Bodenauflösung von etwa 0,5 m-1,0 m bzw. 0,1 m-0,5 m besitzen (Neubert, 2006). Gleiches gilt für Laserscannerdaten, deren Bodenauflösung bzw. Punktabstand entsprechend klein sein muss. In der Praxis werden heutzutage mit modernen Laserscanner-Systemen Punktdichten von 5-10 Punkten pro m² erreicht.

Für die Gewinnung von Gebäudegrundrissen können deshalb folgende bildgebende Aufnahmesysteme Anwendung finden, da sie die Anforderungen an die Auflösung erfüllen:

- Satellitengestützte Fernerkundungssysteme, wie IKONOS, Quickbird, EROS-B oder GeoEye-1
- Flugzeuggetragene analoge oder digitale Messbildkameras, wie CIR-Meßbildkamera, HRSC, ADS oder DMC
- Flugzeuggetragene Laserscanningsysteme mit einer Punktdichte von mehr als 1 Punkt pro m²

Photogrammetrische und fernerkundliche Methoden erlauben es auf dieser Grundlage, Gebäude automatisch in den Bilddaten oder Punktwolken zu erkennen und in 2D-Gebäudegrundrisse oder 3D-Gebäudemodelle zu überführen.

6.3.2 Gebäudeextraktion aus Fernerkundungsdaten

Die automatische Gebäudeerkennung und -rekonstruktion stellt seit vielen Jahren einen wichtigen Forschungsschwerpunkt in der Photogrammetrie und der Fernerkundung dar, und es liegt ein breites Spektrum an Veröffentlichungen vor. Die Sammelbände des internationalen Worshops „Automatic Extraction of Man-Made Objects from Aerial and Satellite Images“ (Baltsavias et al., 2001; Gruen et al., 1995, 1997) sowie Mayer (1999) und Gruen (2008) geben einen umfassenden Überblick über die bildbasierte Gebäudeextraktion aus Luft- und Satellitenbildern.

Die automatische Erkennung zweidimensionaler Gebäudegrundrisse aus Satellitenbilddaten basiert in der Regel auf einer Auswertung der spektralen Signatur, Textur und Morphologie segmentierter Bildregionen und einer anschließenden Klassifikation. In der urbanen Fernerkundung werden hierzu satellitengestützte Fernerkundungssysteme wie IKONOS (Geiß et al., 2011; Lee et al., 2003; vgl. Wurm et al., 2009), Quickbird (Dutta & Serker, 2005) o-

[49] Die Bauaufsichtsbehörde kann jedoch auch örtlich Abweichungen zulassen.

der der jüngste in Betrieb genommene Sensor GEOEye-1[50] (Dey et al., 2011; Grigillo & Fras, 2011) eingesetzt. Ergebnis einer derartigen Analyse auf Grundlage von Satellitenbilddaten sind Gebäudegrundrisse, die eine Gebäuderegion repräsentieren. Eine Modellierung von Einzelgebäuden ist erst mit Luft- und Sattelitenbilddaten ab einer geometrischen Auflösung von 0,5 Meter und kleiner möglich. Erst dann sind Brandmauern deutlich in den Bilddaten erkennbar und können genutzt werden, um die segmentierten Gebäuderegionen weiter in einzelne Gebäude aufzuteilen (Mayer, 2004).

Mithilfe von Stereoluftbildern oder mehreren Bildern aus unterschiedlichen Blickrichtungen lassen sich ganze 3D-Gebäudemodelle rekonstruieren (u. a. Fischer et al., 1998; Suveg, 2002). Auch multispektrale und panchromatische Stereo-Bilddaten satellitengestützter Fernerkundungssysteme, wie z. B. IKONOS oder Quickbird, können für eine dreidimensionale Gebäudemodellierung genutzt werden (u. a. Mosch, 2005; Xiong & Zhang, 2006). Bilddaten allein liefern jedoch meist nicht genügend Informationen für eine widerspruchsfreie Gebäuderekonstruktion, so dass andere Daten, wie etwa Digitale Oberflächenmodellen oder Grundrisse aus dem Liegenschaftskataster, hinzugezogen werden, um die Erkennungsleistung zu erhöhen (Cheng et al., 2008; Haala, 1996; Pasko & Gruber, 1996).

Das flugzeuggetragene Laserscanning (LiDAR – Light Detection and Ranging) ist ein aktives System, basierend auf der Laufzeitmessung reflektierter Laserimpulse. Es erlaubt eine effiziente dreidimensionale Erfassung der Erdoberfläche und der darauf befindlichen Objekte. Mit photogrammetrischen Verfahren können aus den Daten zwei- und dreidimensionale Gebäudemodelle automatisch generiert werden (Vosselman & Maas, 2010). Einfache Verfahren basieren auf interpolierten Rastermodellen, wie dem Digitalen Geländemodell (DGM) und dem Digitalen Oberflächenmodell (DOM), dessen Differenz zu einem normalisierten Digitalen Oberflächenmodell (nDOM) führt und Grundlage für eine Segmentierung von Gebäuderegionen ist. Bei der Rekonstruktion von 3D-Gebäudemodellen wird hingegen meist direkt mit den Punktdaten gearbeitet. Dabei kann ein parametrisiertes Gebäudemodell in die Punktwolken eingepasst (*model-driven*) oder geometrische Primitive (ebene Dachflächen) extrahiert werden, die in einem weiteren Schritt zu komplexen Gebäudemodellen zusammengesetzt werden (*data driven*) (Vosselman & Maas, 2010).

Flugzeuggetragene Hyperspektraldaten, wie die des HyMap-Sensors, eignen sich wegen der zu geringen geometrischen Auflösung nicht für die Gewinnung von Gebäudegrundrissen. Mit der extrem hohen spektralen Auflösung sind diese jedoch eine vielversprechende Ergänzung zur Unterscheidung verschiedener Dachmaterialien (Heiden & Heldens, 2010; Heiden, 2004). Ein größeres Potenzial wird neuerdings auch in der bildgebenden Radarfernerkundung gesehen. Mit modernen flugzeuggetragenen Radarsystemen mit synthetischer Apertur (SAR) können Bilddaten mit einer räumlichen Auflösung von bis zu 20 cm erreicht werden (Sörgel, 2006). Erste Ansätze zur automatisierten Rekonstruktion von Gebäuden sind in den Arbeiten von Bolter & Leberl (2000), Gamba et al. (2000) und Thiele et al. (2007) beschrie-

[50] ehemals geplant als OrbView 5

ben. Den systembedingten Artefakten eines Schrägsicht-SAR (Verschattung, Signalverkürzung, Signalüberlappung) kann zwar durch Mehrfachbeleuchtung (Multiaspekt-SAR) begegnet werden, in eng bebauten Siedlungsbereichen bleiben diese jedoch problematisch (Sörgel, 2006). Eine praktische Anwendung der Technologie ist damit noch nicht gegeben. Die Daten bieten aber wichtige ergänzende Informationen in integrativen Verfahren.

Auch wenn bereits viele Ansätze zur Gebäudeextraktion und -rekonstruktion existieren, so ist eine vollautomatische Ableitung allein auf Bilddaten derzeit noch nicht mit hinreichender Genauigkeit möglich (Gruen, 2008). Die Erkennungsrate ist bei satellitengestützten Ansätzen deutlich unter 90 % (Lee et al., 2003; Shan & Lee, 2005). Durch Kombination mit LiDAR-Daten kann die Erkennungsrate jedoch auf über 90 % erhöht werden (Hermosilla et al., 2011; Sohn & Dowman, 2007). Problematisch sind jedoch der hohe Anteil fälschlich erkannter (falsch-positiver) Gebäude und die geringe geometrische Qualität der extrahierten Gebäuderegionen. Mit Laserscannerdaten können gegenüber den Bilddaten höhere Erkennungsraten von über 90 % erreicht werden (Matikainen et al., 2010). Unter Nutzung zusätzlicher Bildinformation und dem Einsatz von Verfahren der Datenfusion erreichten Lee et al. (2008) eine Erkennungsrate von bis zu 98,2 %. Vollautomatische Implementierungen gibt es bisher jedoch nicht. In der Praxis werden zur Erstellung von 3D-Gebäudemodellen vornehmlich semi-automatische Verfahren eingesetzt, die eine Interaktion mit dem Operateur bedingen. Gegenüber einer manuellen Kartierung kann der Erfassungsaufwand jedoch deutlich gesenkt werden.

7 Entwicklung des Verfahrens

In diesem Kapitel werden die methodischen Bausteine des Verfahrens vorgestellt. Dem Gesamtverfahren wird der Name *Buildung Footprint Classification Tool* (BFClassTool) gegeben. Nach einer Einführung von BFClassTool und dem Vorgehen bei der Entwicklung werden die einzelnen Bausteine beschrieben und deren programmtechnische Umsetzung vorgestellt. Die Verfahrensentwicklung erfolgt vor dem Hintergrund des Einsatzes in der kleinräumigen Analyse der Siedlungsstruktur auf Grundlage von Geobasisdaten in Deutschland.

7.1 Methodisches Design

In der Übersicht (Abb. 7-1) ist das methodische Design der Verfahrensentwicklung dargestellt. Nach Festlegung der Rahmenbedingungen werden die entwickelten Bausteine vorgestellt, die den Modulen eines allgemeinen Mustererkennungssystems (vgl. Kap. 3.3) entsprechen.

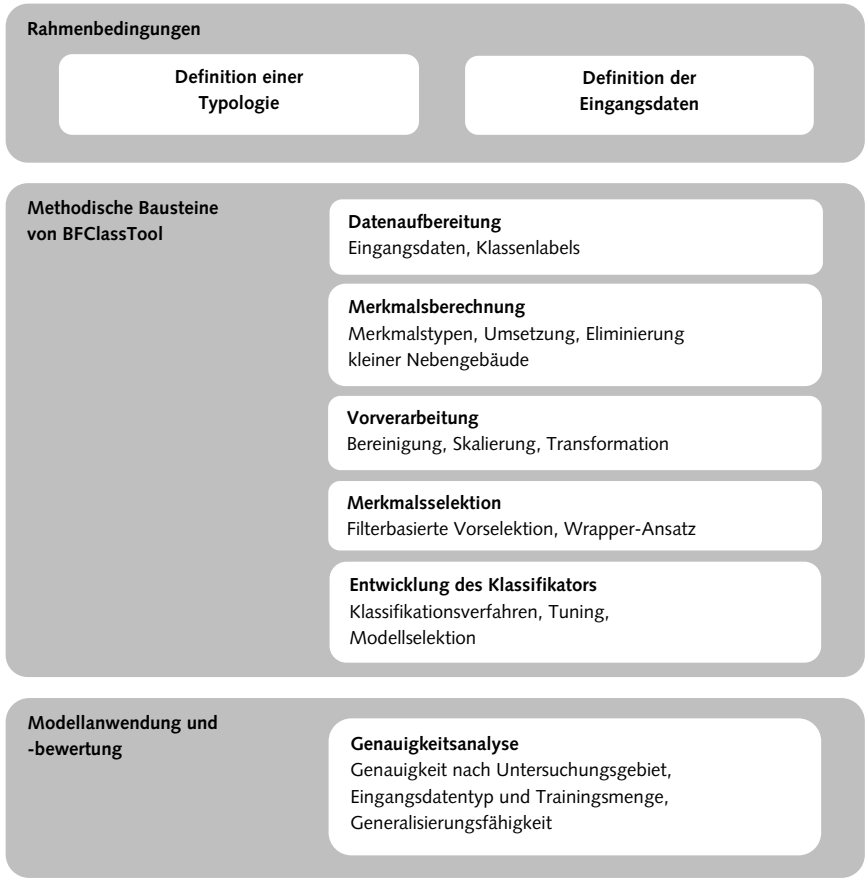

Abb. 7-1: Design der Verfahrensentwicklung

Zunächst steht die Frage nach einer geeigneten *Gebäudetypologie*. Mit Definition der Gebäudeklassen wird festgelegt, nach welchen Kriterien die Gebäude klassifiziert werden sollen. Es bedarf dabei der Wahl einer möglichst allgemeingültigen Gebäudetypologie, mit der verschiedene siedlungsstrukturelle Merkmale modelliert werden können. Andererseits muss diese alle Gebäudetypen berücksichtigen, die im betrachteten Untersuchungsraum vorliegen.

Das entwickelte Klassifikationstool soll anhand verschiedener Eingangsdaten am Beispiel ausgewählter Untersuchungsgebiete in Deutschland entwickelt und getestet werden. Darum müssen geeignete *Eingangsdaten* definiert werden, die untersucht werden sollen. Als Eingangsdaten dienen Geodatensätze, die das Gebäude in einem geeigneten Maßstab abbilden. Als unterstützende Daten werden Baublöcke und Hauskoordinaten betrachtet. Die Wahl der Eingangsdaten erfolgt anhand bestimmter Kriterien, wie Flächendeckung, Homogenität, Vollständigkeit und Genauigkeit. Aus der Menge der Gebäudegrundrisse werden allgemeingültige Eingangsdatentypen herausgearbeitet. Diese bilden die Grundlage, um generalisierte Aussagen zur Eignung verschiedener Datensätze machen zu können.

Die *Datenaufbereitung* ist der erste methodische Baustein und umfasst die Aufbereitung der Gebäudegrundrisse und die Erfassung und Aufbereitung von Klassenlabels. Für die Aufbereitung der Gebäudegrundrisse, Baublöcke und Hauskoordinaten werden Modelle und Transformationsregeln erarbeitet. Die gut standardisierten Datenmodelle der Geobasisdaten erlauben eine größtenteils automatisierte Datenintegration. Der zweite Teil der Datenaufbereitung bezieht sich auf die Erfassung von Klassenlabels, die dem Trainieren, Testen und Validieren des Klassifikators dienen.

Die Klassifikation der Gebäudegrundrisse erfolgt auf Grundlage charakteristischer Merkmale, die aus den Geodatensätzen automatisch berechnet werden sollen. Mit dem Arbeitsschritt *Merkmalsberechnung* werden geeignete Merkmalssets für jeden Eingangsdatentyp erarbeitet und rechnerisch umgesetzt. Nach Umsetzung liegen für die Gebäudegrundrisse die Merkmale in einer Datenbank vor. In einer *Vorverarbeitung* werden die Merkmalsdaten bereinigt, skaliert und transformiert. Mit der *Merkmalsselektion* werden mit einem filterbasierten Ansatz zunächst hochkorrelierte und redundante Merkmale aus den berechneten Merkmalssets eliminiert. Dieser Prozess dient der Reduzierung der Dimension und Redundanz und demnach auch der Modellkomplexität des zu erlernenden Klassifikators in der Entwicklungsphase. Ein zweites Merkmalsselektionsverfahren (Wrapper-Ansatz) wird erst nach Wahl des besten Klassifikators eingesetzt. Es dient vornehmlich der Reduktion von unnötigem Rechenaufwand.

Anschließend erfolgt die *Entwicklung des Klassifikators*. Dazu werden zunächst verschiedene Klassifikationsverfahren betrachtet, die für die Problemlösung in Frage kommen. Die Herausforderung bei der Wahl eines geeigneten Klassifikators besteht dabei, einen möglichst guten Kompromis zwischen einfacher und hoher Modellkomplexität zu finden, um eine Überanpassung (engl. *overfitting*) oder Unteranpassung (engl. *underfitting*) zu vermeiden (Alpaydin, 2004). Ausgewählte Klassifikationsverfahren werden dann anhand verschiedener Eingangsdatensätze trainiert und getestet. Auf Grundlage der gemessenen Genauigkeit und Laufzeit wird in einer Modellselektion das beste Klassifikationsverfahren bestimmt. Abschließend wird das entwickelte Verfahren unter Einsatz des gewählten Klassifikationsverfahrens

an allen zur Verfügung stehenden Datensätzen in einer *Genauigkeitsanalyse,* differenziert nach Untersuchungsgebiet, Eingangsdatentyp und Trainingsdatenmenge, untersucht.

7.2 Definition einer Gebäudetypologie

In diesem Abschnitt wird eine Gebäudetypologie festgelegt nach deren Typen die Gebäude klassifiziert werden sollen. Die Typen sollten Gültigkeit für alle Siedlungsräume in Deutschland besitzen, weshalb zunächst gängige Kriterien und Gebäudetypologien betrachtet werden.

7.2.1 Kriterien und Gebäudetypologien

Der Literatur können diverse Typologien entnommen werden, die sich je nach Zielstellung aus verschiedenen Kriterien definieren (Curdes, 1997; Hofmeister, 1993; Lammert, 1979; Müller & Korda, 1999; Streich, 2005). In der Stadtgeographie, insbesondere der städtebaulichen Struktur- und Gestaltungsplanung, spielen Grundriss- und Aufrisselemente sowie funktionale Aspekte der Bebauung eine bedeutende Rolle bei der Typenbildung.

In Tab. 7-1 sind morphologische, funktionale, stofflich-konstruktive sowie weitere Kriterien aufgeführt, die für die Bildung einer Gebäudetypologie in Frage kommen. Die meisten Kriterien beziehen sich auf das Gebäude als Ganzes. Es gibt jedoch auch Eigenschaften, die sich nur auf einen Teil des Gebäudes, wie z. B. die Dachform oder den räumlichen Kontext in dem sich das Gebäude befindet (z. B. die Bebauungsdichte oder der Erschließungsnetztyp), beziehen.

Tab. 7-1: Kriterien zur Bildung von Gebäudetypen (Quelle: eigene Zusammenstellung)

Typ		Kriterien
morphologisch	Grundriss	- Gebäudeform (z. B. U-Form, L-Form, O-Form etc.) - Bauweise (z. B. geschlossene oder offene Bauweise) - Baualter (z. B. vor 1918, 1919-1948, 1949-1957 etc.) - Erschließungsnetztyp (Rastersystem, Verästelungsnetz) - Bebauungsdichte (z. B. locker, dicht, sehr dicht) - Lage in der Stadt (z. B. Kernlage, Randlage)
	Aufriss	- Bauhöhe (z. B. ein- bis zwei-, drei- bis vier- und fünf- und mehrgeschossig) - Ausrichtung der Gebäude zur Straße (z. B. giebelständig, traufständig) - Dachform (z. B. Flachdach, Satteldach, Walmdach etc.)
funktional		- Gebäudefunktion (z. B. Wohnen, Büro, Lager, Handel, Hotel etc.) - Wohnform (z. B. Einfamilienhaus, Mehrfamilienhaus, Geschosswohnungsbau)
stofflich-konstruktiv		- Fertigung der Gebäude (z. B. Fachwerk, Fertighaus, Plattenbauweise) - Baumaterial (z. B. Holz, Naturstein, Ziegel)
andere (sozio-ökonomisch, energetisch etc.)		- Eigentumsform - Heizungstyp - Zahl der Räume - Einkommen der Bewohner - Solarpotenzial

Die Komplexität einer Gebäudetypologie kann sehr unterschiedlich ausfallen (Abb. 7-2). Diese reichen von einfachen Nomenklaturen ohne Hierarchie bis hin zu Typologien, in denen die Gebäude nach mehreren Kriterien hierarchisch in Haupt- und Untertypen ausdifferenziert werden. Mit der städtebaulichen Gebäudetypologie von Müller und Korda (1999) werden die Gebäude beispielsweise zunächst nach der Wohnform differenziert. Auf tieferer Ebene wird dann beispielsweise der Geschosswohnungsbau als typische Wohnform weiter nach anderen Gesichtspunkten ausdifferenziert (Vielwohnungshaus, Punkthaus etc.). Eine weitere Ausdifferenzierung auf noch tieferer Ebene wäre beispielsweise nach dem Spännertyp (1-, 2-, 3- oder 4-Spänner) möglich (vgl. Streich, 2005).

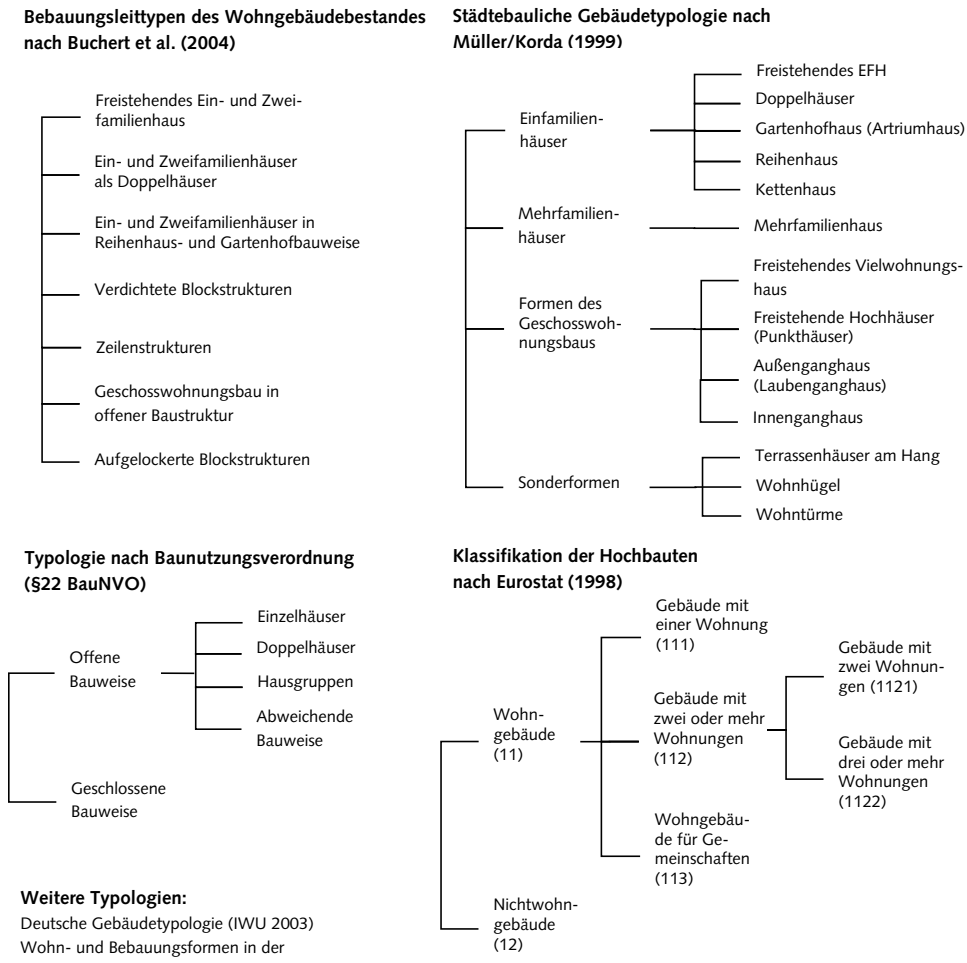

Abb. 7-2: Verschiedene Gebäudetypologien im Vergleich

Eine umfangreiche Typologie ist die deutsche Wohngebäudetypologie (IWU, 1990, 2003). Diese wurde im Rahmen einer stofflich-energetischen Betrachtung des deutschen Gebäudebestandes mit dem Projekt IKARUS[51] vom Institut für Wohnen und Umwelt (IWU) erarbeitet. In einer Matrix wird der Gebäudebestand nach dem Baualter (10 Klassen) und der Gebäudegröße (5 Typen) in insgesamt 44 Klassen[52] differenziert und repräsentative Kenngrößen zum Wärmeschutz, speziell dem Wärmedurchgangskoeffizient (U-Wert), bestimmt. Eine thematisch gröbere Klassifikation ist mit den 7 Bebauungsleittypen des Wohngebäudebestandes (vgl. Abb. 7-2) gegeben, die im Rahmen des Stoffstrommodells vom Öko-Institut entwickelt wurden (Buchert et al., 2004). Grundlage für die Typenbildung waren Gebäudegröße, Gebäudeform, Überbauungsgrad und Stellung der Gebäude. Jedem identifizierten Gebäudemuster, wie der offenen Bebauung, der geschlossenen Blockrandbebauung oder der Zeilenbebauung, konnten auch charakteristische Baualtersgruppen zugeordnet werden.

Die Differenzierung der Gebäude nach der amtlichen Statistik beschränkt sich im Wesentlichen auf das Verhältnis der Wohnungen zu Gebäuden (Wohngebäude mit 1, 2, 3, 4 etc. Wohnungen), der Baualtersklasse und den Ausstattungsstandards (Art der Beheizung, Sanitäre Ausstattung) (Destatis, 2011c). Das Klassifikationsschema des Statistischen Amtes der Europäischen Union differenziert die Gebäude lediglich hinsichtlich der Nutzung und der Wohnungsanzahl (Eurostat, 1998). Stofflich-energetische Aspekte finden in dieser Typologie keine Berücksichtigung.

Weitere Typologien beziehen sich nur auf einen Teilgebäudebestand, wie beispielsweise der Gebäudeatlas der Mehrfamilienhäuser (Schulze & Walter, 1990) oder Typologien für beheizte Nichtwohngebäude (Gierga & Erhorn, 1994; Dirlich et al., 2011).

7.2.2 Gebäudetypologie für siedlungsstrukturelle Analysen

Ziel der Entwicklung von BFClassTool ist die Ableitung planungsrelevanter siedlungsstruktureller Merkmale mit dem Fokus auf Strukturen der Wohnbebauung in Deutschland. Hierzu werden folgende Kriterien definiert, nach denen der Gebäudebestand klassifiziert werden soll:

- Nutzung (Level 1)
- Wohnform (Level 2)
- Städtebauliche Struktur (Level 3)
- Baualter/Konstruktion (Level 4)

Auf Grundlage dieser Kriterien wurde eine Gebäudetypologie erarbeitet (Abb. 7-3). Eine detaillierte Beschreibung der einzelnen Klassen ist im Anhang B.1 zu finden.

[51] Akronym für das UBA-Projekt „Instrumente für Klimagas-Reduktionsstrategien"
[52] Nicht alle Felder der Gebäudetypenmatrix sind belegt.

Die Typologie orientiert sich im Wesentlichen an der städtebaulichen Gebäudetypologie (Müller & Korda, 1999), der deutschen Gebäudetypologie (IWU, 2003) und den Bebauungsleittypen vom Öko-Institut (Buchert et al., 2004) und besitzt eine hierarchische Struktur. Zunächst erfolgt die Unterteilung nach der vorwiegenden Nutzung des Gebäudes in Wohn- und Nichtwohngebäude (Level 1). Zu den Wohngebäuden zählen Gebäude, dessen Gesamtnutzfläche mindestens zur Hälfte der Wohnnutzung dient. Alle restlichen Gebäude zählen zu den Nichtwohngebäuden. Auf zweiter Ebene (Level 2) werden die Gebäude nach der Wohnform differenziert. Hier werden Ein- und Zweifamilienhäuser (EZFH), Mehrfamilienhäuser (MFH) und nicht eindeutig bestimmbare Wohnformen unterschieden. Auf der dritten Ebene erfolgt eine Differenzierung nach der städtebaulichen Struktur. Hier spielen insbesondere die morphologischen Grundriss- und Aufrisselemente, wie die Bauweise und Anordnung der Gebäude, eine Rolle. Auf unterster Ebene 4 werden die Gebäude nach dem Baualter bzw. den damit verbundenen typischen baukonstruktiven Merkmalen differenziert.

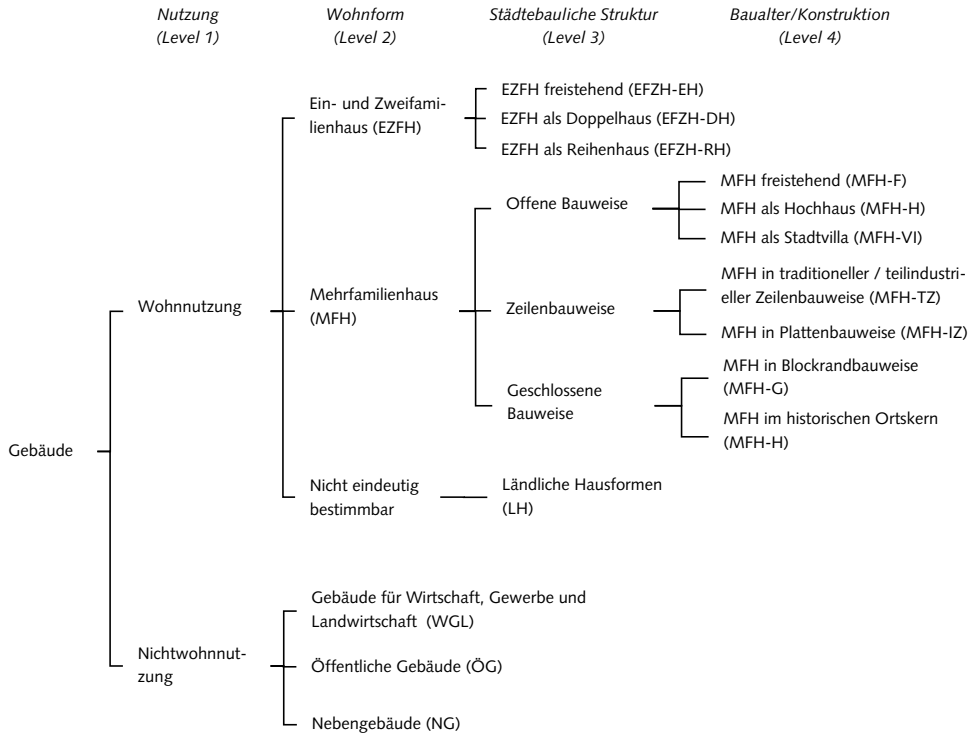

Abb. 7-3: Gebäudetypologie für siedlungsstrukturelle Analyse

Die Definition der Typologie erfolgt im Hinblick auf zu modellierende Zielgrößen der Siedlungsstruktur mit Planungsrelevanz, wie z. B. die Geschossflächendichte, Einwohner- und Wohnungsdichte. Sie ist darum für eine breite Anwendung angedacht. Insgesamt werden 11 Gebäudetypen der Wohnnutzung und 3 Nichtwohnnutzungstypen unterschieden. Der Fokus liegt jedoch auf den Wohngebäudetypen. Eine weitere Ausdifferenzierung der Nichtwohngebäude nach der Nutzung wäre möglich, indem explizite Flächennutzungsinformationen aus dem ATKIS® Basis-DLM oder hinterlegte Gebäudefunktionen aus dem Liegenschaftskataster (ALK/ALKIS®) genutzt werden. Die definierten Gebäudetypen sind durch charakteristische städtebauliche Kenngrößen und Baualtersklassen gekennzeichnet, die dem Anhang B.2 entnommen werden können.

7.3 Eingangsdaten

An die Eingangsdaten wurden verschiedene Anforderungen an die Geometrie, der einheitlichen Datenstruktur und der Vollständigkeit gestellt. Für eine deutschlandweite Anwendung sollten die Daten zudem flächendeckend verfügbar und im Hinblick auf ein Monitoring in ihrer Fortführung gesichert sein. Für die Verfahrensentwicklung werden daher nur die Datengrundlagen betrachtet, die diese Anforderungen erfüllen.

7.3.1 Eingangsdaten zum Gebäudegrundriss

Im Kapitel 6 wurden bereits verschiedene Datengrundlagen vorgestellt aus denen Gebäudegrundrisse entnommen oder extrahiert werden können. Bei der Verfahrensentwicklung und -testung werden nur die amtlichen Geobasisdaten betrachtet. Dieses sind die Digitalen Topographischen Karten TK25, DTK25-V oder DTK25, Gebäude aus dem ATKIS® Basis-DLM (ATKIS), Hausumringe (HU), Gebäude aus dem Liegenschaftskataster (ALK/ALKIS®) sowie 3D-Gebäudestrukturen (3D-GS). Nutzergenerierte Daten, wie OpenStreetMap, wären zwar prinzipiell geeignet, aufgrund ihrer Unvollständigkeit sind sie derzeit jedoch praktisch nicht einsetzbar. Auch aus Fernerkundungsdaten abgeleitete Gebäudegrundrisse werden wegen der fehlenden Möglichkeit einer vollautomatischen Extraktion mit hinreichender Genauigkeit nicht weiter betrachtet. Die Tab. 7-2 zeigt die im Verfahren berücksichtigten Daten zum Gebäudegrundriss im Überblick.

Tab. 7-2: Eigenschaften verschiedener Eingangsdaten

	DTK25-V/TK25	DTK25	ATKIS	HU	ALK/ALKIS®	3D-GS
Bezeichnung	Digitale Topographische Karte (alte Kartengraphik)	Digitale Topographische Karte (in neuer Kartengraphik)	ATKIS® Basis-DLM oder AAA-ATKIS®	Amtliche Hausumringe	Liegenschaftskarte	3D-Gebäudestruktur (3D-Gebäude im LoD1)
Datenmodell	Raster	Raster	Vektor	Vektor	Vektor	Vektor
Maßstab (Aufösung)	1: 25 000 (508 dpi)	1: 25 000 (508 dpi)	1: 10 000 bis 1: 25 000	1: 500 bis 1: 5 000	1: 500 bis 1: 5 000	1: 500 bis 1: 5 000
Grundlage der Erfassung	Topographische Grundkarte	ATKIS® Basis-DLM	Luftbildinterpretation	Vermessung vor Ort	Vermessung vor Ort	Vermessung vor Ort
Erfassung durch	Landesämter	Landesämter	Landesämter	Kataster	Kataster	Kataster
Vertrieb	Landesämter/ BKG[53]	Landesämter/ BKG[53]	Landesämter/ BKG[53]	zentral über GVHH	Landesämter	Landesämter (in Zukunft auch zentral)
Fortführung	ehem. alle 5 Jahre	aller 3 - 5 Jahre	aller 3 - 5 Jahre	jährlich	kontinuierlich	jährlich
Flächendeckung	ja	ja	nur in einigen BL	ja	ja	ja, ab 2013
Historische Daten	ja, bis ca. 1950	nein	nein	nein	nein	nein
Gebühren pro Gebäude	≈ 0,001 €[54]	≈ 0,001 €[54]	≈ 0,008 €[54]	0,12 €[55]	1,80 €[55]	0,12 €[56]
Gebühren Deutschland[57]	24 000 €	24 000 €	180 000 €	100 000 €	5 560 000 €[58]	k.A.
Gebäude	Grundrisslayer (DTK25-V) oder RGB-Scan (TK25)	Ebene 8 („rot“) und Ebene 9 („haus“)	Objektart 2315oder AX_Gebaeude (AAA)	alle Objekte	Folie 011, 084 bzw. 086 (ALK) oder AX_Gebaeude (ALKIS®)	alle Objekte

[53] Nach Verwaltungsvereinbarung nur für behördliche länderübergreifende Aufgaben.
[54] Schätzung aus Gebührensumme für Deutschland bei angenommenen 22 Mio. Gebäuden.
[55] gemäß der AdV-Gebührenrichtlinie (AdV, 2010b)
[56] Gebührenangabe zu den 3D-Gebäudestrukturen in NRW (BezregKöln, 2012)
[57] übernommen aus AdV (2010b)
[58]Schätzung aus Gebührenrichtlinie (AdV, 2010b) und einem deutschlandweiten Datensatz zu den Hausumringen (Burckhardt, 2012).

Fortsetzung der Tab. 7-2:

	DTK25-V/TK25	DTK25	ATKIS	HU	ALK/ALKIS®	3D-GS
Attribute zum Gebäude	keine Information	Geg. durch getrennte Führung der Ebenen „rot" (öffentliches Gebäude) und „haus" (nichtöffentliches Gebäude)	Gebäudefunktion (GFK), aber oft nicht ausgefüllt[59]	keine Information	Gebäudefunktion (FKT) (nach Wohnen, Wirtschaft und Gewerbe und Gemeinwesen), andere Attribute nicht im Grunddatenbestand	Gebäudefunktion (NUTZUNG) nach Wohnen, Wirtschaft und Gewerbe sowie Gemeinwesen), Gebäudehöhe (GEB_HOEHE), Unterscheidung der Haupt- und Nebengebäude (GEB_TYP)
Lagegenauigkeit	<± 5 m	<± 5 m	<± 3 m	± 0,5 m	± 0,5 m	± 0,5 m
Gebäuderepräsentation	Grundrissähnliche Darstellung vereint mit anderen schwarz dargestellten Kartenelementen (Verkehr, Vegetation, Schrift) im Grundrisslayer gespeichert, teilweise mit Freistellung durch Schrift und punktförmige Signaturen	Grundrissähnliche Darstellung der Gebäude in separatem Layer gespeichert, teilweise Freistellung durch Schrift und punktförmige Signaturen	Grundrisstreue Einzelgebäuderepräsentation	Grundrisstreue Einzelgebäuderepräsentation, teilweise auch zusammengefasste Gebäude	Grundrisstreue Einzelgebäuderepräsentation	Grundrisstreue Einzelgebäuderepräsentation mit Nutzungsinformation (Unterscheidung von Wohn, Gewerbe, öffentliche Gebäude)

Topographische Karten im Maßstab 1: 25 000 bieten eine kostengünstige, multitemporale und vor allem bundesweit weitgehend homogen vorliegende Datengrundlage zu Gebäuden. Sie bilden die Gebäude in einer Gebäuderegion-Repräsentation ab. Studien haben gezeigt, dass topographische Karten der Maßstabsebene 1: 25 000 einen optimalen Kompromiss zwischen Datenmenge und -kosten sowie hinreichender Genauigkeit darstellen, da sie den Gebäudebestand vollständig und nur mit geringer Generalisierung abbilden (Meinel et al., 2008a, 2009). Topographische Karten bieten als einzige hier dargestellte Datengrundlage Zugang zum Gebäudebestand der Vergangenheit. Ihnen wird dahingehend eine besondere Bedeutung beigemessen, da deren automatische Gebäudeextraktion im Gegensatz zu Luftbildern mit höherer Genauigkeit möglich ist. Karten größeren Maßstabes, wie etwa die DGK5 oder der DTK10(-V), die den Gebäudebestand grundrißtreu abbilden, werden nicht betrachtet. Das sehr viel größere Datenvolumen bei annähernd gleicher Informationsdichte gegenüber der DTK25, die fehlende Flächendeckung, die länderspezifischen Unterschiede und der ausschließlich dezentrale Vertrieb über die Landesvermessungsämter führen dazu,

[59] In Sachsen besitzen beispielsweise 2,4 % aller Gebäude die Kennung „9998" (keine Zuweisung der Gebäudefunktion möglich).

das diese aus praktischer Überlegung für großflächige Anwendungen weniger geeignet sind. Gebäude aus dem Liegenschaftskataster (ALK/ALKIS®) bieten die genaueste geometrische Datengrundlage. Aufgrund der hohen Anforderung an die Datenqualität und damit auch hohen Erhebungs- und Fortführungskosten entstehen hohe Gebühren von 1,80 € pro Gebäude (AdV, 2010b). Für großflächige Analysen müssten deshalb enorme Beschaffungskosten eingeplant werden. Die Nutzungsinformationen der ALK-Gebäude und den 3D-Gebäudestrukturen orientieren sich an dem von der AdV festgelegten Grunddatenbestand, aus dem eine Unterscheidung zwischen Wohnen, Wirtschaft oder Gewerbe und Gemeinwesen hervorgeht. Weitere Attribute sind zwar möglich, deren Umsetzung ist jedoch sehr heterogen (länder- und behördenspezifisch). Ein weiterer Nachteil der ALK ist, dass diese nur dezentral über die Landesvermessungsämter beziehbar ist. Mit dem Produkt „Hausumringe“ werden, wenn auch ohne semantische Information, Gebäudegrundrissdaten aus dem Liegenschaftskataster ausgekoppelt und über eine zentrale Stelle flächendeckend angeboten.

7.3.2 Definition von Eingangsdatentypen

Aus den Eigenschaften in der Modellierung lässt sich eine Typologie ableiten (Abb. 7-4), die Grundlage für die spätere Bewertung verschiedener Datensätze ist. Es können insgesamt 5 Eingangsdatentypen identifiziert werden, die sich hinsichtlich der geometrischen Gebäudemodellierung und dem semantischen Informationsgehalt unterscheiden. Der Informationsgehalt, die geometrische Genauigkeit und die Kosten für die Beschaffung nehmen von Typ I nach Typ V zu.

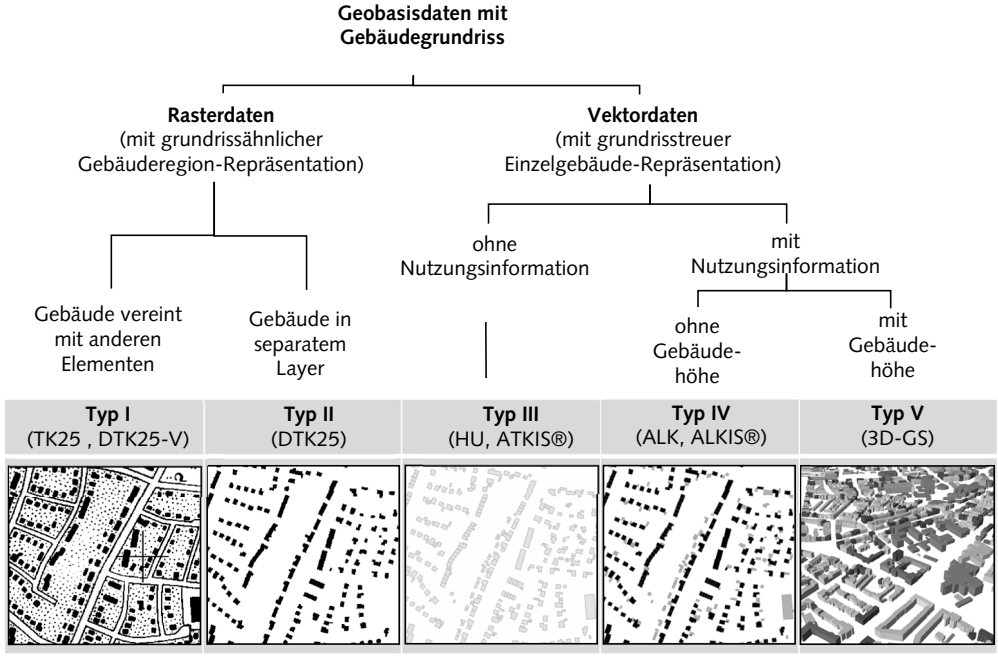

Abb. 7-4: Eingangsdatentypen

7.3.3 Unterstützende Geometriedaten

Neben den Gebäudegrundrissen werden Baublöcke und Hauskoordinaten als unterstützende Information hinzugezogen.

7.3.3.1 Baublöcke

Der Baublock ist eine wichtige städtebauliche Grundeinheit zur kleinräumigen Gliederung des Siedlungsraumes und bildet den Raumbezug für die Berechnung und Visualisierung der abgeleiteten siedlungsstrukturellen Merkmale. Baublöcke können zudem als unterstützende Information während des Mustererkennungsprozesses genutzt werden, da mithilfe der Geometrie die Ableitung von Merkmalen zur Beschreibung des Kontextes möglich wird. Baublöcke werden in digitalen Landschaftsmodellen oder Stadtmodellen explizit modelliert. Die Geometrie kann jedoch auch mittels der Extraktion von Straßennetzen aus Luftbild- und Fernerkundungsdaten (Baumgartner, 2003; Wiedemann, 2002) oder aus topographischen Kartenwerken (vgl. Muhs et al., 2012) abgeleitet werden.

Baublöcke sind mit der Objektgruppe „Baulich geprägte Fläche" (2100) des ATKIS® Basis-DLM gegeben. Die Flächen können hinsichtlich ihrer Nutzung nach den Objektarten Wohnbaufläche (2111), Industrie- und Gewerbefläche (2112), Fläche gemischter Nutzung (2113) und Fläche besonderer funktionaler Prägung (2114) unterschieden werden (AdV, 2008e). Die Flächen werden in der Regel durch das Straßennetz, die Grundstücksgrenze im Übergang zum Freiraum sowie weiteren linearen Elementen (Gewässer, Grenzen) gebildet. Da die Baublöcke die angrenzenden Verkehrsflächen enthalten, stellen diese Brutto-Baublöcke dar. Die Teilflächen der bebauten Fläche müssen dabei eine Mindestgröße von 1 ha besitzen. Im ATKIS® Basis-DLM ist ein Attribut (BEB) vorgesehen, mit dem Wohnbauflächen nach offener und geschlossener Bebauung unterschieden werden können. Bei einer offenen Bauweise (BEB=1000) liegen Gebäude mit seitlichem Grenzabstand als Einzelhäuser, Doppelhäuser oder Hausgruppen vor, wobei die Länge der Gebäudegruppen höchsten 50 m beträgt. Bei einer geschlossenen Bauweise (BEB=9997) sind die Gebäude ohne seitlichen Grenzabstand errichtet. Eine visuelle Plausibilitätskontrolle der ATKIS-Daten von Sachsen zeigte jedoch, dass die Qualität des Attributes unzureichend und eine Unterscheidung dieser Flächen nicht mit hinreichender Genauigkeit möglich ist.

7.3.3.2 Hauskoordinaten

Ein weiterer berücksichtigter Hilfsdatensatz sind amtliche Hauskoordinaten (HK), die von der Zentralen Stelle für Hauskoordinaten und Hausumringe und 3D-Gebäudemodelle (ZSHH) und dem BKG angeboten werden. Hauskoordinaten repräsentieren alle postalisch erfassten Gebäude über eine Koordinate im Landeskoordinatensystem. Die Lageinformation wird aus den Daten des Liegenschaftskatasters (ALK) abgeleitet und mit Informationen aus dem ALB, dem amtlichen Gemeinde- und Ortsteilverzeichnis sowie postalischen Informationen der Deutschen Post angereichert. Insgesamt stehen derzeit ca. 20,6 Mio. amtliche Hauskoordinaten in Deutschland bereit. Inhaltlich besitzt jede Koordinate eine bundesweit eindeutige Kennung, eine Qualitätsangabe, einen amtlichen Schlüssel sowie postalische Angaben (z. B. Straßenname, Hausnummer, Postleitzahl etc.). Das BKG bezeichnet ihr Produkt als „Georeferenzierte Adressdaten" (GAB).

Im Unterschied zu den amtlichen Hauskoordinaten wurde der Datensatz um bisher fehlende Adresskoordinaten ergänzt, in dem ein Adressdatensatz der Firma infas geodaten GmbH hinzugezogen wurde (BKG, 2010).

Die Tab. 7-3 fasst die unterstützenden Daten zusammen. Hauskoordinaten können den amtlichen Produkten der amtlichen Hauskoordinaten (HU) beziehungsweise dem amtlichen Datensatz GAB (Georeferenzierte Adresse – Bund) entnommen werden. Die Baublöcke sind im ATKIS® Basis-DLM modelliert – sowohl im alten (Version 3.2) als auch im neuen integrierten AAA-Modell (Version 6.0).

Tab. 7-3: Zusätzlich gewählte Datengrundlagen

	Hauskoordinaten		Baublockgeometrie und Flächennutzung	
Amtliches Produkt	Amtliche Hauskoordinaten (HK)	Georeferenzierte Adresse – Bund (GAB)	ATKIS® Basis-DLM (Version 3.2)	ATKIS® Basis-DLM im AAA-Modell (Version 6.0)
Datenmodell	Vektor (Punkte)	Vektor (Punkte)	Vektor (Flächen)	Vektor (Flächen)
Beschreibung	2D-Lage adressierter Gebäude	2D-Lage adressierter Gebäude	Objektgruppe der „baulich geprägter Flächen“ (2100)	Objektartengruppe mit der Bezeichnung „Siedlung“ (41000)
Maßstab	1: 500 bis 1: 5 000	1: 500 bis 1: 5 000	1: 10 000 bis 1: 25 000	1: 10 000 bis 1: 25 000
Lagegenauigkeit	<± 5m	<± 5m	<± 3 m	<± 3 m
Grundlage der Erfassung	Vermessung vor Ort	Vermessung vor Ort, infas Geodaten	Luftbild, Topograph	Luftbild, Topograph
Zuständig für Erfassung	Kataster	Kataster und andere	Landesämter	Landesämter
Zuständig für Vertrieb	zentral (ZSHH)	zentral (BKG)	zentral (BKG)	derzeit über die Länder, in Zukunft zentral über BKG
Aktualität	jährlich	jährlich	jährlich (Spitzenaktualität in den Bundesländern)	jährlich (Spitzenaktualität in den Bundesländern)
Flächendeckung	ja	ja	ja	ja, ab 2013
Relevante Flächen	keine	keine	Objektarten: Wohnbaufläche (2111), Industrie- und Gewerbefläche (2112), Fl. gemischter Nutzung (2113), Fl. besond. funktionaler Prägung (2114), Freizeitanlage (2202)	Objektarten: Wohnbaufläche (41001), Industrie- und Gewerbefläche (41002), Fl. gemischter Nutzung (41006), Fl. besonderer funktionaler Prägung (41007), Sport, Freizeit und Erholungsfläche (41008)

7.4 Datenaufbereitung

7.4.1 Aufbereitung der Eingangsdaten

Die relevanten Geoobjekte der Eingangsdaten müssen zunächst aufbereitet und in ein einheitliches, vektorbasiertes Datenmodell überführt werden. In Tab. 7-4 sind die Eingangsdaten und die nötigen Aufbereitungsschritte zusammengefasst. Die Abb. 7-5 zeigt die Prozesse in einem Ablaufdiagramm.

Tab. 7-4: Datenaufbereitungsschritte für die Integration der amtlichen Gebäudegrundrisse

			Eingangsdaten							
			TK25	DTK25-V	DTK25	HU	ATKIS	ALK	ALKIS®	3D-GS
Datenaufbereitung		Kartenscan, Georeferenzierung, Binarisierung	●							
		Gebäudeextraktion	●	●						
		Raster-Vektorkonvertierung	●	●	●					
	Datenintegration	Geometrie	●	●	●	●	●	●	●	●
		Gebäudefunktion						●	●	●
		Gebäudehöhe/ Gebäudetyp[60]								●
		Eingangsdatentyp	Typ I		Typ II	Typ III		Typ VI		Typ V
		Repräsentationsform	Gebäuderegionen			Einzelgebäude				

Analoge Topographische Karten (TK25) müssen für die digitale Verarbeitung zunächst eingescannt, georeferenziert und in einem weiteren Schritt alle schwarz dargestellten Kartenelemente[61] extrahiert werden. In der Regel eignet sich dafür eine Binarisierung des Grauwertbildes über einen Schwellwert. Falls eine höhere Scanauflösung vorliegt, muss das Bild auf 508 dpi umgerechnet werden, damit ein mit der DTK25-V vergleichbarer binärer Grundrisslayer (Eingangsdatentyp I) entsteht.

In dem Grundrisslayer der DTK25-V (einer von 4 Layern neben Vegetation, Gewässer, Höhenlinien) sind die Gebäude zusammen mit Verkehrs- und Grenzlinien, Vegetations- und weiteren Signaturen und Schriften in einem Binärlayer gespeichert. Die Gebäude müssen darum mithilfe der kartographischen Mustererkennung automatisch aus dem binären Rasterbild extrahiert werden. Ein hierfür entsprechendes Verfahren wurde bereits unter Nutzung der Bildanalysesoftware HALCON (www.mvtec.com) und deren umfangreiche Biblio-

[60] Merkmal zur Unterscheidung der Haupt- und Nebengebäude (nicht zu verwechseln mit dem gesuchten Gebäudetyp).
[61] Hierfür eignet sich eine Binarisierung des Grauwertbildes.

thek entwickelt und in Form eines ausführbaren Programms implementiert (Meinel et al., 2008a). Eingangsdaten sind der binäre Grundrißlayer und die Baublockgeometrie als unterstützende Geometrie für eine Einschränkung des Suchbereiches nach Gebäuden im Bild. Dabei erfolgt eine Trennung der Verkehrs- und Grenzlinien durch morphologische Bildoperationen. Für die Schrifterkennung kommen Verfahren der OCR (*Optical Character Recognition*) zum Einsatz und die Eliminierung von Signaturen, für Kirchen, Türme, Bergwerke, Umspannwerke erfolgt über ein Template Matching. Die Extraktion der Gebäude erfolgt mit einer Genauigkeit von 96 %. Es hat sich jedoch gezeigt, dass ein objektbasierter Segmentierungsansatz, beschrieben in Herold et al. (2012), direkt auf farbige Kartenscans angewendet werden kann. Dem Bildrauschen des Scans und Passerfehler einer geringen Druckqualität kann mit einem derartigen Ansatz besser begegnet werden.

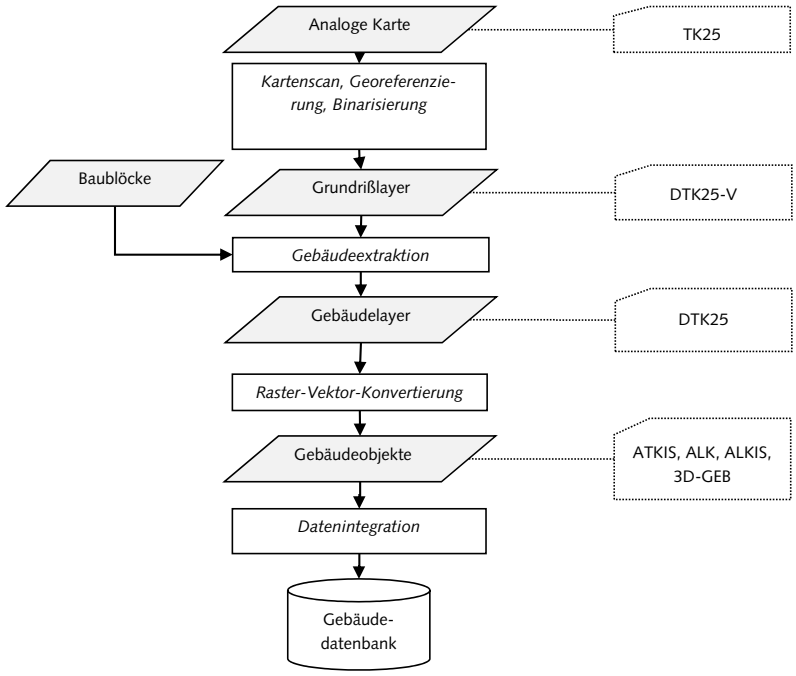

Abb. 7-5: Semantische und geometrische Harmonisierung der verschiedenen Datenmodelle

Bei der DTK25 (Eingangsdatentyp II) ist eine Gebäudeextraktion nicht nötig, da die Gebäude bereits in separierten Rasterlayern (Ebene „haus“ und „rot“) gespeichert sind. Auf Grundlage des oder der binären Gebäudelayer erfolgt eine Raster/Vektor-Konvertierung, um die Gebäuderegionen in die objektbasierte Gebäudedatenbank zu überführen.

Die bereits im Vektorformat vorliegende Gebäudegeometrie (aus HU, ATKIS, ALK, ALKIS® oder 3D-GS vom Eingangsdatentyp II-V) können ohne die eben beschriebenen Aufbereitungsschritte in die Gebäudedatenbank integriert werden. Dabei werden die für das Verfahren relevanten Attribute zur Gebäudefunktion und Gebäudehöhe (nur ALK, ALKIS® oder 3D-GS) eingepflegt. Während die Werte zur Gebäudehöhe direkt übernommen werden können, müssen für die Integration des Nutzungsattributes Transformationsregeln für eine Umkodierung eingeführt werden. Dabei werden alle Klassen auf den von der AdV festgelegten Grunddatenbestand zusammengefasst. Mit dem Grunddatenbestand ist eine zwingende Unterscheidung der Funktionen Wohnen, Wirtschaft und Gewerbe sowie Gemeinweisen festgelegt. Dieser Schritt ist insbesondere bei Anwendung des Verfahrens auf katasterübergreifende Gebiete notwendig, da die Vollständigkeit der Attributsvergabe sehr heterogen ist. Die Abb. 7-6 zeigt die Zuordnungsregeln am Beispiel der ALK und ALKIS® in Mecklenburg-Vorpommern (LAiV, 2011).

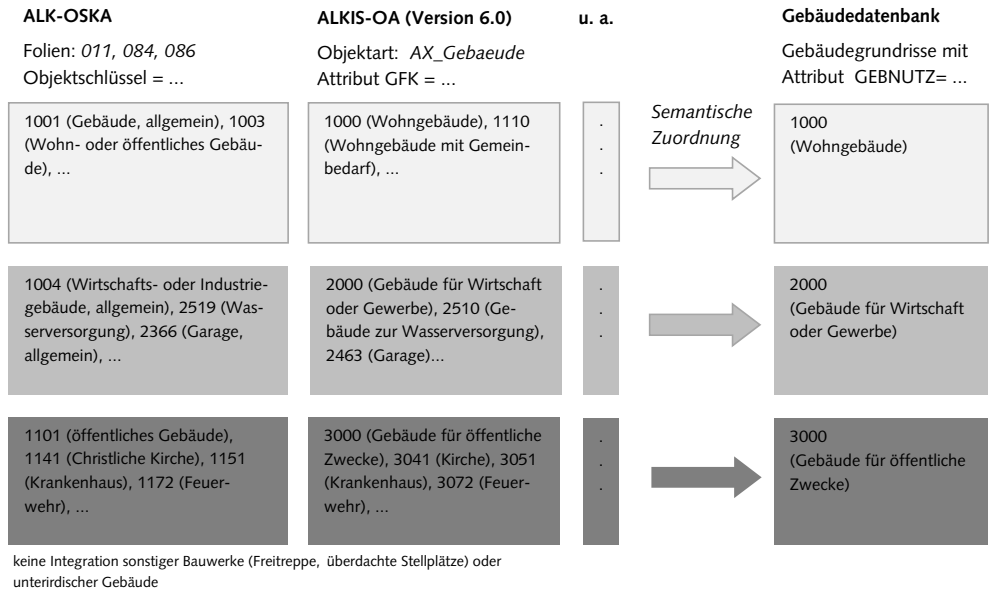

Abb. 7-6: Semantische Transformation der Nutzungsklassen in die drei verfahrensspezifischen Klassen am Beispiel der ALK und dem ALKIS (Eingangsdatentyp IV)

Die geometrische und semantische Datenintegration erlaubt einen einheitlichen Zugriff auf die Gebäudegrundrisse und die unterstützenden Daten wie den Baublock und die Hauskoordinaten in der Datenbank. In Tab. 7-5 sind die Daten und deren Attribute nach der Datenintegration zusammengefasst dargestellt.

Tab. 7-5: Eingangsdaten nach Datenintegration

	Gebäudegrundrisse	Baublöcke	Hauskoordinaten
Geometrietyp	Fläche	Fläche	Punkt
Bildbeispiel			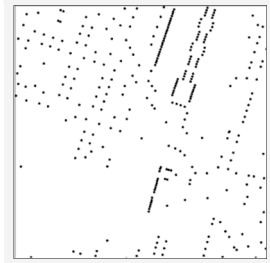
Attribute	+ AREA: REAL + PERIMETER: REAL + GEB_ID: INTEGER + GEBNUTZ: INTEGER* + HOEHE: REAL** + GEB_TYP: INTEGER**	+ AREA: REAL + PERIMETER: REAL + BL_ID: INTEGER + OBJART	+ ADR_ID

* nur Eingangsdatentyp IV und V

** nur Eingangsdatentyp V

7.4.2 Erfassung von Klassenlabels

Zum Trainieren und Testen eines überwachten Klassifikationsverfahrens werden Trainingsobjekte mit bekannter Klassenzugehörigkeit benötigt. Ein wichtiger Aufbereitungsschritt ist die Erfassung des tatsächlich vorliegenden Gebäudetyps für eine Teilmenge der Gebäude im betrachteten Untersuchungsraum. Ausgangsbasis sind die Gebäudegrundrisse der Gebäudedatenbank, die entsprechend der festgelegten Gebäudetypologie mit einem Klassenlabel zum Gebäudetyp über ein Attribut „REF“ kodiert werden. Zusammen mit den berechneten Merkmalen bilden diese später die Lerndatenmenge.

Die Erfassung der Klassenlabels kann für ein repräsentatives Teilgebiet oder zufällig über den gesamt betrachteten Untersuchungsraum erfolgen. Wichtig ist, dass die Lerndaten repräsentativ alle möglichen Erscheinungsformen abbilden. Eine feste Regel über die Mindestanzahl an Trainingsobjekten gibt es in der Literatur nicht, da der Umfang von einer Reihe von Faktoren (Merkmalsanzahl, Klassenanzahl, Merkmalsstreuung, Lernverfahren) abhängt. Folgt man dem „Gesetz der großen Zahlen“, nach dem sich die Eigenschaften der Lerndatenmenge mit wachsendem Umfang den Eigenschaften der Grundgesamtheit annähern, sollten so viele Klassenlabels wie möglich zur Verfügung stehen. Als Faustregel wird in der Mustererkennung häufig angegeben, dass die Anzahl der Trainingsobjekte 5- bis 10-mal höher sein soll als die Anzahl der Merkmale (Webb, 2002). Bei statistischen Verfahren gelten Stichprobengrößen von unter 30 Fällen bereits als zu klein, da damit keine angemessene Normalverteilungsfunktion geschätzt werden kann. Die Frage nach einer minimalen Lerndatenmenge kann mithilfe von Simulation (Variation der Trainingsdatenmenge) beantwortet werden.

Für die Gewinnung von Klassenlabels gibt es zwei Möglichkeiten. Die manuelle Erfassung in einem GIS und die Übernahme aus anderen Geodatensätzen (Abb. 7-7).

Die manuelle Erfassung erfolgt in der Regel auf Grundlage einer visuellen Interpretation von Luftbildern, topographischen Karten oder auch verschiedenen Internet-Bilddiensten (Google Street View, Bing Maps) und Vor-Ort-Begehungen. Diese Erfassungsmethode ist sehr zeit- und kostenaufwändig. Alternativ können Klassenlabels zum Gebäudetyp aus bereits vorhandenen Kartierungen übernommen bzw. abgeleitet werden. Eine Voraussetzung dafür ist, dass für das Kartierungsgebiet eine vergleichbare Datengrundlage sowie Gebäudecharakteristik zugrundeliegt, die auch für den betrachteten Untersuchungsraum zutreffen. So ist es nicht zielführend, eine Gebäudekartierung einer chinesischen Stadt als Trainingsdaten zu verwenden, um die Gebäude einer deutschen Stadt zu klassifizieren. Das Klassifikationsschemata der Kartierung kann gegenüber der Gebäudetypologie semantische, schematische und syntaktische Unterschiede aufweisen. Die Daten müssen durch geeignete Rekodierungsvorschriften und Aggregationsregeln in die Zieltypologie transformiert werden. Werden einige Klassen in den zugrundeliegenden Kartierungen nicht abgebildet, ist eine manuelle Ergänzung bzw. Überarbeitung nötig. Nach semantischer Integration ist häufig eine räumliche Zuordnung der Klassenlabels an die Gebäudegrundrisse nötig. Dies kann entweder über eine Verschneidung der Gebäudepolygone aus der Kartierung mit den Centroiden der Zielgeometrie oder durch Objektzuordnung auf Grundlage der größten gemeinsamen Fläche erfolgen. Wichtig ist stets das kritische Hinterfragen der Validität der übernommenen Klassenlabels aus externen Kartierungen. Es sollte sorgfältig überprüft werden, auf welcher Datengrundlage und unter welchen Bedingungen diese erhoben wurden.

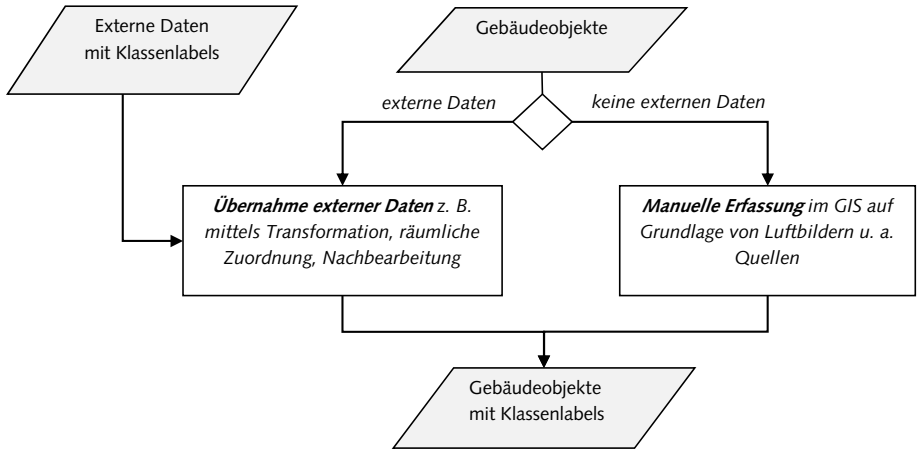

Abb. 7-7: Möglichkeiten der Erfassung von Klassenlabels

7.5 Merkmalsberechnung

Merkmale sind die wichtigsten Grundlage für eine automatische Klassifizierung. Nach einer Charakterisierung der Darstellung der Gebäudetypen in topographischen Daten und Karten werden Merkmalstypen eingeführt, denen verschiedene Bezugsebenen zugrunde liegen können. Nach dieser zunächst konzeptionellen Betrachtung werden die Merkmale anschließend spezifiziert und ihre rechnerische Umsetzung vorgestellt.

7.5.1 Charakterisierung der Gebäudetypen

Die definierten Gebäudetypen unterscheiden sich hinsichtlich der Kriterien Nutzung, Wohnform, städtebauliche Struktur und dem Baualter bzw. der Konstruktion. Bis auf die Nutzungsinformation (die beispielsweise in den ALK-Gebäuden gegeben ist), sind diese Eigenschaften nicht explizit in den Daten modelliert. Die Fähigkeit des Sehens erlaubt es einem Experten dennoch, verschiedene Bebauungsformen in visualisierten topographischen Daten zu identifizieren. Im Gegensatz zur Luftbildinterpretation stehen dem Betrachter keine spektralen Informationen zur Verfügung. Die Erkennung basiert allein auf Wahrnehmung morphologischer Eigenschaften, wie der Größe, Form und Anordnung und einem Abgleich mit dem Wissen und den Erfahrungen des Betrachters.

Anhand der Bildbeispiele in Tab. 7-6 soll deutlich werden, dass die definierten Gebäudetypen charakteristische Eigenschaften aufweisen. Gezeigt wird jeweils ein Ausschnitt der Digitalen Topographischen Karte 1: 25 000 (DTK25-V) sowie den digitalen Gebäudegrundrissen der ALK am Beispiel von Dresden. Die Wahrnehmung verschiedener Bebauungsstrukturen in topographischen Karten kann mit Gestalt-psychologischen Gesetzen, wie beispielsiwese dem Gesetz der Nähe oder dem Gesetz der Ähnlichkeit, erklärt werden. Räumliche Nähe von Gebäuden ist beispielsweise durch die Dichte, bezogen auf eine höhere Bezugseinheit oder die Distanz einzelner Objekte zueinander, beschreibbar, wohingegen Ähnlichkeit zwischen Objekten mithilfe der graphischen Variablen Größe, Form, Orientierung, Farbe formuliert werden kann (Steiniger et al., 2008). Dass eine automatische Differenzierung verschiedener Landnutzungsstrukturen allein auf Grundlage morphologischer Merkmale möglich ist, wurde in der Arbeit von Barr et al. (2004) gezeigt. In Bezug auf eine Klassifizierung der Gebäudegrundrisse nach der oben festgelegter Gebäudetypologie ist demnach auch davon auszugehen, dass ein Zusammenhang zwischen der Bebauungsform und den definierten Gebäudetypen vorliegt, der über geeignete Merkmale beschrieben werden kann.

Tab. 7-6: Darstellung verschiedener Gebäudetypen in topographischen Karten und Daten

Bildbeispiel		
Digitale Topographischen Karte 1: 25 000 (DTK25-V)	Digitale Liegenschaftskarte (ALK)	Gebäudetyp (Akronym)
		Freistehendes Ein- und Zweifamilienhaus (EFZH-EH)
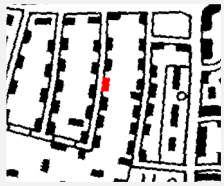		Ein- und Zweifamilienhaus als Doppelhaus (EFZH-DH)
		Ein- und Zweifamilienhaus als Reihenhaus (EZFH-RH)
		Freistehendes Mehrfamilienhaus als Hochhaus (MFH-HH)
		Freistehendes Mehrfamilienhaus (straßenbegleitend /in offener Blockrandbebauung) (MFH-F)
	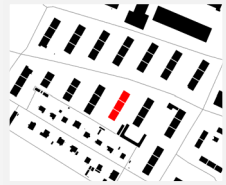	Mehrfamilienhaus in traditioneller/teilindustrieller Zeilenbauweise (MFH-TZ)
		Mehrfamilienhaus in Plattenbauweise (industrieller Bauweise) (MFH-IZ)

Fortführung von Tab. 7-6

Bildbeispiel		
Digitale Topographischen Karte 1: 25 000 (DTK25-V)	Digitale Liegenschaftskarte (ALK)	Gebäudetyp (Akronym)
		Mehrfamilienhaus (überwiegend in Blockrandbebauung) (MFH-G)
	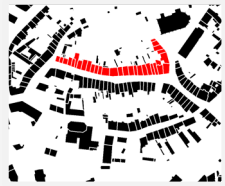	Mehrfamilienhaus im historischen Ortskern (MFH-H)
		Villa (MFH-VI)
		Ländliche Hausform (LH)
		Gebäude für Wirtschaft, Gewerbe und Landwirtschaft (WGL)
	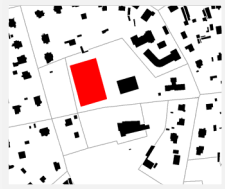	Öffentliches Gebäude (ÖG)
		Nebengebäude (NG)

In Tab. 7-7 sind ausgewählte morphologische Eigenschaften zusammengetragen, mit denen sich die Gebäudetypen im Grundriss beschreiben lassen.

Tab. 7-7: Charakterisierung der Gebäudegrundrisse im Kartenbild

	Räumliche Ebene					
	Einzelgebäude		Gebäuderegion		Baublock	
Gebäudetyp	Größe	Anordnung	Größe	Form	Überbauungs-grad	Baulich-räumliche Struktur
EFZH-EH	klein	freistehend	klein	quadratisch, kompakt	gering	straßenbegleitend, offene Struktur, meist regelmäßig
EFZH-DH	klein	halb freistehend	klein	quadratisch, rechteckig	gering	straßenbegleitend, offene Struktur
EFZH-RH	klein	gereiht	mittel	überwiegend I-Form	gering bis mittel	parallel zur Straßenachse begleitend
MFH-HH	mittel	freistehend	mittel	quadratisch kompakt	gering	offene Struktur, großer Gebäudeabstand
MFH-F	mittel	freistehend	mittel	quadratisch kompakt	mittel	straßenbegleitend, offen, meist regelmäßig
MFH-TZ	mittel	gereiht	groß	Überwiegend I-Form	mittel	regelmäßige Anordnung in meist halboffener Bauweise
MFH-IZ	mittel	gereiht	sehr groß	verschiedene (I, J,U,L,Z,S oder O-Form)	mittel	halb offene Bebauung, geordnete Struktur
MFH-G	mittel	gereiht	sehr groß	verschiedene (I, U,L,O-Form)	hoch	geschlossene Struktur, tlw. fragmentiert, Blockrandlage, Hinterhofbebauung, Treppenaufgänge
MFH-H	klein bis mittel	gereiht	sehr groß	verschiedene	hoch	geschlossene Bebauung tlw. fragmentiert, heterogene Formen
MFH-V	klein bis mittel	freistehend	mittel	quadratisch kompakt	gering	straßenbegleitend, großer Abstand zur Straße
LH	klein bis mittel	beliebig	klein bis groß	quadratisch bis komplex	mittel	locker, heterogene Struktur
WGL	klein bis sehr groß	beliebig	klein bis sehr groß	meist rechteckig	mittel bis hoch	meist offene Struktur
ÖG	klein bis sehr groß	beliebig	mittel bis sehr groß	beliebig	mittel bis hoch	meist offene Struktur
NG	sehr klein	beliebig	sehr klein	meist rechteckig	beliebig	beliebige Struktur

Die Übersicht zeigt, dass einige der Gebäudetypen bereits durch ein oder mehrere Eigenschaften voneinander unterscheidbar sind. So ist beispielsweise ein freistehendes Ein- oder Zweifamilienhaus (EZFH-EH) durch eine kleine Größe und kompakte Fläche gekennzeichnet, die sich gut von den Eigenschaften einer Reihenhausbebauung (EZFH-RH) bzw. dem Mehrfamilienhaus in Zeilenbauweise (MFH-TZ) abgrenzt. Auf der anderen Seite wird deutlich, dass die Gebäudeform, wie beispielsweise für Gebäude in dörflicher Struktur (LH) oder im historischen Ortskern (MFH-H), nur mit vagen Begriffen beschrieben werden kann und deren Eigenschaften zum Teil eine hohe Variabilität besitzen.

Eine linguistische Beschreibung allein reicht nicht aus, um ein Modell zur Klassifizierung zu entwickeln, da die Begriffe noch so aufbereitet werden müssen, dass sie von einem Computer verarbeitet werden können. Ein Problem ist, diese Eigenschaften zu quantifizieren, da beispielsweise nicht klar ist, ab wann die Gebäudegröße noch „klein“ bzw. schon „groß“ ist. Dies stellt eine große Hürde bei der wissensbasierten Klassifizierung dar. Gleichzeitig ist eine Objektbeschreibung aufgrund von Mehrdeutigkeiten nur sehr schwer möglich, da das Regelwerk sehr komplex wird. Da die Gebäudetypen in den verschiedenen Eingangsdaten unterschiedlich abgebildet werden, wäre der Aufbau eines Regelwerks für jeden Eingangsdatentyp nötig. Eine Lösung bietet der in dieser Arbeit verfolgte datengetriebene Mustererkennungsansatz auf Grundlage eines umfangreichen Merkmalssets mit dem die hier beschriebenen Eigenschaften quantifiziert werden. Dazu werden möglichst viele Merkmale erhoben, die für dieses Erkennungsproblem nützlich erscheinen und in einem weiteren Schritt einer Merkmalsselektion unterzogen.

7.5.2 Merkmalstypen

Die Gebäudegrundrisse, Baublöcke und Hauskoordinaten werden in einer objektstrukturierten Datenbank vorgehalten. Mithilfe rasterbasierter Methoden der Bildverarbeitung aber auch vektorbasierter Verfahren der räumlichen Analyse können eine Vielzahl an Merkmalen automatisch aus den Daten gewonnen werden. Zunächst erfolgt jedoch eine Betrachtung der Merkmale auf konzeptioneller Ebene, das heißt einer von der letztendlichen Implementierung unabhängigen Darstellung. Eine vertiefte Studie zu den Eigenschaften und Beziehungen von Geoobjekten, wie sie in räumlichen Daten vorliegen, ist in Peter (2001) sowie Steiniger und Weibel (2005, 2007) beschrieben. Ziel der von den Autoren vorgeschlagenen Typologie der horizontalen Beziehungen ist eine systematische Sicht auf alle charakteristischen Merkmale und Beziehungen des Karteninhaltes, um sie für die automatische Generalisierung nutzbar zu machen. In Anlehnung an diese Typologie können die für das Verfahren entwickelten Merkmale gruppiert werden (Abb. 7-8).

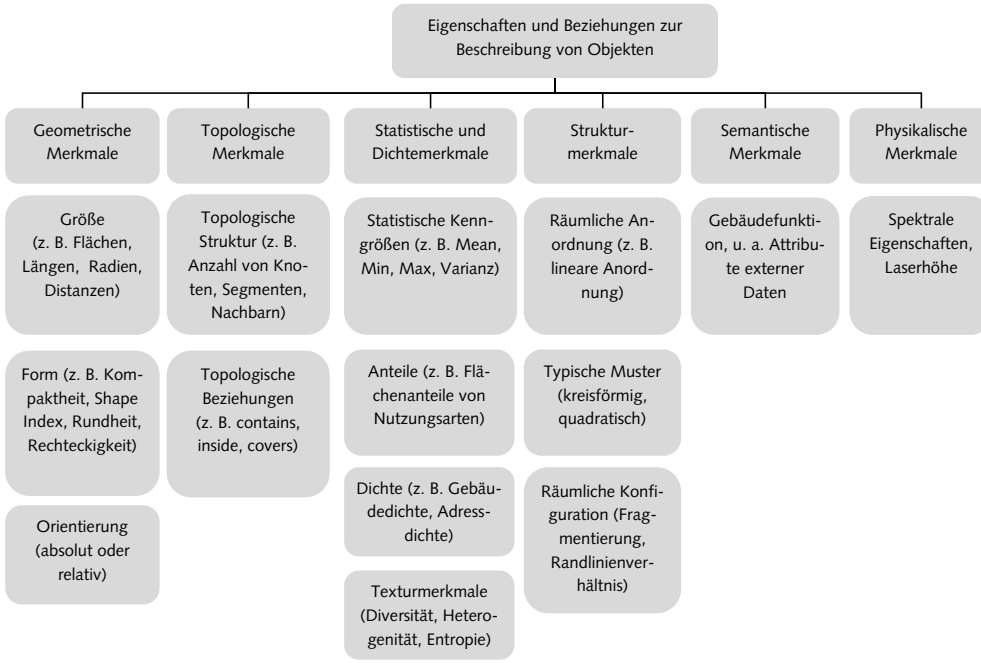

Abb. 7-8: Merkmale und Beziehungen zur Beschreibung von Kartenobjekten in Anlehnung an Peter (2001), Steiniger und Weibel (2005; 2007) und Sester (1995)

Die Merkmale haben immer einen Bezug zu einem Objekt. Sie können sich auf Einzelgebäude, Gebäuderegionen, Gebäudegruppen oder auch auf eine definierte Nachbarschaft oder externe Geometrie wie den Baublock beziehen. Neben den bereits explizit in der Datenbank modellierten Objekten können sich die Merkmale (z. B. Fläche, Länge, Umfang) auch auf abgeleitete Hilfsobjekte beziehen. Die Abb. 7-9 zeigt verschiedene Hilfsobjekte am Beispiel, wie etwa den Flächenschwerpunkt einer Gebäuderegion, das umschreibende Rechteck, den minimal umschreibenden Kreis oder die Mittelachse der Gebäuderegion (Skelettlinie), die sich aus den Mittelpunkten aller größten einschreibenden Kreise einer Gebäuderegion ergeben.

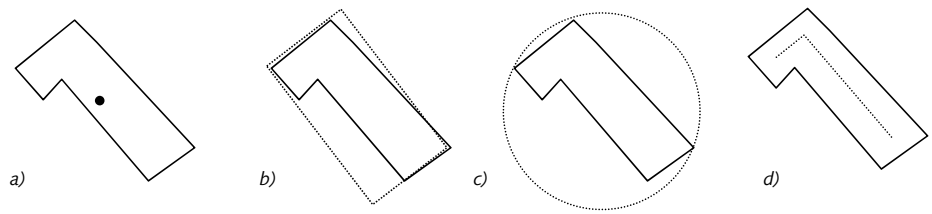

Abb. 7-9: Abgeleitete Hilfsobjekte: a) Flächenschwerpunkt, b) Kleinstes umschließendes Rechteck mit beliebiger Orientierung, c) minimaler Umkreis, d) Skeleton-Linie als Mittelachse der Gebäuderegion (Quelle: Eigene Darstellung)

7.5.2.1 Geometrische Merkmale

Zu den geometrischen (auch morphologischen) Merkmalen zählen Größen-, Form- und Orientierungsmerkmale.

Größenmerkmale sind messbare, metrische Größen wie der Flächeninhalt, Radien oder Distanzen. Die Messungen beziehen sich einerseits auf ein Objekt, wie beispielsweise der Flächeninhalt oder der Umfang einer Gebäuderegion. Die Merkmale können jedoch auch Bezug zu einem Hilfsobjekt nehmen. So kann beispielsweise mit dem kleinsten umschreibenden Kreis oder dem größten einschreibenden Kreis eines Objektes die minimale oder maximale Breite eines Gebäudes in Annäherung beschrieben werden. Andererseits gehören der Gruppe der Größenmerkmale auch alle Abstands- und Differenzmessungen zwischen zwei Objekten an, wie beispielsweise der Abstand zum nächsten Gebäude oder die Differenz der Radien des kleinsten umschreibenden und größten einschreibenden Kreises eines Gebäudes.

Formmerkmale von Objekten spielen bei der Schrifterkennung aber auch in der Landschaftsökologie eine bedeutende Rolle. Im Unterschied zu den Größenmerkmalen wird ein Formmerkmal häufig durch eine Verhältniszahl ausgedrückt. Ein sehr einfaches Maß ist der Formfaktor als Verhältnis von Umfang zur Fläche (Horton, 1932). Der Nachteil ist jedoch dessen Größenabhängigkeit, da eine Vergrößerung des Objektes bei gleichbleibender Form zur Verringerung des Verhältnisses führt (Maceachren, 1985). In der Literatur werden daher skaleninvariante Formmerkmale bevorzugt, deren Maßzahl eine relative Beziehung zu einer idealisierten geometrischen Figur (Kreis, Quadrat oder Rechteck) ausdrückt. Aus den Größenmerkmalen, wie der Fläche, Umfang oder dem Radius, lassen sich diverse Formindizes ableiten. Ein bekanntes Maß ist beispielsweise der Shape Index, der das Verhältnis von Umfang zur Fläche des Objektes in Beziehung zu dem Umfang eines Kreises oder eines Quadrates gleichen Oberflächeninhalts setzt (McGarigal & Marks, 1994). Der Shape-Index beschreibt damit die Komplexität von Objekten. Indizes, die sich am kleinsten umschreibenden Kreis orientieren, sind Maße für die Gestrecktheit, wie etwa der Schumm´s Shape Index (Schumm, 1956). Andere Maße orientieren sich hingegen am größten umschreibenden Kreis als Maß für die innere Kompaktheit oder einer Kombination aus dem kleinsten und größten umschreibenden Kreis (Borg & Fichtelmann, 1998). Ein weiteres, wenn auch weniger intuitives Maß zur Beschreibung der Formkomplexität ist die Fraktale Dimension D von Mandelbrot (1983). Mit diesem Maß kann die Irregularität der Konturlinie eines Objektes beschrieben werden (Lang & Blaschke, 2007; McGarigal & Marks, 1994). Für eine vertiefte Studie zu verschiedenen Formmerkmalen und deren Unterschiede sei auf die entsprechende Literatur verwiesen (Angel et al., 2010; Borg & Fichtelmann, 1998; Boyce & Clark, 1964; Clark & Gaile, 1973; Maceachren, 1985; McGarigal & Marks, 1994; Wentz, 2000). Die digitale Bildverarbeitung hält weitere Verfahren zur Beschreibung von Formen bereit, wie beispielsweise die momentbasierten Formmerkmale oder Fourier-Deskriptoren zur Beschreibung von Konturlinien (vgl. Jähne, 2005; Nixon & Aguado, 2008).

Als dritte Untergruppe werden *Orientierungsmerkmale* eingeführt. Man unterscheidet dabei absolute (Richtung im zugrundeliegenden Koordinatensystem) und relative Orientierungsmessungen (Richtung zu einem Referenzobjekt). Das Maß für die Orientierung eines Gebäudes kann durch die längste Kante des Polygons, die mittlere Orientierung aller Kanten

oder durch die längste Seite des kleinsten umschreibenden Rechteckes bestimmt sein. In einer vergleichenden Studie zur Eignung verschiedener Orientierungsmaße wird die Richtung der längsten Seite des umschreibenden Rechtecks als das beste Orientierungsmaß für Gebäude angegeben (Duchêne et al., 2003). Die Berechnung der Orientierung für komplexe Objekte kann aber auch über die Orientierung des längsten Segmentes einer abgeleiteten Skelettlinie berechnet werden (siehe Merkmal ANGLPCL im Anhang C.1). Eine Beschreibung der Gebäudeorientierung für die Gebäudeklassifizierung macht allerdings nur mit relativen Maßen (z. B. in Bezug zur Straßenachse) oder statistischen Aussagen zur Varianz der Ausrichtung Sinn, da offenbar kein direkter Zusammenhang zwischen der absoluten Gebäudeorientierung und der vorliegenden städtebaulichen Struktur besteht (Steiniger et al., 2008). Es sei jedoch angemerkt, dass die absolute Orientierung von Gebäuden aus energetischen Gesichtspunkten (Energieeffizienz, Solarpotenzial) wohl eine Rolle spielen kann (vgl. StMi Bayern, 2010).

Neben den unmittelbar am Objekt gemessenen Merkmalen können die Merkmale auch horizontale Beziehungen zwischen zwei Objekten beschreiben. Diese kontextbezogenen Merkmale nehmen z. B. Bezug zu Nachbargebäuden in einer definierten Umgebung (Sester, 1995). Eine weitere kontextuelle Information ist der Abstand des Gebäudes zur Baublockgrenze zur Beschreibung der relativen Lage im Baublock oder die Distanz des Gebäudes zum Stadtzentrum zur Beschreibung der Zentralität.

7.5.2.2 Topologische Merkmale

Topologische Merkmale sind translations-, rotations- und skaleninvariante Objekteigenschaften, d. h. sie sind unabhängig von der Größe, Form und Orientierung der Objekte. Mit diesen Merkmalen kann die topologische Struktur einer Geometrie (z. B. Anzahl von Knoten, Segmenten, Nachbarn und Löchern im Polygon) oder eine topologische Beziehung zwischen Objekten beschrieben werden. Ein wichtiges topologisches Merkmal ist beispielsweise die Anzahl der Löcher einer Gebäuderegion. Dessen Nutzung erscheint darum sinnvoll, da eine geschlossene Blockrandbebauung häufig durch ein Ringpolygon mit einem oder mehreren Löchern gekennzeichnet ist.

Ein weiteres Beispiel ist die topologische Auswertung der Skelettlinie einer Gebäuderegion, in dem Knotenanzahl, Anzahl der Verzweigungspunkte oder die Anzahl der Segmente bestimmt werden. Mittels einer geometrisch-topologischen Nachbarschaftsanalyse im GIS können weitere topologische Merkmale abgeleitet werden, wie etwa die Anzahl aller adjazenten (benachbarten) Einzelgebäude eines Gebäudekomplexes. Neben den topologischen Merkmalen auf Objektebene spielen topologische Lagebeziehungen zu externen Objekten eine wichtige Rolle. Grundlagen für eine Formalisierung der topologischen Beziehungen im Vektormodell sind mit dem 9-Intersection-Model in (Egenhofer & Herring, 1994) gegeben und heutzutage in fast jeder GIS-Applikation implementiert. So kann beispielsweise mit einer räumlichen Abfrage geprüft werden, ob ein Gebäudepolygon eine Gebäudeadresse enthält.

7.5.2.3 Statistische und Dichtemerkmale

Statistische Merkmale sind kontinuierliche Größen und beziehen sich auf einen vorab definierten Bereich oder eine Objektgruppe, wie z. B. eine Gebäudegruppe, die sich in einem Baublock oder einer definierten Suchumgebung befinden. Mithilfe der räumlichen Analyse und der deskriptiven Statistik können Kenngrößen wie Mittelwert, Standardabweichung, Minimum, Maximum und Varianz eines Merkmales ausgewertet werden. Als Beispiel sei hier der mittlere Flächenhalt oder die mittlere Distanz aller Gebäude in einem definierten Bereich (Puffer um Gebäude) genannt. Zu dieser Gruppe zählen auch Merkmale, mit denen Flächenanteile, Häufigkeiten und Dichten oder mittlere Orientierungen in Bezug zu einer höheren Raumeinheit beschrieben werden. Dichtemerkmale, wie beispielsweise die Anzahl der Gebäude in einer Umgebung, haben gezeigt, dass sie einen sehr großen Informationsanteil für die Charakterisierung städtischer Strukturen besitzen (Steiniger et al., 2008). Eine weitere Form sind Merkmale zur Beschreibung der Gleichmäßigkeit und Vielfältigkeit (Heterogenität bzw. Diversität). Hierzu zählen Merkmale der statistischen Texturanalyse (Haralick et al.,1973) oder Diversitätsindizes der Landschaftsökologie, wie beispielsweise der Shannon Index oder der Simpson Index (McGarigal & Marks, 1994; O'Neill et al., 1988). Es hat sich gezeigt, dass sich derartige Maße eignen, um städtische Landnutzungstypen zu analysieren und zu beschreiben (Herold et al., 2003).

7.5.2.4 Strukturmerkmale

Unter Strukturmerkmalen werden Merkmale verstanden, mit denen die räumliche Anordnung von Objekten eines komplexen Musters (z. B. einer linearen Anordnung einer Gebäudegruppe) oder die Form eines Musters (kreisförmig, quadratisch) auf einer höheren räumlichen Ebene beschrieben werden. Diese Muster müssen zunächst mit einem Verfahren automatisch erkannt und über ein entsprechendes Merkmal (z. B. Formtyp) explizit gemacht werden. Dazu zählen insbesondere Muster von Gebäudegruppen, die durch Auswertung horizontaler Beziehungen gewonnen werden können (Burghardt & Steiniger, 2005; Li et al., 2004; Ruas & Holzapfel, 2003). Eine Typologie für typische Gebäudemuster wird von Zhang et al. (2010) vorgeschlagen, die zwischen kollinearen, kurvenförmigen, straßenbegleitenden, gitterförmigen und unregelmäßigen Gebäudemustern unterscheidet.

Zu den Struktureigenschaften zählen Steiniger & Weibel (2007) auch Merkmale zur Beschreibung der räumlichen Konfiguration und Fragmentierung. An dieser Stelle seien beispielsweise Strukturmaße, wie das Flächen-Randlinien-Verhältnis, der Contagion-Index oder der Lacunarity-Index genannt (McGarigal & Marks, 1994).

7.5.2.5 Semantische Merkmale

Semantische Merkmale sind qualitative, bereits explizit in den Daten modellierte Informationen. Ein semantisches Merkmal ist zum Beispiel die Gebäudefunktion, die nach der Datenaufbereitung für Gebäudegrundrisse aus der Liegenschaftskarte vorliegt und mit einem Attribut am Gebäude explizit modelliert ist. Das semantische Merkmal kann jedoch auch aus einer externen Geometrie übernommen werden, wie z. B. die Nutzungsart des Baublocks der baulich geprägten Fläche aus dem ATKIS® Basis-DLM, in dem sich das Gebäude befindet. Weitere semantische Merkmale, wie z. B. zur Baualtersklasse oder zur Dachform, liegen

zwar nicht immer vor, sollen aber an dieser Stelle nicht unerwähnt bleiben, da sie bei Vorhandensein optional im Verfahren verwendet werden könnten.

7.5.2.6 Physikalische Merkmale

Physikalische Merkmale sind mit einem Sensor aufgenommene Messungen (Spektrale Information, Phasenverschiebung, Laufzeit) und spielen bei der Nutzung fernerkundlicher Daten eine Rolle. Physikalische Merkmale spielen in dem hier beschriebenen Ansatz eine untergeordnete Rolle, sollen aber der Vollständigkeit wegen aufgeführt sein. Durch Kombination der Eingangsdaten mit Fernerkundungsdaten könnten beispielsweise multispektrale Informationen innerhalb einer Gebäuderegion oder der NDVI im Umkreis eines Gebäudes ausgewertet werden. Zu den physikalischen Merkmalen zählt auch die Gebäudehöhe aus Laserscannerdaten, die über eine physikalische Messung der Laufzeit bestimmt wurde.

7.5.3 Ebenen der Merkmalsberechnung

Für eine automatische Klassifizierung der Gebäudegrundrisse reicht eine vom Kontext losgelöste Merkmalsbeschreibung der Gebäudegrundrisse nicht aus. Darum werden kontextbezogene Merkmale berechnet, die Bezug zu einer höheren räumlichen Ebene haben. Hierzu werden 5 verschiedene räumliche Bezugsebenen eingeführt, auf welche die Merkmale berechnet werden können (Tab. 7-8).

Tab. 7-8: Merkmale auf unterschiedlichen räumlichen Ebenen

Mikro-Ebene		**Meso-Ebene**		**Makro-Ebene**
Einzelgebäude	Gebäuderegion	Umgebung (100 m Suchradius)	Baublock	Siedlungskörper
	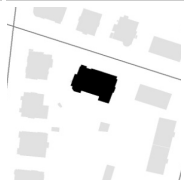			
z. B. Fläche, Umfang, Gebäudehöhe, Nutzung	z. B. Fläche, Umfang, Anzahl adjazenter Gebäude	z. B. Gebäudeanzahl, Mittlerer Abstand der Gebäude	z. B. Gebäudeanzahl, Überbauungsgrad, ATKIS®-Nutzungsart	z. B. Größe des Siedlungskörpers

Diese Ebenen können den Maßstabsebenenen Mikro- (Einzelgebäude, Gebäuderegion), Meso- (Baublock, Umgebung) und Makro-Ebene (Siedlungskörper) zugeordnet werden.

Die *Mikroebene* ist die Ebene individueller Gebäude und damit gleich der Ebene, auf der die Interpretation bzw. Klassifizierung der Gebäudegrundrisse erfolgt. Deutlich wird, dass die zugrundeliegende Repräsentationsform den Umfang der ableitbaren Merkmale bestimmt. Für Gebäudegrundrisse in Gebäuderegion-Repräsentation, wie sie beispielsweise durch Extraktion aus topographischen Karten gewonnen werden, steht nur die Ebene der Gebäuderegion zur Verfügung. Bei Gebäudegrundrissen in Einzelgebäude-Repräsentation (Eingangsdatentyp II-V) steht neben der Gebäuderegion eine zusätzliche Ebene „Einzelgebäude" für die Berechnung der Objektmerkmale bereit. Damit können zusätzliche geometrische Merk-

male (z. B. Fläche, Umfang, Nutzung der Einzelgebäude), topologische Merkmale (Anzahl der Einzelgebäude in einer Gebäuderegion) oder statistische Merkmale (Mittelwert und Standardabweichung der Fläche aller Einzelgebäude auf Ebene der Gebäuderegion) berechnet werden. Für die Berechnung von Merkmalen zur Beschreibung der Gebäuderegionen müssen bei Einzelgebäude-Repräsentation alle adjazenten Einzelgebäude zusammengefasst werden. Das setzt in diesem Fall voraus, dass benachbarte Gebäude immer eine gemeinsame Kante besitzen. Im Falle von topologisch nicht ganz sauber modellierten Daten wäre die Einführung einer Abstandstoleranz von 1 m sinnvoll (vgl. Römer & Plümer, 2010).

Auf *Mesoebene* wird der räumliche Kontext mit Merkmalen beschrieben. Hierzu werden zwei räumliche Ebenen festgelegt. Einerseits die unmittelbare Umgebung eines Gebäudes in einem definierten Suchbereich von 100 m und andererseits der Baublock aus dem ATKIS® Basis-DLM, in dem sich das Gebäude befindet. Gegenüber dem Baublock werden bei Merkmalen, die sich auf eine Abstandsumgebung beziehen, auch Kontextinformationen über die Baublockgrenze hinweg mit einbezogen.

Die *Makroebene* dient der Bereitstellung von Kontextinformationen auf höchster Ebene und spielt bei der Anwendung auf große Untersuchungsgebiete, die sich über mehrere Ortschaften und Städte erstrecken, eine wichtige Rolle. Kleine Ortschaften mit ländlichem Charakter besitzen gegenüber städtischen Räumen eine andere Zusammensetzung von Gebäudetypen. So ist beispielsweise eine Hochhausbebauung im ländlichen Raum unwahrscheinlicher als im städtischen Raum. Es erscheint deshalb sinnvoll, die Urbanität mit geometrischen Merkmalen (Größe, Kompaktheit des Siedlungskörpers) oder Dichtemerkmalen (Gebäudedichte im Siedlungskörper) auf Ebene der Siedlungskörper zu beschreiben. Siedlungskörper können durch Zusammenfassung aller benachbarter Baublöcke abgeleitet werden. Neben den eben dargestellten Merkmalen, die konkreten Objektbezug besitzen und eindeutig einer räumlichen Ebene zugeordnet werden können, gibt es Merkmale, die eine horizontale Beziehung zwischen zwei Objekten unterschiedlicher Ebene beschreiben. Ein derartiges, Ebenenübergreifendes Merkmal wäre beispielsweise der kürzeste Abstand zwischen einer Gebäuderegion und der Baublockgrenze.

7.5.4 Methoden der Merkmalsgewinnung

Für die rechnerische Umsetzung der Merkmalsberechnung stehen verschiedene Methoden bereit. Im Kontext der kartographischen Mustererkennung werden vermehrt rasterorientierte Ansätze der Merkmalsextraktion eingesetzt (Brügelmann, 1996; Stengele, 1995). Bei der Interpretation von Mustern in Vektordaten werden hingegen Methoden der algorithmischen Geometrie (engl. *Computational Geometry*) (Berg et al., 2000) angewendet. Je nach vorliegender Modellform können dementsprechend verschiedene Operatoren angewendet werden, die zu vergleichbaren aber nicht identischen Ergebnissen führen. Bei der Distanzberechnung zwischen zwei Punkten liegt im Vektormodell eine euklidische Metrik zugrunde. Im Rastermodell wird die Distanz zwischen zwei Bildpunkten berechnet, wobei neben der euklidischen Metrik auch andere Metriken, wie beispielsweise die City-Block-Metrik (4er-Nachbarschaft der Rasterzellen) oder die Schachbrett-Metrik (8er-Nachbarschaft), genutzt werden können.

Die Merkmalsextraktion für das hier vorgestellte Verfahren erfolgt in beiden Modellwelten, sowohl raster- als auch vektorbasiert. Dies ist dadurch begründet, dass bestimmte Merkmale nur im Raster- oder nur im Vektordatenmodell berechnet werden können, die Merkmalsberechnung in einer der beiden Modelltypen einfacher umzusetzen ist oder bereits entsprechende Algorithmen implementiert vorliegen, die die Datenstruktur vorgeben. In dem entwickelten Verfahren werden deshalb stets beide Modellformen (Raster- und Vektormodell) für die Berechnung der Merkmale vorgehalten.

Die Bildverarbeitung hält eine Menge von Operatoren bereit, die der Beschreibung von Objekten in Bildern dienen. Ein Großteil der geometrischen Merkmale kann mit Methoden der Bildverarbeitung aus einem binären Rasterlayer gewonnen werden. In Vorarbeiten wurden bereits verschiedene Programmroutinen zur Merkmalsgewinnung entwickelt und in einer HALCON-Umgebung implementiert (Meinel et al., 2008a). Diese konnten im Rahmen dieser Arbeit genutzt werden. Die vektorbasierten Gebäudegrundrisse werden hierzu in ein Rastermodell mit einer Rasterweite von 1,25 m überführt, was der gegebenen Scanauflösung topographischer Karten (Eingangsdatentyp I und II) entspricht. Nach der Merkmalsextraktion werden die rasterbasierten Merkmale mit den Gebäudegrundrissen im Vektormodell verknüpft. Für Gebäude aus topographischen Rasterkarten kann hingegen direkt auf den bereits abgeleiteten binären Gebäudelayer zugegriffen werden.

Die bevorzugte Wahl rasterbasierter Methoden hat einen weiteren Grund. Bei der Raster-Vektor-Konvertierung der Gebäuderegionen aus topographischen Rasterkarten richten sich die Linien des Gebäudepolygons nach den Zellrändern des Eingabe-Rasters. Bei Gebäudegrundrissen, die direkt aus einem Vektormodell übernommen werden, ist dieser „Treppeneffekt“ nicht gegeben. Formbasierte Merkmale, insbesondere jene, die über den Umfang berechnet werden, wie der Shape-Index oder die Fraktale Dimension, sind gegenüber diesem Effekt nicht robust und führen deshalb zu unterschiedlichen Ergebnissen. Um eine Vergleichbarkeit dieser Merkmale zwischen den verschiedenen Eingangsdatentypen zu gewährleisten, erfolgt deshalb die Berechnung in einem einheitlichen Rastermodell. Damit wirkt sich der Treppeneffekt für ein Merkmal gleichermaßen für alle Eingangsdatensätze aus, wohlwissend, dass es bei Vektordaten zu einem geringen Informationsverlust kommt, der jedoch aus Autorensicht vernachlässigbar ist.

Die vektorbasierte Merkmalsberechnung erfolgt unter Nutzung der objektstrukturierten Daten der Gebäudegrundrisse, Baublöcke und Hauskoordinaten in einer GIS-Umgebung. Dazu zählen beispielsweise Flächengrößen und Merkmale, die auf topologischen Beziehungen beruhen, wie die Anzahl der Hauskoordinaten im Gebäude oder der Anteil Gebäudefläche im Baublock.

7.5.5 Workflow der Merkmalsberechnung

Für die rasterbasierte Merkmalsberechnung werden Methoden der Bildverarbeitung unter Nutzung der HALCON-Programmbibliothek eingesetzt. Die vektorbasierte Merkmalsberechnung erfolgt mittels räumlicher Analysefunktionen in der ArcGIS-Desktop-Umgebung. Die einzelnen Geoverarbeitungsschritte wurden mithilfe von Python-Skripten zusammengeführt.

In Abb. 7-10 wird der Workflow der Merkmalsberechnung dargestellt. Ausgehend von den Gebäudegrundrissen wird zunächst nach der Repräsentationsform (Einzelgebäude, Gebäuderegion) unterschieden, da bei einer Einzelgebäude-Repräsentation zusätzliche vektorbasierte Merkmale (z. B. Anzahl adjazenter Polygone) abgeleitet werden können. Die Einzelgebäude werden dann zu Gebäuderegionen zusammengefasst. Da kleine Nebengebäude die Berechnung einiger Objektmerkmale verfälschen, werden diese vorab detektiert und eliminiert. Auf Ebene der Gebäuderegion erfolgt eine vektor- und rasterbasierte Merkmalsberechnung für beide Repräsentationsformen (Einzelgebäude und Gebäuderegionen). Für die rasterbasierten Merkmale ist eine Raster-Vektor-Konvertierung nötig, in der aus dem binären Bild Regionen (Zusammenhangskomponenten) mit einer eindeutigen Objekt-ID gebildet werden. Beispiele von rasterbasierten Merkmalen sind die mittlere Gebäudebreite oder die Länge einer Gebäuderegion, die über eine Extraktion der Skellettlinie ermittelt werden kann. Nach Merkmalsberechnung werden diese in der Gebäudedatenbank gespeichert.

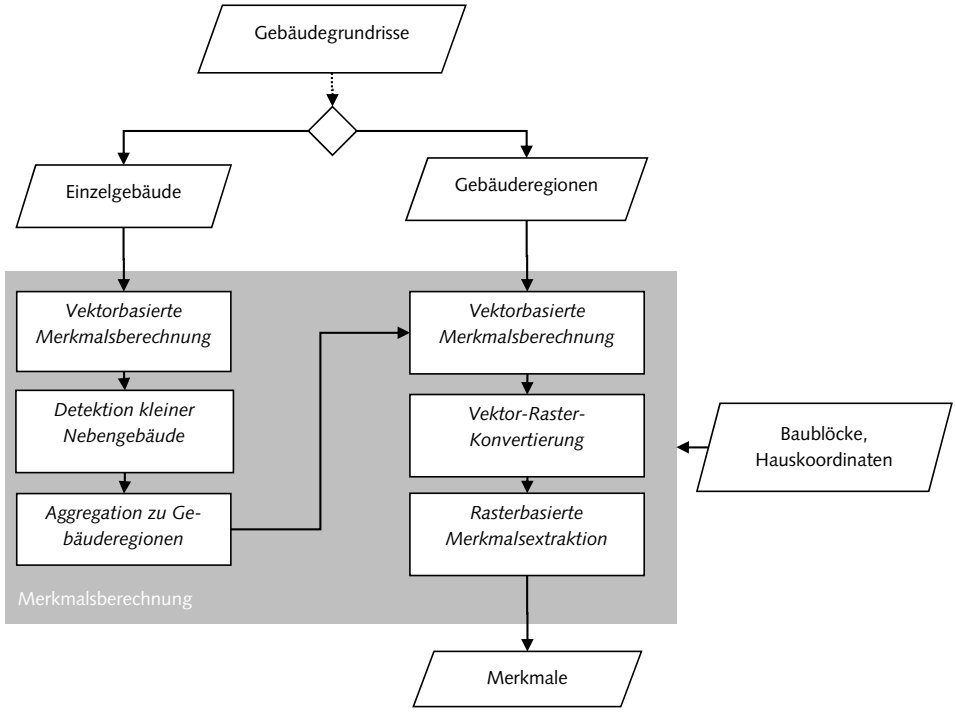

Abb. 7-10: Workflow der Merkmalsberechnung

Für die Merkmalsberechnung werden die unterstützenden Daten (Baublöcke und Hauskoordinaten) hinzugezogen. Dabei wird auch die Objektart der Baublockgeometrie als semantisches Merkmal übernommen. Die abgeleiteten Merkmale werden in einer *Personal Geodatabase* gehalten und können mit der Software R eingelesen und statistisch weiterverarbeitet werden. Eine Übersicht aller berechneten Merkmale ist im Anhang C zu finden.

7.5.6 Merkmale in Abhängigkeit der Eingangsdaten

In Abhängigkeit des zugrundeliegenden Eingangsdatentyps können Merkmalssets verschiedenen Umfanges berechnet werden. In der Tab. 7-9 sind die Merkmale nach gegebener Bezugsebene differenziert. Merkmale und Beziehungen auf Ebene der Gebäuderegion, des Baublocks, der Umgebung oder des Siedlungskörpers können für alle Eingangsdatentypen berechnet werden und sind hier unter der Gruppe der Grundmerkmale (G) zusammengefasst. Merkmale, die nur für Einzelgebäude berechnet werden können, werden unter der Gruppe der Einzelgebäudemerkmale (E) geführt. Alle weiteren datenspezifischen Merkmale, die nur für bestimmte Eingangsdatentypen ableitbar sind, wie etwa die spezielle Umrißsignatur für Hochhäuser in der TK25/DTK25-V, die Gebäudefunktion in Datenmodellen des Liegenschaftskatasters oder die Höheninformationen bei 3D-Gebäudestrukturen, sind der Gruppe der speziellen Merkmale (S) zugeordnet.

Tab. 7-9: Merkmale in Abhängigkeit des Eingangsdatentyps

		Objektbeschreibende Merkmale und Beziehungen (geometrisch, topologisch, statistisch)				Semantische und physikalische Merkmale		
	Eingangsdatentyp	Einzel-gebäude	Gebäude-region	Baublock/ Umgebung	Siedlungs-körper	Hochhaus (Signatur)	Gebäude-funktion	Gebäu-dehöhe
Gebäuderegi-on	Typ I (z.B. TK25, DTK25-V)		●	●	●	●		
	Typ II (z.B. DTK25)		●	●	●		●	
Einzel-gebäude	Typ III (z.B. HU, ATKIS)	●	●	●	●			
	Typ IV (z.B. ALK, ALKIS®)	●	●	●	●		●	
	Typ V (z.B. 3D-GS)	●	●	●	●		●	●
	Merkmals-kategorie	Einzel-gebäude-merkmale (E)	Grundmerkmale (G)			Spezielle Merkmale (S)		

7.5.7 Erkennung kleiner Nebengebäude

Die Gebäudegrundrisse in Einzelgebäude-Repräsentation werden für die Merkmalsberechnung zu Gebäuderegionen aggregiert (vgl. Abb. 7-10). Ein Problem stellen dabei kleine, unbedeutende Nebengebäude dar, welche die Merkmale verfälschen können. Besonders Garagen und Anbauten sollten vor der Anwendung einer Merkmalsextraktion eliminiert werden (Henn et al., 2012; Hussain et al., 2007). So können beispielsweise zwei Einfamilienhäuser über zwei Garagen miteinander verbunden sein, die einen zusammenhängenden Gebäudekomplex bilden. Abgeleitete geometrische Merkmale auf Ebene der Gebäuderegion würden sich in diesem Fall auf alle zusammenhängenden Gebäudeteile (zwei Wohngebäude und die Garagen) beziehen. Für eine Beschreibung der Gebäude ist es deshalb wichtig, nur Merkmale abzuleiten, die sich auf Gebäude exklusive den angeschlossenen, kleinen Nebengebäuden beziehen. Darum werden für die Berechnung ausgewählter Merkmale alle kleinen Nebengebäude automatisch identifiziert und eliminiert.

Die Erkennung kleiner Nebengebäude ist nur für Einzelgebäude relevant und erfolgt in zwei Schritten. Zunächst werden alle *Nebengebäude* über die laufende Nummer (ALK, ALKIS®), einer expliziten Modellierung (3D-GS) oder durch Auswertung der Anzahl der Hauskoordinaten im Gebäudepolygon (HU, ATKIS) selektiert. Im zweiten Schritt werden aus dieser Menge nur die *kleinen Nebengebäude* über ein Flächenkriterium, getrennt für *freistehende* und *nichtfreistehende Nebengebäude,* herausgefiltert (Tab. 7-10).

Tab. 7-10: Regeln zur Selektion kleiner Nebengebäude

Eingangsdatentyp	Amtliche Produkte	Regel 1 (Nebengebäude)	Regel 2 (Kleine Nebengebäude)
Typ I	TK25	-	-
	DTK25-V		
Typ II	DTK25		
Typ III	HU	Anzahl der Hauskoordinaten nach Verschneidung $HK_{Anz} = 0$	Kleine freistehende Nebengebäude: $SUM_{AnzPo} = 1 \wedge Fläche < AreaSingleMin$ oder Kleine nichtfreistehende Nebengebäude: $SUM_{AnzPo} > 1 \wedge Fläche < AreaMultiMin$
	ATKIS		
Typ VI	ALK	Attribut „Laufende Nummer des Gebäudes“ (Objektschlüssel 1032) $LFD_{GEBNR} \geq 2$	
	ALKIS®	Attribut: „Laufende Nummer“ $LNR \geq 1$	
Typ V	3D-GS	Attribut „Gebäudetyp“ $GEB_{TYP} = "NG"$	

Mit der ersten Regel werden zunächst die Nebengebäude aus dem Einzelgebäudedatensatz selektiert. Nebengebäude sind im Sinne des Katasters alle Gebäude ohne eigener Hausnummer oder Pseudo-Hausnummer. In der ALK wird für jedes Gebäude ein bundesweit eindeutiges Gebäudekennzeichen vergeben. Mit diesem 24-stelligen Schlüssel kann mit den letzten zwei Stellen („Laufende Nummer des Gebäudes“) zwischen Haupt- und Nebenge-

bäude unterschieden werden. Die laufende Nummer ist für das Hauptgebäude immer „01" und für die Nebengebäude beginnend mit „02" fortlaufend nummeriert (OBAK-LiKa SN, 2005). Auch im ALKIS® Basis-DLM ist eine Unterscheidung der Haupt- und Nebengebäude mit dem Attribut „Laufende Nummer" (LNR) der Objektart „Lagebezeichnung mit Pseudonummer" möglich. Im Gegensatz zur ALK besitzen jedoch die Hauptgebäude keine LNR und die Nummerierung der Nebengebäude beginnt mit eins (AdV, 2008d). Bei den 3D-Gebäudestrukturen können Nebengebäude über das Attribut „GEB_TYP" selektiert werden, dessen Attributwert mit „NG" (Nebengebäude) belegt ist. Bei Einzelgebäuden ohne derartige Information (HU, ATKIS) können die Nebengebäude über das Attribut „HK_Anz"[62] abgefragt werden, da Nebengebäude in der Regel keine Hauskoordinaten besitzen.

Im zweiten Schritt werden aus der Menge der Nebengebäude die kleinen Nebengebäude selektiert. Im Laufe der Arbeit hat sich gezeigt, dass die Anwendung dieser zusätzlichen Abfrage sinnvoll ist, da damit sichergestellt wird, dass für die Merkmalsberechnung nur unbedeutende Nebengebäude (Garagen, kleine Schuppen) ohne Wohnnutzung[63] eliminiert werden, da eine Wohnnutzung nicht für alle Nebengebäude oder Gebäude ohne Adresse ausgeschlossen werden kann (z. B. Hinterhaus). Die zusätzliche Abfrage erfolgt über Flächengrößenschwellwerte *AreaSingleMin* und *AreaMultiMin*, die getrennt für *freistehende Nebengebäude* (z. B. freistehender Schuppen) und für am Hauptgebäude angeschlossene *nichtfreistehende Nebengebäude* (z. B. Garagen am Einfamilienhaus) angewendet werden. Die Unterscheidung nach freistehenden und nichtfreistehenden Nebengebäuden ist damit begründet, dass für angeschlossene Nebengebäude ein kleinerer Schwellwert vermutet wird.

Die für Regel 2 benötigten Schwellwerte *AreaSingleMin* (kleines freistehendes Nebengebäude) und *AreaMultiMin* (kleines nichtfreistehendes Nebengebäude) werden auf Grundlage von Referenzdaten[64] bestimmt. Dies erfolgte über eine Analyse der *Receiver Operating Characteristic* (ROC) (Fawcett, 2003). Die ROC-Analyse wird in vielen wissenschaftlichen Disziplinen eingesetzt, um die Abhängigkeit der Sensitivität und Spezifität visuell für verschiedene Parameterwerte in einer Kurve darzustellen. Sie eignet sich auch als Methode zur Optimierung und Ermittlung von Parametern in einem Zweiklassenproblem. Bei der Konstruktion der ROC-Kurve wird auf der x-Achse die relative Anzahl der falsch positiven Werte (engl. *false positive*, TP, 1-Spezifität) und auf der y-Achse die relative Anzahl der richtig positiven Werte (engl. *true positive*, TP, Sensitivität) gegeneinander aufgetragen (vgl. Abb. 7-11, links). Bei Variation des gesuchten Schwellwertes wird das FP-TP-Verhältnis in einer ROC-Kurve dargestellt. Den optimalen Schwellwert im Hinblick auf einen minimalen Fehler erhält man durch Bildung eines Kompromisses aus Treffer- und Fehlerrate. Hierzu wird der Schnittpunkt einer 45° ansteigenden Tangente konstruiert, der die ROC-Kurve berührt, wobei sich dieses Optimum auch analytisch ermitteln lässt, in dem die Fehlerrate gegenüber der

[62] Anzahl der Hauskoordinaten im Gebäudegrundriss nach Verschneidung der Gebäudegrundrisse mit den Hauskoordinaten.

[63] Die Gebäude mit Wohnnutzung stellen in der Arbeit den Fokus dar und sollten mit der Eliminierung der Nebengebäude für die Merkmalsberechnung möglichst unangetastet bleiben.

[64] Als Referenzdaten können Gebäude aus dem Liegenschaftskataster mit einer möglichst vollständig modellierten Gebäudefunktion verwendet werden. Kleine untergeordnete Gebäude, Garagen oder Doppelgaragen wären dann kleine Nebengebäude.

zu testenden Größe, in diesem Fall die Gebäudefläche, aufgetragen und das Minimum bestimmt wird (vgl. Abb. 7-11, rechts).

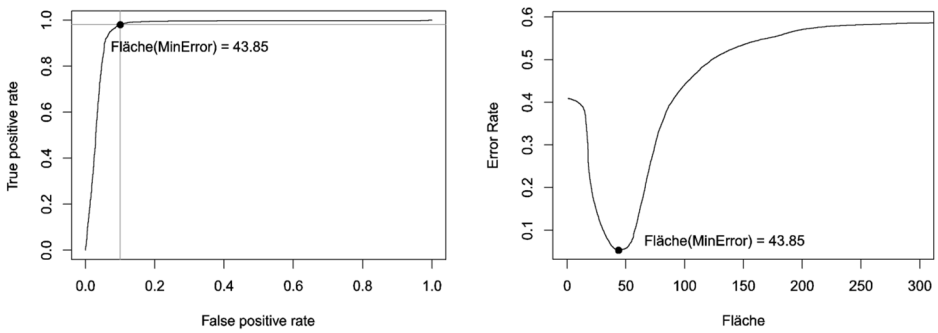

Abb. 7-11: Optimaler Schwellwert bei minimaler Fehlerrate am Beispiel kleiner freistehender Nebengebäude in der ROC-Kurve (links) und Fehlerkurve in Abhängigkeit der Messgröße Fläche (rechts)

Bei der Wahl der Gesamtfehlerrate als Gütekriterium gehen die richtig-positiven Fälle und richtig-negativen Fälle in gleicher Gewichtung ein. Ein fälschlicherweise nicht erkanntes kleines Nebengebäude (falsch-positiv) wäre allerdings eher zu akzeptieren, als ein fälschlicherweise als kleines Nebengebäude interpretiertes Gebäude mit Wohnnutzung (falsch-negativ). Darum wird unter Angabe einer minimal zulässigen Falsch-Negativ-Rate von 1 % (entspricht einer *true positiv rate* > 99 %) der Schwellwert ermittelt, für den die Gesamtfehlerrate minimal ist. Dies bedeutet, dass mit einer 99 %igen Sicherheit ausgeschlossen werden kann, dass versehentlich ein Gebäude mit Wohnnutzung als kleines Nebengebäude interpretiert wurde.

Nach dieser Methodik konnten auf Grundlage von Referenzdaten folgende Schwellwerte für die Regel in Tab. 7-10 bestimmt werden (auf ganze Meter abgerundet):

- Schwellwert für kleines freistehendes Nebengebäude: *AreaSingleMin* < 56 m²
- Schwellwert für kleines nichtfreistehendes Nebengebäude: *AreaMultiMin* < 39 m²

Die Datengrundlage zur Anwendung der ROC-Analyse und die Ergebnisse werden im Ergebnisteil näher beschrieben (Kap. 8.3). Nach Erkennung der kleinen Nebengebäude werden diese für die Berechnung ausgewählter Merkmale vorab eliminiert. Diese Merkmale sind in der Merkmalsbezeichnung mit dem Zusatz „w_“ versehen (vgl. Anhang C).

7.6 Vorverarbeitung der Merkmalsdaten

Nach der Merkmalsberechnung liegen für alle Gebäudegrundrisse die berechneten Merkmale in einer Datenbank vor. Diese Rohdaten müssen für die weitere Verarbeitung vorverarbeitet werden. Dazu zählen die Schritte Konsistenzprüfung, die Merkmalsskalierung, die Merkmalstransformation und das Ersetzen fehlender Werte.

7.6.1 Konsistenzprüfung und Datenbereinigung

In einer Konsistenzprüfung wird der Datensatz auf die Existenz konstanter Merkmale überprüft, da diese keinen Beitrag für die Klassifizierung leisten. Einige Lernverfahren, wie die Lineare Diskriminanzanalyse, sind bei einem konstanten Merkmal sogar nicht ausführbar. Dieser Fall liegt beispielsweise vor, wenn alle Gebäude der Trainingsdatenmenge die gleiche Gebäudefunktion „GEBNUTZ" (einem Merkmal, das aus der ALK übernommen wurde) besitzen. Konstante Merkmale können leicht identifiziert werden, indem geprüft wird, ob deren Varianz $\sigma_j^2 = 0$ beträgt. Diese können anschließend automatisch aus der Lerndatenmenge eliminiert werden.

7.6.2 Skalierung der Merkmale

Der Wertebereich der metrischen Merkmale kann stark variieren. Diese unterschiedliche Skalierung führt bei einigen Klassifikationsansätzen (insb. ANN, SVM etc.) zu einer geringeren Performance, da einige Merkmale über- oder unterbewertet werden. Mit Anwendung einer z-Transformation (auch z-Normalisierung) werden alle Merkmale in einen einheitlichen Wertebereich transformiert und sind besser miteinander vergleichbar (Alpaydin, 2004). Die standardisierten Werte sind wie folgt definiert:

$$\hat{x}_{ij} = \frac{x_{ij} - \mu_j}{\sigma_j} \tag{7.1}$$

Im Ergebnis sind die transformierten Werte so skaliert, dass der Mittelwert $\hat{\mu}_j$ des j-ten Merkmals den Wert 0 und die empirische Standardabweichung $\hat{\sigma}_j = 1$ beträgt. Die Skalierung wird vor dem Erlernen eines Klassifikators auf die Trainingsdatenmenge angewendet.

7.6.3 Transformation kategorialer Merkmale

Die meisten Klassifikationsverfahren können nur metrische Merkmale verarbeiten, weshalb kategoriale Merkmale zur Gebäudefunktion („GEBNUTZ") oder der Flächennutzung aus dem ATKIS® („ATKIS_OBJ") in eine metrische Form überführt werden müssen. Hierzu wird für jede Kategorie eines kategorialen Merkmals eine binäre Dummy-Variable erzeugt, die die jeweilige Ausprägung über die Werte 0 und 1 kodiert. Eine elegantere Lösung bietet eine Kodierung mit relativem Bezug zu einer Referenzkategorie. Mit diesem Verfahren wird die Erzeugung einer Dummy-Variable gespart und die Anzahl der Variablen entspricht immer der Anzahl der Kategorien minus 1. Das Merkmal ATKIS_OBJ mit 4 Ausprägungen kann mithilfe von 3 metrischen Merkmalen kodiert werden (Tab. 7-11).

Tab. 7-11: Prinzip der Transformation kategorialer Merkmale am Beispiel des Merkmals ATKIS_OBJ

Merkmalsausprägung von ATKIS_OBJ	ATKIS1	ATKIS2	ATKIS3
2111	0	0	0
2112	1	0	0
2113	0	1	0
2114	0	0	1

7.6.4 Ersetzen fehlender Werte

Nach der Berechnung und Übernahme von Merkmalen müssen ggf. Merkmale einzelner Objekte mit Fehlwerten belegt werden, wenn beispielsweise einem Gebäude kein Baublock zugeordnet werden kann und eine Berechnung baublockbezogener Merkmale nicht möglich ist. Andererseits kann es vorkommen, dass übernommene Merkmale wegen fehlender oder falscher Attributierung keinen gültigen Wert besitzen (z. B. fehlende Gebäudehöhe). Im Umgang mit diesen *NoData*-Werten gibt es verschiedene Strategien, angefangen vom Ausschluss der Fälle, dem Ersetzen des Wertes mit einem zufälligen oder dem Mittelwert oder durch einen modellbasierten Imputation-Ansatz (engl.: *Missing Data Imputation*) (Gelman & Hill, 2006). Die Behandlung der fehlenden Werte erfolgt in dem Verfahren mithilfe einer statistischen k-Nächste-Nachbar-Imputation der Werte (Hastie et al., 1999). Dieses Verfahren ist ein robustes Verfahren für die Schätzung fehlender Werte und findet Anwendung in der Microarray-Analyse (u. a. Troyanskaya et al., 2001).

Zunächst werden die Eingangsdaten X in die Teilmengen X^c (Daten ohne fehlende Werte) und X^m (Daten mit einem oder mehreren NoData-Werten) aufgeteilt. Die Prozedur für die Imputation sieht dann wie folgt aus (Hastie et al., 1999):

- Berechnung der euklidischen Distanz zwischen einem Objekt mit *NoData*-Wert(en) x* und all den Objekten in X^c unter Verwendung nur jener Merkmale, die in x* gültige Werte besitzen.
- Identifiziere die k-nächsten Nachbarn von X^c.
- Ersetze die fehlenden Werte von x* durch Mittelwertbildung der Werte der k-nächsten Nachbarn.

Der Algorithmus ist im package „impute“ für R implementiert und wird unter Anwendung der Standardparametrierung mit k=10 angewendet.

7.7 Merkmalsselektion

Ziel der Merkmalsselektion ist die Auswahl einer geeigneten Teilmenge aus der Menge aller zur Verfügung stehenden Merkmale. Die Merkmalsselektion dient der Reduzierung der Redundanz, der Dimension, der damit einhergehenden Modellkomplexität sowie unnötiger Rechenressourcen. Da einige Klassifikationsverfahren bei stark korrelierten oder irrelevanten Merkmalen mit wenig Informationsgehalt mit einer geringeren Klassifikationsleistung reagieren, leistet die Merkmalsselektion auch einen Beitrag zur Steigerung der Klassifikationsgenauigkeit. In dieser Phase stellt sich die Frage, welches Merkmalsselektionsverfahren ein-

gesetzt werden kann. Ein sehr einfacher Ansatz wäre eine Selektion der wichtigsten Merkmale bzw. der Verzicht offensichtlich nicht sinnvoller Merkmale auf Grundlage von Intuition oder Wissen, dass durch geeignete Techniken der Datenvisualisierung gewonnen wurde.

In dem hier entwickelten Verfahren kommen folgende automatisierte Verfahren der Merkmalsselektion zum Einsatz:

- Vorselektion mithilfe einer filterbasierten Merkmalsreduktion
- Merkmalsselektion während des Trainings

Zunächst wird ein heuristisches Filterverfahren angewandt, um die Merkmalsmenge von hochkorrelierten Merkmalen zu befreien. Mit diesem „vorsichtigen" Selektionsansatz wird sichergestellt, dass nur korrelierte Merkmale mit geringem Informationsgehalt unberücksichtigt bleiben. Damit können jedoch noch nicht alle für das Klassifikationsproblem unwichtigen Merkmale identifiziert werden. Für eine Identifizierung dieser, soll eine Merkmalsselektion mittels eines Wrapper-Ansatzes bzw. durch bereits eingebettete Merkmalsselektionsverfahren während des Erlernens des Klassifikators im Modellselektionsprozess stattfinden.

7.7.1 Filterbasierte Merkmalsreduktion

Filterverfahren basieren auf einem Ranking der Merkmale über verschiedene Maße wie der *Entropy* oder *Saliency*[65] (Guyon & Elisseeff, 2003) und sind gegenüber den Wrapper-Ansätzen, die Teil der Modellselektion sind, um einiges effizienter (u. a. Hall, 1999). Die Gefahr beim Einsatz von Filtern besteht darin, dass versehentlich Merkmale eliminiert werden, die nach definiertem Maß als irrelevant gelten, aber dennoch einen, wenn auch nur einen kleinen, Beitrag zur Lösung des Klassifikationsproblems beitragen. Darum wird die Strategie einer „vorsichtigen" Merkmalsreduktion verfolgt, in dem zunächst nur stark miteinander korrelierende Merkmale identifiziert und nur auf dieser Untermenge eine Merkmalsselektion angewandt wird. Damit bleibt beispielsweise nur eines von drei sehr ähnlichen Merkmalen erhalten, die anderen zwei werden verworfen.

Die Abb. 7-12 zeigt den Prozess der Vorselektion. Dabei werden zunächst stark korrelierende Merkmale durch Bildung der Korrelationsmatrix und einer Korrelationsanalyse identifiziert. Hierzu müssen die Eingangsdaten bereits vorverarbeitet (transformiert, standardisiert etc.) sein. Die Korrelationsmatrix wird durch die paarweise Berechnung der Korrelation nach Pearson abgeleitet. Von dieser Matrix ausgehend, werden diejenigen Merkmale identifiziert, die mit einem anderen Merkmal besonders stark korrelieren. Als Kriterium wird ein Korrelationskoeffizient von $|\rho| > 0{,}9$ gewählt. Diese Untermenge ist Grundlage der Merkmalsselektion, alle anderen Merkmale bleiben erhalten.

[65] Die „Saliency" ist ein Maß, mit dem die Auffälligkeit eines Merkmals identifiziert wird. Ein salientes (auffälliges) Merkmal liegt vor, wenn eine hohe Varianz im Vergleich zu den anderen Merkmalen vorliegt. Die Entropie (*entropy*) ist ein Maß für den mittleren Informationsgehalt eines Merkmals. Ein Merkmal besitzt eine hohe Entropie, wenn eine gleichmäßige Verteilung vorliegt (Guyon & Elisseeff, 2003).

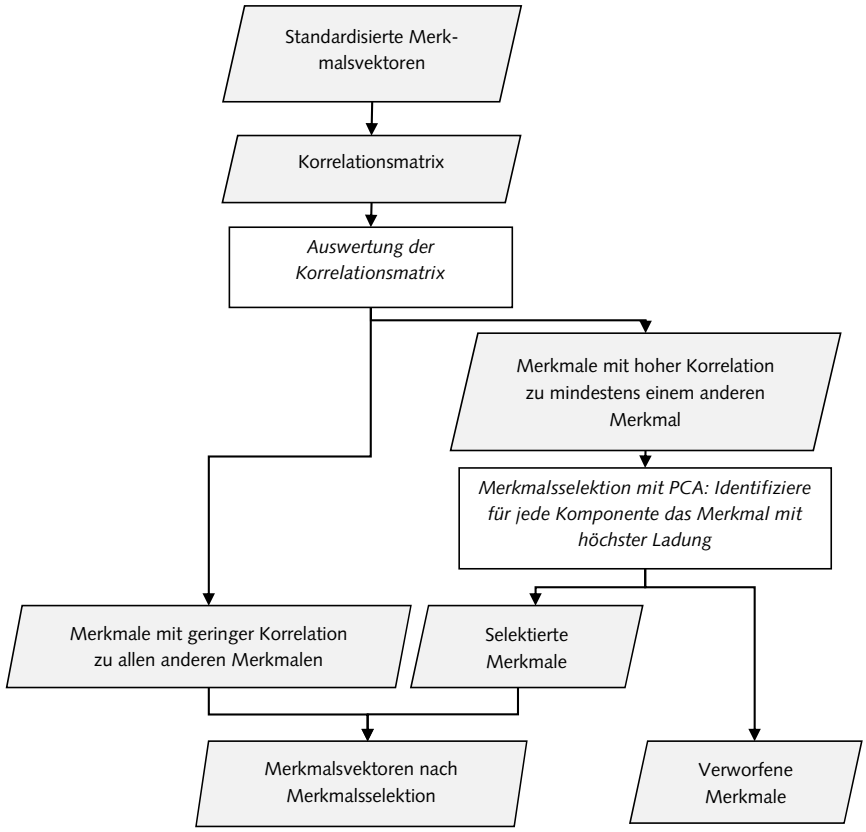

Abb. 7-12: Workflow der Merkmalsselektion

Durch Anwendung einer Hauptkomponentenanalyse (Principal Component Analysis, kurz PCA) auf die Untermenge der hochkorrelierten Merkmale werden Komponenten gebildet und deren Ladungen geschätzt. Anschließend werden die Merkmale selektiert, die am höchsten auf eine der extrahierten Komponente „laden". Diese Herangehensweise zur Dimensionsreduktion wurde von Jolliffe (1972, 1973) als „Methode B4" eingeführt mit dem Unterschied, dass die Merkmalsreduzierung nur auf die Menge der stark korrelierten Merkmale angewendet wird.

Die PCA ist, wie auch die Faktorenanalyse, ein analytisches Verfahren zur Dimensionsdeduktion (Duda et al., 2000; Jolliffe, 2002) und wird im Englischen häufig auch als „feature extraction"[66] bezeichnet. Dabei werden die originalen Merkmale durch eine orthogonale Transformation in einen niedriger dimensionierten Unterraum projiziert, ohne dabei wichtige Informationen zu verlieren. Die latenten Merkmale bilden die Hauptkomponenten, die eine

[66] An dieser Stelle nicht zu verwechseln mit dem Prozess der Merkmalsberechnung aus Bilddaten.

Linearkombination der Merkmale darstellen. Der Schwerpunkt der Datenmenge bildet bei der Transformation den neuen Ursprung des Koordinatensystems. Die erste Hauptkomponente (-achse) ist mit der Richtung der größten Varianz gegeben. Für die Extraktion der zweiten Hauptkomponente wird, ausgehend von der fixierten ersten Hauptachse, orthogonal nach der Richtung mit der größtmöglichen restlichen Varianz gesucht (unkorreliert zur ersten Achse). Gleiches Vorgehen erfolgt für alle weiteren Komponenten, wobei die Varianz der Komponenten stets abnimmt. Als Rotationsverfahren wird hierfür die Varimax-Methode (orthogonale Rotation) angewendet, mit der die Varianz der Ladungen innerhalb der Komponenten maximiert wird.

Entscheidend bei der PCA ist die optimale Anzahl zu extrahierender Komponenten. Die graphische Bestimmung über den Scree-Test (Cattell, 1966), die Parallelanalyse (Horn, 1965) oder die Anwendung des Kaiser-Guttman-Kriteriums (Kaiser, 1960) sind die populärsten Verfahren zur Bestimmung der Komponentenanzahl (Jackson, 1993). Bei der Entwicklung des Verfahrens wurde das Kaiser-Guttman-Kriterium angewendet, mit dem die Komponentenanzahl e auf Grundlage der Eigenwerte λ analytisch bestimmt wird. Mit den Eigenwerten jeder Hauptkomponente wird der Anteil der Gesamtvarianz beschrieben, die mit dieser Komponente erklärt wird. Nach dem Kaiser-Guttman-Kriterium werden nur die Hauptkomponenten extrahiert, die einen Eigenwert $\lambda > 1$ besitzen. Im Vergleich dazu wurde die Parallelanalyse (Horn, 1965) getestet, welche auf einer Simulation basiert und rechenintensiver ist. Dabei werden wiederholt zufällige Daten gleicher Größe und Merkmalsanzahl generiert und jeweils die Eigenwerte der extrahierten Komponenten betrachtet. Durch Vergleich des Verlaufes der Eigenwerte der reellen Daten mit den emittelten Eigenwerten aus der Simulation kann die Komponentenanzahl bestimmt werden. In Versuchen zeigte sich, dass die Anwendung der Parallelanalyse in den meisten Fällen zum gleichen Ergebnis führte, weshalb letztendlich das einfachere Kaiser-Guttman-Kriterium gewählt wurde (Abb. 7-13).

Die direkte Verwendung der extrahierten Komponenten als Merkmale für die Klassifizierung ist in diesem Fall nicht sinnvoll, da diese eine Linearkombination der originalen Merkmale darstellen. Bei praktischer Anwendung wäre stets die Berechnung aller Merkmale nötig, womit keine Einsparung der Rechenzeit bei der Merkmalsgewinnung gegeben wäre. Gleichzeitig wären die latenten Merkmale schlechter interpretierbar. Nach Extraktion der Komponenten wird darum eine Komponentenladungsmatrix berechnet, die sich aus den Korrelationskoeffizienten der originalen Merkmale und den Komponentenladungen ergibt. Hohe Korrelationskoeffizienten deuten darauf hin, dass ein Merkmal stark auf eine Komponente lädt. Auf Grundlage dieser Matrix werden anschließend diejenigen Merkmale identifiziert, die auf eine extrahierte Komponente am höchsten laden (korrelieren). Zusammen mit den nicht korrelierten Merkmalen der Korrelationsanalyse wird dann die reduzierte Merkmalsmenge gebildet.

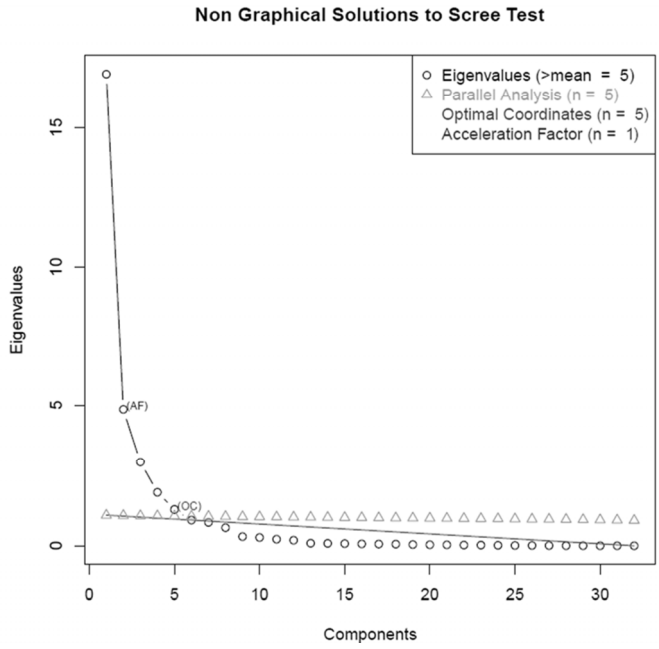

Abb. 7-13: Scree-Plot und Anzahl der extrahierten Komponenten mittels verschiedener Kriterien (Quelle: Eigene Darstellung unter Nutzung des R Packages „nFactors")

7.7.2 Merkmalsselektion während des Trainings

Mit einem Wrapper-Ansatz erfolgt die Wahl des Merkmalssets am Gütekriterium des gewählten Klassifikationsverfahrens über ein Training (vgl. Kap. 3.3.4). Die Brute-Force-Suche nach der optimalen Merkmalsmenge durch Testen aller Merkmalskombinationen ist aufgrund des hohen Rechenaufwandes nicht praktikabel, da die Anzahl der Suchläufe exponentiell mit der Merkmalsmenge wächst. Abhilfe verschaffen hierfür iterative Suchverfahren mit Abbruchkriterien, wie etwa die sequentielle Vorwärtsselektion (Sequential Forward Selection, kurz SFS) oder die sequentielle Rückwärtsselektion (Sequential Backward Selection, kurz SBS) (Alpaydin, 2004). Bei der SFS wird das erstbeste Merkmal gewählt und mit jeder Iteration das nächstbeste Merkmal hinzugezogen, bis keine bedeutende Verbesserung mit jedem neuen Merkmal mehr erreicht wird. Mit der SBS wird, ausgehend von allen Merkmalen, mit jeder Iteration sukzessiv ein Merkmal entfernt, so lange bis der damit verursachte Informationsverlust einen Wert überschreitet.

Ein derartiger sequentieller Suchalgorithmus ist bereits im R-Packet „klaR" mit der Funktion „stepclass" implementiert und wurde am Beispiel eines Datensatzes getestet. Als Abbruchkriterium (Parameter „improvement" von „stepclass") wurde der Standardwert von 0,01 gewählt. Die sequentielle Suche bricht dann ab, wenn sich die Klassifikationsgüte mit jedem hinzugenommenen (SFS) bzw. jedem weggelassenen Merkmal (SBS) nicht um mindestens 0,01 gegenüber der Güte des vorherigen Modells verbessert. Das Gütemaß der getesteten Modelle wird über eine 10-fache Kreuzvalidierung geschätzt.

Es zeigte sich im Laufe der Arbeit, dass mit der SFS bei keiner der getesteten Klassifikatoren eine Verbesserung der Klassifikationsleistung erzielt werden konnte. Ein Grund dafür könnte sein, dass die betrachtete Merkmalsmenge gegenüber der SBS einen geringeren Informationsgehalt besitzt, da die Relevanz der Merkmale ohne Berücksichtigung der noch nicht enthaltenen Merkmale beurteilt wurde und damit nur die unabhängigen Merkmale stärker berücksichtigt werden (vgl. Guyon & Elisseeff, 2003). Die SBS ist hingegen sehr rechenaufwändig, da beim Training mehr Merkmale und damit eine höhere Modellkomplexität vorliegen. Bei Anwendung der SBS an einem Testdatensatz zeigte sich eine marginale, aber meist nicht signifikante Verbesserung der Klassifikationsleistung.

Aus praktischen Gründen wurde auf eine Implementierung der SBS im Modellselektionsprozess verzichtet. Der enorme Rechenaufwand bei der Suche nach dem besten Modell mit der SBS steht in diesem Fall in keinem Verhältnis zu der marginalen Verbesserung der Klassifikationsleistung. Zudem wird für einige Klassifikationsverfahren keine Merkmalsselektion benötigt, da diese bereits in impliziter Form erfolgt (z. B. CART, Neuronale Netze, Bagging, Random Forest, Boosting, SVM) (Alpaydin, 2004). In diesem Zusammenhang spricht man von einer eingebetteten Merkmalsselektion (Guyon, 2006). Darum bleibt die Merkmalsselektion vor der Selektion des besten Klassifikationsverfahrens zunächst auf das oben beschriebene Filterverfahren beschränkt. Eine Merkmalsselektion wird erst nach Wahl des besten Klassifikationsverfahrens angewandt, um das Modell zu optimieren. Es zeigte sich im weiteren Verlauf der Arbeit, dass mit dem Maß zur Merkmalswichtigkeit unter Nutzung des Random Forest-Algorithmus eine geeignete Merkmalsselektion möglich ist (vgl. Kap. 8.6.2).

7.8 Entwicklung des Klassifikators

7.8.1 Wahl der Klassifikationsverfahren

Bei der Entwicklung des Klassifikators steht zunächst die Frage nach geeigneten Klassifikationsmethoden, die in einer Modellselektion bewertet werden sollen. Gemäß den Vorüberlegungen (vgl. Kap. 5.5.2) soll ein datengetriebener überwachter Klassifikationsansatz eingesetzt werden. Mit der starken Entwicklung der Computertechnologie (insbesondere Hardware) stehen heute eine große Menge an Verfahren der Mustererkennung und des maschinellen Lernens zur Verfügung, die dafür in Frage kommen. Die Eigenschaften, die Annahmen und die Anwendbarkeit verschiedener Gruppen von Klassifikationsverfahren (Tab. 7-12) sollen in Bezug auf die Gebäudeklassifizierung zunächst kurz andiskutiert werden.

Parametrische Verfahren unterliegen strengen Annahmen zur Form der Verteilungsfunktion, da der Klassifikator aus parametrisierten Verteilungen, wie z. B. Gaußfunktionen, die sich durch Mittelwert und Kovarianz definieren, konstruiert wird. Da die Dichtefunktionen der Gebäudemerkmale in ihrer Form der Verteilung stark variieren können (vgl. Abb. 8-8), sind parametrische Klassifikatoren vermutlich weniger geeignet.

Tab. 7-12: Eigenschaften verschiedener Klassifikationsverfahren (in Anlehnung an Rubinstein & Hastie, 1997)

Prinzip		Methodengruppe	Annahmen	Vorteil	Nachteil
Bayes Theorem		Parametrische Verfahren	Form der Verteilungsfunktion	Einfache Parameterschätzung	Sensitiv gegenüber Rauschen/Ausreißer, nicht für multimodale Verteilungen geeignet
		Nicht-Parametrische Verfahren	Keine Annahmen zur Verteilung, aber Glattheitseigenschaften	Kein Vorwissen nötig, beliebige Verteilung	Parameterschätzung rechenintensiv bei hoher Dimension, große Anzahl von Lerndaten nötig
Diskriminanzfunktion	linear	Lineare Klassifikatoren	Lineare Trennbarkeit der Klassen	Einfache Parameterschätzung, Effizient	hoher Bias, wenn Modell inkorrekt, nicht resistent gegenüber Ausreißer/Rauschen
	nicht-linear	Verallgemeinerte Lineare Verfahren	Keine Annahmen zur Verteilung	Hohe Flexibilität, Robust wegen weniger Annahmen, teilweise implizite Merkmalsselektion	geringer Bias, Aufwändige iterative Parameterschätzung, Wahrscheinlichkeitsdichte wird ignoriert, Entscheidungsgrenzen vom Trainingsdatensatz abhängig, oft nicht deterministisch
		Neuronale Netze			
		Kernelmethoden			
		Baumbasierte Verfahren			
		Ensemble-Techniken			

Nichtparametrische Verfahren zeichnen sich dadurch aus, dass kein Vorwissen zur Form der Verteilung vorliegen muss. Mit einem Schätzverfahren können auf Grundlage der gegebenen Trainingsdatenmenge beliebige Verteilungen geschätzt werden. Für hochdimensionale Daten sind diese Verfahren jedoch oft nicht sehr effizient, da aufgrund der hohen Modellkomplexität und dem „Fluch der Dimension" sehr viele Trainingsdaten benötigt werden. Ausnahme bildet der Nächste-Nachbarn-Klassifikator (NN-Klassifikator), der zwar ein suboptimales, aber sehr effizientes Verfahren ist, um die optimale Bayes-Fehlerrate abzuschätzen, da dessen Fehler höchstens doppelt so hoch ist als beim Bayes-Klassifikator (Cover & Hart, 1967).

Bei den linearen Verfahren erfolgt die Klassifizierung über lineare Entscheidungsgrenzen. Diese Verfahren sind oft sehr effizient, die Klassen müssen jedoch im Merkmalsraum linear trennbar sein. Ein häufig verwendetes Verfahren ist Fisher´s Lineare Diskriminanzanalyse (LDA), bei der keine klassenspezifische Normalverteilung vorliegen muss und deshalb auch bei nur annähernd normalverteilten Daten Anwendung finden kann. Die Methode hängt jedoch stark von der zugrundeliegenden Trainingsdatenmenge ab und arbeitet am effizientesten, wenn für die kleinste Gruppe mehr Trainingsdatensätze als Merkmale vorliegen und die Gruppen annähernd gleich groß sind (Feldesman, 2002). Die LDA sowie deren Erweiterungen, wie die QDA oder MDA, sind jedoch sensitiv gegenüber Ausreißer und Rauschen und können ohne vorgeschalteter Dateninspektion und Transformation zu schlechten Ergebnissen führen (Bouveyron & Girard, 2009). Bevor komplexere Modelle zum Einsatz

kommen, sollte man sich bei der Modellentwicklung stets vergewissern, ob ein linearer Klassifikator ausreicht und eine höhere Modellkomplexität gerechtfertigt ist[67] (Alpaydin, 2004).

Nichtlineare Klassifikatoren besitzen häufig eine hohe Komplexität, sind jedoch durch eine hohe Flexibilität und Robustheit gekennzeichnet. Verallgemeinerte lineare Verfahren, Neuronale Netze, Kernelmethoden und baumbasierte Verfahren eignen sich besonders gut bei hochdimensionalen Daten. Entscheidungsbaumverfahren werden häufig zur Klassifikation von Mustern in Geodaten eingesetzt, da sie gegenüber den anderen nichtlinearen Verfahren wichtiges strukturelles Wissen bereitstellen. Bei zunehmender Anzahl von Trainingsobjekten und Merkmalen werden die Bäume allerdings sehr groß und nur schwer interpretierbar. In diesem Zusammenhang neigen diese auch zur Überanpassung und lassen sich nur schwer auf unbekannte Daten anwenden (Sester, 1995). Erst mit geeigneten Pruning-Verfahren kann der Überanpassung entgegengewirkt werden.

Kombinierte Klassifikatoren (Ensemble-Methoden) spielen neuerdings eine immer bedeutendere Rolle bei der Mustererkennung in räumlichen Daten (Brenning et al., 2006; Chan & Paelinckx, 2008; Edwards et al., 2007; Gislason et al., 2006; Gonulalan, 2010). Hierzu zählen insbesondere Verfahren des Bagging, Boosting und andere artverwandte Verfahren wie dem Random Forest. Bei einem Vergleich von AdaBoost mit Random Forest wurden marginale Unterschiede in der Klassifikationsleistung festgestellt (Chan & Paelinckx, 2008). Random Forest ist in dieser Studie in Bezug auf die Rechenzeit jedoch schneller als das Boosting, da beim Lernen nur eine zufällige Stichprobe verwendet wird.

7.8.2 Vorstellung der getesteten Klassifikationsverfahren

Merkmale natürlicher Phänomene sind häufig normalverteilt. Es wird jedoch vermutet, dass die gebäudebeschreibenden Merkmale gegen die Grundannahme einer Normalverteilung verstoßen. Mit nichtlinearen Verfahren können deshalb vermutlich höhere Klassifikationsgenauigkeiten erzielt werden als mit linearen Verfahren. Dieser Frage gingen bereits Steiniger et al. (2008) nach und konnten keinen signifikanten Unterschied hinsichtlich der Genauigkeit feststellen. Im Gegensatz zu dem hier vorgestellten Ansatz waren jedoch nur 5 Zielklassen definiert. Des Weiteren standen deutlich weniger Merkmale zur Verfügung. Während der Verfahrensentwicklung wird deshalb ein möglichst breites Spektrum bereits implementierter Klassifikationsverfahren untersucht, um Aussagen über die Anwendbarkeit auf das Problem der Gebäudeklassifizierung machen zu können. Die gewählten Klassifikationsverfahren reichen von klassischen Verfahren, wie dem k-Nearest-Neighbour-Klassifikator (KNN) oder der Linearen Diskriminanzanalyse (LDA), über verallgemeinerte lineare Modelle bis hin zu moderneren maschinellen Lernenverfahren (Tab. 7-13).

[67] "We should always use the linear discriminant before trying a more complicated model to make sure that the additional complexity is justified" (Alpaydin, 2004: S. 211).

Tab. 7-13: Überblick über die getesteten Klassifikationsverfahren

Getestete Klassifikatoren						
Nichtparametrische Modelle	Lineare Modelle	Nichtlineare Modelle				
		Verallgemeinerte lineare Modelle	Kernelmethoden	Neuronale Netze	Baumbasiert	Ensemble-Methoden
KNN	LDA	sLDA MDA FDA-MARS pLDA pMDA	SVM	ANN	CART	PVSLDA BAGGING DOUBAG RF PVSRF ADABOOST

Für die Anwendung kann auf Funktionen der Programmbibliothek der Open Source Software R sowie diversen Zusatzpaketen zurückgegriffen werden. Über die Scriptsprache R ist es möglich, bereits implementierte Klassifikationsverfahren in die eigenen Datenanalysen einzubinden. In den folgenden Abschnitten wird die Funktionsweise der Klassifikationsverfahren im Einzelnen erläutert.

7.8.2.1 K-Nearest-Neighbour (KNN)

Der k-Nearest-Neighbour-Klassifikator (KNN), entsprechend k-nächste-Nachbarn-Algorithmus, ist ein nichtparametrisches Verfahren, bei dem eine Klassenzuordnung unter Berücksichtigung seiner k nächsten Nachbarn im Merkmalsraum erfolgt. Als Abstandsmaß wird der euklidische Abstand im Merkmalsraum verwendet. Die Klassifizierung eines Objekts erfolgt durch Mehrheitsentscheidung der k beteiligten Nachbarn (Ripley, 1996). Für den Fall, dass $k = 1$, entspricht es dem Nächsten-Nachbar-Klassifikator (1NN), mit dem der Merkmalsraum durch ein Voronoi-Diagramm separiert wird. Bei Wahl eines großen k wird die Schätzung aufgrund des Mehrheitsentscheids robuster. Durch die stärkere Glättung in der Umgebung besteht jedoch, insbesondere bei wenigen Trainingsbeispielen, die Gefahr einer Unteranpassung. Ein praktisches Problem ist der Speicher- und Rechenaufwand des KNN-Algorithmus bei Anwendung hochdimensionaler Daten. Der KNN-Klassifikator ist in dem Zusatzpaket „class“ unter GNU R implementiert. Der wichtigste Parameter der Funktion ist die Anzahl der zu berücksichtigenden Nachbarn k, die in einem Tuning-Prozess ermittelt werden müssen.

7.8.2.2 Lineare Diskriminanzanalyse (LDA)

Die Lineare Diskriminanzanalyse (LDA) von Fisher (1936) ist ein linearer Klassifikator zur Bestimmung optimal klassenseparierender Diskriminanzfunktion(en). Für die Trennung der Klassen wird jene Projektion der Daten in Form einer Linearkombination gesucht, mit der die Streuung innerhalb der Klassen minimiert und die Streuung zwischen den Klassen maximiert wird. Fisher´s LDA ist in dem Zusatzpaket MASS für GNU R implementiert (Venables & Ripley, 2002).

7.8.2.3 Flexible Discriminant Analysis (FDA-MARS)

Die flexible Diskriminanzanalyse (engl. *flexible discriminant analysis*, FDA) von Hastie et al. (1994) ist ein verallgemeinertes lineares Modell und gehört der Gruppe der nichtlinearen Verfahren an (vgl. 3.4.2.2). Im Gegensatz zur LDA wird anstelle einer linearen Hyperebene eine gekrümmte Oberfläche gesucht. Das Klassifikationsproblem wird dabei über ein „optimal scoring" in ein Regressionsproblem umformuliert und kann damit nichtlineare Klassifikationsprobleme lösen. Ein Ansatz ist die Erzeugung nichtlinearer Regressionsmodelle über sogenannte *Multivariate Adaptive Regression Splines* (MARS). Mit dem von Friedman (1991) eingeführten Ansatz wird ein adaptives nichtlineares Regressionsmodell geschätzt, dass sich aus mehreren Basisfunktionen (lineare Regressionsmodelle) stückweise zusammensetzt (Adler, 2010). Der Algorithmus ist mit dem CART-Algorithmus verwandt. Nach Erzeugung eines überangepassten Modells wird dieses anschließend durch schrittweises Entfernen von Termen, wie beim Pruning eines Entscheidungsbaumes (vgl. Kap. 3.4.2.2.4), generalisiert.

Eine FDA mit MARS-Modellen (FDA-MARS) ist im Zusatzpaket „earth" unter GNU R implementiert. Die wichtigsten Parameter des Modells sind *degree* und *nprune.* Mit *nprune* wird die maximale Anzahl von Termen als Obergrenze nach der Generalisierung angegeben. Der Parameter *degree* bestimmt den maximalen Interaktionsgrad (Milborrow, 2012).

7.8.2.4 Mixture Discriminant Analysis (MDA)

Die *Mixture Discriminant Analysis* (MDA) (Hastie & Tibshirani, 1996) ist eine Erweiterung der LDA und ein nichtlinearer Klassifikator. Bei der MDA setzt sich die klassenspezifische Verteilungsdichte aus mehreren normalverteilten Untermengen (Gauß´schen Mischverteilungen) zusammen. Mit dem Verfahren können beliebige Verteilungen modelliert werden. Die MDA ist jedoch genauso wie die LDA sensitiv gegenüber Rauschen und Ausreißer (Bouveyron & Girard, 2009). Die MDA ist im Zusatzpaket „mda" für GNU R implementiert (Hastie & Tibshirani, 2009). Wichtigster Parameter ist die Anzahl der Unterklassen *subclasses*, die für jede Klasse in Form eines Vektors definiert werden kann. Mit ihr wird bestimmt, wie viele Gauß´schen Mischverteilungen gebildet werden.

7.8.2.5 Stabilisierte Diskriminanzanalyse (sLDA)

Die stabilisierte lineare Diskriminanzanalyse (engl.: *stabilized Linear Discriminant Analysis*, sLDA) ist ein multivariates Analyseverfahren (Läuter, 1992; Läuter et al., 1998), basierend auf der Theorie links-sphärischer Zufallsvariablen (Fang & Zhang, 1990). Die sLDA wurde insbesondere für hochdimensionale Daten mit stark abhängigen und korrelierenden Merkmalen entwickelt, für die sich klassische Verfahren als instabil erweisen. Mit dem Verfahren werden die hochdimensionalen Merkmalsvektoren mittels datenabhängiger Gewichte in Scores mit geringerer Dimension transformiert. Die Scores sind linkssphärisch verteilt und werden anschließend als Eingangsvariablen einer klassischen LDA verwendet (Peters & Hothorn, 2011). Das Verfahren ist selbst dann anwendbar, wenn die Merkmalszahl die Anzahl der Trainingsdatensätze übersteigt. Im Vergleich zur LDA wird mit der sLDA eine Glättung der Entscheidungsfunktion hervorgerufen. Die sLDA ist in dem R Paket "ipred" mit der

Funktion „slda“ implementiert und wird insbesondere im Bereich der Bioinformatik eingesetzt (Peters & Hothorn, 2011).

7.8.2.6 Penalized Diskriminant Analysis (pLDA)

Die penalisierte Diskriminanzanalyse (engl.: *Penalized Discriminant Analysis*, pLDA) gehört wie die sLDA zur Gruppe der verallgemeinerten linearen Modelle. Der Ansatz wurde von Hastie et al. (1995) für die Anwendung auf hochdimensionale Daten entwickelt. Im Gegensatz zur sLDA wird der Merkmalsvektor um Basisfunktionen erweitert und bei Anwendung der klassischen LDA auf den erweiterten Merkmalsraum Strafterme in Form einer Matrix (engl. *penalty matrix*) eingeführt. Die Strafterme werden über einen Smoothing-Parameter λ gesteuert. Je kleiner der Parameter λ gewählt wird, desto geringer sind die Glättung und der Unterschied des Ergebnisses zur klassischen LDA. Der für das Klassifikationsproblem optimale Parameter muss in einem Tuning-Prozess bestimmt werden. Die pLDA findet unter anderem Anwendung in der Auswertung multi- oder hyperspektraler Bilddaten (Brenning, 2009; Yu et al., 1999) und ist dem package „mda“ unter GNU R implementiert (Hastie & Tibshirani, 2009).

7.8.2.7 Penalized Mixture Discriminant Analysis (pMDA)

Mit der penalisierten MDA (engl.: *Penalized Mixture Discriminant Analysis*, pMDA) ist eine regularisierte Version des Gauß´schen Mischverteilungsansatzes gegeben. Die Vorgehensweise entspricht der pLDA. Für eine Anwendung dieses Modells kann ebenfalls auf das Zusatzpaket „mda“ unter GNU R zurückgegriffen werden.

7.8.2.8 Classification and Regression Trees (CART)

Der CART-Algorithmus (engl. *Classification and Regression Trees*) ist ein rekursiver Partitionsalgorithmus zur Generierung von Entscheidungsbäumen und wurde von Breiman et al. (1984) entwickelt. Anhand von Trainingsdaten werden diese sukzessiv nach einzelnen Merkmalen binär in Teilmengen zerlegt. Die Wahl des Merkmals für die binäre Aufteilung an einem Knoten (Split) erfolgt mithilfe des Gini-Index oder der Entropy, einem statistischen Maß zur Messung der „Unreinheit“ eines Merkmals im Knoten. Mit dem erlernten Entscheidungsbaum werden bei Anwendung die Objekte, ausgehend vom Wurzelknoten entlang der Äste über binäre Entscheidungsknoten, einem Endknoten (einer Klasse) zugeordnet.

Der CART-Algorithmus ist im Zusatzpaket “rpart“ unter GNU R implementiert (Therneau & Atkinson, 1997). Als Unreinheitsmaß wird der Gini-Index verwendet, da dieser auch von Breiman et al. (1984) bevorzugt wird und im Zusatzpaket „rpart“ standardmäßig gesetzt ist. Ein wichtiges Abbruchkriterium des Algorithmus ist die minimale Anzahl an Beobachtungen *minsplit*, die ein Knoten mindestens haben muss, um weiter geteilt zu werden. Mit dem Kompexitätsparameter *cp* wird hingegen die „notwendige Verbesserung“ angegeben, die durch den Entscheidungsknoten hervorgerufen werden muss, um ausgeführt (konstruiert) zu werden. Mit dem Parameter *maxdepth* wird die maximale Tiefe des Baumes angegeben, mit dem der Generalisierungsgrad des Modells gesteuert werden kann.

7.8.2.9 Paarweise LDA mit Variablenselektion (PVSLDA)

Die paarweise LDA mit Variablenselektion (PVSLDA) ist ein nichtlinearer kombinierter Klassifikator. Mit diesem Lernverfahren werden paarweise Regeln zum Separieren zweier Klassen unabhängig von den anderen Klassen erlernt und über ein „pairwise coupling" kombiniert (Hastie, 1998). Szepannek und Weihs (2006) zeigen am Beispiel der paarweisen Klassifikation mit der LDA, dass zum Teil deutliche Verbesserungen der Fehlerrate erzielt werden können, wenn eine Variablenselektion für jedes Paar zweier Klassen angewendet wird. Mit diesem Ansatz wird der Fakt berücksichtigt, dass ein Merkmal nur zwischen bestimmten Klassen gut diskriminiert – für andere Klassenpaare jedoch nicht. Wenngleich dieser Ansatz bei großer Merkmals- und Klassenanzahl rechenzeitintensiv ist, so soll dieser für das vorliegende Erkennungsproblem getestet werden.

PVSLDA ist in dem Zusatzpaket „klaR" implementiert, dass jedoch auch auf Funktionen des Paketes „MASS" zurückgreift. Die Funktion „pvs" erlaubt eine paarweise Variablenselektion unter Nutzung der klassischen LDA. Als Variablenselektionsmethode wird der Kolmogorow-Smirnow-Test (KS-Test) angewendet, mit dem für jede Variable die Verteilung zwischen den zwei betrachteten Klassen verglichen wird. Nur Variablen mit einem p-Wert kleiner als dem festgelegten Parameter *niveau* werden für das Training der einzelnen paarweisen Klassifikatoren verwendet. Um ein neues Objekt zu klassifizieren, müssen K(K–1)/2 paarweise Klassifikatoren trainiert werden. Anschließend werden die erlernten Basisklassifikatoren über das „pairwise coupling" kombiniert.

7.8.2.10 Bagging Trees (BAGGING)

Der Bagging-Algortihmus von Breiman (1996a) ist eines der bekanntesten Ensemble-Verfahren, bei dem mehrere Basisklassifikatoren anhand von Bootstap-Stichproben erlernt werden. In diesem Fall wird für jede einzelne Bootstrap-Stichprobe ein Klassifikationsbaum mit dem CART-Algorithmus konstruiert. Jedes der Bootstrap-Samples wird durch wiederholtes Ziehen mit Zurücklegen von Objekten aus der Trainingsmenge generiert. Die Vorhersage ist die Klasse, die von den Klassifikationsbäumen am häufigsten vorhergesagt wurde (bei Gleichheit wird zufällig entschieden). Mit dem Bagging wird gegenüber dem einfachen CART-Algorithmus die Varianz der Vorhersage deutlich reduziert und liefert damit ein robusteres Verfahren. Der Bagging-Algorithmus ist im Zusatzpaket „ipred" unter GNU R implementiert (Peters & Hothorn, 2011). Wichtige Parameter sind die Anzahl der Boostrap-Stichproben *nbagg* und die Parameter *minsplit* und *cp*, die auch für die Konstruktion des CART-Baumes gelten.

7.8.2.11 Double Bagging (DOUBAG)

Das Double Bagging (DOUBAG) von Hothorn & Lausen (2003) ist ein kombiniertes Aggregationsverfahren und ist im R package „ipred" (Peters & Hothorn, 2011) implementiert. Dabei wird eine Lineare Diskriminanzanalyse (LDA) und ein Klassifikationsbaumverfahren (CART) über ein Bagging kombiniert. Ausgehend vom Trainingsdatensatz wird eine Bootstrap-Stichprobe mit Zurücklegen gezogen. Auf Grundlage der übrigen Menge, Out-of-Bag-Menge (OOB-Menge) genannt, werden mittels der LDA die Koeffizienten der linearen Trennfunktion bestimmt. Diese werden anschließend zusammen mit den originalen Merk-

malen der Bootstrap-Stichprobe als zusätzliche Prädiktoren verwendet, um den Klassifikationsbaum zu konstruieren. Die Klassifikationsbäume werden so für alle Bootstrap-Stichproben bestimmt. Bei der Anwendung des Klassifikators erfolgt die Zuordnung der Klasse über einen Mehrheitsentscheid aller Bäume. Im Gegensatz zum Random Forest, bei dem durch zufälliges Wählen einer Merkmalsmenge die Dimension reduziert wird, wird die Anzahl der Merkmale in diesem Verfahren erweitert. Mit Double Bagging wird eine höhere Klassifikationsgenauigkeit erwartet als mit der LDA, dem CART-Algorithmus oder den Bagging Trees, da dies eine empirische Studie bereits zeigte (Hothorn & Lausen, 2003).

7.8.2.12 Random Forest (RF)

Der Random Forest-Algorithmus (RF) von Breiman (2001) ist eine Erweiterung des klassischen Entscheidungsbaumverfahrens und gehört der Gruppe der kombinierten Ensemble-Verfahren an. Im Gegensatz zum CART-Algorithmus werden beim Random Forest nicht nur ein, sondern mehrere hunderte verschiedene Klassifikationsbäume erlernt.

Die Konstruktion der einzelnen Entscheidungsbäume erfolgt über eine zufällige Stichprobe aus den Lerndaten (*bootstrap*) und einer zufälligen Wahl von Merkmalen (*random feature selection*) für jeden konstruierten Baum. Der Generierung vieler Bäume verdankt der Algorithmus seinen Namen „random forest“ („Zufallswälder“). Random Forest ist stark verwandt mit der Bagging-Methode mit dem Unterschied, dass für jeden konstruierten Baum nur eine zufällige Merkmalsmenge verwendet wird. Die Out-Of-Bag-Menge (OOB-Menge) ist die Menge an Daten, die nicht zur Konstruktion des betrachteten Baumes verwendet wurde. Anhand dieser kann der Klassifikationsfehler jedes einzelnen Baumes bestimmt werden. Betrachtet man den Klassifikationsfehler aller Bäume an allen OOB-Mengen, erhält man mit dem OOB-Fehler eine realistische Abschätzung des Generalisierungsfehlers (Breiman, 2001). Bei Anwendung des erlernten Klassifikators erfolgt die Zuordnung zu der Klasse mit den meisten Stimmen in allen Bäumen über das Mehrheitsprinzip.

RF zeigt in der Praxis sehr gute Ergebnisse im Vergleich zu anderen bekannten Klassifikatoren und neigt im Gegensatz zu den klassischen Klassifikationsbäumen nicht zur Überanpassung (Strobl et al., 2009). Weitere Vorteile von Random Forest sind die hohe Effizienz bei der Verarbeitung, die Robustheit gegenüber Ausreißer und Rauschen sowie keine notwendige Merkmalsselektion, da diese während des Lernens erfolgt. Mit dem Algorithmus kann darüber hinaus die Wichtigkeit der Merkmale (engl. *variable importance*) gemessen werden, weshalb sich dieser auch zur Merkmalsselektion eignet (Genuer et al., 2010; Svetnik et al., 2004). Als Maß für die Merkmalswichtigkeit gibt es verschiedene Ansätze, wie die Gini-Wichtigkeit (engl.: *gini importance*) oder das anspruchsvollere Maß der permutierten Fehlerfreiheit (engl.: *permutation accuracy importance*) (Lüthy, 2009; Strobl et al., 2007).

Random Forest ist im R package „randomForest“ implementiert (Liaw & Wiener, 2002). Die wichtigsten Parameter sind *mtry* (Anzahl der Merkmale, die für ein Training des Baumes zufällig ausgewählt werden) und *ntree* (die Anzahl der zu konstruierenden Bäume).

7.8.2.13 Paarweise Variablenselektion mit Random Forest (PVSRF)

Das Verfahren der paarweisen Variablenselektion mit Random Forest ist analog zur PVLDA. Im Gegensatz zur PVLDA wird jedoch ein Random Forest-Klassifikator paarweise erlernt.

7.8.2.14 Support Vector Machine (SVM)

Eine nichtlineare Support Vector Machine (SVM) ist ein kernelbasiertes Verfahren zur Lösung nichtlinearer Klassifikationsprobleme und wird ausführlich in Vapnik (2000), Schölkopf et al. (2001) und Bishop (2007) behandelt. Dabei werden Objekte mithilfe einer optimalen Hyperebene in einem transformierten Merkmalsraum in zwei Klassen klassifiziert. Die Transformation in den höher dimensionierten Raum erfolgt durch Anwendung einer geeigneten Kern-Funktion unter Nutzung des Kerneltricks von Boser et al. (1992). Da aufgrund von Rauschen in den Daten von keiner linearen Trennbarkeit der Klassen ausgegangen werden kann, erfolgt die Anwendung eines Soft-Margin-Klassifikators. Als Regularisierungsparameter wird der Strafterm C eingeführt, mit dem ein Kompromiss zwischen Komplexität (Anzahl der Stützvektoren) und Datenfehlanpassung hergestellt wird (Alpaydin, 2004).

Es existieren bereits verschiedene Zusatzpakete unter GNU R, mit denen SVM angewendet werden kann („kernlab", „e1071", „klaR" oder „svmpath"), wobei die „Ksvm" und „svm" gegenüber den anderen am effizientesten sind (Karatzoglou et al., 2005). Das R package „e1071" bietet dabei ein Interface für den in C++ implementierten *libsvm* von (Chang & Lin, 2001) und ist durch Visualisierungsoptionen und Funktionen zum Parameter-Tuning ergänzt. Mit der Implementierung stehen die gängigen Kernel (lineare, RBF, polynomiale, sigmoidale) zur Verfügung. Es wird ein RBF-Kernel verwendet, dessen Ausmaß über den Parameter γ gesteuert wird. Als Aggregationsverfahren für die Anwendung des binären SVM-Klassifikators auf das Multiklassenproblem wird eine One-Against-One-Aggregation verwendet. Im Paket steht auch ein Tuning-Framework bereit, mit dem die optimalen Parameter C und γ über eine Rastersuche (engl. *grid search*) im zweidimensionalen Parameterraum ermittelt werden können.

7.8.2.15 Adaboost.M1 (ADABOOST)

Das Boosting ist eine Ensemble-Technik mit dem Ansatz, verschiedene schwache Basisklassifikatoren zu einem einzigen starken Klassifikator zu kombinieren, um eine verbesserte Gesamtperformance zu erzielen (siehe Kap. 3.4.2.2). Im Gegensatz zum Bagging, bei dem die Unterstichproben mittels ungewichteten Bootstrap-Verfahren gewonnen werden, werden beim Boosting Gewichte eingesetzt, die vom Resultat bezüglich der jeweils letzten Unterstichprobe abhängen (Hechenbichler, 2005). Das bekannteste Verfahren ist der AdaBoost-Algorithmus, der jedoch nur für binäre Klassifikationsprobleme anwendbar ist. Ein erweiterter Algorithmus, bei dem jeder Basisklassifikator eine Menge endlicher Klassenlabels erlernt, ist der Adaboost.M1-Algorithmus (Freund & Schapire, 1996).

Adaboost.M1 ist im R Zusatzpaket „adabag" implementiert (Alfaro et al., 2011) und nutzt den CART-Algorithmus als einfachen Basislerner. Die Ergebnisse der einzelnen Entscheidungsbäume werden bei Anwendung über mittlere Gewichte kombiniert. Die wichtigsten Parameter des Algorithmus sind *mfinal* und *maxdepth*. Mit dem Parameter *mfinal* wird die Anzahl der Iterationen bzw. die Anzahl der zu konstruierenden Bäume festgelegt. Der Parameter *maxdepth* bezieht sich wiederum auf den Algorithmus zur Baumkonstruktion und gibt die maximale Tiefe des Baumes, gemessen vom Wurzelknoten bis zum Endknoten, an.

7.8.2.16 Künstliche Neuronale Netze (ANN)

Künstliche Neuronale Netze (engl. *Artificial Neural Network*, kurz: ANN) finden vielseitige Anwendung in der Bild- und Spracherkennung, da mit ihnen ohne Vorwissen komplexe Zusammenhänge modelliert werden können. Aufgrund der Eigenart eignen sich künstliche Neuronale Netze besonders gut für die Lösung schwieriger Klassifikationsprobleme.

Mit dem Package „nnet" unter GNU R ist eine Implementierung eines künstlichen Neuronalen Netzes mit einer verborgenen Schicht (Eingabeschicht, verborgene Schicht, Ausgabeschicht) gegeben (Venables & Ripley, 2002). Im Lernprozess werden mittels des Backpropagation-Algorithmus die Gewichte für die Knoten (sowohl in der verborgenen als auch in der Ausgabeschicht) iterativ anhand der Trainingsbeispiele geschätzt. Trotz einfacher Architektur, können mit einem solchen Modell bei genügend Neuronen und passenden Gewichten auch komplizierte Verteilungen modelliert werden (Duda et al., 2000). Dazu bedarf es einem Tuning-Prozess, mit dem vorab die für das Problem am besten geeigneten Modellparameter bestimmt werden. Die wichtigsten Modellparameter sind die Anzahl der versteckten Neuronen *size* sowie ein numerischer Wert zur Festlegung der Zerfallsrate der Gewichte (auch Weight-Decay-Parameter genannt) *decay* (Adler, 2010). Ziel der Parameteroptimierung ist es, zu große Gewichte zu eliminieren, um einer Zerklüftung der Fehleroberfläche entgegenzuwirken. Das Tuning erfolgt mit einer Grid-Suche, durch Variation des Parameters *decay* von 0,1 bis 8 und der Anzahl der Neuronen *size* im Layer von 1 bis 10. Für das Modelltraining wurde die maximale *maxit* Anzahl der Iterationen auf 1 000 gesetzt, wobei mit dem Parameter *maxNWTs* die Anzahl der Gewichte für den Anpassungsprozess auf 2 500 limitiert ist.

7.8.3 Tuning

Einige Verfahren benötigen ein Tuning der Modellparameter. Das Tuning wird während des Trainingsprozesses durchgeführt. Ausgehend von dem betrachteten Klassifikator werden die zu testenden Parameter oder Parameterkombinationen in einem Parameter-Set festgelegt. Anschließend wird ein Klassifikator für jedes Parameter-Set trainiert und dessen Genauigkeit über eine 5-fache Kreuzvalidierung abgeschätzt. Folgender Pseudo-Code fasst die Prozedur des Tunings zusammen:

```
1. Lege Parameter-Set fest
2. for jedes Parameter-Set do
3.   for jede Partition do
4.   Trainiere Klassifikator mit Trainingsdaten
5.   Teste Klassifikator an Testdaten
6.   end
7.   Berechne mittlere Fehlerrate
8. end
9. Bestimme optimales Parameter-Set
```

Die getesteten Klassifikationsverfahren und deren nötige Parameter sind in der Tab. 7-14 zusammengefasst. Für die Parameter, die erst während des Trainings in einem Tuning-Prozess erlernt werden, ist ein Tuning-Intervall angegeben. Für den KNN-Klassifikator wird beispielweise der beste Parameter *k* aus der Menge {1; 5; 10; 20; 30} bestimmt. Für die Verfahren SVM, ANN und FDA-MARS ist hingegen eine zweidimensionale Suche nach einer besten Parameterkombination nötig. Die festen Parameter sind in der Regel Standard-Werte der jeweiligen Implementierungen in R, deren Änderung in Vorabtests keine Verbesserung der Genauigkeit zeigte. Die Ergebnisse des Tunings an einem Beispieldatensatz sind im Kap. 8.4.2 zu finden.

Tab. 7-14: Getestete Klassifikationsverfahren und deren Parameter

Modell	R Funktion (package)	Modellparameter und Bezeichnung	Parameter und deren Tuning-Intervalle
LDA	lda (MASS)	-	-
KNN	knn (class)	Anzahl nächster Nachbarn `k`	k = {1; 5; 10; 20; 30}
sLDA	slda (ipred)	-	-
pLDA	fda (mda)	Regularisierungsparameter `lambda`	λ ={0,1; 1; 5;10;15;20;25}
MDA	mda (mda)	Anzahl der Subklassen `subclasses`	k_{sub} = {2,3,4,5,6}
pMDA	mda (mda)	Anzahl der Subklassen `subclasses`	k_{sub} = 3
		Smoothing-Parameter `lambda`	λ =1
FDA-MARS	earth (earth)	Maximaler Interaktionsgrad `degree`	β = {1; 2; 3}
		Maximale Anzahl von Termen `nprune`	n_{prune} ={4; 8; 16; 32; 64; 128}
CART	MASS (rpart)	Mindestanzahl an Beobachtungen am Knoten `minsplit`	min_{split} = 20
		Komplexitätsparameter `cp`	c_p = 0,002
		Maximale Tiefe des Baumes `maxdepth`	max_{depth} = {1; 2; ... ;15}
PVSLDA	pvs (klaR)	Niveau für ks-Test `niveau`	α = 0,05
PVSRF	pvs (klaR)	Niveau für ks-Test `niveau`	α = 0,05
BAGGING	bagging (ipred)	Anzahl Bootstrap-Stichproben `nbagg`	n_{bagg} = 25
		Mindestanzahl an Beobachtungen am Knoten `minsplit`	min_{split} = 5
		Komplexitätsparameter `cp`	c_p = 0,00
DOUBAG	bagging (ipred)	Anzahl Bootstrap-Stichproben `nbagg`	n_{bagg} = 25
		Mindestanzahl an Beobachtungen am Knoten `minsplit`	min_{split} = 5
		Komplexitätsparameter `cp`	c_p = 0,00
RF	randomForest (randomForest)	Anzahl der Merkmale pro Baum `mtry`	m_{try} = {h_1; …, h_8} dynamisches Intervall mit h_1 = 2 und h_8 = Anzahl der Merkmale
		Anzahl der Bäume `ntree`	n_{tree} = 200
SVM	svm (e1071)	Strafterm `cost`	C = {2^1; 2^2; …; 2^{10}}
		Kernel-Parameter `gamma`	γ = {2^{-15}; 2^{-14}; ...; 2^{-6}}
ADABOOST	adaboost.M1 (adabag)	Anzahl der Iterationen / Bäume `mfinal`	m_{final} = 100
		Maximale Tiefe des Baumes `maxdepth`	max_{depth} = 10
ANN	nnet (nnet)	Anzahl Neuronen in verborgener Schicht `size`	s = {9, 10;11;12}
		Gewichtsteuerung `decay`	d = {0,1; 0,5; 0,9; 1,0; 1,1; 1,2; 1,4; 1,5; 2,0; 4,0; 8,0}

7.8.4 Modellselektion

In einer Modellselektion soll aus der Menge der getesteten Klassifikationsverfahren das Verfahren identifiziert werden, das für die Gebäudeklassifizierung am besten geeignet ist. In einem Simulationsverfahren werden dabei alle Klassifikationsverfahren differenziert nach dem Eingangsdatentyp und der zur Verfügung stehenden Trainingsdatenmenge validiert. Zur Bewertung werden zwei Kriterien hinzugezogen:

- Klassifikationsgenauigkeit
- Laufzeit

Die Klassifikationsgenauigkeit wird als primäres Kriterium gewählt. Unterscheidet sich die Klassifikationsgenauigkeit zwischen zwei oder mehreren Klassifikationsverfahren nicht signifikant, wird die Laufzeit als zweites Kriterium hinzugezogen und damit das Verfahren ausgewählt, das bei gleicher Klassifikationsleistung weniger Rechenressourcen benötigt.

Der Ablauf der Modellselektion ist in Abb. 7-14 dargestellt. Ausgangspunkt ist der Referenzdatensatz eines betrachteten Eingangsdatentyps, z. B. die mit Merkmalen beschriebenen ALK-Gebäudegrundrisse mit Klassenzugehörigkeit. Aus diesem wird eine stratifizierte Stichprobe der Größe n gezogen, die den Lerndatensatz darstellt. Durch Variation von n soll später das Verhalten des Klassifikationsverfahrens in Abhängigkeit der gegebenen Trainingsdatenmenge beobachtet werden.

Die Abschätzung der Klassifikationsgenauigkeit erfolgt über eine stratifizierte 10-fache Kreuzvalidierung, da diese bei einem empirischen Vergleich verschiedener Schätzansätze als beste Modellselektionsmethode identifiziert wurde (Kohavi, 1995) und ein Standardverfahren bei der Evaluierung darstellt (Lim et al., 1998; Meyer et al., 2002). Es wird darum die Lerndatenmenge L in p gleich große Teile partitioniert (mit p =10).

In einer äußeren Schleife werden die c zu testenden Klassifikationsverfahren C durchlaufen. In jedem Durchlauf der äußeren Schleife wird mit der inneren Schleife das betrachtete Verfahren 10-fach kreuzvalidiert. Dazu wird aus den Partitionen jeweils die i-te Partition L_i zum Testen (Testdaten L_{Test}) und die restlichen 9 Partitionen zum Trainieren (Trainingsdaten L_{Train}) des betrachteten Klassifikators C_j verwendet. Einige Klassifikationsverfahren benötigen ein zusätzliches Tuning. Die besten Parameter werden dabei über eine weitere „innere“ 5-fache Kreuzvalidierung bestimmt. Auf eine Darstellung der inneren Kreuzvalidierung wurde in Abb. 7-14 verzichtet. Nach dem Tuning werden die besten Modellparameter zum Trainieren und Testen des Klassifikators des i-ten Durchlaufes verwendet. Als Gütemaß für die Abschätzung des Generalisierungsfehlers wird die kreuzvalidierte Klassifikationsgenauigkeit am Testdatensatz L_{Test} über alle p Durchläufe gemittelt. Eine unvoreingenommene Schätzung der Generalisierungsfähigkeit ist mit diesem Versuchsaufbau streng genommen nicht gegeben, da der Testdatensatz über die Wahl des besten Verfahrens im Modellselektionsprozess entscheidet und damit Teil des Trainings wurde. In einer anschließenden Genauigkeitsanalyse wird das gewählte beste Klassifikationsverfahren darum an weiteren, bisher ungesichteten Daten validiert.

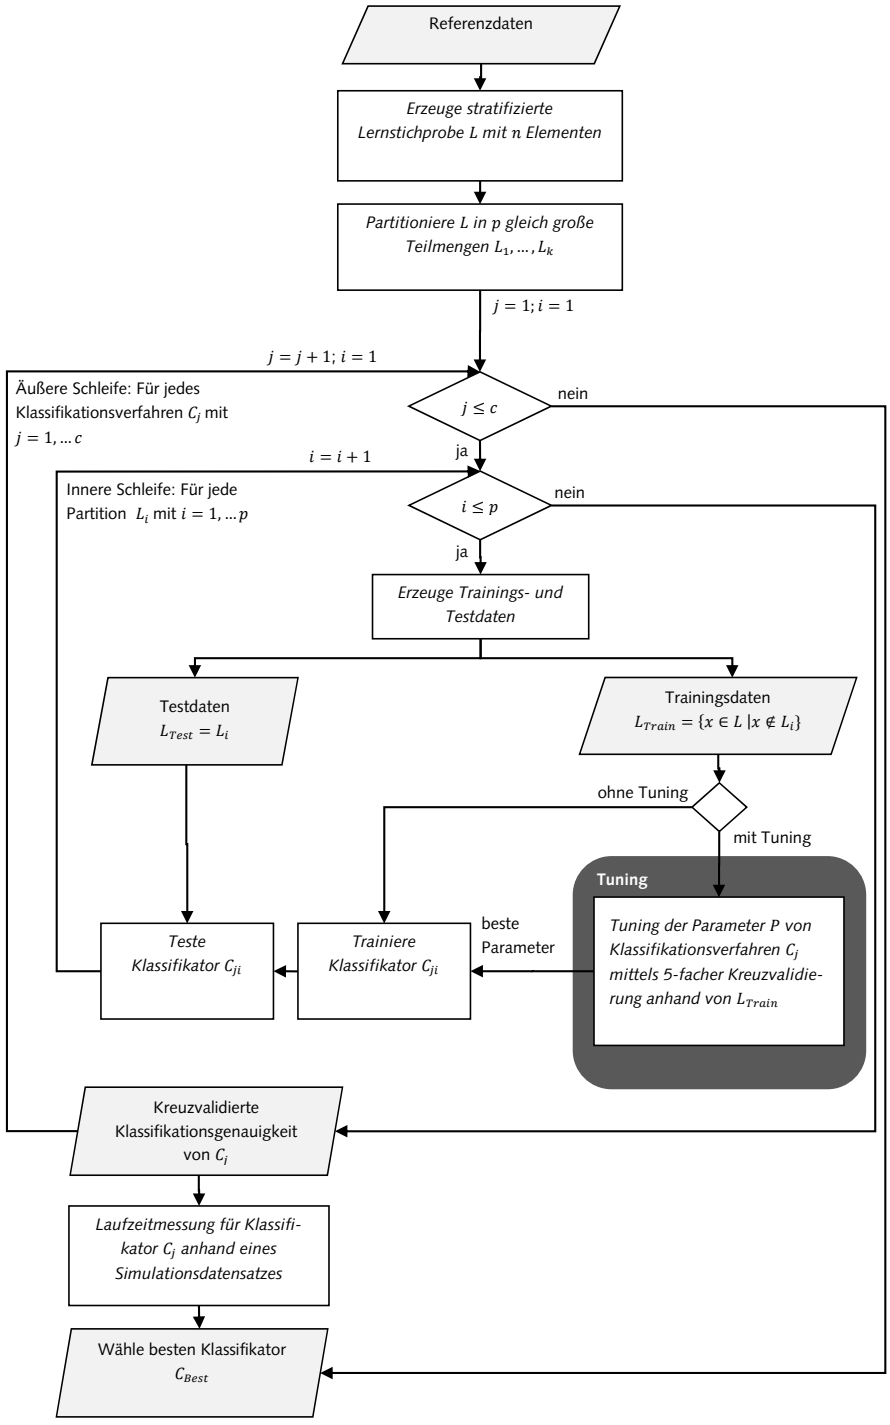

Abb. 7-14: Ablaufdiagramm der Modellselektion

Die empirische Ermittlung der Laufzeit erfolgt für jedes Klassifikationsverfahren durch wiederholtes Messen an einem standardisierten Simulationsdatensatz und unter gleichen Bedingungen (Hardware, Software). Bei der Laufzeit handelt es sich um die Zeit, die benötigt wird, einen Klassifikator zu Trainieren[68] (Laufzeit beim Training inklusive Tuning). Es kann jedoch auch die Laufzeit gemessen werden, die benötigt wird, um einen erlernten Klassifikator auf die Daten anzuwenden (Laufzeit beim Anwenden). Durch Variation der Größe des Trainingsdatensatzes n können auch Aussagen zu den Skalierungseigenschaften des Klassifikators gemacht werden.

In dem Modellselektionsprozess wird der beste Klassifikator C_{Best}anhand der ermittelten kreuzvalidierten Klassifikationsgenauigkeit und der Laufzeit in Bezug zu einem Referenzdatensatz ermittelt. Durch Anwendung des Prozesses der Modellselektion auf verschiedene Eingangsdatentypen und der Variation der Stichprobengröße n kann geprüft werden, ob für alle Datensätze stets das gleiche Klassifikationsverfahren gewählt wurde.

7.9 Genauigkeitsanalyse

Nach Modellentwicklung und der Wahl des besten Klassifikationsverfahrens wird der Ansatz hinsichtlich der Genauigkeit tiefer untersucht. Damit werden im Wesentlichen folgende Ziele verfolgt:

- Bewertung des Verfahrens anhand verschiedener Untersuchungsgebiete
- Bewertung des Verfahrens differenziert nach Eingangsdatentypen
- Untersuchung des Einflusses der Trainingsdatenmenge
- Untersuchung der Generalisierungsfähigkeit

Die Bewertung des entwickelten Verfahrens erfolgt im Gegensatz zur Bewertung der getesteten Klassifikationsverfahren während der Modellselektion nicht nur über ein Gesamtmaß (Overall Accuracy, Kappa), sondern über Gütemaße zur Beurteilung der klassenspezifischen Genauigkeit. Diese werden aus berechneten Konfusionsmatrizen abgeleitet. Mit der Genauigkeitsanalyse wird untersucht, welchen Einfluss die Wahl der Eingangsdaten, der Siedlungstyp und die Anzahl der Trainingsdatenmenge auf die Genauigkeit haben. Mit einem kreuzweisen Trainieren und Testen wird letztendlich die Generalisierungsfähigkeit des Ansatzes untersucht, in dem an einem Untersuchungsgebiet A ein Klassifikator erlernt und anschließend auf ein Untersuchungsgebiet B angewendet und validiert wird.

7.10 Programmtechnische Umsetzung

Im Folgenden wird die Umsetzung der einzelnen Verarbeitungsprozesse sowie deren Kopplung vorgestellt.

[68] Die Rechenzeit, die für die Merkmalsberechnung benötigt wird, bleibt an dieser Stelle außer Acht.

7.10.1 Verwendete Software

Die einzelnen Verarbeitungsprozesse wurden unter verschiedenen Software-Umgebungen mithilfe von Skripten und Modellen operationalisiert. Die räumliche Datenanalyse erfolgt innerhalb von ArcGIS Desktop, die bildverarbeitenden Prozesse werden in einer eigenständigen Anwendung mit Zugriff auf Funktionalitäten der HALCON-Bibliothek verarbeitet und die statistische Datenanalyse wird mithilfe der Statistiksoftware R ausgeführt.

7.10.1.1 ArcGIS Desktop

Die kommerzielle Software ArcGIS Desktop ist Teil der ArcGIS-Produktfamilie der Firma ESRI (*Environmental Systems Research Institute*) und ist ein umfassendes System zur Erfassung, Organisation, Analyse und Visualisierung raumbezogener Daten in einem GIS (ESRI, 2012). Es wird weltweit in Verwaltungen, Unternehmen, Wissenschaft, Lehre und Medien genutzt und besteht aus den Anwendungen ArcMap, ArcCatalog, ArcToolbox und ArcGlobe. Für die räumliche Datenanalyse kann auf eine große Sammlung von Werkzeugen (Geoprocessing Tools) zurückgegriffen werden. Über eine graphische interaktive Modellierungsumgebung (ModelBuilder) oder mithilfe von Skript- und Programmiersprachen können diese Funktionen angesprochen und durch deren Kombination eigene Werkzeuge entwickelt werden. Eine freie und plattformunabhängige Skriptsprache für die Geodatenverarbeitung unter ArcGIS ist Python (www.python.org). Neben der Geodatenverarbeitung bietet Python die Möglichkeit, externe Programme, wie beispielsweise R Code unter ArcGIS, einzubinden (Carrillo, 2012). Für die Entwicklung des Verfahrens wurde ArcGIS Desktop in der Version 9.3 mit der Lizenzstufe ArcInfo verwendet. Als Skriptsprache diente Python 2.6.

7.10.1.2 R

R ist eine Entwicklungsumgebung und Programmiersprache für die Analyse und Visualisierung statistischer Daten. R wird in der Forschung aber auch von großen Unternehmen, wie Google, Microsoft oder Facebook, eingesetzt und steht unter der GNU (General Public License) (Adler, 2010). Es ist demnach eine freie Software unter offener Lizenzordnung, die über das Comprehensive R Archive Network (CRAN) heruntergeladen werden kann (www.cran.r-project.org). Als GNU-Projekt wird die Programmbibliothek von einer breiten wissenschaftlichen Gemeinschaft ständig weiterentwickelt. In der Basisversion können bereits eine Vielzahl statistischer Methoden zur Datenverarbeitung, Testverfahren, Verfahren der Clusteranalyse sowie Visualisierungswerkzeugen genutzt werden. Allerdings steht mit den Erweiterungspaketen (packages) ein enormes Angebot zusätzlicher Funktionen und Modelle bereit. Als Entwicklungsumgebung erfährt R eine große Beliebtheit bei der prototypischen Implementierung moderner statistischer Verfahren der Klassifikation oder des maschinellen Lernens. Die große Auswahl bereits implementierter Algorithmen und die Datenbank-Unterstützung führten letztendlich zur Wahl dieser Software. Mithilfe der Programmiersprache R können Funkionen in eigene Datenverarbeitungsprozesse eingebunden werden. Es wurde die R-Version 2.13.0 verwendet.

7.10.1.3 HALCON

HALCON der Firma MvTEC Software GmbH (www.mvtec.com) ist eine Software zur Entwicklung von Applikationen in der industriellen Bildverarbeitung. Die Software findet Anwendung in den verschiedenen Bereichen, wie Maschinenbau, Medizin, Halbleiterindustrie, Qualitätskontrolle, Photogrammetrie und Fernerkundung. HALCON stellt mit der Image Processing Library über 1 800 verschiedene Bildverarbeitungsoperatoren bereit und verfügt über eine graphische Programmierumgebung (HDevelop). Die Operatoren reichen von morphologischen Operatoren, Algorithmen zur Segmentierung, Matching-Verfahren, verschiedenen Filtern über die Merkmalsextraktion bis hin zu verschiedenen Klassifikationsverfahren. In HALCON werden die zwei grundlegenden Datentypen *iconic data* (images, regions, XLD contours) und *control data* (integers, strings, handles etc.) unterschieden (MVTec Software GmbH, 2009). Neben Bildern und Regionen können mit der eXtended Line Description (XLD) Konturlinien und Polygone beschrieben werden. Ein Datenaustausch mit einer GIS-Applikation ist über das TIFF-Format (images, regions) oder dem ARC/INFO Generate-Format (XLD contours) möglich. Entwickelte HALCON-Komponenten können in C, C++, C# oder Visual Basic Syntax exportiert und in eigene Anwendungen implementiert werden. Die Operatoren lassen sich jedoch auch von externen Anwendungen über verschiedene Sprachschnittstellen ansprechen. Die Software unterstützt dabei Multicore-Verarbeitung. HALCON wurde bereits für die automatische Extraktion von Objekten aus topographischen Karten (Gebäude, Baublöcke) und für die automatische Georeferenzierung (Identifikation von Kartenblattnummer und von Kartenblattecken) eingesetzt (Herold et al., 2012; Muhs et al., 2012; Röhm et al., 2012).

7.10.2 Programme und deren Kopplung

Für die Verfahrensentwicklung werden einzelne Verarbeitungsprozesse mithilfe von Modellen und Scripten prototypisch operationalisiert. Die entwickelten Modelle werden in unterschiedlichen Umgebungen ausgeführt und sind über eine gemeinsame Datenschnittstelle lose gekoppelt. Eine zukünftige GIS-Integration des entwickelten Verfahrens über Python oder in Form einer ArcMap-Erweiterung ist jedoch prinzipiell möglich.

In der Abb. 7-15 werden die einzelnen Arbeitsprozesse und deren Programmumgebung dargestellt. Für die grau hinterlegten Prozesse standen bereits Programmentwicklungen aus Vorarbeiten zur Verfügung. Dazu gehört einerseits eine unter HDevelop (HALCON) entwickelte Applikation (*hextract.exe*) zur automatischen Gebäudeextraktion aus topographischen Karten und andererseits eine Anwendung zur Gewinnung rasterbasierter Merkmale (*hcalc.exe*). Beide Anwendungen wurden in die ArcMap-Erweiterung SEMENTA® eingebunden (Meinel et al., 2008a) und konnten im Rahmen der Dissertation weiter verwendet werden.

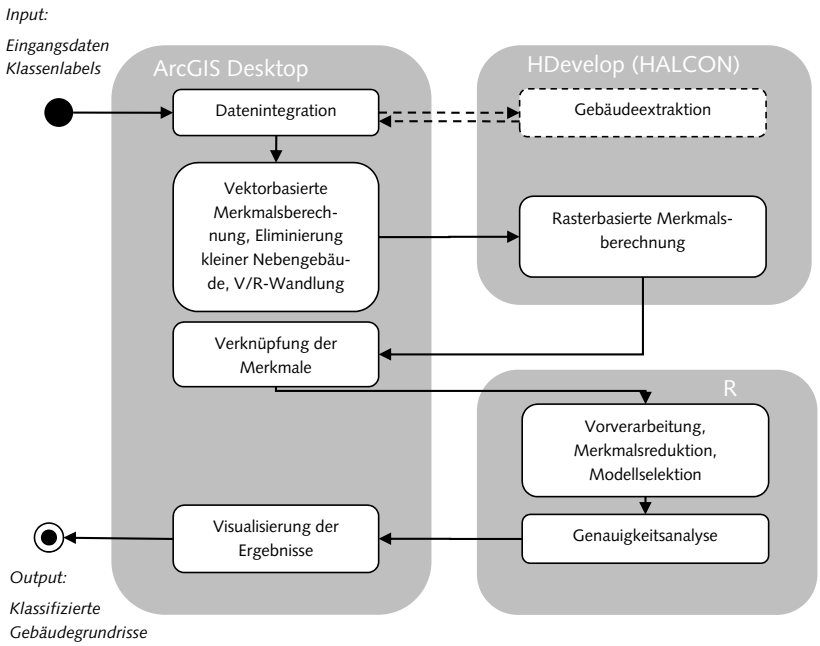

Abb. 7-15: Aktivitätsdiagramm der Verfahrensentwicklung

Die Aktivität Datenintegration unter ArcGIS wurde in Teilen automatisiert, da die Erfassung oder Übernahme von Klassenlabels (Referenzklassen) aus externen Datenquellen im Einzelnen zielgerichtete Nutzereingriffe nötig macht (Umkodierung, Kontrolle, manuelle Nachkartierung etc.). Für Gebäude, Baublöcke und Hauskoordinaten wurden *Feature Class*-Templates in einer ESRI File-based Geodatabase (FGDB) mit entsprechender Datenspezifikation (Geometrietyp, Attributsbezeichung, Datentyp, Bezugssystem etc.) angelegt. Der Import der Vektordaten erfolgt mit einem ModelBuilder-Modell, mit dem über eine SQL-Abfrage die benötigten Objekte integriert werden. Die Gebäudegrundrisse aus topographischen Karten werden durch Anwendung von hextract.exe bzw. hcalc.exe gewonnen und können über die gemeinsame Datenschnittstelle (Arc/Info Generate File) in die Gebäudedatenbank geschrieben werden. Nach geometrischer Integration der rasterbasierten Gebäude ist ergänzend eine räumliche Zuweisung der Klassenlabels (Referenzklassen) nötig. Dieser Schritt ist aufgrund von Lageversätzen zwischen Referenzgeometrie und Gebäudegeometrie nur bedingt automatisierbar und macht daher teilweise interaktive Bearbeitungen erforderlich. Die vektorbasierte Merkmalsberechnung, die Eliminierung der Nebengebäude sowie die Vektor/Rasterkonvertierung werden jeweils in Form eines ModelBuilder-Models realisiert. Bei der vektorbasierten Merkmalsgewinnung wird dabei auf einzelne Python-Skripte zugegriffen. Die rasterbasierten Merkmale werden unter Nutzung verschiedener Operatoren der HALCON-Bibliothek sowie anderen unter HDevelop entwickelten Algorithmen berechnet. Der Datenaustausch der numerischen Merkmale erfolgt über eine Textdatei buildinfo.dat. Über Python können diese eingelesen, über eine vorab definierte Gebäuderegion-ID verknüpft und integriert werden. Die Tabellen der Gebäudedatensätze in der FGDB werden

anschließend in eine Microsoft Access-Datenbank (MDB) kopiert. Diese Datenbank bildet die Datenschnittstelle für die weitere statistische Datenverarbeitung unter R. Für den Import von Daten kann mit dem R-Zusatzpaket „ODBC“ eine Datenbankanbindung zur MDB hergestellt werden.

Unter der Entwicklungsumgebung R wurden verschiedene R-Programme entwickelt, die Zugriff auf die Datenbank haben. Dies sind die folgenden Komponenten: Daten laden (loadData.r), Vorverarbeitung der Eingangsdaten (preProc.r), Merkmalsreduktion mit Filter (featureSelectionFilter.r), Merkmalswichtigkeit (variableImpRF.r), Modellvalidierung für die Modellselektion (modelVal.r) und die Merkmalsselektion mit Random Forest (featureSelectionRF.r). Wichtige Zwischenresultate, wie etwa die in jedem Schleifendurchlauf gemessene Klassifikationsgenauigkeit während der Modellvalidierung oder abgeleitete Konfusionsmatrizen, werden in einer CSV-Datei abgespeichert. Die Ergebnisse der Klassifizierung (numerischer Wert der Klassenzugehörigkeit) werden in die MDB zurückgeschrieben. Über eine Relation mit der FGDB lassen sich die Ergebnisse der Gebäudeklassifizierung im GIS visualisieren.

8 Ergebnisse und Diskussion

In diesem Kapitel werden die Ergebnisse der einzelnen Verfahrensschritte präsentiert und diskutiert. Nach einer Vorstellung der Untersuchungsgebiete stehen die Ergebnisse der Datenaufbereitung, der Merkmalsberechnung, der Merkmalsselektion, des Vergleichs der Klassifikationsverfahren und der Modellselektion im Vordergrund. Anschließend werden die Ergebnisse der Genauigkeitsanalyse und der Merkmalswichtigkeit vorgestellt.

8.1 Untersuchungsgebiete und verwendete Daten

Das entwickelte Klassifikationsverfahren soll an verschiedenen Siedlungstypen der Bundesrepublik getestet werden. Siedlungen lassen sich nach unterschiedlichen Kriterien und Methoden typisieren (vgl. Heineberg, 2006c). Die gängigste Typisierung ist die nach Stadtgrößenklassen mit der diese nach ihrer Einwohnerzahl in Großstädte mit mehr als 100 000, Mittelstädte mit 20 000 bis 100 000, Kleinstädte mit 5 000 bis 20 000 und Landstädte mit 2 000 bis 5 000 Einwohnern klassifiziert werden (Borsdorf & Bender, 2010). Der Rest fällt in die Kategorie der ländlichen Siedlungen. Mit den Stadt- und Gemeindetypen des Bundesinstituts für Bau-, Stadt- und Raumforschung (BBSR) werden die Gemeinden und Gemeindeverbände in die Kategorien Groß-, Mittel-, Kleinstädte und Landgemeinden unterteilt, wobei neben der Größe auch Funktion und Bedeutung der Städte eine Rolle spielen (BBSR, 2012b). Die Auswahl der Untersuchungsgebiete (Abb. 8-1) erfolgte unter Berücksichtigung dieser BBSR-Typen sowie der Verfügbarkeit der Geobasis- und Referenzdaten.

Abb. 8-1: Lage der Untersuchungsgebiete

8.1.1 Vorstellung der Untersuchungsgebiete

Einen Überblick über die strukturelle Ausgangssituation der ausgewählten Gebiete verschafft Tab. 8-1. Gewählt wurden die ländlichen Siedlungen Diera-Zehren, Crostwitz, Stolpen und Rechenberg-Bienenmühle, die kleinstädtische Siedlung Stolpen und die städtisch geprägten Siedlungen Dresden, Halle und Krefeld. Aufgrund der historisch begründeten Unterschiede in der Bebauungsstruktur zwischen Ost- und Westdeutschland, wurde mit Krefeld und Halle jeweils eine vergleichbare Stadt ausgewählt. Die sächsische Landeshauptstadt Dresden ist mit über 500 000 Einwohnern und einer Gebietsfläche von über 300 km² einwohner- und flächenmäßig die größte Stadt, gefolgt von den nur halb so großen kreisfreien Städten Krefeld in Nordrhein-Westfalen und Halle (Saale) in Sachsen-Anhalt.

Tab. 8-1: Raumstrukturelle Ausgangssituation der Untersuchungsgebiete (IÖR-Monitor 2008)

	Städtisch			**Kleinstädtisch**	**Ländlich**		
	Kreisfreie Stadt Dresden	Kreisfreie Stadt Krefeld	Kreisfreie Stadt Halle	Stadt Stolpen	Gemeinde Diera-Zehren	Gemeinde Rechenberg-Bienenmühle	Gemeinde Crostwitz
Stadt und Gemeindetyp des BBSR	Große Großstadt	Kleinere Großstadt	Kleinere Großstadt	Kleine Kleinstadt	Landgemeinde	Landgemeinde	Landgemeinde
Gebietsfläche in km² (2009)	328,3	137,8	135,0	60,9	43,2	52,5	13,3
Siedlungsfläche an Gebietsfläche	35,3 %	44,2 %	34,8 %	7,4 %	8,2 %	3,8 %	5,2 %
Einwohner (2009)	517 052	235 414	232 323	5 872	3 634	2175	1 099
Einwohnerdichte (Einwohner je km² Gebietsfläche)	1 575	1 709	1 721	96	84	41	83
Siedlungsdichte (Einwohner je km² bebauter Fläche)	4 461	3 867	4 944	1 304	1 026	1090	1 587

8.1.1.1 Dresden

Dresden wurde im Jahr 1206 erstmalig erwähnt und war lange Zeit königliche Residenz- und Hauptstadt (Brockhaus, 2005 Stichwort: Dresden). Heute ist die Stadt die flächenmäßig viertgrößte in Deutschland. Wie alle Städte der ehemaligen DDR ist auch Dresden durch den Städtebau und die Architektur einer sozialistischen Gesellschaft geprägt. Die Innenstadt von Dresden wurde bei Luftangriffen im 2. Weltkrieg weitestgehend zerstört. Nach dem Krieg begann man mit dem Wiederaufbau der historischen Bauwerke, der noch bis heute andauert. Viele ehemalige Wohnviertel wurden unter dem DDR-Regime völlig entkernt und mit modernen Bebauungen des industriellen Plattenbaus der 1970er Jahre aufgefüllt. Ausnahme bildet die zentrumsnahe Blockrandbebauung, wie beispielsweise die Leipziger Vorstadt oder die Innere Neustadt sowie die lockere Mehrfamilienhaus- und Villenbebauung in den Stadtteilen Striesen, Blasewitz und Strehlen, die vom Krieg weitestgehend verschont blieben. Am

Rande der Stadt entstanden im Rahmen des Großwohnungsprogrammes die neuen Wohngebiete Prohlis (1976-1980) und Gorbitz (1980er Jahre), die durch den mehrstöckigen industriellen Plattenbau der Wohnungsbauserie WBS 70 geprägt sind (Kowalke, 2000). In den peripheren Randlagen ist Dresden durch in den 1990er Jahren entstandene Eigenheimsiedlungen und Gewerbegebiete geprägt.

8.1.1.2 Halle

Die Stadt Halle (Saale) liegt im Süden von Sachsen-Anhalt und ist die größte Stadt dieses Bundeslandes. Die erste urkundliche Erwähnung ist auf das Jahr 806 n. Chr. datiert (Piechocki, 1994). Ihr städtebaulicher Charakter ist unter den deutschen Großstädten einzigartig, da die Stadt den 2. Weltkrieg im Gegensatz zu Dresden fast unbeschadet überstanden hat und sich die Siedlungsentwicklung der Stadt sehr gut in ihrer Struktur nachvollziehen lässt. Das Zentrum ist weitestgehend durch Altbaubestände in Blockrandbebauung charakterisiert. Im südlichen Innenstadtbereich ist die gründerzeitliche Struktur mit einem großen Bestand ehemaliger Industrieflächen und Gewerbebrachen untersetzt. Östlich des Innenstadtbereiches und des Hauptbahnhofes erschließt sich eine weitreichende industrielle Flächennutzung. Der westliche Teil der Stadt, eine einst im Rahmen des Wohnungsbaus der DDR entstandene eigenständige Stadt Halle-Neustadt, ist durch eine großflächige industrielle Plattenbauweise geprägt. Am Stadtrand sind hingegen Gebäude der Ein- und Zweifamilienhausbebauung dominant. Weitere Ausführungen zur stadtgeschichtlichen und stadtmorphologischen Entwicklung von Halle geben Piechocki (1994) und Friedrich & Frühauf (2006).

8.1.1.3 Krefeld

Die Stadt Krefeld liegt im Westen von Nordrhein-Westfalen am Rhein und wurde durch die Seidenstoffproduktion des 18. und 19. Jahrhunderts unter dem Namen „Seidenstadt" bekannt (Krefeld, 2009). Die Stadt ist Teil der Metropolregion Rhein-Ruhr und damit im größten Verdichtungsraum Deutschlands befindlich. Die Stadtgrenze geht auf die Vereinigung der Städte Krefeld und Uerdingen sowie weiterer Gemeinden im Jahr 1929 zurück. Mit Blick auf die städtebauliche Struktur wird der historische Kern der Stadt von einer geschlossenen Gründerzeitbebauung gesäumt. Zerstörungen aus dem Zweiten Weltkrieg wurden im Stadtbild mit straßenbegleitender Blockbebauung rekonstruiert. Die großflächigen Industrie- und Gewerbegebiete sind schwerpunktmäßig im Nordosten und entlang des Rheinufers angesiedelt, während große Bereiche im Norden und Süden landwirtschaftlich genutzt werden (Stadt Krefeld, 2012). Tieferen Einblick in die stadtgeschichtliche Entwicklung geben Engelbrecht et al. (2006) und Feinendegen et al. (2010)

8.1.1.4 Stolpen

Die Kleinstadt Stolpen, einst eine Burgsiedlung, liegt östlich von Dresden und ist durch einen geringen Siedlungsflächenanteil gekennzeichnet. Die Kleinstadt gehört zum Landkreis Sächsische Schweiz-Osterzgebirge und besteht aus dem Hauptort Stolpen und den weiteren losgelösten ländlich geprägten Ortsteilen Heeselicht, Helmsdorf, Langenwolmsdorf, Lauterbach und Rennersdorf-Neudörfel (Stadtverwaltung Stolpen, 2012). Die im Jahr 1723 abgebrannte Stadt Stolpen wurde unter Beibehaltung der mittelalterlichen Stadtstruktur wieder aufgebaut.

Viele Gebäude aus dieser Zeit sind noch erhalten. Der Marktplatz ist durch eine geschlossene Bebauung umsäumt. Im Südwesten des Ortes Stolpen erschließt sich eine Ein- und Zweifamilienhausbebauung. Einen Abriss der Geschichte in Karten geben Stams & Stams (1998).

8.1.1.5 Ländliche Gemeinden

Die ländlich geprägten Siedlungen in Sachsen befinden sich im Umland von Dresden (vgl. Abb. 8-1). Die Gemeinde Diera-Zehren gehört dem Landkreis Meißen an und besteht aus 21 Ortsteilen. Die Siedlungen liegen beidseitig der Elbe. Hinsichtlich der Siedlungsform handelt es sich größtenteils um Haufen- und Straßendörfer. Rechenberg-Bienenmühle ist ein Erholungsort im Osterzgebirge und besteht aus dem Ort Rechenberg-Bienenmühle und den Ortsteilen Clausnitz und Holzhau (Gemeinde RB, 2012). Charakteristisch ist die straßenbegleitende Dorfform (Straßendorf). Crostwitz im Landkreis Bautzen befindet sich nordöstlich von Dresden und ist Teil des sorbischen Siedlungsgebietes. Der Gemeinde gehören die sechs Ortsteile Caseritz (Kozarcy), Crostwitz (Chróśćicy), Horka (Hórki), Kopschin (Kopšin), Nucknitz (Nuknica) und Prautitz (Prawoćicy) an (Crostwitz, 2012). Der Ort Crostwitz ist durch ältere Wohn- und Fachwerkhäuser charakterisiert. Ländliche Siedlungen sind durch ländliche Hausformen sowie durch Ein- und Zweifamilienhäuser geprägt und zeigen eine deutlich niedrigere Dichte gegenüber den Städten. Bezüglich weiterer Ausführungen der städtebaulichen Charakteristik sei auf Nikolowski et al. (2012) verwiesen.

8.1.2 Datengrundlagen der Untersuchungsgebiete

Für die Untersuchungsgebiete wurden Datengrundlagen zum Gebäude, dem Baublock und den Hauskoordinaten beschafft. Bezüglich der Gebäudegrundrisse galt es, ein möglichst breites Spektrum aller Eingangsdatentypen I-V zu berücksichtigen, um die Genauigkeit möglichst differenziert untersuchen zu können. Als unterstützende Daten wurden der Siedlungslayer (sied_07) aus dem ATKIS® Basis-DLM sowie die Hauskoordinaten (georeferenzierte Gebäudeadressen) beschafft.

Die Tab. 8-2 fasst die verwendeten Datengrundlagen und deren Aktualität für die einzelnen Untersuchungsgebiete zusammen. Die DTK25-V, das ATKIS® Basis-DLM sowie die Hauskoordinaten werden zentral über das BKG bereitgestellt und standen für die Bearbeitung der Dissertation für alle Untersuchungsgebiete zur Verfügung. Die ALK wurde für die Untersuchungsgebiete in Sachsen mit freundlicher Genehmigung des Staatsbetriebes Geobasisinformation und Vermessung Sachsen (GeoSN) bereitgestellt.

Tab. 8-2: Überblick über die verwendeten Datengrundlagen und deren Aktualität. Angaben zur Aktualität über die Grundaktualität (DTK25, DTK25-V), mittlere Grundaktualität (ATKIS® Basis-DLM), Zeitpunkt des Datenbankauszuges (ALK) bzw. Stichtag der Zusammenführung des Sekundärdatenbestandes (3D-GS, HK)

		Gebäude					Bau-blöcke	Hausko-ordinaten
		Typ I	Typ II	Typ III	Typ IV	Typ V		
	Kartenblatt-Nr. und Bezeichnung	DTK25-V	DTK25	ATKIS/HU	ALK	3D-GS	ATKIS	HK
Dresden	4848: Dresden Nord	1998		2001	2008		2001	09/2010
	4849: Radeberg	1998						
	4947: Wilsdruff	1998						
	4948: Dresden	1998						
	4949: Dresden Ost	1998						
	5048: Kreischa	1998						
	5049: Pirna	1998						
Krefeld	4505: Moers	2005	2007	8 /2009 simuliert[69]	8/2009 simuliert[70]	8/2009	2010	09/2010
	4604: Kempen	2005	2007					
	4605: Krefeld	2006	2007					
	4606: Düsseldorf-Kaiserswerth	2006	2006					
	4704: Viersen	2005	2007					
	4705: Willich	2005	2007					
Halle	4437: Halle (S.) Nord	1995	2005 simuliert[71]	2005			2005	09/2010
	4538: Halle (S.) Ost	2005						
	4537: Halle (S.) Süd	2005						
	4438: Landsberg	1999						
Stolpen	4950: Stolpen	1997		1997	2008		1997	09/2010
Rechenberg-Bienenmühle	5247: Rechenberg-Bienenmühle	1999		2000	2008		2000	09/2010
Diera-Zehren	4746: Zehren	1997		2004	2008		2004	09/2010
	4846: Meißen	1999						
Crostwitz	4751: Panschwitz-Kuckau	1997		2004	2008		2004	09/2010

[69] Simulierte Hausumringe über 3D-GS
[70] Simulierte ALK über 3D-GS
[71] Simulierte DTK25 über Vektor-Raster-Konvertierung der Gebäude aus dem ATKIS® Basis-DLM

Da die automatisierte Ableitung der DTK25 aus dem ATKIS® Basis-DLM zum Zeitpunkt der Datenbeschaffung noch nicht in allen Bundesländern realisiert war, standen für die Untersuchungsgebiete in Sachsen sowie Halle keine Daten zur Verfügung. Die DTK25 für Halle konnte jedoch unter Nutzung der Gebäude aus dem ATKIS® Basis-DLM simuliert werden, da die Gebäudegrundrisse der DTK25 scheinbar ohne Generalisierung aus dem ATKIS® Basis-DLM entnommen werden[72]. Durch eine Konvertierung der ATKIS-Gebäude in ein Rastermodell mit einer Rasterweite von 1,25 m konnte für Halle eine simulierte DTK25 erzeugt werden.

Mit den 3D-Gebäudestrukturen (3D-GS) steht für Krefeld als einziges Untersuchungsgebiet ein 3D-Gebäudemodell (Eingangsdatentyp V) zur Verfügung. Die Produktion dieser Daten basiert auf vorhandenen Datensätzen zum Gebäudebestand, namentlich der ALK und deren Attributierung, Daten des Digitalen Gelände- und Oberflächenmodells sowie Adressdaten (Heitmann, 2011). Die Daten wurden mit freundlicher Genehmigung von der zuständigen Landesbehörde in Nordrhein-Westfalen (GEOBasis.nrw) zur Verfügung gestellt. Da die 3D-Gebäudestrukturen aus ALK-Daten abgeleitet sind, konnten simulierte Datensätze des Eingangsdatentyps II und IV erzeugt werden, die in Inhalt und Struktur den ATKIS-Gebäudedaten/Hausumringen bzw. den ALK-Gebäudedaten entsprechen.

8.2 Ergebnisse der Datenaufbereitung

8.2.1 Datenintegration

Die Eingangsdaten wurden mit entsprechenden Prozeduren zur Datenintegration (vgl. Kap. 7.4) aufbereitet und in das verfahrensspezifische Datenmodell überführt. Die vektorbasierten Daten zu den Gebäuden (Eingangsdatentyp III-V), Baublöcken und Hauskoordinaten wurden über eine entsprechende Abfrage im zugrundeliegenden Datenmodell (ATKIS®, ALK etc.) selektiert. Bei der Integration wurden die Angaben zur Gebäudefunktion (nur ALK, 3D-GS) in einem Attribut „GEBNUTZ“ zu den drei Klassen „Wohngebäude“, „Gebäude für Wirtschaft oder Gewerbe“ und „Öffentliches Gebäude“ zusammengefasst. Die Gebäudegrundrisse aus der DTK25 (Eingangsdatentyp II) wurden durch eine Raster-Vektor-Konvertierung der Rasterebenen „haus“ und „rot“ erzeugt. Für die Ableitung der Gebäudegrundrisse aus der rasterbasierten DTK25-V (Eingangsdatentyp I) kam das Programm *BFExtractTool* zur Gebäudeextraktion zum Einsatz, das in Form einer ausführbaren Datei zur Verfügung stand und auf Bildverarbeitungsroutinen von HALCON zugreift (Meinel et al., 2008a; Herold et al., 2012). Für diesen Extraktionsprozess werden die Baublöcke aus dem ATKIS® Basis-DLM benötigt, um den Suchbereich nach Gebäuden einzuschränken.

[72] Eine Überlagerung der Ebene „haus“ (Testdatensatz der DTK25) mit den Gebäuden aus dem ATKIS® Basis-DLM zeigte einen identischen Detaillierungsgrad in der Modellierung. Der Testdatensatz wurde von der Internetseite des Landesamtes für Vermessung und Geoinformation Sachsen-Anhalt zuletzt am 12.12.2012 unter der URL: http://www.lvermgeo.sachsen-anhalt.de/de/geoservice/download/testdaten/files/dtk25.zip heruntergeladen.

Abb. 8-2: Ergebnis der Gebäudeextraktion am Beispiel der DTK25 (Krefeld) und der DTK25-V (Dresden)

Die Abb. 8-2 zeigt das Ergebnis der Gebäudeextraktion am Beispiel der DTK25 in Krefeld und der DTK25-V in Dresden. Die automatische Extraktion der Gebäude aus der DTK25-V unter Nutzung des Extraktionstools *BFExtractTool* ist nicht fehlerfrei. Meinel et al. (2008a) konnten die Extraktionsfehler der falsch positiv und falsch negativ klassifizierten Objekte am Gebäudebestand der Stadt Dresden quantifizieren. Dies geschah mittels eines visuellen Vergleichs zwischen dem Extraktionsergebnis und dem Eingangsdatensatz. Dabei ergab sich ein Anteil falsch positiv erkannter Gebäude von 3,8 %, der auf Schrift- und Signaturobjekte zurückzuführen ist. Der Gebäudeverlust (falsch negativ) durch Schrift- und Signaturüberdeckung ist nur bei sehr hoher Gebäudedichte relevant und liegt für Dresden bei 0,4 % und wird durchschnittlich auf unter < 1,0 % geschätzt.

Nach der Gebäudeextraktion erfolgte eine manuelle Korrektur des Extraktionsergebnisses. Unter Nutzung eines entsprechend besseren Gebäudedatensatzes, wie den Gebäuden aus der ALK oder ATKIS®, konnten die falsch positiven Objekte für die Untersuchungsgebiete identifiziert und ausgeschlossen werden. Der Einfluss der wenigen fehlenden Gebäude wird bei der Verfahrensentwicklung als gering eingeschätzt, weshalb dieser Fehler hinnehmbar war. Die Tab. 8-3 zeigt die Objektanzahl nach der Datenaufbereitung für die Gebäudegrundrisse, Baublöcke und Hauskoordinaten aller Untersuchungsgebiete.

Tab. 8-3: Anzahl der Gebäudeobjekte in den Untersuchungsgebieten

	Gebäudegrundrisse					**Baublöcke**	**Hauskoordinaten**
	Gebäuderegionen (Anzahl)		Einzelgebäude (Anzahl)			(Fläche)	(Anzahl)
Datenbasis	DTK25-V	DTK25	ATKIS/HU	ALK	3D-GS	ATKIS®	HK
Dresden	44 708		123 172	165 046		329,5 m²	66 717
Krefeld	20 553	16 223	115 218	115 218	115 218	137,9 m²	51 257
Halle	16 546	26 055	57 442			135,7 m²	33 566
Stolpen	2 275		3 195	2 984			2 027
Rechenberg-Bienenmühle	969		1 542	1 492		52,8 m²	894
Diera-Zehren	1 708		2 187	2 928		43,3 m²	1 366
Crostwitz	432		608	605		13,4 m²	358

Die höhere Objektanzahl der Gebäude aus dem ATKIS®, der ALK oder dem 3D-Gebäudemodell im Vergleich zu den Gebäuden aus der topographischen Karte ergibt sich aus der detaillierteren Einzelgebäudemodellierung. Für die ländlichen Gebiete in Sachsen ist die Objektanzahl der ATKIS-Gebäude gegenüber den ALK-Gebäuden teilweise höher. Das ist dem Fakt geschuldet, dass einige Gebäude derzeit unvollständig in der ALK modelliert sind (Burckhardt, 2012). Auffällig ist der große Unterschied der Objektanzahl zwischen der DTK25 und der DTK25-V in Halle und Krefeld. In Krefeld sind die Gebäude in der DTK25 einer stärkeren Generalisierung unterzogen als in der DTK25 von Halle. Die Gebäude in Sachsen-Anhalt werden ohne Generalisierung aus dem ATKIS® Basis-DLM übernommen. Viele kleine Nebengebäude, die in der DTK25-V nicht mehr dargestellt werden, führen deshalb zu einer höheren Objektanzahl.

8.2.2 Erfassung der Klassenlabels

Zum Trainieren und Validieren eines Klassifikators wird für einen Teil der Gebäude die zugehörige Klasse (Klassenlabel) benötigt. Für die Aufbereitung der Referenzdaten wurden externe gebäudebasierte Kartierungen genutzt, die im Rahmen verschiedener Projekte, na-

mentlich REGKLAM[73], MULTISURE[74], FoPS[75] und EASE[76], erhoben und mit freundlicher Genehmigung zur Verfügung gestellt wurden. Die Tab. 8-4 gibt Aufschluss über die verwendeten Kartierungen sowie deren zugrundeliegenden Daten und Typologien.

Die Kartierung der Untersuchungsgebiete erfolgte jeweils durch einen Bearbeiter mittels GIS-gestützter visueller Interpretation auf Grundlage hochaufgelöster Ortholuftbilder. Teilweise wurden dazu Liegenschaftskarten, historische Karten und Pläne sowie Schrägluftbilder über den Internetdienst Bing Maps[77] hinzugezogen und die Ergebnisse mittels Vor-Ort-Begehung bestätigt.

Tab. 8-4: Verwendete Kartierungen und deren Eigenschaften

	Projekte mit Referenzdaten			
	MULTISURE	REGKLAM	FoPS	EASE
Bezugsgeometrie der Kartierung	Digitale Stadtkarte (DSK500)	Amtliche Liegenschaftskarte (ALK)	Gebäude aus DTK25-V	Hausumringe
Zweck der Kartierung	Hochwasserschadensmodellierung	Wirkung des Klimawandels auf Gebäude	Siedlungsstrukturelle Analyse	Energetische Modellierung
Typologie	Gebäudetypenmatrix nach Bothmer & Sommer (2010)	Gebäudetypenmatrix nach Nikolowski et al.(2012)	SEMENTA-Typologie nach Meinel et al. (2008a)	SEMENTA-Typologie nach Meinel et al. (2008a)
Untersuchungsgebiete	**Stadt Dresden:** Elbeschlauch bestimmt durch minimalen Grundwasserflurabstand während des Elbe-Hochwassers (2002)	**Stadt Dresden:** Stadtteile Innere Altstadt, Äußere Neustadt, Seevorstadt West/Ost, Striesen, Kleinzschachwitz, Friedrichstadt, Leuben), **Stadt Stolpen:** Altstadt Stolpen **Ländliche Gebiete:** Ort Rechenberg-Bienenmühle (Gemeinde Rechenberg-Bienenmühle), Orte Zehren, Zadel, Diera (Gemeinde Diera-Zehren) und der Ort Crostwitz (Gemeinde Crostwitz)	**Stadt Dresden:** Teilkartierung der Stadt	**Stadt Halle (Saale):** Gesamtstädtische Kartierung; **Stadt Krefeld:** Teilkartierung der Stadt

[73] Projekt „Regionales Klimaanpassungsprogramm für die Modellregion Dresden“ (REGKLAM) im Rahmen der vom BMBF initiierten Fördermaßnahme KLIMZUG zur Entwicklung innovativer Ansätze zur Anpassung an den Klimawandel (www.regklam.de)

[74] Projekt „Entwicklung multisequenzieller Vorsorgestrategien für grundhochwassergefährdete urbane Lebensräume“ (MULTISURE) im Rahmen des vom BMBF geförderten Forschungsvorhabens "Risikomanagement extremer Hochwasserereignisse RIMAX" (www.rimax-hochwasser.de).

[75] Im Rahmen des Projektes „Automatische Ableitung von stadtstrukturellen Grundlagendaten und Integration in einem geographischen Informationssystem“ einem Projekt des „Forschungsprogramms Stadtverkehr (FoPS)" des Bundesministeriums für Verkehr, Bau- und Stadtentwicklung (BMVBS) und des Bundesamtes für Bauwesen und Raumordnung (BBR) konnten Referenzdaten für Dresden erhoben werden (Meinel et al., 2008a).

[76] Das SAW-Projekt „Energetische Aufwertung und Stadtentwicklung“ (EASE) ist eine interdisziplinäre Zusammenarbeit zwischen dem Leibniz-Institut für ökologische Raumentwicklung (IÖR), dem Institut für Wirtschaftsforschung Halle (IWH) und dem E.ON - Energieforschungszentrum der RWTH Aachen. (www.ioer.de).

[77] Zugriff auf den Dienst über www.bing.com/maps

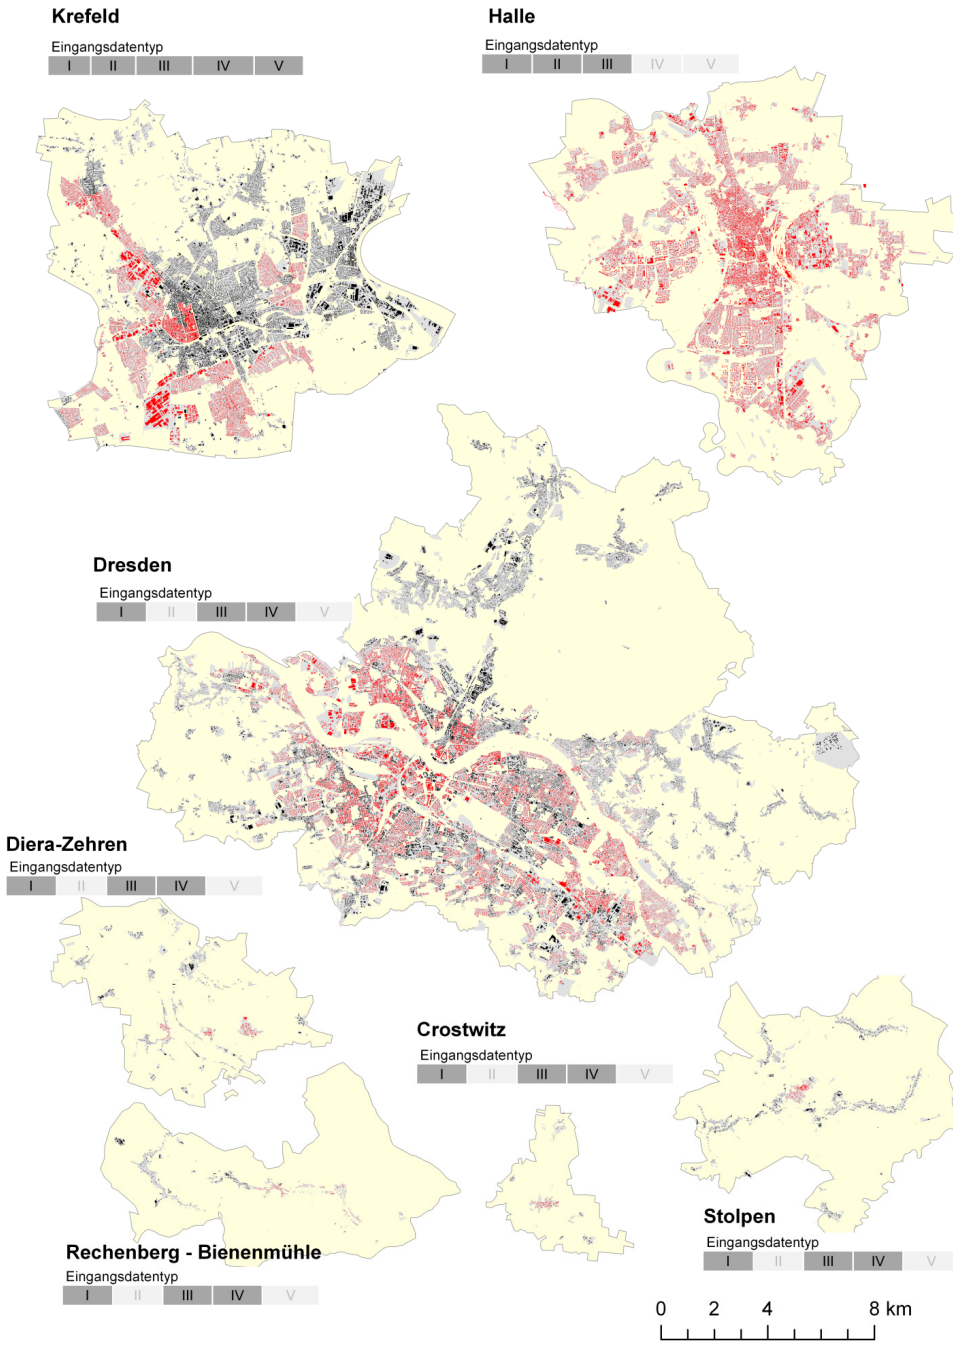

Abb. 8-3: Verteilung der Referenzgebäude in den Untersuchungsgebieten (rot eingefärbt). Die jeweilige Verfügbarkeit der Eingangsdatentypen I-V ist über eine Einfärbung (dunkelgrau – verfügbar bzw. hellgrau – nicht verfügbar) der zugehörigen Balken gekennzeichnet. (Quelle: Eigene Darstellung, Datengrundlage: VG250, ATKIS Basis-DLM und Hausumringe © GeoBasis-DE / BKG 2010)

Für die Stadt Halle lag eine Gesamtkartierung zugrunde, während für die anderen Untersuchungsgebiete nur für Teilgebiete Gebäude mit zugehöriger Klasse zur Verfügung standen. Eine Übersicht der räumlichen Verteilung der Klassenlabels geben die Karten in Abb. 8-3. Den Kartierungen lagen unterschiedliche Gebäudetypologien zugrunde. Die im REGKLAM-Projekt entwickelte Gebäudetypenmatrix wird beispielsweise durch 7 Baualtersklassen und durch die 8 Bebauungsarten aufgespannt (Nikolowski et al., 2012) und bildet mit 56 theoretisch möglichen Gebäudetypen den Gebäudebestand sehr differenziert ab.

Für eine Nutzung der Kartierung als Referenzinformation für die Erzeugung der Klassenlabels waren drei Bearbeitungsschritte nötig:

- Umkodierung in die Zieltypologie
- Attributtransfer von der originalen Kartierung zu den entsprechenden Gebäudegrundrissen in der Datenbank
- Kontrolle, Korrektur und Ergänzung der Klassenlabels

Zunächst wurden die Gebäudetypen der Kartierung in die für die Arbeit festgelegten Klassen der Gebäudetypologie überführt. Diese semantische Transformation erfolgte durch Erstellung entsprechender Zuordnungstabellen, die eine automatische Umkodierung der Klassen erlauben. Nicht eindeutig einer Zielklasse zuzuordnende Gebäudeklassen mussten unter Verwendung von Luftbilddaten manuell umkodiert werden.

Im nächsten Schritt wurden die umkodierten Attribute der originalen Kartierung über eine räumliche Zuordnung im GIS (engl. *spatial join*) den Gebäudegrundrissen der Untersuchungsgebiete in der Datenbank angehangen. Die Zuordnung erfolgte durch Verschneidung der Centroide der Zielgeometrie (ALK, ATKIS und 3D-GS) mit den Polygonen der Bezugsgeometrie der Kartierung. Eine Herausforderung stellt der Attributtransfer zu den Gebäudegrundrissen aus der DTK25 bzw. der DTK25-V dar, da wegen des unterschiedlichen Modellierungsgrades (Gebäuderegionen) gegenüber der Bezugsgeometrie (Einzelgebäude) eine Mehrfachzuordnung möglich ist. In diesem Fall wurde der Gebäudetyp nicht über den Centroiden, sondern über eine Auswertung der Gebäudeteilflächen nach gegenseitiger Verschneidung zugeordnet. Bei einer Mehrfachzuordnung wird dann der Gebäudetyp zugewiesen, dessen Fläche anteilig an der betrachteten Gebäuderegion der Zielgeometrie am größten ist. Da große Lageversätze zwischen den Objekten nicht immer einen plausiblen Attributtransfer zulassen, war eine Kontrolle und manuelle Korrektur nötig. Der Attributtransfer der Gebäude aus der DTK25 und DTK25-V konnte für Krefeld aufgrund großer, unsystematischer Lageversätze nur für wenige Gebäudeobjekte zweifelsfrei richtig transferiert werden, weshalb für diese Datensätze nur wenige Gebäude mit zugehörigem Klassenlabel zur Verfügung stehen.

In Abb. 8-4 sind die Referenzgebäude der ALK und der DTK25-V am Beispiel von Dresden gegenübergestellt. Deutlich werden an dieser Stelle der unterschiedliche Detaillierungsgrad und die verschiedenen Repräsentationsformen der Gebäude.

Abb. 8-4: Referenzdatenbasis am Beispiel von Dresden: a) Gebäude aus der ALK und b) Gebäude aus der DTK25-V (Quelle: Eigene Darstellung; Datengrundlage: Gebäude aus ALK © GeoSN 2008, Gebäude aus DTK25-V © GeoSN 1998 und baulich geprägte Flächen aus ATKIS® Basis-DLM © GeoBasis-DE / BKG 2010)

Eine Übersicht über die Objektanzahl einzelner Klassen in der Referenzdatenbank wird in Tab. 8-5 gezeigt. Für die aus topographischen Karten extrahierten Gebäude stehen deutlich weniger Klassenlabels zur Verfügung als für andere Eingangsdaten. Eine Sonderstellung nimmt die Dresdner Kartierung ein. Da die Bezugsgeometrie der Referenzkartierung den Gebäuderegionen aus der DTK25-V entsprechen (Meinel et al., 2008a), konnten diese Attribute auch nur an die vergleichbaren Gebäudegrundrisse der DTK25-V gehangen werden. Deshalb ist die Anzahl an Referenzgebäuden für die DTK25-V deutlich höher als für die anderen Eingangsdaten. Für Halle und Krefeld existiert keine Kartierung der Villen (MFH-VI). Um eine Vergleichbarkeit zwischen den Städten herzustellen, wurden die Villen für Dresden der Gruppe der freistehenden Mehrfamilienhäuser (MFH-F) zugeordnet.

Tab. 8-5: Anzahl der Objekte in der Referenzdatenbank mit Klassenzugehörigkeit

	Stadt Dresden			Stadt Halle			Stadt Krefeld			Kleinstadt Stolpen			Dörfl. Gebiete		
	DTK25-V	ATKIS	ALK	DTK25-V	DTK25*	ATKIS	DTK25-V	DTK25	3D-GS, ALK*, HU*	DTK25-V	ATKIS	ALK	DTK25-V	ATKIS	ALK
MFH-G	357	1 382	1 383	796	653	6 036	23	164	3 458	16	111	112	0	0	0
MFH-F	5 918	3 665	3 665	744	916	1 245	19	195	359	76	75	70	116	145	179
MFH-TZ	1 396	2 505	2 485	724	716	2 597	33	398	913	3	3	4	1	4	1
MFH-IZ	522	832	833	592	460	4501	9	105	252	0	0	0	0	0	0
MFH-HH	45	19	19	12	12	13	10	51	56	0	0	0	0	0	0
EFZH-EH	4 303	1 843	1 854	3 691	4 702	4 934	188	1 866	3 406	55	74	62	187	290	244
EFZH-DH	1 304	977	1 015	1 420	1 826	3 909	153	1 417	4 914	12	21	32	16	22	32
EFZH-RH	494	959	967	526	617	3 443	100	1 078	6 564	12	14	53	4	7	33
LH	370	496	503	839	1 029	1 583	10	39	53	14	19	15	230	274	321
WGL	2 872	13 566	23 514	4621	13 647	26 794	92	1 030	24140	38	147	290	155	427	743
ÖG	608	616	881	793	1 032	1 478	10	129	530	13	19	25	23	27	39
Summe	18 189	26 860	37 119	14 758	25 610	56 533	647	6 472	44 645	239	483	663	732	1 196	1 592

*simuliert mittels 3D-GS

Eine Betrachtung der Klassenverteilung macht starke Unterschiede zwischen den Untersuchungsgebieten deutlich (Abb. 8-5). Es ist in diesem Zusammenhang jedoch zu berücksichtigen, dass die Klassenverteilung nur für die gesamtstädtische Kartierung von Halle der tatsächlichen Verteilung im Untersuchungsgebiet entspricht. Die Referenzdaten der anderen Untersuchungsgebiete repräsentieren lediglich eine Teilmenge. Es ist zu beobachten, dass der Anteil der Nichtwohnnutzungsklassen (WGL und ÖG) für die Gebäudedatensätze der DTK25 bzw. DTK25-V deutlich geringer ist als für die vektorbasierten Gebäudegrundrisse. Dies ist dadurch begründet, dass viele kleine Nebengebäude in der topographischen Karte nicht mehr darstellbar sind und damit weggelassen wurden. Andererseits führt die Vereinfachung und Zusammenfassung zu Gebäuderegionen zu einer Differenz, da mehrere Einzelgebäude nur noch über eine Gebäuderegion repräsentiert werden.

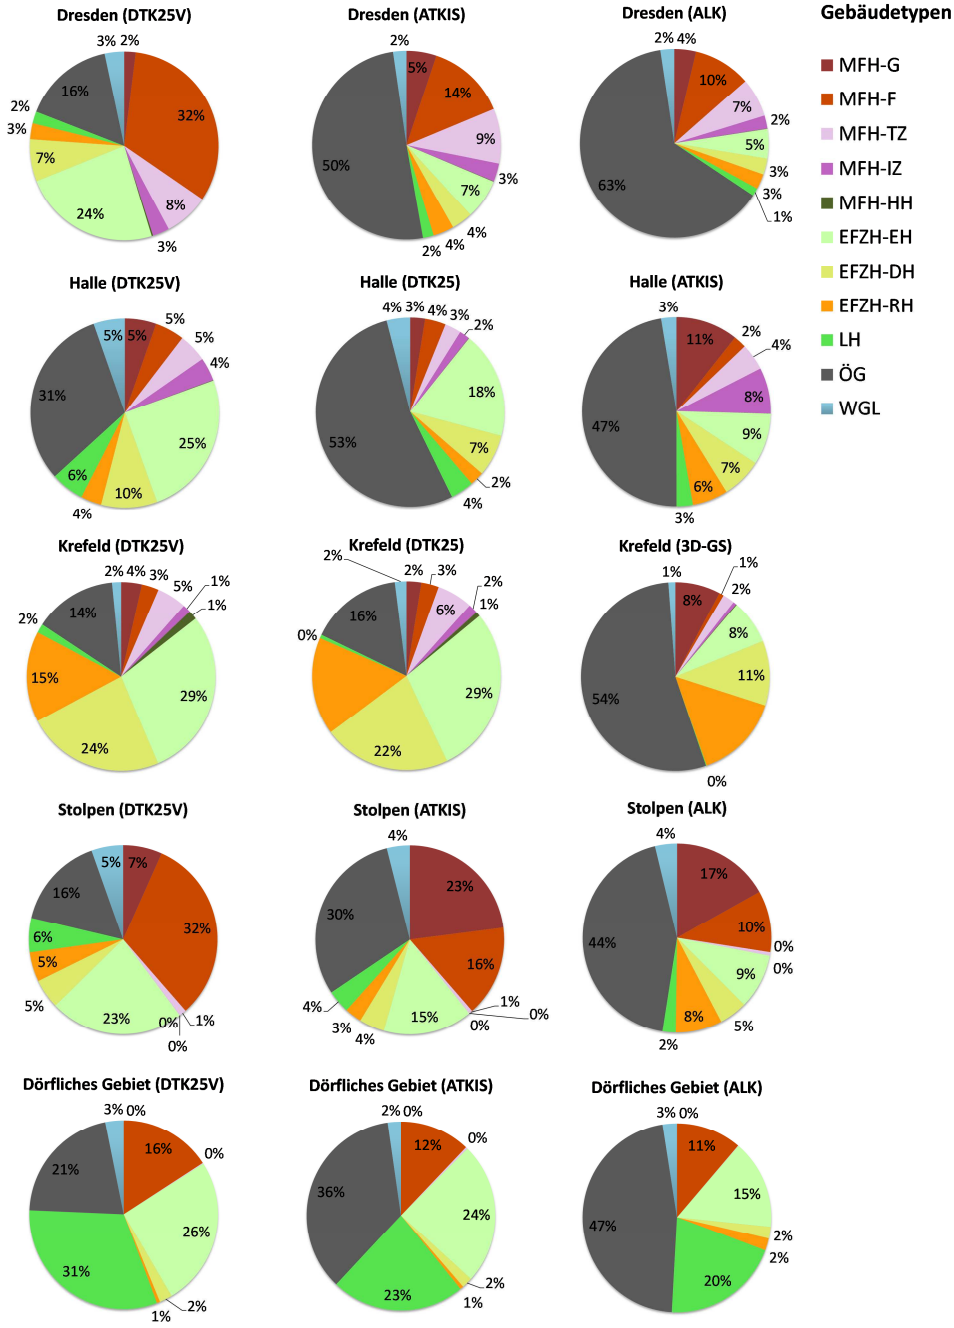

Abb. 8-5: Verteilung der Gebäudetypen in der Referenzdatenbank

8.2.3 Diskussion der Datenaufbereitung

Eine Integration von Gebäudegrundrissen unterschiedlicher Quellen (DTK25, DTK25-V, ATKIS®, ALK, 3D-GS) in ein verfahrensspezifisches Datenmodell kann weitestgehend automatisiert werden. Für die ALK-Gebäude aus dem Liegenschaftskataster ist derzeit jedoch eine länderspezifische Datenintegration nötig, da länderspezifische Objektschlüsselkataloge vorliegen. Mit Umstellung auf das AAA-Modell und mittels einer Harmonisierung der Objektartenkataloge ALKIS® und ATKIS® wird jedoch ein einheitlicher Zugriff auf die Gebäude und deren Nutzungsinformation möglich. Was die Gebäudeextraktion aus topographischen Karten betrifft, so ist eine Kontrolle und Korrektur der Daten nötig. In dieser Arbeit erfolgte diese durch einen räumlichen Abgleich mit einer besseren Gebäudegeometrie. Da diese Daten im praktischen Anwendungsfall nicht zur Verfügung stehen, könnten als Ersatz die Hauskoordinaten verwendet werden, mit denen die falsch positiv extrahierten Gebäudegrundrisse identifiziert und aus dem Datensatz entfernt werden könnten.

Für die Aufbereitung der Referenzdatenbank wurden Untersuchungsgebiete verschiedenen Siedlungstyps (Stadt, Kleinstadt und Dorf) gewählt. Die konkrete Wahl der Gebiete war jedoch primär von der Verfügbarkeit von Referenzdaten zur Gebäudeklasse und den nötigen Datengrundlagen bestimmt. Eine Auswahl der Untersuchungsgebiete allein auf Grundlage raumstruktureller Kriterien hätte vermutlich zu einer repräsentativeren Auswahl geführt. Ohne Zugang zu bereits vorhandenen Kartierungen aus Vorarbeiten oder externen Projekten wären viele Analysen der Arbeit nicht möglich gewesen. Eine Referenzdatenerhebung in diesem Umfang wäre im Rahmen dieser Arbeit nicht leistbar gewesen.

Eine Herausforderung bei der Nutzung externer Gebäudekartierungen stellt die Übertragung der Attribute von der Referenzkartierung (Einzelgebäude) zu den aus topographischen Karten extrahierten Gebäudegrundrissen (leicht generalisierte Gebäuderegionen) dar. Bei guter Lagetreue können die Gebäudetypen der Referenzkartierung über die größte gemeinsame Fläche nach einer Verschneidung der Zielgeometrie zugeordnet werden. Eine eindeutige Zuordnung kann bei größeren Lageversätzen mit dieser Methode nicht erreicht werden, weshalb die Objektanzahl der DTK25-Gebäude von Krefeld deutlich geringer als die der Referenzkartierung ist. Mithilfe objektbasierter Ansätze des Gebäudematchings (u. a. Revell & Antoine, 2009) könnte die Zuordnungsrate gegebenenfalls erhöht werden.

8.3 Ergebnisse der Merkmalsberechnung und Merkmalsreduktion

Nach Aufbereitung aller Datensätze der Untersuchungsgebiete werden die Merkmale mithilfe der entwickelten Modelle unter ArcGIS sowie der Nutzung bereits implementierter Operatoren unter HALCON berechnet. Dieser Abschnitt widmet sich den Ergebnissen Detektion und Eliminierung kleiner Nebengebäude, der Merkmalsberechnung, der Wahrscheinlichkeitsdichte und der Merkmalsreduktion.

8.3.1 Schwellwertermittlung zur Detektion kleiner Nebengebäude

Gebäudegrundrisse in Einzelgebäuderepräsentationen (ALK, ATKIS®, Hausumringe, 3D-GS) müssen von kleinen unbedeutenden Nebengebäuden, wie Garagen, Schuppen etc., befreit werden, damit sie die Merkmalsberechnung nicht verfälschen. Wie im methodischen Teil dargestellt (Kap. 7.5.7), können *Nebengebäude* bereits durch eine Abfrage selektiert werden. Für eine Selektion der *kleinen Nebengebäude* aus dieser Menge der Nebengebäude sind Schwellwerte für freistehende (*AreaSingleMin)* und angeschlossene Nebengebäude (*AreaMultiMin*) gesucht.

Die Ermittlung der optimalen Schwellwerte *AreaSingleMin* und *AreaMultiMin* erfolgte über eine ROC-Analyse auf Basis von Referenzdaten mit bekannter Nutzungsinformation unter Minimierung eines Fehlerkriteriums. Mit den 3D-Gebäudestrukturen von Krefeld liegen für insgesamt 31 393 Gebäude valide Informationen zur Gebäudefunktion (entspricht der Funktion aus der ALK) vor. Mit dem Attribut „NUTZUNG“ können die *kleinen Nebengebäude*[78] (13 784 Gebäude) den *Hauptgebäuden mit Wohnnutzung*[79] (17 609 Gebäude) gegenübergestellt werden (Tab. 8-6).

Tab. 8-6: Referenzdaten für die ROC-Analyse unter Nutzung der 3D-Gebäudestrukturen von Krefeld

Referenzdaten Krefeld (3D-GS)		Anzahl
Gesamt		31 393
Freistehende Gebäude		3 858
	kleine Nebengebäude	2 533
	Hauptgebäude mit Wohnnutzung	1 325
Nicht freistehende Gebäude		27 535
	kleine Nebengebäude	11 251
	Hauptgebäude mit Wohnnutzung	16 284

Ziel ist die Ermittlung eines optimalen Flächenschwellwertes zur Trennung dieser zwei Klassen jeweils für die freistehenden und die angeschlossenen Gebäude. Diese ermittelten Schwellwerte bilden die Grundlage für die Selektion der *kleinen Nebengebäude* aus der Menge der *Nebengebäude* im Merkmalsselektionsprozess.

Die Abb. 8-6 zeigt die Dichteverteilung des Merkmals Fläche (*SHAPE_Area*) für die *Gebäude mit Wohnnutzung (WG)* und die *kleinen Nebengebäude (NG),* getrennt für freistehende und angebaute Gebäude. Es ist in beiden Fällen eine deutliche Überlagerung der Verteilung sichtbar. Eine eindeutige Trennung der zwei Klassen über einen Flächengrößenschwellwert ist darum nicht ohne Fehler möglich.

[78] Zur Gruppe der „kleinen Nebengebäude“ zählen folgende Gebäudefunktionen (entsprechend dem Attribut „NUTZUNG“ der 3D-Gebäudestrukturen von Krefeld): „Kleines untergeordnetes Gebäude“, „Einzelgarage“, „Doppelgarage“, „Gartenhaus“, „Abfall (Lagergebäude)“, „Sammelgarage“, „Schuppen“ und „überdachter Stellplatz (soweit nicht OS 5315)“, „Umformer (soweit nicht OS 3447)“.

[79] Zur Gruppe der „Hauptgebäude mit Wohnnutzung“ zählen folgende Gebäudefunktionen (entsprechend dem Attribut „NUTZUNG“ der 3D-Gebäudestrukturen von Krefeld): „Doppelhaus“, „Einzelhaus“, „Freistehender Wohnblock“, „Gruppenhaus“, „Hochhaus“, „Reihenhaus Wohnblock in geschlossener Bauweise“ und „Wohnhaus in Reihe“.

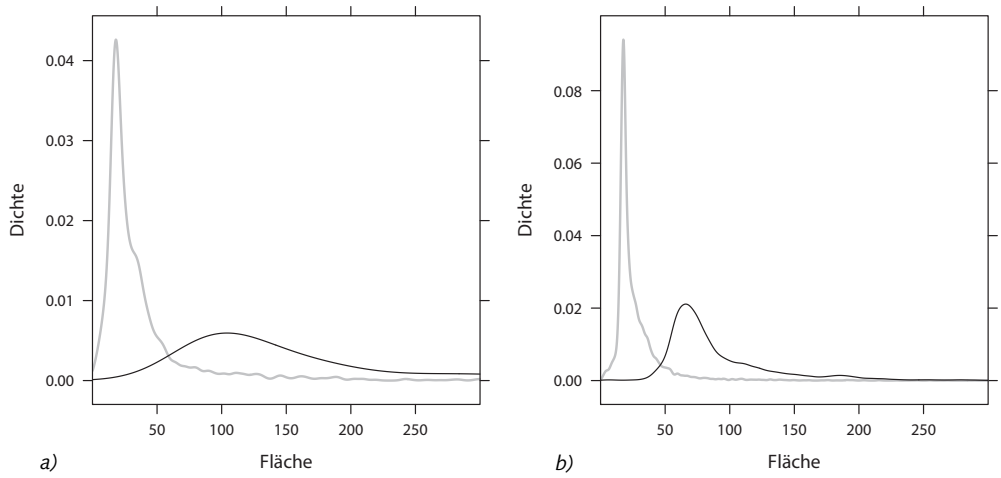

Abb. 8-6: Dichteplot der Klassen „Gebäude mit Wohnnutzung" (schwarz) und „kleine Nebengebäude" (grau) im Vergleich für a) freistehende Gebäude und b) nicht freistehende Gebäude

Die Ergebnisse der ROC-Analyse sind in Tab. 8-7 zusammengefasst. Die Tabelle zeigt die ermittelten Schwellwerte und die verursachten Fehler (TPR – true positive rate, TNR – true negative rate, FNR – false negative rate, FPR – false positive rate) unter Anwendung zweier Methoden. Bei Methode 1 wird als Gütekriterium die Gesamtfehlerrate angewendet, bei Methode 2 ist das Gütekriterium die Fehlerrate unter einer gesetzten Randbedingung.

Tab. 8-7: Ergebnisse der Schwellwertermittlung mit der ROC-Analyse

Methode 1:
Minimiertes Gütekriterium ist Fehlerrate

		Ergebnisse der ROC-Analyse				10-fach kreuzvalidiert	
	Anzahl der Gebäude	Schwellwert	Fehlerrate	TPR (FNR)	TNR (FPR)	Schwellwert Ø (σ)	Fehlerrate Ø (σ)
Freistehende Gebäude	3 858	67,4 m²	8,1 %	97,6 % (2,4 %)	88,9 % (11,1 %)	68,3 (2,9)	7,9 (1,7)
Nichtfreistehende Gebäude	27 535	43,9 m²	5,3 %	98,0 % (2,0 %)	90,0 % (10,0 %)	44,4 (2,0)	5,1 (0,4)

Methode 2:
Minimiertes Gütekriterium ist Fehlerrate
unter der Bedingung, dass FNR < 1 %

		Ergebnisse der ROC-Analyse				10-fach kreuzvalidiert	
	Anzahl der Gebäude	Schwellwert	Fehlerrate	TPR (FNR)	TNR (FPR)	Schwellwert Ø (σ)	Fehlerrate Ø (σ)
Freistehende Gebäude	3 858	56,8 m²	9,3 %	99,0 % (1,0 %)	86,4 % (13,6 %)	58,4 (6,9)	9,2 (2,5)
Nichtfreistehende Gebäude	27 535	39,7 m²	5,8 %	99,0 % (1,0 %)	87,2 % (12,8 %)	39.2 (2,0)	6,0 (1,1)

Mit Methode 1 werden Schwellwerte von 67,4 m² (freistehende Gebäude) und 43,8 m² (nichtfreistehende Gebäude) bestimmt. Die ermittelten Schwellwerte sind nach Meinung des Autors etwas zu hoch. Grund dafür ist, dass bei der Optimierung die Anteile der falsch negativen und falsch positiven Fälle in gleichem Maße eingehen. Die Falsch-Negativ-Rate (FNR) beläuft sich auf 2,4 % (freistehend) bzw. 2,0 % (nichtfreistehend). Dieser Anteil bezieht sich auf Gebäude mit Wohnnutzung, die fälschlicherweise als kleine Nebengebäude klassifiziert wurden.

Mit Methode 2 werden die Schwellwerte unter der Randbedingung einer maximal zulässigen Falsch-Negativ-Rate von 1 % ermittelt. Damit soll dieser Fehler möglichst minimal gehalten werden. Die ROC-Analyse mit Methode 2 ergibt einen Schwellwert von 56,8 m² für *AreaSingleMin* (freistehende Gebäude) sowie 39,7 m² für *AreaMultiMin* (nichtfreistehende Gebäude). Durch Anwendung einer 10-fachen Kreuzvalidierung konnte eine Standardabweichung von 6,9 m² (*AreaSingleMin)* bzw. 2,0 m² (*AreaMultiMin*) ermittelt werden. Die große Streuung bringt eine größere Unsicherheit bei der Schwellwertfindung für die freistehenden Gebäude zum Ausdruck.

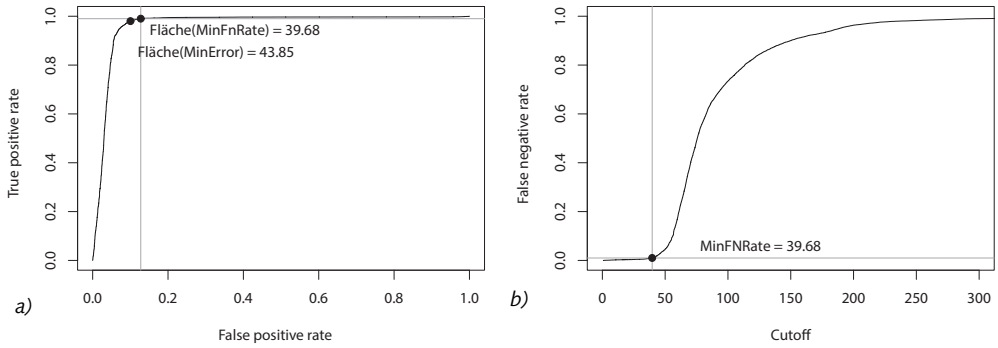

Abb. 8-7: Ermittlung des optimierten Schwellwertes angebauter Nebengebäude: a) ROC-Kurve (links) mit optimalen Schwellwert für Methode 1 (MinFnRate) und Methode 2 (MinError) und b) Kurve der Fehlerrate für Methode 2

Für die Schwellwertermittlung wurde Methode 2 (Abb. 8-7) bevorzugt, mit der unter Zulassung einer minimalen FNR von 1 % möglichst viele Nebengebäude richtig erkannt werden sollen. Die Ergebnisse bestätigen die Vermutung, dass für freistehende kleine Nebengebäude ein kleinerer Schwellwert (39,7 m²) als für angeschlossene kleine Nebengebäude (56,8 m²) nötig ist. Die ermittelten Schwellwerte bilden die Grundlage für die Eliminierung der Nebengebäude im Merkmalsextraktionsprozess für alle Geodatensätze. Die abgeleitete Information hat jedoch noch einen weiteren Nutzen. Die vielen kleinen Nebengebäude können schon vor Anwendung der automatischen Klassifizierung, der Klasse NG zugewiesen werden. Zum Erlernen des Klassifikators können diese ausgelassen werden, was zu einer Reduktion der Objekte und somit zu einem Performancegewinn beim Training führt.

8.3.2 Klassenbedingte Verteilungsdichten der Merkmale

Wie gut eine Klassifizierung möglich ist, hängt von der Verteilung der Merkmalswerte ab. Durch Zusammenfassen der Trainingsdaten nach der Klasse lässt sich eine Wahrscheinlichkeitsdichtefunktion (engl.: *probability density function*, kurz: PDF) eines Merkmals in Bezug zu einer Klasse mithilfe der Kerndichteschätzung darstellen (Bowman & Azzalini, 1997).

Die Abb. 8-8 zeigt die geschätzte Wahrscheinlichkeitsdichte am Beispiel ausgewählter Merkmale des Datensatzes von Krefeld (ALK, Eingangsdatentyp IV). Für die Berechnung wurde das Erweiterungspaket „sm“ unter R verwendet. Die PDF der Gebäudemerkmale variieren dabei sehr stark und können unterschiedliche Formen annehmen. Einige Dichtefunktionen, wie etwa die des Merkmals NUBUILDBU für die freistehenden Ein- und Zweifamilienhäuser (EZFH-EH), besitzen eine annähernde Normalverteilung. Andere zeigen hingegen bimodale Verteilungen, wie z. B. das Merkmal RATIOAREA für die Klasse der Hochhäuser (MFH-HH). Unabhängig von der Form der Verteilung zeigt sich eine starke Überlappung der Klassen hinsichtlich ihrer Merkmalsausprägung. Zwar lassen einzelne Merkmale bereits eine gute Trennung zweier Klassen zu, ob die Merkmale erst in Kombination eine Diskriminierung zweier Klassen ermöglichen ist in dieser Visualisierungsform nicht erkennbar. Die Klassifizierung unter Berücksichtigung vieler Merkmale erfordert demnach ein sehr komplexes Modell.

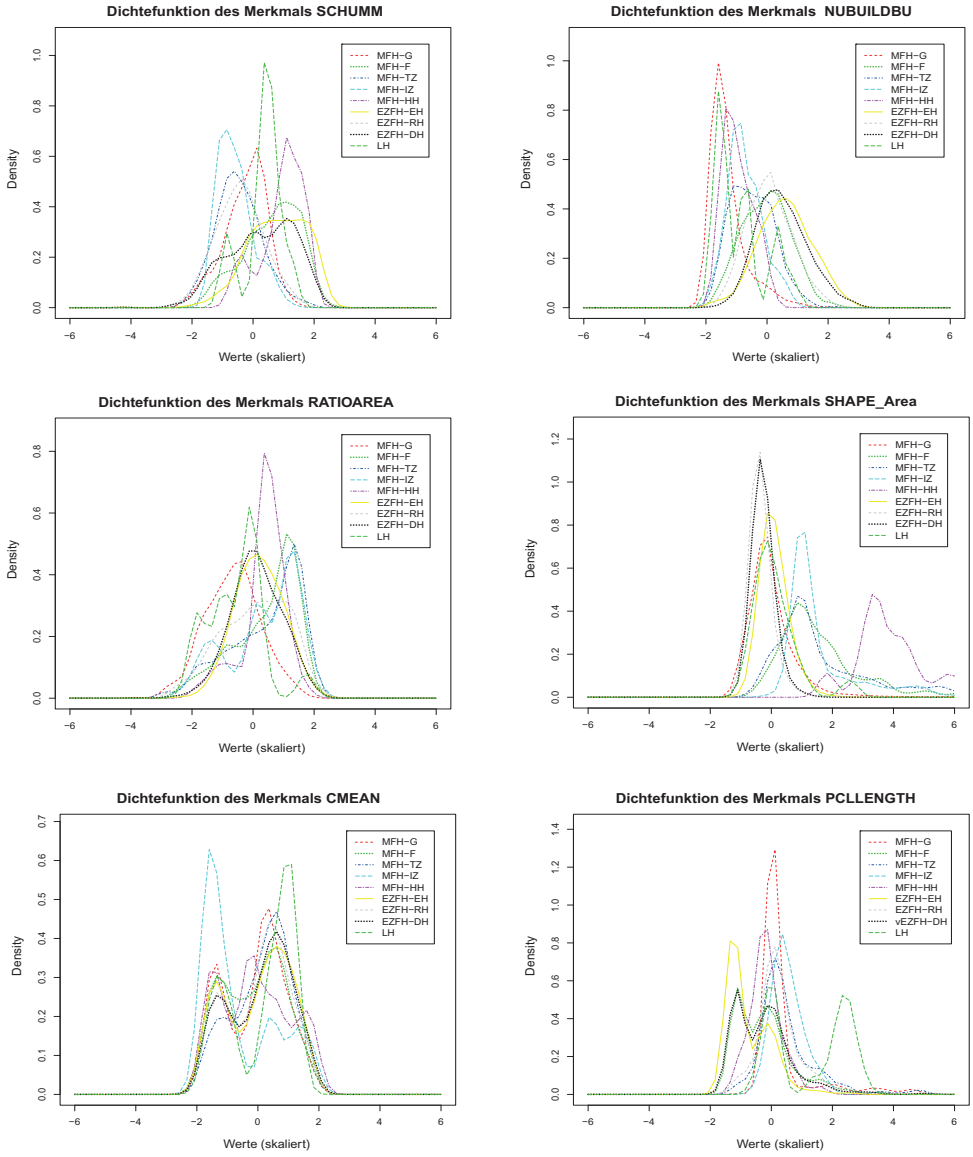

Abb. 8-8: Wahrscheinlichkeitsdichtefunktionen der Wohngebäudeklassen am Beispiel ausgewählter Merkmale. Datengrundlage sind die standardisierten Merkmalsvektoren des Datensatzes von Krefeld (ALK).

8.3.3 Vorverarbeitung und Merkmalsreduktion

Nach Merkmalsberechnung lagen die einzelnen Merkmalswerte in der Gebäudedatenbank vor. Diese Rohdaten wurden zunächst unter R vorverarbeitet (skaliert, transformiert, bereinigt) und mit der Merkmalsreduktion von hochkorrelierten Merkmalen befreit. Die Prozesse der Vorverarbeitung und Merkmalsreduktion wurden für alle Datensätze gleichermaßen angewendet. Die Tab. 8-8 fasst die Anzahl der Merkmale in den einzelnen Verarbeitungsschritten zusammen.

Tab. 8-8: Anzahl der Merkmale vor und nach der Vorverarbeitung und Merkmalsselektion

		Typ I (DTK25-V)				Typ II (DTK25)		Typ III (ATKIS/HU)			Typ IV ALK			Typ V 3D-GS
	Merkmale	Dresden	Halle	Stolpen /Dorf	Krefeld	Krefeld	Halle	Dresden	Halle	Stolpen/Dorf	Dresden	Stolpen/Dorf	Krefeld	Krefeld
Original	metrisch	72	72	72	72	71	71	86	86	86	86	86	86	87
	kategorial (Auspräg.)	1 (6)	1 (6)	1 (4)	1 (4)	1 (5)	1 (6)	1 (6)	1 (6)	1 (4)	2 (6/3)	2 (4/3)	2 (6/3)	3 (6/3/2)
	Gesamtanzahl	73	73	73	73	72	72	87	87	87	88	88	88	90
Vorverarbeitung	metrisch	72	72	72	72	71	71	86	86	86	86	86	86	87
	Dummy	5	5	3	3	4	5	5	5	3	7	5	7	8
	Gesamtanzahl	77	77	75	75	75	76	91	91	89	93	91	93	95
Merkmalsreduktion	unkorreliert: $\|\rho\| \leq 0{,}9$	48	45	42	46	41	53	52	56	49	69	56	64	66
	korreliert: $\|\rho\| > 0{,}9$	29	32	33	29	34	23	39	35	40	24	35	29	29
	Anteil korr. in %	37,7	41,6	44,0	38,7	45,3	30,3	42,9	38,5	44,9	25,8	38,5	31,2	30,5
	PCA-Komponenten *e*	4	5	6	4	7	4	8	7	9	5	8	6	6
	Gesamtanzahl	52	50	48	50	48	57	60	63	58	74	64	70	72
	Reduktion [%]	67,5	64,9	64,0	66,7	64,0	75,0	65,9	69,2	65,2	79,6	70,3	75,3	75,8

In der ersten Zeile ist die Anzahl der originalen Merkmale angegeben. Unmittelbar nach der Merkmalsberechnung stehen 73 (Eingangsdatentypen I und II), 87 (Eingangsdatentyp III), 88 (Eingangsdatentyp IV) und 90 Merkmale für den Eingangsdatentyp V zur Verfügung.

Die zu testenden Klassifikationsverfahren können mit Ausnahme von CART und Random Forest keine kategorialen Merkmale verarbeiten, weshalb diese in metrische Merkmale transformiert wurden. Nach diesem Vorverarbeitungsschritt erhöht sich die Merkmalsanzahl. Nach Transformation des kategorialen Merkmals „ATKIS_OBJ“ mit 6 Ausprägungen entstehen beispielsweise 5 neue binäre Merkmale (Dummy Variablen). Abzüglich des originalen Merkmals erhöht sich die Merkmalsanzahl der Gebäudegrundrisse DTK25-V von ursprünglich 73 auf insgesamt 77. Für den 3D-GS-Datensatz von Krefeld liegen nach der Transformation die meisten Merkmale vor (95 Merkmale). Die große Menge ergibt sich durch Transformation der 3 kategorialen Merkmale mit 6 (ATKIS_OBJ), 3 (GEBNUTZ) und 2 (GEB_TYP)

Merkmalsausprägungen, die nach Umformung zu 8 neuen Dummy-Variablen führen. Im Vorverarbeitungsprozess wurden die Merkmale skaliert und die fehlenden Werte ersetzt (vgl. Kap.7.6).

Die ersten zwei Spalten der Merkmalsreduktion zeigen die Ergebnisse der Korrelationsanalyse. Dabei wird die Merkmalsmenge nach unkorrelierten und korrelierten Merkmalen differenziert. Ein korreliertes Merkmal liegt vor, wenn ein starker Zusammenhang zu mindestens einem anderen Merkmal besteht. Als Schwellwert wurde der Betrag des Korrelationskoeffizienten von $|\rho| > 0{,}9$ gewählt. Der Anteil hoch korrelierter Merkmale an der gesamten definierten Merkmalsmenge beträgt je nach Datensatz zwischen 25,8 % (ALK, Dresden) und 44,9 % (ATKIS, Stolpen/Dorf) bei einem Mittelwert von 37,7 % (mit $\sigma = 6{,}4$) über alle Datensätze. Dieser Anteil ist bei den Merkmalen des Eingangsdatentyps I und II etwas höher als für die definierten Merkmale für Einzelgebäudegrundrisse (Eingangsdatentyp III-V).

Nach Anwendung der Merkmalsreduktion mittels einer Hauptkomponentenanalyse auf die stark korrelierten Merkmalsgruppen werden unter Nutzung des Kaiser-Kriteriums *e* PCA-Komponenten extrahiert. Als Rotationsverfahren wurde die Varimax-Methode verwendet, mit der die Varianz der Ladungen innerhalb der Faktoren maximiert wird. Anschließend erfolgt die Anwendung der als Methode „B4" bekannten Merkmalsselektion von Jolliffe (1972, 1973). Auf Grundlage der rotierten Komponentenladungen werden diejenigen Merkmale selektiert, die mit den jeweiligen *e* Komponenten am höchsten korrelieren. Die Anzahl der extrahierten Komponenten *e* und damit selektierten Merkmale beträgt zwischen 4 (DTK25-V, Dresden) und 9 (ATKIS, Stolpen/Dorf).

Mit der Merkmalsreduktion werden überflüssige hochkorrelierte Merkmale ausgeschlossen, deren Information im Wesentlichen durch eines der anderen Merkmale erfasst wird. Die Ergebnisse können durch Visualisierung des Zusammenhangs der Merkmale dargestellt werden. Die Abb. 8-9 zeigt die in einer Heatmap visualisierte Korrelationsmatrix vor und nach der Merkmalsselektion am Beispiel der Merkmale des Datensatzes von Halle (DTK25-V). Für die Darstellung wurde die Funktion `heatmap.2` des R-Pakets „gplots" (Warnes, 2012) verwendet. An den Reihen ist zusätzlich ein Dendrogramm dargestellt, das durch Anwendung eines hierarchischen Clusteringverfahrens konstruiert wird. Die Merkmale sind in der Heatmap nach den Zeilenmittelwerten sortiert. Mit dieser kombinierten Darstellung von Heatmap und Dendogramm lassen sich Beziehungen und Strukturen im Merkmalsset identifizieren und gegenseitige Ähnlichkeiten ablesen. Im Vergleich der beiden Diagramme wird deutlich, dass mit der Merkmalsreduktion der Anteil der Zellen mit hoher Korrelation (rote und blaue Zellen) deutlich reduziert werden konnte.

Im Ergebnis liegt für jeden Datensatz ein Merkmalsdatensatz vor, dessen Korrelationsmatrix keinen Wert über 0,9 bzw. unter -0,9 annimmt. Dieser bildet die Grundlage für das Trainieren und Testen verschiedener Klassifikationsverfahren. Der Beitrag, den jedes Merkmal bei der Klassifizierung leistet, wird erst nach der Wahl des Klassifikationsverfahrens untersucht (siehe Kap. 8.6).

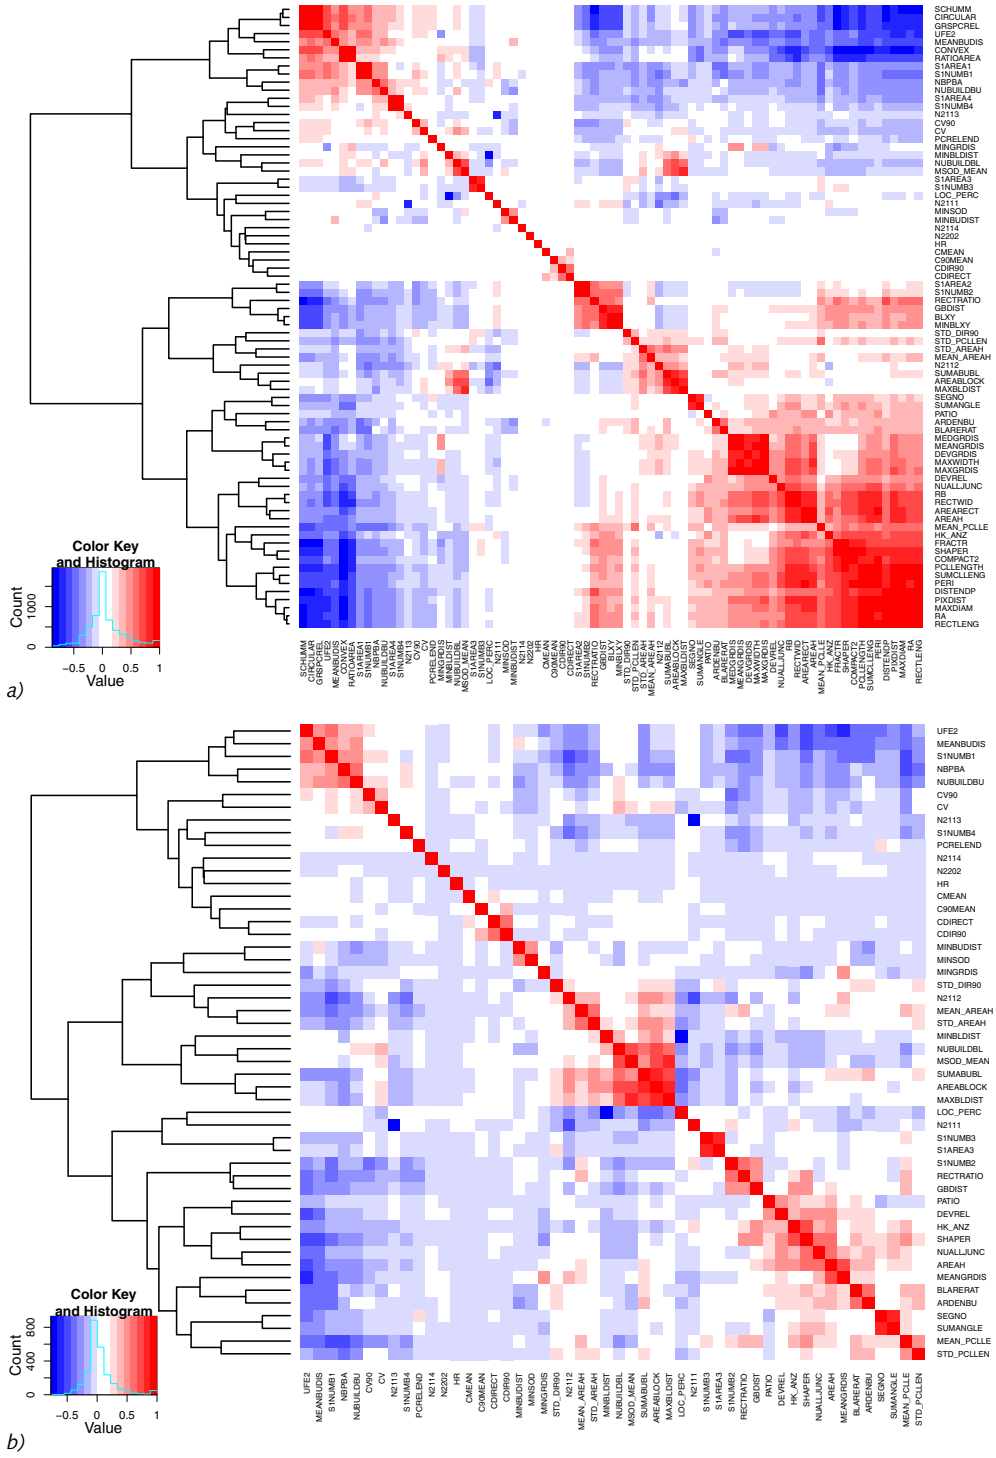

Abb. 8-9: Heatmap-Visualisierung der Korrelation der Merkmale vor (a) und nach der Merkmalsreduktion (b) am Beispiel der Daten von Halle – DTK25-V

8.3.4 Diskussion der Merkmalsberechnung und Merkmalsreduktion

Für jeden Eingangsdatentyp wurde ein umfangreiches Merkmalsset auf verschiedenen räumlichen Ebenen (z. B. Einzelgebäude, Gebäudekomplex, Baublock, Umgebung) erarbeitet. Im Vergleich zu anderen Arbeiten, wie etwa Steiniger et al. (2008) oder Henn (2012), ist die Anzahl der Merkmale dabei deutlich größer. Die Erhebung besonders vieler Merkmale wurde bewusst getätigt, um den zu erlernenden Klassifikatoren so viel wie möglich Informationen bereitzustellen. Dies geschieht dabei ohne Rücksicht auf Effizienz bei der Merkmalsberechnung, da für den praktischen Einsatz des Verfahrens für die kleinräumige Beschreibung der Siedlungsstruktur zunächst keine hohen Ansprüche an die Laufzeit gestellt werden, sondern die Qualität der Klassifikation im Vordergrund steht.

Viele der Merkmale werden mittels Bildverarbeitungsoperatoren unter Nutzung der HALCON-Bibliothek abgeleitet. Aus Vorarbeiten standen entsprechende Programmroutinen zur Verfügung, die für eine Klassifizierung von Gebäuden aus topographischen Rasterkarten angedacht waren (Meinel et al., 2008a). Für die Berechnung dieser Merkmale unter Nutzung von Gebäuden im Vektormodell war eine Umrechnung in ein Raster nötig. Dieser Schritt kann unter Umständen mit einem Informationsverlust einhergehen. Eine direkte Berechnung aus der Vektorgeometrie (u. a. mit Methoden der algorithmischen Geometrie) könnte die Qualität der Merkmale und damit auch die Klassifikationsgenauigkeit erhöhen. Mit der einheitlichen Berechnung aller Merkmale mit ein und derselben Methode ist allerdings eine Vergleichbarkeit der Merkmale von Gebäuden aus Rasterkarten oder Vektordatenmodellen hergestellt.

Zur Identifikation und Befreiung des Merkmalssets von korrelierten Merkmalen wurde ein filterbasiertes Verfahren zur Merkmalsreduktion eingesetzt. Unter Anwendung einer PCA auf die hoch korrelierten Merkmale konnte die Merkmalsanzahl je nach Datensatz um 20 % bis 36 % reduziert werden. Eine Suche nach der optimalen Merkmalsmenge mittels eines Wrapper-Ansatzes (Merkmalsselektion während der Modellselektion) hätte bei der großen Anzahl von Datensätzen mit vielen Trainingsobjekten, Merkmalen und zu testenden Klassifikatoren zu einer enormen Rechenzeit geführt. Die Wahl fiel deshalb auf das „einfachere“ filterbasierte Verfahren. Mit diesem Ansatz besteht jedoch einerseits die Gefahr, Informationen zu verlieren, wenn beispielsweise eines von zwei hoch korrelierten Merkmalen verworfen wurde, dieses jedoch eine kleine, aber wichtige Information beherbergt, die für die Separation einer Klasse wichtig wäre. Andererseits können mit diesem Filteransatz nicht alle irrelevanten Merkmale detektiert werden, da lediglich Korrelation und Varianz eines Merkmals berücksichtigt werden. Um diesem Aspekt zu begegnen, wird für die Bestimmung der optimalen Merkmalsmenge ein Wrapper-Verfahren nach Wahl des besten Klassifikationsverfahrens eingesetzt. Der filterbasierte Ansatz ist deshalb lediglich als Vorverarbeitungsschritt der Modellselektion zu betrachten.

8.4 Ergebnisse der Modellselektion

Mit der Modellselektion werden verschiedene Klassifikationsverfahren anhand der Eingangsdatentypen getestet, um jeweils das beste Verfahren zu bestimmen. Die Ergebnisdarstellung dieses Abschnittes gibt Einblick in das Parameter-Tuning, die Klassifikationsgenauigkeit und die Laufzeit der getesteten Klassifikationsverfahren. Anschließend werden die Ergebnisse bewertet und der beste Klassifikator wird ausgewählt.

8.4.1 Datensätze

Für die Untersuchung wurde repräsentativ für jeden Eingangsdatentyp I bis V ein möglichst großer Datensatz aus der Referenzdatenbank gewählt. Da für keines der Untersuchungsgebiete alle Eingangsdatentypen vorlagen, wurden zunächst die Datensätze des städtischen Untersuchungsgebietes Halle gewählt (Eingangsdatentypen I-III) und für die Eingangsdatentypen IV und V repräsentativ die Datensätze von Dresden (ALK) und Krefeld (3D-Gebäudestrukturen) verwendet. Mit dieser Auswahl steht für jeden Eingangsdatentyp ein größtmöglicher Umfang an Referenzgebäuden bereit (vgl. Tab. 8-9).

Tab. 8-9: Datensätze für die Modellselektion

Eingangsdatentyp	Datensatz	Anzahl Objekte	Anzahl Merkmale
I	DTK25-V (Halle)	14 758	50
II	DTK25 (Halle)	25 610	57
III	ATKIS (Halle)	56 533	63
IV	ALK (Dresden)	37 119	74
V	3D-GS (Krefeld)	44 645	72

Diese Datensätze sind Grundlage für die Validierung verschiedener Klasifikationsverfahren. Aus den Datensätzen wird jeweils eine zufällige Stichprobe gleicher Größe *n* gezogen, damit für jeden Eingangsdatentyp gleich viele Trainings- und Testdaten zur Verfügung stehen. Das soll eine weitestgehende[80] Vergleichbarkeit der Ergebnisse zwischen verschiedenen Eingangsdatentypen erlauben.

8.4.2 Ergebnisse des Modelltunings

Das Tuning ist ein wichtiger Bestandteil des Trainings eines Klassifikators. Der Aufwand hängt dabei von dem betrachteten Klassifikationsverfahren ab und reicht von keinem Tuning, wie bei der LDA, dem Tuning eines Parameters, wie beispielsweise beim KNN-Klassifikator, bis hin zur aufwändigen Suche nach einer optimalen Parameterkombination, wie etwa beim SVM-Klassifikator oder bei Künstlichen Neuronalen Netzen (ANN).

[80] Wegen der ungleichen Klassenverteilung in den Datensätzen ist die Vergleichbarkeit trotz gleicher Trainingsanzahl begrenzt. Auf diesen Aspekt wird in der detaillierten Genauigkeitsbetrachtung nach der Modellselektion im Kap. 8.5.4 näher eingegangen.

Die Bestimmung der besten Parameter(kombination) erfolgt für jede einzelne Lernpartition der äußeren 10-fachen Kreuzvalidierung über eine innere 5-fache Kreuzvalidierung (vgl. Kap. 7.8.4). Ausgehend von einer Lernpartition L_{Train} werden Modelle mit verschiedenen Parameter(kombinationen) über eine 5-fache Kreuzvalidierung getestet und der Klassifikationsfehler bestimmt. Die beste Parameterkombination ergibt sich aus dem Modell mit dem geringsten Klassifikationsfehler. Die besten Parameter werden anschließend verwendet, um das Modell anhand der gesamten Trainingsdatenmenge L_{train} (der ersten Partition) zu trainieren. Die Tab. 8-10 fasst die Ergebnisse des Tunings für die verschiedenen Eingangsdatentypen zusammen.

Tab. 8-10: Optimierte Tuning-Parameter am Beispiel der ersten Partition des Modellselektionsverfahrens mit n=9 000 und Minimierung der Fehlerrate auf Grundlage einer 5-fachen Kreuzvalidierung

		Eingangsdaten				
		Typ I	Typ II	Typ III	Typ IV	Typ V
Methode	Tuning-Parameter	DTK25-V (Halle)	DTK25 (Halle)	ATKIS (Halle)	ALK (Dresden)	3D-GS (Krefeld)
LDA	keine	-	-	-	-	-
kNN	k = {1; 5; 10; 20; 30}	10	30	1	1	10
pLDA	λ= {0,1; 1; 5;10; 15; 20; 25}	5	0,1	5	0,1	0,1
MDA	k_{sub} = {2,3,4,5,6}	3	2	3	5	3
pMDA	keine					
FDA-MARS	β = {1; 2; 3}	2	2	2	2	1
	n_{prune} ={4; 8; 16; 32; 64; 128}	64	32	64	32	64
CART	max_{depth} = {1; 2; … ; 15}	10	13	7	10	14
PVSLDA	keine	-	-	-	-	-
PVSRF	keine	-	-	-	-	-
BAGGING	keine	-	-	-	-	-
DOUBAG	keine	-	-	-	-	-
RF	m_{try} = {h_1; …, h_8} dynamisches Intervall mit h_1 = 2 und h_8 = Anzahl der Merkmale	22	17	10	12	13
SVM	C = {2^1; 2^2; …; 2^{10}}	512	256	16	32	64
	γ = {2^{-15}; 2^{-14}; …; 2^{-6}}	2^{-11}	2^{-11}	2^{-7}	2^{-8}	2^{-9}
ADABOOST	keine	-	-	-	-	-
ANN	s = {9, 10;11;12}	9	11	12	128	12
	d = {0,1; 0,5; 0,9; 1,0; 1,1; 1,2; 1,4; 1,5; 2,0; 4,0; 8,0}	1,4	1,0	1,0	1,1	0,9

Datengrundlage des Tuning-Prozesses ist jeweils eine Stichprobe *n* der Datensätze mit *n*=10 000. Die Ergebnisdarstellung beschränkt sich auf die besten Parameter bzw. Parameterkombinationen der Trainingsdatenmenge L_{train} (mit einer Größe von 9 000) des ersten Durchlaufes der äußeren 10-fachen Kreuzvalidierung. Die besten Tuning-Parameter der anderen Durchläufe können deshalb von den hier dargestellten Ergebnissen abweichen, da dem Tuning-Prozess andere Partitionen (meist andere Daten) zugrundeliegen.

Die Optimierung einer Parameterkombination wird durch eine Grid-Suche im Parameterraum realisiert. Für jeden Parameter wird vorab eine endliche Zahl von Werten angegeben, die getestet werden sollen. Bei einem SVM-Klassifikator mit einem RBF-Kernel sind beispielsweise der Kostenparameter *C* und der Radius der Gauss-Funktion für den Kernel γ gesucht. Durch Festlegung der Werte für die Parameter *C* mit $C = \{2^1; 2^2; \ldots; 2^{10}\}$ und γ mit $\gamma = \{2^{-15}; 2^{-14}; \ldots; 2^{-6}\}$ ergeben sich insgesamt 100 zu testende Parameterkombinationen (siehe Beispiel in Anlage D.1). Beim Tuning mit einer 5-fachen Kreuzvalidierung werden allein 500 SVM-Modelle trainiert und getestet, was bedeutet, dass während der gesamten Modellselektion mit einer 10-fachen Kreuzvalidierung 5 000 SVM-Modelle zu erlernen sind. Eine mehrdimensionale Parametersuche geht deshalb mit einem hohen Bedarf an Rechenzeit einher.

8.4.3 Genauigkeit der getesteten Klassifikatoren

Primäres Kriterium bei der Wahl des Klassifikationsverfahrens ist die Genauigkeit, die mit dem erlernten Klassifikator bei Anwendung auf neue Datensätze erreicht werden kann. In diesem Abschnitt wird die Klassifikationsgenauigkeit der getesteten Klassifikationsverfahren für alle Eingangsdatentypen betrachtet.

8.4.3.1 Klassifikationsgenauigkeit

Die Bewertung der Klassifikationsgenauigkeit erfolgt anhand der 10-fach kreuzvalidierten Klassifikationsgenauigkeit. Die Untersuchung wird für jeden Eingangsdatentyp anhand einer Stichprobe, der Größe n = 10 000, durchgeführt. Während der Kreuzvalidierung wurde die Lerndatenmenge zufällig in 10 Partitionen aufgeteilt, auf deren Grundlage die Klassifikatoren 10 mal mit jeweils 9 000 Objekten trainiert und an 1 000 Objekten getestet wurden.

Die für jeden Klassifikator erreichte, kreuzvalidierte mittlere Klassifikationsgenauigkeit sowie deren Standardabweichung σ der Datensätze sind in Abb. 8-10 und Tab. 8-11 zusammengefasst. Die bei der Untersuchung ermittelten Kappa-Werte sowie weitere deskriptive Kenngrößen (Minimum, Maximum) können dem Anhang D.2 entnommen werden.

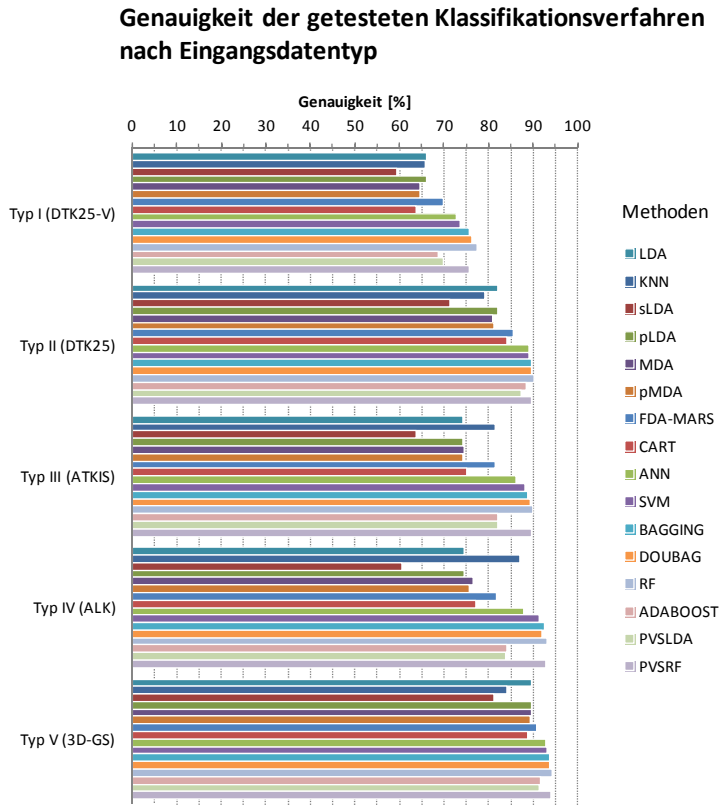

Abb. 8-10: Klassifikationsgenauigkeit der getesteten Klassifikatoren (Abkürzungen der Methoden entsprechend Kap. 7.8.2)

Erwartungsgemäß zeigt sich, dass die nichtlinearen Modelle (z. B. RF, PVSRF, SVM, BAGGING, DOUBAG, ANN) durch eine deutlich höhere Klassifikationsleistung gekennzeichnet sind als die klassischen Verfahren der LDA oder KNN. Die sLDA fällt mit geringster Klassifikationsleistung bei allen Datensätzen auf. Die Klassifikationsleistung der generalisierten linearen Modelle (MDA, pLDA, pMDA) ist im Gegensatz zur LDA nur geringfügig höher. Ausnahme bildet die FDA mit MARS-Modellen, deren Genauigkeit deutlich höher ist. Auch mit dem einfachen KNN-Klassifikator wird für den ALK-Datensatz (Eingangsdatentyp IV) eine beachtliche Güte von 87,5 % erreicht. Die höchste mittlere Klassifikationsgenauigkeit wird für alle betrachteten Datensätze mit dem Random-Forest-Klassifikator erreicht (vgl. Tab. 8-11). Die Klassifikationsgenauigkeit nimmt tendenziell vom Eingangsdatentyp I bis V zu. Betrachtet man die Streuung der gemessenen Genauigkeit im Anhang D.2.3, so ist diese beispielsweise für Gebäudegrundrisse aus der DTK25-V (Eingangsdatentyp I) deutlich größer als für Gebäudegrundrisse aus der ALK.

Tab. 8-11: Kreuzvalidierte Klassifikationsgenauigkeit der getesteten Klassifikationsverfahren

	Datensätze									
	Typ I (DTK25-V)		Typ II (DTK25)		Typ III (ATKIS)		Typ IV (ALK)		Typ V (3D-GS)	
	Genauigkeit [%]		Genauigkeit [%]		Genauigkeit [%]		Genauigkeit [%]		Genauigkeit [%]	
Methoden	Ø	σ	Ø	σ	Ø	σ	Ø	σ	Ø	σ
KNN	65,7	1,3	79,2	1,3	81,6	1,4	87,1	1,4	84,2	1,1
LDA	66,0	1,2	82,0	0,9	74,2	0,9	74,5	1,8	89,7	1,0
MDA	64,7	1,6	81,0	0,9	74,4	0,6	76,5	1,7	89,6	0,6
sLDA	59,5	1,2	71,2	1,1	63,9	1,7	60,5	1,8	81,1	1,4
pLDA	66,0	1,3	82,1	1,0	74,2	1,0	74,4	1,7	89,6	0,9
pMDA	64,6	1,3	81,3	1,0	74,1	0,8	75,7	1,3	89,2	0,7
FDA-MARS	69,7	1,5	85,6	0,9	81,6	1,1	81,9	1,2	90,7	0,9
CART	63,7	1,7	84,2	1,2	75,0	1,7	77,2	1,2	88,6	1,0
ANN	72,8	1,4	88,9	0,9	86,0	1,1	87,9	1,1	92,7	0,6
SVM	73,7	1,3	89,2	1,2	88,3	0,9	91,4	1,0	93,1	0,9
BAGGING	75,6	1,6	89,5	1,2	88,7	0,6	92,4	0,6	93,6	0,5
DOUBAG	76,1	1,5	89,7	1,3	89,3	1,0	92,0	0,6	93,6	0,5
RF	**77,5**	1,5	**90,3**	1,1	**90,0**	1,0	**93,2**	0,7	**94,3**	0,4
ADABOOST	68,8	1,3	88,5	1,1	82,1	1,0	84,1	1,4	91,7	0,7
PVSLDA	69,7	1,7	87,3	1,0	82,2	1,1	83,8	0,9	91,3	0,8
PVSRF	75,7	1,4	89,6	0,8	89,6	1,0	92,8	0,7	94,0	0,5

Das arithmetische Mittel der Klassifikationsgenauigkeit zeigt, dass Random Forest (RF) in allen 5 Fällen die höchste Klassifikationsgenauigkeit besitzt (fett gedruckte Werte in Abb. 8-11). Die Frage, ob die Differenz gegenüber anderen Klassifikatoren groß genug ist, um von einem signifikanten Unterschied zu sprechen, wird mit einem gepaarten T-Test beantwortet. Grundlage dieses statistischen Tests sind die Genauigkeiten der Klassifikatoren aus den 10-Bootstrap-Stichproben der Kreuzvalidierung.

Als Test-Verfahren wird der *Welch-Test* (Welch, 1947) angewendet, bei dem im Gegensatz zu *Student's t-Test* Varianzheterogenität[81] vorliegen darf (Hatzinger et al., 2011). Ergebnis des Tests ist der *p*-Wert als Signifikanzmaß. Dieser gibt mit dem Wert von 0 bis 1 an, wie wahrscheinlich es ist, dass die Ausgangshypothese (Gleichheit der gemessenen Genauigkeit zweier Klassifikatoren) widerlegt werden kann. Der Test erfolgt unter Festlegung eines Signifikanzniveaus $\alpha = 0{,}005$. Die Hypothese wird widerlegt, wenn der *p*-Wert $< \alpha$.

Der Welch-Test wurde angewendet, um die Genauigkeit von Random Forest mit der aller anderer Klassifikatoren zu vergleichen. Die Ergebnisse sind in Tab. 8-12 zusammengefasst. Für die Klassifikationsverfahren mit *p*-Werten $\geq 0{,}005$ (dunkelgrau markierte Zellen) liegt kein signifikanter Unterschied im Vergleich zu Random Forest vor. Für den DTK25-Datensatz (Eingangsdatentyp II) kann für 6 andere Klassifikationsverfahren kein signifikanter Unterschied zu RF festgestellt werden, wohingegen beim 3D-GS-Datensatz (Eingangsdatentyp III) nur der PVSRF-Klassifikator zu vergleichbaren Ergebnissen führt.

[81] Bei einer Varianzheterogenität dürfen die Standardabweichungen in den Gruppen unterschiedlich groß sein.

Tab. 8-12: Ergebnis des einseitigen Welch-Tests. Getestet wurde die Klassifikationsgenauigkeit von RF gegenüber allen anderen Klassifikatoren.

	Typ I	Typ II	Typ III	Typ IV	Typ V
	(DTK25-V)	(DTK25)	(ATKIS)	(ALK)	(3D-GS)
Methode	p-Wert	p-Wert	p-Wert	p-Wert	p-Wert
KNN	3,23E-13	5,72E-14	2,32E-11	1,89E-08	4,87E-12
LDA	4,61E-13	6,28E-13	1,36E-18	1,03E-12	1,26E-08
MDA	6,31E-10	2,01E-13	2,80E-17	2,36E-11	3,45E-12
sLDA	2,36E-16	4,83E-19	2,94E-16	2,60E-15	1,79E-11
pLDA	4,75E-13	7,51E-13	4,76E-18	5,61E-13	3,36E-09
pMDA	6,75E-14	1,79E-13	1,57E-18	3,54E-15	1,99E-11
FDA-MARS	6,85E-10	5,29E-09	1,17E-12	1,87E-13	5,33E-08
CART	2,09E-13	9,99E-10	3,13E-13	1,05E-09	7,69E-10
ANN	1,12E-06	**0,0073**	7,12E-08	1,05E-09	5,45E-06
SVM	1,09E-05	**0,0438**	7,55E-04	2,34E-04	0,0033
BAGGING	**0,0136**	**0,1758**	2,63E-03	**0,0210**	0,0020
DOUBAG	**0,0574**	**0,2900**	**0,1308**	0,0013	0,0026
ADABOOST	0,0000	0,0025	4,69E-13	1,23E-10	1,18E-07
PVSLDA	0,0000	5,87E-06	1,79E-12	2,53E-15	8,98E-08
PVSRF	**0,0122**	**0,1370**	**0,3070**	**0,2761**	**0,2254**

Zusammenfassend kann festgehalten werden, dass mit RF die höchste mittlere Klassifikationsgenauigkeit für alle Eingangsdatentypen gemessen wurde, wobei mit den Methoden PVSRF, BAGGING, DOUBAG, SVM und ANN nicht signifikant schlechtere Ergebnisse erzielt werden können.

8.4.3.2 Variation der Größe der Trainingsmenge

Für das Training eines Klassifikators steht nur eine begrenzte Stichprobe zur Verfügung. Um die Generalisierungsfähigkeit der getesteten Klassifikationsverfahren genauer zu beurteilen, wurde die Klassifikationsgenauigkeit in Abhängigkeit der Trainingsmengengröße untersucht. Hierzu wurden für jeden Eingangsdatentyp Stichproben im Umfang von 625, 1 250, 2 500, 5 000, 10 000 erzeugt und jeweils die Klassifikationsgenauigkeit 10-fach kreuzvalidiert.

In den Diagrammen von Abb. 8-11 sind die Ergebnisse der Untersuchung für jeden Eingangsdatentyp zusammengefasst. Dabei werden die aus dem vorherigen Abschnitt identifizierten, nicht signifikant unterschiedlichen Methoden RF, PVSRF, BAGGING, DOUBAG, SVM, ANN sowie ADABOOST[82] betrachtet und den klassischen Verfahren, wie KNN, CART und LDA, gegenübergestellt. Eine tabellarische Aufbereitung der Ergebnisse ist dem Anhang D.2.4 zu entnehmen.

[82] Der ADABOOST-Algorithmus wurde zusätzlich für diese Darstellung gewählt, da dieser bei kleinen Datensätzen gute Ergebnisse liefert.

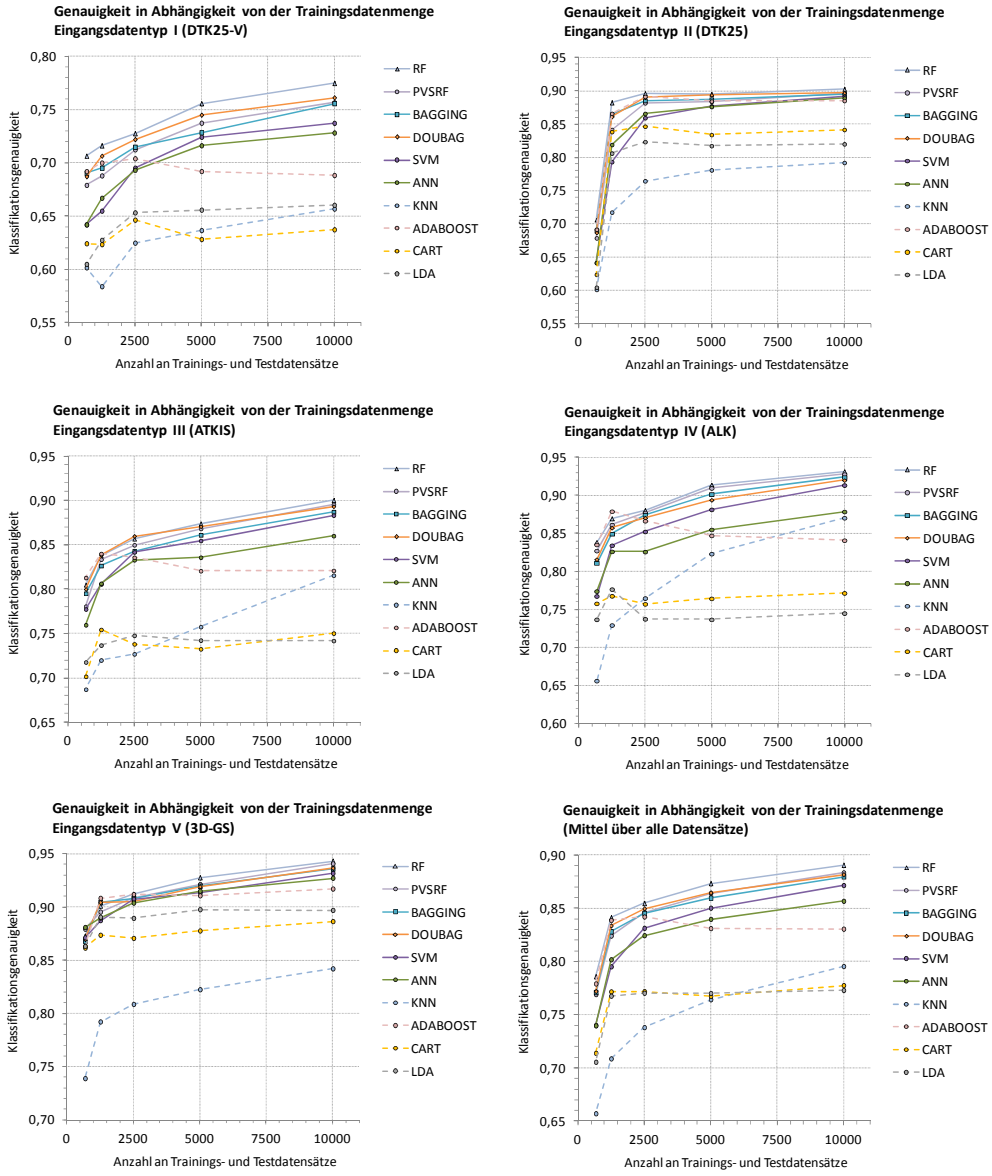

Abb. 8-11: Klassifikationsgenauigkeit in Abhängigkeit des Umfanges der Trainingsdatenmenge

Die meisten Klassifikatoren zeigen bei Zunahme der Trainingsdatenmenge eine kontinuierliche Erhöhung der Klassifikationsgenauigkeit. Die Klassifikatoren RF, PVSRF, SVM, BAGGING, DOUBAG und ANN besitzen bei einer genügend großen Stichprobe ($n > 5\,000$) für alle Eingangsdatentypen die höchste Klassifikationsleistung. Die Klassifikationsgenauigkeit der Methoden KNN, CART und ADABOOST nimmt mit geringerer Trainingsmenge gegenüber den anderen Verfahren im Mittel geringer ab (vgl. Abb. 8-11, Mittel über alle Datensätze). Die Klassifikationsleistung ist weniger von der Menge an Trainingsdaten abhängig. Beim ADABOOST ist mit kleiner werdender Datenmenge sogar eine Verbesserung der Klassifika-

tionsleistung messbar und bei einer sehr kleinen Trainingsdatenmenge von 1 250 und kleiner teilweise der beste Klassifikator zu erreichen.

Aus den Ergebnissen der Untersuchung kann der Rang der Klassifikationsmethoden anhand der gemessenen Genauigkeit bestimmt werden (vgl. Tab. 8-13). Random Forest besitzt für 19 der 25 betrachteten Datensätze die höchste Klassifikationsgenauigkeit. Durch Bildung der Rangsumme über alle Datensätze kann RF eindeutig als bester Klassifikator identifiziert werden, gefolgt von DOUBAG, PVSRF, BAGGING, ADABOOST, SVM und ANN. Die niedrige Rangsumme von ADABOOST ist damit zu erklären, dass dieser bei kleinerer Anzahl von Trainingsobjekten gute Klassifikationsergebnisse erzielt. Darum werden im weiteren Verlauf der Modellselektion nur noch die Methoden RF, DOUBAG, PVSRF, BAGGING, SVM, ANN und ADABOOST betrachtet.

Tab. 8-13: Rang der Klassifikationsverfahren nach der Genauigkeit für verschiedene Datensätze und Bestimmung des besten Klassifikators über die Rangsumme

Datensatz		Methoden															
Typ	n	KNN	LDA	MDA	sLDA	pLDA	pMDA	FDA-MARS	CART	ANN	SVM	BAGGING	DOUBAG	RF	ADABOOST	PVSLDA	PVSRF
Typ I (DTK25-V)	10 000	12	10	13	16	10	14	7	15	6	5	4	2	1	9	7	3
	5 000	14	11	13	16	10	12	7	15	6	5	4	2	1	9	8	3
	2 500	15	10	14	16	11	13	9	12	7	6	3	2	1	5	8	4
	1 250	16	11	13	15	10	14	9	12	6	7	4	2	1	3	8	5
	675	13	12	16	15	11	14	9	10	6	6	3	4	1	2	8	5
Typ II (DTK25)	10 000	15	12	14	16	11	13	9	10	6	5	4	2	1	7	8	3
	5 000	15	11	14	16	12	13	9	10	7	6	3	2	1	4	8	5
	2 500	15	11	13	16	11	14	9	10	7	8	4	3	1	2	6	5
	1 250	16	11	14	15	10	13	9	6	8	12	3	4	1	2	7	5
	675	13	12	16	15	11	14	9	10	6	6	3	4	1	2	8	5
Typ III (ATKIS)	10 000	10	14	12	16	13	15	9	11	6	5	4	3	1	8	7	2
	5 000	10	12	14	16	11	13	9	15	6	5	4	2	1	8	7	3
	2 500	14	11	15	16	10	13	9	12	7	5	4	1	2	6	8	3
	1 250	14	12	15	16	11	13	8	10	6	7	5	2	3	1	8	4
	675	15	12	13	16	10	11	9	14	7	6	4	3	2	1	8	5
Typ IV (ALK)	10 000	7	14	12	16	15	13	10	11	6	5	3	4	1	8	9	2
	5 000	9	15	12	16	14	13	10	11	6	5	3	4	1	7	8	2
	2 500	10	14	12	16	15	13	9	11	8	6	3	4	1	5	7	2
	1 250	15	12	10	16	13	11	8	14	9	6	5	4	2	1	7	3
	675	15	13	7	16	14	11	6	10	7	9	5	4	1	2	12	3
Typ V (3D-GS)	10 000	15	10	11	16	12	13	9	14	6	5	4	3	1	7	8	2
	5 000	15	9	12	16	11	13	8	14	5	6	3	4	1	7	10	2
	2 500	15	10	12	16	9	13	8	14	7	5	4	6	1	2	11	3
	1 250	16	8	14	15	7	11	5	13	9	10	2	2	4	1	12	6
	675	16	10	14	15	4	13	7	11	1	4	7	6	3	9	12	2
Rangsumme		340	287	325	394	276	323	210	295	161	155	95	79	35	118	210	87
Rang der Rangsumme		15	11	14	16	10	13	8	12	7	6	4	2	1	5	8	3

8.4.4 Evaluierung der Laufzeit

Das zweite Kriterium bei der Modellauswahl ist die Effizienz des eingesetzten Klassifikationsverfahrens. In der Informatik wird dazu die Big O Notation verwendet, um die Komplexität eines Algorithmus, gemessen an der Anzahl nötiger Operationen für jedes neue Objekt, anzugeben. In dieser Arbeit wird die Effizienz anhand der Laufzeit betrachtet, die zum Tuning, Trainieren und Testen der Klassifikatoren benötigt wird. Anhand der gemessenen Laufzeit der Prozesse soll an realen Daten empirisch untersucht werden, wie unterschiedlich effizient die jeweiligen Klassifikatoren bzw. deren Algorithmen arbeiten.

Die Laufzeitmessung wurde mithilfe des R-Zusatzpaketes „microbenchmark" (Mersmann, 2011) durchgeführt. Mit diesem ist es möglich, die verstrichene Zeit zwischen dem Start und der Fertigstellung einer Operation in Nanosekunden zu messen. Die Laufzeiteffizienz wird allerdings nicht alleine durch die Eigenschaft des Algorithmus und deren Implementation bestimmt, sie hängt auch von der zugrundeliegenden Hardware und der Größe der verarbeiteten Datenmenge ab.

Der Vergleich der Laufzeit verschiedener Klassifikationsverfahren wurde am Beispiel des Referenzdatensatzes Halle (ATKIS) getestet. Hierzu wurden jeweils in 5-facher Wiederholung Stichproben der Größen n = {500, 1 000, 1 500, 2 000, 2 500, 3 000, 3 500, 4 000, 4 500, 5 000, 6 000, 7 000, 8 000, 9 000, 10 000} aus dem Datensatz gezogen und zufällig in Trainings- (50 %) und Testdaten (50 %) aufgeteilt. Die Simulation wurde unter Windows XP (32bit) an einem Intel® Core™ 2 Quad CPU Q8300 mit 2,50GHz und verfügbaren 3,43 GB RAM durchgeführt. Die jeweiligen Prozesse beanspruchen dabei nur eine CPU. Die Tab. 8-14 und Abb. 8-12 fassen die Ergebnisse der Laufzeitmessung des Trainings und Anwendens für die getesteten Klassifikationsverfahren zusammen.

Tab. 8-14: Gemessene Laufzeit der getesteten Klassifikatoren aus 10 Wiederholungen bei n=6 000 (Test- und Trainingsdaten jeweils 3.000) unter Verwendung des Datensatzes Halle (ATKIS)

	Mittlere gemessene Laufzeit für 5 000 Trainingsobjekte und 5 000 Testobjekte		
Klassifikator	Training mit Tuning	Training ohne Tuning	Anwenden des Klassifikators
ANN	≈ 5 h 30 min	≈ 2 min	< 1 sec
SVM	≈ 4 h	≈ 1 min	≈ 25 sec
BAGGING*	≈ 12 min	≈ 12 min	≈ 2 sec
DOUBAG*	≈ 11 min	≈ 11 min	≈ 9 sec
RF	≈ 12 min	≈ 15 sec	< 1 sec
ADABOOST*	≈ 22 min	≈ 22 min	≈ 30 sec
PVSRF*	≈ 2 min	≈ 2 min	≈ 20 sec

* kein Training

Die Gesamttrainingszeit setzt sich aus dem Tuning und dem Training zusammen, da das Tuning der modellspezifischen Parameter über eine innere 5-fache Kreuzvalidierung während des Trainings erfolgt (vgl. Kap. 7.8.4). Die Laufzeitmessung für das Training ohne Tuning gibt hingegen an, wie viel Rechenzeit für den Modellaufbau benötigt wird, wenn die optimalen Tuning-Parameter bereits bekannt sind. Die geringsten Zeitressourcen werden für das Anwenden, also der Klassifizierung neuer Daten, benötigt.

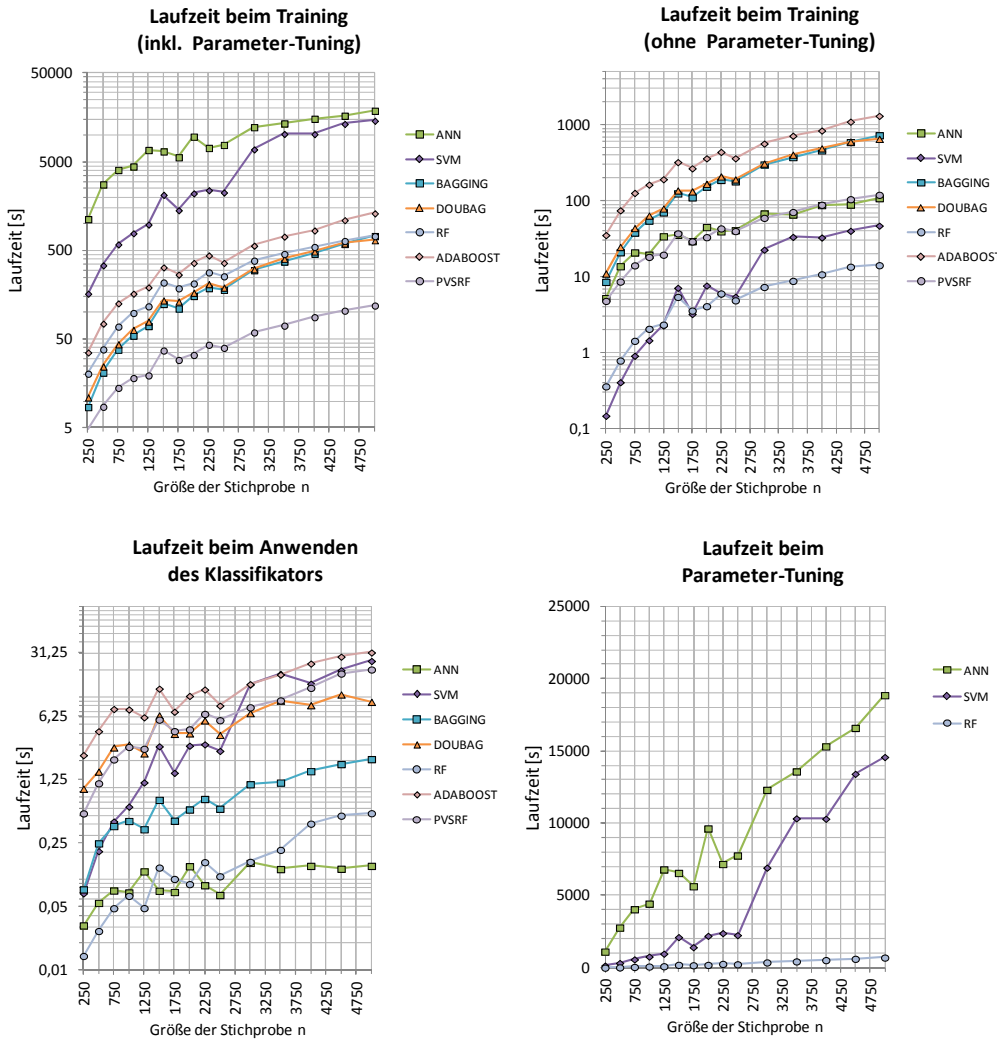

Abb. 8-12: Ergebnisse der Laufzeitmessung ausgewählter Methoden (logarithmisch skalierte Vertikalachse)

Den größten zeitlichen Aufwand verursacht das Tuning der Parameter. Methoden, für die mehrere Parameter über eine zeitaufwändige Grid-Suche ermittelt werden müssen, zeigen besonders lange Gesamttrainingszeiten. Dies betrifft besonders die Künstlichen Neuronalen Netze (ANN) und die Support Vector Machines (SVM). Das Bagging und das Double-Bagging benötigt zum Training gegenüber dem Random Forest-Algorithmus mehr als doppelt so viel Rechenzeit. Die zufällige Merkmalsauswahl bei der Konstruktion der einzelnen Bäume mit Random Forest macht gegenüber dem Bagging weniger Rechenoperationen nötig (vgl. Chan & Paelinckx, 2008). Die gemessene längere Rechenzeit beim ADABOOST-Algorithmus gegenüber Random Forest-Algorithmus wurde auch in der Arbeit von Banfield et al. (2007) festgestellt. Auch wenn die reine Anwendung des Klassifikators für alle Klassifikatoren keine großen Rechenressourcen beanspruchen, so ist diese beim Random Forest und dem ANN-Klassifikator am geringsten.

8.4.5 Wahl des besten Klassifikators

Für die Modellselektion war es nötig, einen guten Kompromiss zwischen der Generalisierungsfähigkeit (gemessen an der kreuzvalidierten Genauigkeit) und dem Trainingsaufwand (gemessen an der Laufzeit) zu finden. Die Wahl fällt dabei auf den Random Forest-Algorithmus (RF) als bestes Klassifikationsverfahren, da dieser durch eine hohe Klassifikationsgenauigkeit und kurze Laufzeit beim Training gekennzeichnet ist.

Mit RF wurde bei großer Trainingsdatenmenge die höchste Klassifikationsgenauigkeit erzielt. Im Vergleich zu den Methoden DOUBAG, PVSRF, BAGGING, SVM und ANN unterscheidet sich dieser jedoch nicht bei allen betrachteten Datensätzen signifikant. Mit ADABOOST wurde bei kleiner Trainingsdatenmenge sogar eine leicht höhere Genauigkeit an einigen Datensätzen gemessen. Die Verfahren RF, DOUBAG, PVSRF, BAGGING, SVM, ANN und ADABOOST besitzen demnach eine vergleichbar hohe Klassifikationsgenauigkeit. Ausschlaggebend für die Wahl von Random Forest war die deutlich geringere Trainingszeit gegenüber den anderen Verfahren.

8.4.6 Diskussion der Modellselektion

Die Ergebnisse des Vergleiches verschiedener Klassifikationsverfahren bestätigen die Annahme, dass nichtlineare Klassifikatoren besser geeignet sind als lineare Verfahren. In den Untersuchungen von Steiniger et al. (2008) besaßen lineare und nichtlineare Verfahren eine annähernd gleiche Klassifikationsleistung. Es wird daher vermutet, dass die im Vergleich zu Steiniger et al. (2008) größere Anzahl an Klassen, Merkmalen und Trainingsobjekten zu einem schwierigeren Klassifikationsproblem führen, das nur mit komplexeren Modellen gelöst werden kann.

Random Forest wurde mit der Modellselektion als bester Klassifikator für alle Eingangsdaten identifiziert (Kap. 0). Bedingung ist, dass eine ausreichend große Trainingsdatenmenge von mindestens ≈ 2 500 zur Verfügung steht. Zwischen den Ensemble-Klassifikatoren wurden nur geringe Unterschiede in der Klassifikationsgenauigkeit festgestellt. Zu dieser Erkenntnis kamen auch Banfield et al. (2007), die RF, BAGGING und ADABOOST durch Anwendung an verschiedenen Datensätzen unterschiedlicher Disziplinen untersuchten.

Der RF-Algorithmus besitzt neben der hohen Generalisierungsfähigkeit und Effizienz weitere Vorteile. So kann bereits während des Trainings der Klassifikationsfehler realistisch über die OOB-Menge abgeschätzt werden. Ein weiterer Vorteil ist, dass eine interne Merkmalsselektion (Klassifikator mit eingebetteter Merkmalsselektion) stattfindet und keine vorgeschaltete Merkmalsreduktion nötig ist. Mit der Möglichkeit der Messung der Merkmalswichtigkeit bietet das Verfahren auch ein nützliches Werkzeug zur Identifizierung unnötiger Merkmale, die bei einer praktischen Anwendung nicht mehr erhoben werden müssen. Gleichzeitig ist der Klassifikator robust gegenüber Rauschen und Ausreißern und kann wie beim CART-Algorithmus direkt kategoriale Merkmale verarbeiten. Ensemble-Klassifikatoren haben allgemein den Vorteil, dass diese gut parallelisierbar sind. Eine effiziente Implementierung von RF für die Verarbeitung Mehrkernprozessoren ist bereits mit dem Zusatzpaket „random jungle" gegeben (Schwarz et al., 2010).

Ein Nachteil von Random Forest und allgemein von Ensemble-Techniken ist die geringe Transparenz des erlernten Klassifikators. Das Modell besteht aus Hunderten von Entscheidungsbäumen und stellt aufgrund der Komplexität gegenüber dem Nutzer eine „Black-Box" dar. Beim einzelnen Entscheidungsbaum, wie etwa beim CART-Algorithmus, können hingegen Zusammenhänge und Strukturen im Modell sichtbar gemacht werden. Ein weiterer Nachteil ist, dass das Training eines Random Forest durch Zufallsprozesse gesteuert ist und ein erlerntes Modell nicht reproduzierbar ist (nicht deterministisches Verfahren). Beim wiederholten Training mit ein und denselben Daten werden zwar sehr ähnliche, aber nicht identische Ergebnisse erzeugt. Dieser Nachteil betrifft jedoch auch alle anderen Verfahren, die mit zufälligen Stichproben (DOUBAG, BAGGING, PVSRF, ADABOOST) oder durch Initialisierung von Gewichten mit Zufallszahlen arbeiten, wie beim ANN-Klassifikator. SVM sind zwar von Natur aus deterministisch, die Suche nach der optimalen Parameterkombination über eine Grid-Suche verlangt bei der inneren Kreuzvalidierung jedoch genauso das Ziehen zufälliger Bootstrap-Stichproben, weshalb die SVM in diesem Fall nur ohne Tuning reproduzierbar sind[83].

8.5 Ergebnisse der Modellvalidierung

Mit der Modellselektion wurde Random Forest als bester Klassifikator identifiziert. Eine detailliertere Genauigkeitsanalyse soll durch Trainieren und Testen des Klassifikators anhand der zur Verfügung stehenden Referenzdaten klären, welchen Einfluss die Untersuchungsgebiete (städtisch, kleinstädtisch, ländlich) und die Wahl des Eingangsdatentyps auf die Genauigkeit der Klassifizierung haben. Die Bewertung erfolgt dabei klassenspezifisch unter Auswertung von Konfusionsmatrizen. Zunächst soll jedoch kurz auf die Besonderheiten von Random Forest eingegangen werden.

[83] Es sei an dieser Stelle erwähnt, dass ein deterministisches Tuning möglich ist, in dem beispielsweise anstatt der k-fachen Kreuzvalidierung eine Leave-One-Out-Kreuzvalidierung angewendet wird, die jedoch bei großer Trainingsdatenmenge zu einem gewaltigen Rechenaufwand führt.

8.5.1 Besonderheiten von Random Forest

Random Forest zeichnet sich durch eine eingebettete Merkmalsselektion aus, kann kategoriale Merkmale verarbeiten und benötigt keine Skalierung der Daten (Breiman, 2001). Das hat den Vorteil, dass die Datensätze ohne Anwendung der Vorverarbeitungsschritte (Merkmalsreduktion, Datentransformation und Datenskalierung) genutzt werden können. Auf eine Imputation fehlender Werte kann jedoch nicht verzichtet werden.

Eine weitere Besonderheit von Random Forest ist, dass dieser mit der internen Out-Of-Bag-Menge (OOB-Menge) eine Möglichkeit bietet, den wahren Klassifikationsfehler auf Grundlage der gegebenen Trainingsdatenmenge realistisch abzuschätzen (Breiman, 1996b, 2001). Um dies anhand der Gebäudedaten zu überprüfen, wurde die an der OOB-Menge abgeschätzte Klassifikationsgenauigkeit mit der 10-fach kreuzvalidierten Klassifikationsgenauigkeit verglichen.

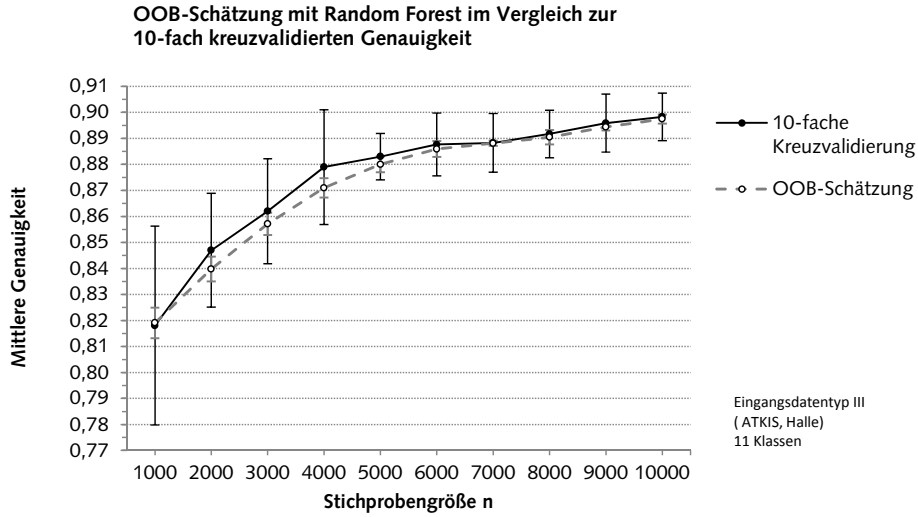

Abb. 8-13: Schätzung der Klassifikationsgenauigkeit über die OOB-Menge im Vergleich zur 10-fach kreuzvalidierten Klassifikationsgenauigkeit am Beispiel der ATKIS-Gebäudegrundrisse von Halle

Im Diagramm (Abb. 8-13) ist die aus der OOB-Menge geschätzte Klassifikationsgenauigkeit der 10-fach kreuzvalidierten Klassifikationsgenauigkeit für den Datensatz von Halle (ATKIS) gegenübergestellt. Für die Untersuchung wurden verschiedene Stichprobengrößen n mit n={1 000, 2 000 ... 10 000} verwendet. Die OOB-Schätzung ist etwas geringer und liefert ein realistisches, nicht zu optimistisches Maß zur Beurteilung des erlernten Klassifikators. Es bietet sich daher an, dieses vom Algorithmus mitgelieferte Gütemaß zum Parameter-Tuning einzusetzen, was eine innere 5-fache Kreuzvalidierung erübrigt und Rechenzeit beim Trainieren einspart. Die klassenspezifische Genauigkeitsuntersuchung des nächsten Abschnittes erfolgt jedoch weiterhin auf Grundlage einer 10-fachen Kreuzvalidierung.

8.5.2 Klassengenauigkeit nach Untersuchungsgebieten

In diesem Abschnitt werden die Ergebnisse der Klassifizierung mit Random Forest für alle zur Verfügung stehenden Referenzdatensätze betrachtet. Um die Objektanzahl zu reduzieren, wurden die kleinen Nebengebäude aus den Referenzdatensätzen entfernt, da diese nicht im Fokus der Untersuchung standen und aufgrund der Vielzahl die Gesamtklassifikationsgenauigkeit verzerren. Die Objektanzahl kann deshalb von den Angaben zur Referenzdatenbank in Tab. 8-5 abweichen. Die Genauigkeit wurde für alle Datensätze über eine 10-fache Kreuzvalidierung abgeschätzt. Zum Tuning des Parameters „mtry" wurde jedoch ein Gütemaß eingesetzt, das über die interne OOB-Menge abgeschätzt wurde (vgl. Kap 8.5.1).

Die ermittelte Gesamtgenauigkeit für alle Datensätze ist in Tab. 8-15 zusammengefasst. Es lässt sich von Eingangsdatentyp I bis hin zu V eine stetige Zunahme der Genauigkeit erkennen. Für die Kleinstadt Stolpen und die dörflichen Gebiete wird eine geringere Genauigkeit beobachtet, die jedoch im Zusammenhang mit der deutlich geringeren Anzahl an Trainingsobjekten stehen kann.

Tab. 8-15: Aus 10-facher Kreuzvalidierung ermittelte Gesamtgenauigkeit (OA – Overall Accuracy, κ – Kappa) und Standardabweichung σ in Klammern für alle betrachteten Datensätze

			städtisch			kleinstädisch	dörflich
			Dresden	Halle	Krefeld	Stolpen	Dörfl. Gebiete
Eingangsdaten	Typ I DTK25-V	n	18 180	14 750	640	230	730
		OA in %	**78,90** (±0,67)	**76,62** (±1,27)	**76, 56** (±6,91)	**67,39** (±11,46)	**56,44** (±7,04)
		κ	0,73 (±0,01)	0,71 (±0,02)	0,71 (±0,09)	0,57 (±0,15)	0,42 (±0,10)
	Typ II DTK25	n		25 610	6470		
		OA in %		**88,85** (±0,44)	**78,21** (±2,16)		
		κ		0,83 (±0,01)	0,73 (±0,03)		
	Typ III ATKIS	n	19 370	39 630	26 040	370	920
		OA in %	**90,42** (±0,62)	**91,84** (±0,45)	**93,64** (±0,51)	**72,16** (±9,01)	**62,39** (±3,41)
		κ	0,88 (±0,01)	0,90 (±0,01)	0,92 (±0,01)	0,65 (±0,12)	0,50 (±0,04)
	Typ IV ALK	n	19 590		26 040	430	1 030
		OA in %	**94,28** (±0,39)		**94,34** (±0,33)	**84,19** (±4,46)	**78,74** (±5,09)
		κ	0,93 (±0,00)		0,93 (±0,00)	0,81 (±0,05)	0,72 (±0,07)
	Typ V 3D-GS	n			26 040		
		OA in %			**94,85** (±0,28)		
		κ			0,94 (±0,00)		

Die höchste Genauigkeit konnte für die 3D-Gebäudestrukturen von Krefeld mit 94,9 % korrekt klassifizierten Gebäuden erreicht werden. Bei ausreichend großer Trainingsdatenmenge wurde im städtischen Gebiet für die ALK-Gebäude eine Genauigkeit von über 94 % (Dresden, Krefeld) und für die Gebäude des Eingangsdatentyps III (ATKIS) mindestens über 90 % (Dresden, Halle, Krefeld) gemessen. Die Standardabweichung σzeigt die Messunsicherheit, die sich aus den zufälligen Stichproben der Kreuzvalidierung ergeben. Diese ist für die kleinen Datensätze erwartungsgemäß größer als für die Datensätze mit großer Gebäudeanzahl. Die Betrachtung der Gesamtgenauigkeit ist allein nicht ausreichend, um die Qualität einer Klassifikation zu beurteilen. Darum wurden Konfusionsmatrizen (vgl. Kap. 3.5.4) abgeleitet, die durch Vergleich der klassifizierten Gebäudemenge mit den Referenzdaten berechnet werden können. Für jede der 10 Bootstrab-Stichproben wurde eine Konfusionsmatrix errechnet und anschließend aufsummiert.

Die aufsummierte Konfusionsmatrix am Beispiel der Daten von Krefeld zeigt Abb. 8-14. Die fett gedruckten Werte der Hauptdiagonalen repräsentieren die richtig klassifizierten Gebäude. Die anderen Werte zeigen falsch klassifizierte Objekte an. An ihnen lässt sich nachvollziehen, wie viele Objekte welcher Klasse falsch zugeordnet wurden. Aus der Konfusionsmatrix kann unmittelbar die Gesamtgenauigkeit (Overall Accuracy, OA) abgeleitet werden, die durch den Prozentanteil der korrekt klassifizierten Gebäude (Summe der Diagonalen) zur Gesamtzahl aller betrachteten Gebäude definiert ist.

		Referenzdaten												
		MFH-G	MFH-F	MFH-TZ	MFH-IZ	MFH-HH	EFZH-EH	EFZH-DH	EFZH-RH	LH	WGL	ÖG	Summe	UA[%]
Klassifikation	MFH-G	**3147**	12	8	9	0	4	4	30	1	140	7	3362	93,60
	MFH-F	8	**236**	13	1	1	19	5	3	0	11	0	297	79,46
	MFH-TZ	3	31	**848**	18	4	3	0	8	0	6	1	922	91,97
	MFH-IZ	3	4	5	**225**	1	0	0	0	0	0	0	238	94,54
	MFH-HH	0	0	0	0	**32**	0	0	0	0	0	0	32	100,00
	EFZH-EH	1	46	2	0	0	**3168**	45	13	5	96	4	3380	93,73
	EFZH-DH	9	9	17	0	0	58	**4711**	30	2	50	0	4886	96,42
	EFZH-RH	20	13	14	0	0	10	22	**6403**	1	30	1	6514	98,30
	LH	0	0	0	0	0	0	0	0	**34**	0	0	34	100,00
	WGL	160	21	5	2	1	127	84	52	8	**5525**	12	5997	92,13
	ÖG	3	0	0	0	0	3	0	0	0	1	**371**	378	98,15
	Summe	3354	372	912	255	39	3392	4871	6539	51	5859	396	26040	
	PA[%]	93,83	63,44	92,98	88,24	82,05	93,40	96,72	97,92	66,67	94,30	93,69		

Ø Overall Accuracy (σ): 94,85 % (±0,28)
Ø Cohen´s Kappa κ (σ): 0,94 (±0,00)

Abb. 8-14: Konfusionsmatrix am Beispiel der Klassifizierung des Datensatzes für Krefeld (3D-GS)

Gütemaße zur Beschreibung der klassenspezifischen Genauigkeit sind die in Prozent angegebene Herstellergenauigkeit (Producer´s Accuracy, kurz PA) und die Nutzergenauigkeit (User's Accuracy, kurz: UA). Die PA beschreibt den Prozentanteil der Referenzdaten einer Klasse, die mit den klassifizierten Gebäuden übereinstimmen. Sie ergibt sich aus der Anzahl richtig klassifizierter Gebäude einer Klasse und der dazugehörigen Spaltensumme. Die UA gibt den Prozentanteil der klassifizierten Gebäude einer Klasse wieder, die mit den Referenzgebäuden übereinstimmen. Sie ist durch das Verhältnis des Wertes der richtig klassifizierten Gebäude einer Klasse (fett dargestellt) zur Zeilensumme bestimmt. Die Konfusionsmatrizen aller betrachteten Datensätze sind Anhang 0 zu entnehmen.

In Abb. 8-15 ist die klassenspezifische Genauigkeit mit den Gütemaßen PA und UA in Diagrammen für alle Datensätze dargestellt. Für die städtischen Untersuchungsgebiete konnten bei Verwendung des Eingangsdatentyps III bis V für die Mehrheit der Klassen Herstellergenauigkeiten von über 90 % erzielt werden. Insbesondere die Klassen der Wohnbebauung MFH-G, MFH-TZ, MFH-IZ, EFZH-EH, EFZH-DH, EFZH-RH und die Nichtwohnnutzungsklassen WGL und ÖG können sehr gut vorhergesagt werden. Eine geringere Genauigkeit ist für die häufig unterbesetzten Klassen der freistehenden Mehrfamilienhäuser (MFH-F), Ländlichen Häuser (LH) und Hochhäuser (MFH-HH) zu beobachten. Bei der Verwendung von Gebäuden aus topographischen Karten (Eingangsdatentyp I und II) ist die Genauigkeit über alle Klassen hinweg deutlich geringer.

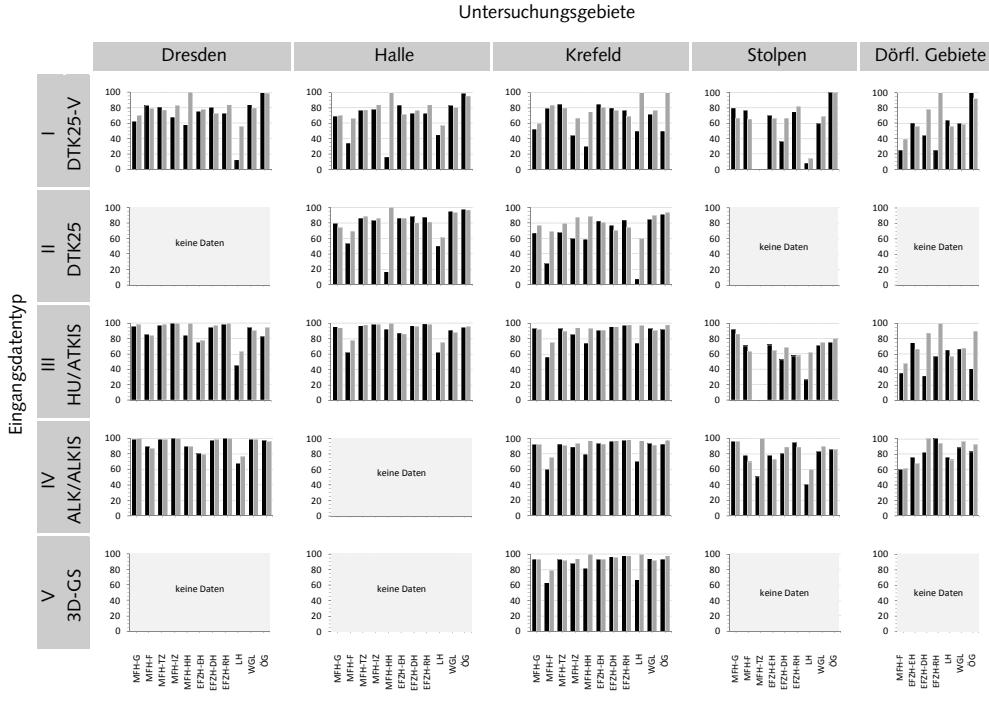

Abb. 8-15: Klassenspezifische Genauigkeit für alle Datensätze. In den Diagrammen sind die Producer´s Accuracy (PA) schwarz und die User´s Accuracy (UA) grau dargestellt.

8.5.3 Bewertung der Untersuchungsgebiete

Für eine Bewertung werden Güteklassen festgelegt, mit denen die quantitativ gemessene Genauigkeit auch in Worte gefasst werden kann:

- Sehr gut (≥ 90 %)
- Gut (80 % bis < 90 %)
- Befriedigend (70 % bis < 80 %)
- Ausreichend (60 % bis < 70 %)
- Mangelhaft (50 % bis < 60 %)
- Unbefriedigend (< 50 %)

Im Folgenden werden die Ergebnisse der klassenspezifischen Genauigkeit anhand der einzelnen Untersuchungsgebiete diskutiert. Wenn nicht anders angegeben, beziehen sich die Angaben vornehmlich auf die Herstellergenauigkeit.

8.5.3.1 Dresden

In Dresden wird mit den Gebäuden der DTK25-V nur eine befriedigende Klassifikationsgenauigkeit von 78,9 % erreicht. Die Klassen MFH-F, MFH-TZ. EZFH-DH, WGL und ÖG können gut (> 80 %) und die Klassen EZFH-EH, EZFH-RH mit befriedigender Klassifikationsleistung (> 70 %) vorhergesagt werden. Die Klassifikationsgenauigkeit der Klassen MFH-G und MFH-IZ ist nur 62,4 % bzw. 68,0 %. Von den 45 Hochhäusern (MFH-HH) werden nur knapp 60 % erkannt, da diese den Klassen MFH-F und WGL falsch zugeordnet sind. Eine Erkennung der ländlichen Hausformen (LH) ist mit der DTK25-V nicht möglich. Die dort abgebildeten Gebäude werden häufig anderen Klassen zugeordnet. Offenbar weisen Gebäude der Klasse LH nur selten eindeutig charakteristische Eigenschaften auf, die sich von denen der Klassen MFH-F, EZFH-EH, EZFH-DH oder WGL unterscheiden.

Unter Verwendung des Eingangsdatentyps III (ATKIS) ist die Gesamtgenauigkeit mit 90,4 % sehr gut. Für 6 Klassen können sehr gute und für 3 Klassen gute Herstellergenauigkeiten erreicht werden. Eine Herausforderung stellt jedoch auch bei Nutzung dieser Datengrundlage die Klasse LH dar, die nur mit ungenügender Genauigkeit klassifiziert werden kann. Eine nur befriedigende Erkennungsleistung der EZFH-EH (74,8 %) ist einer Verwechslung mit den freistehenden Mehrfamilienhäusern (MFH-F) geschuldet, die sich in Größe und Form offenbar nicht immer eindeutig unterscheiden. Allein 15 % der EZFH-EH gehen durch diese Fehlzuordnung verloren.

Bei der Verwendung der ALK (Typ IV) kann eine Gesamtgenauigkeit von über 94 % erreicht werden. Insgesamt werden 7 Klassen sehr gut und 3 Klassen gut klassifiziert. Der Anteil an Verwechslungen von Wohnnutzungs- mit Nichtwohnnutzungsklassen kann mit dem Nutzungsattribut der ALK deutlich reduziert werden. Die Klasse LH konnte jedoch auch bei Verwendung der Gebäude aus der ALK nur in 68,0 % der Fälle richtig klassifiziert werden. Die geringe Nutzergenauigkeit von 77,0 % deutet darauf hin, dass ein gewisser Anteil von Gebäuden anderer Klassen fälschlicherweise die Klasse LH zugeordnet bekommt (ca. 23 % aller LH).

8.5.3.2 Halle

Für die Stadt Halle wird bei der Nutzung von Gebäuden aus der DTK25-V (Eingangsdatentyp I) eine mit Dresden vergleichbare Gesamtgenauigkeit von 76,6 % erreicht. Jedoch können lediglich die freistehenden Einfamilienhäuser (EZFH-EH) und die Nichtwohnnutzungsklassen WGL und ÖG mit einer guten bis sehr guten Genauigkeit klassifiziert werden. Für die Wohnnutzungsklassen der Zeilenbebauung (MFH-TZ, MFH-IZ) sowie die Doppel- und Reihenhäuser (EZFH-DH, EZFH-RH) ist die Genauigkeit mit über 70 % nur befriedigend. Eine ungenügende Erkennungsleistung muss bei der Nutzung der Gebäude aus der DTK25-V für die freistehenden Mehrfamilienhäuser (MFH-F), die Hochhäuser (MFH-HH) und die Ländlichen Hausformen (LH) festgestellt werden. Die Klassen MFH-F und LH werden in großem Umfang fälschlicherweise der Klasse der EZFH-EH zugeordnet. Die geringe Erkennungsleistung für Hochhäuser in Halle (nur 2 der 12 Hochhäuser wurden richtig klassifiziert) ist dadurch begründet, dass in den Kartenblättern der DTK25-V keine Umringsignatur für Hochhäuser existiert, weshalb im Merkmal HR keine Informationen gespeichert sind. Da offenbar kein weiteres diskriminierendes Merkmal vorliegt, wurde mit dem erlernten Klassifikator die Klasse WGL zugeordnet, da Hochhäuser eine größere Gebäudegrundfläche besitzen.

Mit den aus den ATKIS-Daten simulierten Gebäuden der DTK25[84] (Eingangsdatentyp II) kann für die Nichtwohnnutzungsklassen WGL und ÖG eine sehr gute Herstellergenauigkeit von über 90 % und für die Klassen MFH-TZ, MFH-IZ, EZFH-EH, EZFH-DH, EZFH-RH eine gute Genauigkeit von über 80 % erreicht werden. Die fehlende Generalisierung der Gebäude in der DTK25 in Sachsen-Anhalt führt offensichtlich zu einer höheren Klassifikationsgüte im Vergleich zur DTK25-V. Nicht unproblematisch ist jedoch die schwache Erkennungsleistung für die Klassen MFH-F, MFH-HH und LH, die auf die bereits für die DTK25-V diskutierten Gründe zurückzuführen sind.

Eine deutliche Verbesserung der Genauigkeit kann für Halle mit den ATKIS-Gebäuden (Eingangsdatentyp III) erzielt werden. Insgesamt werden 8 der 11 Klassen mit einer Herstellergenauigkeit von über 90 % klassifiziert. Auch die Hochhäuser des Geschosswohnungsbaus (MFH-HH) können in Halle wegen ihrer typischen Größe, Form und der geringen Dichte in der Umgebung im Vergleich zur DTK25 sehr gut klassifiziert werden. Die Erkennungsleistung für die Klassen LH und MFH-F kann mit den ATKIS-Gebäudedaten zwar auf über 60 % erhöht werden, für eine praktische Anwendung ohne manuelle Korrektur ist die Genauigkeit jedoch zu gering.

8.5.3.3 Krefeld

Für Krefeld lagen nur kleine Referenzdatensätze für die Eingangsdatentypen I und II vor, da aufgrund der Lageversätze und der stärkeren Gebäudegeneralisierung nur für wenige Gebäude der DTK25-V (640) und DTK25 (6470) Klassenlabels eindeutig zugeordnet werden

[84] Eine visuelle Begutachtung der Kartenblätter zeigte, dass Gebäude in der DTK25 von Sachsen-Anhalt ohne Generalisierung übernommen werden.

konnten. Die Gesamtklassifikation ist mit 76,6 % (DTK25-V) und 78,2 % (DTK25) zunächst vergleichbar mit den Ergebnissen für Dresden und Halle. Die klassenspezifische Genauigkeit zeigt jedoch, dass lediglich die stark besetzten Klassen EZFH-EH und MFH-TZ (DTK25-V) bzw. EZFH-EH und WGL (DTK25) mit einer Genauigkeit von über 80 % erkannt werden können. Alle anderen Klassen können aufgrund der geringen Trainingsmenge nur befriedigend bis ungenügend klassifiziert werden. Die Ergebnisse der zwei Datensätze sind deshalb nur bedingt aussagefähig, weshalb der Fokus der Ergebnisdarstellung auf den 3D-Gebäudestrukturen (Typ V) und den daraus simulierten Daten der ALK (Typ IV) und Hausumringen (Typ III) liegen sollte. Für diese drei Eingangsdatentypen stehen die gleiche Anzahl an Lerndaten zur Verfügung und sie sind daher sehr gut miteinander vergleichbar.

Für Hausumringe kann bereits eine hohe Klassifikationsgenauigkeit von 93,6 % gemessen werden. Für 7 der 11 Klassen ist die PA über 90 %. Nur für die Klassen MFH-F und LH ist die PA mit 56,5 % bzw. 74,5 % deutlich geringer. Wie auch für Dresden und Halle werden viele MFH-F versehentlich als EZFH-EH klassifiziert.

Mit der simulierten ALK kann die OA um ein knappes Prozent auf 94,3 % gesteigert werden, da das Attribut zur Gebäudefunktion nützliche Informationen zur Unterscheidung von Wohn- und Nichtwohnnutzung liefert. Die meisten Klassen erfahren dabei eine leichte Erhöhung der Herstellergenauigkeit gegenüber den Hausumringen.

Mit den 3D-Gebäudestrukturen (Typ V) konnte eine OA von 94,9 % erzielt werden. Mit Ausnahme der Klassen MFH-F und LH konnte für alle Klassen eine gute, oft sogar sehr gute Klassifikationsgenauigkeit gemessen werden. Gegenüber der ALK ist die PA aufgrund der zusätzlichen Höheninformation für alle Klassen höher. Ausnahme bilden die LH, deren Klassifikationsgenauigkeit gegenüber der ALK etwas geringer ausfällt. Ursache ist möglicherweise eine Messunsicherheit, da nur eine geringe Fallanzahl für die Klasse LH vorliegt (vgl. Kap. 8.5.4).

8.5.3.4 Stolpen

Für die Kleinstadt Stolpen beschränkt sich die Klassifizierung auf die Zuordnung in 9 Klassen, da die Klassen MFH-HH und MFH-IZ nicht vorkommen. Die Gesamtgenauigkeit von 67,4 % ist gegenüber den anderen städtischen Datensätzen bei Verwendung der DTK25-V deutlich geringer und unterliegt einer sehr großen Varianz. Grund dafür ist die geringe Anzahl an Trainings- und Testdaten (insgesamt nur 230 Gebäuderegionen). Das hat auch zur Folge, dass einige Klassen in den Trainingsdaten extrem unterbesetzt sind (z. B. nur 3 Gebäude der Klasse MFH-TZ) und beim Erlernen von Random Forest nicht genügend berücksichtigt werden. Für den Großteil der Klassen kann nur eine Klassifikationsgenauigkeit von 60 % bis 80 % erreicht werden. Viele Gebäude der Klasse LH werden fälschlicher Weise den freistehenden Mehrfamilienhäusern (MFH-F) zugeordnet. Die geringe Klassifikationsgenauigkeit der Doppelhäuser (MFH-DH) ist durch eine ungenügende Zuordnung der Hauskoordinaten zu einigen Gebäuden und damit fehlerhaften Merkmalen begründet.

Bei der Verwendung der ATKIS-Gebäude wird eine OA von 72,1 % erreicht. Die geschlossene Mehrfamilienhausbebauung (MFH-G) konnte mit 92,5 % sehr gut erkannt werden. Die Herstellergenauigkeit der Klassen MFH-TZ, EZFH-DH, EZFH-RH und LH ist jedoch ge-

genüber den anderen Klassen geringer als 70 %. Eine Betrachtung der Doppelhäuser zeigte, dass diese in vielen Fällen als zusammenhängende Gebäuderegion modelliert sind.

Die Klassifizierung der ALK-Gebäude erfolgte mit einer Gesamtgenauigkeit von 84,2 %. Gegenüber den ATKIS-Gebäuden konnte die Herstellergenauigkeit für jede Klasse erhöht werden. Eine deutliche Verbesserung von ca. 30 % erfuhren die Doppelhäuser und Reihenhäuser, die in der ALK als Einzelgebäude modelliert sind. Eine Verbesserung von über 10 % konnte auch für die Nichtwohnnutzungsklassen WGL und ÖG festgestellt werden, da mit den Gebäuden der ALK wichtige semantische Informationen mitgeliefert werden.

8.5.3.5 Ländliche Gebiete

Für die Genauigkeitsanalyse wurden die drei ländlichen Gebiete Diera-Zehren, Crostwitz und Rechenberg-Bienenmühle zusammengefasst, damit die Anzahl der Trainingsdaten ausreichend groß ist. Die Gesamtgenauigkeit der Klassifizierung in 7 Klassen ist für die Gebäude aus der DTK25-V mit 56,4 % mangelhaft. Die drei Klassen MFH-F, MFH-EH und LH werden aufgrund ihrer ähnlichen Morphologie sehr häufig verwechselt. Die Reihenhäuser (MFH-RH) sind im Gebäudedatensatz mit insgesamt nur 4 Objekten unterrepräsentiert. Zusammen mit den Doppelhäusern (MFH-DH) leidet diese Klasse an einer sehr geringen Erkennungsrate durch Datenrauschen. Starke Lageversätze führen zu einer Fehlzuordnung der Hauskoordinaten und somit zu verfälschten Merkmalen der Anzahl der Hauskoordinaten pro Gebäuderegion.

Eine geringe Verbesserung der Genauigkeit konnte durch Verwendung der ATKIS-Gebäude festgestellt werden. Die zusammengefasst modellierten Gebäude in Sachsen führen jedoch dazu, dass für keine der Klassen eine Herstellergenauigkeit von über 80 % erreicht werden konnte.

Unter Verwendung der ALK konnten 78,7 % der Gebäude richtig klassifiziert werden. Trotz höchster Genauigkeit für dieses Untersuchungsgebiet, ist die Genauigkeit im Vergleich zu den städtischen Untersuchungsgebieten um ca. 15 Prozentpunkte geringer. Die Nichtwohnnutzungsklassen (WGL, ÖG) und die Doppelhäuser (EZFH-DH) können mit über 80 %, die Klassen EZFH-EH, LH mit über 70 % klassifiziert werden. Wegen der höheren geometrischen Genauigkeit und Einzelgebäudemodellierung konnten alle Reihenhäuser richtig klassifiziert werden. Die MFH-F erfährt mit 59,7 % die geringste Klassifikationsgenauigkeit, da diese häufig mit den LH verwechselt werden.

8.5.4 Einfluss des Eingangsdatentyps auf die Klassengenauigkeit

Im letzten Abschnitt wurden die Genauigkeiten diskutiert, die bei Verwendung aller zur Verfügung stehenden Referenzgebäude ermittelt werden konnten. Da die Anzahl der Trainingsobjekte und die Gruppengrößen stark variieren, sind die Ergebnisse zwar in sich konsistent, jedoch untereinander nur bedingt vergleichbar. Um möglichst valide Aussagen über den Einfluss des verwendeten Eingangsdatentyps auf die klassenspezifische Genauigkeit machen zu können, werden in einer Untersuchung die zu vergleichenden Datensätze hinsichtlich ihrer Trainingsdatenmenge und Klassenverteilung vereinheitlicht. Die Erkennungsleistung der Klassen mit kleiner Gruppengröße kann beispielsweise mit Random Forest erhöht

werden, wenn zum Training gleiche Gruppengrößen verwendet werden (Chen et al., 2004), da die OOB-Fehlerrate, dem entscheidenden Gütemaß beim Trainieren von RF, durch alle Klassen mit gleicher Gewichtung bestimmt wird.

Grundlage folgender Untersuchung ist der Datensatz von Krefeld, da mit diesem, ausgehend von den 3D-Gebäudestrukturen (Eingangsdatentyp V), die Eingangstypen III und IV sehr gut simuliert werden können. Da für Krefeld keine Referenzdaten für die DTK25-V und DTK25 in gleichem Umfang zugrunde lagen, wurden die Datensätze von Halle (Eingangsdatentyp I und II) für die Untersuchung gewählt. Zur Erzeugung der Trainingsdatenmenge wurden aus den Datensätzen stratifizierte Stichproben im Umfang von jeweils 250 Objekten pro Klasse (ohne Zurücklegen) gezogen. Vorab wurden jedoch 1/3 der Daten weggelegt, die dem Aufbau des Testdatensatzes dienen. Für die Klassen MFH-IZ, MFH-HH und LH standen jedoch weniger als 250 Objekte zum Training zur Verfügung, weshalb die Objektanzahl dieser Klassen geringer ist (vgl. Tab. 8-16). Aus der Gesamtheit aller nicht zum Training verwendeten Datenobjekte wurde der Testdatensatz durch zufälliges Ziehen von 250 Objekten (mit Zurücklegen) aufgebaut. Erst mit gleicher Klassenverteilung in den Testdaten ist die Nutzergenauigkeit der Klassen zwischen den Eingangsdatentypen vergleichbar. Bei Anwendung auf echte Daten ist die Nutzergenauigkeit jedoch stark von der zugrundeliegenden Klassenverteilung abhängig. Die hier betrachtete Nutzergenauigkeit dient demnach lediglich dem relativen Vergleich der Klassen und spiegelt nicht die wahre Nutzergenauigkeit wider, die bei Anwendung des Modells auf das gesamte Untersuchungsgebiet zu erwarten wäre.

Tab. 8-16: Stichprobengrößen der Trainings- und Testdaten (Train/Test) für die Bestimmung der klassenspezifischen Genauigkeit

	Typ I (Halle)		Typ II (Halle)		Typ III (Krefeld)		Typ IV (Krefeld)		Typ V (Krefeld)	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
MFH-G	250	250	250	250	250	250	250	250	250	250
MFH-F	250	250	250	250	248	250	248	250	248	250
MFH-TZ	250	250	250	250	250	250	250	250	250	250
MFH-IZ	250	250	250	250	170	250	170	250	170	250
MFH-HH	8	250	8	250	26	250	26	250	26	250
EFZH-EH	250	250	250	250	250	250	250	250	250	250
EFZH-DH	250	250	250	250	250	250	250	250	250	250
EFZH-RH	250	250	250	250	250	250	250	250	250	250
LH	250	250	250	250	34	250	34	250	34	250
WGL	250	250	250	250	250	250	250	250	250	250
ÖG	250	250	250	250	250	250	250	250	250	250
Summe	2 508	2 750	2 508	2 750	2 228	2 750	2 228	2 750	2 228	2 750

Anhand der Trainingsdaten wird ein Klassifikator mittels Random Forest erlernt und über den unabhängigen Testdatensatz durch Berechnung der Konfusionsmatrix validiert. Der Ablauf (Ziehen von Zufallsstichproben, Trainieren, Testen) wird in einer Simulation 10-fach wiederholt, um Erkenntnisse über die Streuung zu erlangen.

Dabei zeigt sich, dass bei Verwendung von Trainingsdaten mit gleichen Klassenanteilen die Klassengenauigkeit unterbesetzter Klassen (z. B. LH, MFH-F) im Vergleich zur Verwendung aller zu Verfügung stehenden Daten erhöht werden. Gleichzeitig fällt die Klassengenauigkeit der in den Referenzdaten hochbesetzten Klassen (z. B. WGL, EZFH-EH) geringer aus, da diesen beim Training eine geringere Bedeutung beigemessen wird. Mit den Fehlerbalken wird die statistische Unsicherheit (2-fache Standardabweichung) angezeigt, die für die Klasse MFH-HH besonders hoch ist, da für diese beim Training zwangsweise weniger Objekte zur Verfügung standen. In Abb. 8-16 sowie detailliert in Anlage E.2, ist die Produzenten- und Nutzergenauigkeit der Klassen differenziert nach dem Eingangsdatentyp dargestellt.

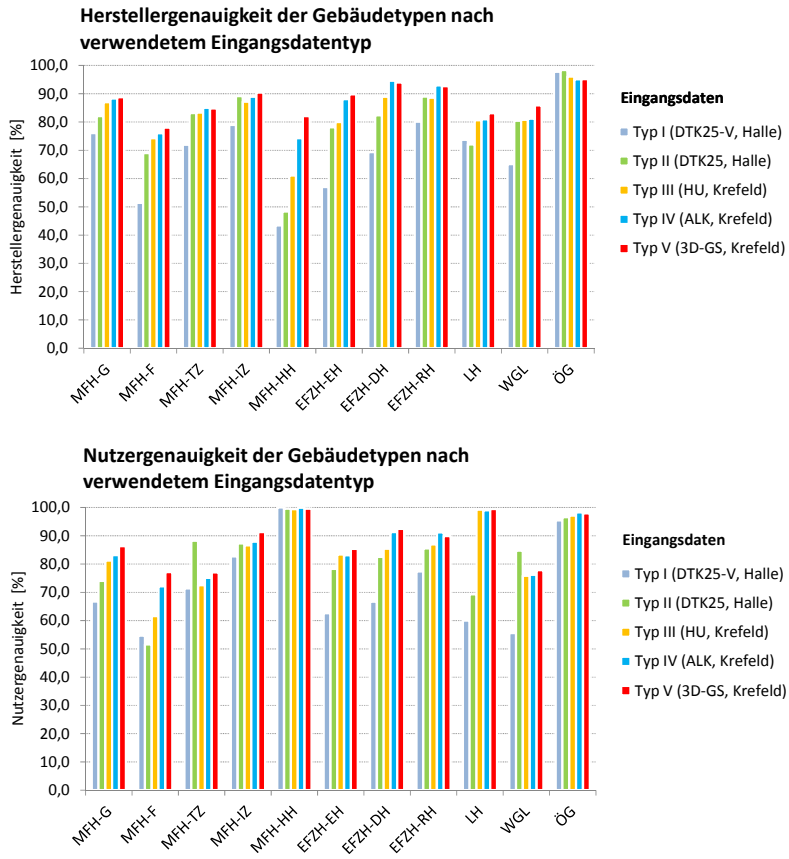

Abb. 8-16: Hersteller- und Nutzergenauigkeit nach Eingangsdatentyp

Die ermittelte Gesamtgenauigkeit dieser Untersuchung ist 69,5 % (Eingangsdatentyp I), 79,3 % (Eingangsdatentyp II), 82,5 % (Eingangsdatentyp III), 86,0 % (Eingangsdatentyp IV) und 87,7 % (Eingangsdatentyp V). Für Eingangsdatentyp I werden 6 von 11 Klassen mit einer PA von über 70 % erfasst. Für den Eingangsdatentyp II konnten hingegen 7 der 11 Klassen mit einer PA von über 80 % klassifiziert werden. Bei der Verwendung der vektorbasierten Gebäudegrundrisse wurden 8 (Eingangsdatentyp III), 9 (Eingangsdatentyp IV) und 10 (Eingangsdatentyp V) der 11 Klassen mit über 80 % klassifiziert, wobei für Typ V sogar 4 Klassen mit über 90 % erfasst sind. Es lässt sich festhalten, dass bei Nutzung der vektorbasierten Gebäudegrundrisse (Eingangsdatentyp III-V) keine der 11 Klassen mit einer geringeren PA oder UA als 70 % klassifiziert wurde[85]. Für Eingangsdatentyp I-II ist die Herstellergenauigkeit nicht für alle, jedoch für den Großteil der Klassen über 70 %.

In der Tendenz nimmt die Herstellergenauigkeit und in den meisten Fällen auch die Nutzergenauigkeit für alle Klassen von Eingangsdatentyp I bis V zu. Bei gleicher Trainingsdatengröße ist die Genauigkeit der Klassen MFH-HH, EZFH-EH, EZFH-DH und MFH-F bei Nutzung von Einzelgebäuden, wie den Hausumringen oder den ALK-Gebäuden (Eingangsdatentyp II, IV und V), höher als bei der Verwendung von Gebäudegrundrissen aus topographischen Karten. Die Klassengenauigkeit der Nichtwohngebäudeklassen WGL und ÖG unterscheidet sich nur in geringem Maße. Der positive Einfluss der zusätzlichen Nutzungsinformation bei Eingangsdatentyp IV und V ist in dieser Untersuchung kaum messbar. Auch das zusätzliche Attribut der 3D-Gebäudestrukturen liefert in diesem Fall nur einen geringen Beitrag zur Verbesserung der Klassengenauigkeit. Der in den Daten sichtbare Bruch zwischen Typ I/II und Typ III/IV/V (insbesondere die Nutzergenauigkeit von MFH-TZ) ist offenbar dem Fakt geschuldet, dass unterschiedliche Untersuchungsgebiete zugrundeliegen. Eine Vergleichbarkeit der Städte kann offenbar allein durch Homogenisierung der Trainingsmenge und Klassenverteilung nicht erreicht werden.

Es sei abschließend bemerkt, dass zwei gleich große Gruppengrößen des Eingangsdatentyps I/II und III/IV/V lediglich aus statistischer Sicht identisch sind. Bei einer räumlichen Betrachtung beschreibt ein Trainingsdatensatz für Eingangsdatentyp I/II wegen der Gebäuderegion-Repräsentation eine deutlich größere Menge von Gebäuden als ein Trainingsdatensatz des Eingangsdatentyps III/IV/V. Dem Effekt könnte bei einer weiteren Untersuchung mit einem gebäudetypischen Faktor begegnet werden, der durch die mittlere Anzahl der Einzelgebäude pro Gebäuderegion bestimmt ist und sich empirisch aus dem Verhältnis der Objektanzahl der ATKIS-Gebäude zur Objektanzahl der DTK25-Gebäude ermitteln ließe. Dieser Aspekt wurde in dieser Arbeit nicht weiter vertieft.

[85] Mit Ausnahme der Klasse MFH-HH und MFH-F für den Eingangsdatentyp III mit einer PA von 61,1 % (MFH-HH) und einer UA von 61,6 % (MFH-F).

8.5.5 Einfluss der Anzahl der Trainingsobjekte nach Eingangsdatentyp

Über eine Simulation mit verschiedenen Größen von Trainingsdaten sollen Erkenntnisse über die Mindestanzahl von Trainingsobjekten pro Klasse gewonnen werden. Bei einer manuellen Erhebung von Trainingsdaten ist die Klassenverteilung der Grundgesamtheit meist unbekannt, so dass zunächst von gleich großen Gruppengrößen ausgegangen werden kann.

Als Datengrundlage der Untersuchung dient der Datensatz von ATKIS-Halle, da dieser einerseits eine gesamtstädtische Kartierung mit insgesamt 40 809 Referenzobjekten darstellt und andererseits für alle Klassen eine ausreichend große Anzahl an Trainingsobjekten zur Verfügung steht. Mit dieser Grundlage wurde der Einfluss der Klassengenauigkeit für verschiedene Größen von Trainingsdaten (bis zu 750 Objekte pro Klasse) untersucht.

Das Diagramm in Abb. 8-17 zeigt die Herstellergenauigkeit der Klassen in Abhängigkeit der Anzahl der zur Verfügung stehenden Trainingsmenge, die durch 10-fache Wiederholung an der Gesamtheit der nicht am Training beteiligten Daten gemessen wurde. Für jeden Durchlauf wurden die Trainingsdaten durch Ziehen einer Bootstrap-Stichprobe im Umfang von n mit n={50, 100 ...,750} erzeugt. Hochhäuser fanden an dieser Stelle keine Beachtung und wurden mit der Klasse MFH-F vereint, da deren Anzahl für diese Untersuchung zu gering wäre. Es zeigt sich, dass die Herstellergenauigkeit für alle Klassen mit der Anzahl an Trainingsobjekten stetig zunimmt und logarithmisch gegen eine Herstellergenauigkeit konvergiert, die man bei unendlicher Trainingsdatenmenge erreichen würde. Die Varianz (2σ der Gesamtgenauigkeit dargestellt mit Fehlerbalken) nimmt ab einer Trainingsdatenmenge von ca. 250 und mehr sichtbar ab. Ab einer Anzahl von 500 Trainingsobjekten pro Klasse wird für alle Klassen eine Herstellergenauigkeit von über 70 % erreicht, ab 750 bereits 75 %. Der Genauigkeitszuwachs nimmt jedoch mit größerer Trainingsdatenmenge ab.

Mit Herstellung gleicher Gruppengrößen in den Trainingsdaten werden die bisher unterbesetzten Klassen, wie z. B. LH oder MFH-F, deutlich besser klassifiziert als bei der Nutzung aller Trainingsdaten (vgl. Kap. 8.5.2). Ein Verlust an Genauigkeit ist jedoch für die im Untersuchungsgebiet hoch besetzten Klassen EZFH-EH und WGL zu verzeichnen. Diese werden bei Verwendung einer Trainingsdatenmenge mit Klassenverteilung der Grundgesamtheit deutlich besser klassifiziert.

Konkrete Aussagen zu klassenspezifischen Mindestgrößen der Trainingsdatenmenge können nicht gemacht werden. Die Genauigkeitsanforderungen bzgl. der Erkennung einzelner Typen hängen immer von der jeweiligen Zielstellung ab. Weitere Untersuchungen, auch für die anderen Eingangsdatentypen, wären hierzu nötig. Allerdings lässt sich aus dem Diagramm eine generelle Aussage ableiten. Für Klassen, die bereits mit geringer Trainingsdatenmenge gut klassifiziert werden und die mit zunehmender Trainingsmenge keine große Verbesserung der Genauigkeit erfahren (z. B. die Klassen ÖG, EZFH-RH), ist eine geringere Trainingsmenge ausreichend als für Klassen, die bei Erhöhung der Trainingsdatenmenge mit einer größeren Geschwindigkeit konvergieren (z. B. die Klassen WGL, MFH-F).

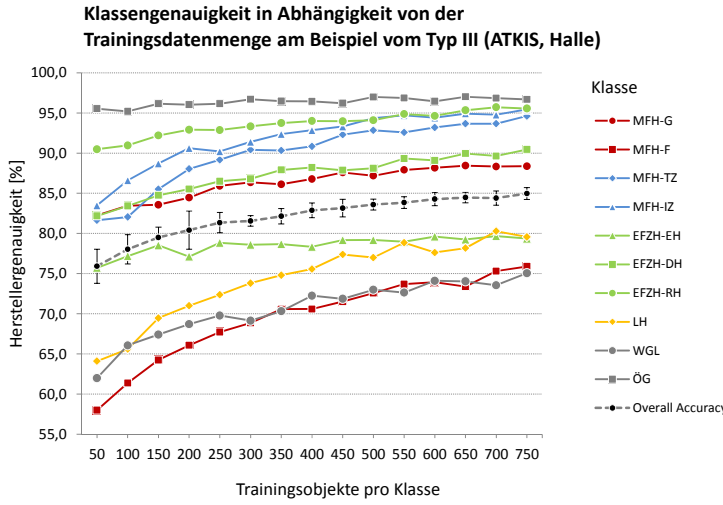

Abb. 8-17: Klassengenauigkeit in Abhängigkeit von der Anzahl an Trainingsbeispielen pro Klasse. Die Herstellergenauigkeit wurde durch 10-fach wiederholtes Trainieren und Testen ermittelt.

8.5.6 Kreuzweises Trainieren und Testen

Mit einem kreuzweisen Trainieren und Testen soll die Generalisierungsfähigkeit im Hinblick auf eine überregionale Anwendung des Verfahrens näher untersucht werden. Dazu wird beispielhaft der Eingangsdatentyp III (ATKIS, HU) betrachtet, da nur für diesen ein ausreichend großer Umfang an Referenzdaten für alle städtischen Untersuchungsgebiete vorliegt.

Die Genauigkeitsuntersuchung erfolgte durch ein 10-fach wiederholtes Trainieren an einem Untersuchungsgebiet A und Testen an einem Untersuchungsgebiet B. Zum Training wurde jeweils eine Bootstrap-Stichprobe im Umfang von 10 000 Trainingsobjekten aus A gezogen. Zum Testen wurde stets der gesamte Referenzdatenbestand von B verwendet.

Die Tab. 8-17 fasst die Ergebnisse des kreuzweisen Trainierens und Testens mit den erreichten Klassifikationsgenauigkeiten und den Kappa-Werten in einer Matrix zusammen. In der Hauptdiagonale ist die Genauigkeit eingetragen, die beim Trainieren und Testen innerhalb des gleichen Untersuchungsgebietes erreicht wird. Diese Genauigkeit wurde gegenüber den anderen Werten in der Matrix an der restlichen, nicht am Training beteiligten Referenzdatenmenge des Untersuchungsgebietes gemessen.

Die Experimente zeigen, dass die Genauigkeit der erlernten Klassifikatoren bei Anwendung auf ein anderes Untersuchungsgebiet ca. 10 bis 30 Prozentpunkte geringer ist. Die höchste Klassifikationsgenauigkeit konnte mit knapp 80 % für Krefeld durch Verwendung von Trainingsbeispielen von Halle erzielt werden. Auch wenn die Gesamtgenauigkeit relativ gut ist, so ist die Erkennung der Klassen MFH-F, MFH-TZ, MFH-HH und LH jedoch nicht ausreichend (vgl. Abb. 8-18). Das Klassifikationsergebnis für Halle auf Grundlage der Trainingsdaten von Krefeld ist mit einer Genauigkeit von knapp über 60 % eher schwach.

Tab. 8-17: Klassifikationsgenauigkeit durch kreuzweises Trainieren und Testen am Beispiel der Untersuchungsgebiete Dresden, Halle und Krefeld (Eingangsdatentyp III)

		Trainingsdaten		
		Dresden (n=10 000)	Halle (n=10 000)	Krefeld (n=10 000)
Validierungsdaten	Dresden n= 19 370	**OA: 89,17 %** ±0,57 κ: 0,86 ±0,01	**OA: 73,12 %** ±1,22 κ: 0,67 ±0,01	**OA: 60,60 %** ±3,26 κ: 0,53 ±0,04
	Halle n= 39 636	**OA: 69,80 %** ±1,25 κ: 0,56 ±0,01	**OA:88,36 %** ±0,43 κ: 0,86 ±0,00	**OA: 60,31 %** ±2,92 κ: 0,54 ±0,03
	Krefeld n= 26 042	**OA: 63,80 %** ±1,37 κ: 0,56 ±0,01	**OA: 79,35 %** ±0,67 κ: 0,75 ±0,01	**OA:91,36 %** ±0,24 κ: 0,89 ±0,00

Ein Blick auf die klassenspezifische Genauigkeit in Abb. 8-18 verrät, dass in diesem Fall nur die 4 Klassen MFH-F, EZFH-EH, EZFH-DH und EZFH-RH mit einer Herstellergenauigkeit von über 70 % klassifiziert werden konnten. Die restlichen Klassen, die einen großen Anteil an der Gesamtheit ausmachen, werden mit geringerer Leistung klassifiziert. Ein gegenseitiges Trainieren der beiden ostdeutschen Städte Dresden und Halle ist mit einer höheren Genauigkeit von ca. 70 % (Halle mit Trainingsdaten von Dresden) bzw. 73 % (Dresden mit Trainingsdaten von Halle) möglich. Die baulich-räumliche Struktur der Städte Dresden und Halle ist offensichtlich ähnlich, da beide Städte vom sozialistischen Wohnungsbau der DDR geprägt sind.

Derartige Interpretationen sind jedoch nur zulässig, wenn andere Effekte, die sich aus den Daten ergeben, ausgeschlossen werden können. Gebäudegrundrisse vom Eingangsdatentyp III wurden für Krefeld aus der Geometrie der 3D-Gebäudestrukturen (Grundlage dafür ist die Geometrie aus der Liegenschaftskarte) abgeleitet. Die Gebäudegrundrisse von Dresden und Halle stammen aus dem ATKIS® der Bundesländer. Modellierungsunterschiede (vgl. Burckhardt, 2012) zwischen den Datensätzen schlagen sich in den Merkmalen und letztendlich auch in einer geringeren Klassifikationsleistung nieder. Hierzu bedarf es in Zukunft weiterer Untersuchungen.

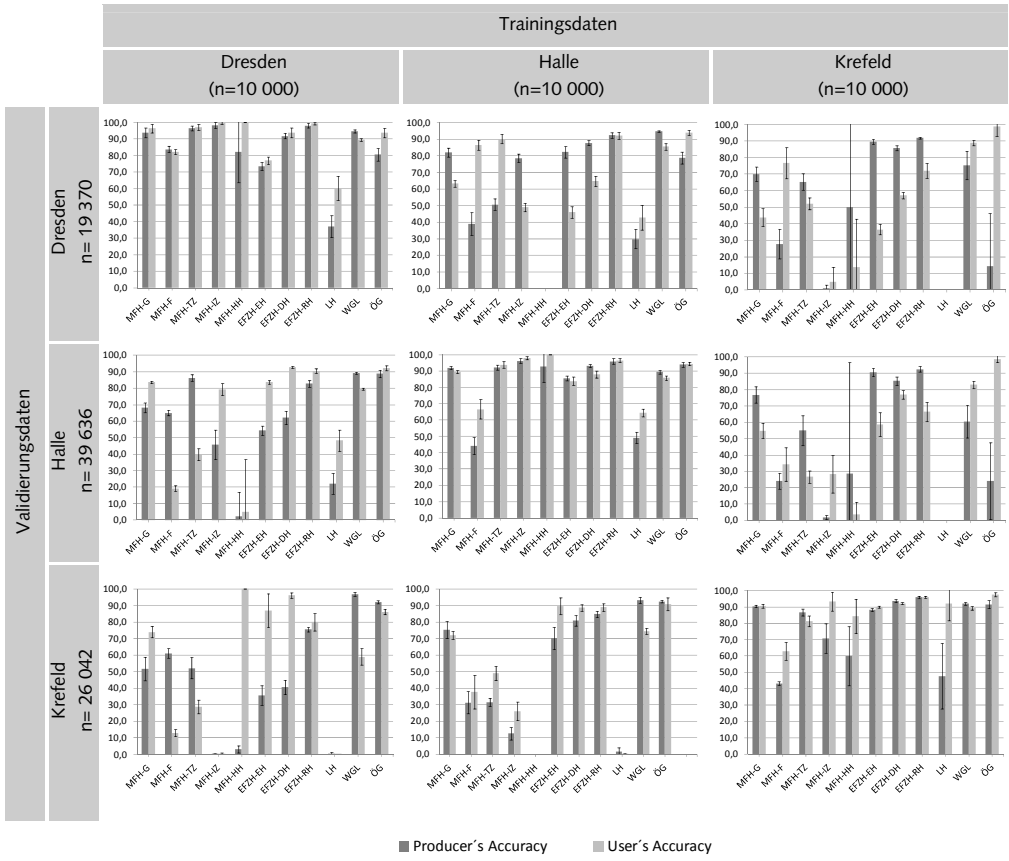

Abb. 8-18: Klassenspezifische Genauigkeit beim kreuzweisen Trainieren und Testen (Quelle: Eigene Darstellung)

8.5.7 Diskussion der Modellvalidierung

Mit der Genauigkeitsanalyse wurde das entwickelte Klassifikationsverfahren unter Einsatz des Random Forest-Algorithmus validiert und bewertet. Die quantifizierte Genauigkeit hängt dabei von verschiedenen Faktoren, wie dem Eingangsdatentyp, dem betrachteten Siedlungstyp, der Größe der Trainingsdatenmenge und auch der Datenqualität ab.

Die städtischen Untersuchungsgebiete unterscheiden sich in der Gesamtgenauigkeit nur marginal, weshalb auch für andere deutsche Städte vergleichbare Ergebnisse erwartet werden können. Für die Kleinstadt Stolpen und die ländlichen Gebiete wurde eine deutlich geringere Klassifikationsgenauigkeit gegenüber den städtischen Gebieten gemessen. Eine Ursache ist dabei die geringere Dimension der dörflichen Gebiete und die damit einhergehende kleinere Trainingsmenge. Ein Vergleich der Ergebnisse anhand städtischer und dörflicher Da-

tensätze mit annähernd gleich großer Trainingsmenge zeigte dennoch eine um 20 Prozentpunkte höhere Klassifikationsgenauigkeit für die städtischen Gebiete[86]. Eine Klassifizierung der dörflichen Gebiete ist offenbar mit größeren Unsicherheiten behaftet, da deren Gebäudebestand durch eine sehr heterogene Nutzung geprägt ist (z. B. Wohnstallhäuser, Scheunen etc.). Eine Unterscheidung zwischen Wohn- und Nichtwohngebäuden ist anhand der Informationen zur Gebäudefunktion, z. B. aus der ALK, schwierig.

Für einzelne unterbesetzte Klassen wurde zum Teil eine sehr geringe Klassifikationsgenauigkeit beobachtet. Dies betrifft einige Klassen der Datensätze DTK25 und DTK25-V von Krefeld, für die wegen fehlender räumlicher Zuordnung der Klassenlabels nicht mehr Trainingsdaten zur Verfügung standen sowie einige Klassen der Datensätze von Stolpen und den dörflichen Gebieten. Grund dafür ist, dass bei ungleicher Klassenverteilung Random Forest dazu neigt, hochbesetzte Klassen besser zu erlernen als die unterbesetzten Klassen. Das Training eines Random Forest erfolgt allein auf Grundlage des OOB-Fehlers. Beim zufälligen Ziehen der Bootstrap-Stichproben zur Konstruktion der Bäume werden die unterbesetzten Klassen nur selten gezogen und finden damit nicht genügend Berücksichtigung beim Modellaufbau. Es wäre in diesem Fall eine höhere Anzahl an Trainingsdaten für die Klasse nötig.

Eine Untersuchung der klassenspezifischen Genauigkeit zeigte, dass bei Verwendung einer Trainingsdatenmenge mit gleicher Gruppengröße die Herstellergenauigkeit unterbesetzter Klassen erhöht werden kann. Auf Grundlage einer Stichprobe von 250 Gebäuden pro Klasse (vektorbasierte Gebäudegrundrisse vom Eingangsdatentyp III-V) konnten 70 % aller Klassen[87] richtig klassifiziert werden. Eine derartig gleiche Klassenverteilung liegt in der Praxis allerdings nicht vor, weshalb die Anwendung des erlernten Klassifikators auf echte Daten zu einer geringeren Nutzergenauigkeit (höherer Überlassungsfehler) führen kann. Im Hinblick auf die Bestimmung einer optimalen Menge und Klassenverteilung der Trainingsdaten wird weiterer Forschungsbedarf gesehen.

Ein bisher nicht betrachteter Aspekt ist die Datenqualität. Trotz einheitlich festgelegter Modellierungskriterien und Qualitätsstandards ist eine vollständige Homogenität in der Praxis nur selten gegeben, da die Zuständigkeit der Erfassung und Aufbereitung von Gebäuden in Deutschland dezentral geregelt ist. Eine Analyse der Gebäudemodellierung aller amtlichen Hausumringe (entsprechend der Gebäudegeometrie aus ALK/ALKIS®) zeigte deutliche Differenzen im geometrischen Detaillierungsgrad (Burckhardt, 2012). Auch die topographischen Rasterkarten sind von einer länderspezifischen Heterogenität geprägt (Meinel et al., 2008b), was die Stärke der Generalisierung, die Datenstruktur sowie die Qualität des Kartenscans bzw. der Originalvorlage betrifft. Diese Aspekte haben auch Einfluss auf die Ergebnisse der Untersuchung. So führt der höhere Generalisierungsgrad der DTK25 (Krefeld) im Vergleich zur DTK25 (Halle) bereits während der Datenaufbereitung zu Problemen (Attributübertragung). Andererseits führt die stärkere Generalisierung offensichtlich zu einer ge-

[86] Mit Bezug auf die Gesamtgenauigkeit (vgl. Tab. 8-15) am Beispiel der DTK25-V: Dörfliche Gebiete mit n=730 (56,6 %), Stadt Krefeld mit n=640 (76,6 %).

[87] mit Ausnahme der Hochhäuser

ringeren Klassifikationsgenauigkeit, was ein Vergleich der Ergebnisse von Krefeld (DTK25) und Halle (DTK25) zeigt. Wie groß der Einfluss der Generalisierung konkret ist, kann mit weiteren Untersuchungen unter Nutzung der Referenzdatenbank abgeschätzt werden.

8.6 Ergebnisse der Merkmalswichtigkeit

Maße zur Beurteilung der Relevanz einzelner Merkmale (Merkmalswichtigkeit) sind bedeutsam für die Dateninterpretation, da mit ihnen zugrundeliegende Zusammenhänge aufgedeckt werden können. Auf der anderen Seite können derartige Maße dem Ranking der Merkmale dienen, auf deren Grundlage eine Merkmalsselektion möglich wird. Im folgenden Abschnitt wird die Merkmalswichtigkeit, die mithilfe von Random Forest untersucht werden kann, betrachtet.

8.6.1 Merkmalswichtigkeit nach Eingangsdaten

Random Forest hält verschiedene Maße zur Messung der Merkmalswichtigkeit (engl. *variable importance*) bereit. Ziel folgender Untersuchung soll dabei die Beurteilung der Relevanz der gebäudebeschreibenden Merkmale sein. Die zwei geläufigsten Maße sind die Gini-Wichtigkeit (engl. *gini importance measurement,* GIM) und ein permutiertes Maß der Fehlerfreiheit (engl. *permutation importance measurement,* PIM), die beide mit der Implementierung im R-Paket „randomForest" berechnet werden können (Calle & Urrea, 2011). Die Gini-Wichtigkeit basiert auf dem Gini-Index, einem Maß zur Messung der Qualität eines Splits mit einem Merkmal bei der Baumkonstruktion. Beim PIM wird jedes Merkmal durch Messung des mittleren Vorhersagegenauigkeitsverlustes quantifiziert. Durch Weglassen des Merkmals (simuliert über Permutation) wird die Genauigkeit der Klassifikation gemessen und mit der Genauigkeit bei Verwendung der ursprünglichen Daten verglichen.

Strobl et al. (2007) zeigen, dass die Gini-Wichtigkeit von der Skalierung der Merkmale und der Anzahl der Kategorien nichtmetrischer Merkmale beeinflusst ist, weshalb zur Quantifizierung das vertrauenswürdigere permutierte Maß PIM bevorzugt wird. Entgegen der standardmäßigen Implementierung sollte jedoch das unskalierte Maß verwendet werden, da diesem bessere statistische Eigenschaften nachgesagt werden (Strobl & Zeileis, 2008).

Die Wichtigkeit der Merkmale (unskalierte PIM) wurde für verschiedene Datensätze berechnet. Eingang fanden dabei die bereits von Korrelation befreiten Merkmale (vgl. Kap. 7.7.1). Grundlage der Analyse war jeweils eine zufällige Stichprobe im Umfang von 5 000 Objekten, mit denen ein Random Forest aus 200 Bäumen konstruiert wurde. Die Ergebnisse sind in ihrer Vollständigkeit in Anhang C.4 zu finden. In Abb. 8-19 ist die Merkmalswichtigkeit der 40 wichtigsten Merkmale am Beispiel der DTK25-Gebäude von Halle (Eingangsdatentyp II) und den Gebäudegrundrissen von Krefeld (Eingangsdatentyp III) dargestellt.

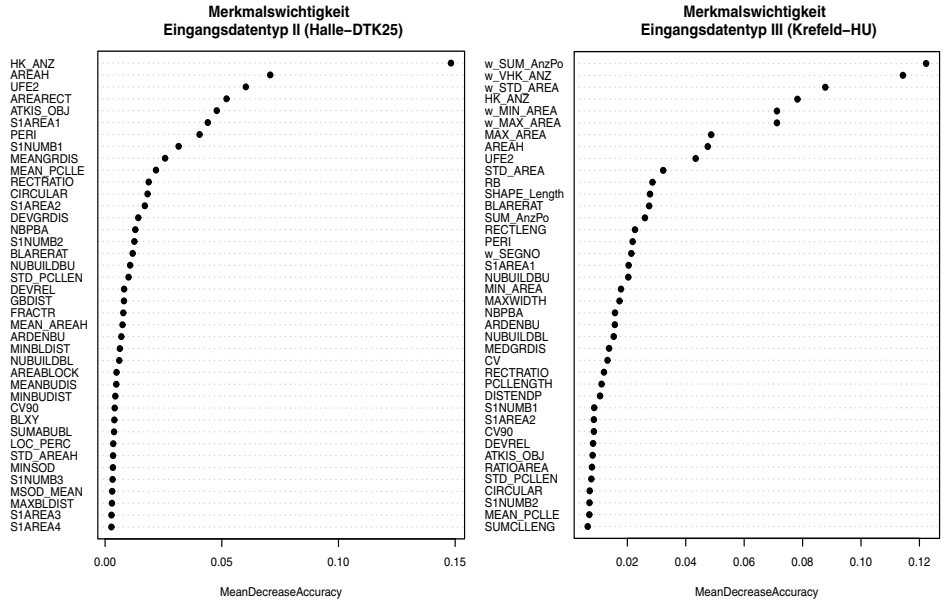

Abb. 8-19: Merkmalswichtigkeit (PIM) gemessen am mittleren Genauigkeitsverlust (Mean Decrease Accuracy) beim Weglassen des Merkmals am Beispiel der Eingangsdatentypen II und III

Hohe Werte deuten auf einen großen mittleren Genauigkeitsverlust (MeanDecreaseAccuracy) beim Weglassen des jeweiligen Merkmals hin (hohe Wichtigkeit). Deutlich wird dabei, dass einige Merkmale einen großen, andere hingegen einen kleinen Beitrag bei der Klassifizierung leisten. Wichtigstes Merkmal für den Eingangsdatentyp I und II ist die Anzahl der Hauskoordinaten pro Gebäude (HK_ANZ). Dieses Merkmal scheint besonders wichtig, da mit diesem eine gute Trennung der freistehenden Ein- und Zweifamilienhäuser (EZFH-EH) von den Doppelhäusern (EZFH-DH) bzw. den Reihenhäusern (EZFH-RH) und den Gebäuden der Zeilenbebauung (MFH-TZ, MFH-IZ) möglich wird. Diese Klassen sind oftmals hoch besetzt, weshalb die Merkmale, die zur richtigen Klassifizierung dieser Klassen beitragen, eine besonders hohe Bedeutung im Wichtigkeitsmaß beigemessen bekommen. Die nächst wichtigsten Merkmale sind bei Eingangsdatentyp II die Fläche der Gebäuderegion AREAH und die Formmerkmale UFE2 und AREARECT. Bereits an vierter Stelle steht das Merkmal zur Beschreibung der Flächennutzung (ATKIS_OBJ). Dieses Merkmal ist besonders wichtig, um die Wohnnutzungsklassen von den Nichtwohnnutzungsklassen (WGL, ÖG) zu unterscheiden. Für Einzelgebäudegrundrisse ohne semantische Information (Eingangsdatentyp III) sind vektorbasierte Merkmale, wie die Anzahl zusammenhängender Einzelgebäude (w_SUM_Anzpo), die Varianz der Fläche zusammenhängender Einzelgebäude (w_STD_AREA) oder die maximale Fläche aller Einzelgebäude in der Gebäuderegion (w_MAX_AREA) am bedeutendsten. Diese beschreiben die Struktur eines zusammenhängenden Gebäudekomplexes. Die Anzahl der Hauskoordinaten pro Gebäudegrundriss (HK_ANZ) und im Gebäudekomplex (w_VHK_ANZ) ist ebenso bedeutsam. Für den Eingangsdatentyp IV und V ist die semantische Information zur Gebäudenutzung (GEBNUTZ) am wichtigsten, gefolgt von den vektorbasierten Merkmalen, die das Einzelgebäude und

den Gebäudekomplex beschreiben. Für Eingangsdatentyp V leisten auch die zusätzlichen Merkmale zur Trennung von Haupt- und Nebengebäude (GEB_TYP) und die Gebäudehöhe (GEB_HOEHE) einen wichtigen Beitrag. Fast unbedeutend für alle Datensätze sind die Merkmale PATIO, SEGNO und SUMANGLE. Auch die Merkmale zur Beschreibung der relativen Gebäudeorientierung (CDIRECT, CDIR90, SUMANGLE) leisten offenbar nur einen geringen Beitrag für die Klassifizierung.

8.6.2 Merkmalsselektion über Merkmalswichtigkeit

Die Untersuchung zur Merkmalswichtigkeit hat gezeigt, dass nicht alle Merkmale Informationen enthalten, die für die Klassifizierung relevant sind. Mithilfe einer Merkmalsselektion könnten demnach Speicher- und Rechenressourcen eingespart werden, ohne dass sich die Klassifzierungsgenauigkeit signifikant verschlechtert.

Ein effizienter Ansatz aus der Bioinformatik ist die Rückwärtseliminierung unter Nutzung der Vorhersagegenauigkeit gemessen an der OOB-Menge (Díaz-Uriarte & Alvarez de Andrés, 2006). Aus der nach der Wichtigkeit sortierten Merkmalsmenge werden iterativ die unwichtigsten Merkmale eliminiert. In jedem Durchlauf wird ein Random Forest mit der jeweilig reduzierten Merkmalsmenge konstruiert. Am Ende wird das Modell mit der kleinsten Merkmalsmenge gewählt, dessen Vorhersagefehler (gemessen an der OOB-Menge) am geringsten oder nicht signifikant höher[88] als bei Verwendung aller Merkmale ist. Bei jedem Durchlauf wird allerdings nicht nur ein Merkmal, sondern ein definierter Anteil an der Merkmalsmenge (jeweils die unwichtigsten 20 %) eliminiert. Dies erlaubt bei Vorhandensein sehr vieler Merkmale eine sehr effiziente Merkmalsselektion.

Das eben beschriebene Merkmalsselektionsverfahren wurde anhand der 5 Eingangsdatensätze (siehe vorheriger Abschnitt) unter Nutzung des R-Paketes „varSelRF“ angewendet. Der Anteil der bei jedem Durchlauf zu eliminierenden Merkmale wird über den Parameter „drop.frac“ gesteuert und auf 0.2 gesetzt (entspricht einer sukzessiven Merkmalsreduktion um 20 %).

Das Ergebnis der Merkmalsselektion ist in Abb. 8-20 am Beispiel der Eingangsdatentypen II und III dargestellt (alle Ergebnisse in Anlage C.5). Die Diagramme zeigen den OOB-Fehler in Abhängigkeit von der betrachteten Merkmalsmenge. Dabei wird deutlich, dass mit der iterativen Eliminierung der unwichtigsten Merkmale der OOB-Fehler nur minimal geringer wird. Random Forest kann deshalb auch ohne Merkmalsselektion auf Grundlage des originären Merkmalssets angewendet werden (implizite Merkmalsselektion). Aus dem Kurvenverlauf der Fehlerrate wird ebenfalls deutlich, dass bereits mithilfe weniger relevanter Merkmale eine relativ hohe Klassifikationsgenauigkeit erzielt werden kann.

[88] innerhalb der einfachen Standardabweichung

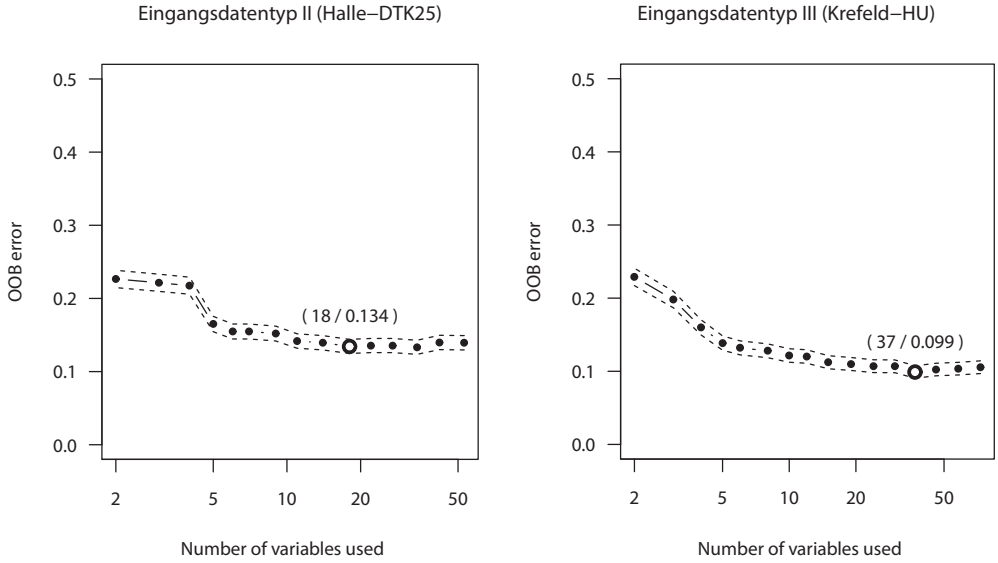

Abb. 8-20: OOB-Fehler in Abhängigkeit der Merkmalsanzahl am Beispiel der Eingangsdatentypen II (links) und III (rechts). Die beste Merkmalsmenge ist hervorgehoben.

Bei praktischer Anwendung auf große Gebäudedatensätze eignet sich die Merkmalsselektion, um Ressourcen (Rechenzeit, Speicher) einzusparen, in dem die unwichtigen Merkmale in der praktischen Anwendungsphase nicht mehr berechnet werden müssen.

Die Tab. 8-18 zeigt ergänzend das Einsparpotenzial an einem Beispiel. Für die betrachteten Eingangsdatensätze wäre die Berechnung von lediglich 18 (Typ I), 19 (Typ II), 37 (Typ III) bzw. 34 (Typ IV und V) Merkmalen ausreichend, um einen Klassifikator zu erhalten, der eine vergleichbare Genauigkeit besitzt, wie der unter Nutzung aller zur Verfügung stehenden Merkmale. Unter der Annahme, dass der Aufwand für die Berechnung jedes Merkmals annähernd gleich ist[89], könnten in diesem Fall etwa 43 % (HU, Krefeld) bis 66 % (Halle, DTK25) an Rechenressourcen eingespart werden.

[89] Dies ist in der Regel jedoch meist nicht der Fall (vgl. Diskussion im Kap. 8.6.3).

Tab. 8-18: Vorhersagegenauigkeit (OOB-Genauigkeit) des Klassifikators mit den originalen Merkmalen (O) und nach der Merkmalsselektion (S) (Trainingsmenge: 5 000 Objekte, Anzahl konstruierter Bäume: 200)

	Eingangsdatentyp									
	I (Halle)		II (Halle)		III (Krefeld)		IV (Krefeld)		V (Krefeld)	
	Orig.	Sel.	Orig.	Sel.	Orig.	Sel.	Orig.	Sel.	Orig.	Sel.
Merkmalsanzahl	46	19	53	18	65	37	73	34	67	34
OOB-Genauigkeit [%]	73,00	73,16	86,34	86,34	89,74	89,76	91,56	91,7	92,38	92,34
Differenz OOB-Genauigkeit		+0,16		0,00		+0,02		+0,14		-0,04
Ressourceneinsparung bei der Merkmalsgewinnung [%]	59		66		43		54		49	

8.6.3 Diskussion der Merkmalswichtigkeit

Random Forest stellt ein sehr effizientes Maß zur Messung der Merkmalswichtigkeit bereit. Jüngste Forschungsergebnisse zeigen jedoch, dass die von Random Forest mitgelieferten Maße zur Merkmalswichtigkeit sensitiv gegenüber einigen Randbedingungen sind (Strobl et al., 2007; Genuer et al., 2010). So wird den kategorialen Merkmalen mit vielen Ausprägungen eine größere Bedeutung beigemessen als den metrischen Merkmalen. Auch hoch korrelierte Merkmale neigen dazu, bevorzugt zu werden. Ein demgegenüber resistentes, jedoch auch rechenintensiveres Maß schlagen Strobl et al. (2008) vor. Auf einen Einsatz dieses Maßes wurde jedoch verzichtet, da die gebäudebeschreibenden Merkmale einerseits bereits über die filterbasierte Merkmalsreduktion von Korrelation befreit sind und andererseits vornehmlich metrische Merkmale vorliegen.

Die Merkmalswichtigkeit unterstützt die Suche nach einer optimalen Merkmalsmenge (Merkmalsselektion). Mit der Eliminierung unwichtiger Merkmale kann der Rechenaufwand zur Merkmalsgewinnung deutlich reduziert werden (vgl. Rechenbeispiel im Kap. 8.6.2). Entgegen der Annahme, dass der Aufwand für die Berechnung jedes Merkmals annähernd gleich ist, beansprucht jedes Merkmal jedoch unterschiedliche Ressourcen (Speicher, Rechenzeit). Es wäre darum eine Evaluierung der einzelnen Prozesse der Merkmalsextraktion nötig, um die Ressourceneinsparung realistischer abschätzen zu können.

9 Schlussfolgerungen und Ausblick

Das letzte Kapitel widmet sich der Reflexion der gewonnen Erkenntnisse. Zunächst werden die eingangs formulierten Forschungsfragen beantwortet. Anschließend werden die praktische Bedeutung in Bezug auf die Ergebnisse der Genauigkeitsanalyse, das entwickelte Verfahren selbst und die sich daraus ergebenden potenziellen Anwendungsfelder diskutiert. In einem Ausblick werden schließlich offene Fragen und der weitere Forschungsbedarf aufgezeigt.

9.1 Beantwortung der Forschungsfragen

Aus den Ergebnissen der Arbeit können verschiedene Schlussfolgerungen gezogen werden. Im Folgenden werden die aufgestellten Forschungsfragen mithilfe der gewonnen Erkenntnisse beantwortet.

Welche Anforderungen werden an Gebäudegrundrisse gestellt und welche Datengrundlagen sind geeignet?

Im Hinblick auf eine vollautomatisierte Anwendung des Verfahrens für eine kleinräumige Beschreibung der Siedlungsstruktur werden möglichst homogene Daten benötigt, die Gebäude im Grundriss abbilden. Gebäudegrundrisse können aus verschiedenen Datenquellen gewonnen werden. Dazu gehören digitale topographische Daten der Landesvermessung und Katastervermessung, nutzergenerierte Daten sowie Fernerkundungsdaten.

Geobasisdaten der Landesvermessung oder des Liegenschaftskatasters eignen sich dabei am besten, da diese das Gebäude in ausreichender Genauigkeit abbilden, die Anforderungen an Flächendeckung, Vollständigkeit und Homogenität am besten erfüllen und ein einfacher Zugang zum Gebäudegrundriss gewährleistet ist. Die Anforderungen an die geometrische Genauigkeit und den Abstraktionsgrad ergeben sich aus den Spezifikationen von CityGML. Konkret eignen sich dafür Gebäudegrundrisse, die in vektorbasierten topographischen Datenbanken vorliegen (z. B. ALK, ALKIS®, Hausumringe) oder mittels kartographischer Mustererkennung aus topographischen Rasterkarten mit einem Maßstab von 1: 25 000 und größer (z. B. DTK10, DTK25) extrahiert werden können. Hochauflösende Satellitenbild- und Luftbilddaten besitzen zwar ein größeres Maß an Information und Aktualität, für eine automatisierte Anwendung im Verfahren eignen sich diese jedoch nur bedingt, da eine vollautomatische Extraktion der Gebäudegrundrisse noch nicht mit hinreichender Genauigkeit möglich ist. Eine vollautomatische Rekonstruktion der Gebäude auf Grundlage von Laserscannerdaten ist hingegen bereits mit hoher Genauigkeit möglich. Nutzergenerierte Daten, deren Datenumfang ständig wächst, bieten derzeit keine Alternative, da es die geringe Vollständigkeit in der Gebäudeerfassung noch nicht erlaubt.

Aus der Menge flächendeckender Geobasisdaten in Deutschland können fünf verschiedene Eingangsdatentypen identifiziert werden, die sich in ihrer geometrischen Modellierung und dem semantischen Informationsgehalt unterscheiden. Das sind einerseits Gebäudegrundrisse aus topographischen Rasterkarten (in Gebäuderegion-Repräsentation), die zusammen mit anderen Signaturen vereint (Typ I: TK25, DTK25-V) oder in einem separierten Layer (Typ II:

DTK25) gespeichert sind. Andererseits sind das vektorbasierte Gebäudegrundrisse (in Einzelgebäude-Repräsentation), die weiter nach dem semantischen Informationsgehalt in Einzelgebäude ohne semantische Information (Typ III: ATKIS-Gebäude, Hausumringe), mit semantischer Information (Typ IV: ALK, ALKIS®) sowie mit semantischer Information und zusätzlicher Höheninformation (Typ V: 3D-Gebäudestrukturen) untergliedert werden können.

Als unterstützende Geometrie für die Klassifizierung können Baublöcke aus dem ATKIS® Basis-DLM sowie Hauskoordinaten hinzugezogen werden, da diese ebenfalls flächendeckend vorliegen und diese wichtigen kontextuellen Informationen enthalten.

Welche gebäudebeschreibenden Merkmale können automatisch aus den Daten abgeleitet werden?

Städtebauliche Gebäudetypen zur kleinräumigen Beschreibung der Siedlungsstruktur besitzen charakteristische Eigenschaften, auf deren Grundlage der Mensch fähig ist, diese als solche zu erkennen. Für die automatische Klassifizierung von Gebäudegrundrissen werden objektbeschreibende Eigenschaften in Form numerischer Merkmale benötigt. Aus den Bild- und Vektordaten können diese mit rasterbasierten Methoden der Bildverarbeitung oder vektorbasierten Methoden der räumlichen Analyse im GIS automatisch extrahiert werden.

Für eine automatische Gebäudeklassifizierung auf der Grundlage topographischer Daten spielen geometrische, topologische, statistische und semantische Merkmale eine bedeutende Rolle. Diese Merkmale können auf verschiedenen räumlichen Ebenen (z. B. Einzelgebäude, Gebäuderegion, Baublock, Umgebung etc.) erhoben und jedem Gebäudegrundriss zugeordnet werden. Die Möglichkeiten zur Gewinnung von Merkmalen werden dabei von der gegebenen Datengrundlage bestimmt. Aus Gebäudegrundrissdaten des Liegenschaftskatasters (Einzelgebäude) können beispielsweise mehr Merkmale abgeleitet werden als bei der Nutzung von Gebäuden aus topographischen Karten (Gebäuderegionen), da mit dem höheren Detaillierungsgrad (Einzelgebäudemodellierung) mehr Informationen zur Verfügung stehen. Unter Berücksichtigung aller flächendeckend verfügbaren Gebäudegrundrisse in Deutschland wurde für jeden definierten Eingangsdatentyp ein Merkmalsset erarbeitet (vgl. Kap. 7.5.6).

Während der Merkmalsgewinnung werden unterstützende Daten zu den bebauten Flächen (Baublöcke) und Hauskoordinaten hinzugezogen. Baublöcke bieten eine wichtige Bezugsgeometrie zur Beschreibung des räumlichen Kontextes. Auf dieser Grundlage ist beispielsweise die Berechnung der Gebäudedichte, des Überbauungsgrades oder des Gebäudeabstandes zur Straße möglich. Mithilfe der Hauskoordinaten können hingegen zusätzliche Merkmale zur Beschreibung der Hauseingangszahl abgeleitet werden. Für die automatische Klassifizierung können darüber hinaus Informationen genutzt werden, die bereits explizit in den Daten modelliert sind. Dies sind beispielsweise die zugrundeliegende Flächennutzung aus dem ATKIS® Basis-DLM und die semantische Information zur Gebäudefunktion, die jedem Gebäude im Liegenschaftskataster hinterlegt ist. Um diese Informationen in einem Mustererkennungsprozess nutzen zu können, ist in der Regel eine Transformation in einen numerischen Wert nötig.

Welche Merkmale sind wichtig für die Klassifizierung?

Maschinelle Lernverfahren erlauben die Identifikation der relevanten Merkmale aus einer gegebenen Merkmalsmenge. Der Random Forest-Algorithmus stellt ein effizientes Maß zur Quantifizierung der Merkmalswichtigkeit bereit. Mit der Anwendung auf verschiedene Datensätze können die berechneten Merkmale nach ihrer Wichtigkeit bewertet werden. Es zeigte sich, dass die Anzahl der Hauskoordinaten pro Gebäudegrundriss die wichtigste Eigenschaft bei der Klassifizierung von Gebäuderegionen aus topographischen Rasterdaten (z. B. DTK25, DTK25-V) ist. Gefolgt wird diese von grundlegenden geometrischen Merkmalen zur Größe und zur Form. Dass die blockbezogene Flächennutzung aus dem ATKIS® einen wichtigen Beitrag für die Klassifizierung leistet ist trivial, da mit dieser Information ein Großteil der Wohn- von den Nichtwohngebäuden separiert werden kann. Für die vektorbasierten Gebäudegrundrisse in Einzelgebäudemodellierung (z. B. Hausumringe, ATKIS®-Gebäude) spielen die geometrisch-topologischen Merkmale (Anzahl, Größe und Varianz der Einzelgebäude im Gebäudekomplex) eine wesentliche Rolle. Ist hingegen bereits eine explizite Information zur Gebäudefunktion in den Daten gegeben (z. B. ALK/ALKIS®), so wurde dieses Merkmal als Wichtigstes eingestuft. Für Gebäudegrundrisse mit expliziter Gebäudehöhe belegt dieses Merkmal Platz 8 im Ranking. Ein Großteil der Merkmale zur Beschreibung der Orientierung konnte hingegen als unwichtig eingestuft werden, wie auch die Arbeit von Steiniger et al. (2008) zeigte.

Mit der Anwendung einer automatischen Merkmalsselektion mittels Rückwärts-Eliminierung der unwichtigsten Merkmale unter Nutzung von Random Forest konnte gezeigt werden, dass bereits mit wenigen relevanten Merkmalen eine Klassifizierung mit hoher Genauigkeit möglich ist. Nach der Selektion konnte das Merkmalsset für rasterbasierte Gebäudegrundrisse auf weniger als 20 Merkmale und für vektorbasierte Grundrisse auf weniger als 40 Merkmale reduziert werden, ohne dass sich die Klassifikationsgenauigkeit dabei signifikant verschlechtert. Für einen operationellen Einsatz des Verfahrens können damit Rechenressourcen für die Merkmalsgewinnung eingespart werden.

Welche Klassifikationsverfahren der Mustererkennung und des maschinellen Lernens sind geeignet?

Aus konzeptionellen Vorüberlegungen ging hervor, dass ein überwachtes Klassifikationsverfahren besser geeignet ist, da die gesuchten Gebäudetypen für die kleinräumige Beschreibung der Siedlungsstruktur in der Regel als bekannt vorausgesetzt werden können. Andererseits ist im Gegensatz zu den unüberwachten Klassifikationsverfahren keine aufwändige Dateninterpretation nötig, und der zu erwartende Klassifikationsfehler kann direkt anhand der Trainings- und Testdaten quantifiziert werden. Allerdings ist zum Trainieren und Testen eines überwachten Klassifikators eine ausreichend große Trainingsdatenmenge nötig. Im Rahmen der Anwendung des Verfahrens für eine raumwissenschaftliche Untersuchung kann jedoch häufig auf bereits vorhandene Kartierungen zurückgegriffen werden.

Die Statistik und Informatik hält ein breites Spektrum an Methoden der Mustererkennung und des maschinellen Lernens bereit. Es werden insgesamt 16 überwachte Klassifikationsverfahren anhand von Datensätzen der 5 Eingangsdatentypen getestet und hinsichtlich der Generalisierungsfähigkeit (kreuzvalidierte Klassifikationsgenauigkeit) und Effizienz (Laufzeit)

bewertet (vgl. Kap. 0). Es wurden dabei nichtparametrische, lineare und nichtlineare Modelle der Statistik sowie moderne Verfahren des maschinellen Lernens getestet. Darunter fallen auch Verfahren, die bereits Anwendung in publizierten Ansätzen zur Gebäudeklassifizierung fanden (u. a. SVM, AdaBoost, CART). Random Forest zeigte die höchste Klassifikationsgenauigkeit, wobei sich diese im Vergleich zu fünf anderen Methoden (Bagging, Double Bagging, paarweise Random Forest, SVM, Neuronale Netze) nicht signifikant unterscheidet. Die Ergebnisse der Untersuchung bestätigen die Annahme, dass nichtlineare Klassifikatoren (insbesondere Ensemble-Methoden, Künstliche Neuronale Netze und SVM) besser geeignet sind als die linearen Verfahren. Aus den Untersuchungen von Steiniger et al. (2008) ging hingegen hervor, dass mit linearen und nichtlinearen Klassifikationsverfahren eine annähernd gleich gute Klassifikationsleistung erreicht werden kann. Im Vergleich zu Steiniger et al. (2008) liegt in diesem Fall eine größere Anzahl an Klassen, Merkmalen und Trainingsobjekten vor. Für eine Klassifizierung von Gebäuden nach 11 städtebaulichen Gebäudetypen unter Nutzung zusätzlicher Informationen ist offensichtlich ein nichtlineares Verfahren besser geeignet.

Eine Evaluierung der Laufzeit führte letztendlich zur Wahl von Random Forest als bestes getestetes Klassifikationsverfahren. Das Tuning eines Künstlichen Neuronalen Netzes oder eines SVM-Klassifikators nahm hingegen enorme Rechenressourcen in Anspruch. Ein weiterer Vorteil von Random Forest ist, dass dieser ein realistisches Maß zur Abschätzung des Generalisierungsfehlers liefert, dass bei der praktischen Anwendung als Optimierungskriterium beim Tuning verwendet werden kann. Mit einem Maß zur Quantifizierung der Merkmalswichtigkeit liefert Random Forest des Weiteren eine effiziente Möglichkeit, nicht relevante Merkmale zu identifizieren. Letzlich ist der Algorithmus aufgrund seines Designs sehr gut parallelisierbar. Random Forest ist allerdings nicht deterministisch, was bedeutet, dass ein erlerntes Modell nicht reproduzierbar ist. Für die Entwicklung eines möglichst leistungsfähigen Klassifikators, spielt dieser Aspekt jedoch eine untergeordnete Rolle, da ein erneutes Training nicht zu signifikanten Unterschieden in der Klassifikationsgenauigkeit führt.

Welche Klassifikationsgenauigkeit kann erreicht werden?

Mit einer Genauigkeitsanalyse auf Grundlage einer umfangreichen Referenzdatenbank konnte das entwickelte Verfahren unter Nutzung von Random Forest anhand verschiedener Eingangsdaten und Untersuchungsgebieten bewertet werden (vgl. Kap. 8.5). In einer Gebäudetypologie wurden vorab 11 städtebauliche Gebäudetypen festgelegt, deren Erkennung auf eine kleinräumige Beschreibung und Analyse der Siedlungsstruktur abzielt. Die hier gewonnen Ergebnisse der Genauigkeitsuntersuchung nehmen deshalb immer Bezug auf diese Anwendung.

Bei einer ausreichend großen Trainingsdatenmenge können für die betrachteten Städte Dresden, Halle und Krefeld unter Verwendung von vektorbasierten Gebäudegrundrissen mit Einzelhausmodellierung (Eingangsdatentyp III-V) mit einer Klassifikationsgenauigkeit von über 90 % sehr gute Ergebnisse erzielt werden. Die höchste Genauigkeit wurde mit den 3D-Gebäudestrukturen (Eingangsdatentyp V) von Krefeld mit 94,9 % ±0,3 % ermittelt. Doch auch unter Nutzung von Einzelgebäudegrundrissen ohne semantische Information zur Gebäudefunktion (Eingangsdatentyp III), konnte eine Gesamtgenauigkeit von 90,4 % ±0,6 %

(Dresden) bis 93,6 % ±0,5 % (Krefeld) erzielt werden. Eine differenzierte Betrachtung der einzelnen Klassen zeigt, dass 9 der 11 Klassen mit einer Genauigkeit von über 90 % klassifiziert werden. Die Ergebnisse legen jedoch eine geringere Genauigkeit der ländlichen Hausformen und der Mehrfamilienhäuser offen, die häufig mit freistehenden Ein- und Zweifamilienhäusern verwechselt werden. Für die ATKIS®-Gebäude (Eingangsdatentyp III) von Halle beträgt die Genauigkeit für Ein- und Zweifamilienhäuser 87,4 %, für freistehende Mehrfamilienhäuser 68,0 % und für ländliche Häuser lediglich 61,9 %. Die Gebäudegrundrisse aus topographischen Karten (Eingangsdatentyp I und II) konnten für alle Städte mit einer Gesamtgenauigkeit von über 76 % klassifiziert werden. Die höchste Klassifikationsgenauigkeit von 88,8 % ±0,4 % wurde mit den Gebäuden aus der DTK25 von Halle gemessen. Deren Gebäude wurden ohne Generalisierung aus dem ATKIS® in die DTK25 übernommen. Die Klassifikationsgenauigkeit für Gebäude aus der DTK25-V in alter Kartengraphik (und mit stärkerer Generalisierung) ist deshalb mit 76,6 % ±1,3 um 12 Prozentpunkte geringer als für Gebäude aus der DTK25.

Die Gesamtgenauigkeit der Kleinstadt Stolpen ist mit 67,4 % ±11,5 (DTK25-V) bis 84,2 % ±4,5 (ALK) gegenüber den städtischen Untersuchungsgebieten deutlich geringer. Ähnlich verhält es sich mit den dörflichen Gebieten, die mit einer Genauigkeit von 56,4 % ±7,0 % (DTK25-V) bis 78,7 % ±5,09 % (ALK) klassifiziert werden konnten. Die Ergebnisse der Kleinstadt und des dörflichen Gebietes unterliegen einer sehr großen Varianz, die der geringeren Objektanzahl geschuldet ist, die zum Training und der Validierung zur Verfügung standen. Eine Betrachtung der klassenspezifischen Genauigkeit deckt auf, dass die drei Klassen MFH-F, MFH-EH und LH aufgrund ihrer ähnlichen Morphologie vom Klassifikator häufig verwechselt werden.

Die Ergebnisse der Genauigkeitsuntersuchung sind nur schwer mit den Ergebnissen anderer Autoren vergleichbar, da unterschiedliche Datengrundlagen, Untersuchungsgebiete, Trainingsmengen, Gebäudetypologien oder Validierungsverfahren zugrundeliegen. Steiniger et al. (2008) erreichten mit einer SVM eine Klassifikationsgenauigkeit von 82 % (Kappa 0,73) für 5 Gebäudetypen. Allerdings wurden ausschließlich Gebäudegrundrisse und daraus abgeleitete morphologische Merkmale verwendet. Eine gegenüber den eigenen Ergebnissen vergleichbare Genauigkeit erhielten Henn et al. (2012), auch wenn diese zusätzliche infrastrukturelle Informationen aus OSM während der Erkennung nutzten. Mit einer SVM erreichten sie für 3D-Gebäude von Bonn eine Genauigkeit von 90,8 % (1 227 Trainingsobjekte, 7 Gebäudetypen). Für die Klassifizierung der 3D-Gebäudemodelle von Krefeld (allerdings mit Nutzungsinformation) mit Random Forest konnte in der eigenen Arbeit (vgl. Anlage D.2.4) eine Genauigkeit von 90,1 % gemessen werden (1 250 Trainingsobjekte, 11 Klassen).

Welche Faktoren haben Einfluss auf die Klassifikationsgenauigkeit?

Die Genauigkeit einer automatischen Klassifizierung ist von verschiedenen Einflussfaktoren abhängig: der verwendeten Datengrundlage und deren Qualität (Eingangsdatentyp), dem Siedlungstyp und der Trainingsdatenmenge.

Eingangsdatentyp: Den wichtigsten Einfluss auf die Klassifikationsgenauigkeit haben die verwendeten Datengrundlagen, da sich diese im Informationsgehalt und Generalisierungsgrad unterscheiden. Die Ergebnisse des Vergleiches nach dem Eingangsdatentyp zeigen,

dass die Gesamtgenauigkeit von Eingangsdatentyp I bis V stetig zunimmt (vgl. Kap. 8.5.4). Die Klassifikationsgenauigkeit erhöht sich dabei mit der zur Verfügung stehenden Information, die dem Klassifikator mittels numerischer Merkmale bereitgestellt werden kann. Die kontinuierliche Zunahme der Genauigkeit trifft prinzipiell auch auf die klassenspezifische Genauigkeit zu, wobei die Zunahme der Genauigkeit von Eingangsdatentyp IV zu V nur marginal ist. Öffentliche Gebäude werden für alle Eingangsdatentypen in annähernd gleicher Qualität klassifiziert, da das Merkmal zur Flächennutzung aus dem ATKIS® Basis-DLM für alle Eingangsdatentypen zur Verfügung steht. Bei analogen topographischen Rasterkarten hängt die Genauigkeit jedoch auch letztendlich von der zugrundeliegenden Qualität der Rasterprodukte und dem Grad der Generalisierung ab.

Siedlungstyp: Für alle drei städtischen Untersuchungsgebiete konnten vergleichbare Genauigkeiten festgestellt werden. Bei Nutzung der ATKIS-Gebäude war die Genauigkeit beispielsweise 93,6 % (Krefeld), 91,8 % (Halle) und 90,4 % (Dresden) und für die DTK25-V 78,9 % (Dresden), 76,6 % (Krefeld) und 76,6 % (Halle). Es kann demnach vermutet werden, dass für andere deutsche Städte vergleichbare Genauigkeiten erzielt werden können. Für die Kleinstadt Stolpen und die ländlichen Gebiete waren die gemessenen Genauigkeiten deutlich geringer, was allerdings auch durch die kleinere Trainingsdatenmenge begründet ist. Ein Vergleich annähernd gleichgroßer Trainingsdatensätze zeigte für ländliche Gebiete eine um 20 Prozentpunkte geringere Klassifikationsgenauigkeit gegenüber den städtischen Gebieten.

Trainingsdatenmenge: Die Trainingsmenge hat einen sehr großen Einfluss auf das Klassifikationsergebnis. Schon während der Modellselektion konnte durch Variation der Trainingsdatenmenge gezeigt werden, dass die Gesamtgenauigkeit mit dieser stetig zunimmt und gegen die Genauigkeit konvergiert, die bei theoretisch unendlicher Trainingsdatenmenge erreicht wird (vgl. Kap. 8.4.3.2). Am Beispiel der ATKIS-Gebäude von Halle reichen 625 Objekte, um einen Klassifikator mit einer Genauigkeit von etwa 80 % zu trainieren. Stehen 2 500 Trainingsobjekte zur Verfügung, so können bereits über 85 % der Gebäude richtig klassifiziert werden. Bei Nutzung von 10 000 Trainingsobjekten wurde hingegen eine Genauigkeit von ca. 90 % erreicht. Auch eine Betrachtung der klassenspezifischen Genauigkeit zeigte am ATKIS-Datensatz von Halle, dass ab einer Anzahl von 350 Trainingsobjekten pro Klasse, alle Klassen mit einer Herstellergenauigkeit von mindestens 70 % klassifiziert werden. Prinzipiell gilt „je mehr Trainingsdaten desto besser". Dennoch zeigt sich mit der Analyse, dass die Zunahme der Genauigkeit einzelner Klassen mit unterschiedlicher Geschwindigkeit (Konvergenzgeschwindigkeit) erfolgt. Für Gebäudeklassen mit geringem Genauigkeitszuwachs in der Herstellergenauigkeit sind offenbar weniger Trainingsobjekte ausreichend als für Klassen, deren Genauigkeit mit der Trainingsdatenmenge in starkem Maße zunimmt. Die Mindestanzahl an Trainingsobjekten hängt immer von der Genauigkeitsanforderung und der Zielstellung der Klassifizierung ab und kann nicht pauschal angegeben werden. Es muss dabei berücksichtigt werden, dass die Erhebung der Trainingsdaten mit hohen Kosten verbunden ist. In der Praxis gilt es im konkreten Fall abzuwägen, welche Genauigkeit ausreichend ist und ob eine Erhebung weiterer Trainingsdaten zur Verbesserung der Klassifizierung aus ökonomischer Sicht Sinn macht.

Ist ein erlernter Klassifikator übertragbar?

Die Frage nach der Übertragbarkeit spielt in der Praxis eine bedeutende Rolle, da die Erhebung von Trainingsdaten in der Regel mit großem zeitlichen Aufwand, Expertise und hohen Kosten verbunden ist. In einer Untersuchung wurde deshalb die Übertragbarkeit eines erlernten Klassifikators erprobt. Die Experimente zeigen, dass eine Klassifizierung von Gebäudegrundrissen einer Stadt mit einem auf Grundlage einer anderen Stadt trainierten Klassifikator nur dann gut funktioniert, wenn die Städte durch ähnliche städtebauliche Muster der Bebauungsstruktur gekennzeichnet sind. Dies stellten auch Steiniger et al. (2008) fest, die einen Klassifikator anhand des Gebäudedatensatzes von Zürich (Schweiz) erlernten und auf die Stadt Southampton (England) anwendeten. Sie kamen dabei zum Schluss, dass man Gebäudedaten eines Landes nur mit Trainingsdaten des jeweiligen Landes klassifizieren kann. Die eigenen Ergebnisse zeigen jedoch, dass selbst innerhalb eines Landes große regionale Unterschiede vorliegen, die offenbar mit regional unterschiedlichen Baukulturen und städtebaulichen Entwicklungen zusammenhängen. Darum kann ein erlernter Klassifikator nur auf Siedlungsgebiete der gleichen baukulturhistorischen Region angewendet werden. Für eine deutschlandweite Anwendung des Verfahrens bedeutet es, dass eine regionale Differenzierung der Landesfläche und der Erhebung von Trainingsdaten in diesen Regionen nötig ist (siehe Ausblick in 0). Eine regionale Abgrenzung und Typisierung könnte beispielsweise auf Grundlage von Siedlungsatlanten oder mit geeigneten quantitativen Verfahren des Data-Minings oder der Geostatistik erfolgen.

Wie kann das Verfahren flexibel gehalten werden?

Wissensbasiert konstruierte Klassifikationsmodelle haben den Nachteil, dass diese bei Änderung des Problemkreises (z. B. andere Fragestellung und Gebäudetypologie, anderes Untersuchungsgebiet oder andere Eingangsdaten) unflexibel und nur schwer übertragbar sind. Für jede Änderung wäre die Konstruktion eines neuen Modells nötig. Ontologiebasierte Ansätze in Kombination mit maschinellen Lernverfahren sind ein guter Schritt in Richtung Interoperabilität, allerdings fehlt es bisher an genügend Wissen, die städtischen Konzepte in Merkmalen zu formalisieren. Eine ontologiebasierte Beschreibung konnte bisher nur für einfach zu formalisierende Gebäudetypen (z. B. Reihenhäuser) realisiert werden (Lüscher et al., 2009). Mit dem Einsatz überwachter maschineller Lernverfahren kann ein Beitrag zur Erhöhung der Flexibilität geleistet werden, da der Modellaufbau von einem Automaten übernommen wird. Für gängige Eingangsdaten wurde ein umfangreiches Merkmalsset definiert und ein Klassifikationsverfahren gewählt, welches auch eine Verarbeitung redundanter bzw. irrelevanter Information erlaubt. Es ist daher möglich, eine neue Gebäudetypologie zu definieren und das Merkmalsset individuell zu erweitern. Mit dieser Flexibilisierung kann das Verfahren für verschiedene Aufgabenstellungen anwendbar gemacht werden. Mit genauer Spezifikation der Eingangsdaten werden hingegen Wege eröffnet, das Verfahren auch auf andere Länder zu übertragen, in denen vergleichbare Datensätze zum Gebäudegrundriss, dem Baublock oder den Hauskoordinaten vorliegen.

9.2 Praktische Bedeutung

Im Folgenden wird auf die praktische Bedeutung der Ergebnisse und des entwickelten Verfahrens sowie potenzielle Anwendungen, die sich daraus ergeben, eingegangen.

9.2.1 Bedeutung der Ergebnisse für die Praxis

Die Ergebnisse der Arbeit zeigen, dass eine automatische Klassifizierung von Gebäudegrundrissen für die kleinräumige Beschreibung der Siedlungsstruktur möglich ist. Eine Validierung des Ansatzes, differenziert nach Eingangsdaten, Siedlungstypen und der Trainingsdatenmenge, lässt erstmals Rückschlüsse auf die zu erreichende Genauigkeit unter verschiedenen Randbedingungen zu. Mit einer systematischen Unterscheidung nach Eingangsdatentypen können Schlussfolgerungen auf alle flächendeckend verfügbaren Datengrundlagen zum Gebäudegrundriss gezogen werden, auch für die, die in dieser Arbeit nicht explizit untersucht wurden. So sind beispielsweise ähnliche Ergebnisse bei der Genauigkeitsanalyse auf Grundlage der vektorbasierten Gebäudegrundrisse ohne semantische Information (Eingangsdatentyp III) sowohl für Gebäude aus dem ATKIS®, für amtliche Hausumringe als auch, bei entsprechender Vollständigkeit und Datenqualität, für OSM-Gebäude zu erwarten. Eine derartige Verallgemeinerung ist jedoch nur möglich, wenn die Standards hinsichtlich der Semantik und Geometrie in den Daten tatsächlich eingehalten werden.

Bei der photogrammetrischen und fernerkundlichen Erfassung der Flächenbedeckung und Flächennutzung wird eine Genauigkeit von mindestens 85 % verlangt (Anderson et al., 1976). Diese Genauigkeitsanforderung wird für die betrachteten Städte Dresden, Halle und Krefeld bei der Nutzung von vektorbasierten Gebäudegrundrissen mit Einzelgebäudemodellierung überboten. Hausumringe, Gebäude aus dem ATKIS, der ALK, dem ALKIS oder auch 3D-Gebäudemodelle sind damit eine ausgezeichnete Datengrundlage für das Verfahren. Allerdings stehen diese neuen vektorbasierten Gebäudegrundrisse für die Planung, Politik und Wissenschaft oft nicht zur Verfügung. Gebäude, die aus rasterbasierten topographischen Karten gewonnen werden, bieten in diesem Fall eine kostengünstige Alternative. Die geringere Klassifikationsgüte von ca. 75 % lässt allerdings nur einen Einsatz für mittelmaßstäbige Anwendung zu, wie etwa zur Ableitung von Bebauungsstrukturtypen auf Baublockebene oder die Modellierung planungsunterstützender Kennzahlen für die überörtliche Planung.

9.2.2 Werkzeug für die Wissenschaft und Praxis

Mit dem entwickelten Verfahren wird ein potenzielles Werkzeug für die Wissenschaft und Praxis vorgestellt, das für verschiedene Aufgabenfelder eingesetzt werden kann. Auch wenn dieses aktuell noch prototypischen Charakter besitzt, so lassen sich die unter R und HALCON implementierten Modelle leicht in ein GIS einbinden (vgl. Kap. 7.10.2).

Eine Möglichkeit, das entwickelte Verfahren für der Wissenschaft und Praxis zugänglich zu machen, wäre beispielsweise die Einbettung in Form einer nutzerfreundlichen ArcGIS Extension. In einem fiktiven Anwendungsszenario bräuchte der Nutzer lediglich entsprechende Eingangsdaten (Gebäudegrundrisse, Baublöcke und Hauskoordinaten) und für das Untersuchungsgebiet entsprechend repräsentative Trainingsdaten laden. Die Typologie wäre implizit durch ein Attribut in den Trainingsdaten gegeben. Bereits beim Einladen könnte der Nutzer gewarnt werden, wenn zu wenige Trainingsdaten einer Klasse vorhanden sind. Die Merkmalsberechnung könnte vollautomatisch ablaufen. In einen optionalen Nutzereingriff könnte jedoch auch nur eine Teilmenge zu berechnender Merkmale aus einer gegebenen Liste ausgewählt werden. Der Trainingsprozess wird durch den Nutzer gestartet und enthält eine automatische Merkmalsselektion. Nach dem Trainingsprozess wird der Nutzer über die zu erwartende Klassifikationsgenauigkeit informiert und ihm bleibt die Wahl, den erlernten Klassifikator zu akzeptieren oder, bei unzureichender Genauigkeit, Maßnahmen zur Genauigkeitssteigerung zu ergreifen. Der Nutzer könnte dafür im GIS weitere Trainingsdaten für „problematische" Gebäudetypen erheben oder zusätzliche Informationen in Form von Merkmalen bereitstellen. Nach Akzeptanz der zu erwartenden Genauigkeit könnte der Nutzer anschließend den erlernten Klassifikator auf das gesamte Untersuchungsgebiet anwenden und speichern. Mit einer derartigen Implementierung bietet das Verfahren ein breites Anwendungsspektrum für die Wissenschaft und Praxis.

9.2.3 Potenzielle Anwendungen

Das entwickelte Verfahren kann für verschiedene Anwendungen in der Raum- und Fachplanung auf unterschiedlichen Ebenen (Stadt-/Kommunalplanung, Regionalplanung, Landesplanung sowie Bundesraumordnung), den Raumwissenschaften sowie in der Wirtschaft und Politik eingesetzt werden. Im Folgenden werden einige Beispiele gegeben.

Mit Blick auf die stadtplanerische Ebene werden insbesondere Indikatoren zur baulichen Nutzung (Überbauungsgrad, Geschossflächendichte, Gebäudevolumen) oder der Wohnungs- und Einwohnerverteilung benötigt. Durch eine automatische Klassifizierung von Gebäudegrundrissen als integrativer Bestandteil einer gebäudebasierten Siedlungsstrukturanalyse wird eine kleinräumige Abschätzung dieser Kennzahlen möglich. Die Abb. 9-1 zeigt klassifizierte Gebäude von Krefeld sowie die unter gebäudetypischen Annahmen modellierte Einwohnerzahl. Wie diese und weitere Informationen abgeleitet, aggregiert und visualisiert werden können, wird exemplarisch am Beispiel der Daten von Krefeld im Anhang F.1 dargestellt.

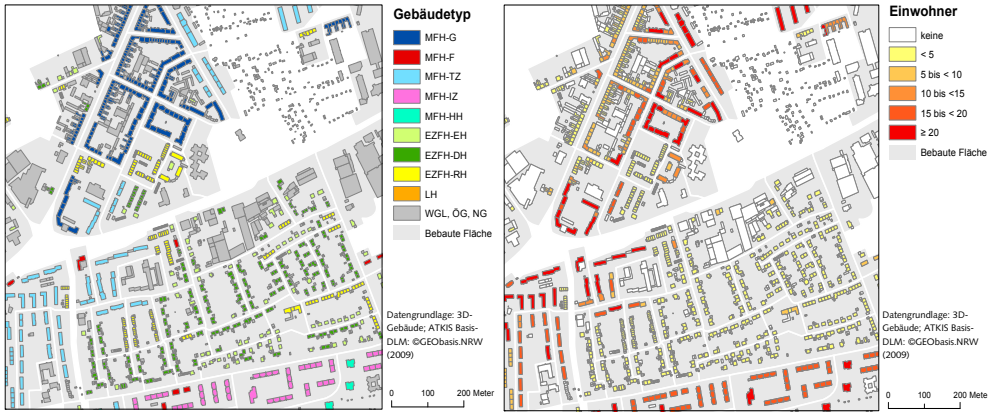

a) b)

Abb. 9-1: Modellierung gebäudebezogener Einwohner am Beispiel von Krefeld auf Grundlage der 3D-Gebäudestrukturen: a) Klassifizierte Gebäudegrundrisse und b) Einwohner pro Gebäude (Quelle: Eigene Darstellung)

Mithilfe dieser gewonnenen Informationen können Bedarfe und Standorte (z. B. Infrastruktureinrichtungen, gewerbliche Nutzungen, Sport- und Freizeitangebote) geplant sowie Betroffenheiten bei konkreten Planungsvorhaben (z. B. Lärmbelastung, Luftschadstoffbelastung) modelliert und bewertet werden. Daten zur Gebäude- oder Einwohnerverteilung spielen dabei auch für lokale Risikoabschätzungen (Flugsicherheit, Sicherheit bei Großveranstaltungen, Hochwasser, Erdbeben, Tornados) eine bedeutende Rolle. Durch Kombination der gebäudebezogenen Daten mit Gefahrenkarten können beispielsweise Informationen für den Katastrophenschutz oder die Gefahrenabwehr abgeleitet werden.

Auf regionalplanerischer Ebene sind kleinräumige Daten von besonderem Interesse, da den Akteuren dieser Ebene nur selten siedlungsstrukturbeschreibende Informationen unterhalb der Gemeindeebene zur Verfügung stehen. Diese werden für die überörtliche Planung, wie z. B. die Infrastrukturplanung (Verkehrstrassenplanung, Versorgung, ÖPNV) oder die Standortplanung (z. B. Windkraftanlagen, Gewerbeflächen), benötigt.

Auf Landes- und Bundesebene spielen hingegen Kennzahlen eine Rolle, um bundespolitische Ziele einer nachhaltigeren Siedlungsentwicklung (z. B. Flächenverbrauchsreduktion, Nachverdichtung) oder Klimaschutzziele (z. B. CO_2-Senkung, Energieverbrauchsreduktion durch Gebäudesanierung) umsetzen zu können. Monitoringsysteme gewinnen in diesem Zusammenhang eine immer größere Bedeutung, da sie Informationen über Zustand und Intensität der Flächennutzung liefern und zur Bewusstseinsschärfung gegenüber den Auswirkungen von Entwicklungstrends beitragen (Fina, 2011). Das Klassifikationsverfahren könnte dabei ein wichtiger Baustein für eine landes- bzw. bundesweite Analyse der Siedlungsstruktur werden. Mit dem webbasierten Informationssystem „Monitor der Siedlungs- und Freiraumentwicklung“ (www.ioer-monitor.de) werden bereits kleinräumige Informationen zur Nachhaltigkeit von Siedlungen und deren Entwicklung angeboten. Durch Integration des Verfahrens könnten räumlich und semantisch hochauflösende Informationen zur Siedlungsstruktur und, bei kontinuierlicher Beobachtung, deren Entwicklung gewonnen

werden. Als Datengrundlage eignen sich dafür die amtlichen Hausumringe am besten, da diese flächendeckend homogenisiert vorliegen und zentral angeboten werden. Eine deutschlandweite Klassifizierung aller Hausumringe nach städtebaulichen Kriterien hätte einen besonderen Reiz, da eine viel differenziertere Sicht auf den gesamten Wohngebäudebestand von Deutschland möglich wäre, die mit Daten der amtlichen Statistik nicht abgebildet wird. Aggregierte Zahlen zur Gebäudestruktur (Gebäudefläche, -anzahl und -volumen nach Gebäudetyp) auf Gemeinde- oder Kreisebene liefern – ergänzend zur Statistik – wichtige Informationen für die Raumbeobachtungen im kleinen Maßstab. Da das Verfahren lediglich wenige Daten benötigt, eröffnen sich perspektivisch auch Anwendungen auf europäischer Ebene. Hierzu wäre jedoch eine Operationalisierung des Klassifikationsverfahrens unter Nutzung einer INSPIRE-konformen Gebäudetypologie (INSPIRE, 2011b) nötig. Als Bezugsgrundlage für grenzüberschreitende Analysen könnte das europaweit einheitlich festgelegte Geographische Gittersystem genutzt werden (INSPIRE, 2011a).

Auch im Hinblick auf den demographischen und klimatischen Wandel werden siedlungsstrukturelle Daten als integrativer Bestandteil komplexer Modellierungen von Szenarien benötigt. Das Verfahren liefert deshalb für die Beantwortung gesellschaftsrelevanter Fragen einen Beitrag, da damit räumlich vergleichbare Datengrundlagen für verschiedene Modellierungen bereitgestellt werden können, u. a. zur Bewertung der Ressourceneffizienz von Siedlungsstrukturen, Stoffstromanalysen, der Modellierung von CO_2-Vermeidungs- und Energieeinsparpotenzialen oder zur Abschätzung von Infrastrukturkosten bei Bevölkerungsabnahme. Mithilfe klassifizierter Gebäudegrundrisse könnten räumlich viel differenziertere Aussagen getroffen werden. Die bisherigen regionalisierten Schätzungen auf Grundlage konstruierter Mengengerüste, die auf der amtlichen Gebäudestatistik basieren, lassen diese aktuell nicht zu.

Für die quantitative Stadtforschung sind diese Daten ebenso relevant, um Theorien und Modelle der Stadtgeographie mithilfe der räumlichen Analyse, Statistik und Visualisierung im GIS zu überprüfen und Prozesse innerhalb und zwischen Siedlungen (Suburbanisierung, Zersiedlung) zu untersuchen. Durch Kombination mit anderen Daten können beispielsweise Zusammenhänge zwischen der morphologischen und der funktionalen bzw. sozialräumlichen Struktur weiter untersucht werden (Herold M. et al., 2003; Meinel et al., 2009; Smith & Crooks, 2010). Doch auch für die Analyse und den Vergleich von Flächennutzungsstrukturen unterschiedlicher Städte (Thinh, 2002; Winkler & Meinel, 2003) liefert das Verfahren eine effiziente Möglichkeit zur automatisierten und objektiven Erfassung der Siedlungsstruktur.

Doch auch bei der Entwicklung von Geo-Simulationsmodellen (z. B. Verkehr, Pendlerverhalten) werden Bestandsdaten zur Siedlungsstruktur benötigt. So werden kleinräumige Daten für die Modellierung zukünftiger Ereignisse oder Szenarien der Stadtentwicklung eingesetzt, wie etwa beim Einsatz computergestützter Planungs- und Entwurfsmethoden (Streich, 2011) oder mikroskaliger Simulationstechniken mit UrbanSim (Waddell et al., 2003; Schirmer, 2010; Schirmer et al., 2011). Für eine Simulation von Siedlungsdynamiken (Thinh, 2006) oder Verdichtungsprozessen (Curie et al., 2010) werden allerdings auch Daten der

Vergangenheit benötigt. Derartige Daten könnten durch eine multitemporale Auswertung von Gebäudegrundrissen aus topographischen Karten generiert werden.

Die Arbeit liefert auch einen Beitrag für die Thematische Kartographie (Stadtkartographie), in dem es möglich wird, thematische Karten aus topographischen Datenbanken automatisch abzuleiten. Da die Gebäude aufgrund ihrer geringen Dimension ab einem Maßstab von 1: 25 000 und kleiner zwar noch dargestellt, aber nicht mehr qualitativ in ihrer Fläche eingefärbt werden können, sind Abstraktions- und Generalisierungsprozesse nötig. Eine Möglichkeit ist es, die Information zum Gebäudetyp auf Baublock- oder Rasterebene abzubilden. Damit kann die Bebauungsstruktur auch in kleineren Maßstäben kartographisch dargestellt werden. Das Ergebnis der automatischen Ableitung ist an einem Ausschnitt von Dresden in Abb. 9-2 dargestellt. In der Anlage F wird die Vorgehensweise unter Einsatz des entwickelten Verfahrens BFClassTool vorgestellt und ausgewählte Ergebnisse exemplarisch am Beispiel von Dresden und seiner Umlandregion in Karten visualisiert.

Aus dem Bereich der freien Wirtschaft bieten sich weitere Anwendungsfelder. Private Planungsbüros oder Unternehmen benötigen raumbezogene Daten zur Siedlungsstruktur in Kombination mit anderen Daten, um thematische Karten zu generieren, die Grundlage unternehmerischer Entscheidungen bilden. Diese neue Branche des „Geomarketing" unterstützt unternehmerische Prozesse der Risikoanalyse, Marketing-Planung, Mediaplanung, Marktanalyse, Vertriebscontrolling, Kundenlokalisierung etc. (Freckmann, 2009). So benötigen beispielsweise Mobilfunkunternehmen bei der Funknetzplanung u. a. Informationen zur Bebauung (Gebäudemodelle mit Höhe) oder zur räumlichen Verteilung der Bevölkerung. Auch Energieversorgungsunternehmen sind auf kleinräumige Informationen über die Lage und Anzahl der Haushalte für eine Wärme- bzw. Energiebedarfsmodellierung (Wärmebedarfskarten) angewiesen. In der Immobilienwirtschaft sind hingegen Informationen zum Gebäudetyp, zur Haushaltsbelegung und zur Bevölkerungsstruktur für Wohnungsmarktanalysen und -prognosen interessant. Ein weiteres Beispiel für eine potenzielle Nutzung gebäudebezogener Informationen sind Versicherungsunternehmen, die mithilfe von Modellen Schadenspotenziale an Gebäuden im Falle extremer Naturereignisse berechnen können. Auch für die Verwaltung, Analyse und Visualisierung dieser mehrdimensionalen raumbezogenen Geomarketing-Daten spielen Rasterbezüge eine immer größere Rolle (Dickmann & Sohst, 2008).

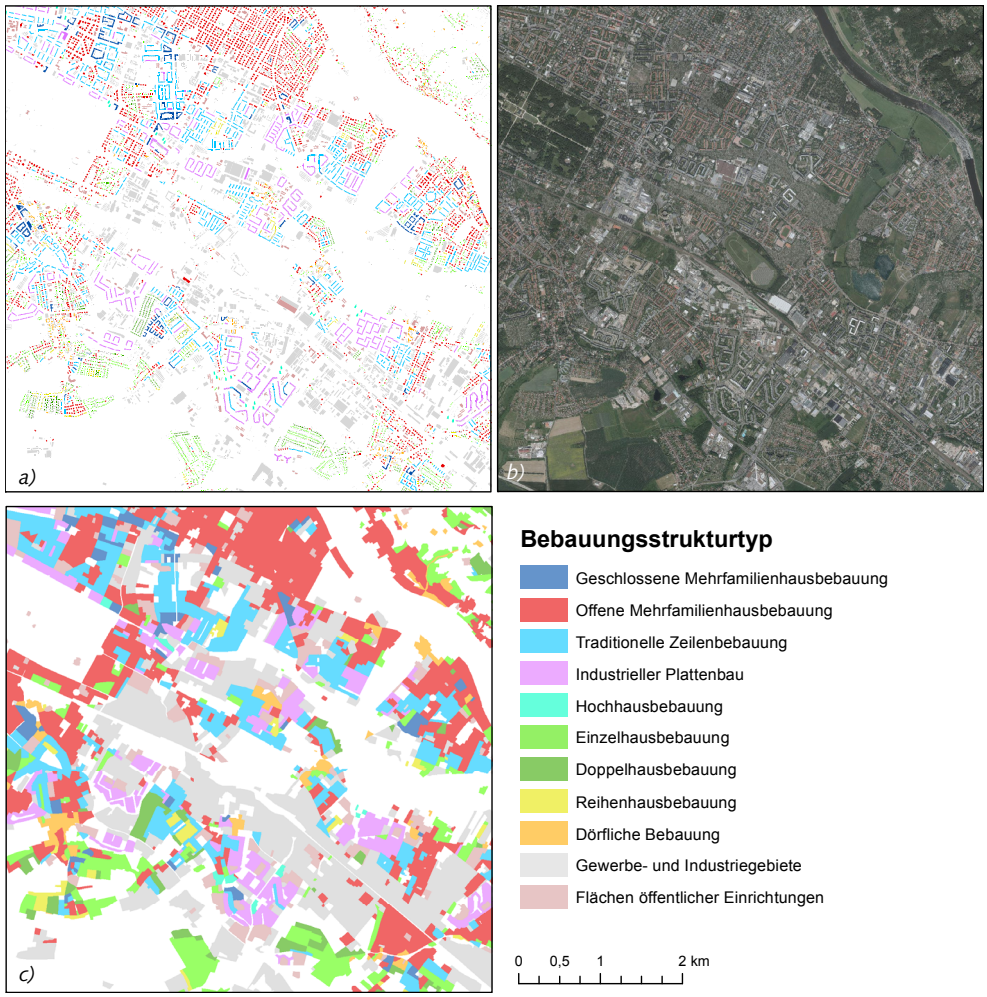

Abb. 9-2: Ableitung von Bebauungsstrukturtypen mittels Flächendominanzprinzip am Beispiel des ALK-Datensatzes von Dresden: a) klassifizierte Gebäudegrundrisse b) Ortholuftbild und c) Bebauungsstrukturtyp auf Baublockebene (Quelle: Eigene Darstellung; Datengrundlage: DOP40/ATKIS® Basis-DLM ©GeoBasis-DE / BKG (2010), ALK © GeoSN Sachsen, (2008))

9.3 Ausblick

Das entwickelte Verfahren wurde bisher anhand topographischer Rasterkarten, 2D-Gebäudegrundrissen und 3D-Gebäuden im LoD1 getestet. In Zukunft ist jedoch mit einer flächendeckenden Verfügbarkeit von 3D-Stadtmodellen im LoD2 zu rechnen (AdV, 2010c). Mit der Modellierung der Dachform stünde dann eine weitere nützliche Information flächendeckend zur Verfügung, die dem zu erlernenden Klassifikator in Form eines Merkmals mitgegeben werden kann. Es wird vermutet, dass durch Nutzung dieser Information eine höhere Klassifikationsgenauigkeit erzielt werden kann, da städtebauliche Gebäudetypen in der Regel auch durch eine spezifische Dachform charakterisiert sind.

Das bisherig erarbeitete Merkmalsset könnte um weitere Merkmale erweitert werden. Dazu gehören beispielsweise bisher nicht genutzte Merkmale, wie etwa die Anzahl der Vertizes pro Gebäude oder auch strukturelle Merkmale zur Beschreibung einer Gebäudegruppe, in dem sich das Gebäude befindet. Auch weitere kontextbeschreibende Merkmale, wie z. B. der Abstand zum Stadtzentrum oder zur Stadtgrenze, könnten eingeführt werden.

In weiteren Untersuchungen könnte auch geprüft werden, ob die Integration zusätzlicher Daten die Klassifikationsleistung weiter verbessert. Eine bisher unberücksichtigte, aber aus stadtmorphologischer Sicht wichtige Geometrie ist beispielsweise das Flurstück bzw. deren Grenze. Diese kann aus der Liegenschaftskarte (ALKIS®, ALK) entnommen und für die Berechnung weiterer kontextueller Merkmale hinzugezogen werden. Neben weiteren Geometrien könnten auch semantische Informationen integriert werden, wie z. B. Informationen zum Straßentyp oder Gewerbe- und Infrastruktureinrichtungen in der Umgebung (Bushaltestellen, Bahnhof, Gewerbe etc.). Als Datenquelle kommen dafür weitere Objektbereiche des ATKIS® Basis-DLM, nutzergenerierte Daten wie Open Street Map oder Firmendaten (z. B. Handelsregisterdaten, Daten des Geomarketings) in Frage. Hierzu müssen jedoch geeignete Konzepte der Datenintegration erarbeitet werden.

Eine weitere Möglichkeit, zusätzliche Merkmale einzubinden, verspricht die Datenfusion mit Bilddaten. So könnten aus Fernerkundungsdaten (Luftbilder, Satellitenbilder, Hyperspektraldaten, Laserscannerdaten, Schrägluftbilder) abgeleitete Merkmale (z. B. radiometrische Merkmale, Texturmaße, Höhe etc.) in den Klassifikationsprozess integriert werden. Insbesondere Informationen zur Bodenbedeckung, dem Dachmaterial, dem Versiegelungsgrad und der Vegetationsausstattung in unmittelbarer Umgebung liefern möglicherweise wichtige Informationen, die den Erkennungsprozess unterstützen. In diesem Zusammenhang stellen auch terrestrische Gebäudeaufnahmen und Schrägluftbilder eine potenzielle Informationsquelle dar, da mit diesen Daten die Fassadenstruktur in Beschaffenheit und Stil beschrieben werden könnte (Ripperda, 2010; Drauschke, 2011; Becker, 2011).

Bisher wurde das Verfahren anhand einer einzigen Gebäudetypologie getestet. Um die Flexibilität zu eruieren, sollte der Einsatz für weitere Anwendungen und Untersuchungsgebiete, die eine andere Gebäudetypologie verlangen, getestet werden. So könnte beispielsweise die Klassifizierung nach charakteristischen Gebäudeformtypen (u. a. Rainsford & Mackaness, 2002) untersucht werden, die in der automationsgestützten Generalisierung eine wichtige Rolle spielen. Denkbar wäre auch der Versuch, die aktuell entwickelte Gebäudetypologie weiter nach Baualtersperioden auszudifferenzieren und zu prüfen, wie gut diese Typen mit-

hilfe der definierten Merkmale erlernt werden können. Des Weiteren könnte eine Klassifizierung der Gebäude aus energetischer Sicht untersucht werden, wie etwa nach den Wohngebäudetypen der deutschen Gebäudetypologie (Loga et al., 2011) oder denen anderer europäischer Länder[90] (TABULA, 2010). Von großem Interesse wäre auch eine feinere Differenzierung des Nichtwohngebäudebestandes nach morphologischen oder funktionalen Gesichtspunkten (Dirlich et al., 2011). Gelänge dies, könnten Verteilungen von Arbeitsplätzen modelliert werden. Des Weiteren könnte die Übertragbarkeit des Verfahrens auf Städte anderer Länder getestet werden, für die eine andere Gebäudetypologie zugrundeliegt. In Europa stehen in der Regel vergleichbare Daten und topographische Karten zur Verfügung, die für eine automatische Klassifizierung genutzt werden können.

Bisher wurde das entwickelte Verfahren lediglich bezüglich der Klassifikationsgenauigkeit bewertet. Für eine Bewertung im Hinblick auf eine konkrete Anwendung, wie etwa der Ableitung verschiedener Indikatoren zur Siedlungsstruktur, sollten in einem nächsten Schritt die ermittelten Zielgrößen (z. B. Geschossflächen, Wohnungen, Einwohner) evaluiert werden. Ein Vergleich abgeleiteter Kennzahlen auf Stadtebene zeigte bereits, dass Wohnungen und Einwohner mithilfe der klassifizierten Gebäudegrundrisse mit hinreichender Genauigkeit geschätzt werden konnten. Für eine Quantifizierung des Schätzfehlers der aggregierten Kennzahlen wäre jedoch eine Validierung auf Grundlage kleinräumiger Referenzdaten (z. B. Kommunalstatistik auf Baublockebene) nötig. Es könnte dann auch untersucht werden, welchen Einfluss die Klassifikationsgenauigkeit und die gebäudetypischen Annahmen (z. B. zur Geschosszahl, Geschosshöhe, Wohnungsgröße) auf die berechneten Kennzahlen haben.

Die Ergebnisse der Arbeit zeigen, dass eine Übertragbarkeit eines erlernten Klassifikators überregional nur eingeschränkt möglich ist. Für großflächige Anwendungen müssen darum geeignete Strategien zur Überwindung regionaler Unterschiede erarbeitet werden. Eine Lösung wäre eine Abgrenzung homogener Regionen mit ähnlichen baukulturhistorischen Eigenschaften und die Erhebung von Trainingsdaten für jede Region. Die regionale Abgrenzung könnte auf Grundlage von Vorwissen unter Nutzung von Literatur (Siedlungsatlanten, Untersuchungen zur Siedlungs- und Baugeschichte) und der Beachtung der städtebaulichen Charakteristik der Siedlung erfolgen. In diesem Zusammenhang könnte aber auch der Einsatz von Verfahren des Urban Data Mining (Behnisch, 2009) untersucht werden. Eine weitere offene Frage bezieht sich auf die Strategie bei der Erfassung von Lerndaten (Samplingstrategie). Es bleibt zu klären, ob ein einziger, sehr komplexer Klassifikator für mehrere Regionen erlernt werden kann, oder ob für jede Region das Erlernen eines eigenen Klassifikators nötig ist. Da viele Trainingsdaten nötig sind, sollte auch der Einfluss der Trainingsdatenmenge detaillierter als bisher untersucht werden. Um den Aufwand der Erhebung von Trainingsdaten zu reduzieren, könnte auch ein semi-automatisches Verfahren zur Erzeugung von Trainingsdaten (Henn et al., 2012) in Betracht gezogen werden.

[90] Siehe hierzu auch die Internetpräsenz des europäischen Projektes zur Entwicklung harmonisierter Gebäudetypologien (www.building-typology.eu).

Mit der Referenzdatenbank steht eine sehr umfangreiche Datenbank zur Verfügung, die weitere Untersuchungen hinsichtlich des entwickelten Klassifikators zulässt. So könnte beispielsweise durch simuliertes Rauschen der Einfluss von Fehlern in den Trainingsdaten untersucht werden. Auch könnte die Messung der Merkmalswichtigkeit vertieft werden, in dem diese durch eine paarweise Klassifizierung ermittelt wird. Dies erlaubt dann eine Quantifizierung der Bedeutung jedes Merkmals in Bezug auf jede Klasse. Mit der Referenzdatenbank können auch neue Klassifikationsverfahren getestet werden, wie etwa der Fuzzy-Random-Forest-Algorithmus (Bonissone et al., 2010).

Im Hinblick auf eine weitere Operationalisierung für großflächige Analysen der Siedlungsstruktur wäre die Implementierung in der ArcGIS Extension Settlement Analyzer (kurz: SEMENTA®) denkbar. SEMENTA® diente bisher der automatischen Ableitung siedlungsstruktureller Kennzahlen auf Grundlage topographischer Karten unter Nutzung eines wissensbasierten Regelwerkes. Mit Implementierung des entwickelten Klassifikationstools stünde ein flexibleres Werkzeug für eine automatisierte Beschreibung und Analyse der Siedlungsstruktur bereit.

Literatur

Adler, J. (2010): R in a Nutshell. 1. Aufl., O'Reilly Media.

AdV (2006): Erläuterungen zu ATKIS® Basis-DLM - Version 5.1. AdV Online. Download am 21.12.2012 via http://www.adv-online.de/AAA-Modell/Dokumente-der-GeoInfoDok/Aeltere-Versionen/GeoInfoDok-5-1-Vollversion/

AdV (2008a): 60 Jahre AdV. Tätigkeitsbericht 2007/2008, Hannover: AdV-Geschäftsstelle.

AdV (2008b): ALKIS-Objektartenkatalog - Version 6.0. AdV Online. Download am 11.12.2012 via http://www.adv-online.de/AAA-Modell/Dokumente-der-GeoInfoDok/

AdV (2008c): ATKIS-Objektartenkatalog für das Digitale Basis-Landschaftsmodell (ATKIS - OK Basis DLM) - Version 6.0. AdV Online. Download am 11.03.2013 via http://www.adv-online.de/AAA-Modell/Dokumente-der-GeoInfoDok/

AdV (2008d): Erläuterungen zu ALKIS® - Version 6.0. AdV Online. Download am 11.12.2012 via http://www.adv-online.de/AAA-Modell/Dokumente-der-GeoInfoDok/

AdV (2008e): Erläuterungen zum ATKIS® - Version 6.0. AdV Online. Download am 21.12.2012 via http://www.adv-online.de/AAA-Modell/Dokumente-der-GeoInfoDok/

AdV (2010a): Produktblatt ATKIS - Digitale Topographische Karte 1:10 000 (DTK10). AdV Online. Download am 03.12.2012 via http://www.adv-online.de/AdV-Produkte/Geotopographie/Digitale-Topographische-Karten/DTK10/

AdV (2010b): Richtlinie über Gebühren für die Bereitstellung und Nutzung von Geobasisdaten der Vermessungsverwaltungen der Länder der Bundesrepublik Deutschland - Version 2.1. AdV Online. Download am 03.12.2012 via http://www.adv-online.de/AdV-Produkte/Bezugsbedingungen/Lizenzvereinbarungen-Gebuehrenrichtlinien/

AdV (2010c): Tätigkeitsbericht 2009/2010. Hannover: AdV-Geschäftsstelle.

AdV (2011a): Katalog der tatsächlichen Nutzungsarten im Liegenschaftskataster und ihrer Begriffsbestimmungen (Stand November 2011), Download am 03.12.2012 via http://www.adv-online.de/AdV-Produkte/Liegenschaftskataster/Download/

AdV (2011b): Grundsätze des amtlichen Vermessungswesens (Thesenpapier). AdV Online. Download am 21.12.2012 via http://www.adv-online.de/Veroeffentlichungen/Grundsaetze-des-amtlichen-Vermessungswesens/

AdV (2012a): AAA®-Umfrage zum Sachstand der Migration in den Ländern. AdV Online Download am 04.04.2012 via http://www.adv-online.de/AAA-Modell/Sachstand-der-Migration/

AdV (2012b): ALKIS®- Grunddatenbestand und länderspezifische Inhalte. AdV Online. Download am 11.12.2012 via http://www.adv-online.de/AdV-Produkte/Liegenschaftskataster/Download/

AG Methodik (1993): Flächendeckende Biotopkartierung im besiedelten Bereich als Grundlage einer am Naturschutz orientierten Planung. In: Natur und Landschaft 68 (10), S. 491-526.

Ahl, V.; Allen, T. F. H. (1996): Hierarchy Theory: A Vision, Vocabulary, and Epistemology. New York: Columbia University Press.

Albers, G. (1995): Stadtstrukturplanung. In: Akademie für Raumforschung und Landesplanung (Hrsg.): Handwörterbuch der Raumordnung, Hannover, S. 905–911.

Alexander, C. (1977): A Pattern Language: Towns, Buildings, Construction. Oxford University Press.

Alexander, C.; Ishikawa, S.; Silverstein, M. (1995): Eine Muster-Sprache: Städte, Gebäude, Konstruktion. Löcker.

Alfaro, E.; Gamez, M.; García, N. (2011): The adabag Package: Applies Adaboost.M1 and Bagging. Technical Report. Download am 03.12.2012 via http://cran.r-project.org/web/packages/adabag/adabag.pdf

Alpaydin, E. (2004): Introduction to Machine Learning. The MIT Press.

Amigó, E.; Gonzalo, J.; Artiles, J. et al. (2009): A comparison of extrinsic clustering evaluation metrics based on formal constraints. In: Information Retrieval 12 (4), S. 461–486.

Anders, F. (2007): Mustererkennung in Straßennetzwerken: Verfahren zur Interpretation von Vektordaten. Dissertation, Leibniz Universität Hannover, Deutsche Geodätische Kommission, Reihe C, Heft Nr. 607

Anders, F.; König, R.; Steinhöfel, J. et al. (2010): Straßennetzwerkanalysen zur Unterstützung sozialräumlicher Untersuchungen - das Projekt CoMStaR. In: Strobl, J.; Blaschke, T.; Griesebner, G. (Hrsg.): Angewandte Geoinformatik 2010, Salzburg, S. 454–463.

Anders, K.-H. (2003): A Hierarchical Graph-Clustering Approach to find Groups of Objects. Technical Paper, In: 5th ICA Workshop on Progress in Automated Map Generalisation, S. 5–10.

Anders, K.-H. (2006): Grid Typification. In: Riedl, A.; Kainz, W.; Elmes, G. A. (Hrsg.): Progress in spatial data handling - 12th International Symposium on Spatial Data Handling, S. 633–642.

Anders, K.-H. (2004): Parameterfreies hierarchisches Graph-Clustering-Verfahren zur Interpretation raumbezogener Daten, Dissertation, Universität Stuttgart.

Anders, K.-H.; Sester, M. (1997): Methods of Data Base Interpretation – Applied to Model Generalization from Large to Medium Scale. In: Förstner, W.; Plümer, L. (Hrsg.): Semantic Modeling for the Acquisition of Topographic Information from Images and Maps. Birkhäuser, S. 89–103.

Anders, K.-H.; Sester, M.; Fritsch, D. (1999): Analysis of Settlement Structures by Graph-Based Clustering. In: SMATI 99 Workshop on Semantic Modeling. München, S. 41–49.

Anderson, J. R.; Hardy, E. E.; Roach, J. T. et al. (1976): A Land Use And Land Cover Classification System For Use With Remote Sensor Data. U.S. Geological Survey Professional Paper 964, Washington.

Angel, S.; Parent, J.; Civco, D. L. (2010): Ten compactness properties of circles: measuring shape in geography. In: Canadian Geographer 54 (4), S. 441–461.

ARL (1991): Aufgabe und Gestaltung von Planungskarten. Hannover: Akademie für Raumforschung und Landesplanung (ARL).

Arlt, G.; Blum, A.; Gruhler, K. et al. (2010): Siedlungsraumbezogene Strukturtypen. In: Blum, A.; Gruhler, K. (Hrsg.): Typologien der gebauten Umwelt - Modellierung und Analyse der Siedlungsentwicklung mit dem Strukturtypenansatz. Aachen: Shaker, S. 25–38.

Arnberger, E. (1966): Handbuch der Thematischen Kartographie. Wien: Deuticke.

Arnberger, E. (1977): Thematische Kartographie. Braunschweig: Westermann.

Arnold, S. (2009): Integration of remote sensing data in national and European spatial data infrastructures derivation of CORINE Land Cover data from the DLM-DE. In: Photogrammetrie - Fernerkundung - Geoinformation 2/2009, S. 129–141.

Aubrecht, C.; Steinnocher, K. (2007): Der Übergang von Bodenbedeckung über urbane Struktur zu urbaner Funktion - ein integrativer Ansatz von Fernerkundung und GIS. In: Schrenk M.; Popovich V. V.; Benedikt J. (Hrsg.): 12th International Conference on Urban Planning and Regional Development in the Information Society (CORP), CD-ROM, S. 667–675.

Aubrecht, C.; Steinnocher, K.; Hollaus, M. et al. (2009): Integrating earth observation and GIScience for high resolution spatial and functional modeling of urban land use. In: Computers, Environment and Urban Systems 33 (1), S. 15–25.

Backhaus, K.; Erichson, B.; Plinke, W. (2006): Multivariate Analysemethoden: eine anwendungsorientierte Einführung. Berlin: Springer.

Bader, G.; Schwaiger, B.; Ferrara, C. (2001): Methoden zur Analyse von Gebäudebeständen, Alterungsmodelle und Prognose von Stoffströmen mit Anwendung auf den Gebäudebestand der Stadt Ettlingen (Arbeitsbericht), Karlsruhe.

Bähr, H. P.; Vögtle, T. (2005): Digitale Bildverarbeitung. Anwendung in Photogrammetrie, Fernerkundung und GIS. 4. Aufl., Heidelberg: Wichmann.

Baltsavias, E. P.; Gruen, A.; Gool, L. Van (2001): Automatic extraction of man-made objects from aerial and space images (III). Lisse, Abingdon, Exton, Tokyo: A. A., Balkema Publishers.

Balzert, H. (2005): Lehrbuch der Objektmodellierung: Analyse und Entwurf mit der UML 2. Heidelberg: Spektrum Akademischer Verlag.

Banfield, R. E.; Hall, L. O.; Bowyer, K. W. et al. (2007): A Comparison of Decision Tree Ensemble Creation Techniques. In: IEEE Transactions on Pattern Analysis and Machine Intelligence 29 (1), S. 173–180.

Banyard, P.; Cassells, A.; Green, P. et al. (1995): Einführung in die Kognitionspsychologie. Stuttgart: UTB.

Banzhaf, E.; Höfer, R. (2008): Monitoring Urban Structure Types as Spatial Indicators With CIR Aerial Photographs for a More Effective Urban Environmental Management. In: IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing 1 (2), S. 129–138.

Barnsley, M. J.; Barr, S. L. (1997): Distinguishing urban land-use categories in fine spatial resolution land-cover data using a graph-based, structural pattern recognition system. In: Computers, Environment and Urban Systems 21 (3-4), S. 209–225.

Barnsley, Michael J.; Barr, Stuart L. (1996): Inferring urban land use from satellite sensor images using kernel-based spatial reclassification. In: Photogrammetric Engineering Remote Sensing 62 (8), S. 949–958.

Barr, S. L.; Barnsley, M. J. (1997): A region-based, graph-theoretic data model for the inference of second-order thematic information from remotely-sensed images. In: International Journal of Geographical Information Science 11 (6), S. 555–576.

Barr, S. L.; Barnsley, M. J. (1998): Application of structural pattern-recognition techniques to infer urban land use from Ordnance Survey digital map data. In: 3rd International Conference on GeoComputation, Bristol, UK.

Barr, S. L.; Barnsley, M. J. (2004): Characterizing Land Use in Urban Systems via Built-Form Connectivity Models. In: Kelly, R. E. J.; Drake, N. A.; Barr, S. L. (Hrsg.): Spatial Modelling of the Terrestrial Environment. Wiley, S. 201–225.

Barr, S. L.; Barnsley, M. J.; Steel, A. (2004): On the separability of urban land-use categories in fine spatial scale land-cover data using structural pattern recognition. In: Environment and Planning B: Planning and Design 31 (3), S. 397–418.

Bartelme, N. (2005): Geoinformatik: Modelle, Strukturen, Funktionen. 4. vollständig überarbeitete Aufl., Berlin: Springer.

Basaraner, M.; Selcuk, M. (2008): A Structure Recognition Technique in Contextual Generalisation of Buildings and Built-up Areas. In: Cartographic journal 45 (4), S. 274–285.

Batty, M.; Longley, P. A. (1994): Fractal Cities: A Geometry of Form and Function. London: Academic Press.

Bauer, T.; Steinnocher, K. (2001): Per-parcel land use classification in urban areas applying a rule-based technique. In: GeoBIT/GIS 6 (2001), S. 24–27.

Baumgartner, A. (2003): Automatische Extraktion von Straßen aus digitalen Luftbildern. Dissertation, München: Bayerische Akademie der Wissenschaften.

Baumgärtner, I.; Klumbies, P.-G.; Sick, F. (2009): Raumkonzepte: Disziplinäre Zugänge. Göttingen: V & R Unipress.

BBSR (2010): Die europäische Bauwirtschaft. BBSR-Berichte KOMPAKT Nr. 8/10 Bonn. Download am 04.04.2012 via http://www.bbsr.bund.de/BBSR/DE/ Veroeffentlichungen/BerichteKompakt/2010/BK082010.html

BBSR (2012a): Laufende Raumbeobachtung - Raumabgrenzungen - Siedlungsstrukturelle Gemeindetypen. Download am 11.03.2014 via http://www.bbsr.bund.de/BBSR/DE/Raumbeobachtung/Raumabgrenzungen/SiedlungsstrukturelleGebietstypen/Gemeindetypen/gemeindetypen.html

BBSR (2012b): Laufende Stadtbeobachtung - Raumabgrenzungen - Stadt- und Gemeindetypen in Deutschland. Download am 11.03.2014 via http://www.bbsr.bund.de/BBSR/DE/Raumbeobachtung/Raumabgrenzungen/StadtGemeindetyp/StadtGemeindetyp_node.html

Becker, S. (2011): Automatische Ableitung und Anwendung von Regeln für die Rekonstruktion von Fassaden aus heterogenen Sensordaten. Dissertation, Institut für Photogrammetrie, Universität Stuttgart.

Behnisch, M.; Meinel, G. (2011): Kleinräumige quantitative Abschätzung des deutschen Gebäudebestandes - Ausgangslage und Perspektive. In: Meinel, G.; Schumacher, U. (Hrsg.): Flächennutzungsmonitoring III. Erhebung - Analyse - Bewertung. IÖR-Schriften 58, Berlin: Rhombos-Verlag, S.47–59.

Behnisch, M; Meinel, G.; Burckhardt, M.; Hecht, R. (2012): Auswertungen zum Gebäudebestand in Deutschland auf Grundlage digitaler Geobasisdaten. In: Meinel, G.; Schumacher, U.; Behnisch, M. (Hrsg.): Flächennutzungsmonitoring IV. Genauere Daten - informierte Akteure - praktisches Handeln, IÖR-Schriften 58, Berlin: Rhombos-Verlag, S. 151–158.

Behnisch, M. (2009): Urban Data Mining. Karlsruhe: Kit Scientific Publishing.

Beierle, C.; Kern-Isberner, G. (2006): Methoden wissensbasierter Systeme: Grundlagen - Algorithmen - Anwendungen. 4. Aufl., Wiesbaden: Vieweg-Teubner.

Benediktsson, J. A.; Kittler, J. (2010): Multiple Classifier Systems: 8th International Workshop, MCS 2009, Reykjavik, Iceland, June 10-12, 2009, Proceedings. Lecture Notes in Computer Science, Vol. 5519, Berlin: Springer.

Benenson, I.; Torrens, P. M. (2004): Geosimulation: Automata-Based Modeling of Urban Phenomena. London: John Wiley and Sons.

Berg, M. de; Krefeld, M. van; Overmars, M. et al. (2000): Computational Geometry: Algorithms and Applications. 3. Aufl., Springer.

Berry, B.; Joe L.; Marble, D. F. (1968): Spatial analysis: a reader in statistical geography. Englewood Cliffs, New Jersey: Prentice Hall.

Bertin, J. (1974): Graphische Semiologie: Diagramme, Netze, Karten. Berlin; New York: Walter de Gruyter.

Betzholz, T.; Wöllper, F. (2010): Liegenschaftskataster - Datenquelle der Flächenerhebung. In: Statistisches Monatsheft Baden-Württemberg 2/2010, S. 18–24.

Beutel, M.; Brodale, R.; Hillebrecht, G. (1989): Luftbildinterpretation für die Generalbebauungsplanung. Katalog der Zuordnungsmerkmale von Flächennutzungskategorien. Berlin: Selbstverlag (Bauakademie der DDR, Institut für Städtebau und Architektur, Berlin/Ost).

BezregKöln (2012): 3D-Gebäudestrukturen (3D-GS). Bezirksregierung Köln, Download am 02.03.2012 via http://www.bezreg-koeln.nrw.de/brk_internet/organisation/ abteilung07_produkte/reliefinformationen/3d/index.html.

Biederman, I. (1987): Recognition-by-components: A Theory of Human Image Understanding. In: Psychological Review 94 (2), S. 115–147.

Bill, R. (2012): Geoinformatik Service GI-LEXIKON. Universität Rostock. Download am 22.08.2012 via http://www.geoinformatik.uni-rostock.de/lexikon.asp.

Bill, R. (2010): Grundlagen der Geo-Informationssysteme. 5. Aufl., Wichmann.

Bill, R. (1999): Grundlagen der Geo-Informationssysteme: Band 2: Analysen, Anwendungen und neue Entwicklungen. 2. Aufl., Wichmann.

Bill, R.; Zehner, M. (2001): Lexikon der Geoinformatik. 1. Aufl., Wichmann.

Birth, K. (2003): ATKIS-Projekt Modell- und kartographische Generalisierung, und die Entwicklung geht weiter. In: Kartographische Nachrichten 53 (3), S. 119–126.

Bishop, C. M. (1995): Neural networks for pattern recognition. Clarendon Press.

Bishop, C. M. (2007): Pattern Recognition and Machine Learning. 1. Aufl., Springer.

Bishr, Y. (1998): Overcoming the semantic and other barriers to GIS interoperability. In: International Journal of Geographical Information Science 12 (4), S. 299–314.

Bizer, K.; Einig, K.; Köck, W. et al. (Hrsg.) (2011): Raumordnungsinstrumente zur Flächenverbrauchsreduktion. Schriftenreihe Recht, Ökonomie und Umwelt, Band 19, Baden-Baden: Nomos.

BKG (2011): Digitales Basis-Landschaftsmodell (AAA-Modellierung). Online-Dokumentation, Bundesamt für Kartographie und Geodäsie. Download am 02.05.2012 via http://www.geodatenzentrum.de/docpdf/basis-dlm-aaa.pdf

BKG (2010): Georeferenzierte Adressdaten – Bund (GAB). Dokumentation Bundesamt für Kartographie und Geodäsie. Download am 12.03.2014 via http://www.geodatenzentrum.de/docpdf/gab.pdf

Blotevogel, H. H. (1995): Raum. In: Akademie für Raumforschung und Landesplanung (Hrsg.): Handwörterbuch der Raumordnung. Hannover, S. 733–740.

Blum, A.; Gruhler, K. (2010): Typologien der gebauten Umwelt - Modellierung und Analyse der Siedlungsentwicklung mit dem Strukturtypenansatz. Aachen: Shaker.

Blum, A.; Gruhler, K.; Thinh, N. X. (2010): Typenbildung. In: Blum, Andreas; Gruhler, Karin (Hrsg.): Typologien der gebauten Umwelt - Modellierung und Analyse der Siedlungsentwicklung mit dem Strukturtypenansatz. Aachen: Shaker, S. 7–24.

Blum, A.; Mitchell, T. (1998): Combining labeled and unlabeled data with co-training. In: Proceedings of the 11th Annual Conference on Computational Learning Theory, San Francisco: Morgan Kaufmann Publishers, S. 92–100.

BMU (2012): Nachhaltige Entwicklung als Handlungsauftrag. Internetseite des Bundesministeriums für Umwelt, Naturschutz, Bau und Reaktorsicherheit. Download am 11.10.2012 via http://www.bmu.de/nachhaltige_entwicklung/strategie_und_umsetzung/nachhaltigkeit_handlungsauftrag/doc/print/2396.php?fSD=big.

Bobzien, M. (2006): Methodische Aspekte der Generalisierung von Geodaten. Dissertation, Rheinische Friedrich-Wilhelms-Universität Bonn.

Bobzien, M.; Burghardt, D.; Petzold, I. et al. (2006): Multi-representation databases with explicitly modelled intra-resolution, inter-resolution and update relations. In: AutoCarto 2006, University of Zurich.

Bochow, M. (2010): Automatisierungspotenzial von Stadtbiotopkartierungen durch Methoden der Fernerkundung. Dissertation, Universität Osnabrück, Berlin: Logos Verlag.

Bochow, M.; Taubenbock, H.; Segl, K. et al. (2010): An automated and adaptable approach for characterizing and partitioning cities into urban structure types. In: 2010 IEEE International Geoscience and Remote Sensing Symposium. Honolulu, HI, USA, S. 1796–1799.

Bock, H. (1974): Automatische Klassifikation: theoretische und praktische Methoden zur Gruppierung und Strukturierung von Daten (Cluster-Analyse). Göttingen: Vandenhoeck & Ruprecht.

Boffet, A; Serra, R. (2001): Identification of spatial structures within urban blocks for town characterisation. In: Proceeding of 20th International Cartographic Conference, Beijing, S. 1974–1983.

Bollmann, J. (2001): Kartographische Generalisierung. In: Bollmann, J.; Koch, W. G. (Hrsg.): Lexikon der Kartographie und Geomatik: Karto bis Z. Spektrum Akademischer Verlag, S. 21–23.

Bollmann, J.; Koch, W. G. (2001): Lexikon der Kartographie und Geomatik: in zwei Bänden. Spektrum Akademischer Verlag.

Bolter, R.; Leberl, F. (2000): Detection and Reconstruction of Buildings from Multiple View Interferometric SAR Data. In: Geoscience and Remote Sensing Symposium. IGARSS 2000, S. 749–751.

Bonissone, P.; Cadenas, J. M.; Carmen, G. M. et al. (2010): A fuzzy random forest. In: International Journal of Approximate Reasoning 51 (7), S. 729–747.

Borg, E.; Fichtelmann, B. (1998): Vergleichende Analyse von Formindizes zur Charakterisierung von Landschaftsobjekten unter ökologischen Aspekten. In: Zeitschrift für Photogrammetrie und Fernerkundung 66 (4), S. 66–78.

Borsdorf, A.; Bender, O. (2010): Allgemeine Siedlungsgeographie. 1. Aufl., Stuttgart: UTB.

Boser, B. E.; Guyon, I. M.; Vapnik, V. N. (1992): A Training Algorithm for Optimal Margin Classifiers. In: Proceedings of the 5th Annual ACM Workshop on Computational Learning Theory. ACM Press, S. 144–152.

Bothmer, D.; Sommer, T. (2010): BMBF-Verbund-Projekt Entwicklung multisequenzieller Vorsorgestrategien für grundhochwassergefährdete urbane Lebensräume" (MULTISURE). Abschlussbericht, Zittau: Technische Informationsbibliothek u. Universitätsbibliothek.

Bouveyron, C.; Girard, S. (2009): Robust supervised classification with mixture models: Learning from data with uncertain labels. In: Pattern Recognition 42 (11), S. 2649–2658.

Bowman, A. W.; Azzalini, A. (1997): Applied Smoothing Techniques for Data Analysis: The Kernel Approach With S-Plus Illustrations. Oxford University Press.

Boyce, R. R.; Clark, W. A. V. (1964): The Concept of Shape in Geography. In: Geographical Review 54 (4), S. 561–572.

Brassel, K. E.; Weibel, R. (1988): A review and conceptual framework of automated map generalization. In: International Journal of Geographical Information Systems 2 (3), S. 229–244.

Breiman, L. (1998): Arcing Classifiers. In: The Annals of Statistics 40 (3), S. 801–849.

Breiman, L. (1996a): Bagging Predictors. In: Machine Learning 24 (2), S. 123–140.

Breiman, L. (1996b): Out-Of-Bag Estimation. Technical Report, Statistics Department, University of California Berkeley.

Breiman, L. (2001): Random Forests. In: Machine Learning 45 (1), S. 5–32.

Breiman, L.; Friedman, J.; Stone, C. et al. (1984): Classification and Regression Trees. Chapman & Hall/CRC.

Brenning, A. (2009): Benchmarking classifiers to optimally integrate terrain analysis and multispectral remote sensing in automatic rock glacier detection. In: Remote Sensing of Environment 113 (1), S. 239–247.

Brenning, A.; Kaden, K.; Itzerott, S. (2006): Comparing classifiers for crop identification based on multitemporal Landsat TM/ETM data. In: Proceedings of the 2nd Workshop of the EARSeL SIG on Land Use and Land Cover, Bonn, S. 64-71.

Bringmann, O. (2003): Symbolische Interpretation Technischer Zeichnungen. Dissertation, Technische Universität Dresden.

Brockhaus (2005): Brockhaus. Brockhaus multimedial. Bibliographisches Institut & F. A. Brockhaus AG.

Brück, H.; Schild, K.; Willems, W. (2010): Energie-Effizienzbewertung von Gebäuden: Anforderungen und Nachweisverfahren gemäß EnEV 2009. 1. Aufl., Vieweg+Teubner Verlag.

Brügelmann, R. (1996): Recognition of Hatched Cartographic Patterns. In: International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 31 (Part B3), S. 82–87.

Bubik, M.; Lamla, K. (2011): Möglichkeiten und Grenzen der Regionalisierung statistischer Erhebungen am Beispiel des Zensus 2011. In: Meinel, G.; Schuhmacher, U. (Hrsg.): Flächennutzungsmonitoring III: Erhebung - Analyse - Bewertung, IÖR-Schriften 58, Berlin: Rhombos-Verlag, S. 213–218.

Buchert, M.; Fritsche, U.; Jenseit, W. et al.; Öko-Institut (Hrsg.) (2004): Nachhaltiges Bauen und Wohnen in Deutschland: Stoffflussbezogene Bausteine für ein nationales Konzept der nachhaltigen Entwicklung, Forschungsbericht 29892303/02, UBA-Texte 01/2004. Umweltbundesamt.

Buchroithner, M. F.; Fernández, P. A. (2011): Cartography in the Context of Sciences: Theoretical and Technological Considerations. In: Cartographic Journal 48 (1), S. 4–10.

Buchroithner, M. F.; Koch, W. G.; Zimmermann, G. (2006): Die SLUB im Dienst der Vermittlung raumbezogener graphischer Information. In: Geschichte und Zukunft von Information und Wissen. S. 105–112.

Bundesregierung (2012): Gesetz zur Förderung der elektronischen Verwaltung sowie zur Änderung weiterer Vorschriften. Gesetzentwurf vom 21.09.12, Download am 02.03.2014 von http://dipbt.bundestag.de/extrakt/ba/WP17/473/47380.html

Burckhardt, M. (2012): Analyse des Gebäudebestandes in Deutschland auf Grundlage der Hausumringe (HU) und georeferenzierter Adressdaten. Diplomarbeit, TU Dresden.

Burgess, E. W. (1925): The Growth of the City. In: Park, R. E.; Burgess, E. W; McKenzie, R. D. (Hrsg.): The City. University of Chicago Press, S. 47–62.

Burghardt, D.; Petzold, I.; Bobzien, M. (2010): Relation Modelling within Multiple Representation Databases and Generalisation Services. In: Cartographic Journal 47 (3), S. 238–249.

Burghardt, D.; Steiniger, S. (2005a): Usage of principal component analysis in the process of automated generalisation. In: Proceedings of the 22nd International Cartographic Conference, A Coruña, Spain.

Caelli, T.; Johnston, M.; Robinson, T. (1993): 3D Object Recognition: Inspirations and Lessons from Biological Vision. In: Jain A. K.; Flynn P. J. (Hrsg.): Three-Dimensional Object Recognition Systems. New York: Elsevier, S. 1–17.

Calle, M. L.; Urrea, V. (2011): Letter to the editor: Stability of Random Forest importance measures. In: Briefings in Bioinformatics 12 (1), S. 86–89.

Carrillo, G. (2012): Interfacing R and ArcGIS with Python. White Paper, Institut für Geoinformatik. Download am 12.12.2012 via http://ifgibox.de/g_carr02/Interfacing_R_and_ArcGIS_with_Python.pdf

Cattell, R. B. (1966): The Scree Test For The Number Of Factors. In: Multivariate Behavioral Research 1 (2), S. 245–276.

Chan, J.; Paelinckx, D. (2008): Evaluation of Random Forest and Adaboost tree-based ensemble classification and spectral band selection for ecotope mapping using airborne hyperspectral imagery. In: Remote Sensing of Environment 112 (6), S. 2999–3011.

Chang, C.-C.; Lin, C.-J. (2001): LIBSVM: a library for support vector machines. In: Science 2 (3), S. 1–39.

Chaudhry, O. Z.; Gravelle, M.; Regnauld, N. (2010): Automatic identification of High Streets and classification of urban land use in large scale topographic database. In: Proceedings of the GIS Research UK 18th Annual Conference GISRUK 2010. London, United Kingdom, S. 285–290.

Chen, C.; Liaw, A.; Breiman, L. (2004): Using Random Forest to Learn Imbalanced Data. Berkeley, California: Statistics Department, University of California, Berkeley.

Cheng, L.; Gong, J.; Chen, X. et al. (2008): Building Boundary Extraction from High Resolution Imagery and LIDAR Data. In: International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 37 (Part B3), S. 693–698.

Christophe, S.; Ruas, A. (2002): Detecting building alignments for generalisation purposes. In: Richardson D.; Oosterom P. van (Hrsg.): Advances in Spatial Data Handling: 10th International Symposium on Spatial Data Handling, Heidelberg: Springer, S. 121–136.

Chudy, T. (2007): Planungskartographie ländlicher Räume in Deutschland - Eine Analyse und Diskussion aktueller Bestimmungsfaktoren zur kartographischen Modellierung einer Raumkategorie. Dissertation, Technische Universität Dresden.

Clark, C. (1951): Urban Population Densities. In: Journal of the Royal Statistical Society 114 (4), S. 490–496.

Clark, W. A. V.; Gaile, G. L. (1973): The Analysis and Recognition of Shapes. In: Geografiska Annaler. Series B, Human Geography 55 (2), S. 153–163.

Cohen, J. (1960): A Coefficient of Agreement for Nominal Scales. In: Educational and Psychological Measurement 20 (1), S. 37–46.

Cohen, J. (1968): Weighted kappa: Nominal scale agreement provision for scaled disagreement or partial credit. In: Psychological Bulletin 70 (4), S. 213–220.

Colaninno, N.; Cladera, J. R.; Pfeffer, K. (2011): An automatic classification of urban texture: form and compactness of morphological homogeneous structures in Barcelona. In: Proceedings of the 51st European Congress of the Regional Science Association International (ERSA). Download am 02.03.2014 via http://www.ekf.vsb.cz/export/sites/ekf/projekty/cs/weby/esf-0116/databaze-prispevku/clanky_ERSA_2011/ERSA2011_paper_00769.pdf

Congalton, R. G. (1991): A review of assessing the accuracy of classifications of remotely sensed data. In: Remote Sensing of Environment 37 (1), S. 35–46.

Congalton, R. G.; Green, K. (1998): Assessing the Accuracy of Remotely Sensed Data: Principles and Practices. 1. Aufl., CRC Press.

Conzen, M.R.G. (1960): Alnwick, Northumberland: A Study in Town-plan Analysis. London: George Philip.

Cover, T. (1965): Geometrical and Statistical Properties of Systems of Linear Inequalities with Applications in Pattern Recognition. In: IEEE Transactions on Electronic Computers EC-14 (3), S. 326 –334.

Cover, T.; Hart, P. (1967): Nearest neighbor pattern classification. In: IEEE Transactions on Information Theory 13 (1), S. 21–27.

Crostwitz (2012): Crostwitz und Umgebung. Internetauftritt der Gemeinde Crostwitz. Download am 12.12.2012 via http://crostwitz.de.

Curdes, G. (1997): Stadtstruktur und Stadtgestaltung. 2. Aufl., Kohlhammer.

Curdes, G. (2010): Urban morphology and climate change - Which morphology can survive?. In: ISUF 2010. Hamburg. Download am 12.12.2012 via http://www.isuf2010.de/Papers/Curdes%20Gerhard.pdf

Curie, F.; Perret, J.; Ruas, A. (2010): Simulation of urban blocks densification. In: The 13th AGILE International Conference on Geographic Information Science. Guimarães, Portugal.

Dara-Abrams, D.; Hölscher, C.; Conroy-Dalton, R.; Turner A. (2010): Environmental Modeling: Using Space Syntax in Spatial Cognition Research. Proceedings of the Workshop at Spatial Cognition 2010. Mt. Hood, Oregon.

Deseilligny, M. P.; Mariani, R.; Labiche, J. et al. (1998): Topographic maps automatic interpretation: Some proposed strategies. In: Tombre, K.; Chhabra, A. (Hrsg.): Graphics Recognition Algorithms and Systems. Lecture Notes in Computer Science Vol. 1389, Berlin; Heidelberg: Springer, S. 175–193.

Destatis (2009): Bauen und Wohnen. Bestand an Wohnungen. Fachserie 5 (Heft 3), Wiesbaden: Statistisches Bundesamt.

Destatis (2006): Bauen und Wohnen. Mikrozensus - Zusatzerhebung 2006. Bestand und Struktur der Wohneinheiten. Wohnsituation der Haushalte. Fachserie 5 (Heft 1), Wiesbaden: Statistisches Bundesamt.

Destatis (2011a): Bevölkerung und Erwerbstätigkeit - Bevölkerungsfortschreibung - 2010, Fachserie 1, Reihe 1.3, Wiesbaden: Statistisches Bundesamt.

Destatis (2010): Bevölkerung und Erwerbstätigkeit - Bevölkerungsfortschreibung - 2009. Fachserie 1, Reihe 1.3, Wiesbaden: Statistisches Bundesamt.

Destatis (2012a): Destatis Glossar A-Z: Wohngebäude. Download am via https://www.destatis.de/DE/Service/Glossar/W/Wohngebaeude.html?nn=198856.

Destatis (2011b): Erläuterungen zur Statistik der Bautätigkeit im Hochbau: Baugenehmigenehmigungen - Baufertigstellungen - Bauüberhang. Wiesbaden: Statistisches Bundesamt.

Destatis (2011c): Gebäude und Wohnungen - Bestand an Wohnungen und Wohngebäuden / Bauabgang von Wohnungen und Wohngebäuden / Lange Reihen ab 1969 - 2010. Wiesbaden: Statistisches Bundesamt.

Destatis (2011d): Sektorale und gesamtwirtschaftliche Vermögensbilanzen: 1992 bis 2010. Wiesbaden: Statistisches Bundesamt.

Destatis (2011e): Siedlungs- und Verkehrsfläche wächst täglich um 87 Hektar. Download am 13.10.2012 via https://www.destatis.de/DE/PresseService/Presse/ Pressemitteilungen/2011/10/PD11_382_331.html.

Destatis (2012b): Statistik von A bis Z - Mikrozensus. Download am 13.10.2012 via https://www.destatis.de/DE/Meta/AbisZ/Mikrozensus.html.

Deutscher Städtetag (1991): Kommunale Gebietsgliederung. Empfehlungen zur Ordnung des Straßen-/Hausnummernsystems und Gliederung des Gemeindegebiets nach Gemeindeteilen, Blöcken und Blockseiten sowie DV-Organisation. DST-Beiträge zur Informationsgesellschaft und Stadtforschung, Reihe H (Heft 39).

Dey, V.; Zhang, Y.; Zhong, M. (2011): Building Detection from Pan-Sharpened GeoEye-1 Satellite Imagery Using Context Based Multi-Level Image Segmentation. In: 2011 International Symposium on Image and Data Fusion (ISIDF), S. 1–4.

Dhar, D.; Chanda, B. (2006): Extraction and recognition of geographical features from paper maps. In: International Journal on Document Analysis and Recognition 8 (4), S. 232–245.

Díaz-Uriarte, R.; Alvarez de Andrés, S. (2006): Gene selection and classification of microarray data using random forest. In: BMC Bioinformatics 7(3).

Dickmann, F.; Sohst, A. (2008): Vom Baublock zum Grid – Die Visualisierung künstlicher Raumeinheiten im Geomarketing. In: Kartographische Nachrichten 58 (5), S. 227–234.

Dirlich, S.; Gruhler, K.; Deilmann, C. et al. (2011): Typologie und Bestand beheizter Nichtwohngebäude in Deutschland. BMVBS-Online-Publikation 16/2011, Berlin: BMVBS.

Dogruso, E.; Aksoy, S. (2007): Modeling Urban Structures Using Graph-Based Spatial Patterns. In: IEEE International Geoscience and Remote Sensing Symposium, 2007 (IGARSS 2007), Barcelona, Spain, S. 4826–4829.

Donnay, J.-P.; Barnsley, M. J.; Longley, P. A. (2001): Remote Sensing and Urban Analysis: GISDATA 9. 1. Aufl., CRC Press.

Drauschke, M. (2011): Ein hierarchischer Ansatz zur Interpretation von Gebäudeaufnahmen. Dissertation, Institut für Geodäsie und Geoinformation, Universität Bonn.

Duchêne, C; Bard, S.; Barillot, X. et al. (2003): Quantitative an qualitative description of building orientation. In: Fifth Workshop on Progress in Automated Map Generalisation, Working Paper, Paris.

Duda, R. O.; Hart, P. E.; Stork, D. G. (2000): Pattern Classification. 2. Aufl., Wiley-Interscience.

Dutta, D.; Serker, K. (2005): Urban Building Inventory Development using Very High-Resolution Remote Sensing Data for Urban Risk Analysis. In: International Journal of Geoinformatics 1 (1), S. 109–116.

Ecoplan (2000): Siedlungsentwicklung und Infrastrukturkosten. Schlussbericht im Auftrag von: Bundesamt für Raumentwicklung Staatssekretariat für Wirtschaft Amt für Gemeinden und Raumordnung des Kantons Bern.

Edwards, T. C.; Beard, K. H.; Cutler, A. et al. (2007): Random forests for classification in ecology. In: Ecology 88 (11), S. 2783–92

Effenberger, K.-H.; Banse, J. (2010): Städtische Wohnungsbestände in Ostdeutschland im Vergleich. Reihe Wissenschaft. 23, Stuttgart: Fraunhofer IRB Verlag.

Efron, B. (1979): Bootstrap Methods: Another Look at the Jackknife. In: The Annals of Statistics 7 (1), S. 1–26.

Egenhofer, M. J.; Herring, J. (1994): Categorizing binary topological relations between regions, lines, and points in geographic databases. Technical Report, Department of Surveying Engineering, University of Maine.

Eichhorn, D.; Oertel, H.; Iwanow, I.; et al. (2009): Entwicklung des Nachfragepotenzials nach Wohnungsneubau für Baden-Württemberg bis 2020 und 2025. Dresden: IÖR.

Ejiri, M.; Kakumoto, S.; Miyatake, T. et al. (1984): Automatic recognition of design drawings and maps. In: Proceedings of the Seventh International Conference on Pattern Recognition, S. 1296–1305.

EnEV (2009): Verordnung über energiesparenden Wärmeschutz und energiesparende Anlagentechnik bei Gebäuden (Energiesparverordnung - EnEV). Download am 13.10.2012 via http://www.enev-online.org/enev_2009_volltext.

Engelbrecht, J.; Röttges, O.; Stratmann, W. et al. (2006): Krefeld - Die Geschichte der Stadt: Von der Franzosenzeit bis zum Ende des Ersten Weltkrieges (1794-1918). 1. Aufl., Stadt Krefeld.

Enquete-Kommission (1998): Abschlußbericht der Enquete-Kommission Schutz des Menschen und der Umwelt - Ziele und Rahmenbedingungen einer nachhaltig zukunftsverträglichen Entwicklung. Drucksache 13/11200 vom 26.06.1998, Bonn: Deutscher Bundestag.

Esch, T. (2010): Erfassung und Bewertung der Bodenversiegelung. In: Taubenböck, Hannes; Dech, Stefan (Hrsg.): Fernerkundung im urbanen Raum. 1. Aufl., Wissenschaftliche Buchgesellschaft, S. 58–62.

Eschwege, A. von; Heidrich-Riske, H.; Statistisches Bundesamt (Hrsg.) (2006): Nutzung des Raumbezuges in der amtlichen Statistik. In: Wirtschaft und Statistik 2/2006. S. 118–135.

ESRI (2012): ArcGIS: Das umfassende GeoInformationssystem. Download am 12.12.2012 via http://www.esri.de/products/arcgis/index.html.

Eurostat (1998): Klassifikation der Bauwerke. Fassung vom 15.10.1997, Eurostat, Download am 12.12.2012 via http://ec.europa.eu/eurostat/ramon/index.cfm?TargetUrl=DSP_PUB_WELC

Ewing, R. H.; Pendall, R.; Chen, D. (2002): Measuring sprawl and its impact. Technical Paper, Smart Growth America.

Fang, K.-T.; Zhang, Y.-T. (1990): Generalized Multivariate Analysis. 1. Aufl., Berlin; Heidelberg: Springer.

Fawcett, T. (2003): ROC Graphs: Notes and Practical Considerations for Data Mining Researchers. Technical Report, HP Laboratories Palo Alto. Download am 12.12.2012 via http://www.hpl.hp.com/techreports/2003/HPL-2003-4.pdf

Feinendegen, R.; Vogt, H.; Houben, H. et al. (2010): Krefeld - Die Geschichte der Stadt / Vom Ende des Ersten Weltkrieges bis zur Gegenwart (1918-2004). 1. Aufl., Stadt Krefeld.

Feldesman, M. R. (2002): Classification trees as an alternative to linear discriminant analysis. In: American Journal of Physical Anthropology 119 (3), S. 257–275.

Fichtinger, R.; Geipel, R.; Schrettenbrunner, H. (1974): Studien zu einer Geographie der Wahrnehmung. Stuttgart: Klett.

Fina, S. (2011): Planungsrelevanz: Potenziale und Herausforderungen neuer Geodatenstrukturen. In: CHANGE FOR STABILITY: Lifecycles of Cities and Regions. Proceedings REAL CORP 2011. Essen, S. 715–725.

Fischer, A.; Kolbe, T. H.; Lang, F. et al. (1998): Extracting Buildings from Aerial Images Using Hierarchical Aggregation in 2D and 3D. In: Computer Vision and Image Understanding 72 (2), S. 185–203.

Fisher, R. (1936): The use of multiple measurements in taxonomic problems. In: Annals Eugen 7 (7), S. 179–188.

Fix, E.; Hodges, J. L. (1951): Discriminatory analysis: Nonparametric discrimination: Consistency properties. Technical Report, Project 21-49-004, Nr. 4, USAF School of Aviation Medicine.

Foody, G. M. (2002): Status of land cover classification accuracy assessment. In: Remote Sensing of Environment 80 (1), S. 185–201.

Fotheringham, A. S.; Brunsdon, C.; Charlton, M. (2000): Quantitative geography: perspectives on spatial data analysis. SAGE Publications Ltd.

Freckmann, P. (2009): Die Bedeutung thematischer Karten im Geomarketing – Aktueller Stand und Zukunftstrends. In: Kartographische Nachrichten 59 (5), S. 233–237.

Freund, Y.; Schapire, R. E. (1997): A Decision-Theoretic Generalization of on-Line Learning and an Application to Boosting. In: Journal of Computer and System Sciences 55 (1), S. 119–139.

Freund, Y.; Schapire, R. E. (1996): Experiments with a New Boosting Algorithm. In: Machine Learning: Proceedings of the Thirteenth International Conference, S. 148–156.

Friedman, J. H. (1991): Multivariate Adaptive Regression Splines. In: The Annals of Statistics. 19 (1), S. 1–67.

Friedman, N.; Geiger, D.; Goldszmidt, M. (1997): Bayesian Network Classifiers. In: Machine Learning 29, S. 131–163.

Friedrich, K.; Frühauf, M. (2006): Halle und sein Umland. 2 Aufl., Mitteldeutscher Verlag.

Frischknecht, S. (1999): Eine Abfragesprache für die Geometrie von Rasterelementen für die rasterorientierte Kartographische Mustererkennung und Datenanalyse. Dissertation, Institut für Geodäsie u. Photogrammetrie, ETH Zürich.

Frischknecht, S.; Kanani, E. (1998): Automatic interpretation of scanned topographic maps: A raster-based approach. In: Chhabra, Atul K.; Tombre, Karl (Hrsg.): Graphics Recognition Algorithms and Systems. Springer, S. 207–220.

Fürnkranz, J. (2001): Round Robin Rule Learning. In: Proceedings of the 18th International Conference on Machine Learning (ICML-01), S. 146–153.

Gaffuri, J.; Trévisan, J. (2004): Role of urban patterns for building generalisation: An application of AGENT. In: Proceedings of the 7th ICA Workshop on Generalisation and Multiple Representation. Download am 12.12.2012 via https://geoazur.oca.eu/IMG/pdf/pubTrevisan_wACI04_Gaffuri.pdf

Galar, M.; Fernández, A.; Barrenechea, E. et al. (2011): An overview of ensemble methods for binary classifiers in multi-class problems: Experimental study on one-vs-one and one-vs-all schemes. In: Pattern Recognition 44 (8), S. 1761–1776.

Gallego, F. J. (2010): A population density grid of the European Union. In: Population and Environment 31 (6), S. 460–473.

Gamba, P; Houshmand, B.; Saccani, M. (2000): Detection and extraction of buildings from interferometric SAR data. In: IEEE Transactions on Geoscience and Remote Sensing 38 (1), S. 611–618.

Gayar, N. E; Kittler, J.; Roli, F. (2010): Multiple Classifier Systems: 9th International Workshop, MCS 2010, Cairo, Egypt, April 7-9, 2010, Proceedings. LNCS 5997, 1. Aufl., Berlin: Springer.

Geisler, W. (1924): Die deutsche Stadt – Ein Beitrag zur Morphologie der Kulturlandschaft. Stuttgart: Engelhorn.

Geiß, C.; Taubenböck, H.; Wurm, M. et al. (2011): Remote Sensing-Based Characterization of Settlement Structures for Assessing Local Potential of District Heat. In: Remote Sensing 3 (7), S. 1447–1471.

Gelman, A.; Hill, J. (2006): Missing-data imputation. In: Gelman A.; Hill J. (Hrsg.): Data Analysis Using Regression and Multilevel/Hierarchical Models. Cambridge University Press (Analytical Methods for Social Research), S. 529–546.

Gemeinde RB (2012): Gemeinde Rechenberg-Bienenmühle. Internetauftritt der Gemeindeverwaltung Rechenberg-Bienenmühle. Download am 12.12.2012 via http://www.gemeinde-rechenberg-bienenmuehle.de/

Genuer, R.; Poggi, J.-M.; Tuleau-Malot, C. (2010): Variable selection using random forests. In: Pattern Recognition Letters 31 (14), S. 2225–2236.

infas geodaten (2012): Datenkatalog - Marktinformationen. Download am 15.04.2012 via http://www.infas-geodaten.de/fileadmin/media/pdf/katalog/Marktdatenkatalog.pdf

Geoghegan, J.; Wainger, L. A.; Bockstael, N. E. (1997): Spatial landscape indices in a hedonic framework: an ecological economics analysis using GIS. In: Ecological Economics 23 (3), S. 251–264.

GfK (2012): Mikrogeografische Daten für Deutschland. Internetauftritt der Gfk geomarketing, Download am 10.07.2012 via http://www.gfk-geomarketing.de/marktdaten/mikrogeografische_daten.html.

Gibson, C. C.; Ostrom, E.; Ahn, T. K. (2000): The concept of scale and the human dimensions of global change: a survey. In: Ecological Economics 32 (2), S. 217–239.

Gierga, M.; Erhorn, H.; Forschungszentrum Jülich GmbH (Hrsg.) (1994): Bestand und Typologie beheizter Nichtwohngebäude in Westdeutschland. Forschungszentrum Jülich.

Gislason, P. O.; Benediktsson, J. A.; Sveinsson, J. R. (2006): Random Forests for land cover classification. In: Pattern Recognition Letters 27 (4), S. 294–300.

Glasze, G. (2009): Kritische Kartographie. In: Geographische Zeitschrift 97 (4), S. 181–191.

Gong, P.; Howarth, P. F. (1992): Frequency-Based Contextual Classification and Gray-Level Vector Reduction for Land-Use Identification. In: Photogrammetric Engineering and Remote Sensing 58 (4), S. 423–437.

Gonulalan, C. (2010): An AdaBoost based approach to automatic classification and detection of buildings footprints, vegetation areas and roads from satellite images. Master Thesis, Northeastern University, Boston. Download am 02.03.2014 via http://iris.lib.neu.edu/elec_comp_theses/49/

Goodchild, M. F. (2007): Citizens as Sensors: The World of Volunteered Geography. In: GeoJournal 69 (4), S. 211–221.

Goodchild, M. F. (2010): Twenty years of progress: GIScience in 2010. In: Journal of Spatial Information Science 1 (2010), S. 3–20.

Gordon, I. E. (2004): Theories of Visual Perception. 3. Aufl., Hove: Psychology Press.

Gorki, H. F.; Pape, H. (1987): Stadtkartographie. Wien: Franz Deuticke.

Götz, M.; Zipf, A. (2012): OpenStreetMap in 3D – Detailed Insights on the Current Situation in Germany. In: AGILE 2012. Avignon. Download am 12.12.2012 via http://koenigstuhl.geog.uni-heidelberg.de/publications/2012/Goetz/Goetz-Zipf_2012_OSM-3D.pdf

Graeff, B. (2002): Abfragesprache für geometrische und semantische Information aus rasterbasierten topografischen Karten. Institut für Geodäsie u. Photogrammetrie, ETH Zürich.

Grigillo, D.; Fras, M. K. (2011): Classification based building detection from GeoEye-1 images. In: Urban Remote Sensing Event (JURSE), 2011 Joint, S. 381–384.

Gröger, G.; Kolbe, T. H.; Plümer, L. (2004): Mehrskalige, multifunktionale 3D-Stadt- und Regionalmodelle. In: Photogrammetrie - Fernerkundung - Geoinformation 2/2004, S. 121–132.

Gruber, T. R. (1993): Toward principles for the design of ontologies used for knowledge sharing. In: International Journal of Human-Computer Studies 43 (5-6), S. 907–928.

Gruen, A.; Behnisch, M.; Kohler, N. (2009): Perspectives in the reality-based generation,nD modelling, and operation of buildings and building stocks. In: Building Research & Information 37 (5-6), S. 503–519.

Gruen, A. (2008): Building Extraction from Aerial Imagery. In: Weng, Qihao (Hrsg.): Remote sensing of impervious surfaces. Taylor & Francis series in remote sensing applications, Boca Raton: CRC Press, S. 269–294.

Gruen, A.; Kuebler, O.; Agouris, P. (1995): Automatic extraction of man-made objects from aerial and space images. Basel: Birkhäuser.

Gruen, A.; Baltsavias, E. P.; Henricsson, O. (1997): Automatic extraction of man-made objects from aerial and space images (II). Basel: Birkhäuser.

Guyon, I. (2006): Feature Extraction: Foundations and Applications. 1. Aufl., Berlin; Heidelberg: Springer.

Guyon, I.; Elisseeff, A. (2003): An Introduction to Variable and Feature Selection. In: Journal of Machine Learning Research 3/2003, S. 1157-1182.

Haala, N. (1996): Gebäuderekonstruktion durch Kombination von Bild- und Höhendaten. Dissertation, Universität Stuttgart.

Hake, G.; Grünreich, D.; Meng, L. (2002): Kartographie. Berlin; New York: Walter de Gruyter.

Hall, M. A. (1999): Correlation-based Feature Selection for Machine Learning. Doctoral Thesis, Department of Computer Science, Waikato University, New Zealand. Download am 02.03.2014 via www.cs.waikato.ac.nz/~mhall/thesis.pdf

Hand, D. J. (1997): Construction and Assessment of Classification Rules. Wiley.

Haralick, R. M.; Shapiro, L. G. (1985): Image Segmentation Techniques. In: Computer Vision, Graphics, and Image Processing 29 (1), S. 100–132.

Haralick, R.; Shanmugam, K.; Dinstein, I. (1973): Textural Features for Image Classification. In: IEEE Transactions on Systems, Man, and Cybernetics 3 (6), S. 610–621.

Harley, J. B.; Woodward, D. (Hrsg.) (1987): The History of Cartography: Cartography in Prehistoric, Ancient and Medieval Europe and the Mediterranean, Volume 1 University of Chicago Press.

Harris, C. D.; Ullman, E. L. (1945): The Nature of Cities. In: Mitchell R. B. (Hrsg.): Building the future city. Philadelphia: American academy of political and social Science.

Hassler, U. (2011): Langfristst abilität: Beiträge zur langfristigen Dynamik der gebauten Umwelt. 1, Aufl., Zürich: Vdf Hochschulverlag.

Hastie, T. (1998): Classification by pairwise coupling. In: The Annals of Statistics 26 (2), S. 451–471.

Hastie, T.; Buja, A.; Tibshirani, R. (1995): Penalized Discriminant Analysis. In: The Annals of Statistics 23 (1), S. 73–102.

Hastie, T.; Tibshirani, R. (1996): Discriminant Analysis by Gaussian Mixtures. In: Journal of the Royal Statistical Society (Series B) 58 (1), S. 155–176.

Hastie, T.; Tibshirani, R. (2009): Package 'mda'. Technical Report. Download am 03.12.2012 via http://cran.r-project.org/web/packages/mda/mda.pdf

Hastie, T.; Tibshirani, R.; Buja, A. (1994): Flexible Discriminant Analysis by Optimal Scoring. In: Journal of the American Statistical Association 89 (428), S. 1255–1270.

Hastie, T.; Tibshirani, R.; Friedman, J. (2009): The Elements of Statistical Learning: Data Mining, Inference, and Prediction. 2. Aufl., Springer.

Hastie, T.; Tibshirani, R.; Sherlock, G. et al. (1999): Imputing missing data for gene expression arrays. Technical Report, Division of Biostatistics, Stanford University.

Hatzinger, R.; Hornik, K.; Nagel, H. (2011): R: Einführung durch angewandte Statistik. Pearson Deutschland GmbH.

Haunert, J.-H. (2005): Geometrietypwechsel in einer Multi-Resolution-Datenbank. Mitteilungen des Bundesamtes für Kartographie und Geodäsie, Band 34: Arbeitsgruppe Automation in der Kartographie – Tagung 2004, Frankfurt am Main: BKG.

Haußmann, M. (2012): Probleme und Lösungen auf dem Weg zu kleinräumigen innerstädtischen Statistiken. In: Meinel, G.; Schumacher, U.; Behnisch, M. (Hrsg.): Flächennutzungsmonitoring IV. Genauere Daten - informierte Akteure - praktisches Handeln, IÖR-Schriften 58, Berlin: Rhombos-Verlag, S. 169–173.

Hay, G. J.; Castilla, G. (2008): Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline. In: Blaschke, T.; Lang, S.; Hay, G. (Hrsg.): Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications, Lecture Notes in Geoinformation and Cartography, Springer, S. 75–89.

HbauStatG (1998): Hochbaustatistikgesetz – HbauStatG. Download am 03.02.2012 via http://www.gesetze-im-internet.de/bundesrecht/hbaustatg/gesamt.pdf

Hechenbichler, K. (2005): Ensemble-Techniken und ordinale Klassifikation. Dissertation, Ludwig-Maximilians-Universität München.

Hecht, R.; Herold, H.; Meinel, G. (2010): Analyse und Visualisierung der Siedlungsentwicklung mit SEMENTA®-CHANGE. In: Meinel, G.; Schumacher, U. (Hrsg.): Flächennutzungsmonitoring II Konzepte – Indikatoren – Statistik. IÖR-Schriften 52, Berlin: Rhombos-Verlag, S. 217–236.

Hecht, R.; Herold, H.; Meinel, G. (2008): Gebäudescharfe Analyse der Siedlungsentwicklung auf Grundlage mittelmaßstäbiger Karten. In: Strobl, J.; Blaschke, T.; Griesebner, G. (Hrsg.): Beiträge zum 20. AGIT-Symposium Salzburg. Wichmann, S. 11–17.

Hecht, R.; Kunze, C.; Hahmann, S. (2013): Measuring Completeness of Building Footprints in OpenStreetMap over Space and Time. In: ISPRS International Journal of Geo-Information 2 (4), S.1066-1091

Heiden, U.; Heldens, W. (2010): Automatische Erkennung von Oberflächenmaterialien städtische Objekte. In: Taubenböck, H.; Dech, S. (Hrsg.): Fernerkundung im urbanen Raum. 1. Aufl., Wissenschaftliche Buchgesellschaft, S. 76–83.

Heiden, U. (2004): Analyse hyperspektraler Flugzeugscannerdaten zur ökologischen Charakterisierung städtischer Biotope. Dissertation, Technische Universität Berlin.

Heijden, F. van der; Duin, R. P. W.; de Ridder, D. et al. (2004): Classification, Parameter Estimation and State Estimation. Chichester: John Wiley & Sons, Ltd.

Heineberg, H. (2006a): Einführung in die Anthropogeographie / Humangeographie. 2. Aufl., Stuttgart: UTB.

Heineberg, H. (2006b): Geographische Stadtmorphologie in Deutschland im internationalen und interdisziplinären Rahmen. In: Gans, P.; Priebs, A.; Wehrhahn, R. (Hrsg.): Kulturgeographie der Stadt. Kieler Geographische Schriften Band 111, S. 1–33.

Heineberg, H. (2006c): Grundriß Allgemeine Geographie: Stadtgeographie. 3. Aufl., Stuttgart: UTB.

Heinzle, F.; Anders, K.-H.; Sester, M. (2007): Automatic Detection of Pattern in Road Networks - Methods and Evaluation. In: International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 36 (Part 4/W45), CD-ROM.

Heinzle, F.; Kopczynski, M.; Sester, M. (2003): Spatial Data Interpretation for the Intelligent Accee to Spatial Information in the Internet. In: Proceedings of 21st International Cartographic Conference. S. 10–16.

Heinzle, F.; Sester, M. (2004): Derivation of Implicit Information from Spatial Data Sets with Data Mining. In: International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 35 (Part B4), 335–340.

Heissler, V.; Hake, G. (1970): Kartographie: Kartenaufnahme, Netzentwürfe, Gestaltungsmerkmale, topographische Karten. 4. Aufl., Walter De Gruyter.

Heitmann, S. (2011): Das neue Geobasisprodukt 3D-Gebäudestrukturen. In: Meinel, G.; Schuhmacher, U. (Hrsg.): Flächennutzungsmonitoring III: Erhebung - Analyse - Bewertung, IÖR-Schriften 58, Berlin: Rhombos-Verlag, S. 219–225.

Henderson, H. (2003): Encyclopedia of Computer Science and Technology. In: Reference Reviews incorporating ASLIB Book Guide. 17 (8), S. 38–39.

Henkel, G. (2004): Der Ländliche Raum: Gegenwart und Wandlungsprozesse seit dem 19. Jahrhundert in Deutschland. 4. Aufl., Borntraeger.

Henn, A,; Römer, C.; Gröger, G. et al. (2012): Automatic classification of building types in 3D city models Using SVMs for semantic enrichment of low resolution building data. In: GeoInformatica 16 (2), S. 281–306.

Hermosilla, T.; Ruiz, L. A.; Recio, J. A. et al. (2011): Evaluation of Automatic Building Detection Approaches Combining High Resolution Images and LiDAR Data. In: Remote Sensing 3 (6), S. 1188–1210.

Herold, H.; Meinel, G.; Hecht, R. et al. (2012): A GEOBIA approach to map interpretation – Multitemporal building footprint retrieval for high resolution monitoring of spatial urban dynamics. In: Proceedings of the 4th GEOBIA. São José dos Campos, INPE, S. 252–256.

Herold, H.; Hecht, R.; Meinel, G. (2011): Hochauflösende Modellierung urbaner Veränderungsprozesse auf Basis multitemporaler topographischer Kartenserien. In: Thinh, N. X.; Behnisch, M.; Margraf, O. (Hrsg.): Beiträge zur Theorie und quantitativen Methodik in der Geographie. IÖR-Schriften 57, Berlin: Rhombos-Verlag, S. 177–194.

Herold, H.; Meinel, G.; Csaplovics, E. (2010): An Approach to Spatio-Temporal Information Retrieval from Map Series for Monitoring Urban Dynamics. In: Wallgrün, J. O.; Lautenschütz, A.-K. (Hrsg.): Proceedings of the GIScience 2010 Doctoral Colloquium. Zürich: AKA Verlag (IfGIprints), S. 41–44.

Herold M.; Goldstein N.C.; Clarke K.C. (2003): The spatiotemporal form of urban growth: measurement, analysis and modeling. In: Remote Sensing of Environment. 86 (3), S. 286–302.

Herold, M.; Couclelis, H.; Clarke, K. C. (2005): The role of spatial metrics in the analysis and modeling of urban land use change. In: Computers, Environment and Urban Systems 29 (4), S. 369–399.

Herold, M.; Liu, X. H.; Clarke, K. C. (2003): Spatial Metrics and Image Texture for Mapping Urban Land Use. In: Photogrammetric Engineering & Remote Sensing 69 (9), S. 991–1001.

Herold, M.; Scepan, J.; Clarke, K. C. (2002): The use of remote sensing and landscape metrics to describe structures and changes in urban land uses. In: Environment and Planning A 34 (8), S. 1443–1458.

Hillier, B.; Hanson, J. (1984): The Social Logic of Space. Cambridge University Press.

Hoffmeyer-Zlotnik, J. H. P. (2005): Klassische Verfahren der innerstädtischen Typisierung. In: Arbeitsgruppe Regionale Standards (Hrsg.): Regionale Standards. 1. Aufl., Mannheim: ZUMA, S. 160–164.

Hofmeister, B. (1980): Die Stadtstruktur. Ihre Ausprägung in den verschiedenen Kulturräumen der Erde. Darmstadt: Wissenschaftliche Buchgesellschaft.

Hofmeister, B. (1993): Stadtgeographie. Braunschweig: Westermann.

Hofmeister, B. (2004): The study of urban form in Germany. In: Urban Morphology 8 (1), S. 3–12.

Horn, J. (1965): A rationale and test for the number of factors in factor analysis. In: Psychometrika 30 (2), S. 179–185.

Horton, R. E. (1932): Drainage-basin characteristics. In: Transactions American Geophysical Union (13), S. 350–361.

Hothorn, T.; Lausen, B. (2003): Double-bagging: combining classifiers by bootstrap aggregation. In: Pattern Recognition 36 (6), S. 1303–1309.

Hoyt, H. (1939): The structure and growth of residential neighborhoods in American cities. Washington: Federal Housing Administration.

Hruby, F.; Guerrero, R. M. (2008): Kartographie im Spannungsfeld expliziter und impliziter Forschung. In: Journal for Theoretical Cartography 1, S. 1–13.

Humphreys, G. W.; Bruce, V. (1989): Visual cognition: computational, experimental and neuropsychological perspectives. Psychology Press Ltd.

Hussain, M.; Davies, C.; Barr, R. (2007): Classifying Buildings Automatically: A Methodology. In: Proceedings of the Geographical Information Science Research UK 15th Annual Conference. Maynooth (Ireland), S. 343–347.

NZCS (2010): International Cartographic Association - Definitions. Homepage der New Zealand Cartographic Society, Download am 21.01.2010 via http://www.cartography.org.nz/index.php?option=com_content&view=section&id=7&Itemid=76

ICA (1973): Multilingual dictionary of technical terms in cartography. International Cartographic Association, Wiesbaden: Franz Steiner.

Illert, A. (1991): Automatic Digitization of Large Scale Maps. In: Auto-Carto 10: Technical Papers of the 1991 ACSM-ASPRS Annual Convention. Baltimore: ACSM-ASPRS, S. 113–122.

IMAGI; Bundesamt für Kartographie (Hrsg.) (2002): Geoinformation und moderner Staat. Eine Informationsschrift des Interministeriellen Ausschusses für Geoinformationswesen (IMAGI) im Jahr der Geowissenschaften 2002, Frankfurt am Main: BKG.

Imhof, E. (1972): Thematische Kartographie. Walter de Gruyter.

INSPIRE (2011a): D2.8.I.2 Data Specification on Geographical Grid Systems. INSPIRE. Download am 25.04.2011 via http://inspire.jrc.ec.europa.eu/documents/Data_Specifications/INSPIRE_Specification_GGS_v3.0.pdf

INSPIRE (2011b): D2.8.III.2 Data Specification on Building – Draft Guidelines. INSPIRE. Download am 25.04.2011 via http://inspire.jrc.ec.europa.eu/documents/Data_Specifications/INSPIRE_DataSpecification_BU_v3.0rc3.pdf

IÖR (2010): Forschung und Beratung für eine dauerhaft umweltgerechte Entwicklung von Städten und Regionen - Das Leibniz-Institut für ökologische Raumentwicklung 2010+. Broschüre. Dresden: IÖR.

IWU (2003): Deutsche Gebäudetypologie - Systematik und Datensätze. Institut Wohnen und Umwelt, Darmstadt. Download am 25.04.2011 via http://www.iwu.de/fileadmin/user_upload/dateien/energie/klima_altbau/Gebaeudetypologie_Deutschland.pdf

IWU (1990): Energiesparpotentiale im Gebäudebestand. Darmstadt: Institut Wohnen und Umwelt.

IWU (2004): Wohnungsbedarfsprognose Hessen 2020, im Auftrag des Hessischen Ministeriums für Wirtschaft, Verkehr und Landesentwicklung, Institut Wohnen und Umwelt. Darmstadt: Institut Wohnen und Umwelt.

Jackson, D. A. (1993): Stopping Rules in Principal Components Analysis: A Comparison of Heuristical and Statistical Approaches. In: Ecology 74 (8), S. 2204–2214.

Jaeger, J. A. G.; Bertiller, R.; Schwick, C. et al. (2010a): Suitability criteria for measures of urban sprawl. In: Ecological Indicators 10 (2), S. 397–406.

Jaeger, J. A. G.; Bertiller, R.; Schwick, C. et al. (2010b): Urban permeation of landscapes and sprawl per capita: New measures of urban sprawl. In: Ecological Indicators. 10 (2), S. 427–441.

Jähne, B. (2005): Digitale Bildverarbeitung. 6. Aufl., Springer.

Jain, A. K.; Dubes, R. C.; Chen, C.-C. (1987): Bootstrap Techniques for Error Estimation. In: IEEE Transactions on Pattern Analysis and Machine Intelligence. PAMI-9 (5), S. 628 –633.

Jiang, B. (1999): SimPed: Simulating Pedestrian Flows in a Virtual Urban Environment. In: Journal of Geographic Information and Decision Analysis 3 (1), S. 21–30.

Jiang, B.; Claramunt, C. (2002): Integration of Space Syntax into GIS: New Perspectives for Urban Morphology. In: Transactions in GIS 6 (3), S. 295–309.

Jolliffe, I. T. (1972): Discarding Variables in a Principal Component Analysis. I: Artificial Data. In: Journal of the Royal Statistical (Series C) 21 (2), S. 160–173.

Jolliffe, I. T. (1973): Discarding Variables in a Principal Component Analysis. II: Real Data. In: Journal of the Royal Statistical (Series C) 22 (1), S. 21–31.

Jolliffe, I. T. (2002): Principal Component Analysis. 2. Aufl., Springer.

Jonas, C. (2009): Die Stadt und Ihr Grundriss: Zu Form und Geschichte der deutschen Stadt nach Entfestigung und Eisenbahnanschluss, 2. Aufl., Wasmuth.

Kada, M. (2007): Zur maßstabsabhängigen Erzeugung von 3D-Stadtmodellen. Dissertation, Universität Stuttgart.

Kaiser, H. F. (1960): The application of electronic computers to factor analysis. In: Educational and Psychological Measurement 20, S. 141–151.

Kampshoff, S. (2005): Integration heterogener raumbezogener Objekte aus fragmentierten Geodatenbeständen. Dissertation, Rheinisch-Westfälische Technische Hochschule Aachen.

Karatzoglou, A.; Meyer, D.; Hornik, K. (2005): Support Vector Machines in R. In: Journal of Statistical Software 15 (9), S. 1–28.

Kasturi, R.; Alemany, J. (1988): Information Extraction from Images of Paper-Based Maps. In: IEEE Transactions on Software Engineering 14 (5), S. 671–675.

Keil, M.; Metz, A.; Bock, M. et al. (2010): Flächenerhebung und -statistik in CORINE Land Cover – Aktuelle Ergebnisse und Programmentwicklung. In: Meinel, G.; Schumacher, U. (Hrsg.): Flächennutzungsmonitoring II: Konzepte – Indikatoren – Statistik. IÖR-Schriften 52, Berlin: Rhombos-Verlag, S. 93–107.

Koch, W. G. (2001): Kartographische Darstellungsmethoden. In: Bollmann, J.; Koch, W. G. (Hrsg.): Lexikon der Kartographie und Geomatik: Karto bis Z. Spektrum Akademischer Verlag, S. 16–18.

Kohavi, R. (1995): A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection. In: International Joint Conference on Artificial Intelligence 14 (12), S. 1137–1143.

Kohavi, R.; John, G. H. (1997): Wrappers for Feature Subset Selection. In: Artificial Intelligence 97 (1), S. 273–324.

Kohler, N.; Bradley, P. E. (2007): Methodology for the survival analysis of urban building stocks. In: Building Research and Information 35 (5), S. 529–542.

Kolacny, A. (1969): Cartographic Information - A Fundamental Concept and Term in Modern Cartography. In: Cartographic Journal 6 (1), S. 47–49.

Kolbe, T. H.; Czerwinski, A.; Nagel, C. (2008): OpenGIS ® City Geography Markup Language (CityGML) Encoding Standard. Nr. OGC 08-007r1, Open Geospatial Consortium Inc.

Kolbe, T. H. (2008): Representing and Exchanging 3D City Models with CityGML. In: Lee, J.; Zlatanova, S. (Hrsg.): 3D Geo-Information Sciences. Springer.

König, R. (2010): Simulation und Visualisierung der Dynamik räumlicher Prozesse: Eine computergestützte Untersuchung zu den Wechselwirkungen zwischen baulichen Strukturen und sozialräumlicher Organisation städtischer Gesellschaften. Wiesbaden: VS Verlag.

Körner, S. (2011): Erfassung und Bewertung kartographischer Gebäudemuster in Topographischen Karten. Diplomarbeit, Technische Universität Dresden.

Koster, E. (1998): Urban Morphology and Computers. In: Urban Morphology 2 (1), S. 3–7.

Kowalke, H. (Hrsg.) (2000): Sachsen. Gotha; Stuttgart: Klett-Perthes.

Kpalma, K.; Ronsin, J. (2007): An Overview of Advances of Pattern Recognition Systems in Computer Vision. In: Obinata G.; Ashish Dutta and Dutta A. (Hrsg.): Vision Systems Segmentation and Pattern Recognition. Vienna: I-Tech Education and Publ.

Krauss, G. (1969): Die Topographische Karte 1:25000. In: Krauss, G.; Beck, W.; Appelt, G. et al. (Hrsg.): Die amtlichen topographischen Kartenwerke der Bundesrepublik Deutschland. Karlsruhe: Wichmann Verlag.

Krefeld (2009): Stadtumbau West – Innenstadt Krefeld. Städtebauliches Entwicklungskonzept). Download am 17.03.2014 via www.krefeld.de/C1257478002CCFBA/files/krefeld_stadtumbau_endbericht_.pdf/$file/krefeld_stadtumbau_endbericht_.pdf

Kresse, W. (2004): Standardization of Geographic Information. In: International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 35 (Part B2), S. 249 – 253.

Kresse, W.; Fadaie, K. (2004): ISO standards for geographic information. Springer.

Krug, H. (2006): Räumliche Wahlmöglichkeiten als Effizienzkriterium für Siedlung und Verkehr. Dissertation, Universität Kassel.

Krüger, M. J. T. (1979a): An approach to built-form connectivity at an urban scale: variations of connectivity and adjacency measures amongst zones and other related topics. In: Environment and Planning B: Planning and Design 6 (3), S. 305– 320.

Krüger, M. J. T. (1979b): An approach to built-form connectivity at an urban scale: system description and its representation. In: Environment and Planning B: Planning and Design 6 (1), S. 67– 88.

Kuncheva, L. I. (2004): Combining Pattern Classifiers: Methods and Algorithms. 1. Aufl., John Wiley & Sons.

Kunze, C. (2012): Vergleichsanalyse des Gebäudedatenbestandes aus OpenStreetMap mit amtlichen Datenquellen - Eine Vollständigkeitsanalyse am Beispiel von Sachsen und Nordrhein-Westfalen. Studienarbeit, Technische Universität Dresden.

Kunze, W. (2010): Das ATKIS Basis-DLM im neuen Gewand - was hat sich geändert. In: Meinel, G.; Schumacher, U. (Hrsg.): Flächennutzungsmonitoring II: Konzepte – Indikatoren – Statistik. Berlin: Rhombos-Verlag, S. 125–146.

Kwon, Y.-B. (2000): Detection of Black Point Houses on the Large Size Scanned Topographic Map. In: Chhabra, A. K.; Dori, D. (Hrsg.): Graphics Recognition Recent Advances. Lecture Notes in Computer Science Vol. 1941, Springer, S. 69–80.

Lai, C.-C.; Doong, S.-H.; Wu, C.-H.; Wah, B. W. (2008): Machine Learning. Wiley Encyclopedia of Computer Science and Engineering. 1. Aufl., John Wiley & Sons.

LAiV (2011): Migrationskonzept für Mecklenburg-Vorpommern: Teil IV - Gegenüberstellung ALK/ALB-ALKIS®: Teil IV. Technische Dokumentation, Version 3.0 (Stand: 20.07.2011). Download am 17.02.2012 via http://www.laiv-mv.de/land-mv/LAiV_prod/LAiV/AfGVK/Projekt_AAA/ALKIS/index.jsp

Lal, T.; Chapelle, O.; Weston, J.; et al. (2006): Embedded Methods. In: Guyon, I.; Gunn, S.; Nikravesh, M.; Zadeh, L. A. (Hrsg.): Feature Extraction: Foundations and Applications. 1. Aufl., Berlin; Heidelberg: Springer, S. 137–204.

Lammert, U.; Bauakademie der DDR; Institut für Städtebau und Architektur (Hrsg.) (1979): Städtebau: Grundsätze, Methoden, Beispiele, Richtwerte. Verlag für Bauwesen, VEB.

Landesvermessungsamt NRW (1967): Musterblatt für die Topographische Karte 1:25 000. Im Auftrag der AdV bearbeitet, Bad Godesberg: Landesvermessungsamt Nordrhein-Westfalen.

Landesvermessungsamt NRW (1981): Musterblatt für die Topographische Karte 1:25 000. Im Auftrag der AdV bearbeitet, 2. Aufl., Bad Godesberg: Landesvermessungsamt Nordrhein-Westfalen.

Landesvermessungsamt NRW (1993): Musterblatt für die Topographische Karte 1:25 000. Im Auftrag der AdV bearbeitet, 3. Aufl., Bad Godesberg: Landesvermessungsamt Nordrhein-Westfalen.

Landesvermessungsamt NRW (1998): Musterblatt für die Topographische Karte 1:25 000. Im Auftrag der AdV bearbeitet, 4. Aufl., Bad Godesberg: Landesvermessungsamt Nordrhein-Westfalen.

Landesvermessungsamt NRW (1995): Zeichenerklärung für die Deutsche Grundkarte 1: 5 000. 8. Aufl., Auszug aus dem Musterblatt für die Deutsche Grundkarte 1: 5.000, Bad Godesberg: Landesvermessungsamt Nordrhein-Westfalen.

Landis, J. R.; Koch, G. G. (1977): The measurement of observer agreement for categorical data. In: Biometrics 33 (1), S. 159–174.

Lang, S.; Blaschke, T. (2007): Landschaftsanalyse mit GIS. 1. Aufl., Stuttgart: UTB.

Lange, N. de (2005): Geoinformatik in Theorie und Praxis. 4. Aufl., Springer.

Larkham, P. J.; Jones, A. (1991): Glossary of Urban Form. Historical Geography Research Group.

Läuter, J. (1992): Stabile multivariate Verfahren: Diskriminanzanalyse - Regressionsanalyse - Faktoranalyse. Berlin: Akademie-Verlag.

Läuter, J.; Glimm, E.; Kropf, S. (1998): Multivariate tests based on left-spherically distributed linear scores. In: The Annals of Statistics 26 (5), S. 1972–1988.

Lee, D. S.; Shan, J.; Bethel, J. S. (2003): Class-Guided Building Extraction from Ikonos Imagery. In: Photogrammetric Engineering & Remote Sensing 69 (2), S. 143–150.

Lee, D. H.; Lee, K. M.; Lee, S. U. (2008): Fusion of Lidar and Imagery for Reliable Building Extraction. In: Photogrammetric Engineering and Remote Sensing 74 (2), S. 215–225.

Levin, S. A. (1992): The problem of pattern and scale in ecology. In: Ecology 73 (6), S. 1943–1967.

Levy, A. (1999): Urban Morphology and the problem of the modern urban fabric: some questions for research. In: Urban Morphology 3 (2), S. 79–85.

Leyk, S.; Boesch, R.; Weibel, R. (2006): Saliency and semantic processing: Extracting forest cover from historical topographic maps. In: Pattern Recognition 39 (5), S. 953–968.

Leyk, S.; Zimmermann, N. E. (2006): Improving land change detection based on uncertain survey maps using fuzzy sets. In: Landscape Ecology 22 (2), S. 257–272.

Li, Z.; Yan, H.; Ai, T. et al. (2004): Automated building generalization based on urban morphology and Gestalt theory. In: International Journal of Geographical Information Science 18 (5), S. 513–534.

Liaw, A.; Wiener, M. (2002): Classification and regression by randomForest. In: R News 2 (3), S. 18–22.

Lichtenberger, E. (1998): Stadtgeographie, Band1: Begriffe, Konzepte, Modelle, Prozesse. 3. Aufl., Teubner.

Lim, T.-S.; Loh, W.-Y.; Shih, Y.-S. (1998): An Empirical Comparison of Decision Trees and Other Classification Methods. Technical Report 979, Department of Statistics, University of Wisconsin.

Link, I.; Wiegand, P. (2011): Von Kursachsen nach Europa - Digitales Kartenforum der SLUB erheblich erweitert. In: Das Magazin der Bibliotheken in Sachsen (2), S. 74–77.

Liu, C.; Frazier, P.; Kumar, L. (2007): Comparative assessment of the measures of thematic classification accuracy. In: Remote Sensing of Environment 107 (4), S. 606–616.

Liu, X.; Jiang, B. (2010): Defining and Generating Axial Lines from Street Center Lines for better Understanding of Urban Morphologies. In: International Journal of Geographical Information Science 26 (8), 1521–1532.

Loga, T.; Diefenbach, N.; Born, R. (2011): Deutsche Gebäudetypologie - Beispielhafte Maßnahmen zur Verbesserung der Energieeffizienz von typischen Wohngebäuden. Darmstadt: Institut Wohnen und Umwelt GmbH.

Longley, P. A. (2002): Geographical Information Systems: will developments in urban remote sensing and GIS lead to 'better' urban geography? In: Progress in Human Geography 26 (2), S. 231–239.

Longley, P. A.; Goodchild, M. F.; Maguire, D. J. et al. (2005): Geographic Information Systems and Science. 2. Aufl., Wiley.

Longley, P. A.; Mesev, V. (2000): On the measurement and generalisation of urban form. In: Environment and Planning A 32 (3), S. 473–488.

Luft, H.; Bender, G. (1998): Fachwörterbuch: Benennungen und Definitionen im Deutschen Vermessungswesen mit englischen und französischen Äquivalenten / Stadtplanung, Raumordnung. Band 15, 1. Aufl., Frankfurt am Main: Inst. für Angewandte Geodäsie.

Lüscher, P.; Burghardt, D.; Weibel, R. (2007): Ontology-driven Enrichment of Spatial Databases. In: Proceedings of the 9th Workshop on Generalisation and Multiple Representation. Moscow, 2-3 August 2007. Download am 17.02.2012 via http://www.geo.uzh.ch/~luescher/publications/luescher_genws2007.pdf

Lüscher, P.; Weibel, R.; Burghardt, D. (2008a): Alternative options of using processing knowledge to populate ontologies for the recognition of urban concepts. In: Proceedings of the 11th ICA Workshop on Generalisation and Multiple Representation. Montpellier, 20-23 June 2008. Download am 17.02.2012 via http://www.geo.uzh.ch/~luescher/publications/luescher_genws2008.pdf

Lüscher, P.; Weibel, R.; Burghardt, D. (2009): Integrating ontological modelling and Bayesian inference for pattern classification in topographic vector data. In: Computers, Environment and Urban Systems. 33 (5), S. 363–374.

Lüscher, P.; Weibel, R.; Mackaness, W. (2008b): Where is the terraced house?: on the use of ontologies for recognition of urban concepts in cartographic databases. In: Ruas, A.; Gold, C. (Hrsg.): Headway in spatial data handling. Berlin, Heidelberg: Springer, S. 449–466.

Lüthy, S. (2009): Merkmalswichtigkeit im Random Forest. Masterarbeit, Eidgenössische Technische Hochschule Zürich.

Lwin, K.-K.; Murayama, Y. (2009): A GIS Approach to Estimation of Building Population for Micro-spatial Analysis. In: Transactions in GIS 13 (4), S. 401–414.

Lynch, K. (1960): The image of the city. 20. Aufl., MIT Press.

Maceachren, A. M. (1985): Compactness of Geographic Shape: Comparison and Evaluation of Measures. In: Geografiska Annaler. Series B, Human Geography 67 (1), S. 53–67.

MacEachren, A. M. (1995): How Maps Work: Representation, Visualization, and Design. Guilford Pubn.

Mackaness, William A.; Chaudhry, O. Z. (2011): Automatic Classification of Retail Spaces from a Large Scale Topographic Database. In: Transactions in GIS 15 (3), S. 291–307.

Mackaness, W. A.; Ruas, A.; Sarjakoski, L. T. (2007): Generalisation of geographic information: cartographic modelling and applications. Amsterdam: Elsevier Science.

Madelin, M.; Grasland, C.; Mathian, H. et al. (2009): Das MAUP: Modifiable Areal Unit – Problem oder Fortschritt? In: BBSR im BBR (Hrsg.): Kartographische Visualisierung in der Raumplanung. Informationen zur Raumentwicklung, Heft 10/11 2009, S. 645–660.

Maderlechner, G.; Mayer, H. (1994): Automated acquisition of geographic information from scanned maps for GIS using frames and semantic networks. In: Proceedings of 12th International Conference on Pattern Recognition. Jerusalem, Israel, S. 361–363.

Mandelbrot, B. B. (1983): The Fractal Geometry of Nature. 1. Aufl., WH Freeman.

Manning, C. D.; Raghavan, P.; Schütze, H. (2008): Introduction to Information Retrieval. Cambridge University Press.

March, L.; Steadman, P. (1974): The geometry of environment: an introduction to spatial organization in design. MIT Press.

Mark, D. M. (2003): Geographic Information Science: Defining the Field. In: Duckham, M.; Goodchild, M. F.; Worboys, M. F. (Hrsg.): Foundations of Geographic Information Science. New York: Taylor and Francis, S. 1–18.

Marr, D. (1982): Vision: A Computational Investigation into the Human Representation and Processing of Visual Information. W.H.Freeman & Co Ltd.

Marshall, S. (2005): Streets and patterns. London; New York: Spon Press (Taylor & Francis Group).

Martin, J. L.; March, L. (1972): Urban Space and Structures. Cambridge Urban and Architectural Studies, Cambridge University Press.

Martiny, R. (1928): Die Grundrissgestaltung der deutschen Siedlungen. Gotha: Perthes.

Mathey, J.; Rößler, S.; Lehmann, I.; Bräuer, A.. (2011): Urban Green Spaces: Potentials and Constraints for Urban Adaptation to Climate Change. In: Otto-Zimmermann, K. (Hrsg.): Resilient Cities. Cities and Adaptation to Climate Change. Proceedings of the Global Forum 2010. Local Sustainability, 1, Springer, S. 479–485.

Matikainen, L.; Hyyppä, J.; Ahokas, E. et al. (2010): Automatic Detection of Buildings and Changes in Buildings for Updating of Maps. In: Remote Sensing 2 (5), S. 1217–1248.

Mayer, H. (1999): Automatic Object Extraction from Aerial Imagery – A Survey Focusing on Buildings. In: Computer Vision and Image Understanding 74 (2), S. 138–149.

Mayer, S. (2004): Automatisierte Objekterkennung zur Interpretation hochauflösender Bilddaten in der Erdfernerkundung. Dissertation, Humboldt-Universität zu Berlin.

MBO (2002): Musterbauordnung – MBO. Fassung November 2002. Download am 17.02.2012 via http://www.is-argebau.de/lbo/VTMB100.pdf

McGarigal, K.; Marks, B. (1994): FRAGSTATS: Spatial Pattern Analysis Program for Quantifying Landscape Structure. Technical Report PNW-GTR-351. United States Deparment of Agriculture. Download am 17.02.2012 via http://www.fs.fed.us/pnw/pubs/gtr_351.pdf

MdI (1984): ACD13-16: Zeichenvorschrift, Instruktion und Redaktionsanweisung für die Bearbeitung der Topographischen Karten 1: 25 000, 1: 50 000, 1: 100 000, 1: 200 000, des Topographischen Stadtplans 1: 25 000 und der Topographischen Karte 1: 200 000 (zweisprachig). 4. Aufl., Berlin: Ministerium des Innern, Verwaltung Vermessungs- und Kartenwesen.

Meinel, G.; Krüger, T.; Schumacher, U. et al. (2012): Neue Entwicklungen und Analyseergebnisse des Monitors der Siedlungs- und Freiraumentwicklung sowie Schlussfolgerungen für das Flächenmonitoring. In: Meinel, G.; Schumacher, U.; Behnisch, M. (Hrsg.): Flächennutzungsmonitoring IV. Genauere Daten - informierte Akteure - praktisches Handeln. IÖR-Schriften 60, Berlin: Rhombos-Verlag, S. 41–51.

Meinel, G. (2009): Konzept eines Monitors der Siedlungs- und Freiraumentwicklung auf Grundlage von Geobasisdaten. In: Flächennutzungsmonitoring. Konzepte - Indikatoren - Statistik. Aachen: Shaker, S. 177–194.

Meinel, G.; Hecht, R.; Herold, H. (2009): Analyzing building stock using topographic maps and GIS. In: Building Research & Information 37 (5-6), S. 468–482.

Meinel, G.; Hecht, R.; Herold, H.; Schiller G. (2008a): Automatische Ableitung von stadtstrukturellen Grundlagendaten und Integration in einem Geographischen Informationssystem. Berlin; Bonn: BMVBS; BBR (Forschungen, Bundesministerium für Verkehr, Bau und Stadtentwicklung, Bundesamt für Bauwesen und Raumordnung).

Meinel, G.; Knop, M.; Hecht, R. (2008b): Qualitätsaspekte und Verfügbarkeit digitaler Geobasidaten in Deutschland unter besonderer Berücksichtigung des ATKIS Basis-DLM und der DTK25(-V). In: Photogrammetrie - Fernerkundung - Geoinformation 1/2008, S. 29–40.

Meng, L.; Forberg, A. (2007): 3D Building Generalisation (Chapter 11). In: Mackaness, William A; Ruas, Anne (Hrsg.): Generalisation of Geographic Information. Amsterdam: Elsevier Science, S. 211–231.

Meng, X. (2010): Determining Urban Land Uses Through Building-associated Element Attributes Derived from LIDAR and Aerial Photographs. Dissertation, Texas State University-San Marcos.

Mersmann, O. (2011): Package 'microbenchmark'. Download am 03.12.2012 via http://cran.r-project.org/web/packages/microbenchmark/microbenchmark.pdf

Mesev, V. (2007): Fusion of point-based postal data with IKONOS imagery. In: Information Fusion 8 (2), S. 157–167.

Mesev, V. (2005): Identification and characterisation of urban building patterns using IKONOS imagery and point-based postal data. In: Computers Environment and Urban Systems 29 (5), S. 541–557.

Meyer, D.; Leisch, F.; Hornik, K. (2002): Benchmarking Support Vector Machines. Report Series No. 78, Vienna University of Economics. Download am 23.09.2011 via http://epub.wu.ac.at/1578/1/document.pdf

MHHR (2008): Muster-Richtlinie über den Bau und Betrieb von Hochhäusern: Erläuterungen. Download am 22.06.2011 via http://www.umwelt-online.de/recht/bau/argebau/mhhre1.htm

Microm (2012): Übersicht microm MARKET - Alle Variablenpakete im Überblick. Download am 03.02.2012 via http://www.microm-online.de/Ressourcen/PDF/Broschueren/micromMARKET_Uebersicht.pdf

Milborrow, S. (2012): Package 'earth'. Technical Report. Download am 03.12.2012 via http://cran.r-project.org/web/packages/earth/earth.pdf

Miller, H. J.; Han, J. (2001): Geographic Data Mining and Knowledge Discovery. 1. Aufl., CRC Press.

Mosch, M. (2005): 3D-Gebäudeextraktion aus Satellitenbildern suburbaner Regionen. Dissertation, Universität Freiburg.

Moudon, A. V. (1997): Urban Morphology as an emerging interdisciplinary field. In: Urban Morphology 1, S. 3–10.

Muhs, S.; Meinel, G.; Burghardt, D. (2012): Konzept und Ergebnisse einer automatisierten Baublockabgrenzung aus topographischen Kartenwerken. In: Kartographische Nachrichten 62 (3), S. 145–150.

Müller, J. C. (1990): Rule Based Generalization: Potentials and Impediments. In: Proceedings 4th International Symposium on Spatial Data Handling. Zürich, S. 317–334.

Müller, W. (1979): Städtebau. Teubner.

Müller, W.; Korda, M. (1999): Städtebau. Teubner.

MVTec Software GmbH (2009): Quick Guide to HALCON. MVTec Software GmbH.

Myint, S. W.; Mesev, V.; Lam, N. (2006): Urban textural analysis from remote sensor data: lacunarity measurements based on the differential box counting method.. In: Geographical Analysis 38 (4), S. 371–390.

Næsset, E. (1996): Use of the weighted Kappa coefficient in classification error assessment of thematic maps. In: International journal of geographical information systems 10 (5), S. 591–603.

Naumann, T.; Nikolowski, J.; Golz, S. et al. (2011): Resilience and Resistance of Buildings and Built Structures to Flood Impacts – Approaches to Analysis and Evaluation. In: Müller, B. (Hrsg.): Urban Regional Resilience: How Do Cities and Regions Deal with Change? German Annual of Spatial Research and Policy 2010, Berlin; Heidelberg: Springer, S. 89–100.

Neidhart, H.; Sester, M. (2004): Identifying Building Types and Building Clusters Using 3D-Laser Scanning and GIS-Data. In: International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences 35 (Part B4), S. 715–720.

Neisser, U. (1967): Cognitive psychology. New York: Appleton-Century-Crofts.

Neubert, M. (2006): Bewertung, Verarbeitung und segmentbasierte Auswertung sehr hoch auflösender Satellitenbilddaten vor dem Hintergrund landschaftsplanerischer und landschaftsökologischer Anwendungen. Dissertation, Technischen Universität Dresden, Berlin: Rhombos-Verlag.

Neun, M.; Weibel, R.; Burghardt, D. (2004): Data enrichment for adaptive generalisation. In: Proceedings of the 7th ICA Workshop on Generalisation and Multiple representation, Leicester, UK. Download am 12.8.2011 via http://www.geo.uzh.ch/~burg/literatur/res/leicester_degen.pdf

Niemann, Heinrich (2003): Klassifikation von Mustern. 2. Überarbeitete Auflage im Internet. Download am 22.7.2012 via www5.informatik.uni-erlangen.de/fileadmin/Persons/NiemannHeinrich/klassifikation-von-mustern/m00-www.pdf

Nikolowski, J.; Hennersdorf, J.; May, F. (2012): Gebäudetypen der Modellregion Dresden. In: Weller, B.; Naumann, T.; Jakubetz, S. (Hrsg.): Gebäude unter den Einwirkungen des Klimawandels. Berlin: Rhombos-Verlag, S. 67-122.

Nixon, M. S.; Aguado, A. S. (2008): Feature extraction and image processing. Academic Press.

Noth, M.; Borning, A.; Waddell, P. (2001): An extensible, modular architecture for simulating urban development, transportation, and environmental impacts. In: Computers Environment and Urban Systems, S. 181–203.

O'Neill, R. V.; Krummel, J. R.; Gardner, R. H. et al. (1988): Indices of landscape pattern. In: Landscape Ecology 1 (3), S. 153–162.

O'Neill, R. V. (1986): A Hierarchical Concept of Ecosystems. Princeton University Press.

OBAK-LiKa RP (2008): Richtlinien zur Bildung und Abbildung von Objekten der Automatisierten Liegenschaftskarte - Objektabbildungskatalog Liegenschaftskarte Rheinland-Pfalz (OBAK-LiKa RP). Vermessungs- und Katasterverwaltung Rheinland-Pfalz. Download am 29.5.2012 via http://tzmz.service24.rlp.de/tz_wiki/images/f/f4/OBAK.pdf

OBAK-LiKa SN (2005): Objektabbildungskatalog (OBAK). Staatsbetrieb Geobasisinformation und Vermessung Sachsen. Download am 12.12.2012 via http://www.landesvermessung.sachsen.de/inhalt/produkte/lika/alk/download/K-5-05N1_CA2.pdf

Ogrissek, R. (1987): Theoretische Kartographie. 1. Aufl., Gotha: Haack.

Omer, I.; Gabay, R. (2007): Social Homogeneity and Space Syntax of Towns in Israel. In: Proceedings of the 6th International Space Syntax Symposium, Istanbul. Download am 12.12.2012 via http://www.spacesyntaxistanbul.itu.edu.tr/papers%5Cshortpapers%5C108%20-%20Omer%20Gabay.pdf

Openshaw, S. (1984): The Modifiable Areal Unit Problem. Concepts and Techniques in Modern Geography, Vol. 38, Norwich: Geo Books.

Orford, S.; Radcliffe, J. (2007): Modelling UK residential dwelling types using OS Mastermap data: A comparison to the 2001 census. In: Computers, Environment and Urban Systems. 31 (2), S. 206–227.

Ostrau, S. (2010): Konzept zur Harmonisierung und Präsentation von Nutzungsdaten auf Grundlage des 3A-Modells. Dissertation, Rheinische Friedrich-Wilhelms-Universität zu Bonn.

Oza, N. C. (2003): Boosting with averaged weight vectors. In: Windeatt, T.; Roli, F. (Hrsg.): Proceedings of the 4th international conference on Multiple classifier systems. Berlin; Heidelberg: Springer, S. 15–24.

Paetz, J. (2006): Soft Computing in der Bioinformatik: Eine grundlegende Einführung und Übersicht. 1. Aufl., Berlin; Heidelberg: Springer.

Parker, S. P. (2002): The McGraw-Hill Dictionary of Scientific and Technical Terms. 6. Aufl., McGraw-Hill Professional.

Pasko, M.; Gruber, M. (1996): Fusion of 2D GIS Data and Aerial Images for 3D Building Reconstruction. In: International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 31 (Part B3), S. 257–260.

Pauleit, S.; Duhme, F. (1999): Stadtstrukturtypen. Bestimmung der Umweltleistungen von Stadtstrukturtypen für die Stadtplanung. In: RaumPlanung (84), S. 33–44.

Pearl, J. (1988): Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference. 1. Aufl., Morgan Kaufmann.

Peisker, T. (2006): Klassifizierung von Stadtbiotoptypen mit wissensbasierten Fuzzy-Logik-Modellen basierend auf hyperspektralen Flugzeugscannerdaten. Diplomarbeit, Technische Universität Dresden.

Pellegrini, T.; Blumauer, A. (Hrsg.) (2006): Semantic Web: Wege zur vernetzten Wissensgesellschaft. Berlin; Heidelberg: Springer.

Peter, B. (2001): Measures for the generalization of polygonal maps with categorical data. In: 4th Workshop on Progress in Automated Map Generalization. Beijing.

Peters, A.; Hothorn, T. (2011): Package 'ipred': Improved Predictors. Technical Report. Download am 03.12.2012 via http://cran.r-project.org/web/packages/ipred/ipred.pdf

Piechocki, W. (1994): Halle und seine Geschichte. Halle (Saale): Fliegenkopf Verlag.

Pile, S. (1999): What is a city? In: Massey, Doreen B.; Allen, J.; Pile, S. (Hrsg.): City worlds. Routledge, S. 4–19.

Pinz, A. (1994): Bildverstehen. Wien; New York: Springer.

Preuß T; Floeting H. (2009): Folgekosten der Siedlungsentwicklung. Bewertungsansätze, Modelle und Werkzeuge der Kosten-Nutzen-Betrachtung. Beiträge aus der REFINA-Forschung, Reihe REFINA, Band III, Berlin: Difu.

Quinlan, J. R. (1993): C4.5: Programs for Machine Learning. Morgan Kaufmann Publishers.

Raheja, J. L. (2005): Recognition of 3D settlement structure for generalization. Dissertation, Technische Universität München.

Rainsford, D.; Mackaness, W. A. (2002): Template Matching in Support of Generalisation of Rural Buildings. In: Richardson, D.; Oosterom, P. Van (Hrsg.): Advances in Spatial Data Handling. 10th International Symposium on Spatial Data Handling. Berlin: Springer, S. 137–152.

Rashed, T.; Jürgens, C. (2010): Remote Sensing of Urban and Suburban Areas. 1. Aufl., Springer.

RatSWD (2011): Endbericht der AG „Georeferenzierung von Daten" des RatSWD. Bericht der Arbeitsgruppe und Empfehlung des Rates für Sozial- und Wirtschaftdaten (RatSWD). Download am 28.03.2013 via http://ratswd.de/Geodaten/downloads/RatSWD_Endbericht_Geo-AG.pdf

Regnauld, N. (2001): Contextual Building Typification in Automated Map Generalization. In: Algorithmica 30 (2), S. 312–333.

Regnauld, N.; McMaster, R. B. (2007): A Synoptic View of Generalisation Operators. In: Mackaness, W. A.; Ruas, A.; Sarjakoski, L. T. (Hrsg.): Generalisation of geographic information: cartographic modelling and applications. Amsterdam: Elsevier Science, S. 37–66.

Rengelink, M.; van Oosterom, P. J. M.; Quak, C. W. et al. (2000): Automatic Derivation and Classification of Houses on a Cadastral Map. Urban Data Management Society.

Revell, P.; Antoine, B. (2009): Automated matching of building features of differing levels of detail: A case study. In: In Proceedings of the 24th International Cartography Conference. Santiago de Chile, Chile.

Richards, J. A. (1996): Classifier performance and map accuracy. In: Remote Sensing of Environment 57 (3), S. 161–166.

Ripley, B. D. (1996): Pattern recognition and neural networks. Cambridge University Press.

Ripperda, N. (2010): Rekonstruktion von Fassadenstrukturen mittels formaler Grammatiken und Reversible Jump Markov Chain Monte Carlo Sampling. Dissertation, Wissenschaftliche Arbeiten der Fachrichtung Geodäsie und Geoinformatik der Leibniz Universität Hannover, Nr. 284.

Ritter, E.-H. (2005): Freiraum. In: Akademie für Raumforschung und Landesplanung (Hrsg.): Handwörterbuch der Raumordnung. 4. Aufl., Hannover: Eigenverlag, S. S. 831–841.

Röhm, P.; Herold, H.; Meinel, G. (2012): Automatische Georeferenzierung gescannter deutscher Topographischer Karten im Maßstab 1: 25.000. In: Kartographische Nachrichten 62 (4), S.195–199

Roli, F.; Kittler, J.; Windeatt, T. (2004): Multiple Classifier Systems: 5th International Workshop, MCS 2004, Cagliari, Italy, June 9-11, 200, Proceedings, Lecture Notes in Computer Science, Vol. 3077, Springer.

Römer, C.; Plümer, L. (2010): Identifying Architectural Style in 3D City Models with Support Vector Machines. In: Photogrammetrie - Fernerkundung - Geoinformation 5/2010, S. 371–384.

Rose, A.; Schwander, C.; Czerkauer, C. et al. (2008): Space Matters. In: Arch+ : Zeitschrift für Architektur und Städtebau (189), S. 32–37.

Rosenblatt, F. (1958): The Perceptron: A probabilistic model for information storage and organization in the brain. In: Psychological Review 65, S. 386–408.

Rosenfeld, A. (2001): From Image Analysis to Computer Vision: An Annotated Bibliography, 1955–1979. In: Computer Vision and Image Understanding 84 (2), S. 298–324.

Ruas, A.; Holzapfel, F. (2003): Automatic characterisation of building alignments by means of expert knowledge. In: Proceedings of the 21st International Cartographic Conference, S. 1604–1615.

Rubinstein, Y. D.; Hastie, T. (1997): Discriminative vs Informative Learning.. In: Heckerman, D.; Mannila, H.; Pregibon, D. (Hrsg.): Proceedings of the Third International Conference on Knowledge Discovery and Data Mining. Menlo Park: AAAI Press, S. 49–53.

Satterthwaite, D.; Huq, S.; Pelling, et al. (2007): Adapting to Climate Change in Urban Areas: The Possibilities and Constraints in Low- and Middle-Income Nations. Human Settlements Discussion Paper Series, IIED.

Schalkoff, J. R.; Wah, B. W. (Hrsg.) (2008): Pattern Recognition. Wiley Encyclopedia of Computer Science and Engineering. 1. Aufl., John Wiley & Sons.

Schemionek, C. (2005): New urbanism in US-amerikanischen Stadtregionen: Ein effektives Planungskonzept gegen Urban Sprawl? Dissertation, Institut für Geographie, Universität Würzburg.

Schiller, G. (2010): Kostenbewertung der Anpassung zentraler Abwasserentsorgungssysteme bei Bevölkerungsrückgang. IÖR-Schriften 51 Berlin: Rhombos-Verlag.

Schiller, G.; Blum, A.; Behnisch, M. (2012): Resource Efficiency of Settlement Structures: Terms, Conceptual Implications and Connecting Factors to the Resilience Debate. In: Raumforschung und Raumordnung 70 (4), S. 377–386.

Schiller, G.; Gutsche, J.-M.; Siedentop, S. (2009): Von der Außen- zur Innenentwicklung in Städten und Gemeinden – Das Kostenparadoxon der Baulandentwicklung. Texte 31/2009. Dessau-Roßlau: Umweltbundesamt

Schiller, G.; Siedentop, S. (2010): Der Einsatz von Siedlungsstrukturtypen zur Schätzung zukünftiger Infrastrukturkosten auf regionaler Ebene. In: Blum, A.; Gruhler, K. (Hrsg.): Typologien der gebauten Umwelt - Modellierung und Analyse der Siedlungsentwicklung mit dem Strukturtypenansatz. Aachen: Shaker, S. 81–90.

Schirmer, P. (2010): Options and constraints of a parcel based approach in UrbanSimE. Eidgenössische Technische Hochschule Zürich, IVT, Institut für Verkehrsplanung und Transportsysteme. Download am 28.03.2013 via http://e-collection.library.ethz.ch/eserv/eth:4599/eth-4599-01.pdf

Schirmer, P.; Zöllig, C.; Müller, K. et al. (2011): The Zurich Case Study of UrbanSIM. Eidgenössische Technische Hochschule Zürich, IVT. Download am 28.03.2013 via http://e-collection.library.ethz.ch/eserv/eth:3085/eth-3085-01.pdf

Schlüter, O. (1899): Über den Grundriss der Städte. In: Zeitschrift der Gesellschaft für Erdkunde 34, Berlin, S. 446–462.

Schmitt, U.; Sulzer, W.; Schardt, M. (1998): Analysis of settlement structure by means of high resolution satellite imagery. In: International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 32 (Part B4), S. 557–562.

Schölkopf, B.; Smola, A. J.; Schalkopf, B. (2001): Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond. MIT Press.

Schönheit, R. (2011): Das kleinräumige städtische Gliederungssystem AGK als Basis intrakommunaler Informationssysteme. In: Meinel, G.; Schuhmacher, U. (Hrsg.): Flächennutzungsmonitoring III: Erhebung - Analyse - Bewertung, IÖR-Schriften 58, Berlin : Rhombos-Verlag, S. 219–225.

Schulz, J. (2000): Praktischer Einsatz des Gebäude-Generalisierungsprogramms CHANGE bei der Ableitung der Digitalen Topographischen Karte 1: 25.000. In: Mitteilungen des Bundesamtes für Kartographie und Geodäsie, Band 17, Frankfurt am Main: BKG, S. 93–103.

Schulze, H.-J.; Walter, R. (1990): Gebäudeatlas- Mehrfamilienwohngebäude der Baujahre 1880 bis 1980. Berlin: Bauinformation.

Schumm, S. A. (1956): Evolution of Drainage Systems and Slopes in Badlands at Perth Amboy, New Jersey. In: Geological Society of America Bulletin 67 (5), S. 597–646.

Schürer, D. (2002): Ableitung von digitalen Landschaftsmodellen mit geringem Strukturierungsgrad durch Modellgeneralisierung. Dissertation, Schriftenreihe des Instituts für Kartographie und Topographie der Universität Bonn 28, Rheinische Friedrich-Wilhelms-Universität Bonn.

Schüssler, F. (2000): Geomarketing: Anwendungen Geographischer Informationssysteme im Einzelhandel. Tectum Verlag.

Schwarz, D. F.; König, I. R.; Ziegler, A. (2010): On safari to Random Jungle: a fast implementation of Random Forests for high-dimensional data. In: Bioinformatics 26 (14), S. 1752–1758.

Seidl, E. (2006): Lexikon der Bautypen: Funktionen und Formen der Architektur. Stuttgart: Reclam.

Seifert, M. (2004): Der Standard ALKIS - Was bringt er? In: Vermessung Brandenburg 2/2004, S. 25–33.

Selfridge, O. G. (1959): A paradigm for learning. In: Blake, D. V.; Uttley, A. M. (Hrsg.): Mechanisation of thought processes; proceedings of a symposium held at the National Physical Laboratory on 24th, 25th, 26th and 27th November 1958. London: Her Majesty's Stationery Office, S. 511–529.

Selfridge, O. G.; Neisser, U. (1960): Pattern recognition by machine. In: Scientific American 203, S. 60–68.

Senatsverwaltung für Stadtentwicklung (2012): Digitaler Umweltatlas Berlin = Berlin Digital Environmental Atlas. Umweltatlas / Senatsverwaltung für Stadtentwicklung und Umwelt – Berlin. Download am 12.12.2012 von www.stadtentwicklung.berlin.de/umwelt/umweltatlas.

Sester, M. (2000): Knowledge acquisition for the automatic interpretation of spatial data. In: International Journal of Geographical Information Science 14 (1), S. 1–24.

Sester, M. (1995): Lernen struktureller Modelle für die Bildanalyse. Dissertation, Universität Stuttgart.

Sester, M.; Haunert, J. H.; Anders, K.-H. (2008): Modell- und kartographische Generalisierung von topographischen und thematischen Informationen. In: Kartographische Nachrichten 58 (6), S. 307–314.

SGK (1980): Kartographische Generalisierung: topographische Karten. 2. Aufl., Kartographische Schriftenreihe 1, Bern: Schweizerische Gesellschaft für Kartographie.

Shan, J.; Lee, S. D. (2005): Quality of Building Extraction from IKONOS Imagery. In: Journal of Surveying Engineering 131 (1), S. 27–32.

Shekhar, S.; Hui, X.; Goodchild, M. F. (Hrsg.) (2008): Spatial Data Analysis. In: Encyclopedia of GIS. Springer, S. 200–203.

Sheppard, E. S.; McMaster, R. B. (2004): Scale and Geographic Inquiry: Nature, Society, and Method. Blackwell Publishing.

Shevky, E.; Bell, W. (1955): Social Area Analysis: Theory, Illustrative Application and Computational Procedures. Stanford University Press.

Siedentop, S. (2005): Urban Sprawl - verstehen, messen, steuern. Ansatzpunkte für ein empirisches Mess- und Evaluationskonzept der urbanen Siedlungsentwicklung. In: DISP 160, S. 23–35.

Siemer, J. (2004): Zeichenorientierte Landschaftsmodelle aus graphikfreien Landschaftsmodellen für Anwendungen im Hochwasserschutz. Dissertation, Mathematisch-Naturwissenschaftliche Fakultät, Universität Potsdam.

Simms, A. (2004): Neue Wege der historisch-geographischen Erforschung von Stadtlandschaften in der anglo-amerikanischen Geographie. In: Johanek, P.; Post, F.-J. (Hrsg.): Vielerlei Städte. Der Stadtbegriff. Köln/Weimar/Wien: Böhlau), Städteforschung A 61, S. 53–70.

Simon, M. (1990): Das Ring-Sektoren-Modell: Ein Erfassungsinstrument für demografische und sozio-ökonomische Merkmale und Pendlerbewegungen in gleichartig definierten Stadt-Umland-Gebieten: Grundlagen, Methodik, Empirie. Dissertation, Geographica Bernensia G 36, Geografisches Institut, Universität Bern.

De Simone, M. (1986): Automatic Structuring and Feature Recognition for Large Scale Digital Mapping. In: Proceedings of Auto-Carto London Volume 1: Hardware, Data Capture and Management Techniques. London, S. 86–95.

Skupin, A. (2009): Discrete and continuous conceptualizations of science: Implications for knowledge domain visualization. In: Journal of Informetrics 3 (3), S. 233–245.

Smith, D.; Crooks, A. (2010): From buildings to cities: techniques for the multi-scale analysis of urban form and function. CASA Working Papers 155. Centre for Advanced Spatial Analysis (UCL), London.

Smith, E. E. (2001): Cognitive Psychology: History. In: Smelser N. J.; Baltes P. B. (Hrsg.): International Encyclopedia of the Social and Behavioral Sciences, New York: Elsevier, S. 2140–2147.

Smith, M. J. de; Goodchild, M. F.; Longley, P. A. (2007): Geospatial Analysis. 2. Aufl., Troubador Publishing Ltd.

Sohn, G.; Dowman, I. (2007): Data fusion of high-resolution satellite imagery and LiDAR data for automatic building extraction. In: ISPRS Journal of Photogrammetry and Remote Sensing 62 (1), S. 43–63.

Sonquist, J. A.; Morgan, J. N. (1964): The detection of interaction effects a report on a computer program for the selection of optimal combinations of explanatory variables. Ann Arbor: Survey Research Center, University of Michigan.

Sörgel, U. (2006): Stand der Technik und Trends der Radarfernerkundung: Festschrift 125 Jahre Geodäsie und Geoinformatik. In: Wissenschaftliche Arbeiten der Fachrichtung Geodäsie und Geoinformatik der Leibniz Universität Hannover, Band 263, S. 295–302.

Spiess, E. (2002): Topografische Karten - Kartengrafik und Generalisierung. Cartographic publication series 16, Wabern: Schweizerische Gesellschaft für Kartographie.

Stadt Krefeld (2012): Flächennutzungsplan der Stadt Krefeld. Wirksamer Flächennutzungsplan, Stand Dez. 2012. Download am 22.03.2013 via http://www.krefeld.de/C1257478002CCFBA/files/fnp_begruendung120613.pdf/$file/fnp_begruendung120613.pdf?OpenElement

Stadtverwaltung Stolpen (2012): Stolpen. Internetauftritt der Stadtverwaltung Stolpen. Download am 12.12.2012 via http://www.stolpen.de.

Stams, M.; Stams, W. (1998): Amt, Burg und Stadt Stolpen in alten Karten und Plänen: Abriß zur Geschichte der sächsischen Kartographie von den Anfängen bis zur Gegenwart. Stolpener Hefte Nr. 4, Stolpen.

StatAmt München (2011): Metadaten - Räumliche Gliederungen. Statistisches Amt München. Download am 22.02.2012 via http://www.mstatistik-muenchen.de/metadaten/raumbezug/metadaten_raeumliche_gliederungen_20110901.pdf

Statistische Ämter des Bundes und der Länder (2012): Regio-Stat: Regionalstatistischer Datenkatalog des Bundes und der Länder. Landesamt für Statistik u. Datenverarbeitung. Download am 14.11.2012 via http://www.statistikportal.de/statistik-portal/regio-stat-katalog.pdf

Steiniger, S. (2007): Enabling Pattern-Aware Automated Map Generalization. Dissertation, University of Zurich.

Steiniger, S.; Lange, T.; Burghardt, D. et al. (2008): An Approach for the Classification of Urban Building Structures Based on Discriminant Analysis Techniques. In: Transactions in GIS 12 (1), S. 31–59.

Steiniger, S.; Taillandier, P.; Weibel, R. (2010): Utilising urban context recognition and machine learning to improve the generalisation of buildings. In: International Journal of Geographical Information Science 24 (2), S. 253–282.

Steiniger, S.; Weibel, R. (2007): Relations among Map Objects in Cartographic Generalization. In: Cartography and Geographic Information Science 34, S. 175–197.

Steiniger, S.; Weibel, R. (2005): Relations and Structures in Categorical Maps. In: Proceedings of the 8th ICA Workshop on Generalisation and Multiple Representation. A Coruña, S. 1–18

Steinmüller, J. (2008): Bildanalyse: Von der Bildverarbeitung zur räumlichen Interpretation von Bildern. Springer.

Stengel, S.; Pomplun S. (2010): OpenStreetMap – die freie Weltkarte für alle oder Spielerei von Karten-Amateuren? In: Vermessung Brandenburg 1/2010, S. 18–32.

Stengele, R. E. (1995): Kartographische Mustererkennung: Rasterorientierte Verfahren zur Erfassung von Geo-Informationen. Dissertation, Eidgenössische Technische Hochschule Zürich.

Sternberg, R. J. (2008): Cognitive psychology. Wadsworth/Cengage Learning.

Stevens, S. S. (1946): On the Theory of Scales of Measurement. In: Science 103 (2684), S. 677–680.

StMi Bayern (2010): Energie und Ortsplanung. Arbeitsblätter für die Bauleitplanung Nr. 17, München: Oberste Baubehörde im Bayerischen Staatsministerium des Innern.

Straub, H. R. (2009): Das interpretierende System. 3. Aufl., Zim-Verlag.

Streich, B. (2005): Stadtplanung in der Wissensgesellschaft: Ein Handbuch. VS Verlag für Sozialwissenschaften.

Streich, B. (2011): Stadtplanung in der Wissensgesellschaft: Ein Handbuch. Springer.

Strobl, C.; Boulesteix, A.-L.; Kneib, T. et al. (2008): Conditional variable importance for random forests. In: BMC Bioinformatics 9 (307).

Strobl, C.; Boulesteix, A.-L.; Zeileis, A. et al. (2007): Bias in random forest variable importance measures: Illustrations, sources and a solution. In: BMC Bioinformatics 8 (25).

Strobl, C.; Malley, J.; Tutz, G. (2009): An introduction to recursive partitioning: Rationale, application, and characteristics of classification and regression trees, bagging, and random forests.. In: Psychological Methods 14 (4), S. 323–348.

Strobl, C.; Zeileis, A. (2008): Danger: High Power! – Exploring the Statistical Properties of a Test for Random Forest Variable Importance. Technical Reports, Nr. 17, Department of Statistics, University of Munich, Download am 17.09.2012 via http://epub.ub.uni-muenchen.de/2111.

Sukopp, H.; Wittig, R. (1998): Stadtökologie. 2. Aufl., Spektrum Akademischer Verlag.

Suveg, I. (2002): Automatic 3D building reconstruction. In: Corner, B. D.; Pargas R. P.; Nurre J. H. (Hrsg.): SPIE Proceedings, Volume 4661: Three-Dimensional Image Capture and Applications V, SPIE Digital Library, S. 59–69.

Suzuki, S.; Yamada, T. (1990): MARIS: map recognition input system. In: Pattern Recognition 23 (8), S. 919–933.

Svetnik, V.; Liaw, A.; Tong, C. (2004): Variable Selection in Random Forest with Application to Quantitative Structure-Activity Relationship. In: Intrator, N; Masulli, F. (Hrsg.): Proceedings of the 7th Course on Ensemble Methods for Learning Machines. Springer-Verlag.

Szepannek, G.; Weihs, C. (2006): Variable Selection for Discrimination of More Than Two Classes Where Data are Sparse. In: Spiliopoulou, M.; Kruse, R.; Borgelt, C. et al. (Hrsg.): From Data and Information Analysis to Knowledge Engineering. Berlin/Heidelberg: Springer-Verlag, S. 700–707.

Szibalski, M.; Statistisches Bundesamt (Hrsg.) (2007): Kleinräumige Bevölkerungsund Wirtschaftsdaten in der amtlichen Statistik Europas. In: Wirtschaft und Statistik. (2), S. 137–143.

TABULA (2010): Use of Building Typologies for Energy Performance Assessment of National Building Stocks.Existent Experiences in European Countries and Common Approach: First TABULA Synthesis Report. Report, Institut Wohnen und Umwelt. Download am 17.09.2012 via http://www.building-typology.eu/downloads/public/docs/report/TABULA_SR1.pdf

Tainz, J. (2001): Kartographische Kommunikation. In: Bollmann, J.; Koch, W. G. (Hrsg.): Lexikon der Kartographie und Geomatik: Karto bis Z. Spektrum Akademischer Verlag, S. 27–29.

Taubenböck, H.; Heldens, W.; Heiden, U. et al. (2010): Physische Indikatoren für die Stadtplanung. In: Taubenböck, H.; Dech, S. (Hrsg.): Fernerkundung im urbanen Raum. 1. Aufl., Wissenschaftliche Buchgesellschaft, S. 86–93.

Taubenböck, H.; Dech, S. (2010): Fernerkundung im urbanen Raum. 1. Aufl., Wissenschaftliche Buchgesellschaft.

Theile, E. (2002): Ableitung Digitaler Topographischer Karten aus dem ATKIS-Basis-DLM im Land Brandenburg. In: Vermessung Brandenburg 2/2002, S. 47–60.

Theodoridis, S.; Koutroumbas, K. (2008): Pattern Recognition. 4. Aufl., Academic Press.

Therneau, T. M.; Atkinson, E. J. (1997): An Introduction to Recursive Partitioning Using the RPART Routines. Technical Report, Download am 08.12.2012 via http://cran.r-project.org/web/packages/rpart/vignettes/longintro.pdf

Thiele A.; Cadario, E.; Schulz, K. et al. (2007): Building Recognition From Multi-Aspect High-Resolution InSAR Data in Urban Areas. In: IEEE Transactions on Geoscience and Remote Sensing 45 (11), S. 3583–3593.

Thinh, N. X. (2004): Entwicklung von Maßen zur Charakterisierung und Bewertung des räumlichen Ordnungsgefüges von Stadtlandschaften. In: Walz, U. et al. (Hrsg.): Landschaftsstruktur im Kontext von naturräumlicher Vorprägung und Nutzung - Datengrundlagen, Methoden und Anwendungen. IÖR-Schriften 43, Dresden: IÖR, S. 237–254.

Thinh, N. X.; Behnisch, M.; Margraf, O. (Hrsg.) (2011): Beiträge zur Theorie und quantitativen Methodik in der Geographie. IÖR-Schriften 57, Berlin: Rhombos-Verlag.

Thinh, N. X. (2002): Entwicklung von AML-Programmen zur räumlichen Analyse der Flächennutzungsmuster von 116 kreisfreien Städten in Deutschland. In: Photogrammetrie - Fernerkundung - Geoinformation 6/2002, S. 409–422.

Thinh, N. X. (2006): Neue Entwicklungen in der zellulären Simulation der Flächennutzungsdynamik. In: Rödel, R.; Aurada, K. D. (Hrsg.): Beiträge zum 16. Kolloquium Theorie und quantitative Methoden in der Geographie Gemeinsame Tagung der Arbeitskreise (DGfG). Greifswalder Geographische Arbeiten 39, Greifswald: Ernst-Moritz-Arndt-Universität, S. 63–74.

Thomson, M.-K. (2009): Dwelling on Ontology - Semantic Reasoning over Topographic Maps. Doctoral Thesis, University College London.

Tinz, M. (2010): Flächenerhebung und -aktualisierung im Rahmen von GMES Land Monitoring. In: Meinel, G.; Schumacher, U. (Hrsg.): Flächennutzungsmonitoring II: Konzepte – Indikatoren – Statistik. Berlin: Rhombos-Verlag, S. 109–111.

Torrens, P. M.; Alberti, M. (2000): Measuring sprawl. CASA Working Papers 27, Centre for Advanced Spatial Analysis (UCL), London.

Triantakonstantis, D. P.; Barr, S. L. (2009): A Spatial Structural and Statistical Approach to Building Classification of Residential Function for City-Scale Impact Assessment Studies. In: Proceedings of the International Conference on Computational Science and Its Applications: Part I. Lecture Notes in Computer Science, Springer-Verlag, S. 221–236.

Trimmel, M. (2003): Allgemeine Psychologie: Motivation, Emotion, Kognition. Facultas Verlag.

Troyanskaya, O.; Cantor, M.; Sherlock, G. et al. (2001): Missing value estimation methods for DNA microarrays. In: Bioinformatics 17 (6), S. 520–525.

Tuia, D.; Kaiser, C. (2007): From maps to urban morphology: mathematical morphology algorithms for urban feature detection. In: 15th European Colloquium on Theoretical and Quantitative Geography. Montreux: IGUL.

Turney, P. (2000): Types of Cost in Inductive Concept Learning. In: Proceedings of the ICML 2000 Workshop on Costsensitive Learning. Stanford University, S. 15–21.

Ueberfuhr, F.; Glaser, F. F. (2010): Beschreibung der Kartiereinheiten zur Neufassung der BTLNK 2005 auf der Grundlage und unter Verwendung des Luftbildinterpretationsschlüssels 1992/93. Dokumentation, Dresden: Sächsisches Landesamt für Umwelt, Landwirtschaft und Geologie. Download am 09.10.2012 via http://www.umwelt.sachsen.de/umwelt/download/natur/beschreibung_kartiereinheiten_2005.pdf

UNEP (2009): Buildings and Climate Change: A Summary for Decision-Makers. Paris: UNEP DTIE Sustainable Consumption & Production Branch.

University of Oregon (2005): The Interactive Nolli Map Website. University of Oregon. Download am 12.12.2012 via http://nolli.uoregon.edu.

UNO (2011): World Urbanization Prospects, the 2011 Revision. New York: United Nations Department of Economic and Social Affairs (DESA). Download am 22.01.2012 via http://esa.un.org/unpd/wup/index.htm.

Ural, S.; Hussain, E.; Shan, J. (2011): Building population mapping with aerial imagery and GIS data. In: International Journal of Applied Earth Observation and Geoinformation 13 (6), S. 841–852.

Uschold, M.; Grüninger, M. (1996): Ontologies: principles, methods, and applications. In: Knowledge Engineering Review 11 (2), S. 93–155.

Valiant, L. G. (1984): A theory of the learnable. In: Communications of the ACM 27 (11), S. 1134–1142.

Vance, C.; Hedel, R. (2008): On the Link Between Urban Form and Automobile Use: Evidence from German Survey Data. In: Land Economics 84 (1), S. 51–65.

Vanderhaegen, S.; Canters, F. (2010): Developing urban metrics to describe the morphology of urban areas at block level. In: International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 38 (4/C7), CD-ROM.

Vapnik, V. (2000): The Nature of Statistical Learning Theory. 2. Aufl., Springer.

Venables, W. N.; Ripley, B. D. (2002): Modern Applied Statistics with S. 4. Aufl., Springer.

VermKatG NRW (2005): Gesetz über die Landesvermessung und das Liegenschaftskataster (Vermessungs- und Katastergesetz – VermKatG NRW). Download am 17.10.2012 via https://recht.nrw.de/lmi/owa/pl_text_anzeigen?v_id=3320070525144653193

Van de Voorde, T.; Jacquet, W.; Canters, F. (2011): Mapping form and function in urban areas: An approach based on urban metrics and continuous impervious surface data. In: Landscape and Urban Planning. 102 (3), S. 143–155.

Vornholt, S. (2006): Merkmalsauswahl und Merkmalsgewichtung für die Qualitätsanalyse. Diplomarbeit, Otto-von-Guericke-Universität Magdeburg.

Vosselman, G.; Maas, H.-G. (2010): Airborne and Terrestrial Laser Scanning. 1. Aufl., CRC Press.

VwVLika (2005): Verwaltungsvorschrift des Sächsischen Staatsministeriums des Innern zur Führung des Liegenschaftskatasters (Liegenschaftskatastervorschrift - VwVLika). Download am 21.10.2012 via http://www.landesvermessung.sachsen.de/inhalt/service/recht/download/VwVLika.pdf

Wächter, M. (2003): Die Stadt: Umweltbelastendes System oder wertvoller Lebensraum?; Zur Geschichte, Theorie und Praxis stadtökologischer Forschung in Deutschland. Dissertation, UFZ-Bericht 9/2003, Leipzig: UFZ.

Waddell, P.; Borning, A.; Noth, M. et al. (2003): Microsimulation of urban development and location choices: design and implementation of UrbanSim. In: Networks and Spatial Economics 3 (1), S. 43–67.

Walde, I.; Hese, S.; Schmullius, C. (2012): Graph-based Mapping of Urban Structure Types from High Resulution Satellite Image Objects. In: Proceedings of the 4th GEOBIA. Rio de Janeiro (INPE), S. 355–360.

Wallbaum, H.; Ostermeyer, Y.; Goto, Y. (2011): Nutzer- und klimaangepasstes Bauen — Leitbild und Chance für die globale Verbreitung von nachhaltigen Gebäudelösungen. In: Bautechnik 88 (1), S. 3–16.

Walter, V.; Luo, F. (2011): Automatic interpretation of digital maps. In: ISPRS Journal of Photogrammetry and Remote Sensing 66 (4), S. 519–528.

Warnes, G. R. (2012): Package 'gplots'. Technical Report. Download am 05.07.2012 via http://cran.r-project.org/web/packages/gplots/gplots.pdf

Watanabe, S. (1985): Pattern Recognition: Human and Mechanical. 1. Aufl., Wiley.

Webb, A. R. (2002): Statistical Pattern Recognition. 2. Aufl., John Wiley & Sons.

Webb, G. I. (2000): MultiBoosting: A Technique for Combining Boosting and Wagging. In: Machine Learning 40, S. 159–196.

Weibel, R. (2004): Modellgeneralisierung und kartographische Generalisierung - Stand und Entwicklung. In: Kartographische Nachrichten 54 (4), S. 150–152.

Weibel, R.; Keller, S.; Reichenbacher, T. (1995): Overcoming the Knowledge Acquisition Bottleneck in Map Generalization: the Role of Interactive Systems and Computational Intelligence. In: Frank, A. U.; Kuhn, W. (Hrsg.): Spatial Information Theory A Theoretical Basis for GIS. Springer-Verlag, S. 139–156.

Weichhart, P. (1999): Die Räume zwischen den Welten und die Welt der Räume. In: Meusburger, P. (Hrsg.): Handlungszentrierte Sozialgeographie: Benno Werlens Entwurf in Kritischer Diskussion. Franz Steiner Verlag, S. 67–94.

Welch, B. L. (1947): The Generalization of `Student's' Problem when Several Different Population Variances are. Involved. In: Biometrika 34 (1-2), S. 28–35.

Weng, Q. (2007): Remote sensing of impervious surfaces. CRC Press.

Wentz, E. A. (2000): A Shape Definition for Geographic Applications Based on Edge, Elongation, and Perforation. In: Geographical Analysis 32 (2), S. 95–112.

Werder, S.; Kieler, B.; Sester, M. (2010): Semi-automatic interpretation of buildings and settlement areas in user-generated spatial data. In: Proceedings of the 18th SIGSPATIAL In-

ternational Conference on Advances in Geographic Information Systems. New York: ACM, S. 330–339.

Wertheimer, M. (1923): Untersuchungen zur Lehre von der Gestalt. II. In: Psychologische Forschung 4 (1), S. 301–350.

Wharton, S. W. (1982): A contextual classification method for recognizing land use patterns in high resolution remotely sensed data. In: Pattern Recognition 15 (4), S. 317–324.

Whitehand, J. W. R. (2001): British urban morphology: the Conzenian tradition. In: Urban Morphology. 5 (2), S. 103–109.

Whitehand, J. W. R. (2007): Conzenian Urban Morphology and Urban Landscapes. In: 6th International Space Syntax Symposium. Istanbul, Turkey, S. 1–9.

Wickop, E.; Böhm, P.; Eitner, K. et al. (1998): Qualitätszielkonzept für Stadtstrukturtypen am Beispiel der Stadt Leipzig - Entwicklung einer Methodik zur Operationalisierung einer nachhaltigen Stadtentwicklung auf der Ebene von Stadtstrukturen. UFZ-Bericht 14/1998 (Stadtökologische Forschungen), Leipzig: UFZ.

Widrow, B.; Hoff, M. E. (1960): Adaptive switching circuits. In: IRE WESCON Convention Record 4/1960, New York: Institute of Radio Engineers, S. 96–104.

Wiedemann, C. (2002): Extraktion von Straßennetzen aus optischen Satellitenbilddaten. Dissertation, TU München. München: Verlag der Bayerischen Akademie der Wissenschaft.

Winkler, M.; Meinel, G. (2003): GIS-basierte Flächenentwicklungsanalyse von fünf europäischen Großstädten (Bilbao, Bratislava, Dresden, Lyon, Palermo) auf der Basis digitaler Datenbestände. In: Prechtel, N. (Hrsg.): Geoinformationssysteme - Theorie, Anwendungen, Problemlösungen. Kartographische Bausteine 21, Dresden: Inst. für Kartographie, S. 28–35.

Witt, W. (1967): Thematische Kartographie. Methoden und Probleme, Tendenzen und Aufgaben. Veröffentlichungen der Akademie für Raumforschung und Landesplanung, Abhandlungen 49, Hannover: Jänecke.

Witten, I. H.; Frank, E. (2005): Data Mining: Practical Machine Learning Tools and Techniques, Second Edition. 2. Aufl., Morgan Kaufmann.

Wolfram, M. (2010): Nutzung von Geoinformatik in der Stadtplanung: Stand und Perspektiven. Ergebnisse einer Online-Befragung unter deutschen Groß- und Mittelstädten. IÖR-Texte 163, Dresden: IÖR.

Wolpert, D. H. (1992): Stacked Generalization. In: Neural Networks 5, S. 241–259.

Wu, J. (1999): Hierarchy and scaling: Extrapolating information along a scaling ladder. In: Canadian Journal of Remote Sensing 25 (4), S. 367–380.

Wu, S.-S.; Xu, B.; Wang, L. (2006): Urban Land-use Classification Using Variogram-based Analysis with an Aerial Photograph. In: Photogrammetric Engineering and Remote Sensing 72 (7), S. 813–822.

Wurm, M.; Taubenböck, H.; Goebel, J. et al. (2010): Menschen zählen aus dem All. Möglichkeiten und Grenzen von Satellitendaten zur Abschätzung der Bevölkerungsentwicklung und des Gebäudebestandes in deutschen Städten. Working Paper Nr. 155/2010, Rat für Sozial- und Wirtschaftsdaten (RatSWD).

Wurm, M.; Taubenböck, H.; Roth, A. et al. (2009): Urban structuring using multisensoral remote sensing data: By the example of the German cities Cologne and Dresden. In: 2009 Joint Urban Remote Sensing Event. Shanghai, China, S. 1–8.

Xiong, Z.; Zhang, Y. (2006): Automatic 3D Building Extraction from Stereo IKONOS Images. In: 2006 IEEE International Symposium on Geoscience and Remote Sensing. Denver, S. 3283–3286.

Yoshida, H.; Omae, M. (2005): An approach for analysis of urban morphology: methods to derive morphological properties of city blocks by using an urban landscape model and their interpretations. In: Computers, Environment and Urban Systems 29 (2), S. 223–247.

Yu, B.; Ostland, M.; Gong, P. et al. (1999): Penalized discriminant analysis of in situ hyperspectral data for conifer species recognition. In: IEEE Transactions on Geoscience and Remote Sensing 37 (5), S. 2569 –2577.

Zahn, C. T. (1971): Graph-Theoretical Methods for Detecting and Describing Gestalt Clusters. In: IEEE Transactions on Computers 20 (1), S. 68–86.

ZensG 2011 (2009): Gesetz über den registergestützten Zensus im Jahre 2011 (Zensusgesetz 2011 - ZensG 2011), Stand: 08.07.2009, Download am 03.02.2012 via http://www.gesetze-im-internet.de/bundesrecht/zensg_2011/gesamt.pdf

Zhang, X.; Ai, T.; Stoter, J. (2010): Characterization and Detection of Building Patterns in Cartographic Data: Two Algorithms. In: International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 38 (Part 2), S. 261–266.

Zimbardo, P. G.; Gerrig, R. J. (2008): Psychologie. Pearson Education.

Abkürzungsverzeichnis

2D	Zweidimensional
3D	Dreidimensional
3D-GS	3D-Gebäudestrukturen (Bezeichnung für das landesweite 3D-Gebäudemodell im LoD1 in NRW)
AAA	AFIS®-ALKIS®-ATKIS®-Modell
ADABOOST	Adaboost.M1-Algorithmus
ADS	Airborne Digital Sensor (Flugzeugsensor)
AdV	Arbeitsgemeinschaft der Vermessungsverwaltungen der Länder der Bundesrepublik Deutschland
AFIS®	Amtliches Festpunkt-Informationssystem
AGENT	Automated Generalisation New Technology (Wissenschaftliches Projekt zur automatisierten Generalisierung)
AGK	Verwaltungsprogramm der kommunalen Statistik „Adresszentraldatei, Gebäudedatei und Kleinräumige Gliederung“
AGS	Amtlicher Gemeindeschlüssel
AK10	Arbeitskarte 1: 10 000 der Landesvermessung im Saarland
ALB	Automatisiertes Liegenschaftsbuch
ALK	Automatisierte Liegenschaftskarte
ALKIS®	Amtliches Liegenschaftskatasterinformationssystem
ANN	Artificial Neural Network (Künstliches neuronales Netz)
AOG	Anzahl oberirdischer Geschosse (Attribut im ALKIS®)
ArcGIS	Produktfamilie der GIS-Softwareprodukte des Unternehmens ESRI
ATKIS®	Amtliches Topographisch-Kartographisches Informationssystem
BAGGING	Bagging Trees (maschinelles Lernverfahren)
BauNVO	Baunutzungsverordnung
BAW	Bauweise (Attribut im ALKIS®)
BBSR	Bundesinstitut für Bau-, Stadt- und Raumforschung
BEB	Bebauungsart (Attribut im ATKIS®)
BFClassTool	Buildung Footprint Classification Tool
BFExtractTool	Buildung Footprint Extraction Tool
BKG	Bundesamt für Kartographie und Geodäsie
BL	Bundesländer
BMBF	Bundesministerium für Bildung und Forschung

CA	Cellular Automata (Zellulärer Automat)
CART	Classification and Regression Trees (Algorithmus zur Konstruktion von Entscheidungsbäumen)
CCD	Charge Coupled Devices (Halbleitertechnologie optischer Sensoren)
CHAID	Chi-square Automatic Interaction Detectors (baumbasiertes Lernverfahren)
CHANGE	Programmsystem zur Generaisierung von Gebäuden (entwickelt an der Leibniz Universität Hannover)
CIR	Color Infrared (Color-Infrarot)
CityGML	City Geography Markup Language
CLC	CORINE Land Cover, europaweites Projekt zur Bereitstellung von Landnutzungsdaten
CLUBFS	Centre for Land Use and Built Form Studies
CORONA	US-amerikanischer Spionagesatellit
CPU	Central processing unit
CRAN	Comprehensive R Archive Network
D1000	Karte „Bundesrepublik Deutschland" im Maßstab 1: 1 Mio.
DAF	Dachform (Attribut im ALKIS®)
DFG	Deutsche Forschungsgemeinschaft
DFK	Digitale Flurkarte
DGK	Deutsche Grundkarte
DGK5	Deutsche Grundkarte 1: 5 000
DGM	Digitales Geländemodell
DIN	Deutsche Industrienorm
DKM	Digitales Kartographisches Modell
DLM	Digitales Landschaftsmodell
DLM 1000	Digitales Landschaftsmodell 1: 1 Mio.
DLM250	Digitales Landschaftsmodell 1: 250 000
DLM50	Digitales Landschaftsmodell 1: 50 000
DMC	Digitale Modulare Camera (Flugzeugscanner der Firma Zeiss)
DOK	Digitale Ortskarte 1: 10 000 (Bayern)
DOM	Digitales Oberflächenmodell
DOP	Digitale Orthophotos
DOUBAG	Double Bagging (maschinelles Lernverfahren)
DSK	Digitale Stadtkarte
DSK500	Digitale Stadtkarte 1: 500

DTK	Digitale Topographische Karten
DTK10	Digitale Topographische Karte 1: 10 000
DTK100	Digitale Topographische Karte 1: 100 000
DTK100-V	Digitale Topographische Karte 1: 100 000 (vorläufige Ausgabe)
DTK1000	Digitale Topographische Karte 1: 1 Mio.
DTK1000-V	Digitale Topographische Karte 1: 1 Mio. (vorläufige Ausgabe)
DTK200	Digitale Topographische Karte 1: 200 000
DTK200-V	Digitale Topographische Karte 1: 200 000 (vorläufige Ausgabe)
DTK25	Digitale Topographische Karte 1: 25 000
DTK25-V	Digitale Topographische Karte 1: 25 000 (vorläufige Ausgabe)
DTK50	Digitale Topographische Karte 1: 50 000
DTK50-V	Digitale Topographische Karte 1: 50 000 (vorläufige Ausgabe)
DTK-V	Digitale Topographische Karte (vorläufige Ausgabe)
E.ON	Energieforschungszentrum der RWTH Aachen
E0	Bootstrapp-Verfahren zur Abschätzung des Generalisierungsfehlers
E632	Bootstrapp-Verfahren zur Abschätzung des Generalisierungsfehlers
EASE	Projekt "Energetische Aufwertung und Stadtentwicklung"
EASYSTAT®	Recherchesoftware für Datenrecherche und Export amtlicher Statistikdaten
ED	Einwohnerdichte
EDBS	Einheitliche Datenbankschnittstelle (standardisiertes Datenformat zum Austausch von Geodaten
EDV	Elektronische Datenverarbeitung
EGD	Einwohnergrundflächendichte
EM	Expectation-Maximization-Algorithmus (Verfahren der Parameterschätzung)
ER-Konzept	Entity-Relationship-Konzept
EROS-B	*Earth Resources Observation System*, isrealisch-US-amerikanischer Erdbeobachtungssatellit
ESA	*European Space Agency* (Europäische Weltraumorganisation)
ESRI	*Environmental Systems Research Institute* (US-amerikanischer Softwarehersteller von Geoinformationssystemen)
ET	Eingangsdatentyp
ETRS89	Europäisches Terrestrisches Referenzsystem 1989
EU	Europäische Union
EW	Einwohnerzahl
FDA	Flexible Discriminant Analysis

FDA-MARS	Flexible Discriminant Analysis with Multivariate Adaptive Regression Splines (statistisches Lernverfahren)
FKT	Gebäudefunktion (Attribut in der ALK)
FNR	False negative rate (Falsch-Negativ-Rate)
FoPS	Forschungsschwerpunkt „Forschungsprogramm Stadtverkehr" des BMVBS
FPR	False positive rate (Falsch-Positiv-Rate)
FRAGSTATS	Spatial Pattern Analysis Program for Categorical Maps (Software zur Berechnung räumlicher Strukturmaße)
GAB	Georeferenzierte Adressdaten – Bund (bundesweiter Adressdatensatz)
GD	Gebäudedichte
GDI	Geodateninfrastruktur
GDI-DE	Geodateninfrastruktur Deutschland
GENESIS	Internet-Datenbank des Statistischen Bundesamtes
GEOBasis.nrw	Behörde in NRW (zuständig für Landesvermessung)
GEOBIA	Geographic Object-Based Image Analysis
GEOEye-1	Beobachtungssatellit des amerikanischen Unternehmens GeoEye
GeoMIS.Bund	Metainformationssystem für Geodaten des Bundes
GeoSN	Staatsbetrieb Geobasisinformation und Vermessung Sachsen
GF	Geschossfläche
GFK	Gebäudefunktion (Attribut im ALKIS®)
GI	Geoinformation
GIM	Gini importance measurement
GIS	Geoinformationssystem
GIScience	Geographic information science
GMES	Global Monitoring for Environment and Security (europäische Initiative)
GNU	General Public License
GPS	Global Positioning System
GV	Gebäudevolumen
GVHK	Gemeinschaft zur Verbreitung der Hauskoordinaten
GWZ	Gebäude- und Wohnungszählung
GZF	Geschossflächenzahl
HALCON	Bildanalysesoftware der Firma MVTec Software GmbH
HBauStatG	Hochbaustatistikgesetz
HHO	Gebäudehöhe (Attribut im ALKIS®)
HK	Amtliche Hauskoordinaten

HRSC	High Resolution Stereo Camera (Kamerasystem)
HU	Amtliche Hausumringe
HyMap	Flugzeuggetragener Hyperspektralsensor der Firma Integrated Spectronics
ICA	International Cartographic Association (Internationale Kartographische Vereinigung)
ID3	Iterative Dichotomiser 3 (Lernverfahren)
IGN	Institut Géografique National (für die französische Landesvermessung zuständige Behörde)
IKARUS	Projekt „Instrumente für Klimagas-Reduktionsstrategien“
IKONOS	Kommerzieller Erdbeobachtungssatellit der Firma GeoEye (früher Space Imaging)
IMAGI	Interministerieller Ausschuss für Geoinformationswesen
INSPIRE	Infrastructure for Spatial Information in the European Community
IÖR	Leibniz-Institut für ökologische Raumentwicklung
ISO	International Organization for Standardization
ISPRS	International Society for Photogrammetry and Remote Sensing
ISUF	International Seminar on Urban Form
IWH	Institut für Wirtschaftsforschung Halle
IWU	Institut Wohnen und Umwelt
JOG250	Joint Operations Graphic 1: 250 000
JOSM	Java OpenStreetMap Editor
KDD	Knowledge Discovery in Databases
KDE	Kernel Density Estimation
KFA	Russisches photographisches Aufnahmesystem
KLIMZUG	BMBF-geförderte Maßnahme zur Entwicklung innovativer Ansätze zur Anpassung an den Klimawandel
kNN	k-Nächster-Nachbar-Klassifikator
KOSTAT	Arbeitsgemeinschaft Kommunalstatistik
KWR	Russisches photographisches Aufnahmesystem
LDA	Lineare Diskriminanzanalyse
LiDAR	Light Detection and Ranging
LMS	Least Mean Squares (Algorithmus)
LNR	Laufende Nummer (Attribut im ALKIS®)
LOD	Level of Detail
MAP	Maximum-a-posteriori-Schätzung
MAS	Multi-Agent System

MAVE	Minimum Mean Absolute Value of Error
MBO	Musterbauordnung
MCS	Multiple Classifier Systems
MDA	Mixture Discriminant Analysis
MERKIS	Maßstabsorientierte Einheitliche Raumbezugsbasis für Kommunale Informationssysteme
MKRO	Ministerkonferenz für Raumordnung
ML	Maximum-Likelihood-Schätzung
MLP	Multi-Layer-Perzeptron
MLR	Multinomiale Logistische Regression
MMSE	Minimum mean square error (Schätzung nach dem kleinsten mittleren Fehlerquadrat)
MRDB	Multiple representation database
MRRG	Melderechtsrahmengesetz
MSE	Mean squared error
MST	Minimum spanning tree
MULTISURE	Projekt „Entwicklung multisequenzieller Vorsorgestrategien für grund-hochwassergefährdete urbane Lebensräume“
nDOM	Normalisiertes digitales Oberflächenmodell
NDVI	Normalized Differenced Vegetation Index
NN	Nächster-Nachbar-Klassifikator
NUTZUNG	Gebäudenutzung (Attribut der 3D-Gebäudestrukturen)
OA	Overall Accuracy (Gesamtgenauigkeit)
OBAK	Objektabbildungskatalog
OCR	Optical Character Recognition (optische Zeichenerkennung)
OGC	Open Geospatial Consortium
OK	Objektartenkatalog
OOB	Out-of-bag
OrbView 3	US-amerikanisches Satellitensystem betrieben von der Firma GeoEye
OS Master-Map®	Topographische Datenbank der Landesvermessungsbehörde Großbritanniens (Ordnance Survey)
OSKA	Objektschlüsselkatalog
OSM	OpenStreetMap
OVA	One-versus-all (Strategie zur Zerlegung des Mehrklassen-Problems in ein binäres Problem)
OVO	One-versus-one (Strategie zur Zerlegung des Mehrklassen-Problems in ein binäres Problem)

OWL-DL	Web Ontology Language – Description Logic
PA	Producer´s Accuracy (Herstellergenauigkeit)
PCA	Principal Component Analysis (Hauptkomponentenanalyse)
pdf	probability density function
PIM	Permutation importance measurement
pLDA	Penalized Diskriminant Analysis
PLZ	Postleitzahl
pMDA	Penalized Mixture Discriminant Analysis
PR	Pattern recognition
PVSLDA	Paarweise LDA mit Variablenselektion
PVSRF	Paarweise Variablenselektion mit Random Forest
QDA	Quadratische Diskriminanzanalyse
Quickbird	Kommerzieller Erdbeobachtungssatellit der Firma DigitalGlobe
R	Freie Programmiersprache für statistisches Rechnen und statistische Graphiken
RAM	Random access memory
RapidEye	Deutsches Satellitensystem bestehend aus einer Satellitenflotte
RatSWD	Rat für Sozial- und Wirtschaftsdaten
RBF	Radial basis function (radiale Basisfunktion)
REGKLAM	„Regionales Klimaanpassungsprogramm für die Modellregion Dresden“ (Projekt)
RF	Random Forest
RIMAX	Förderaktivität "Risikomanagement extremer Hochwasserereignisse" des BMBF
RK10	Rasterkarte 1:10 000 der Landesvermessung Schleswig-Holstein
ROC	Receiver Operating Characteristic (Optimierungsverfahren)
RTL	Run-Time Library
RWTH	Rheinisch-Westfälische Technische Hochschule Aachen
SAMS	Structural Analysis and Mapping System (Programm zur graphenbasierten strukturellen Beschreibung der Landbedeckung und Landnutzung)
SAR	Synthetic Aperture Radar (flugzeuggetragenes Radarsystem mit synthetischer Apertur)
SBS	Sequential Backward Selection (sequentielle Rückwärtsselektion, Merkmalsselektionsverfahren)
SDK	Software Development Kit
SEMENTA®	SettlementAnalyzer (Programm zur automatisierten Analyse von Siedlungsstrukturen auf Grundlage topographischer Informationen)

SFS	Sequential Forward Selection (sequentielle Vorwärtsselektion, Merkmalsselektionsverfahren)
SIG 3D	Special Interest Group 3D
SK	Signaturenkatalog
sLDA	Stabilisierte Diskriminanzanalyse
SLUB	Sächsische Landesbibliothek – Staats- und Universitätsbibliothek Dresden
SOM	Self-organizing map (Selbstorganisierende Karten, unüberwachtes Lernverfahren)
SPIRIT	Spatially-Aware Information Retrieval on the Internet (Projekt)
SPOT-5	Satellite Pour l'Observation de la Terre, franz. Satellitensystem
SVM	Support Vector Machine (maschinelles Lernverfahren)
TIFF	Tagged Image File Format (Dateiformat zur Speicherung von Bilddaten)
TK10	Topographische Karte 1: 10 000
TK25	Topographische Karte 1: 25 000
TK50	Topographische Karte 1: 50 000
TNR	True negative rate (Falsch-Positiv-Rate)
TPR	True positive rate (Richtig-Positiv-Rate)
UA	User´s Accuracy (Nutzergenauigkeit)
UCGIS	University Consortium for Geographic Information Science
UCL	University of London
UG	Überbauungsgrad
ÜK500	Übersichtskarte der Bundesrepublik Deutschland 1 : 500 000
UML	Unified Modeling Language
UMRG	Urban Morphology Research Group
UrbanSim	Agentenbasiertes System zur Simulation
USGS	United States Geological Survey
UTM	Universal Transverse Mercator
VDS	Verband Deutscher Städtestatistiker
VERIS-Elbe	BMBF-Forschungsvorhaben "Veränderungen und Management der Risiken extremer Hochwasserereignisse in großen Flussgebieten – am Beispiel der Elbe"
VGI	Volunteered Geographic Information
VHR	Very high resolution (sehr hoch auflösend im Kontext der Fernerkundung)
WD	Wohnungsdichte
WEKA	Waikato Environment for Knowledge Analysis (Software)
WF	Wohnfläche

WGD	Wohnungsgrundflächendichte
WO	Wohnungszahl
XLD	eXtended Line Description (HALCON-spezifischer Datentyp)
XRAG	Extended Region-Adjacency Graph (am UCL entwickelte Graphenrepräsentation zur Beschreibung räumlicher Strukturen)
ZUS	Betriebsbereitschaft (Attribut im ALKIS®)

Gebäudeklassen

EFZH-DH	Ein- und Zweifamilienhaus als Doppelhaus
EFZH-EH	Freistehendes Ein- und Zweifamilienhaus
EFZH-RH	Ein- und Zweifamilienhaus als Reihenhaus
LH	Ländliche Hausform
MFH-F	Mehrfamilienhaus in offener Bauweise
MFH-G	Mehrfamilienhaus in geschlossener Bauweise
MFH-H	Mehrfamilienhaus im historischen Ortskern
MFH-HH	Freistehendes Mehrfamilienhaus als Hochhaus
MFH-IZ	Mehrfamilienhaus in industrieller Plattenbauweise
MFH-TZ	Mehrfamilienhaus in traditioneller Zeilenbauweise
MFH-VI	Villa
NG	Nebengebäude
ÖG	Öffentliches Gebäude

Abbildungsverzeichnis

Abb. 1-1: Wissenschaftliche Einordnung der Arbeit 7
Abb. 2-1: Sichtweisen der Siedlungsstruktur 16
Abb. 2-2: Modellarten im kartographischen Modellbildungsprozess 24
Abb. 2-3: Arten der Generalisierung in der digitalen Kartographie 29
Abb. 2-4: Automatisierte Liegenschaftskarte und Deutsche Grundkarte 1: 5 000 31
Abb. 2-5: Stadtplan von Rom (1748) von Giambattista Nolli im Maßstab 1:2 900 36
Abb. 2-6: Gliederung thematischer Stadtkarten 42
Abb. 2-7: Stadtstrukturmodelle der funktionalen Stadtgeographie 44
Abb. 2-8: Die Gestalt von Los Angeles entsprechend den Aufzeichnungen geschulter Beobachter 46
Abb. 2-9: Schematische Darstellung der Hierarchie-Level des Modells von Krüger 48
Abb. 2-10: Methoden der räumlichen Analyse 51
Abb. 2-11: Stadtstrukturtypen 54
Abb. 3-1: Zyklisches Modell des Bildverstehens nach Pinz 62
Abb. 3-2: Genereller Ablauf beim maschinellen Lernen 67
Abb. 3-3: Schema eines Mustererkennungssystems 68
Abb. 3-4: Klassifikationsverfahren 73
Abb. 3-5: Eindimensionale Verteilungsdichten zweier normalverteilter Klassen mit gleicher Varianz und Aufteilung des Merkmalsraums in zwei Regionen R_1 und R_2 76
Abb. 3-6: 3D-Darstellung zweidimensionaler Verteilungsdichten und optimale Trennung nach dem Bayes-Theorem 77
Abb. 3-7: Beste Hyperebene der LDA 80
Abb. 3-8: Einlagiges Netz als einfaches lineares Regressionsmodell und das Standardnetzwerk mit drei Schichten 83
Abb. 3-9: Strategien zur Zerlegung des Mehrklassen-Problems in binäre Teilprobleme nach OVO-Strategie und der OVA-Strategie 85
Abb. 3-10: Zusammenhang zwischen Vorhersagefehler und Modellkomplexität 89
Abb. 3-11: Beispiel einer Konfusionsmatrix und mathematischen Definition 91
Abb. 4-1: Ansätze zur Klassifizierung individueller Gebäudegrundrisse 104
Abb. 5-1: Gebäudeklassifizierung im Kontext der Siedlungsstrukturanalyse 115
Abb. 5-2: Objekte der Modellierung 125

Abb. 5-3: Objekte des Siedlungsraums und deren Beziehungen 126
Abb. 6-1: Datengrundlage zum Gebäudegrundriss 127
Abb. 6-2: Gebäudedarstellung in den topographischen Karten unterschiedlichen Maßstabs (TK10, TK25, TK50, TK100) für verschiedene Regionen 133
Abb. 6-3: Darstellung kleiner Wohngebäude 135
Abb. 6-4: Graphische Mindestgrößen von Gebäuden in topographischen Karten bei maximalem Kontrast 136
Abb. 7-1: Design der Verfahrensentwicklung 143
Abb. 7-2: Verschiedene Gebäudetypologien im Vergleich 146
Abb. 7-3: Gebäudetypologie für siedlungsstrukturelle Analyse 148
Abb. 7-4: Eingangsdatentypen 152
Abb. 7-5: Semantische und geometrische Harmonisierung 156
Abb. 7-6: Semantische Transformation der Nutzungsklassen in die drei verfahrensspezifischen Klassen am Beispiel der ALK und dem ALKIS 157
Abb. 7-7: Möglichkeiten der Erfassung von Klassenlabels 159
Abb. 7-8: Merkmale und Beziehungen zur Beschreibung von Kartenobjekten 165
Abb. 7-9: Abgeleitete Hilfsobjekte: a) Flächenschwerpunkt, b) Kleinstes umschließendes Rechteck mit beliebiger Orientierung, c) minimaler Umkreis, d) Skeleton-Linie als Mittelachse der Gebäuderegion 165
Abb. 7-10: Workflow der Merkmalsberechnung 172
Abb. 7-11: Optimaler Schwellwert bei minimaler Fehlerrate am Beispiel kleiner freistehender Nebengebäude 176
Abb. 7-12: Workflow der Merkmalsselektion 180
Abb. 7-13: Scree-Plot und Anzahl der extrahierten Komponenten 182
Abb. 7-14: Ablaufdiagramm der Modellselektion 195
Abb. 7-15: Aktivitätsdiagramm der Verfahrensentwicklung 199
Abb. 8-1: Lage der Untersuchungsgebiete 201
Abb. 8-2: Ergebnis der Gebäudeextraktion am Beispiel der DTK25 (Krefeld) und der DTK25-V (Dresden) 207
Abb. 8-3: Verteilung der Referenzgebäude in den Untersuchungsgebieten 210
Abb. 8-4: Referenzdatenbasis am Beispiel von Dresden: a) Gebäude aus der ALK und b) Gebäude aus der DTK25-V 212
Abb. 8-5: Verteilung der Gebäudetypen in der Referenzdatenbank 214
Abb. 8-6: Dichteplot der Klassen „Gebäude mit Wohnnutzung“ (schwarz) und „kleine Nebengebäude“ (grau) im Vergleich für a) freistehende Gebäude und b) nicht freistehende Gebäude 217

Abb. 8-7: Ermittlung des optimierten Schwellwertes angebauter Nebengebäude: a) ROC-Kurve (links) mit optimalen Schwellwert für Methode 1 (MinFnRate) und Methode 2 (MinError) und b) Kurve der Fehlerrate für Methode 2 218

Abb. 8-8: Wahrscheinlichkeitsdichtefunktionen der Wohngebäudeklassen am Beispiel ausgewählter Merkmale. Datengrundlage sind die standardisierten Merkmalsvektoren des Datensatzes von Krefeld (ALK) 220

Abb. 8-9: Heatmap-Visualisierung der Korrelation der Merkmale vor (a) und nach der Merkmalsreduktion (b) am Beispiel der Daten von Halle – DTK25-V....223

Abb. 8-10: Klassifikationsgenauigkeit der getesteten Klassifikatoren 228

Abb. 8-11: Klassifikationsgenauigkeit in Abhängigkeit des Umfanges der Trainingsdatenmenge 231

Abb. 8-12: Ergebnisse der Laufzeitmessung ausgewählter Methoden 234

Abb. 8-13: Schätzung der Klassifikationsgenauigkeit über die OOB-Menge im Vergleich zur 10-fach kreuzvalidierten Klassifikationsgenauigkeit am Beispiel der ATKIS-Gebäudegrundrisse von Halle 237

Abb. 8-14: Konfusionsmatrix am Beispiel der Klassifizierung des Datensatzes für Krefeld (3D-GS) 239

Abb. 8-15: Klassenspezifische Genauigkeit für alle Datensätze 240

Abb. 8-16: Hersteller- und Nutzergenauigkeit nach Eingangsdatentyp....246

Abb. 8-17: Klassengenauigkeit in Abhängigkeit von der Anzahl an Trainingsbeispielen pro Klasse....249

Abb. 8-18: Klassenspezifische Genauigkeit beim kreuzweisen Trainieren und Testen....251

Abb. 8-19: Merkmalswichtigkeit (PIM) gemessen am mittleren Genauigkeitsverlust (Mean Decrease Accuracy) beim Weglassen des Merkmals am Beispiel der Eingangsdatentypen II und III 254

Abb. 8-20: OOB-Fehler in Abhängigkeit der Merkmalsanzahl am Beispiel der Eingangsdatentypen II (links) und III (rechts)....256

Abb. 9-1: Modellierung gebäudebezogener Einwohner am Beispiel von Krefeld auf Grundlage der 3D-Gebäudestrukturen: a) Klassifizierte Gebäudegrundrisse und b) Einwohner pro Gebäude 268

Abb. 9-2: Ableitung von Bebauungsstrukturtypen mittels Flächendominanzprinzip am Beispiel des ALK-Datensatzes von Dresden: a) klassifizierte Gebäudegrundrisse b) Ortholuftbild und c) Bebauungsstrukturtyp auf Baublockebene 271

Tabellenverzeichnis

Tab. 2-1: Gliederung des Raumes nach Ebenen und Elementen 12
Tab. 2-2: Skalenebenen und administrative Raumebenen der Siedlungsstruktur 14
Tab. 2-3: Bebauungsleittypen des Wohngebäudebestandes 19
Tab. 2-4: Digitale Landschaftsmodelle in Deutschland und die daraus abgeleiteten Digitalen Topographischen Karten 32
Tab. 2-5: Übersicht der Darstellungsarten der Siedlung in topographischen Karten 35
Tab. 2-6: Beispiele zur Beschreibung der Siedlungsstruktur mit Fokus auf die Bebauung nach sachlichem und temporalem Objektbezug 40
Tab. 5-1: Repräsentationsformen von Gebäudegrundrissen 120
Tab. 7-1: Kriterien zur Bildung von Gebäudetypen 145
Tab. 7-2: Eigenschaften verschiedener Eingangsdaten 150
Tab. 7-3: Zusätzlich gewählte Datengrundlagen 154
Tab. 7-4: Aufbereitungsschritte für die Integration der amtlichen Gebäudegrundrisse 155
Tab. 7-5: Eingangsdaten nach Datenintegration 158
Tab. 7-6: Darstellung verschiedener Gebäudetypen in topographischen Karten und Daten 161
Tab. 7-7: Charakterisierung der Gebäudegrundrisse im Kartenbild 163
Tab. 7-8: Merkmale auf unterschiedlichen räumlichen Ebenen 169
Tab. 7-9: Merkmale in Abhängigkeit des Eingangsdatentyps 173
Tab. 7-10: Regeln zur Selektion kleiner Nebengebäude 174
Tab. 7-11: Prinzip der Transformation kategorialer Merkmale am Beispiel des Merkmals ATKIS_OBJ 178
Tab. 7-12: Eigenschaften verschiedener Klassifikationsverfahren 184
Tab. 7-13: Überblick über die getesteten Klassifikationsverfahren 186
Tab. 7-14: Getestete Klassifikationsverfahren und deren Parameter 193
Tab. 8-1: Raumstrukturelle Ausgangssituation der Untersuchungsgebiete 202
Tab. 8-2: Überblick über die verwendeten Datengrundlagen und deren Aktualität 205
Tab. 8-3: Anzahl der Gebäudeobjekte in den Untersuchungsgebieten 208
Tab. 8-4: Verwendete Kartierungen und deren Eigenschaften 209
Tab. 8-5: Anzahl der Objekte in der Referenzdatenbank mit Klassenzugehörigkeit 213

Tab. 8-6: Referenzdaten für die ROC-Analyse unter Nutzung der 3D-Gebäudestrukturen von Krefeld 216
Tab. 8-7: Ergebnisse der Schwellwertermittlung mit der ROC-Analyse 217
Tab. 8-8: Anzahl der Merkmale vor und nach der Vorverarbeitung und Merkmalsselektion....221
Tab. 8-9: Datensätze für die Modellselektion 225
Tab. 8-10: Optimierte Tuning-Parameter am Beispiel der ersten Partition des Modellselektionsverfahrens mit n=9 000 und Minimierung der Fehlerrate auf Grundlage einer 5-fachen Kreuzvalidierung 226
Tab. 8-11: Kreuzvalidierte Klassifikationsgenauigkeit der getesteten Klassifikationsverfahren 229
Tab. 8-12: Ergebnis des einseitigen Welch-Tests 230
Tab. 8-13: Rang der Klassifikationsverfahren nach der Genauigkeit für verschiedene Datensätze und Bestimmung des besten Klassifikators über die Rangsumme....232
Tab. 8-14: Gemessene Laufzeit der getesteten Klassifikatoren aus 10 Wiederholungen bei n=6 000 unter Verwendung des Datensatzes Halle (ATKIS)....233
Tab. 8-15: Aus 10-facher Kreuzvalidierung ermittelte Gesamtgenauigkeit (OA – Overall Accuracy, κ – Kappa) und Standardabweichung σ in Klammern für alle betrachteten Datensätze....238
Tab. 8-16: Stichprobengrößen der Trainings- und Testdaten (Train/Test) für die Bestimmung der klassenspezifischen Genauigkeit....245
Tab. 8-17: Klassifikationsgenauigkeit durch kreuzweises Trainieren und Testen am Beispiel der Untersuchungsgebiete Dresden, Halle und Krefeld (Eingangsdatentyp III) 250
Tab. 8-18: Vorhersagegenauigkeit (OOB-Genauigkeit) des Klassifikators mit den originalen Merkmalen (O) und nach der Merkmalsselektion (S) (Trainingsmenge: 5 000 Objekte, Anzahl konstruierter Bäume: 200) 257

Anhang

A Datengrundlagen zur Siedlungsstruktur

Strukturdaten zu Gebäuden und Wohnungen bilden die Entscheidungsgrundlage für eine Vielzahl politischer und raumplanerischer Fragestellungen auf unterschiedlichen räumlichen Ebenen. In Kombination mit sozio-ökonomischen Daten, wie der Bevölkerungsstruktur, lassen sich dann Wohnungsmärkte (z. B. Wohnungs- oder Haushaltsnachfrage) modellieren, prognostizieren und damit Investitionen in Gebäuden und Wohnungen besser planen.

Eine kleinräumige Betrachtung des Siedlungsraumes stellt deshalb hohe Anforderungen an die Datengrundlage, da diese die Siedlungsstruktur in möglichst hoher semantischer und geometrischer Auflösung wiedergeben müssen. Für einen operationellen Einsatz entwickelter Analyseverfahren sollten die Daten jedoch weitere Kriterien wie die digitale Verfügbarkeit, deutschlandweite Abdeckung, hohe Aktualität, Fortschreibungsgarantie und eine möglichst zentrale Datenvorhaltung erfüllen.

Im Folgenden werden verschiedene Datenquellen vorgestellt, die diesen Anforderungen weitestgehend gerecht werden:

- Daten der amtlichen Statistik
- Daten zur Flächenbedeckung und Flächennutzung

Anfangs werden Daten zum Gebäude- und Wohnungsbestand diskutiert, die seitens der amtlichen Statistik sowie privatwirtschaftlicher Anbieter auf unterschiedlichen Bezugsebenen aggregiert zur Verfügung stehen. Es wird gezeigt, dass es zum Bestand derzeit keine flächendeckenden Informationen unterhalb der Gemeindeebene gibt. In einer weiteren Zusammenschau werden Daten zur Flächenbedeckungs- und Flächennutzung vorgestellt, in denen der Siedlungsraum und deren Elemente beschrieben werden.

A.1. Daten der amtlichen Statistik

Die amtliche Statistik wird vertreten durch das Statistische Bundesamt, den Statistischen Landesämtern und den Statistischen Ämtern der Gemeinden und Gemeindeverbände. Einen guten Überblick über die verfügbaren statistischen Daten verschafft der regionalstatistische Datenkatalog des Bundes und der Länder (Statistische Ämter des Bundes und der Länder, 2012). Diese enthalten Themen zur Umwelt, zur Bevölkerung und Erwerbstätigkeit, zum Gebäude- und Wohnungsbestand, zur Flächennutzung oder zum Handel, Gewerbe bzw. Tourismus. Die Daten können mithilfe des Systems EASYSTAT aus einer von Bund und Ländern gemeinsam herausgegebenen Datenbank „Statistik lokal“ herausgelesen werden und werden auf Kreis- und z. T. auch Gemeindeebene über die "Regionaldatenbank Deutschland" (GENESIS Online regional, www.regionalstatistik.de) kostenfrei im Internet bereitgestellt und fortlaufend aktualisiert sowie um weitere Themen erweitert. Neben der amtlichen Statistik gibt es zunehmend auch privatwirtschaftliche Unternehmen, welche kleinräumige nichtamtliche Daten zur Siedlungsstruktur anbieten.

A.1.1 Gebäude- und Wohnungsbestandsdaten

Die amtliche Statistik liefert Daten zur Qualität, Quantität und Struktur des Gebäude- und Wohnungsbestandes (Destatis, 2011c). Eine tiefe regionale Gliederung wird nur mit einer kosten- und zeitintensiven Vollerhebung wie der Gebäude- und Wohnungszählung (GWZ) erreicht. Eine derartige Erhebung fand in den alten Bundesländern mit Stichtag am 25. Mai 1987 (GWZ'87) und in den neuen Ländern und Berlin-Ost am 30. September 1995 (kurz GWZ'95) statt. Erst mit dem Zensus 2011 kann ab 2013 mit neuen Vollerhebungsdaten gerechnet werden. In dem langen Zeitraum zwischen den Erhebungen ist man auf eine jährliche Fortschreibung des Bestandes angewiesen. Amtliche Daten zum Gebäude- und Wohnungsbestand basieren deshalb derzeit auf der jährlichen Fortführung der GWZ'87, GWZ'95, die im Hochbaustatistikgesetz (HBauStatG 285) geregelt ist. Auf Grundlage dieser Regelungen werden folgende Kenngrößen für Landkreise, kreisangehörige Gemeinden und für kreisfreie Städte jährlich fortgeschrieben (HbauStatG, 1998):

- der Bestand an Wohngebäuden[91],
- der Bestand an Wohnungen in Wohn- und Nichtwohngebäuden nach Zahl der Räume
- und der Bestand an Räumen und Wohnfläche.

Tab. A-1 zeigt einen Auszug aus der gemeindebezogenen Wohnungs- und Gebäudestatistik. Die Fortschreibung erfolgt jährlich zum Ende des Kalenderjahres (Stichtag 31. Dezember) durch einen Abgleich der Basisdaten durch Saldo der Zu- und Abgänge aus der Bautätigkeitsstatistik (Destatis, 2011c). Die Daten der Bautätigkeitsstatistik werden über die Erhebungsbögen der Baugenehmigung, Baufertigstellung und dem Bauabgang gewonnen. Im Rahmen dieser Erfassung werden für den Neubau zusätzliche Merkmale zum Gebäudetyp (z. B. Einzelhaus, Doppelhaus, gereihtes Haus), zum verwendeten Baustoff (z. B. Ziegel, Porenbeton, Stahl), zur Heizenergie (primär/sekundär) oder der Anzahl der Vollgeschosse erhoben, wohingegen beim Abriss das Baualter abgefragt wird. Diese zusätzlichen Merkmale werden zwar erfasst, gehören jedoch nicht zum Standardveröffentlichungsprogramm. Gemeindescharfe Aussagen zur aktuellen Baualtersstruktur im Gebäudebestand können darum nur durch eine eigene Datenauswertung unter Nutzung der letzten Vollerhebung vorgenommen werden.

Eine jährliche Fortschreibung der Daten ist jedoch nicht fehlerfrei und mit Unsicherheiten behaftet. Ein Problem stellen die in der Bauabgangsstatistik nur unvollständig erfassten Wohnungsabgänge dar (Effenberger & Banse, 2010). Dies sind einerseits nicht gemeldete Abgänge (z. B. beim Ersatzneubau oder Umbau) oder kleinere baurechtlich nicht relevante Umbaumaßnahmen, die jedoch statistisch erfasst werden müssten. Eine Untersuchung in Hessen hat ergeben, dass die Abgänge zwischen den letzten beiden Vollerhebungen 1968

[91] Nach dem Begriffsverständnis der amtlichen Statistik sind Wohngebäude „Gebäude, die mindestens zur Hälfte (gemessen an der Gesamtnutzfläche) Wohnzwecken dienen" (Destatis, 2012a). Deshalb können Wohngebäude einen gewissen Nichtwohnnutzungsanteil (Gewerbe, Arztpraxis) besitzen.

und 1987 im Durchschnitt fast viermal so hoch waren, wie die von der Statistik erfassten Abgänge (IWU, 2004). Es wird deshalb vermutet, dass eine Unterschätzung der Abgänge zu einer Überschätzung des fortgeschriebenen Wohnungsbestandes führt und die tatsächlichen Wohnungszahlen unter den Werten der amtlichen Wohnungsfortschreibung liegen. Um diese Ungenauigkeiten der Wohnungsabgänge besser einschätzen zu können, werden für die Modellierung der Wohnungsnachfrageprognose ergänzende Expertenbefragungen zu Wohnungsabgängen eingesetzt (Eichhorn et al., 2009). Sichere Aussagen dazu lassen sich jedoch erst mit Veröffentlichung der Ergebnisse des registergestützten Zensus 2011 voraussichtlich im Jahr 2013 treffen (siehe A.1.5).

Tab. A-1: Auszug aus der Gemeindebezogenen Wohnungs- und Gebäudestatistik (Quelle: Statistische Ämter des Bundes und der Länder: Statistik lokal – Ausgabe 2010, Stand 31.12.2008)

Schlüssel Region	Wohngebäude*)				Wohnungen in Wohn- und Nichtwohngebäuden*)								
	Insgesamt	darunter mit		Wohnfläche in 1 000 m²	Insgesamt	davon mit ... Raum/Räumen							Räume in Wohnungen mit 7 oder mehr Räumen
		1 Wohnung	2 Wohnungen			1	2	3	4	5	6	7 oder mehr	
	1	2	3	4	5	6	7	8	9	10	11	12	13
00 Bundesrepublik Deutschland	17950185	11306332	3578001	3393447	40057869	849529	2454258	8576996	11751142	7833711	4357374	4234859	33055914
01 Schleswig-Holstein, Land	740124	559097	94833	118900,4	1393054	25074	83182	283894	390903	318027	163673	128301	988762
01001 Flensburg, krsfr. Stadt	15182	9131	1324	3550,7	47966	694	2818	13015	16426	9025	3611	2377	18272
01002 Kiel, krsfr. Stadt	35345	20064	3188	8988,7	131069	3560	9054	42234	43577	20384	7732	4528	34542
01003 Lübeck, krsfr. Stadt	41295	25112	5555	8052,4	113893	2620	8682	30569	38636	20607	7786	4993	38171
01004 Neumünster, krsfr. Stadt	18251	12812	1978	3169,6	41078	519	2067	9906	13730	8562	3804	2490	18911
01051 Dithmarschen, Landkreis	47374	39708	4910	6246,1	67266	776	3521	11599	17246	16520	9480	8124	62755
01051001 Albersdorf	1122	861	177	155,8	1593	11	65	224	385	417	263	228	1778
01051002 Arkebek	69	53	13	11,1	89	0	2	12	16	19	15	25	207
01051003 Averlak	240	208	25	28,4	293	6	8	46	79	76	46	32	249
01051004 Bargenstedt	310	282	24	37,3	381	0	9	45	88	98	79	62	476
01051005 Barkenholm	66	58	8	8,6	87	0	1	12	15	16	18	25	195
01051006 Barlt	315	274	34	38,6	392	2	9	62	98	116	47	58	441

A.1.2 Bevölkerungsstatistik

Die Bevölkerungsdaten werden jeweils auf Grundlage der letzten Volkszählung vom 25. Mai 1987 (alte Bundesländer) und der amtlichen Einwohnerzahl vom 3. Oktober 1990 (neue Bundesländer) fortgeschrieben. Die Fortschreibung des Bevölkerungsstandes erfolgt nach der Hauptwohnung der Einwohner und stützt sich auf das Melderechtsrahmengesetz (MRRG). Die jährliche Fortschreibung basiert auf den Ergebnissen der Statistik zur natürlichen Bevölkerungsbewegung (Geburten und Sterbefälle), Eheschließungen, Ehelösungen sowie der Wanderungsstatistik über die Zu- und Fortzüge. Diese Daten werden von den Statistischen Ämtern der Länder (Standesämtern, Familiengerichten und Meldebehörden) erhoben. Mit der jährlichen Fortschreibung liegt eine vollständige Zeitreihe seit 1950 vor, die über das Statistische Bundesamt veröffentlicht wird (Destatis, 2010).

A.1.3 Mikrozensus-Erhebung

Zu den jährlichen Fortschreibungen der amtlichen Statistik werden mit dem Mikrozensus weitere statistische Erhebungen auf Grundlage einer 1 %igen Stichprobe der Privathaushalte durchgeführt. Der Mikrozensus stellt seit 1957 eine jährliche Repräsentativstatistik über die Bevölkerungsstruktur und den Arbeitsmarkt dar. Neben dem jährlichen Grundprogramm werden mit dem Mikrozensus in periodischen Zeitabständen zusätzliche Erhebungen durchgeführt (Destatis, 2012b). Die Haushaltsbefragung zur „Wohnsituation der Haushalte“ ist eine derartige Zusatzerhebung, die auf Grundlage des Mikrozensusgesetzes alle 4 Jahre erfolgt und Informationen über die Art und Größe des Wohngebäudes, die Baualtersgruppe, Wohnfläche, Nutzung, Mietsverhältnis, Ausstattung, Heizungsart etc. bis hin zu den Miets- und Nebenkosten liefert (Destatis, 2006). Auf Grundlage der Mikrozensusdaten erfolgt eine Hochrechnung auf Ebene regionaler Anpassungsschichten. Diese bundesweit 132 Mikrozensus-Anpassungsschichten sind zusammengefasste Stadt- und Landkreise mit ausreichender Flächengröße und damit die kleinstmöglichen Bezugsflächen für die das Hochrechnungsverfahren noch belastbar ist. Dabei werden die Stichprobenverteilungen an Eckwerten ausgewählter Hilfsvariablen der laufenden Wohnungsfortschreibung angepasst (Destatis, 2006).

A.1.4 Sonderauswertungen

Im Rahmen der letzten Vollerhebungen GWZ'87 und GWZ'95 wurden neben den fortgeführten Merkmalen (Anzahl der Gebäude, Wohnungen, Wohnfläche) Informationen zum Baualter, Erhaltungszustand, Eigentumsform, Heizungsart oder der Geschosszahl (nur GWZ'95) erhoben. Diese Daten sind auf Kreisebene beim Statistischen Bundesamt oder auf Gemeindeebene bei den Landesämtern erhältlich. Eine Kreuzung zweier Merkmale, wie z. B. Baualter und Geschosse, kann im Rahmen einer Sonderauswertung kostenpflichtig bei den jeweiligen Ämtern durchgeführt werden. Eine derartige Auswertung der GWZ'87-Daten der alten Bundesländer gestaltet sich aber in der Regel schwierig, da diese oft in veralteten Datenformaten oder sogar nur analog vorliegen. Da die Auswertung jeweils durch die zuständigen Ämter erfolgt, bleibt häufig die ämterübergreifende Vergleichbarkeit der Daten begrenzt, da die Berechnungen in der Regel auf individuellen Lösungen beruhen.

A.1.5 Zensus 2011

Die derzeit verfügbaren Daten zur Bevölkerung, Wohnungen und Gebäuden basieren auf Fortschreibungen der letzten Zählungen, womit sie eine zunehmende Ungenauigkeit bekommen. Mit dem Zensus 2011 findet neben einer erstmaligen registergestützten Volkszählung eine postalische Vollerhebung im Rahmen einer Gebäude- und Wohnungszählung statt, die auf einer Eigentümerbefragung beruht. Eine ergänzende Haushaltsbefragung auf Stichprobenbasis sowie eine Erhebung der Gemeinschafts- und Anstaltsunterkünfte sollen die Daten ergänzen (Bubik & Lamla, 2011). Die dabei erhobenen Merkmale sind im Pflichtprogramm der EU gemäß EU-Zensusverordnung festgelegt (z. B. Gebäudeart, Wohnungszahl, Gebäudetyp, Baujahr, Heizungsart etc.) und werden voraussichtlich im Jahr 2013 veröffentlicht[92] (www.zensus2011.de). Allerdings werden diese Daten der Politik, Wissenschaft und Gesellschaft ebenfalls nur in aggregierter Form auf Gemeindeebene zur Verfügung stehen. Da die adressscharfen Daten aus Datenschutzgründen nicht dauerhaft gespeichert werden dürfen (ZensG 2011, 2009), überlegt man sich derzeit Konzepte für die Speicherung, die nicht im Konflikt mit den Vorschriften zur Geheimhaltung und Anonymisierung stehen. Geographische Rasterbezüge bieten hierzu einen geeigneten Raumbezug (Eschwege & Heidrich-Riske, 2006; RatSWD, 2011). In vielen Ländern Europas gibt es hierzu bereits Erfahrungen (z. B. Finnland, Österreich, Norwegen, Schweiz). In Deutschland sind Rasterzellen als räumliches Bezugssystem noch wenig verbreitet, da weder die rechtlichen noch die organisatorischen Rahmenbedingungen bestehen (Szibalski, 2007). Um die Zensusdaten dauerhaft kleinräumig nutzbar zu machen, setzten sich derzeit der Bund im Rahmen der Einführung von E-Government (Bundesregierung, 2012) sowie andere Initiativen, wie der Rat für Sozial- und Wirtschaftsdaten (RatSWD), für eine Änderung im Bundesstatistikgesetz und der Entwicklung von Standards für ein Gitternetz ein (RatSWD, 2011).

A.1.6 Kommunale Statistik

Viele städtische Statistikstellen halten ein breites Angebot statistischer Daten unterhalb der Gemeindeebene (statistische Bezirke, Baublöcke) bereit. Auf Grundlage des Deutschen Städtetages wurde vom Verband Deutscher Städtestatistiker (VDS) ein Leitfaden für eine kommunale Gebietsgliederung herausgearbeitet (Deutscher Städtetag, 1991). Mit ihm werden Raumbezüge vorgeschlagen, wie sie von den Statistikstellen geführt werden sollen. Dazu gehört die Ordnung des Straßen- und Hausnummernsystems sowie die Gliederung des Gemeindegebietes nach Gemeindeteilen, Blöcken und Blockseiten, um eine eindeutige EDV-gestützte Zuordnung statistischer Daten zu ermöglichen. Da eine derartige Datenerfassung und Fortführung sehr teuer ist, stehen solche Daten häufig nur für ausgewählte Städte zur Verfügung. Ein dafür entwickeltes Verwaltungsprogramm (AGK) stellt die Basis für ein kommunales Geodatenmanagement und Informationssystem dar, mit dem alle Elemente des

[92] siehe hierzu auch www.zensus2011.de

statistischen Raumbezuges (Adresszentraldatei, Gebäudedatei und kleinräumige Gliederungen) beschrieben, verwaltet und ausgewertet werden können (Schönheit, 2011).

Die Arbeitsgemeinschaft Kommunalstatistik KOSTAT[93] sammelt in Deutschland diese kleinräumig gegliederten Daten der Kommunalstatistik und stellt sie für öffentliche, private und wissenschaftliche Zwecke zentral bereit. An diesem Projekt beteiligen sich ca. 100 deutsche Kommunen mit einer Einwohnerzahl ab 50.000. Die Daten beschreiben die Bevölkerungs- und Haushaltsstruktur auf Stadtteil- oder Stadtbezirksebene und werden seit 1998/99 jährlich fortgeschrieben. Daten zur Bebauungsstruktur werden dabei allerdings nicht geführt.

A.1.7 Mikrogeographische Marktdaten

Infolge der großen Nachfrage nach kleinräumigen Daten, welche die amtliche Statistik nicht erfüllen kann, werden zunehmend auch nichtamtliche Marktdaten angeboten. Diese privatwirtschaftlichen Geodaten werden von kommerziellen Unternehmen oder Organisationen erfasst, geführt und verkauft und dienen insbesondere dem Geomarketing, worunter man die Planung, Koordination und Kontrolle kundenorientierter Marktaktivitäten von Unternehmen mithilfe von GIS versteht (Schüssler, 2000). Die angebotenen Daten sind meist Ergebnis zielgerichteter räumlicher Analysen, die auf multivariaten Datengrundlagen beruhen. Häufig werden amtliche Grunddaten (Adressen, Hausumringe, Verwaltungsgrenzen, Statistische Daten) erworben, mit zusätzlichen Informationen anderer Quellen oder eigenen Erhebungen kombiniert (veredelt) und auf verschiedene räumliche Einheiten aggregiert.

An dieser Stelle sei kurz auf die mikrogeographischen Daten von infas Geodaten eingegangen (www.infas-geodaten.de), da sie für Deutschland kleinteilige Daten zur Siedlungsstruktur bereithalten. Ein wichtiges Produkt sind die Hausbegehungsdaten. Im Rahmen eigener Hausbegehungen wurden hausscharfe Merkmale für über 19 Mio. Gebäude erhoben (infas geodaten, 2012). Das Merkmal Gebäudecharaktersistik unterscheidet beispielsweise die acht Gebäudeklassen[94]. Weitere Merkmale beziehen sich auf den Pflegezustand, Bauweise, Gebäudealter, Lage des Hauses oder den Wohntyp (infas geodaten, 2012). Aggregierte Daten können dann auf Wohnquartiers-, Straßenabschnitts- oder auf Hausebene erworben werden. Deutschland besteht aus ca. 75 000 Wohnquartieren, die etwa den ehemaligen Stimmbezirken entsprechen und eine annähernd vergleichbare Größe von je 500 Haushalten besitzen.

Einen entscheidenden Nachteil haben diese Daten jedoch. Derzeit beziehen sich die erhobenen Merkmale lediglich auf Hauskoordinaten und nicht auf modellierte Gebäudegrundflächen. Für stadtmorphologische oder -planerische Analysen fehlt es darum an expliziter Gebäudegeometrie, da das Ausmaß im Grundriss eine wichtige Rolle spielt. Zudem sind sie nicht amtlich und damit deren Fortführung nicht gesichert.

---

[93] www.staedtestatistik.de/kostat.html

[94] Ein- oder Zweifamilienhaus, Reihen- oder Doppelhaus, Mehrfamilienhaus, Wohnblock, Terrassenhaus, Bauernhaus, Büro oder sonstiges Gebäude, Fabrik und Lagergebäude (infas geodaten, 2012)

Ein weiterer Punkt sind die fehlenden Informationen zur Datenaktualität, den verwendeten Datenquellen und Methoden. Wegen dem hohen Grad an Intransparenz und Unschärfe ist eine Verwendung für staatliche Anwendungen bedenklich. Zudem sind die Datenpakete sehr kostenintensiv und für wissenschaftliche Belange unbezahlbar. Weitere vergleichbare Datenangebote werden von GfK, GeoMarketing oder Microm vertrieben (GfK, 2012; Microm, 2012).

A.1.8 Fazit

Die Daten der amtlichen Statistik stehen der Politik, Wissenschaft und Gesellschaft nur in sehr aggregierter Form zur Verfügung. Sie sind aufgrund der geringen räumlichen und häufig auch thematischen Auflösung für hochauflösende Analysen der Siedlungsstruktur lediglich als Validierungs- und Dissagregationsgrundlage geeignet. Die kleinste räumliche Bezugseinheit, auf der flächendeckende Angaben zum Gebäude, Wohnungsbestand oder anderen statistischen Kenngrößen bundesweit verfügbar sind, ist die Gemeindeebene. Auf dieser sind derzeit nur die fortgeschriebenen Bestandsgrößen Gebäude und Wohngebäudezahl (mit 1, 2, 3 oder mehr Wohnungen), Wohnungen in Wohn- und Nichtwohngebäuden (nach Anzahl der Räume 1, 2 …7 oder mehr) und die Wohnfläche verfügbar. Hochgerechnete Daten zum Leerstand und dem Baualter sind auf Ebene der regionalen Anpassungsschichten[95] beziehbar. Nur im Rahmen kostenpflichtiger Sonderauswertungen, die auf den Erhebungen der GWZ, der Bautätigkeitsstatistik bzw. des Mikrozensus beruhen, können bei den statistischen Ämtern Daten unterhalb der Gemeindeebene bezogen werden. Damit sind jenseits der wohnungs- und gebäudebezogenen Statistiken keine baustrukturellen Informationen beziehbar. In Tab. A-2 sind die flächendeckend verfügbaren statistischen Bestandsgrößen zur Siedlungsstruktur in einer Übersicht zusammenfassend dargestellt.

Die Bebauungsform wird in der amtlichen Statistik nicht erfasst. Im Mehrfamilienhausbestand können jedoch Bezüge ausgenutzt werden, die zwischen dem Gebäudealter und der Bebauungsform stehen (Meinel et al., 2008a). Kenngrößen zur Wohnungsdichte, Wohndichte oder Geschossfläche können aus den Daten der Flächen- und Wohnungsstatistik nur grob auf Gemeindeebene abgeschätzt werden. Die mikrogeographischen Marktdaten privater Anbieter werden wegen des nichtamtlichen Charakters, den intransparenten Erhebungsmethoden und letztendlich auch den hohen Beschaffungskosten in dieser Arbeit nicht weiter betrachtet.

[95] Anpassungsschichten sind zusammengefasste Kreise, die im Durchschnitt 500 000 Einwohner umfassen.

Tab. A-2: Gebäudekenngrößen der amtlichen Statistik (in Anlehnung an Meinel et al., 2008a mit Bezug auf Statistische Ämter des Bundes und der Länder, 2012)

Bestandsgröße	Kleinste räumliche Ebene	Sachliche Differenzierung	Erhebung (E) Fortschreibung (F)
Wohnungen			
Wohnungszahl im Wohngebäude	Gemeinde	nach Anzahl der Räume 1, 2 …7 (nur auf Länderebene)	jährlich (F)
Wohnungsgröße im Gebäudebestand	Gemeinde	Wohngebäude	jährlich (F)
Einwohner			
Bevölkerung	Gemeinde	nach Geschlecht und Altersgruppen	jährlich (F)
Bevölkerung	Kreise	nach Geschlecht, Nationalität und Altersgruppen, nach Geschlecht und Altersjahren, Durchschnittliche Jahresbevölkerung nach Geschlecht	jährlich (F)
Zu- und Fortzüge	Gemeinde	nach Geschlecht und Altersgruppen	jährlich (F)
Gebäude			
Gebäudezahl	Gemeinde	Wohngebäude mit 1, 2 und 3 Wohnungen	jährlich (F)
Geschosszahl Gebäudetyp Heizungsart Baustoff	Gemeinde		jährlich (E) nur für den Neubau
Baualtersklasse	Gemeinde		jährlich (E) nur für den Abgang
Wohnungsbelegung Baualtersgruppe Wohnfläche Nutzung Mietsverhältnis Ausstattung Heizungsart Miet-/Nebenkosten	Regionale Anpassungsschichten		Erfassung aller 4 Jahre im Rahmen des Mikrozensus
Sonstige			
Flächenerhebung	Gemeinde	nach Art der tatsächlichen Nutzung	jährlich
Energieverbrauch	Kreise		jährlich

A.2. Daten zur Flächenbedeckung und Flächennutzung

Im Folgenden werden flächendeckend verfügbare Daten zur Flächenbedeckung und Flächennutzung vorgestellt, die in der Regel auf Basis von Luft- oder Satellitenbilddaten erstellt werden. Unberücksichtigt bleiben Datengrundlagen, die nicht flächendeckend vorliegen oder nicht homogenisiert und nur dezentral in Städten und Gemeinden vorgehalten werden, wie etwa Bebauungs- und Flächennutzungpläne oder das Digitale Raumordnungskataster. Auch digitale Blockkarten, Stadtstrukturtypenkartierungen oder weitere Daten aus kommunalen Fachinformationssystemen, die die Siedlungsstruktur in hoher räumlicher und thematischer Auflösung beschreiben, sollen in diesem Zusammenhang nicht betrachtet werden, da sich ihre Verfügbarkeit nur auf größere Städte beschränkt. Im Folgenden gehen wir der Frage nach, inwieweit diese Daten Informationen für die Beschreibung der Siedlungsstruktur besitzen.

A.2.1 Amtliche Geobasisdaten

Das amtliche Vermessungswesen wird in Deutschland durch die Landesvermessung und das Liegenschaftskataster repräsentiert. Es erfasst und dokumentiert „grundlegende Daten von den Erscheinungsformen der Oberfläche (Geotopographie) bis zur Abgrenzung von Grundstücken und grundstücksbezogenen Rechten (Liegenschaftskataster) und stellt den einheitlichen Raumbezug bereit“ (AdV, 2011b). Die Geobasisdaten werden in einem Geobasisinformationssystem geführt und stehen dem Nutzer für unterschiedliche Fachanwendungen mit Raumbezug bereit. Die Vermessungs- und Katasterverwaltungen der Bundesländer sind für die Bereitstellung und den Vertrieb der Geobasisdaten verantwortlich.

Die Arbeitsgemeinschaft der Vermessungsverwaltungen der Länder der Bundesrepublik Deutschland (AdV) stellt die bundeseinheitliche Gliederung und Bezeichnung der Objekte und Nutzungen im Modell sicher. Um ein nationales einheitliches Mindestmaß an Informationsgehalt und Genauigkeit zu gewährleisten, ist ein Grunddatenbestand vereinbart, der von den Ländern umgesetzt werden muss. Dieser bezieht sich insbesondere auf die bundesweit zu führenden Objektartengruppen und Objektarten in den Modellen. Mit der eingeführten AdV-Gebührenrichtlinie, in der Empfehlungen zur Gebührenerhebung für die Geobasisdaten festgelegt sind, werden einheitliche Gebühren sichergestellt.

Die Flächenbedeckung und Flächennutzung wird einerseits in der Automatisierten Liegenschaftskarte (ALK) sowie den Digitalen Landschaftsmodellen des Amtlichen Topographisch-Kartographischen Informationssystems (ATKIS®) wiedergegeben.

A.2.1.1 Automatisierte Liegenschaftskarte (ALK)

In der Liegenschaftskarte des Liegenschaftskatasters werden die Flurstücksgrenzen, die baulichen Anlagen und deren Nutzung dargestellt. In den letzten Jahren wurden die analogen Liegenschaftskarten von den Vermessungsverwaltungen aufbereitet und stehen in Deutschland inzwischen flächendeckend in digitaler Vektorform als Automatisierte Liegenschaftskarte (ALK) bereit[96].

Die ALK wird im Maßstab 1: 1 000 (bzw. 1: 500) erhoben. Im Datenbankmodell der ALK wird zwischen der Grundrissdatei (z. B. Flurstücke, Gemarkungen, Gebäude, Nutzung etc.) und der Punktdatei (Festpunkte, Grenzpunkte, Gebäudepunkte etc.) unterschieden. In der ALK-Grundrissdatei werden die Grundrissobjekte entsprechend ihrer fachlichen Bedeutung zusammengefasst und in Form von Fachfolien (vgl. Tab. A-3) gegliedert. Der Nachweis aller Folien und Objektarten, die im ALK-Verfahren verwendet werden, sind im länderspezifischen Objektschlüsselkatalog (OSKA) und Objektabbildungskatalog (OBAK) festgelegt. Diese gehen jedoch aus den Musterobjektabbildungskatalogen hervor, die für die Anwendung der Liegenschaftskarte von der AdV bereitgestellt werden (AdV, 2006).

[96] in Bayern wird die digitale Liegenschaftskarte als Digitale Flurkarte (DFK) bezeichnet

Tab. A-3: Ausgewählte Fachfolien des OSKA (Quelle: www.landesvermessung.sachsen.de)

Folien-Nr.	Bezeichnung
001	Flurstücke
002	Gemarkung, Flur
003	Politische Grenzen
011	Gebäude
021	Nutzung
022	Topographie
033	Straßenflächen
034	Gewässerflächen
042	Flächen der Bodenschätzung
071	Kartenblattrand
086	Gebäude aus Luftbilderzeugnissen

Die föderale Verwaltungsstruktur in Deutschland bedingt, dass die Vermessungs- und Katasterverwaltungen von Land zu Land unterschiedlich organisiert sind. Die Organisationsformen reichen von einer vom Bundesland geführten Behörde (Integrationsbehörde), wie die Landesvermessungsämter in Niedersachsen und Sachsen-Anhalt, bis hin zu einer kommunalisierten Organisation (z. B. Brandenburg, Nordrhein-Westfalen), in die sämtliche Aufgaben der kommunalen Vermessungsämter übertragen worden sind. Im Freistaat Sachsen wird die ALK beispielsweise von 13 verschiedenen Vermessungsbehörden geführt, die auf Ebene der Landkreise und kreisfreien Städten organisiert sind. Um einen katasteramtsübergreifenden Datenzugang zu gewährleisten, werden diese über eine zentrale Stelle (Landesvermessungsamt, Geodatenzentrum) vertrieben, so dass zwar nicht deren Erhebung, aber deren Vertrieb in der Regel zentral gewährleistet ist[97].

In den Verwaltungsvorschriften (Nutzungsartenerlasse) der Länder sind die im Kataster auszuweisenden Flächen der „Tatsächlichen Nutzung" (Folie 021) im OSKA rechtlich festgelegt. Sie ist Grundlage für die amtliche Flächenstatistik. Die Flächenausweisung orientiert sich aber an dem von der AdV ausgearbeiteten Nutzungsartenkatalog (AdV, 2011a). Am Beispiel von Sachsen sind in Abb. A-1 ausgewählte Nutzungsarten der ALK aufgezeigt, die hauptsächlich den Siedlungsbereich betreffen. Dabei werden im Wesentlichen die Funktionen Wohnen, Arbeiten, Erholung, Ver- und Entsorgung und Verkehr abgebildet. Informationen zur baulich-räumlichen Struktur (z. B. die Unterscheidung nach der Wohnform) sind jedoch nicht enthalten.

[97] Für einige Städte, wie z. B. die Städte Chemnitz, Dresden und Leipzig in Sachsen, sind die Daten dennoch nur bei den jeweiligen städtischen Vermessungsämtern erhältlich.
(www.landesvermessung.sachsen.de/inhalt/produkte/lika/alk /alk.html)

Abb. A-1: Modellierte Objektarten der Nutzung aus Folie 021 mit Fokus auf die bebauten Flächen aus der Verwaltungsvorschrift des Freistaates Sachsen (VwVLika 2005)

A.2.1.2 Digitales Landschaftsmodell (ATKIS® Basis-DLM)

Mit dem Digitalen Landschaftsmodell (DLM) werden bundeseinheitliche geotopographische Daten für mittel- bis kleinmaßstäbige Anwendungen bereitgestellt. An dieser Stelle wird der Fokus auf das ATKIS® Basis-DLM mit höchster Auflösung gelegt, das auf Grundlage aktueller Ortholuftbilddaten flächendeckend homogenisiert erstellt und regulär fortgeführt wird. Die objektbasierte Beschreibung der Landschaft im Basis-DLM ist im hierarchisch strukturierten Objektartenkatalog der AdV (ATKIS®-OK) samt deren Erfassungs- und Modellierungskriterien festgelegt.

Der Informationsumfang orientiert sich inhaltlich an dem der Topographischen Karte 1: 10 000 bzw. 1: 25 000. Die Landschaftsstruktur wird durch Objekte der Bereiche Siedlung, Verkehr, Vegetation, Gewässer, Relief und Gebiete beschrieben (Abb. A-2). Die „bebaute Fläche“ wird im Basis-DLM weiter nach den Nutzungsarten „Wohnbauflächen“, „Industrie- und Gewerbeflächen“, „Flächen gemischter Nutzung“ und „Flächen besonderer funktionaler Prägung“ differenziert. Mit den baulich geprägten Flächen, die durch topographische Linienelemente (Straßen, Gewässer etc.) zerschnitten werden, steht der Baublock als eine für die Stadtmorphologie und Planung höchst wichtige Geometrie und Bezugseinheit bereit. Dabei handelt es sich um Bruttobaublöcke, die im Gegensatz zu den Nettobaublöcken die Erschließungsflächen beinhalten.

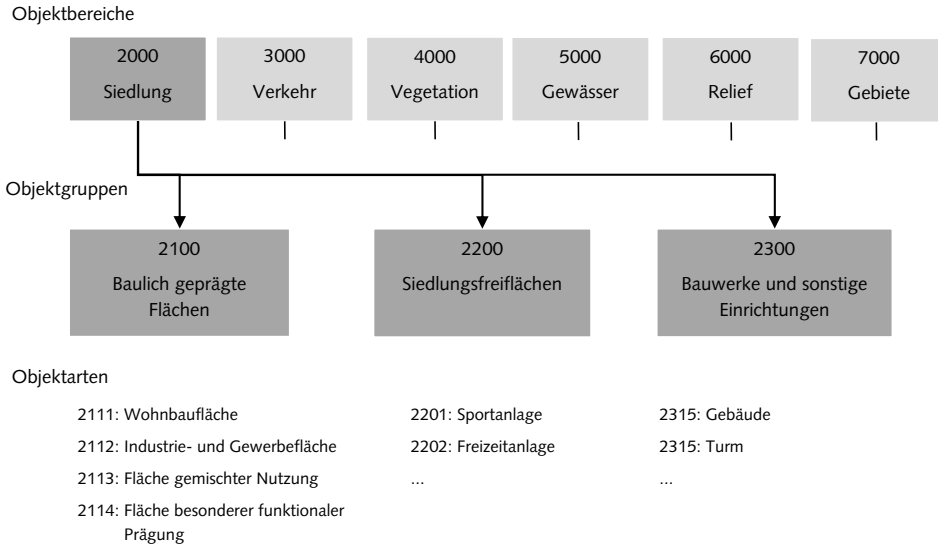

Abb. A-2: Aufbau des ATKIS® Basis-DLM: Elemente des Objektbereiches Siedlung

Das ATKIS® Basis-DLM enthält darüber hinaus Bauwerke, die jedoch zumeist nicht Bestandteil der von den Landesvermessungsämtern herausgegebenen Daten sind. Die Modellierung der Gebäude war zwar in der letzten Realisierungsstufe 3 (DLM/3) als Grunddatenbestand angedacht, mit der letzten Version 6.0 sind diese jedoch optional. Die Gebäudebereitstellung im Basis-DLM ist dann Länderentscheidung. Aktuell führen insbesondere die neuen Bundesländer die Gebäude im Grundriss. Mit einem Erfassungsmaßstab von ca. 1: 10 000 ist das Basis-DLM die Grundlage für die automatisierte Ableitung der DTK25 bzw. der DTK10.

Die Datensätze des ATKIS® Basis-DLM werden vom BKG überprüft, harmonisiert und in ein blattschnittfreies bundeseinheitliches Basis-DLM gebracht, um sie dem Nutzer für die Bearbeitung länderübergreifender Fragestellungen zur Verfügung zu stellen. Das digitale Landschaftsmodell in seiner Basisversion stellt darum eine gute Grundlage für flächendeckende Analysen und Anwendungen dar. Im Monitor der Siedlungs- und Freiraumentwicklung im IÖR wird das ATKIS® Basis-DLM beispielsweise genutzt, um auf Gemeinde- oder Rasterzellenbasis verschiedene Indikatoren der Siedlungsstruktur zu berechnen (Meinel, 2009).

A.2.1.3 Flächennutzung im integrierten AAA-Modell

Die Führung geotopographischer Geobasisinformation und Liegenschaftskataster erfolgte bisher getrennt durch die Landesvermessungsämter (ATKIS®) und die kommunalen Katasterämter (ALK). Mit den Anforderungen einer modernen Informations- und Kommunikationsgesellschaft haben sich die Aufgaben der amtlichen Vermessung in den letzten Jahren grundlegend geändert. Neben dem Führen von Liegenschaften und dem Bereitstellen von Geoinformation gehört seit geraumer Zeit auch die Integration von Geoinformation zum Geobasisinformationssystem zur Kernaufgabe (Ostrau, 2010).

Da die Daten des Liegenschaftskatasters und der Landesvermessung einen engen Sachzusammenhang aufweisen, diese aber bisher getrennt geführt werden, wird mit dem neuen integrierten, bundesweit einheitlichen Datenmodell, dem AAA-Modell der AdV, eine integrative Zusammenführung zu einem Geobasisinformationssystem realisiert (Abb. A-3).

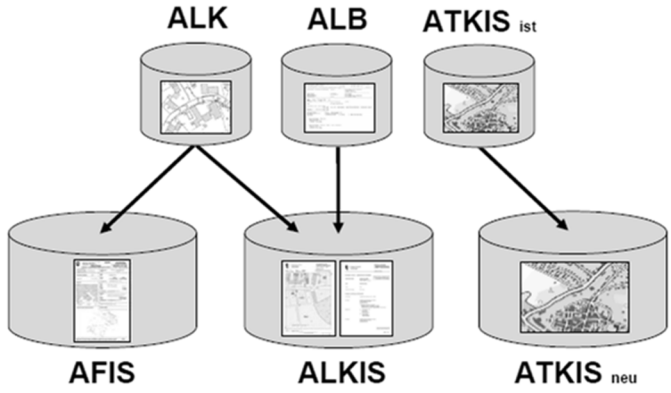

Abb. A-3: Überführung von ALK, ALB und ATKIS® in das AAA-Modell (Quelle: TOPO graphics GmbH)

Hinter dem AAA-Modell verbirgt sich das AFIS®-ALKIS®-ATKIS®-Modell als konzeptuelles Anwendungsschema für die Informationssysteme AFIS® (Amtliches Festpunkt-Informationssystem), ALKIS® (Amtliches Liegenschaftskatasterinformationssystem) und das ATKIS® (Amtliches Topographisch-Kartographisches Informationssystem). Im AAA-Modell werden die ALK und das Automatisierte Liegenschaftsbuch (ALB) durch das Amtliche Liegenschaftskatasterinformationssystem (ALKIS®) ersetzt und in einem System vereint.

Das Ziel der Migration ist eine geometrische und semantische Harmonisierung zu einem bundesweit einheitlichen Grunddatenbestand mit einem einheitlichen Raumbezug (Bezugssystem ETRS89/UTM). Der neue Objektartenbereich der Tatsächlichen Nutzung beinhaltet alle Objektarten mit denen die Erdoberfläche lückenlos und überschneidungsfrei beschrieben werden kann und ist im AAA-Modell zwischen ALKIS® (Liegenschaftskataster) und ATKIS® (Landesvermessung) vollständig semantisch harmonisiert.

Bei der Umstellung auf das AAA-Modell waren einige Umstrukturierungen im ATKIS®-Objektartenkatalog nötig (Kunze, 2010). Eine gegenüberstellende Analyse der Grunddatenbestände von ALKIS® und ATKIS® (Ostrau, 2010) hat am Beispiel der tatsächlichen Nutzung gezeigt, dass diese im ALKIS® einen höheren semantischen und geometrischen Strukturierungsgrad gegenüber dem ATKIS® Basis-DLM erfährt. Die Migration des ATKIS® Basis-DLM in das neue AAA-Modell hatte weder geometrische Verbesserungen noch feingliedrigere semantische Strukturen zur Folge. Die Nutzungsinformationen sind im ATKIS® jedoch in der Regel aktueller als in der Liegenschaftskarte (Ostrau, 2010; Meinel et al., 2012), da eine zyklische Grundaktualisierung durchgeführt wird und mit der Ableitung topographischer Karten Datenfehler schneller sichtbar werden.

Aktuell findet in den Ländern die Umstellung zum integrierten AAA-Modell statt. Eine Umfrage vom 22.03.2012 zum Sachstand der Migration in den Ländern zeigte, dass bereits 12 von 16 Bundesländern auf ATKIS® sowie 6 von 16 Bundesländern auf ALKIS® im AAA-Modell umgestellt haben (AdV, 2012a).

A.2.2 Fernerkundungsbasierte Erhebungen

A.2.2.1 Biotoptypenkartierungen

Biotoptypen- und Nutzungstypenkartierungen sind eine wichtige Grundlage für ökologische Planungsbelange, wie den Naturschutz oder die Landespflege. In der Regel werden sie durch manuelle Interpretation von CIR-Luftbildern im Maßstab 1: 10 000 und zusätzlichen Ortsbegehungen nach einem einheitlichen Klassifikationsschema erstellt (Bill & Zehner, 2001). In den Bundesländern liegen sie als selektive (nur schutzwürdige Biotope werden kartiert) oder flächendeckende Biotoptypenkartierungen vor. Eine flächendeckende Erfassung der Biotoptypen- und Landnutzungskartierung erfolgte beispielsweise in Sachsen. Im urbanen Raum wird zwischen „Blockrand- und Zeilenbebauung", „Punktbebauung" und „Hochhäuser", „Villenbebauung" und „Einzel- und Reihenhaussiedlungen" unterschieden (Ueberfuhr & Glaser, 2010). Hinderlich für eine deutschlandweite Bilanzierung sind eine fehlende Flächendeckung, die geringe Aktualität und der nicht bundeseinheitliche Kartierschlüssel (föderative Organisation des Naturschutzes) und die fehlende Nachführungspflicht.

Im urbanen Raum kann die Biotoptypenkartierung auf eine lange Tradition zurückblicken, da sie eine wichtige Datenbasis für stadtökologische Fragestellungen darstellt (Sukopp & Wittig, 1998). Stadtbiotoptypenkartierungen werden seit den frühen 1980er Jahren systematisch angefertigt. Man unterscheidet zwischen flächendeckenden und selektiven Kartierungen. Bei einer selektiven Biotopkartierung werden nur schutzwürdige bzw. potenziell schutzwürdige Biotope erfasst. Im Jahr 2002 waren bereits 222 deutsche Städte mit einer derartigen Kartierung ausgestattet, wobei davon nur 25 % der Städte eine flächendeckende Kartierung vornahmen (Bochow, 2010; Wächter, 2003). Bei flächendeckenden Kartierungen wird im bebauten Bereich teilweise sehr differenziert zwischen verschiedenen Bebauungs- und Wohnnutzungsformen unterschieden. Hierzu wurde von der Bund-Länder-Arbeitsgruppe „Methodik der Biotopkartierung im besiedelten Bereich" (AG Methodik, 1993) eine einheitliche stadtökologisch fundierte Kartiermethodik vorgeschlagen. Der dabei ausgearbeitete Kartierschlüssel sieht eine Differenzierung des besiedelten Bereiches nach verschiedenen Wohn- und Bebauungsformen vor, in dem die Typen „Blockbebauung", „Blockrandbebauung", „Zeilenbebauung", „Großformbebauung und Hochhäuser", „Einzel- und Reihenhausbebauung", „alte Villen mit parkartigen Gärten", „verstädterte Dorfgebiete", „Längliche Wohnformen" und „Dörfliche Siedlungsflächen" unterschieden werden. Da derartige Kartierungen sehr zeit- und kostenintensiv sind, erfolgt eine Aktualisierung in der Regel nur sehr selten. Es wird geschätzt, dass nur fünf Prozent aller Erstkartierungen eine Aktualisierung erfahren. Darum ist man bestrebt Methoden zu entwickeln, die eine automatisierte Aktualisierung auf Grundlage von Fernerkundungsdaten erlauben (vgl. Bochow, 2010).

A.2.2.2 CORINE Land Cover

Ziel des europaweiten Projektes *CORINE Land Cover* (CLC) ist die Bereitstellung einheitlicher und vergleichbarer Daten zur Bodenbedeckung und Landnutzung in Europa. Die europaweit harmonisierten CLC-Daten basieren auf einer Auswertung von Satellitendaten und finden viele Anwendungen auf nationalem und regionalem Level. Mit der regelmäßigen Aktualisierung stehen bereits CLC-Daten für die Jahre 1990, 2000, 2006 und 2009 zur Verfügung (2012 ist in Arbeit). Mit dem kleinen Erhebungsmaßstab 1: 100 000 liefert CLC aber nur eine sehr grobe Differenzierung der bebauten Flächen. Kleinere bebaute Flächen (kleine Ortschaften, Einzelsiedlungen) werden nicht erfasst, da die Erfassungsuntergrenze bei 25 ha liegt. Thematisch steht die Bodenbedeckung im Vordergrund. Die „Städtisch geprägte Fläche" auf Level 2 der CLC-Nomenklatur wird lediglich weiter in die Unterklassen „durchgängig städtische Prägung" und „nicht durchgängig städtische Prägung" untergliedert. Für eine siedlungsstrukturelle Analyse sind diese Daten aufgrund der geringen thematischen und räumlichen Auflösung nur für kleinmaßstäbige Anwendungen geeignet. Auf deren Grundlage wurde mittels räumlicher Dissaggregation eine europaweite Karte der Bevölkerungsdichte im Raster mit einer Auflösung von 100 m x 100 m erstellt (Gallego, 2010).

A.2.2.3 DML-DE

Für viele Anwender ist die räumliche und zeitliche Auflösung der europaweit verfügbaren CLC-Datensätze zu gering. In Deutschland wurde deshalb im Rahmen von GMES (Global Monitoring for Environment and Security) ein integrierter Datensatz initiiert, der vorhandende topographische Daten und Fernerkundungsdaten miteinander kombiniert. GMES ist eine gemeinsame Initiative der Europäischen Kommission und der Europäischen Weltraumorganisation (ESA) und widmet sich der Versorgung von Entscheidungsträgern mit Informationen zur Umwelt und Sicherheit (Tinz, 2010). Das Produkt mit der Bezeichnung DLM-DE LC (Land Cover) wurde auf Grundlage des ATKIS® Basis-DLM (2009) und RapidEye Daten mit einer Auflösung von 5 Metern im Sinne der EU-Nomenklatur (CLC) abgeleitet. Im Gegensatz zu CORINE liegt eine geringere Erfassungsuntergrenze von 1 Hektar vor. Das hochauflösende DLM-DE 2009 wird in Zukunft in einem weiteren Generalisierungsschritt zum CLC2009-Produkt mit EU-Spezifikationen überführt (Arnold, 2009; Keil et al., 2010).

Ein weiterer Datensatz, der im Rahmen von GMES entstand, ist der hochaufgelöste „Urban Atlas". Mit einer gesamteuropäischen Systematik werden für insgesamt 305 Städte und deren Umland vergleichbare Daten erzeugt. Die Kategorien entsprechen ebenfalls denen der CORINE Land Cover Nomenklatur. Wegen fehlender Flächendeckung und der geringen thematischen Auflösung sind diese Daten nur für vergleichende Studien relevant.

A.2.3 Fazit

In Deutschland stehen verschiedene Daten zur Flächenbedeckung und Flächennutzung zur Verfügung. Die fernerkundungsbasierten Kartierungen besitzen gegenüber den geotopographischen Daten eine geringere geometrische und thematische Auflösung im besiedelten Bereich. Gegenüber den geotopographischen Daten differenzieren die fernerkundungsbasierten Daten den Siedlungsraum in stärkerem Maße hinsichtlich der Bodenbedeckung. Aus-

nahme bilden Biotoptypenkartierungen, die jedoch nur in einigen Bundesländern flächendeckend vorliegen und nur selten aktualisiert werden. Bei den amtlichen Geobasisdaten wird der Siedlungsraum aus einer topographisch-funktionalen Sicht abgebildet. Es lassen sich in diesem Modell die Siedlungsraumelemente der Bebauung, Infrastruktur und Freifläche nach Arlt et al. (2010) in den Objektarten wiederfinden. Die gegenüber den ATKIS®-Daten semantisch und geometrisch höher aufgelösten ALK-Daten werden von den unteren Vermessungsbehörden geführt. Sie werden aber zentral von den Behörden der Landesvermessung angeboten. ATKIS®-Daten sind homogenisiert und zentral beim BKG verfügbar. Weder die ALK noch ATKIS® enthalten ausreichend explizite Informationen zur Bebauungsstruktur. Sie sind lediglich implizit mit den darin modellierten Gebäuden gegeben. Mit der flächendeckenden Bereitstellung von ALKIS® im AAA-Modell wird zwar in Zukunft eine deutliche Verbesserung des Zugangs, der Analyse- und Auswertemöglichkeit der Geobasisdaten erwartet, mit einer Verbesserung der semantischen Information zur Bebauungsstruktur kann jedoch nicht gerechnet werden.

B Gebäudetypologie

B.1. Klassenbeschreibung der Gebäudetypologie

Im Folgenden werden die einzelnen Gebäudeklassen näher beschrieben. Grundlage der Herausarbeitung waren insbesondere Müller & Korda (1999), Meinel et al. (2008a) und Gruhler & Blum (2010).

Freistehendes Ein- und Zweifamilienhaus (EFZH-EH)
Bei den freistehenden Ein- und Zweifamilienhäusern handelt es sich um kleine einzeln stehende Wohngebäude mit quadratischer bzw. rechteckiger Form. Sie besitzen einen Haupteingang und in der Regel nur eine oder zwei Wohnungen. Gegen die Nachbargrenzen und Erschließungsflächen wird ein Mindestabstand entsprechend der Baunutzungsverordnung eingehalten. Typisch ist eine straßenbegleitende lockere ein- bis zweigeschossige Wohnbebauung mit großen Grundstücken. Garagen können direkt an das Gebäude oder auch bis an die Grundstücksgrenze gebaut werden. Der Gruppe der EFZH kann kein charakteristisches Baualter zugewiesen werden.

Ein- und Zweifamilienhaus als Doppelhaus (EFZH-DH)
Doppelhäuser sind zwei selbständig aneinander gebaute Ein- oder Zweifamilienhäuser. Jede Doppelhaushälfte ist durch einen eigenen Haupteingang gekennzeichnet. Typisch ist eine straßenbegleitende lockere ein- bis zweigeschossige Bebauung.

Ein- und Zweifamilienhaus als Reihenhaus (EFZH-RH)
Reihenhäuser sind Hausgruppen, die aus mindestens drei aneinander gebauten Gebäuden bestehen. Die einzelnen Gebäude der Gruppe besitzen eine annähernd gleiche Größe und bilden ein handtuchförmiges Gefüge (Gebäudetiefe größer als Gebäudebreite). Die Reihenhäuser stehen für flächensparendes Bauen und deren Bebauung lässt sich gut an die topographische Gegebenheiten anpassen. Zu den Reihenhäusern zählen in diesem Fall auch die Sonderformen des Gartenhof- und Artriumhauses, die in Müller & Korda (1999) eine eigene Klasse der Einfamilienhäuser darstellen.

Mehrfamilienhaus in offener Bauweise (MFH-F)
Freistehende Mehrfamilienhäuser sind Einzel- und Doppelhäuser mittlerer Größe, die über eine selbstständige Erschließung verfügen und mindestens 3 Wohnungen besitzen. Hierzu zählen Zweispänner (2 Wohnungen pro Geschoss), Dreispänner (3 Wohnungen pro Geschoss) und Vierspänner (4 Wohnungen pro Geschoss). Demnach fallen auch alle freistehenden Vielwohnungshäuser des Geschosswohnungsbaus, deren Höhe unter 22 m liegt, in die Gruppe der freistehenden Mehrfamilienhäuser (Müller & Korda, 1999). Die Gebäude sind in festen Baufluchten angeordnet und bilden eine offene, meist regelmäßige Blockbauweise, sofern sie eine Gebäudelänge von 50 m nicht überschreiten (Baunutzungsverordnung).

Villa (MFH-VI)
Villen sind hochwertige, freistehende Mehrfamilienhäuser. Hierzu zählen auch Herrenhäuser und kleine Schlösser. Villen sind durch eine gegenüber dem Typ *MFH-F* größere Gebäudegrundfläche gekennzeichnet und bilden eine offene aufgelockerte Struktur. Villen besitzen einen größeren Abstand zur Straße, wobei deren Fluchtabstand unregelmäßig ist. Der hohe Freiraumanteil in der Umgebung ist durch die großen Grundstücke begründet. Villen können bis zu 4 Vollgeschosse und bis zu 8 Wohnungen besitzen. Den Villen kann keine charakteristische Baualtersklasse zugeordnet werden.

Freistehendes Mehrfamilienhaus als Hochhaus (MFH-HH)
Freistehende Einzelgebäude mit einer großen Höhe und Anzahl an Wohnungen werden als Hochhäuser (auch Punkthäuser) bezeichnet. In der Landesbauordnung werden Gebäude nach ihrer Höhe in Gebäude mit geringer, mittlerer und großer Höhe differenziert und Gefahrenklassen für den Brandschutz zugeordnet. Man spricht von Hochhäusern, wenn der Fußboden mindestens eines Aufenthaltsraumes mehr als 22 m über der Geländeoberfläche liegt (MBO, 2002; MHHR, 2008). Für Hochhäuser im Geschosswohnungsbau gilt i. d. R. eine Grenze von 8 oberirdischen Geschossen, wie es etwa die Modellvorschrift des ATKIS® Basis-DLM vorsieht (AdV, 2008c). Bei den Hochhäusern sind Vielspänner dominant.

Mehrfamilienhaus in traditioneller/teilindustrieller Zeilenbauweise (MFH-TZ)
Unter dieser Klasse ist die Zeilenbebauung der Zwischenkriegszeit (1919 und 1930er Jahre) bzw. der Nachkriegszeit (1945 bis 1968) zu verstehen. Die Konstruktion der Zeilenbebauung der 1920 und 1930er Jahre erfolgte vorwiegend in traditioneller Ziegelbauweise und nach dem Krieg dann durch teilindustrielle Fertigung. Die länglichen Häuserzeilen sind parallel zueinander aufgereiht und sind zur Sicherung der Belichtung in Ost-West-Richtung ausgerichtet. Die Freiraumstruktur ist durch große zusammenhängende Freiflächen gekennzeichnet. Diese Mehrfamilienhäuser besitzen bis zu 6 Geschosse.

Mehrfamilienhaus in Plattenbauweise (MFH-IZ)
Mehrfamilienhäuser in Plattenbauweise sind industriell gefertigte Gebäude des Geschosswohnungsbaus. Sie sind durch mehrere aneinandergereihte Gebäude in offener oder halboffener Zeilenbauweise mit 3 bis maximal 14 Geschossen gekennzeichnet. Die Bebauung ist Ergebnis von Großwohnprogrammen der 1970er Jahre und dementsprechend überwiegend den Baualtersklassen zwischen 1965 und 1990 zuzuordnen.

Mehrfamilienhaus in geschlossener Bauweise (MFH-G)
Unter dieser Kategorie werden Mehrfamilienhäuser in typischer geschlossener Blockbebauung der Gründerzeit mit Baujahren von 1870 bis 1945 verstanden. In Ostdeutschland wurden ab Ende der 1970er Jahre und in den 1980er Jahren die ehemaligen Baulücken durch Neubauten geschlossen bzw. teilweise abgerissen. In den alten Bundesländern erfolgte der Wiederaufbau direkt nach dem Krieg. Gebäude dieser Bebauungsform besitzen im Stadtzentrum häufig einliegendes Gewerbe.

Mehrfamilienhaus im historischen Ortskern (MFH-H)
Zu dieser Kategorie gehört die innerstädtische zentrumsbildende Reihenhausbebauung der Baujahre vor 1918. Die Gebäude werden in Blockrandlage straßenbegleitend aneinandergereiht. Das Straßennetz und die Gebäudeanordnung werden im Wesentlichen von früheren Stadtmauern und der Geländetopographie bestimmt, was zu unregelmäßigen Strukturen führt. Die Gebäude einer Reihe sind durch unterschiedliche Traufhöhen und individueller Fassadengestaltung gekennzeichnet, wobei in der Regel die Geschosszahl mit der Nähe zur Kirche zunimmt. Die Geschossanzahl dieser Bebauungsform reicht von 1-4 Vollgeschossen und die Gebäudetiefe ist ab 2 Geschossen oft größer als die Breite, sonst umgekehrt (Beutel et al., 1989). In Gebäuden bedeutender historischer Ortskerne sind häufig Gewerbe und andere Nutzungen (z. B. für den Tourismus) eingelagert (Luftbildinterpretation).

Ländliche Hausformen (LH)
Zu den Gebäuden in dörflicher Struktur zählen ländliche Hausformen, wie etwa Wohnstallhäuser, Bauernhäuser, Gehöfte und Gutshäuser. Die Gebäude sind meist in unregelmäßiger Struktur angeordnet. Dörfliche Gebäude sind durch die Landwirtschaft geprägt und können einen größeren Anteil an Nichtwohnnutzung besitzen. Den Gebäuden in dörflicher Struktur kann die Baualtersklasse vor 1918 zugeordnet werden. Es ist jedoch zu beachten, dass es hinsichtlich der Gebäudestruktur regionaltypische Hausformen gibt. In Nord- und Süddeutschland dominieren Einhaustypen, wie z. B. das Groninger Gulfhaus oder das Niederdeutsche Hallenhaus. Der mitteldeutsche Raum ist durch Gehöfte wie Haken- und Dreiseitgehöfte geprägt. Zur Verbreitung und Typisierung bäuerlicher Haus- und Gehöftformen sei an dieser Stelle auf Borsdorf & Bender (2010) verwiesen.

Gebäude für Wirtschaft, Gewerbe und Landwirtschaft (WGL)
Prägendes Merkmal dieser Gebäude ist die überwiegende gewerbliche, industrielle und landwirtschaftliche Nutzung. Hierzu zählen sämtliche Hallen- und Lagergebäude von Produktionsstätten, Bürogebäude, Gebäude für Handel, Einzelhandel und Großhandel, Hotels und Gebäude für das Gaststättengewerbe sowie Landwirtschaftliche Gebäude, wie Scheunen, Ställe oder Silogebäude. Zu dieser Gruppe werden auch sämtliche Verkehrsgebäude gezählt, wie beispielsweise Betriebsgebäude für den Bahn- oder Flugverkehr.

Öffentliche Gebäude (ÖG)
Öffentliche Gebäude sind Gebäude mit gemeinnütziger Funktion, wie etwa Gebäude für Verwaltung (Rathaus, Ortsamt), Gesundheit und Soziales (z. B. Krankenhaus), für Bildung und Forschung (z. B. Schulen, Universitäten), für Kultur (z. B. Theater, Kino, Kirche), für Sicherheit und Ordnung (z. B. Haftanstalt), aber auch für Funktionen, die beispielsweise der Erholung dienen (z. B. Ferienhäuser und -wohnungen).

Nebengebäude (NG)
Nebengebäude sind Gebäude mit einer geringen Grundrißfläche, die nicht der Wohnnutzung dienen und gegenüber dem Verwendungszweck des Hauptgebäudes eine untergeordnete Rolle spielen. Zu den wichtigsten Nebengebäuden zählen Garagen, Schuppen, Gerätehütten oder Gartenhäuser. Nebengebäude sind eingeschossig und besitzen in der Regel eine geringe Traufhöhe (kleiner als 3 bis 4 Meter), die im Bebauungsplan festgelegt ist. Neben

den freistehenden Nebengebäuden zählen auch Anbauten, wie etwa Windfänger, Treppenaufgänge, Wintergärten oder Veranden zu den Nebengebäuden.

B.2. Kenngrößen und Baualtersklassen der Gebäudetypen

Die definierten Gebäudetypen sind durch charakteristische städtebauliche Kenngrößen gekennzeichnet. Dazu zählt beispielsweise die Netto-Geschossflächendichte, die das Verhältnis der Geschossflächensumme zur Grundstücksfläche (Nettowohnbauland) beschreibt. Eine andere Größe ist die Nettowohndichte, die sich aus dem Quotient Einwohner pro Hektar Nettowohnbauland ergibt. Diese zwei Kenngrößen sind in Tab. B-1 für jeden Gebäudetyp dargestellt.

Tab. B-1: Typische Kenngrößen der Gebäudetypen

Gebäudetyp		Kenngrößen des Städtebaus		Überwiegendes bauliches Alter	
Akronym	Bezeichnung	Geschoss-flächendichte*	Nettowohndichte* [1/ha]	Alte Bundesländer	Neue Bundesländer
EFZH-EH	Freistehendes Ein- und Zweifamilienhaus	0,1 - 0,4	30 - 75	ab 1919	ab 1919
EFZH-DH	Ein- und Zweifamilienhaus als Doppelhaus	0,2 - 0,5	k.A.	ab 1919	ab 1919
EZFH-RH	Ein- und Zweifamilienhaus als Reihenhaus	0,4 - 0,8	150 - 200	ab 1919	ab 1919
MFH-HH	Freistehendes Mehrfamilienhaus als Hochhaus	k.A.	240 - 380	1969 - 1990	1969 - 1990
MFH-F	Freistehendes Mehrfamilienhaus in offener Bauweise	0,5 - 1,8	100 - 120	ab 1870	1870-1945, ab 1990
MFH-TZ	Mehrfamilienhaus in traditioneller/teilindustrieller Zeilenbauweise	0,5 - 1,3	200 - 330	1919 - 1945, 1949 - 1990	1919 - 1945, 1949 - 1968
MFH-IZ	Mehrfamilienhaus in Plattenbauweise	0,8 - 2,5	180 - 330	1969-1982	1969 - 1982
MFH-G	Mehrfamilienhaus in geschlossener Bauweise	1,2 - 3,5	200 - 330	1870 - 1945, nach 1982**	1870 - 1945, nach 1990**
MFH-H	Mehrfamilienhaus im historischen Ortskern	k.A.	k.A.	bis 1918	bis 1918
MFH-VI	Villa	k.A.	k.A.	k.A.	k.A.
LH	Ländliche Hausformen	0,1 - 0,5	20 - 60	bis 1918	bis 1918
WGL, ÖG, NG	Nichtwohnnutzung	-	-	k.A.	k.A.

* Geschossflächendichte und Nettowohndichte aus Müller (1979), Buchert et al. (2004) und Meinel et al. (2008)

** Rekonstruktion der Innenstadt

Bei einer energetischen Betrachtung spielt auch das Baualter eine wichtige Rolle. Den Gebäudetypen können charakteristische Baualtersklassen zugeordnet werden, da deren Morphologie durch Baustile bestimmter Epochen geprägt ist. Gebäudetypische Baualtersgruppen konnten auf Grundlage einer Literaturauswertung (Buchert et al., 2004) und einem IÖR-internen Expertenworkshop[98] erarbeitet werden. Die zugeordneten Baualtersklassen orientieren sich an den klassischen Schnittstellen der Verfassungs- und Gebietsänderungen im staatlichen System und den Zeitpunkten statistischer Vollerhebungen (1918/19 Gründung der Weimarer Republik, 1948/49 Gründung der BRD, 1968 Gebäude- und Wohnungszählung, 1978 Wohnungsstichprobe, 1990 Wiedervereinigung). Die Zuordnung erfolgte differenziert nach alten und neuen Bundesländern. Für genauere Analysen einzelner Städte wäre an dieser Stelle eine räumlich differenziertere Betrachtung denkbar, in dem regionalisierte gebäudetypische Annahmen zum Baualter gemacht werden. Hierzu wären jedoch umfangreiche Auswertungen auf Grundlage amtlicher statistischer Daten nötig.

[98] IÖR-interner Experten-Workshop „Bebauungsstrukturen“ am 17.5.2010 in Dresden

C Merkmale

C.1. Übersicht zu den Merkmalen

Im Folgenden werden die einzelnen Merkmale und deren Umsetzung gemäß der Typisierung (geometrische, topologische, statistische sowie semantische und physikalische Merkmale) vorgestellt. Die Kennzeichnung G (Grundmerkmale), E (Einzelgebäudemerkmale) und S (Spezielle Merkmale) macht deutlich, welcher Merkmalskategorie das Merkmal angehört und für welchen Eingangsdatentyp es berechnet werden kann.

Geometrische Merkmale

Größen-, Form- und Orientierungsmerkmale sind wichtigste Eigenschaften zur Beschreibung der Morphologie einer Gebäuderegion bzw. eines Einzelgebäudes (Tab. C-1).

Tab. C-1: Geometrische Merkmale

Geometrische Merkmale		Typ
Größe	AREAH : Flächeninhalt der Gebäuderegion (Gebäudegröße) in m²	G
	PERI: Länge der Kontourlinie der Gebäuderegion in m	G
	MAXWIDTH: Durchmesser des größten einschreibenden Kreises (Maximale Gebäudebreite) in m	G
	MAXDIAM: Durchmesser des kleinsten umschreibenden Kreises (Gebäudeausdehnung) in m	G
	RECTLENG: Länge des umschließenden Rechteckes (Gebäudelänge) in m	G
	RECTWID: Breite des umschließenden Rechteckes (Gebäudebreite) in m	G
	RA: Länge der Hauptachse der umschließenden Ellipse in m	G
	RB: Länge der Nebenachse der umschließenden Ellipse in m	G
	AREABLOCK: Fläche des Baublocks in m²	G
	MINBLDIST: Minimaler Gebäudeabstand zur Blockgrenze in m	G
	MAXBLDIST: Maximaler Gebäudeabstand zur Blockgrenze in m	G
	MINSOD: Minimaler Abstand zum nächsten ähnlichen Gebäude in m	G
	MINBUDIST: Minimaler Gebäudeabstand zum nächsten Nachbarn in m	G
	PCLLENGTH: Länge der Hauptgebäudelinie (Gebäudemittellinie der Skeleton) in m	G
	SUMCLLENG: Summe aller Gebäudemittellinien (Skeleton incl. Verzweigungen) in m	G
	DISTENDP: Abstand zwischen den Endpunkten der Gebäudemittellinie in m	G
	DISTNBOB: Minimaler Abstand zum nächstgelegenen Gebäude im Nachbarblock in m	G
	GBDIST: Minimale Distanz der Gebäudemittelpunkte von zeilenförmigen Gebäuden in m	G
	BLXY: Existenz eines ähnlichen Gebäudes im Nachbarblock im Suchradius	G
	MINBLXY: Minimaler Abstand eines Gebäudes zum nächsten Gebäude im Nachbarblock in m	G
	SHAPE_Area: Fläche des Einzelgebäudes in m²	E
	SHAPE_Length: Umfang des Einzelgebäudes in m	E
Form	AREARECT: Fläche des umschreibenden Rechtecks in m²	G
	UFE: Umfang-Flächenverhältnis	G
	RATIOAREA: Flächenverhältnis der Gebäudefläche/Fläche des umschließenden Rechteckes	G
	CONVEX: Formkonvexität (Convexity), Verhältnis der Gebäudegrundfläche zur Fläche der konvexen Hülle	G
	CIRCULAR: Kreisähnlichkeit (Circularity)	G
	COMPACT2: Kompaktheitsgrad	G
	PIXDIST: Mittlere Distanz der Kontourpunkte zum Flächenschwerpunkt	G

Fortführung von Tab. C-1

Geometrische Merkmale		Typ
Form	RECTRATIO: Längen-/Breiten-Verhältnis des umschließenden Rechtecks	G
	GRSPCREL: Gebäudebezogener Formindikator	G
	SCHUMM: Verhältnis des Durchmessers des Kreises mit derselben Fläche zu dem Durchmesser des kleinsten umschreibenden Kreises	G
	SHAPER: Shapeindex der Gebäuderegion	G
	FRACTR: Fraktale Dimension der Kontourlinie	G
Orientierung	DIRECT: Orientierung der Gebäudehauptachse von 0° (West-Ost-Richtung) bis 90° (Nord-Süd-Richtung)	G
	ANGBUILD: Orientierung der Gebäudehauptachse von 0° bis 180°	G
	ANGLPCL: Orientierung des längsten Teils der Hauptgebäudelinie von 0° bis 180°	G
	RELBUAN: Absolute Winkeldifferenz zwischen der Hauptrichtung des Gebäudes und dem Baublock	G
	CDIRECT: Absolute Orientierung des längsten Teils der Hauptgebäudelinie von 0° bis 180° (Bogenmaß)	G
	CDIR90: Absolute Orientierung des längsten Teils der Hauptgebäudelinie von 0° bis 180° (Bogenmaß)	G
	SUMANGLE: Summe der Richtungswinkel der generalisierten Gebäuderegionhauptlinie	G
	w_SUMANGLE: Summe der Richtungswinkel der generalisierten Gebäuderegionhauptlinie	E

Topologische Merkmale

Topologische Merkmale beschreiben die Struktur einer Geometrie oder Beziehungen zwischen Objekten. Das Merkmal PATIO beschreibt beispielsweise die Topologie einer Gebäuderegion und gibt die Anzahl der Löcher des Gebäudepolygons an. Dessen Nutzung erscheint darum sinnvoll, da eine geschlossene Blockrandbebauung häufig durch ein Ringpolygon mit einem oder mehreren Löchern gekennzeichnet ist. Die Merkmale SEGNO, NUALLJUNC und NUPCLJUNC beziehen sich hingegen auf die Gebäudehauptlinie, die über eine Extraktion der Skelettlinie abgeleitet werden kann. Die Anzahl benachbarter Polygone im Gebäudekomplex (SUM_AnzPo) ergibt sich aus einer topologischen Nachbarschaftsbeziehung der Gebäudegrundrisspolygone (Tab. C-2).

Tab. C-2: Topologische Merkmale

Topologische Merkmale		Typ
Topologische Struktur	PATIO: Anzahl der Löcher in Gebäuderegion	G
	NUALLJUNC: Anzahl der Verzweigungspunkte (Gebäudeflügelanzahl)	G
	NUPCLJUNC: Anzahl der Verzweigungspunkte entlang der Hauptlinie	G
	(w_)SEGNO: Anzahl der Segmente der generalisierten Gebäudehauptlinie	G
	(w_)SUM_AnzPo: Anzahl aller benachbarten Einzelgebäude mit gemeinsamer Kante	E
Topologische Beziehungen	HK_ANZ: Anzahl der Hauskoordinaten pro Einzelgebäude	Z
	(w_)VHK_ANZ: Anzahl der Hauskoordinaten pro Gebäuderegion	Z

Statistische und Dichtemerkmale

Statistische und Dichtemerkmale dienen insbesondere der Beschreibung des Kontextes auf Meso-Ebene, wie beispielsweise dem mittleren Gebäudeabstand in einem 100 m-Suchradius oder der mittleren Ausrichtung der Gebäude im Baublock. Statistische Merkmale spielen aber auch eine Rolle bei der Charakterisierung der Geometrie auf Mikroebene, wie z. B. mit dem Merkmal MEANGRDIS, das sich auf alle einschreibenden Kreise einer Region bezieht und durch Mittelwertbildung die mittlere Breite einer Gebäuderegion beschreibt (Tab. C-3).

Tab. C-3: Statistische und Dichtemerkmale

Statistische und Dichtemerkmale		Typ
Statistische Kenngrößen	SUMABUBL: Summe der Gebäudefläche im Block	G
	MEANBUDIS: Mittlerer Gebäudeabstand im 100 m-Puffer	G
	NUBUILDBU: Anzahl der Gebäude im 100 m-Puffer	G
	MSOD_MEAN: Mittlerer Abstand zu ähnlichen Gebäuden im Block	G
	MEANGRDIS: Mittlerer Abstand der Konturpunkte zur Gebäudehauptlinie (Skellettlinie)	G
	MEDGRDIS: Median der Gebäudebreiten entlang der Hauptlinie	G
	DEVGRDIS: Standardabweichung der Gebäudebreiten entlang der Hauptlinie	G
	DEVREL: Prozentuale Standardabweichung der Gebäudebreite von der mittleren Gebäudebreite	G
	MINGRDIS: Minimale Gebäudebreite entlang der Hauptlinie	G
	MAXGRDIS: Maximale Gebäudebreite entlang der Hauptlinie	G
	MEAN-PCLLENGHT: Mittlere Gebäudelänge im Block aller zeilenförmigen Gebäude	G
	CMEAN: Mittlere Ausrichtung des Gebäudes im Block (Grundlage CDIRECT)	G
	CV: Varianz der Orientierung (Circular Variance) des Gebäudes im Block (Grundlage CDIRECT)	G
	CMEAN90: Mittlere Ausrichtung des Gebäudes im Block (Grundlage CDIR90)	G
	CV90: Varianz der Orientierung (Circular Variance) des Gebäudes im Block (Grundlage CDIR90)	G
	MEAN_AREAH: Mittlerer Flächeninhalt der Gebäude im Block	G
	STD_AREAH: Standardabweichung der Gebäudegrößen im Block	E
	(w_)MEAN_PCLLE: Mittlere Länge der Hauptgebäudelinien im Block	G/E
	STD_PCLLEN: Standardabweichung der Hauptgebäudelinienlänge im Block	G
	(w_)SUM_AREA: Summe der Flächen aller Gebäudeteile eines Gebäudeverbunds (=AREAH)	E
	(w_)MIN_AREA: Minimale Fläche aller Gebäudeteile eines Gebäudeverbunds	E
	(w_)MAX_AREA: Maximale Fläche aller Gebäudeteile einer Gebäuderegion	E
	NUBUILDBL: Anzahl von Gebäuderegionen im Baublock	G
	NBPBA: Normalisierte Anzahl der Gebäuderegionen pro Blockfläche (Gebäudedichte)	G
	(w_)STD_AREA: Standardabweichung der Einzelgebäudefläche pro Gebäudekomplex	E
Dichten und Anteile	ARDENBU: Überbauungsgrad im Suchradius von 100 m	G
	BLARERAT: Blockbezogener Gebäudeflächenanteil	G
	LOC_PERC: Anteil der Gebäudefläche mit mehr als 30 m Abstand zur Blockgrenze	G
	S1AREA1: Flächenanteil sehr kleiner Grundrisse im Baublock (vgl. Meinel et al., 2008)	G
	S1AREA2: Flächenanteil kleiner Grundrisse im Baublock (vgl. Meinel et al., 2008)	G
	S1AREA3: Flächenanteil zeilenförmiger Grundrisse im Baublock (vgl. Meinel et al., 2008)	G
	S1AREA4: Flächenanteil großer Grundrisse im Baublock (vgl. Meinel et al., 2008)	G
	S1NUMB1: Anteil sehr kleiner Grundrisse im Baublock (Anzahl)	G
	S1NUMB2: Anteil kleiner Grundrisse im Baublock (Anzahl)	G
	S1NUMB3: Anteil zeilenförmiger Grundrisse im Baublock (Anzahl)	G
	S1NUMB4: Anteil großer Grundrisse im Baublock (Anzahl)	G

Semantische und weitere Merkmale

Informationen, die in den Eingangsdaten über ein Attribut explizit vorliegen, können als semantische Information übernommen werden (Tab. C-4). Dazu zählt beispielsweise das Attribut zur Gebäudefunktion „NUTZUNG“, das für Gebäudegrundrisse aus ALK, ALKIS® oder den 3D-Gebäudestrukturen (Eingangsdatentyp III) zur Verfügung steht. In dieser Arbeit werden jedoch nur die Nutzungsartengruppen berücksichtigt, die von der AdV als Grunddatenbestand festgelegt sind und bundesweit geführt werden. Das sind die Obergruppen „Wohngebäude“ (NUTZUNG = 1000), Gebäude für Wirtschaft oder Gewerbe (NUTZUNG = 2000) und Gebäude für öffentliche Zwecke (NUTZUNG = 3000). Für die aus topographischen Karten extrahierten Gebäude liegt keine Nutzungsinformation vor. Ein weiteres semantisches Merkmal ist die Objektart OBJART der Baublockgeometrie aus dem ATKIS® Basis-DLM, das als Merkmal ATKIS_OBJ geführt wird und mit denen 4 Nutzungsarten im bebauten Siedlungsbereich unterschieden werden. Gebäude mit einer Höhe > 50 m (Hochhäuser) sind in der DTK25-V mit einer speziellen umschließenden Liniensignatur versehen. Diese Information lässt sich mithilfe eines Bildverarbeitungsprozesses gewinnen und in Form eines Merkmals HR explizit machen. Da dieses Merkmal nur für deutsche topographische Karten abgeleitet werden kann, wurde es in die Kategorie der speziellen Merkmale aufgenommen.

Tab. C-4: Semantische und weitere Merkmale

Semantische und weitere Merkmale		Typ
Nutzung	ATKIS_OBJ: Blockbezogene ATKIS®-Objektart	G
	GEBNUTZ: entnommen aus Nutzungsattribut (ALKIS®/ATKIS®)	S
	GEB_TYP: Haupt oder Nebengebäude	S
weitere	HR: Wahrscheinlichkeit einer Hochhaussignatur in TK25 (Merkmal für die Erkennung von Hochhäusern in topographischen Karten)	S
	GEB_HOEHE: Gebäudehöhe (z. B. aus 3D-Gebäudemodell)	S

C.2. Verteilungsdichte der Merkmale

Die folgenden Plots zeigen die Dichteverteilung der Merkmalswerte am Beispiel der Daten von Halle (ATKIS-Gebäude). Die Merkmale wurden über den Mittelwert normalisiert.

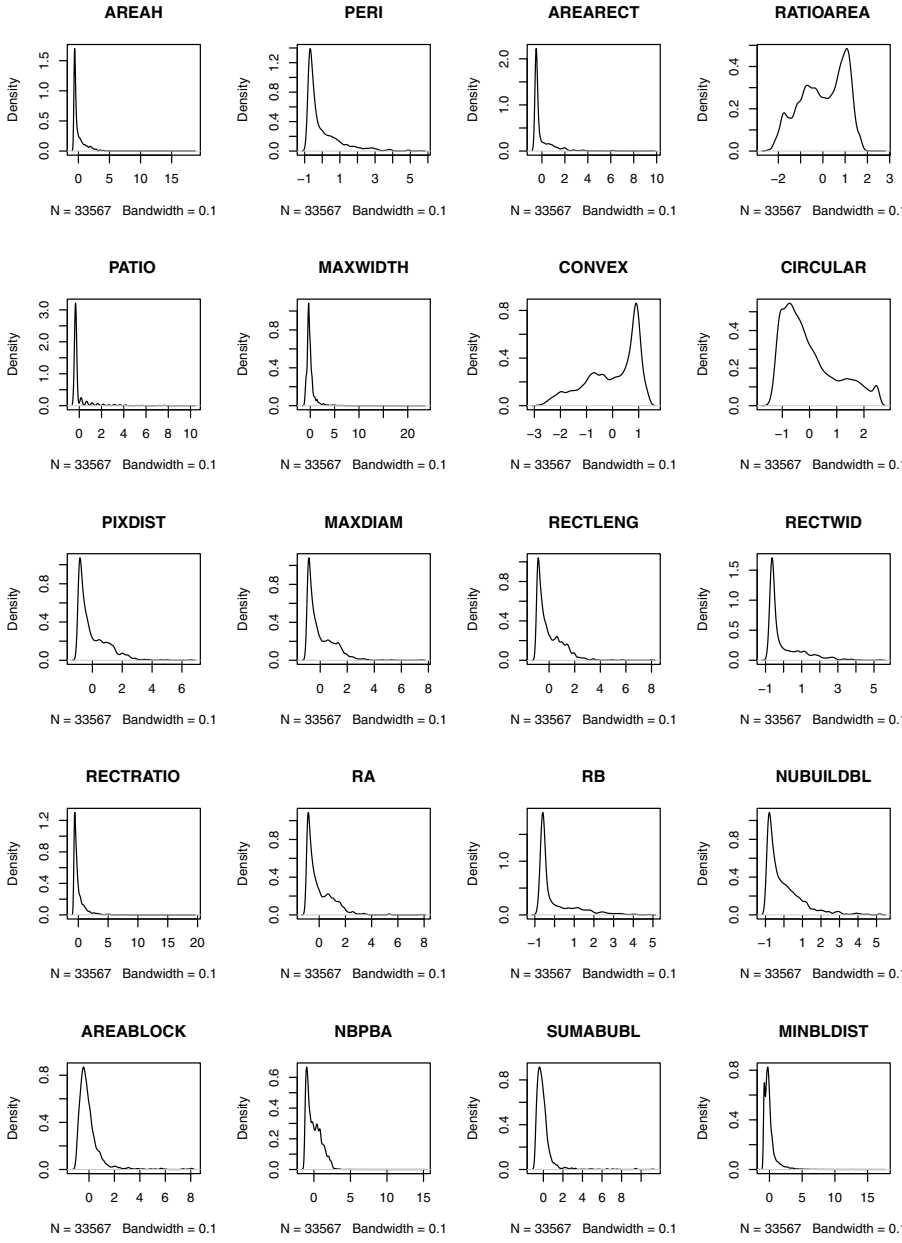

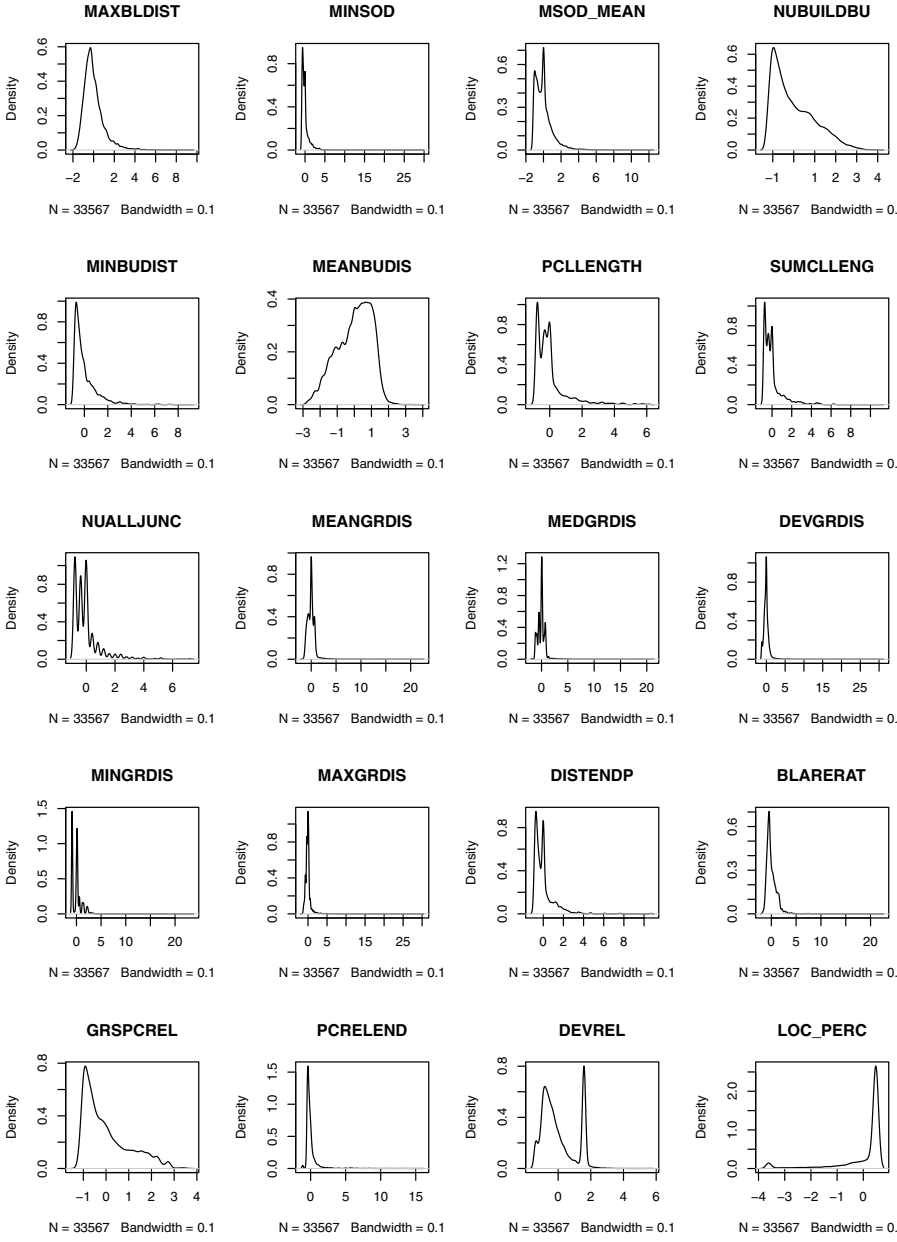
MAXBLDIST
MINSOD
MSOD_MEAN
NUBUILDBU
MINBUDIST
MEANBUDIS
PCLLENGTH
SUMCLLENG
NUALLJUNC
MEANGRDIS
MEDGRDIS
DEVGRDIS
MINGRDIS
MAXGRDIS
DISTENDP
BLARERAT
GRSPCREL
PCRELEND
DEVREL
LOC_PERC
Density
N = 33567 Bandwidth = 0.1

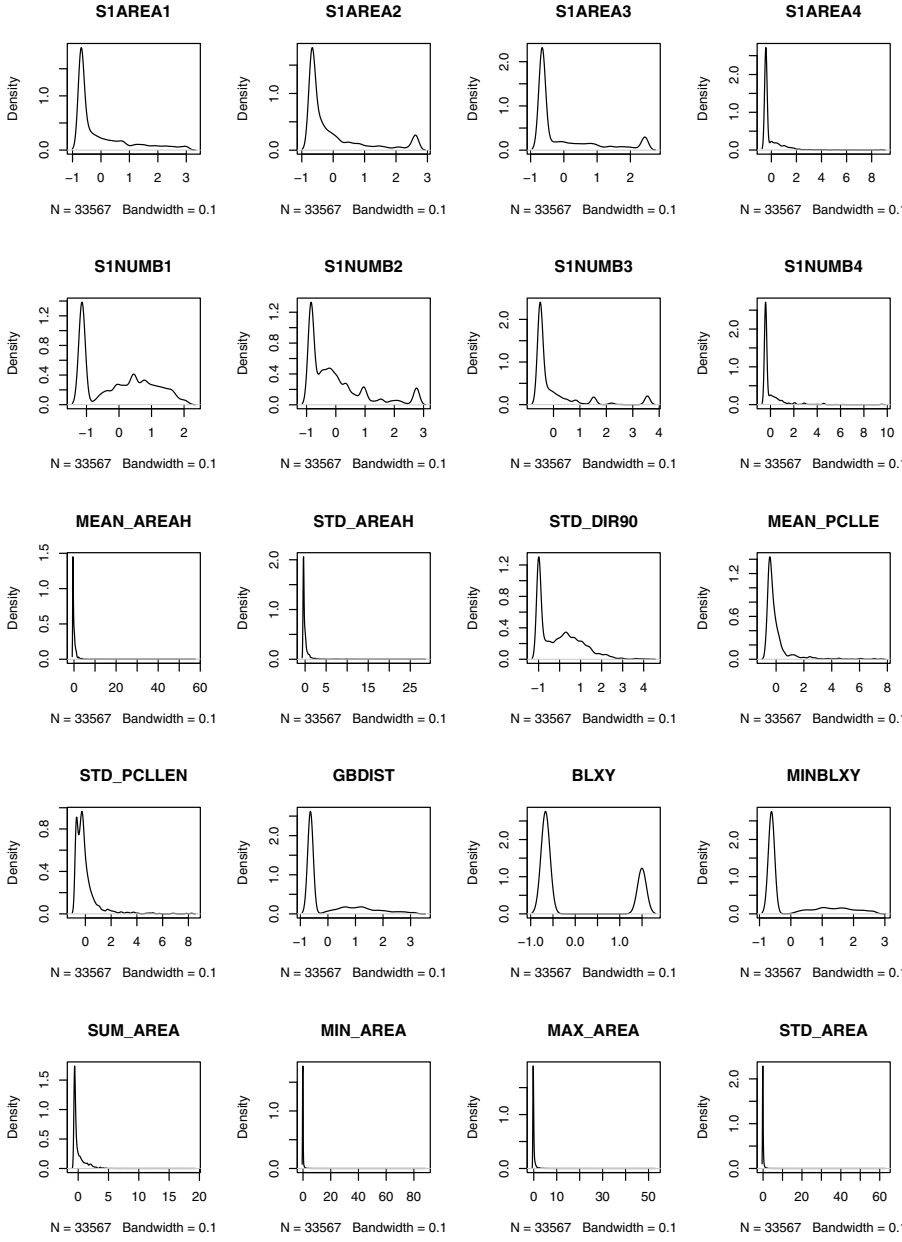
S1AREA1
S1AREA2
S1AREA3
S1AREA4
S1NUMB1
S1NUMB2
S1NUMB3
S1NUMB4
MEAN_AREAH
STD_AREAH
STD_DIR90
MEAN_PCLLE
STD_PCLLEN
GBDIST
BLXY
MINBLXY
SUM_AREA
MIN_AREA
MAX_AREA
STD_AREA
Density
N = 33567 Bandwidth = 0.1

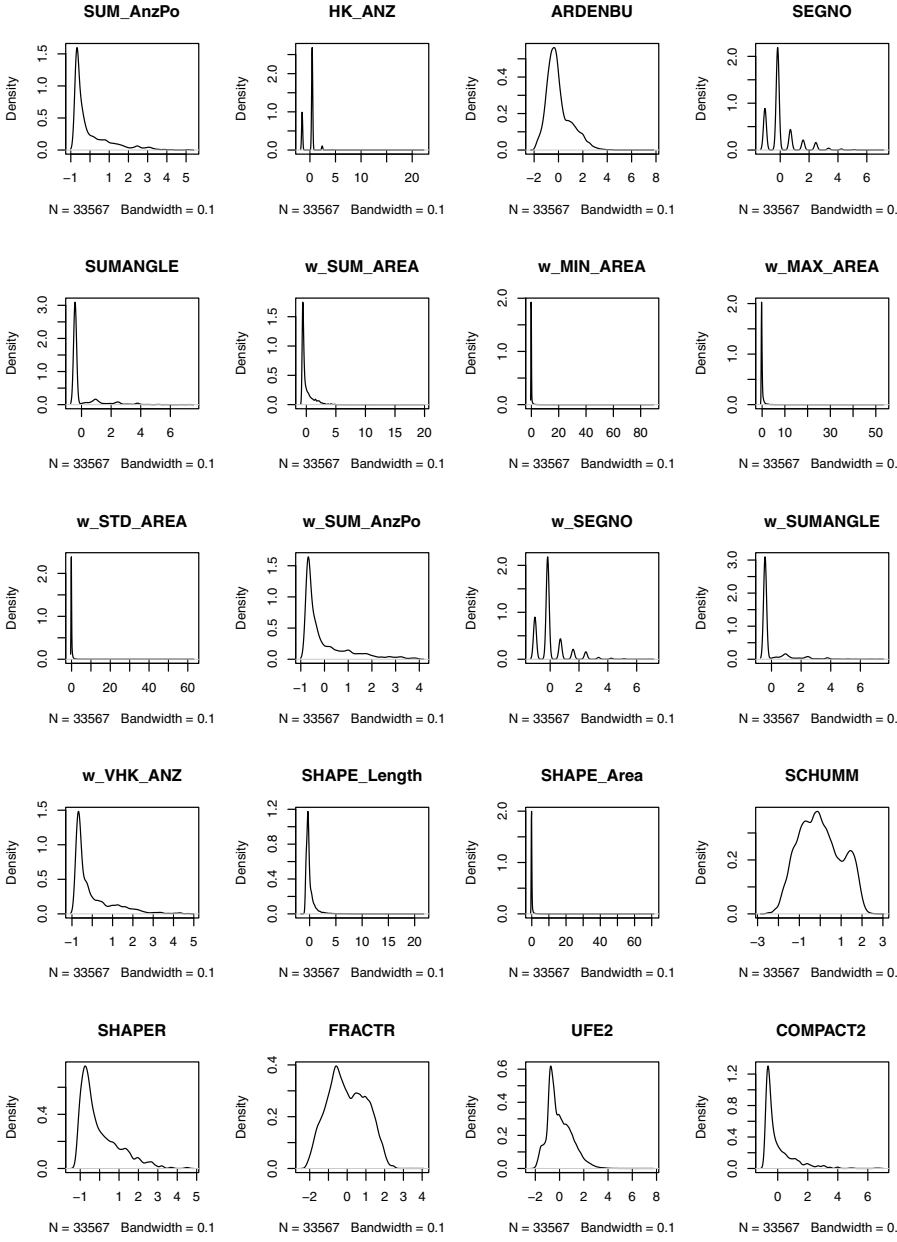
SUM_AnzPo
HK_ANZ
ARDENBU
SEGNO
SUMANGLE
w_SUM_AREA
w_MIN_AREA
w_MAX_AREA
w_STD_AREA
w_SUM_AnzPo
w_SEGNO
w_SUMANGLE
w_VHK_ANZ
SHAPE_Length
SHAPE_Area
SCHUMM
SHAPER
FRACTR
UFE2
COMPACT2
Density
N = 33567 Bandwidth = 0.1

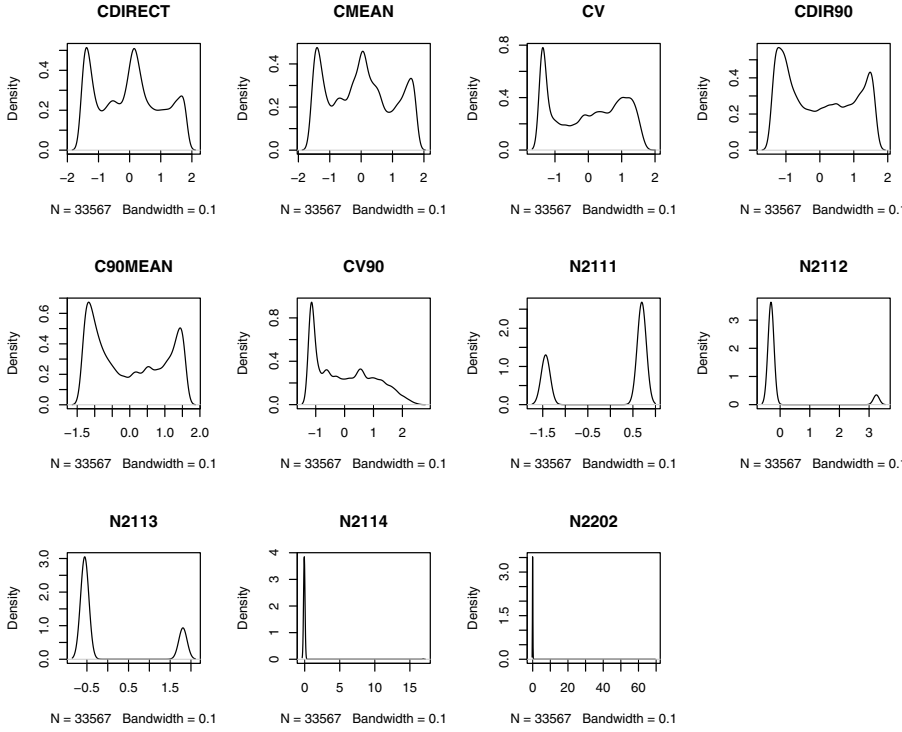
CDIRECT
CMEAN
CV
CDIR90
C90MEAN
CV90
N2111
N2112
N2113
N2114
N2202
Density
N = 33567 Bandwidth = 0.1

C.3. Merkmalsreduktion

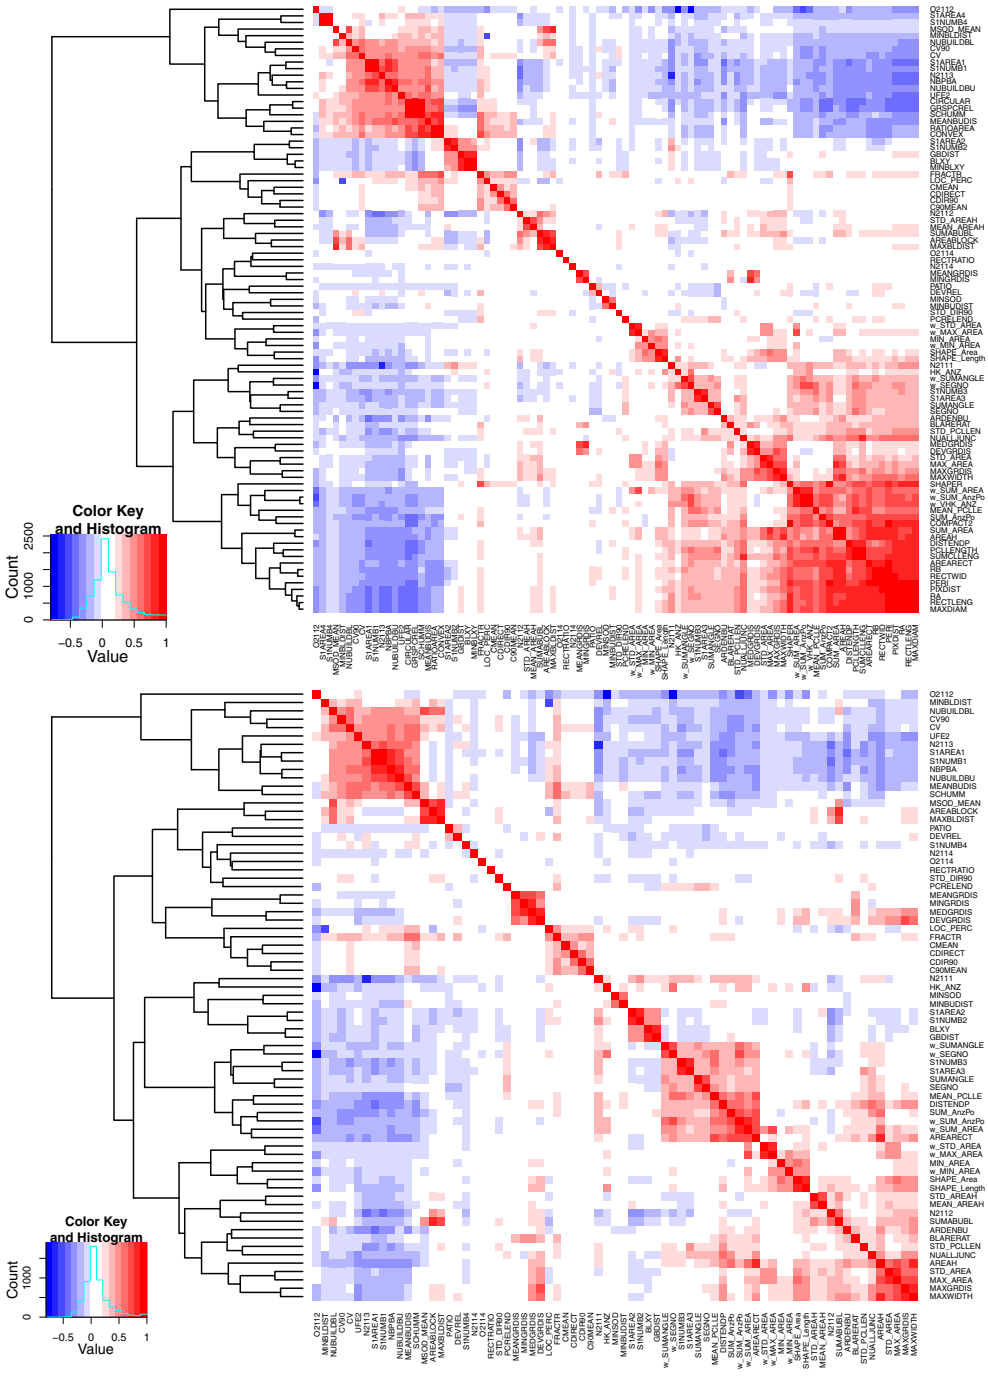

Abb. C-1: Visualisierte Korrelationsmatrix vor (oben) und nach (unten) der Merkmalsreduktion am Beispiel vom Datensatz Dresden (ALK)

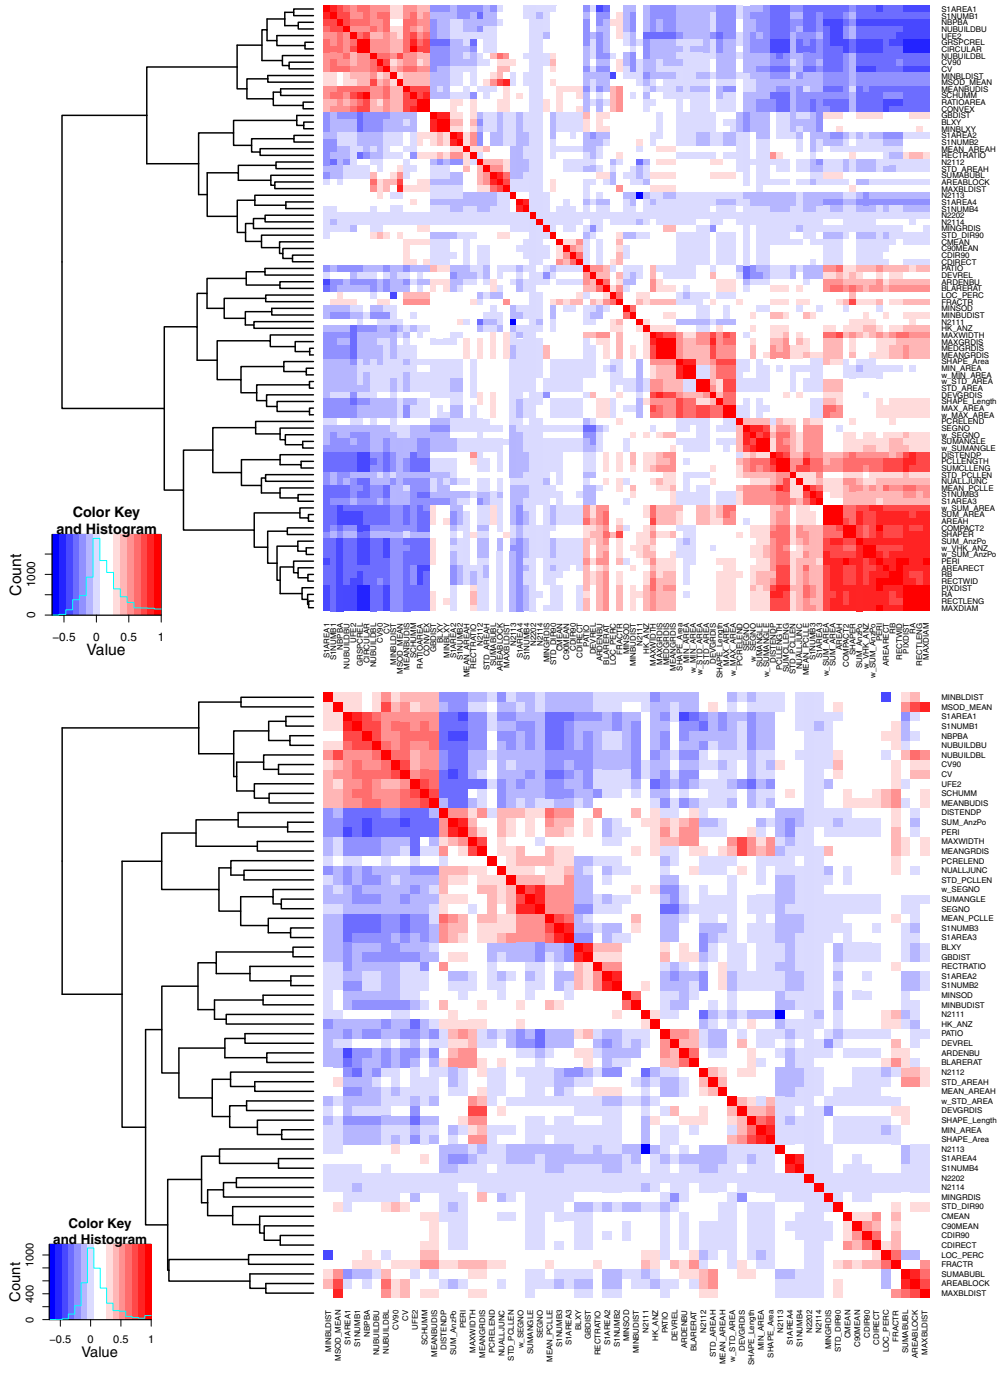

Abb. C-2: Visualisierte Korrelationsmatrix vor (oben) und nach (unten) der Merkmalsreduktion am Beispiel vom Datensatz Halle (Gebäude aus ATKIS® Basis-DLM)

C.4. Merkmalswichtigkeit mit Random Forest

Die folgenden Abbildungen zeigen die mittels Random Forest gemessene Merkmalswichtigkeit (engl. *Permutation importance*) für verschiedene Eingangsdatentypen.

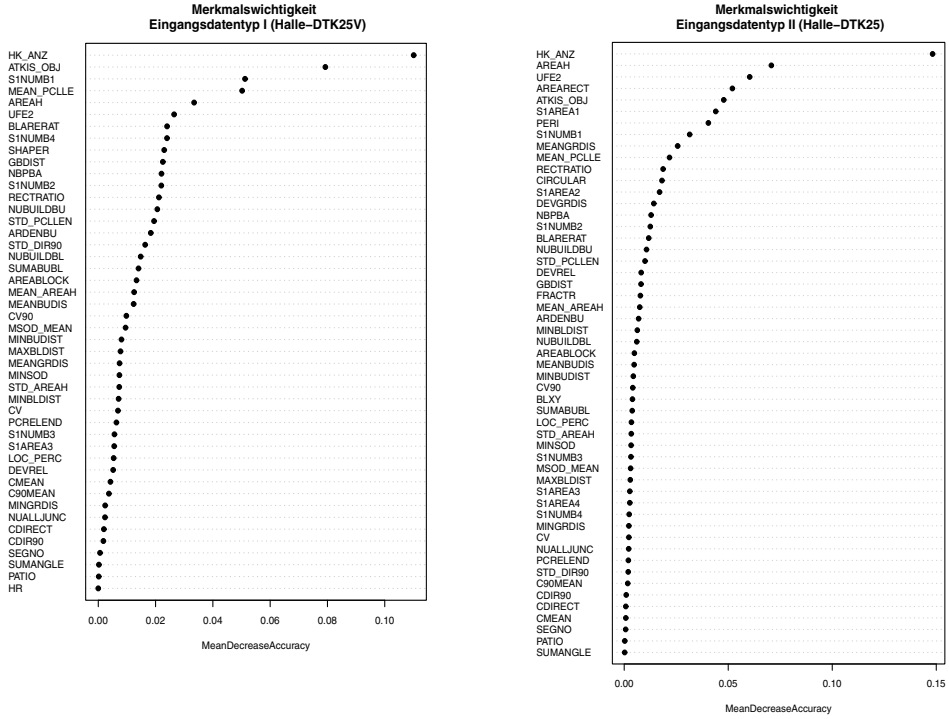

Abb. C-3: Merkmalswichtigkeit am Beispiel der Datensätze von Halle (DTK25-V und DTK25)

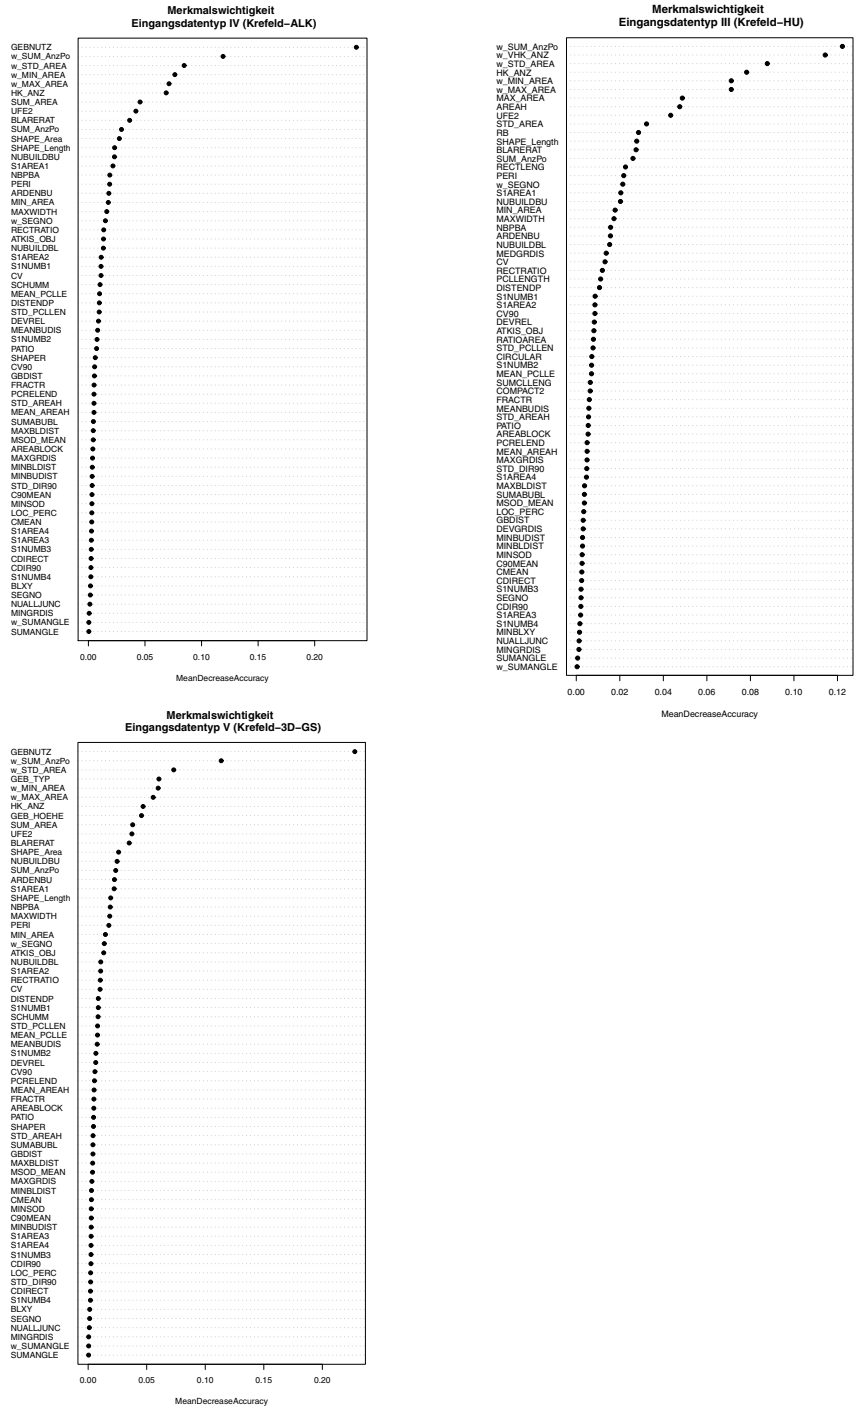

Abb. C-4: Merkmalswichtigkeit am Beispiel der Datensätze von Krefeld (HU, ALK und 3D-GS)

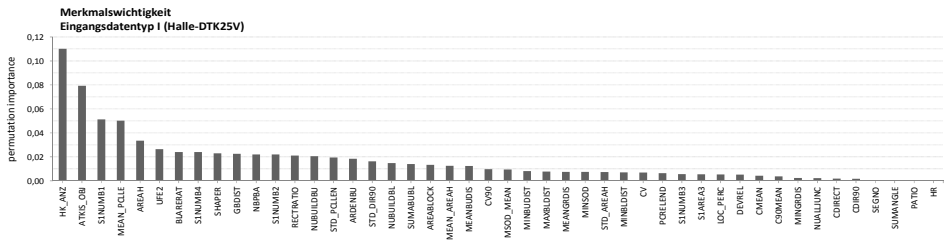

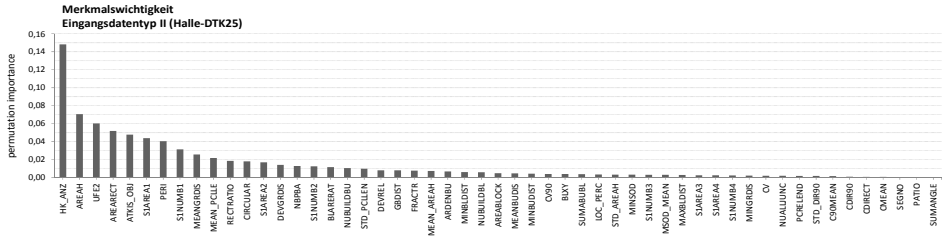

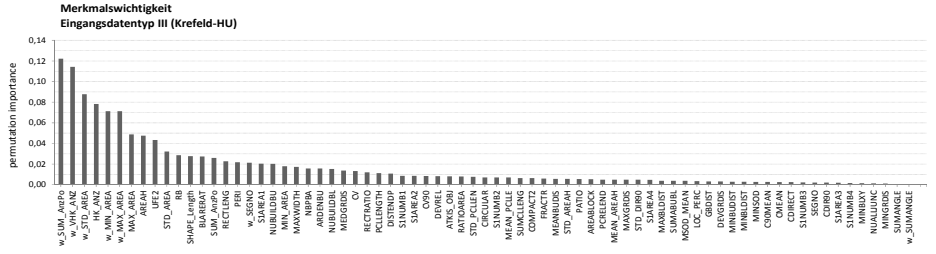

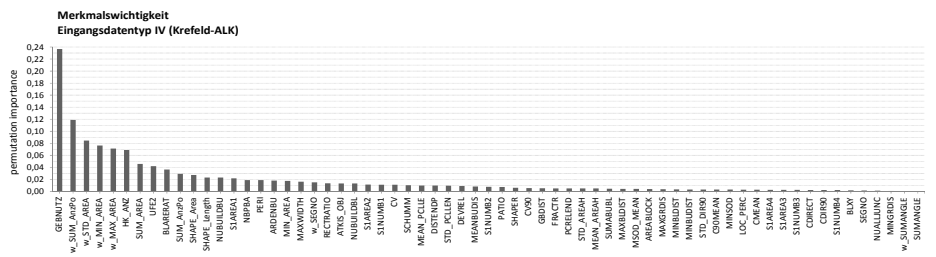

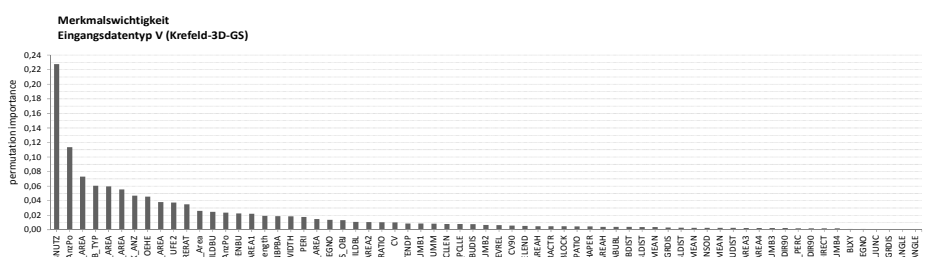

Abb. C-5: Merkmalswichtigkeit aller betrachteten Datensätze

C.5. Merkmalsselektion mit Random Forest

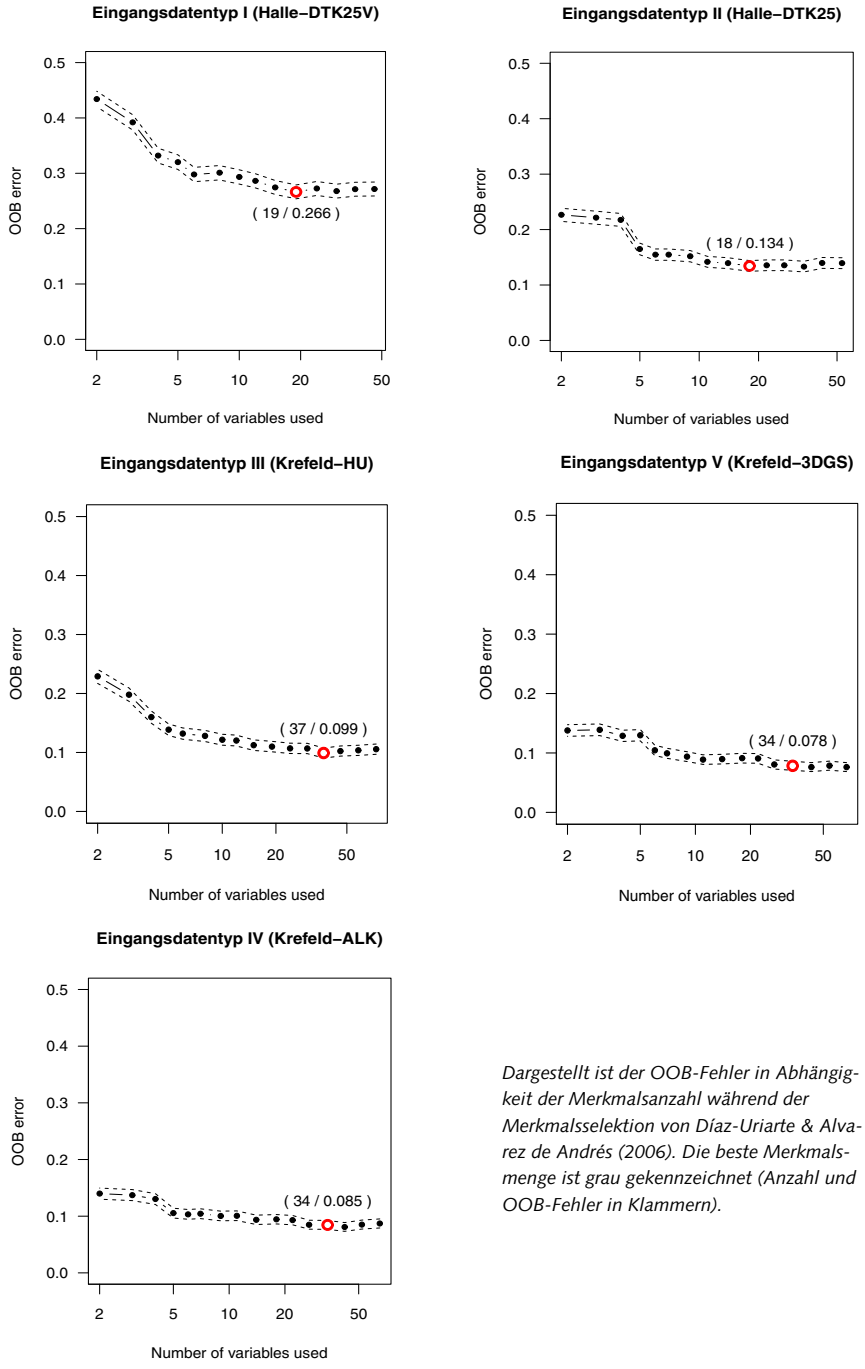

Dargestellt ist der OOB-Fehler in Abhängigkeit der Merkmalsanzahl während der Merkmalsselektion von Díaz-Uriarte & Alvarez de Andrés (2006). Die beste Merkmalsmenge ist grau gekennzeichnet (Anzahl und OOB-Fehler in Klammern).

Abb. C-6: Ergebnisse der Merkmalsselektion mittels Random Forest

Tab. C-5: Ergebnisse der Merkmalsselektion im Überblick

	Eingangsdatentyp									
	I (Halle)		II (Halle)		III (Krefeld)		IV (Krefeld)		V (Krefeld)	
	Orig.	Sel.	Orig.	Sel.	Orig.	Sel.	Orig.	Sel.	Orig.	Sel.
Merkmalsanzahl	46	19	53	18	65	37	73	34	67	34
OOB-Genauigkeit [%]	73,00	73,16	86,34	86,34	89,74	89,76	91,56	91,7	92,38	92,34
Differenz		+0,16		+0,00		+0,02		+0,14		-0,04
Selektierte Merkmale	ARDENBU AREAH ATKIS_OBJ BLARERAT GBDIST HK_ANZ MEAN_PCLLE NBPBA NUBUILDBL NUBUILDBU RECTRATIO S1NUMB1 S1NUMB2 S1NUMB4 SHAPER STD_DIR90 STD_PCLLEN SUMABUBL UFE2"		AREAH AREARECT ATKIS_OBJ BLARERAT CIRCULAR DEVGRDIS HK_ANZ MEAN_PCLLE MEANGRDIS NBPBA NUBUILDBU PERI RECTRATIO S1AREA1 S1AREA2 S1NUMB1 S1NUMB2 UFE2		ARDENBU AREAH ATKIS_OBJ BLARERAT CIRCULAR CV CV90 DEVREL DISTENDP HK_ANZ MAX_AREA MAXWIDTH MEAN_PCLLE MEDGRDIS MIN_AREA NBPBA NUBUILDBL NUBUILDBU PCLLENGTH PERI RATIOAREA_RB RECTLENG RECTRATIO S1AREA1 S1AREA2 S1NUMB1 SHAPE_Length STD_AREA SUM_AnzPo UFE2 w_MAX_AREA w_MIN_AREA w_SEGNO w_STD_AREA w_SUM_AnzPo w_VHK_ANZ		ARDENBU ATKIS_OBJ BLARERAT CV DEVREL DISTENDP GEBNUTZ HK_ANZ MAXWIDTH MEAN_PCLLE MEANBUDIS MIN_AREA NBPBA NUBUILDBL NUBUILDBU PATIO PCRELEND PERI RECTRATIO S1AREA1 S1AREA2 S1NUMB1 SCHUMM SHAPE_Area SHAPE_Length STD_PCLLEN SUM_AnzPo SUM_AREA UFE2 w_MAX_AREA w_MIN_AREA w_SEGNO w_STD_AREA w_SUM_AnzPo		ARDENBU ATKIS_OBJ BLARERAT CV DISTENDP GEB_HOEHE GEB_TYP GEBNUTZ HK_ANZ MAXWIDTH MEAN_PCLLE MEANBUDIS MIN_AREA NBPBA NUBUILDBL NUBUILDBU PCRELEND PERI RECTRATIO S1AREA1 S1AREA2 S1NUMB1 SCHUMM SHAPE_Area SHAPE_Length STD_PCLLEN SUM_AnzPo SUM_AREA UFE2 w_MAX_AREA w_MIN_AREA w_SEGNO w_STD_AREA w_SUM_AnzPo	

D Entwicklung des Klassifikators

D.1. Tuning der SVM

In Tab. D-1: Ergebnisse der Grid-Suche am Beispiel des Tunings des SVM-KlassifikatorsDie grau hinterlegten Zellen entsprechen der besten Parameterkombination.

Tab. D-1: Ergebnisse der Grid-Suche am Beispiel des Tunings des SVM-Klassifikators

	Parameter		Eingangsdatentyp I DTK25-V		Eingangsdatentyp II DTK25		Eingangsdatentyp III ATKIS		Eingangsdatentyp IV ALK		Eingangsdatentyp V 3D-GS	
Durchlauf	γ	C	Fehler	σ	Fehler	σ	Fehler	σ	Fehler	σ	Fehler	σ
1	2^{-15}	2	0,4940	0,0122	0,4443	0,0119	0,4679	0,0124	0,5289	0,0115	0,1476	0,0095
...	...	...	...	...	...	...	...	...	...	...	...	...
47	2^{-9}	32	0,2953	0,0085	0,1352	0,0048	0,1600	0,0033	0,1603	0,0094	0,0768	0,0077
48	2^{-8}	32	**0,2910**	**0,0112**	0,1342	0,0051	**0,1507**	**0,0062**	0,1368	0,0098	**0,0750**	**0,0057**
49	2^{-7}	32	0,2951	0,0109	0,1371	0,0072	0,1535	0,0053	0,1289	0,0099	0,0754	0,0074
50	2^{-6}	32	0,3037	0,0101	0,1511	0,0049	0,1618	0,0061	0,1287	0,0062	0,0780	0,0070
51	2^{-15}	64	0,3685	0,0195	0,2157	0,0043	0,2379	0,0034	0,2712	0,0102	0,0983	0,0061
52	2^{-14}	64	0,3449	0,0131	0,1908	0,0031	0,2190	0,0024	0,2513	0,0065	0,0932	0,0059
53	2^{-13}	64	0,3278	0,0152	0,1716	0,0028	0,2009	0,0047	0,2301	0,0073	0,0892	0,0082
54	2^{-12}	64	0,3132	0,0144	0,1503	0,0041	0,1829	0,0066	0,2128	0,0065	0,0842	0,0085
55	2^{-11}	64	0,3047	0,0149	0,1401	0,0043	0,1730	0,0063	0,1936	0,0063	0,0789	0,0063
56	2^{-10}	64	0,2973	0,0120	0,1350	0,0040	0,1636	0,0051	0,1699	0,0099	0,0780	0,0076
57	2^{-9}	64	0,2926	0,0097	0,1350	0,0029	0,1513	0,0053	0,1462	0,0092	0,0759	0,0078
58	2^{-8}	64	0,2932	0,0084	0,1336	0,0064	0,1532	0,0064	0,1295	0,0108	0,0754	0,0085
59	2^{-7}	64	0,3005	0,0101	0,1460	0,0064	0,1613	0,0070	0,1267	0,0078	0,0772	0,0091
60	2^{-6}	64	0,3090	0,0121	0,1544	0,0058	0,1655	0,0070	0,1270	0,0100	0,0779	0,0074
61	2^{-15}	128	0,3453	0,0140	0,1914	0,0034	0,2191	0,0029	0,2515	0,0077	0,0933	0,0052
62	2^{-14}	128	0,3281	0,0152	0,1706	0,0022	0,2009	0,0041	0,2307	0,0069	0,0891	0,0085
63	2^{-13}	128	0,3141	0,0132	0,1506	0,0037	0,1849	0,0057	0,2142	0,0066	0,0849	0,0081
64	2^{-12}	128	0,3048	0,0149	0,1410	0,0036	0,1749	0,0050	0,2000	0,0053	0,0799	0,0075
65	2^{-11}	128	0,2987	0,0107	0,1350	0,0055	0,1666	0,0064	0,1815	0,0074	0,0798	0,0057
66	2^{-10}	128	0,2960	0,0069	0,1332	0,0052	0,1548	0,0048	0,1565	0,0080	0,0779	0,0087
67	2^{-9}	128	0,2928	0,0114	0,1321	0,0074	0,1513	0,0054	0,1341	0,0103	0,0761	0,0075
68	2^{-8}	128	0,2982	0,0081	0,1380	0,0055	0,1569	0,0083	0,1280	0,0086	0,0767	0,0095
69	2^{-7}	128	0,3037	0,0090	0,1512	0,0070	0,1621	0,0087	0,1281	0,0067	0,0785	0,0081
70	2^{-6}	128	0,3168	0,0127	0,1585	0,0066	0,1653	0,0084	0,1287	0,0092	0,0786	0,0070
71	2^{-15}	256	0,3283	0,0153	0,1702	0,0027	0,2011	0,0048	0,2316	0,0072	0,0896	0,0080
72	2^{-14}	256	0,3152	0,0126	0,1505	0,0039	0,1857	0,0054	0,2151	0,0071	0,0849	0,0081
73	2^{-13}	256	0,3070	0,0151	0,1421	0,0027	0,1768	0,0053	0,2031	0,0047	0,0810	0,0078
74	2^{-12}	256	0,2998	0,0132	0,1361	0,0055	0,1699	0,0070	0,1880	0,0094	0,0802	0,0061
75	2^{-11}	256	0,2963	0,0076	0,1326	0,0051	0,1609	0,0039	0,1659	0,0072	0,0784	0,0065
76	2^{-10}	256	0,2916	0,0087	0,1342	0,0067	0,1536	0,0054	0,1427	0,0079	0,0783	0,0076
77	2^{-9}	256	0,2937	0,0079	0,1343	0,0038	0,1522	0,0067	0,1299	0,0105	0,0777	0,0085
78	2^{-8}	256	0,3032	0,0095	0,1480	0,0077	0,1623	0,0097	0,1281	0,0049	0,0810	0,0097
79	2^{-7}	256	0,3141	0,0100	0,1565	0,0082	0,1640	0,0076	0,1300	0,0080	0,0790	0,0078
80	2^{-6}	256	0,3200	0,0144	0,1602	0,0064	0,1669	0,0098	0,1307	0,0098	0,0809	0,0073
81	2^{-15}	512	0,3152	0,0121	0,1505	0,0035	0,1868	0,0046	0,2156	0,0066	0,0853	0,0076
82	2^{-14}	512	0,3089	0,0138	0,1431	0,0025	0,1780	0,0050	0,2042	0,0056	0,0821	0,0082
83	2^{-13}	512	0,3033	0,0119	0,1376	0,0041	0,1732	0,0048	0,1925	0,0074	0,0808	0,0075
84	2^{-12}	512	0,2993	0,0075	0,1344	0,0062	0,1658	0,0073	0,1771	0,0070	0,0793	0,0073
85	2^{-11}	512	0,2938	0,0051	0,1324	0,0069	0,1556	0,0042	0,1538	0,0087	0,0793	0,0083
86	2^{-10}	512	0,2943	0,0109	0,1338	0,0051	0,1519	0,0053	0,1332	0,0102	0,0790	0,0070
87	2^{-9}	512	0,3003	0,0107	0,1425	0,0065	0,1567	0,0077	**0,1265**	**0,0086**	0,0797	0,0093
88	2^{-8}	512	0,3098	0,0118	0,1551	0,0087	0,1652	0,0108	0,1290	0,0073	0,0823	0,0077
89	2^{-7}	512	0,3167	0,0076	0,1606	0,0078	0,1651	0,0087	0,1309	0,0084	0,0811	0,0072
90	2^{-6}	512	0,3211	0,0142	0,1602	0,0064	0,1688	0,0089	0,1307	0,0081	0,0829	0,0066
91	2^{-15}	1024	0,3099	0,0140	0,1422	0,0022	0,1786	0,0052	0,2052	0,0061	0,0830	0,0087
92	2^{-14}	1024	0,3042	0,0136	0,1379	0,0042	0,1738	0,0044	0,1943	0,0056	0,0822	0,0074
93	2^{-13}	1024	0,3002	0,0093	0,1344	0,0051	0,1690	0,0063	0,1821	0,0081	0,0794	0,0081
94	2^{-12}	1024	0,2967	0,0062	**0,1313**	**0,0059**	0,1611	0,0035	0,1647	0,0081	0,0791	0,0075
95	2^{-11}	1024	0,2922	0,0072	0,1334	0,0060	0,1556	0,0060	0,1411	0,0097	0,0796	0,0081
96	2^{-10}	1024	0,2953	0,0071	0,1365	0,0019	0,1520	0,0059	0,1295	0,0093	0,0800	0,0065
...	...	...	...	...	...	...	...	...	...	...	...	...
100	2^{-6}	1024	0,3207	0,0137	0,1602	0,0064	0,1698	0,0104	0,1315	0,0089	0,0844	0,0066

D.2. Klassifikationsgenauigkeit der getesteten Klassifikationsverfahren

D.2.1 Overall Accuracy und Kappa in tabellarischer Darstellung

Tab. D-2: Getestete Klassifikatoren und die 10-fach kreuzvalidierte Klassifikationsgenauigkeit für verschiedene Eingangsdatensätze (n= 10 000, 11 Klassen)

		Methoden															
		LDA	KNN	SLDA	PDA	MDA	PMDA	FDA-MARS	CART	NNET	SVMe107	BAGGING	DOUBAG	RF	ADABOOS	PVSLDA	PVSRF
DTK25-V																	
Acc	Ø	0,660	0,657	0,595	0,660	0,647	0,646	0,697	0,637	0,728	0,737	0,756	0,761	0,775	0,688	0,697	0,757
	σ	0,012	0,013	0,012	0,013	0,016	0,013	0,015	0,017	0,014	0,013	0,016	0,015	0,015	0,013	0,017	0,014
	min	0,630	0,632	0,578	0,630	0,622	0,625	0,665	0,604	0,704	0,718	0,736	0,739	0,750	0,665	0,669	0,734
	max	0,671	0,678	0,616	0,672	0,661	0,660	0,721	0,660	0,748	0,755	0,793	0,791	0,798	0,703	0,715	0,778
Kappa	Ø	0,558	0,552	0,464	0,558	0,541	0,541	0,609	0,520	0,643	0,654	0,680	0,688	0,704	0,587	0,601	0,677
	σ	0,018	0,019	0,015	0,019	0,024	0,019	0,021	0,023	0,021	0,020	0,022	0,020	0,020	0,015	0,025	0,020
	min	0,511	0,512	0,442	0,511	0,501	0,508	0,562	0,471	0,609	0,622	0,649	0,657	0,670	0,554	0,559	0,646
	max	0,573	0,583	0,488	0,577	0,561	0,559	0,641	0,547	0,671	0,680	0,730	0,727	0,736	0,603	0,631	0,706
DTK25																	
Acc	Ø	0,820	0,792	0,712	0,821	0,810	0,813	0,856	0,842	0,889	0,892	0,895	0,897	0,903	0,885	0,873	0,896
	σ	0,009	0,013	0,011	0,010	0,009	0,010	0,009	0,012	0,009	0,012	0,012	0,013	0,011	0,011	0,010	0,008
	min	0,807	0,777	0,692	0,807	0,798	0,797	0,841	0,819	0,873	0,874	0,872	0,869	0,879	0,861	0,860	0,882
	max	0,835	0,815	0,728	0,836	0,820	0,829	0,869	0,860	0,901	0,914	0,914	0,915	0,918	0,899	0,894	0,909
Kappa	Ø	0,711	0,660	0,518	0,712	0,701	0,706	0,771	0,737	0,819	0,824	0,829	0,832	0,841	0,812	0,794	0,828
	σ	0,016	0,019	0,015	0,016	0,013	0,014	0,012	0,018	0,014	0,018	0,018	0,019	0,016	0,018	0,016	0,011
	min	0,686	0,639	0,488	0,686	0,680	0,689	0,750	0,706	0,789	0,800	0,794	0,789	0,805	0,775	0,767	0,808
	max	0,735	0,693	0,546	0,737	0,718	0,727	0,784	0,765	0,833	0,858	0,853	0,859	0,860	0,834	0,822	0,843
ATKIS																	
Acc	Ø	0,742	0,816	0,639	0,742	0,744	0,741	0,816	0,750	0,860	0,883	0,887	0,893	0,900	0,821	0,822	0,896
	σ	0,009	0,014	0,017	0,010	0,006	0,008	0,011	0,017	0,011	0,009	0,006	0,010	0,010	0,010	0,011	0,010
	min	0,729	0,797	0,617	0,726	0,730	0,732	0,800	0,729	0,838	0,873	0,877	0,880	0,888	0,807	0,804	0,882
	max	0,757	0,838	0,672	0,757	0,751	0,758	0,838	0,776	0,877	0,901	0,896	0,908	0,919	0,834	0,837	0,917
Kappa	Ø	0,700	0,785	0,579	0,700	0,701	0,698	0,786	0,707	0,837	0,864	0,868	0,875	0,884	0,790	0,792	0,878
	σ	0,010	0,016	0,020	0,011	0,007	0,009	0,013	0,019	0,012	0,011	0,007	0,012	0,011	0,011	0,012	0,012
	min	0,686	0,764	0,556	0,683	0,685	0,689	0,769	0,684	0,811	0,852	0,856	0,860	0,870	0,774	0,772	0,862
	max	0,717	0,811	0,618	0,717	0,710	0,718	0,811	0,737	0,856	0,885	0,879	0,893	0,905	0,805	0,809	0,903
ALK																	
Acc	Ø	0,745	0,871	0,605	0,744	0,765	0,757	0,819	0,772	0,879	0,914	0,924	0,920	0,932	0,841	0,838	0,928
	σ	0,018	0,014	0,018	0,017	0,017	0,013	0,012	0,012	0,011	0,010	0,006	0,006	0,007	0,014	0,009	0,007
	min	0,706	0,845	0,572	0,707	0,721	0,733	0,797	0,761	0,864	0,893	0,914	0,908	0,919	0,813	0,827	0,910
	max	0,766	0,891	0,632	0,767	0,773	0,771	0,840	0,801	0,898	0,926	0,932	0,930	0,943	0,861	0,855	0,935
Kappa	Ø	0,692	0,845	0,520	0,691	0,709	0,708	0,782	0,726	0,854	0,896	0,908	0,904	0,918	0,808	0,805	0,913
	σ	0,020	0,017	0,021	0,020	0,020	0,015	0,014	0,014	0,013	0,012	0,007	0,008	0,009	0,016	0,010	0,009
	min	0,646	0,814	0,485	0,647	0,664	0,678	0,756	0,713	0,836	0,872	0,897	0,889	0,903	0,776	0,793	0,892
	max	0,718	0,870	0,556	0,720	0,724	0,721	0,806	0,760	0,878	0,911	0,917	0,916	0,931	0,831	0,824	0,922
3D-GS																	
Acc	Ø	0,897	0,842	0,811	0,896	0,896	0,892	0,907	0,886	0,927	0,931	0,936	0,936	0,943	0,917	0,913	0,940
	σ	0,010	0,011	0,014	0,009	0,006	0,007	0,009	0,010	0,006	0,009	0,005	0,005	0,004	0,007	0,008	0,005
	min	0,882	0,830	0,781	0,882	0,888	0,882	0,887	0,871	0,919	0,912	0,927	0,929	0,939	0,905	0,898	0,933
	max	0,916	0,861	0,833	0,914	0,908	0,909	0,916	0,900	0,937	0,941	0,942	0,942	0,952	0,933	0,924	0,950
Kappa	Ø	0,872	0,803	0,764	0,871	0,871	0,866	0,884	0,858	0,909	0,915	0,920	0,921	0,929	0,896	0,891	0,926
	σ	0,012	0,013	0,017	0,011	0,007	0,009	0,011	0,012	0,008	0,012	0,006	0,006	0,005	0,009	0,010	0,006
	min	0,854	0,790	0,727	0,854	0,860	0,853	0,860	0,840	0,899	0,891	0,909	0,912	0,924	0,882	0,873	0,917
	max	0,896	0,826	0,793	0,893	0,886	0,887	0,896	0,875	0,922	0,927	0,927	0,928	0,940	0,917	0,905	0,938

D.2.2 Overall Accuracy und Kappa in Diagramm

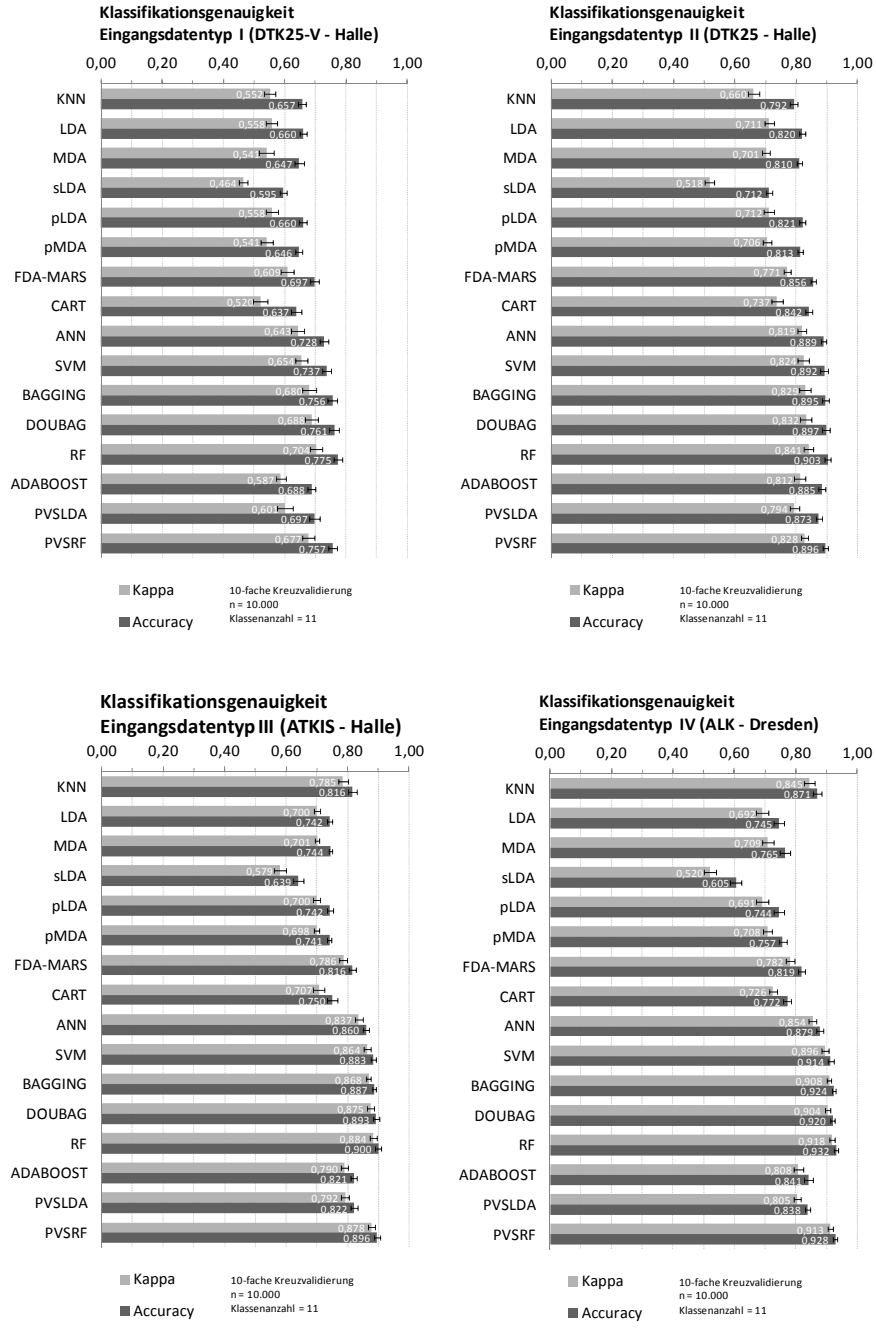

Abb. D-1: Klassifikationsgenauigkeit (Overall Accuracy und Kappa) für die Eingangsdatentypen I-IV

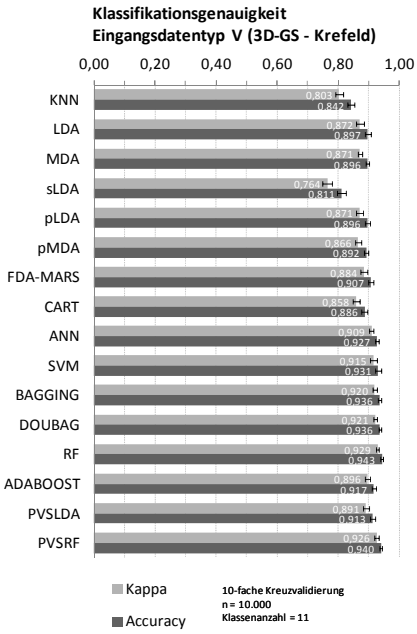

Abb. D-2: Klassifikationsgenauigkeit (Overall Accuracy und Kappa) für den Eingangsdatentyp V

D.2.3 Mittelwert und Streuung der Overall Accuracy

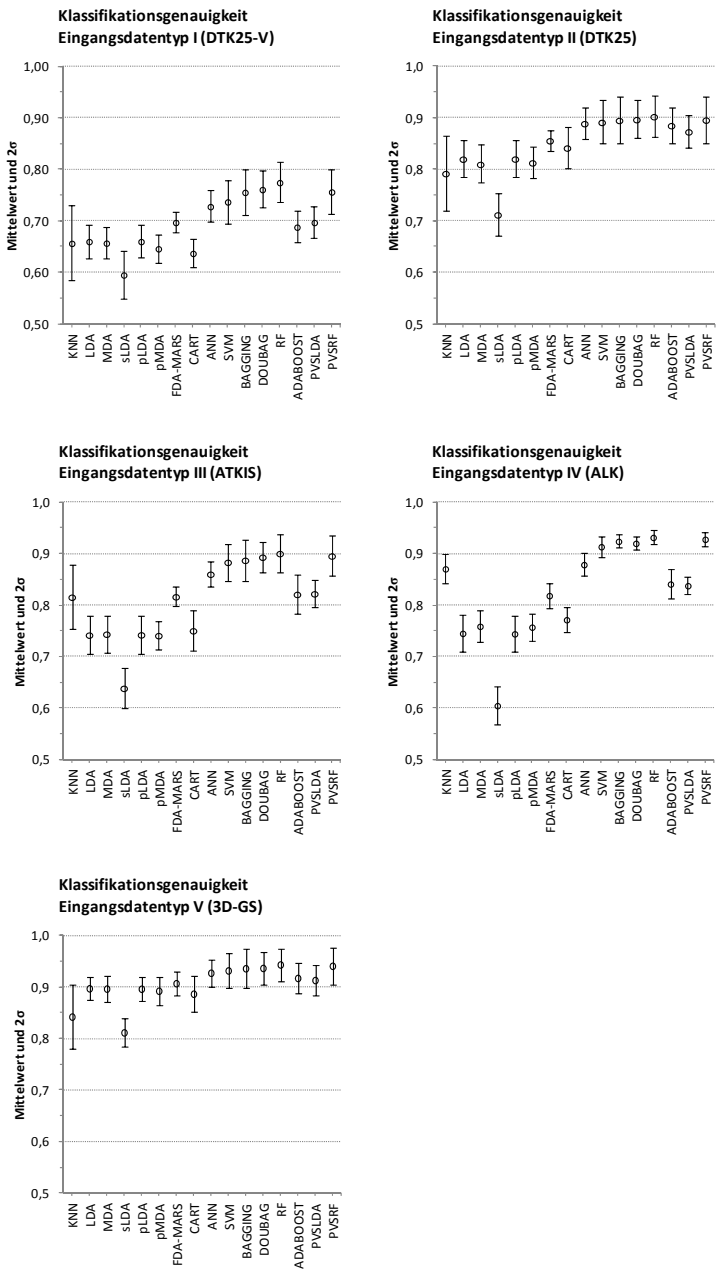

Abb. D-3: 10-fach kreuzvalidierte Klassifikationsgenauigkeit der getesteten Klassifikationsverfahren und deren Streuung (zweifache Standardabweichung 2σ) anhand verschiedener Eingangsdatentypen bei einer Lerndatenmenge n = 10 000

D.2.4 Variation der Trainingsdatenmenge

DTK25V (Halle)

	n	LDA	KNN	SLDA	PDA	MDA	PMDA	FDA-MARS	CART	NNET	SVM	BAGGING	DOUBAG	RF	ADABOOST	PVSLDA	PVSRF
Accuracy Ø	10000	0,660	0,657	0,595	0,660	0,647	0,646	0,697	0,637	0,728	0,737	0,756	0,761	0,775	0,688	0,697	0,757
	5000	0,656	0,637	0,590	0,656	0,644	0,648	0,697	0,628	0,716	0,724	0,728	0,745	0,756	0,692	0,694	0,737
	2500	0,653	0,625	0,585	0,651	0,630	0,631	0,673	0,646	0,693	0,695	0,715	0,722	0,728	0,704	0,681	0,712
	1250	0,627	0,584	0,589	0,632	0,609	0,609	0,641	0,623	0,667	0,655	0,695	0,706	0,716	0,700	0,650	0,688
	675	0,605	0,602	0,597	0,623	0,557	0,597	0,627	0,624	0,642	0,642	0,690	0,687	0,706	0,692	0,639	0,679
SD σ	10000	0,012	0,013	0,012	0,013	0,016	0,013	0,015	0,017	0,014	0,013	0,016	0,015	0,015	0,013	0,017	0,014
	5000	0,014	0,021	0,010	0,014	0,011	0,018	0,020	0,019	0,015	0,018	0,021	0,021	0,018	0,028	0,015	0,014
	2500	0,026	0,032	0,047	0,025	0,028	0,030	0,039	0,038	0,035	0,023	0,034	0,030	0,032	0,037	0,024	0,031
	1250	0,035	0,039	0,041	0,044	0,035	0,040	0,040	0,040	0,023	0,032	0,037	0,029	0,037	0,029	0,034	0,026
	675	0,047	0,064	0,068	0,060	0,074	0,072	0,050	0,065	0,089	0,072	0,047	0,049	0,060	0,070	0,035	0,047

DTK25 (Halle)

	n	LDA	KNN	SLDA	PDA	MDA	PMDA	FDA-MARS	CART	NNET	SVM	BAGGING	DOUBAG	RF	ADABOOS	PVSLDA	PVSRF
Accuracy Ø	10000	0,820	0,792	0,712	0,821	0,810	0,813	0,856	0,842	0,889	0,892	0,895	0,897	0,903	0,885	0,873	0,896
	5000	0,818	0,781	0,709	0,817	0,801	0,804	0,859	0,834	0,876	0,877	0,887	0,894	0,895	0,885	0,871	0,884
	2500	0,824	0,765	0,710	0,824	0,814	0,807	0,850	0,847	0,866	0,860	0,886	0,890	0,896	0,892	0,866	0,882
	1250	0,806	0,718	0,719	0,811	0,771	0,784	0,811	0,839	0,819	0,794	0,865	0,861	0,882	0,866	0,821	0,842
	675	0,605	0,602	0,597	0,623	0,557	0,597	0,627	0,624	0,642	0,642	0,690	0,687	0,706	0,692	0,639	0,679
SD σ	10000	0,009	0,013	0,011	0,010	0,009	0,010	0,009	0,012	0,009	0,012	0,012	0,013	0,011	0,011	0,010	0,008
	5000	0,016	0,015	0,027	0,015	0,010	0,006	0,021	0,023	0,020	0,014	0,017	0,019	0,016	0,014	0,015	0,015
	2500	0,024	0,021	0,022	0,015	0,023	0,021	0,020	0,014	0,011	0,021	0,017	0,016	0,016	0,014	0,018	0,019
	1250	0,035	0,049	0,040	0,032	0,028	0,028	0,038	0,033	0,035	0,038	0,018	0,019	0,008	0,018	0,027	0,035
	675	0,049	0,057	0,064	0,042	0,044	0,058	0,046	0,040	0,031	0,050	0,035	0,046	0,037	0,044	0,051	0,033

ATKIS (Halle)

	n	LDA	KNN	SLDA	PDA	MDA	PMDA	FDA-MARS	CART	NNET	SVM	BAGGING	DOUBAG	RF	ADABOOS	PVSLDA	PVSRF
Accuracy σ	10000	0,742	0,816	0,639	0,742	0,744	0,741	0,816	0,750	0,860	0,883	0,887	0,893	0,900	0,821	0,822	0,896
	5000	0,742	0,758	0,645	0,743	0,736	0,737	0,808	0,733	0,836	0,855	0,861	0,871	0,874	0,821	0,821	0,868
	2500	0,748	0,727	0,660	0,749	0,726	0,730	0,810	0,738	0,833	0,842	0,843	0,860	0,857	0,836	0,820	0,850
	1250	0,737	0,720	0,654	0,740	0,710	0,722	0,802	0,754	0,806	0,806	0,826	0,838	0,838	0,840	0,802	0,834
	675	0,718	0,687	0,639	0,731	0,704	0,723	0,750	0,702	0,760	0,777	0,795	0,800	0,805	0,813	0,756	0,781
SD σ	10000	0,009	0,014	0,017	0,010	0,006	0,008	0,011	0,017	0,011	0,009	0,006	0,010	0,010	0,010	0,011	0,010
	5000	0,014	0,023	0,024	0,013	0,018	0,016	0,019	0,020	0,017	0,013	0,013	0,012	0,012	0,016	0,019	0,021
	2500	0,022	0,037	0,034	0,024	0,037	0,034	0,014	0,030	0,029	0,024	0,031	0,025	0,026	0,023	0,029	0,037
	1250	0,027	0,030	0,041	0,042	0,031	0,025	0,039	0,041	0,026	0,040	0,039	0,032	0,026	0,020	0,035	0,028
	675	0,038	0,061	0,056	0,054	0,047	0,056	0,044	0,052	0,060	0,042	0,037	0,034	0,030	0,030	0,045	0,029

ALK (Dresden)

	n	LDA	KNN	SLDA	PDA	MDA	PMDA	FDA-MARS	CART	NNET	SVM	BAGGING	DOUBAG	RF	ADABOOS	PVSLDA	PVSRF
Accuracy Ø	10000	0,745	0,871	0,605	0,744	0,765	0,757	0,819	0,772	0,879	0,914	0,924	0,920	0,932	0,841	0,838	0,928
	5000	0,737	0,823	0,605	0,737	0,758	0,757	0,811	0,765	0,855	0,882	0,902	0,894	0,914	0,847	0,835	0,910
	2500	0,738	0,765	0,608	0,737	0,752	0,741	0,808	0,757	0,826	0,853	0,875	0,871	0,881	0,867	0,827	0,878
	1250	0,777	0,730	0,629	0,775	0,790	0,779	0,830	0,768	0,826	0,834	0,850	0,858	0,870	0,879	0,831	0,862
	675	0,737	0,656	0,618	0,734	0,774	0,752	0,802	0,758	0,774	0,768	0,811	0,816	0,839	0,835	0,747	0,827
SD σ	10000	0,018	0,014	0,018	0,017	0,017	0,013	0,012	0,012	0,011	0,010	0,006	0,006	0,007	0,014	0,009	0,007
	5000	0,015	0,020	0,017	0,016	0,012	0,019	0,020	0,015	0,013	0,016	0,013	0,020	0,014	0,012	0,020	0,017
	2500	0,026	0,026	0,035	0,028	0,019	0,028	0,016	0,029	0,021	0,022	0,017	0,015	0,019	0,015	0,021	0,022
	1250	0,045	0,034	0,032	0,037	0,037	0,028	0,039	0,047	0,035	0,039	0,030	0,032	0,038	0,032	0,036	0,044
	675	0,058	0,086	0,072	0,046	0,066	0,057	0,053	0,050	0,067	0,050	0,048	0,038	0,040	0,045	0,055	0,046

3D-GD (Krefeld)

	n	LDA	KNN	SLDA	PDA	MDA	PMDA	FDA-MARS	CART	NNET	SVM	BAGGING	DOUBAG	RF	ADABOOS	PVSLDA	PVSRF
Accuracy Ø	10000	0,897	0,842	0,811	0,896	0,896	0,892	0,907	0,886	0,927	0,931	0,936	0,936	0,943	0,917	0,913	0,940
	5000	0,897	0,822	0,810	0,897	0,891	0,888	0,903	0,877	0,915	0,913	0,919	0,919	0,927	0,910	0,897	0,921
	2500	0,889	0,808	0,802	0,890	0,880	0,871	0,890	0,870	0,904	0,907	0,908	0,905	0,912	0,912	0,884	0,908
	1250	0,890	0,792	0,813	0,892	0,873	0,885	0,896	0,873	0,890	0,887	0,904	0,904	0,901	0,908	0,881	0,895
	675	0,863	0,739	0,789	0,871	0,819	0,839	0,868	0,861	0,881	0,871	0,868	0,869	0,873	0,863	0,842	0,879
SD σ	10000	0,010	0,011	0,014	0,009	0,006	0,007	0,009	0,010	0,006	0,009	0,005	0,005	0,004	0,007	0,008	0,005
	5000	0,016	0,022	0,013	0,015	0,022	0,017	0,012	0,020	0,015	0,012	0,010	0,014	0,011	0,012	0,017	0,011
	2500	0,013	0,023	0,023	0,012	0,015	0,024	0,015	0,029	0,026	0,018	0,021	0,021	0,024	0,020	0,017	0,023
	1250	0,021	0,032	0,035	0,020	0,016	0,022	0,017	0,014	0,012	0,014	0,017	0,016	0,021	0,014	0,023	0,022
	675	0,036	0,053	0,065	0,037	0,033	0,033	0,040	0,058	0,047	0,032	0,039	0,040	0,035	0,044	0,043	0,035

D.3. Laufzeitmessung der besten Klassifikationsverfahren

Tab. D-3: Gemessene Laufzeit verschiedener Klassifikationsverfahren in Sekunden aus 5-fach wiederholten Stichproben

		Training mit Tuning		Training ohne Tuning		Anwenden	
n	Methode	Ø	σ	Ø	σ	Ø	σ
500	ANN	1138,732	46,167	5,290	0,510	0,031	0,007
	SVM	164,324	1,664	0,150	0,010	0,071	0,004
	BAGGING	8,652	0,324	8,652	0,324	0,078	0,005
	DOUBAG	11,136	0,592	11,136	0,592	0,994	0,286
	RF	20,603	6,129	0,365	0,011	0,014	0,001
	ADABOOST	35,721	0,992	35,721	0,992	2,327	0,173
	PVSRF	4,854	0,155	4,854	0,155	0,533	0,032
1000	ANN	2805,867	300,978	13,881	4,544	0,055	0,014
	SVM	343,274	4,861	0,413	0,032	0,205	0,017
	BAGGING	21,206	0,339	21,206	0,339	0,250	0,063
	DOUBAG	24,891	1,137	24,891	1,137	1,535	0,315
	RF	38,694	1,781	0,797	0,051	0,027	0,009
	ADABOOST	75,511	1,436	75,511	1,436	4,263	0,611
	PVSRF	8,725	0,354	8,725	0,354	1,142	0,024
1500	ANN	4086,412	272,253	21,096	4,226	0,076	0,012
	SVM	590,842	11,844	0,922	0,071	0,434	0,034
	BAGGING	38,495	0,435	38,495	0,435	0,387	0,048
	DOUBAG	44,183	2,025	44,183	2,025	2,828	0,898
	RF	69,951	1,423	1,450	0,070	0,048	0,013
	ADABOOST	127,916	2,009	127,916	2,009	7,485	0,863
	PVSRF	14,263	0,340	14,263	0,340	2,087	0,097
2000	ANN	4472,935	495,394	19,747	4,121	0,072	0,016
	SVM	788,620	7,271	1,473	0,034	0,632	0,053
	BAGGING	55,349	1,394	55,349	1,394	0,440	0,050
	DOUBAG	64,366	1,305	64,366	1,305	3,039	0,746
	RF	99,671	1,418	2,086	0,159	0,066	0,016
	ADABOOST	164,580	3,790	164,580	3,790	7,389	0,824
	PVSRF	18,413	0,211	18,413	0,211	2,864	0,165
2500	ANN	6854,990	915,983	34,367	10,853	0,123	0,017
	SVM	989,360	22,752	2,301	0,470	1,166	0,241
	BAGGING	71,024	2,421	71,024	2,421	0,357	0,043
	DOUBAG	79,828	4,142	79,828	4,142	2,432	0,861
	RF	118,431	8,210	2,367	0,114	0,049	0,005
	ADABOOST	193,721	3,255	193,721	3,255	6,054	0,240
	PVSRF	19,695	0,330	19,695	0,330	2,732	0,101
3000	ANN	6611,421	867,412	36,015	5,369	0,075	0,016
	SVM	2140,885	187,738	7,219	1,971	2,906	2,401
	BAGGING	126,111	8,599	126,111	8,599	0,750	0,149
	DOUBAG	138,018	8,738	138,018	8,738	6,360	1,059
	RF	219,674	19,563	5,482	1,128	0,135	0,030
	ADABOOST	325,397	18,404	325,397	18,404	12,514	1,456
	PVSRF	37,612	1,389	37,612	1,389	5,713	0,498
3500	ANN	5683,118	72,144	29,661	6,746	0,073	0,010
	SVM	1435,449	17,069	3,265	0,181	1,487	0,196
	BAGGING	112,009	1,645	112,009	1,645	0,442	0,009
	DOUBAG	134,334	8,712	134,334	8,712	3,987	0,738
	RF	189,134	5,597	3,622	0,279	0,102	0,015
	ADABOOST	269,861	3,529	269,861	3,529	6,970	0,123
	PVSRF	29,451	0,492	29,451	0,492	4,270	0,125
4000	ANN	9702,646	545,009	45,549	9,602	0,140	0,033

n	Methode	Training mit Tuning Ø	Training mit Tuning σ	Training ohne Tuning Ø	Training ohne Tuning σ	Anwenden Ø	Anwenden σ
	SVM	2226,350	359,558	7,737	2,860	2,954	1,300
	BAGGING	155,005	2,391	155,005	2,391	0,588	0,099
	DOUBAG	168,677	6,560	168,677	6,560	4,034	0,888
	RF	214,226	7,111	4,135	0,127	0,089	0,014
	ADABOOST	364,968	8,954	364,968	8,954	10,393	0,834
	PVSRF	33,517	0,829	33,517	0,829	4,464	0,208
4500	ANN	7235,595	351,627	39,923	2,063	0,087	0,005
	SVM	2412,973	395,416	6,055	1,741	3,056	1,370
	BAGGING	190,074	5,789	190,074	5,789	0,768	0,055
	DOUBAG	210,768	6,278	210,768	6,278	5,600	0,642
	RF	285,819	8,288	6,084	0,328	0,155	0,021
	ADABOOST	443,329	11,129	443,329	11,129	12,225	1,675
	PVSRF	43,653	1,244	43,653	1,244	6,603	0,169
5000	ANN	7825,017	109,933	41,303	8,458	0,068	0,001
	SVM	2274,931	31,797	5,505	0,132	2,587	0,360
	BAGGING	181,830	3,716	181,830	3,716	0,600	0,010
	DOUBAG	192,680	4,262	192,680	4,262	3,881	0,802
	RF	258,096	3,916	4,942	0,089	0,109	0,008
	ADABOOST	365,678	3,377	365,678	3,377	8,147	0,224
	PVSRF	40,316	0,183	40,316	0,183	5,633	0,055
6000	ANN	12399,989	1663,648	68,652	13,242	0,152	0,060
	SVM	6963,209	1451,249	22,888	4,958	13,901	6,531
	BAGGING	302,931	5,988	302,931	5,988	1,114	0,157
	DOUBAG	311,404	23,162	311,404	23,162	6,741	2,153
	RF	387,815	9,588	7,412	0,324	0,156	0,005
	ADABOOST	571,248	14,526	571,248	14,526	14,006	0,512
	PVSRF	60,114	1,409	60,114	1,409	7,800	0,368
7000	ANN	13672,392	1748,312	66,576	8,699	0,130	0,031
	SVM	10390,186	1312,134	33,776	7,756	18,133	5,133
	BAGGING	378,734	11,147	378,734	11,147	1,162	0,071
	DOUBAG	407,573	14,539	407,573	14,539	9,243	1,479
	RF	461,291	11,111	8,921	0,223	0,212	0,016
	ADABOOST	722,913	24,927	722,913	24,927	17,856	2,139
	PVSRF	71,761	1,847	71,761	1,847	9,279	0,717
8000	ANN	15424,632	1506,917	88,415	22,598	0,141	0,033
	SVM	10361,579	1792,389	33,156	8,545	14,186	5,784
	BAGGING	464,325	11,963	464,325	11,963	1,549	0,207
	DOUBAG	493,053	12,849	493,053	12,849	8,232	1,710
	RF	553,332	15,239	10,866	0,578	0,411	0,114
	ADABOOST	847,574	24,438	847,574	24,438	23,613	2,292
	PVSRF	89,369	3,414	89,369	3,414	12,769	0,642
9000	ANN	16708,553	1036,986	89,902	16,169	0,131	0,029
	SVM	13477,563	4182,878	40,555	10,397	19,900	10,380
	BAGGING	598,034	27,411	598,034	27,411	1,855	0,392
	DOUBAG	605,852	16,756	605,852	16,756	10,799	1,650
	RF	646,100	25,209	13,682	2,151	0,503	0,215
	ADABOOST	1109,424	59,897	1109,424	59,897	28,113	3,296
	PVSRF	105,859	2,372	105,859	2,372	18,331	2,021
10000	ANN	18992,028	1053,705	109,286	27,234	0,141	0,026
	SVM	14649,351	3334,516	47,484	18,383	25,193	12,117
	BAGGING	734,484	39,147	734,484	39,147	2,104	0,306
	DOUBAG	659,370	21,868	659,370	21,868	8,956	0,607
	RF	732,660	24,251	14,342	0,556	0,536	0,106
	ADABOOST	1322,980	89,910	1322,980	89,910	31,223	3,476
	PVSRF	120,903	0,832	120,903	0,832	20,305	2,466

E Genauigkeitsuntersuchung

E.1. Konfusionsmatrizen der Genauigkeitsuntersuchung

Dresden – DTK25-V

		Referenzdaten												
		MFH-G	MFH-F	MFH-TZ	MFH-IZ	MFH-HH	EFZH-EH	EFZH-DH	EFZH-RH	LH	WGL	ÖG	Summe	UA[%]
Klassifikation	MFH-G	222	20	44	12	0	0	0	2	7	9	1	317	70,03
	MFH-F	42	4900	91	13	10	631	71	21	165	270	0	6214	78,85
	MFH-TZ	64	70	1127	116	0	5	11	33	13	15	0	1454	77,51
	MFH-IZ	7	0	65	354	1	0	0	1	0	0	0	428	82,71
	MFH-HH	0	0	0	0	26	0	0	0	0	0	0	26	100,00
	EFZH-EH	1	562	8	3	1	3251	140	21	49	141	0	4177	77,83
	EFZH-DH	0	89	16	1	0	198	1046	53	16	13	0	1432	73,04
	EFZH-RH	1	6	16	5	0	13	20	356	2	5	0	424	83,96
	LH	1	17	1	1	0	7	1	0	47	10	0	85	55,29
	WGL	14	249	28	16	7	197	15	6	71	2408	0	3011	79,97
	ÖG	4	1	0	0	0	0	0	0	0	0	607	612	99,18
	Summe	356	5914	1396	521	45	4302	1304	493	370	2871	608	18180	
	PA[%]	62,36	82,85	80,73	67,95	57,78	75,57	80,21	72,21	12,70	83,87	99,84		

Ø OA (σ) in %	78,90	(0,67)
Ø κ (σ)	0,73	(0,01)

Dresden – ATKIS

		Referenzdaten												
		MFH-G	MFH-F	MFH-TZ	MFH-IZ	MFH-HH	EFZH-EH	EFZH-DH	EFZH-RH	LH	WGL	ÖG	Summe	UA[%]
Klassifikation	MFH-G	1331	1	1	0	0	0	0	0	0	25	4	1362	97,72
	MFH-F	8	3126	20	0	0	286	17	4	54	162	37	3714	84,17
	MFH-TZ	4	12	2442	1	0	1	0	2	1	12	1	2476	98,63
	MFH-IZ	0	0	1	830	0	0	0	0	0	1	1	833	99,64
	MFH-HH	0	0	0	0	16	0	0	0	0	0	0	16	100,00
	EFZH-EH	0	250	0	0	0	1338	10	1	68	57	2	1726	77,52
	EFZH-DH	0	5	6	0	0	5	920	2	5	4	0	947	97,15
	EFZH-RH	0	0	2	0	0	0	0	930	0	0	0	932	99,79
	LH	1	23	0	0	0	23	1	0	220	80	0	348	63,22
	WGL	32	221	30	1	3	135	19	3	137	5939	46	6566	90,45
	ÖG	5	13	2	0	0	1	0	1	0	5	423	450	94,00
	Summe	1381	3651	2504	832	19	1789	967	943	485	6285	514	19370	
	PA[%]	96,38	85,62	97,52	99,76	84,21	74,79	95,14	98,62	45,36	94,49	82,30		

Ø OA (σ) in %	90,42	(0,62)
Ø κ (σ)	0,88	(0,01)

Dresden – ALK

		Referenzdaten												
		MFH-G	MFH-F	MFH-TZ	MFH-IZ	MFH-HH	EFZH-EH	EFZH-DH	EFZH-RH	LH	WGL	ÖG	Summe	UA[%]
Klassifikation	MFH-G	1360	2	2	1	0	0	0	0	0	2	0	1367	99,49
	MFH-F	9	3274	26	0	0	309	14	2	77	53	2	3766	86,94
	MFH-TZ	2	6	2452	5	0	0	0	1	5	3	1	2475	99,07
	MFH-IZ	0	0	0	826	0	0	0	0	0	0	0	826	100,00
	MFH-HH	1	0	0	0	17	0	0	0	0	1	0	19	89,47
	EFZH-EH	0	284	0	0	0	1454	7	0	71	28	2	1846	78,76
	EFZH-DH	0	9	0	0	0	5	978	0	1	3	0	996	98,19
	EFZH-RH	0	0	0	0	0	1	0	942	0	1	0	944	99,79
	LH	3	47	0	0	0	28	4	1	336	17	0	436	77,06
	WGL	6	29	1	0	2	10	2	1	4	6347	8	6410	99,02
	ÖG	0	7	2	0	0	0	0	1	0	11	484	505	95,84
	Summe	1381	3658	2483	832	19	1807	1005	948	494	6466	497	19590	
	PA[%]	98,48	89,50	98,75	99,28	89,47	80,46	97,31	99,37	68,02	98,16	97,38		

Ø OA (σ) in %	94,28	(0,39)
Ø κ (σ)	0,93	(0,00)

Halle – DTK25-V

		Referenzdaten												
		MFH-G	MFH-F	MFH-TZ	MFH-IZ	MFH-HH	EFZH-EH	EFZH-DH	EFZH-RH	LH	WGL	ÖG	Summe	UA[%]
Klassifikation	MFH-G	549	30	41	36	0	21	9	14	9	78	1	788	69,67
	MFH-F	15	258	15	4	0	34	6	1	4	52	2	391	65,98
	MFH-TZ	26	21	554	43	0	12	10	31	3	16	0	716	77,37
	MFH-IZ	17	11	35	461	0	0	0	6	0	16	0	546	84,43
	MFH-HH	0	0	0	0	2	0	0	0	0	0	0	2	100,00
	EFZH-EH	26	198	23	6	0	3086	252	28	213	452	4	4288	71,97
	EFZH-DH	7	26	14	3	0	133	1022	49	24	55	0	1333	76,67
	EFZH-RH	7	5	17	3	0	9	29	384	0	3	0	457	84,03
	LH	10	36	2	5	0	81	28	6	376	119	0	663	56,71
	WGL	132	146	22	26	10	303	62	7	206	3828	5	4747	80,64
	ÖG	7	13	0	5	0	9	0	0	4	0	781	819	95,36
	Summe	796	744	723	592	12	3688	1418	526	839	4619	793	14750	
	PA[%]	68,97	34,68	76,63	77,87	16,67	83,68	72,07	73,00	44,82	82,88	98,49		

Ø OA (σ) in %	76,62	(1,27)
Ø κ (σ)	0,71	(0,02)

Halle – DTK25

		Referenzdaten												
		MFH-G	MFH-F	MFH-TZ	MFH-IZ	MFH-HH	EFZH-EH	EFZH-DH	EFZH-RH	LH	WGL	ÖG	Summe	UA[%]
Klassifikation	MFH-G	521	30	22	27	0	1	6	21	17	52	1	698	74,64
	MFH-F	25	489	11	4	2	51	11	2	19	82	5	701	69,76
	MFH-TZ	8	11	618	23	0	3	6	19	0	6	0	694	89,05
	MFH-IZ	18	5	25	383	0	0	0	5	0	6	1	443	86,46
	MFH-HH	0	0	0	0	2	0	0	0	0	0	0	2	100,00
	EFZH-EH	1	138	3	0	0	4074	60	2	153	266	2	4699	86,70
	EFZH-DH	8	60	12	1	0	138	1612	16	69	85	2	2003	80,48
	EFZH-RH	10	13	17	1	0	7	61	542	3	8	1	663	81,75
	LH	11	32	0	0	0	83	40	6	518	157	0	847	61,16
	WGL	48	128	8	18	8	335	30	4	244	12985	10	13818	93,97
	ÖG	3	10	0	3	0	10	0	0	6	0	1010	1042	96,93
	Summe	653	916	716	460	12	4702	1826	617	1029	13647	1032	25610	
	PA[%]	79,79	53,38	86,31	83,26	16,67	86,64	88,28	87,84	50,34	95,15	97,87		

Ø OA (σ) in %	88,85	(0,44)
Ø κ (σ)	0,83	(0,01)

Halle – ATKIS

		Referenzdaten												
		MFH-G	MFH-F	MFH-TZ	MFH-IZ	MFH-HH	EFZH-EH	EFZH-DH	EFZH-RH	LH	WGL	ÖG	Summe	UA[%]
Klassifikation	MFH-G	5774	30	49	30	0	13	0	2	8	207	7	6120	94,35
	MFH-F	9	771	4	6	0	62	3	1	25	114	2	997	77,33
	MFH-TZ	33	4	2514	0	0	1	4	2	0	11	0	2569	97,86
	MFH-IZ	17	2	0	4436	0	0	0	0	0	30	0	4485	98,91
	MFH-HH	0	0	0	0	12	0	0	0	0	0	0	12	100,00
	EFZH-EH	5	159	6	0	0	4308	19	3	188	317	2	5007	86,04
	EFZH-DH	0	22	3	0	0	46	3792	12	29	45	0	3949	96,02
	EFZH-RH	2	11	5	0	0	3	16	3410	2	8	0	3457	98,64
	LH	9	30	0	0	0	97	10	0	977	182	0	1305	74,87
	WGL	180	203	15	25	1	386	65	11	347	9283	48	10564	87,87
	ÖG	6	13	0	3	0	11	0	0	7	5	1120	1165	96,14
	Summe	6035	1245	2596	4500	13	4927	3909	3441	1583	10202	1179	39630	
	PA[%]	95,68	61,93	96,84	98,58	92,31	87,44	97,01	99,10	61,72	90,99	95,00		

Ø OA (σ) in %	91,84	(0,45)
Ø κ (σ)	0,90	(0,01)

Krefeld – DTK25-V

		Referenzdaten												
		MFH-G	MFH-F	MFH-TZ	MFH-IZ	MFH-HH	EFZH-EH	EFZH-DH	EFZH-RH	LH	WGL	ÖG	Summe	UA[%]
Klassifikation	MFH-G	12	0	0	0	0	0	0	6	0	2	0	20	60,00
	MFH-F	0	15	0	0	0	0	0	1	0	2	0	18	83,33
	MFH-TZ	0	0	28	1	3	0	0	2	0	1	0	35	80,00
	MFH-IZ	0	0	0	4	0	0	1	0	0	1	0	6	66,67
	MFH-HH	0	0	0	0	3	0	0	0	0	1	0	4	75,00
	EFZH-EH	0	0	0	0	0	156	23	4	0	11	0	194	80,41
	EFZH-DH	0	3	2	0	2	19	121	7	0	3	1	158	76,58
	EFZH-RH	9	0	3	3	0	7	5	76	2	5	0	110	69,09
	LH	0	0	0	0	0	0	0	0	5	0	0	5	100,00
	WGL	2	1	0	1	2	2	2	3	3	65	4	85	76,47
	ÖG	0	0	0	0	0	0	0	0	0	0	5	5	100,00
	Summe	23	19	33	9	10	184	152	99	10	91	10	640	
	PA[%]	52,17	78,95	84,85	44,44	30,00	84,78	79,61	76,77	50,00	71,43	50,00		

Ø OA (σ) in % 76,56 (6,91)
Ø κ (σ) 0,71 (0,09)

Krefeld – DTK25

		Referenzdaten												
		MFH-G	MFH-F	MFH-TZ	MFH-IZ	MFH-HH	EFZH-EH	EFZH-DH	EFZH-RH	LH	WGL	ÖG	Summe	UA[%]
Klassifikation	MFH-G	110	4	4	0	0	2	1	12	0	8	2	143	76,92
	MFH-F	0	54	6	0	1	4	1	0	0	11	1	78	69,23
	MFH-TZ	3	15	269	23	1	6	6	9	0	6	0	338	79,59
	MFH-IZ	0	2	5	63	0	1	0	1	0	0	0	72	87,50
	MFH-HH	0	3	0	0	30	0	0	0	0	1	0	34	88,24
	EFZH-EH	4	55	34	7	10	1541	131	16	13	96	5	1912	80,60
	EFZH-DH	13	27	30	1	4	238	1091	129	6	16	0	1555	70,16
	EFZH-RH	29	17	43	7	2	31	174	907	0	16	3	1229	73,80
	LH	0	0	0	0	0	0	0	0	3	2	0	5	60,00
	WGL	4	16	7	4	3	38	12	3	17	874	0	978	89,37
	ÖG	0	2	0	0	0	5	0	1	0	0	118	126	93,65
	Summe	163	195	398	105	51	1866	1416	1078	39	1030	129	6470	
	PA[%]	67,48	27,69	67,59	60,00	58,82	82,58	77,05	84,14	7,69	84,85	91,47		

Ø OA (σ) in % 78,21 (2,16)
Ø κ (σ) 0,73 (0,03)

Krefeld – ATKIS (simuliert aus 3D-GS)

		Referenzdaten												
		MFH-G	MFH-F	MFH-TZ	MFH-IZ	MFH-HH	EFZH-EH	EFZH-DH	EFZH-RH	LH	WGL	ÖG	Summe	UA[%]
Klassifikation	MFH-G	3120	3	7	9	0	9	0	39	3	187	10	3387	92,12
	MFH-F	6	210	15	1	3	22	2	8	0	13	0	280	75,00
	MFH-TZ	5	27	849	21	4	3	4	12	0	14	2	941	90,22
	MFH-IZ	2	2	5	218	1	0	0	0	0	3	0	231	94,37
	MFH-HH	0	1	0	0	29	0	0	0	0	1	0	31	93,55
	EFZH-EH	4	78	3	1	0	3078	86	15	4	95	7	3371	91,31
	EFZH-DH	2	15	4	0	0	122	4645	20	0	60	0	4868	95,42
	EFZH-RH	27	14	18	0	0	13	24	6385	0	38	2	6521	97,91
	LH	0	0	0	0	0	0	0	0	38	1	0	39	97,44
	WGL	183	22	11	5	2	143	109	59	6	5448	11	5999	90,82
	ÖG	5	0	0	0	0	2	0	0	0	1	364	372	97,85
	Summe	3354	372	912	255	39	3392	4870	6538	51	5861	396	26040	
	PA[%]	93,02	56,45	93,09	85,49	74,36	90,74	95,38	97,66	74,51	92,95	91,92		

Ø OA (σ) in %	93,64	(0,51)
Ø κ (σ)	0,92	(0,01)

Krefeld – ALK (simuliert aus 3D-GS)

		Referenzdaten												
		MFH-G	MFH-F	MFH-TZ	MFH-IZ	MFH-HH	EFZH-EH	EFZH-DH	EFZH-RH	LH	WGL	ÖG	Summe	UA[%]
Klassifikation	MFH-G	3099	8	10	5	0	4	5	40	1	178	9	3359	92,26
	MFH-F	6	223	14	1	2	24	5	8	0	13	0	296	75,34
	MFH-TZ	5	32	844	17	4	3	2	9	0	11	2	929	90,85
	MFH-IZ	2	4	7	227	1	0	0	0	0	2	0	243	93,42
	MFH-HH	0	1	0	0	31	0	0	0	0	0	0	32	96,88
	EFZH-EH	3	64	2	0	0	3175	43	13	7	117	4	3428	92,62
	EFZH-DH	7	8	7	1	0	48	4712	23	0	49	0	4855	97,05
	EFZH-RH	24	10	21	0	0	12	24	6397	1	35	1	6525	98,04
	LH	0	0	0	0	0	0	0	0	36	1	0	37	97,30
	WGL	201	22	7	4	1	124	80	49	6	5454	12	5960	91,51
	ÖG	6	0	0	0	0	2	0	0	0	0	368	376	97,87
	Summe	3353	372	912	255	39	3392	4871	6539	51	5860	396	26040	
	PA[%]	92,42	59,95	92,54	89,02	79,49	93,60	96,74	97,83	70,59	93,07	92,93		

Ø OA (σ) in %	94,34	(0,33)
Ø κ (σ)	0,93	(0,00)

Krefeld – 3D-GS

		Referenzdaten												
		MFH-G	MFH-F	MFH-TZ	MFH-IZ	MFH-HH	EFZH-EH	EFZH-DH	EFZH-RH	LH	WGL	ÖG	Summe	UA[%]
Klassifikation	MFH-G	3147	12	8	9	0	4	4	30	1	140	7	3362	93,60
	MFH-F	8	236	13	1	1	19	5	3	0	11	0	297	79,46
	MFH-TZ	3	31	848	18	4	3	0	8	0	6	1	922	91,97
	MFH-IZ	3	4	5	225	1	0	0	0	0	0	0	238	94,54
	MFH-HH	0	0	0	0	32	0	0	0	0	0	0	32	100,00
	EFZH-EH	1	46	2	0	0	3168	45	13	5	96	4	3380	93,73
	EFZH-DH	9	9	17	0	0	58	4711	30	2	50	0	4886	96,42
	EFZH-RH	20	13	14	0	0	10	22	6403	1	30	1	6514	98,30
	LH	0	0	0	0	0	0	0	0	34	0	0	34	100,00
	WGL	160	21	5	2	1	127	84	52	8	5525	12	5997	92,13
	ÖG	3	0	0	0	0	3	0	0	0	1	371	378	98,15
	Summe	3354	372	912	255	39	3392	4871	6539	51	5859	396	26040	
	PA[%]	93,83	63,44	92,98	88,24	82,05	93,40	96,72	97,92	66,67	94,30	93,69		

Ø OA (σ) in %	94,85	(0,28)
Ø κ (σ)	0,94	(0,00)

Stolpen – DTK25-V

		Referenzdaten										
		MFH-G	MFH-F	MFH-TZ	EFZH-EH	EFZH-DH	EFZH-RH	LH	WGL	ÖG	Summe	UA[%]
Klassifikation	MFH-G	12	1	1	0	0	1	3	0	0	18	66,67
	MFH-F	1	57	2	8	1	2	4	12	0	87	65,52
	MFH-TZ	0	0	0	0	0	0	0	0	0	0	#
	EFZH-EH	0	8	0	37	6	0	3	2	0	56	66,07
	EFZH-DH	0	1	0	1	4	0	0	0	0	6	66,67
	EFZH-RH	1	0	0	1	0	9	0	0	0	11	81,82
	LH	1	1	0	3	0	0	1	1	0	7	14,29
	WGL	0	6	0	3	0	0	1	22	0	32	68,75
	ÖG	0	0	0	0	0	0	0	0	13	13	100,00
	Summe	15	74	3	53	11	12	12	37	13	230	
	PA[%]	80,00	77,03	0,00	69,81	36,36	75,00	8,33	59,46	100,00		

Ø OA (σ) in %	67,39	(11,46)
Ø κ (σ)	0,57	(0,15)

Stolpen – ATKIS

		Referenzdaten										
		MFH-G	MFH-F	MFH-TZ	EFZH-EH	EFZH-DH	EFZH-RH	LH	WGL	ÖG	Summe	UA[%]
Klassifikation	MFH-G	86	2	1	0	0	4	0	5	2	100	86,00
	MFH-F	0	52	1	13	3	1	6	6	0	82	63,41
	MFH-TZ	0	0	0	0	0	0	0	0	0	0	#
	EFZH-EH	0	12	0	51	6	0	5	5	0	79	64,56
	EFZH-DH	0	2	0	2	11	0	1	0	0	16	68,75
	EFZH-RH	3	0	1	1	0	8	1	0	0	14	57,14
	LH	0	1	0	1	0	0	5	0	1	8	62,50
	WGL	3	5	0	3	1	1	0	42	1	56	75,00
	ÖG	1	0	0	0	0	0	1	1	12	15	80,00
	Summe	93	74	3	71	21	14	19	59	16	370	
	PA[%]	92,47	70,27	0,00	71,83	52,38	57,14	26,32	71,19	75,00		

Ø OA (σ) in %	72,16	(9,01)
Ø κ (σ)	0,65	(0,12)

Stolpen – ALK

		Referenzdaten										
		MFH-G	MFH-F	MFH-TZ	EFZH-EH	EFZH-DH	EFZH-RH	LH	WGL	ÖG	Summe	UA[%]
Klassifikation	MFH-G	106	1	1	0	0	0	0	1	1	110	96,36
	MFH-F	2	54	0	11	1	0	5	4	1	78	69,23
	MFH-TZ	0	0	2	0	0	0	0	0	0	2	100,00
	EFZH-EH	0	9	0	46	1	0	3	4	0	63	73,02
	EFZH-DH	0	1	0	0	24	2	0	0	0	27	88,89
	EFZH-RH	0	0	1	0	4	48	1	0	0	54	88,89
	LH	0	3	0	1	0	0	6	0	0	10	60,00
	WGL	3	1	0	1	0	1	0	59	1	66	89,39
	ÖG	0	0	0	0	0	0	0	3	17	20	85,00
	Summe	111	69	4	59	30	51	15	71	20	430	
	PA[%]	95,50	78,26	50,00	77,97	80,00	94,12	40,00	83,10	85,00		

Ø OA (σ) in %	84,19	(4,36)
Ø κ (σ)	0,81	(0,05)

Dörfliches Gebiet – DTK25-V

		Referenzdaten								
		MFH-F	EFZH-EH	EFZH-DH	EFZH-RH	LH	WGL	ÖG	Summe	UA[%]
Klassifikation	MFH-F	29	15	0	0	19	10	0	73	39,73
	EFZH-EH	28	113	7	1	30	23	0	202	55,94
	EFZH-DH	0	1	7	0	0	1	0	9	77,78
	EFZH-RH	0	0	0	1	0	0	0	1	100,00
	LH	51	33	2	1	147	29	0	263	55,89
	WGL	6	25	0	0	34	92	0	157	58,60
	ÖG	1	0	0	1	0	0	23	25	92,00
	Summe	115	187	16	4	230	155	23	730	
	PA[%]	25,22	60,43	43,75	25,00	63,91	59,35	100,00		

Ø OA (σ) in %	56,44	(7,04)
Ø κ (σ)	0,42	(0,10)

Dörfliches Gebiet – ATKIS

		Referenzdaten								
		MFH-F	EFZH-EH	EFZH-DH	EFZH-RH	LH	WGL	ÖG	Summe	UA[%]
Klassifikation	MFH-F	50	17	1	2	21	12	1	104	48,08
	EFZH-EH	37	195	7	0	34	17	2	292	66,78
	EFZH-DH	1	0	7	0	0	0	0	8	87,50
	EFZH-RH	0	0	0	4	0	0	0	4	100,00
	LH	48	31	6	0	171	40	4	300	57,00
	WGL	6	17	1	0	34	138	6	202	68,32
	ÖG	0	0	0	1	0	0	9	10	90,00
	Summe	142	260	22	7	260	207	22	920	
	PA[%]	35,21	75,00	31,82	57,14	65,77	66,67	40,91		

Ø OA (σ) in %	62,39	(3,41)
Ø κ (σ)	0,50	(0,04)

Dörfliches Gebiet – ALK

		Referenzdaten								
		MFH-F	EFZH-EH	EFZH-DH	EFZH-RH	LH	WGL	ÖG	Summe	UA[%]
Klassifikation	MFH-F	92	16	2	0	31	6	3	150	61,33
	EFZH-EH	22	137	2	0	26	14	1	202	67,82
	EFZH-DH	0	0	24	0	0	0	0	24	100,00
	EFZH-RH	0	1	0	33	1	0	0	35	94,29
	LH	39	22	1	0	211	19	0	292	72,26
	WGL	0	3	0	0	7	289	1	300	96,33
	ÖG	1	1	0	0	0	0	25	27	92,59
	Summe	154	180	29	33	276	328	30	1030	
	PA[%]	59,74	76,11	82,76	100,00	76,45	88,11	83,33		

Ø OA (σ) in %	78,74	(5,09)
Ø κ (σ)	0,72	(0,07)

E.2. Produzenten- und Nutzergenauigkeit nach Eingangsdatentyp

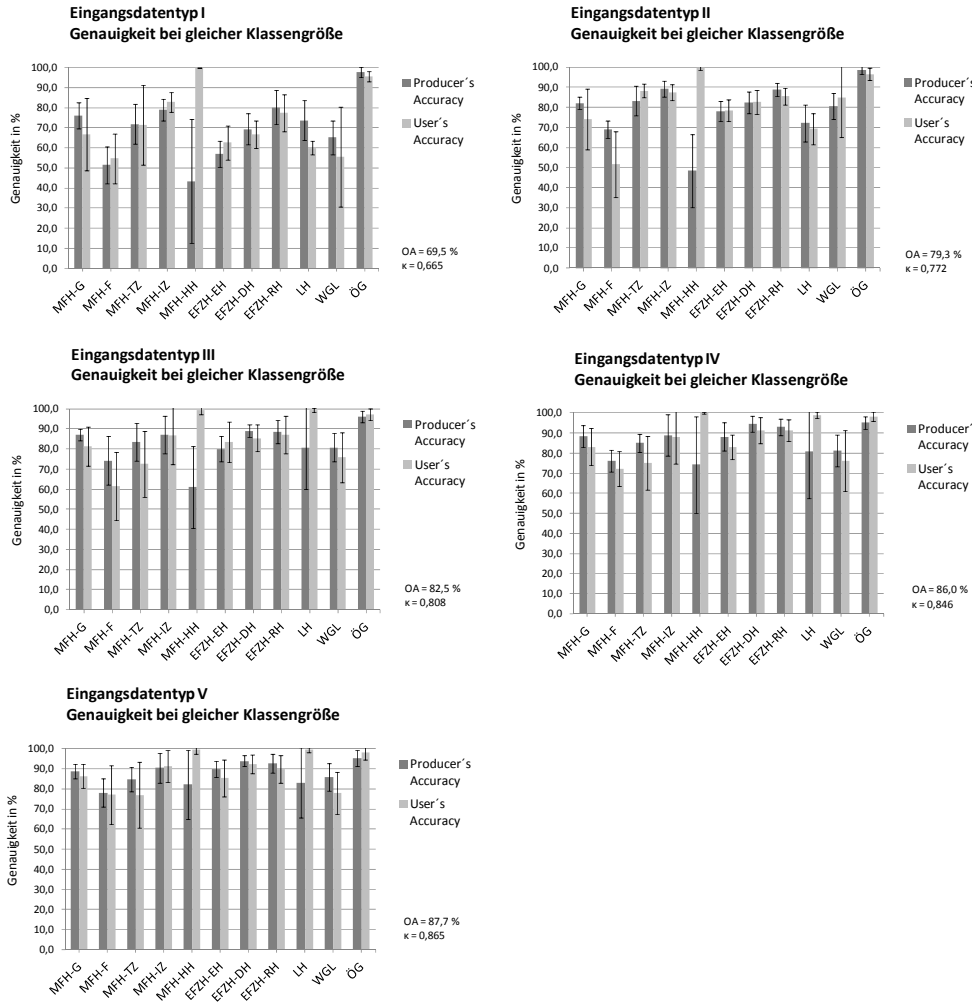

Abb. E-1: Klassenspezifische Genauigkeit verschiedener Eingangsdatentypen durch 10-fach wiederholtes Training und Testen anhand von 250 Trainings- und 250 Testobjekten pro Klasse (Fehlerbalken gibt 2σ an).

E.3. Ergebnisse der automatischen Klassifizierung am Beispiel von Halle

Die folgenden Karten zeigen das Ergebnis der Klassifizierung mit Random Forest am Beispiel von Halle.

- Referenzkartierung auf Grundlage der Gebäude aus ATKIS® (Abb. E-2)
- Klassifizierung auf Grundlage der Gebäude der DTK25-V (Abb. E-3)
- Klassifizierung auf Grundlage der Gebäude der DTK25 (Abb. E-4)
- Klassifizierung auf Grundlage der Gebäude der ATKIS® (Abb. E-5)

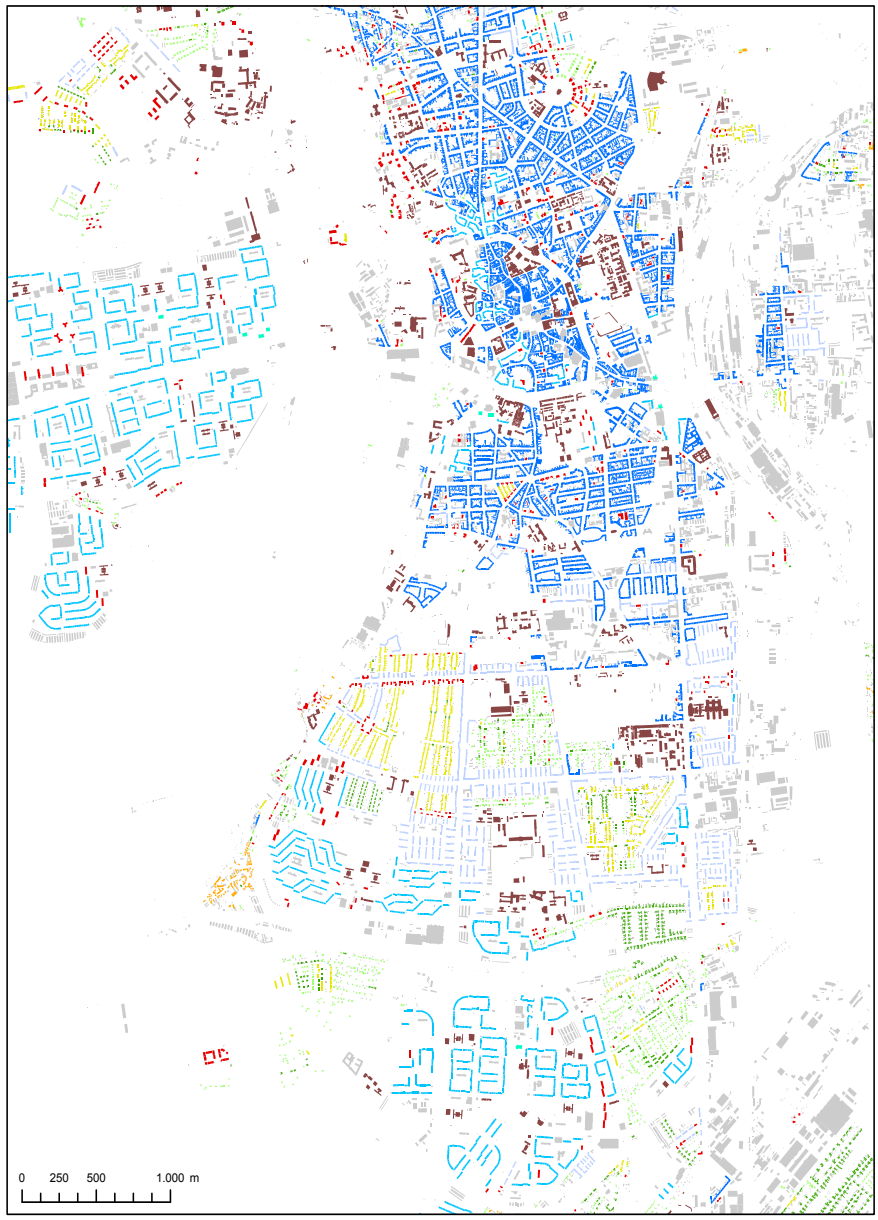

Abb. E-2: Referenzkartierung von Halle

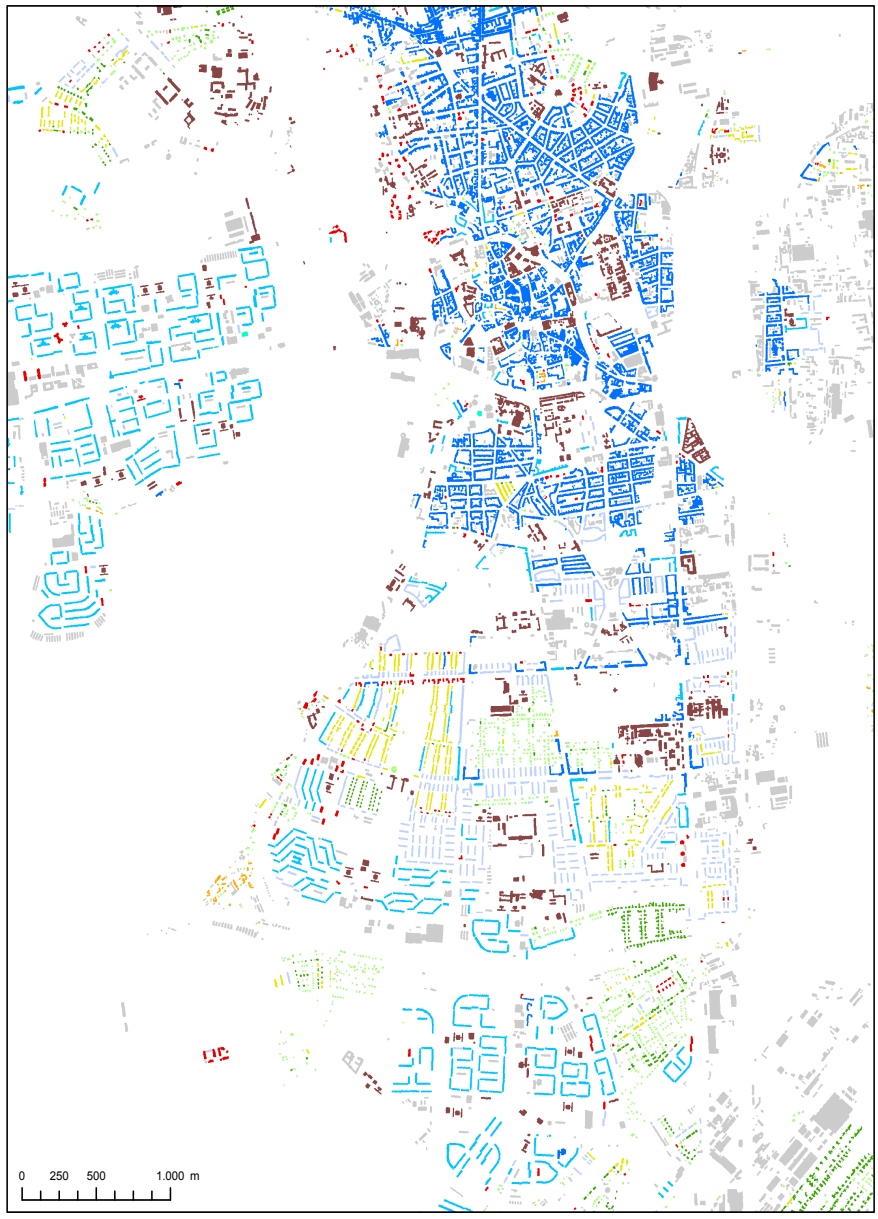

Abb. E-3: Automatisch klassifizierte Gebäudegrundrisse von Halle (Datengrundlage DTK25-V)

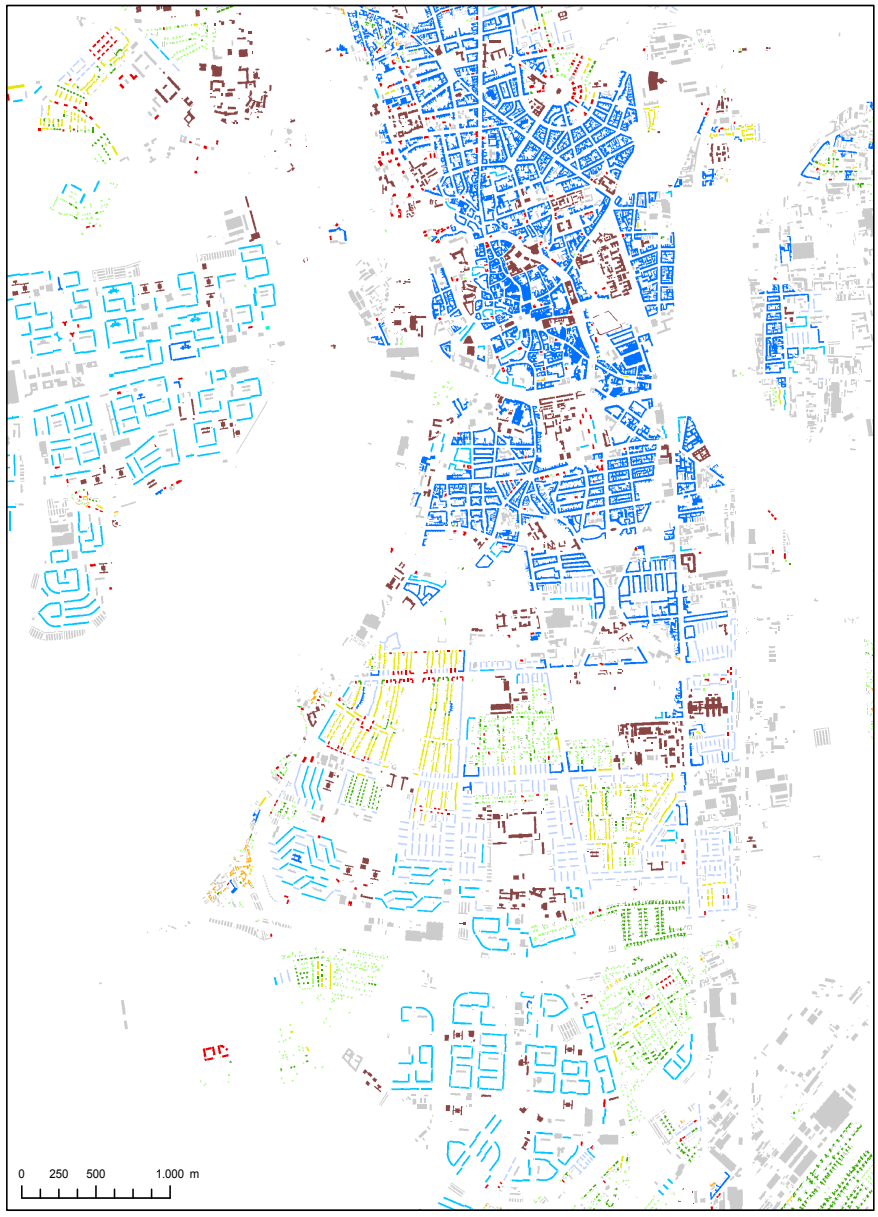

Abb. E-4: Automatisch klassifizierte Gebäudegrundrisse von Halle (Datengrundlage DTK25)

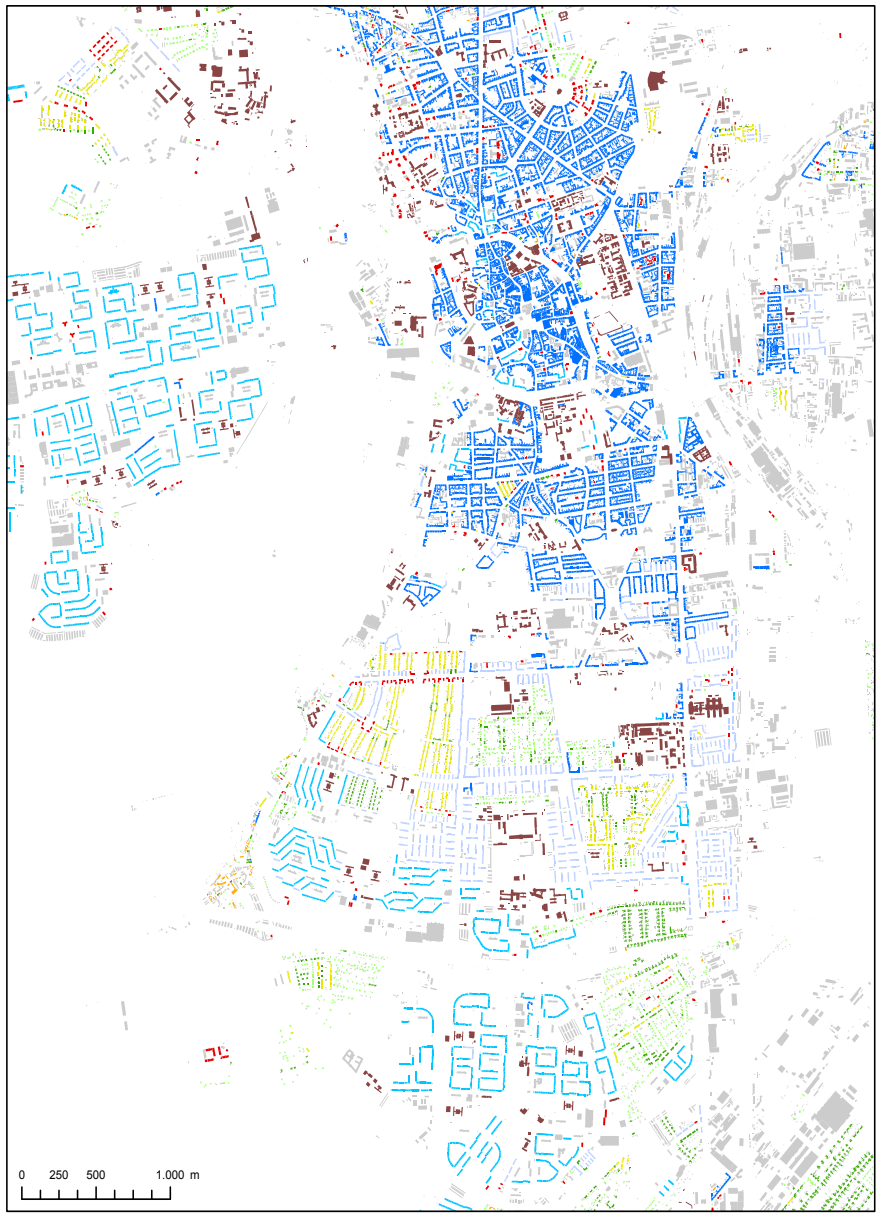

Abb. E-5: Automatisch klassifizierte Gebäudegrundrisse von Halle (Datengrundlage ATKIS®)

F Exemplarische Anwendung von BFClassTool

Im letzten Teil erfolgt eine exemplarische Anwendung des Verfahrens als integrativer Bestandteil einer gebäudebasierten Siedlungsstrukturanalyse. Am Beispiel der Stadt Krefeld werden unter Einsatz von BFClassTool ausgewählte siedlungsstrukturelle Merkmale automatisiert abgeleitet und in Karten visualisiert. Im zweiten Teil wird das Verfahren eingesetzt, um Bebauungsstrukturtypen am Beispiel der Region von Dresden automatisch abzuleiten.

F.1. Gebäudebasierte Analyse der Siedlungsstruktur

Eine klassifizierte Gebäudemenge erlaubt im GIS die Ableitung siedlungsstruktureller Merkmale auf beliebigen räumlichen Ebenen. Automatisierte Ansätze auf Grundlage von Gebäude(regionen) aus topographischen Karten wurden bereits vorgestellt (Meinel et al., 2008a). Ausgangspunkt für folgende Analyse bilden klassifizierte Gebäudegrundrisse in Einzelgebäuderepräsentation sowie eine Baublockabgrenzung als räumlicher Bezug für die abgeleiteten Kennzahlen. Die Ergebnisse werden in Form von Karten in Abb. F-2 bis Abb. F-7 präsentiert.

F.1.1 Grundlagen der Berechnung

Bei den siedlungsstrukturellen Kennzahlen lassen sich primäre und sekundäre siedlungsstrukturelle Merkmale unterscheiden. Die primären siedlungsstrukturellen Merkmale lassen sich unmittelbar am Gebäudegrundriss ableiten. Ein Mustererkennungsprozess ist in diesem Falle nicht nötig. Ein derartiges Merkmal ist beispielsweise der Überbauungsgrad oder die Gebäudedichte. Die sekundären siedlungsstrukturellen Merkmale sind hingegen von der vorliegenden morphologischen Struktur abhängig und können erst über die Schnittstelle eines Gebäudetyps und einem daran gekoppelten Mengengerüst berechnet werden. Für eine Ableitung dieser ist eine Gebäudeklassifizierung nötig.

In der Tab. F-1 sind ausgewählte siedlungsstrukturelle Merkmale und deren Berechnungsvorschriften [99] dargestellt. Für die Modellierung der sekundären siedlungsstrukturellen Merkmale werden die jeweils in der letzten Spalte angegebenen gebäudetypischen Annahmen benötigt.

Der Überbauungsgrad ist eine Zahl, mit der das Verhältnis zwischen bebauter und unbebauter Fläche in Bezug zu einer Siedlungseinheit angegeben wird. Mit Bezug auf ein Grundstück entspricht diese der Grundflächenzahl, dem in der Baunutzungsverordnung (BauNVO) angegebenen Maß der baulichen Nutzung mit dem festgelegt wird, wie viel

[99] Die Berechnungsvorschriften folgen den Ansätzen aus Meinel et al. (2008a) mit dem Unterschied, dass die Einwohner- und Wohnungsdichte über empirisch ermittelte grundflächenbezogene Dichten, wie die Einwohnergrundflächendichte (EGD) bzw. die Wohnungsgrundflächendichte (WGD), realisiert wurde.

Quadratmeter Grundfläche je Quadratmeter Grundstücksfläche bebaut werden dürfen (Müller & Korda, 1999). Da die Bezugseinheit eine von der Grundstücksfläche abweichende Siedlungseinheit darstellt, wird hier vom „Überbauungsgrad" gesprochen. In der Regel ist die Siedlungseinheit der Baublock (streng genommen der Bruttobaublock), kann jedoch auch Element eines regelmäßigen Rasters sein. Die bebaute Fläche wird durch Aggregation und Summenbildung aller Gebäudegrundflächen (einschließlich der kleinen Nebengebäude) ermittelt und ins Verhältnis zur Bezugsfläche gesetzt. Da Gebäude aus topographischen Kar-Karten teilweise vergrößert dargestellt sind, ist hierfür eine gebäudetypische Flächenkorrektur angebracht.

Tab. F-1: Siedlungsstrukturelle Merkmale und deren Berechnung unter gebäudetypischen Annahmen

Merkmale der Siedlungsstruktur		Berechnung in Bezug auf eine Bezugsfläche (Raster, Baublock, Stadtteil, Stadt, Region)	Einheit	Berechnung	Gebäudetypische Annahmen
primäre Merkmale	Überbauungsgrad (UG), auch Grundflächendichte	Summe der Gebäudegrundflächen (F_G) pro Bezugsfläche (F_B)	o.E.	$UG = \frac{\sum F_G}{F_B}$	-
	Gebäudedichte (GD)	Gebäudeanzahl (A_G) pro Bezugsfläche (F_B)	1/m²	$GD = \frac{A_G}{F_B}$	-
sekundäre Merkmale	Geschossflächendichte (GFD)	Summe der Geschossfläche (GF) aller Gebäude pro Bezugsfläche (F_B) mit $GF = F_G G_Z$	o.E.	$GFD = \frac{\sum F_G G_Z}{F_B}$	Geschosszahl (G_Z)
	Gebäudevolumen (GV)	Summe des Gebäudevolumens (GV) aller Gebäude pro Bezugsfläche (F_B) mit $GV = F_G G_Z G_H$ oder $GV = F_G H$	m³/m²	$GV = \frac{\sum F_G G_Z G_H}{F_B}$	G_Z und Geschosshöhe (G_H) oder nur Gebäudehöhe (H)
	Wohnungsdichte (WD), auch Bruttowohndichte	Summe der Wohnungszahl (WO) aller Gebäude pro Bezugsfläche mit $WO = \frac{F_G G_Z}{U_F W_G}$, Wohnfläche pro Gebäude $WF = \frac{F_G G_Z}{U_F}$	1/ha	$WD = \frac{\sum F_G G_Z}{U_F W_G F_B}$	Wohnungsgröße (W_G), Geschosszahl (G_Z), Umrechnungsfaktor* (U_F)
	Einwohnerdichte (ED)	Summe der Einwohner (EW) aller Gebäude pro Bezugsfläche mit $EW = \frac{F_G G_Z B}{U_F W_G}$	1/ha	$ED = \frac{\sum F_G G_Z B}{U_F W_G F_B}$	Wohnungsgröße (W_G), Geschosszahl (G_Z), Umrechnungsfaktor* (U_F), Einwohnerbelegung (B)

* Umrechnungsfaktor: Geschossfläche/Wohnfläche = 1,25

Die Gebäudedichte beschreibt die Anzahl der Gebäude pro Bezugsfläche. Bilanziert man im Sinne der Gebäudestatistik sollten nur die Hauptgebäude betrachtet werden. Bei Einzelgebäudedaten müssen deshalb kleine Nebengebäude außer Acht gelassen oder gesondert bilanziert werden (vgl. Behnisch et al., 2012). Für Gebäude(regionen) aus topographischen Karten muss die spezielle Repräsentationsform berücksichtigt werden. Für Gebäudegruppen ergibt sich die Gebäudeanzahl aus der Anzahl der Gebäudeadressen pro Gebäuderegion. Liegen keine Gebäudeadressen vor, so muss die Gebäudeanzahl pro Gebäuderegion über gebäudetypische Hauseingangsabstände abgeschätzt werden (Meinel et al., 2009).

Für die Berechnung der baublockbezogenen Geschossflächendichte müssen gebäudetypische Annahmen zur Geschosszahl gemacht werden, wenn keine explizite Höhe gegeben ist. Im Gegensatz zur Geschossflächenzahl (GZF), die ein Maß der baulichen Nutzung in der Bauleitplanung ist, hat sich der Begriff der Geschossflächendichte auch als gängige städtebauliche Kenngröße etabliert, mit der das Verhältnis der Geschossfläche zum Bruttowohnbauland (z. B. Baublockfläche) beschrieben werden kann. Für eine Berechnung wird die Geschossfläche aller Gebäude im Baublock aufsummiert und ins Verhältnis zur Baublockfläche gesetzt. Die Geschossfläche ist die „Summe der nach den Außenmaßen der Gebäude in allen Vollgeschossen ermittelten Flächen", jedoch ohne Balkone und Terrassen (Müller & Korda, 1999: S. 109). Für eine Berechnung werden deshalb nur Gebäudegrundrisse ausschließlich den kleinen Nebengebäuden verwendet. Gebäudetypische Annahmen zur Geschosszahl können entweder der Literatur entnommen oder mittels empirischen Erhebungen gewonnen werden (vgl. Meinel et al., 2008a).

Das (beheizte) Gebäudevolumen (GV) ist ein Begriff der Energiesparverordnung und ist das von der wärmeübertragenden Hüllfläche eines Gebäudes umschlossene Volumen (EnEV, 2009). Es setzt sich aus den Außenmaßen des Baukörpers und dem Dach zusammen. Für eine Berechnung ist die Kenntnis der Geschossanzahl (G_Z) bzw. der Gebäudehöhe (H) nötig. Liegt keine Höheninformation vor, kann mit einer gebäudetypischen Annahme zur Geschossanzahl über eine gebäudetypische Annahme zur Geschosshöhe eine Gebäudehöhe abgeschätzt werden. Als Dachform wird in dieser Betrachtung ein Flachdach angenommen, obwohl eine gebäudetypische Annahme zur Dachform und deren Berücksichtigung bei der Volumenberechnung möglich wären. Im Zusammenhang mit der Umfassungsfläche (A) kann das A/V-Verhältnis gebildet werden. Diese Maßzahl dient neben anderen Kenngrößen (Sanierungszustand, Dämmung, Sonneneinstrahlung) zur Berechnung des spezifischen Energiebedarfs pro m³ und ist damit ein wichtiger Indikator zur Beurteilung von Energieeffizienz (Brück et al., 2010; vgl. StMi Bayern, 2010).

Mit der Wohnungsdichte wird die Anzahl an Wohnungen pro Bezugsfläche (WoE/ha) ausgedrückt. Die Berechnung erfolgt über die Summenbildung der Wohnungszahl pro Gebäude. Für die Abschätzung der Wohnungszahl pro Gebäude werden neben Geschosszahl, Annahmen zur gebäudetypischen Wohnungsgröße (W_G) nötig. Betrachtet werden in diesem Fall nur die Wohngebäude. Zur Abschätzung der Wohnfläche pro Gebäude (WF) wird ein Umrechnungsfaktor U_F benötigt, der das Verhältnis von Geschossfläche (GF) zu Wohnfläche (WF) beschreibt. Müller und Korda (1999) geben einen Umrechnungsfaktor von 1,25 an, mit dem sonstige Flächen, wie etwa das aufgehende Mauerwerk oder Treppenräume, heraus gerechnet werden können. Man unterscheidet die Bruttowohnungsdichte und die Nettowohnungsdichte. Letztere bezieht sich nur auf das Grundstück (Nettowohnbauland). Bei Berechnung über den Brutto-Baublock muss streng genommen von der Bruttowohnungsdichte gesprochen werden.

Für eine Abschätzung der Einwohnerdichte (auch Wohndichte) wird ein gebäudetypischer Parameter zur Belegungsziffer (B) benötigt, mit dem die Bewohner pro Wohnung (EW/WoE) beschrieben werden (Müller & Korda, 1999). Mit diesem Parameter können sozialbedingte Unterschiede in der Wohnungsbelegung unterschiedlicher Gebäudetypen be-

rücksichtigt werden. Wie bei der Wohnungsdichte, wird auch hier zwischen Bruttoeinwohner- und Nettoeinwohnerdichte unterschieden.

F.1.2 Beispielrechnung Krefeld

Grundlage für eine beispielhafte Anwendung ist der Gebäudebestand (3D-Gebäudestrukturen) der Stadt Krefeld mit insgesamt 115 200 Gebäuden[100], die mithilfe des entwickelten Verfahrens klassifiziert wurden. Zum Training wurden insgesamt 24 554 Objekte, zur Modellbewertung die restlichen 24 555 Lerndaten verwendet. In die Klassifikation gingen die 87 Merkmale (Eingangsdatentyp V) ein. Es wurden hier jedoch nur die 10 Bebauungsstrukturklassen berücksichtigt, da die ländlichen Hausformen (LH) unterbesetzt sind und für die Modellierung den EZFH-EH zugerechnet wurden. Mit dem Random Forest-Algorithmus wurde eine Gesamtklassifikationsgüte von 92,1 % erreicht.

Für die Berechnung der siedlungsstrukturellen Merkmale auf Baublockebene wurden die in Tab. F-2 gezeigten Annahmen getroffen. Da für die 3D-Gebäudestrukturen die Höhe gegeben ist, kann die Geschosszahl unter Nutzung einer angenommenen Geschosshöhe modelliert werden.

Tab. F-2: Gebäudetypische Annahmen für die Stadt Krefeld (Meinel et al., 2008a; Müller & Korda, 1999)

Gebäudetyp	Geschosshöhe $\mathbf{G_H}$ [m]	Geschosszahl $\mathbf{G_Z}$	Umrechnungsfaktor $\mathbf{U_F}$	Wohnungsgröße $\mathbf{W_G}$ [m²]	Einwohnerbelegung **B** [EW/WO]
MFH-G	3,5	H/G_H	1,25	75	1,9
MFH-F	3,5	H/G_H	1,25	75	1,9
MFH-TZ	3,5	H/G_H	1,25	60	1,9
MFH-IZ	3,5	H/G_H	1,25	60	1,9
MFH-HH	3,5	H/G_H	1,25	60	1,9
EFZH-EH	3,2	H/G_H	1,25	120	2,5
EFZH-DH	3,2	H/G_H	1,25	100	2,5
EFZH-RH	3,5	H/G_H	1,25	100	2,5
WGL	-	1	0	0	0
ÖG	-	1	0	0	0

Die Ergebnisse der berechneten siedlungsstrukturellen Merkmale zum Überbauungsgrad, Gebäudedichte, Geschossflächendichte, Gebäudevolumen sowie zur Wohnungs- und Einwohnerdichte sind kartographisch in Abb. F-2 bis F-7 dargestellt. Im Folgenden sei lediglich ein Blick auf die Modellierung der Einwohner- und Geschossflächendichte geworfen.

[100] Gebäude außerhalb der bebauten Fläche werden nicht betrachtet.

F.1.2.1 Beispiel Einwohnerdichte und Wohnungszahl

Am Beispiel der Einwohnerdichte werden die Modellierungsschritte in Abb. F-1 aufgezeigt. Ausgehend von den Gebäudetypen werden die Einwohnerzahl pro Gebäude bestimmt und auf Ebene der Baublöcke aggregiert. Zur Aggregation können dabei auch andere administrative (Stimmbezirke, Stadtteile) oder geometrische Bezugsflächen (regelmäßiges Raster) verwendet werden.

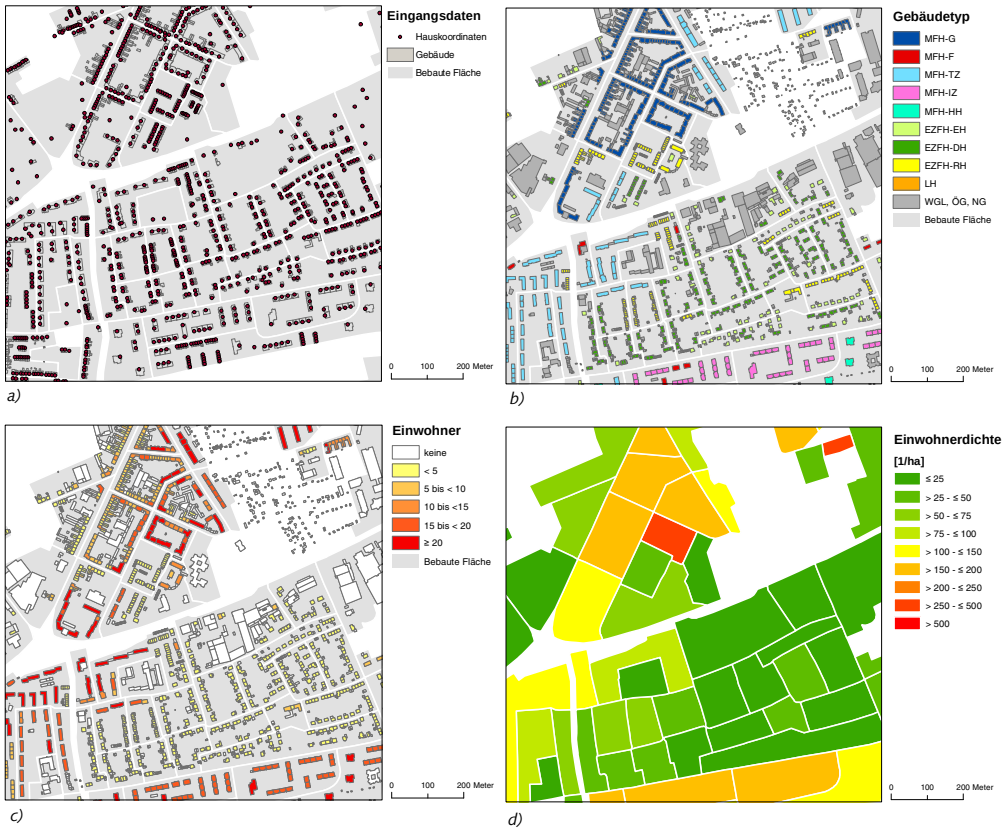

Abb. F-1: Modellierung der Einwohnerdichte: a) Eingangsdaten (3D-Gebäudestrukturen, Baublöcke aus dem ATKIS® Basis-DLM und Hauskoordinaten), b) Gebäudetyp, c) Einwohner pro Gebäude über gebäudetypische Annahmen und d) Aggregation der Einwohnerzahl (Quelle: Eigene Darstellung; Datengrundlage: 3D-Gebäude/ATKIS® Basis-DLM: ©GEObasis.NRW (2009))

Die synthetische Modellierung der Wohnungen und Einwohner ergeben für die Stadt Krefeld 118 545 Wohnungen und 228 159 Einwohner. Nach offiziellen Zahlen der amtlichen Statistik (Stichtag: 31.12.2009) besitzt Krefeld 123 764 Wohnungen und 235 414 Einwohner (Destatis, 2009, 2011a). Die geringe negative Abweichungen von 4,2 % (Wohnungen) und 3,1 % (Einwohner) gegenüber den Zahlen der amtlichen Statistik zeigen, dass eine Abschätzung der Einwohner möglich ist. Durch Abgleich der Wohnungen und Einwohner mit den amtlichen Zahlen auf Gemeindeebene können die Behausungsziffern (EW/Gebäude) durch Anwendung eines Korrekturfaktors korrigiert werden, so dass die Summen den Werten der offiziellen Statistik entsprechen (vgl. Meinel et al., 2008a).

F.1.2.2 Geschossflächendichte

Mit der Geschossflächendichte (GFD) wird das Maß der baulichen Nutzung visualisiert. Damit können Flächen mit hoher Nutzungsintensität von locker bebauten Flächen mit niedriger Nutzungsintensität unterschieden werden. Vor dem Hinblick einer nachhaltigeren Siedlungspolitik, wie die Reduktion der täglichen Flächeninanspruchnahme auf 30 ha bis 2020 und die Nutzung von Innenentwicklungspotenzialen, werden geeignete Instrumente zur Quantifizierung benötigt (Bizer et al., 2011). Eine wichtige Rolle spielt dabei die Geschossflächendichte als Indikator für Nachverdichtungspotenziale. Das Potenzial ist bei geringer Geschossflächendichte größer als bei Baublöcken mit hoher Geschossflächendichte. Durch Kombination mit Bebauungsplänen können Diskrepanzen zwischen baurechtlich zulässiger und realisierter Geschossflächendichte aufgedeckt werden (vgl. Schiller et al., 2009).

Ein vereinfachter Ansatz zur Identifikation von Nachverdichtungspotenzialen ist der Vergleich der Geschossflächendichte im Baublock mit einer für den Baublocktyp gängigen Geschossflächendichte. Als gängige Geschossflächendichte kann die mittlere Geschossflächendichte pro Typ innerhalb einer Stadt angesetzt werden. Durch Visualisierung der Differenz zwischen realer GFD und „möglicher" GFD unter Nutzung der mittleren Dichte des entsprechenden Bebauungsstrukturtyps, können in der Karte (Abb. F-5) Flächen mit hohem (blau) und niedrigem (rot) Verdichtungspotenzial identifiziert werden.

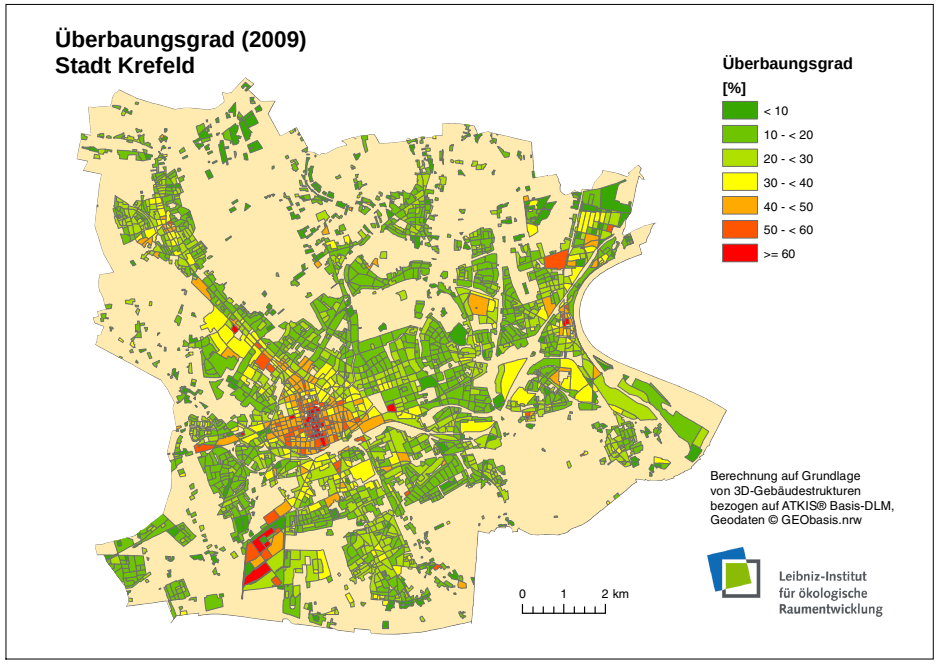

Abb. F-2: Überbauungsgrad der Stadt Krefeld

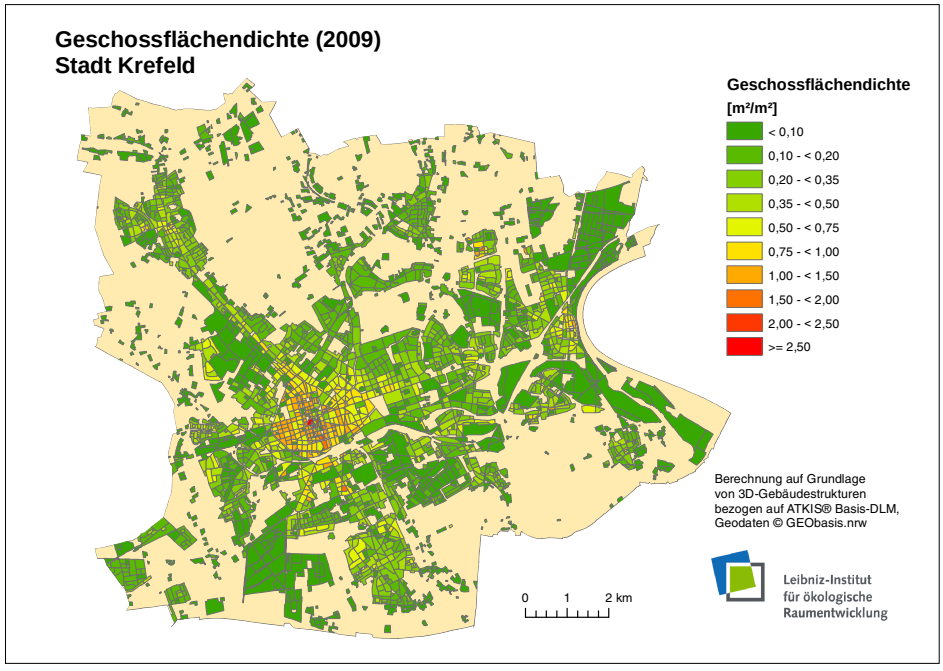

Abb. F-3: Geschossflächendichte der Stadt Krefeld

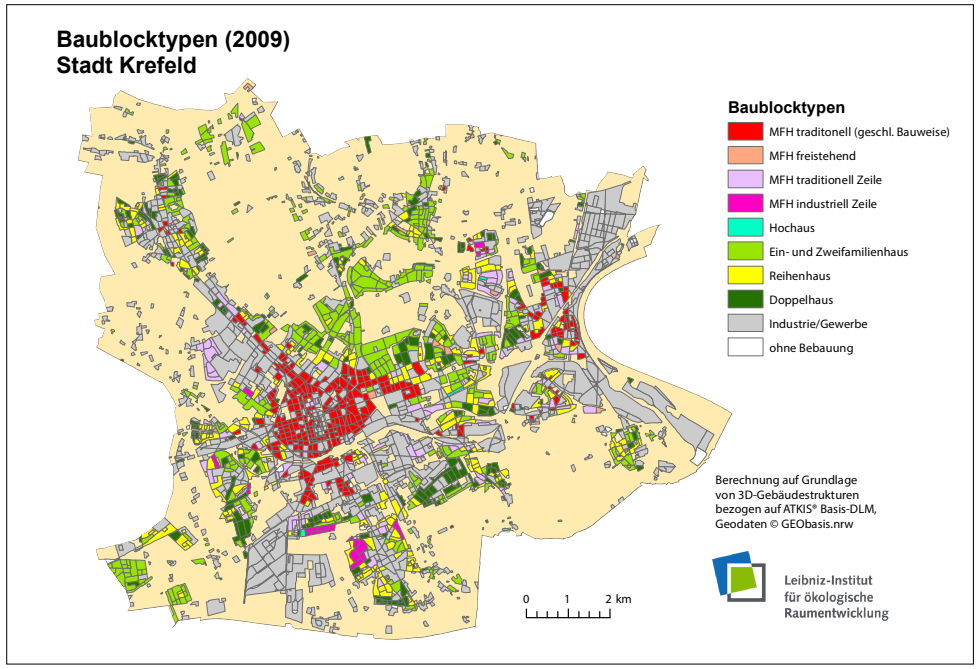

Abb. F-4: Städtebauliche Strukturtypen der Stadt Krefeld

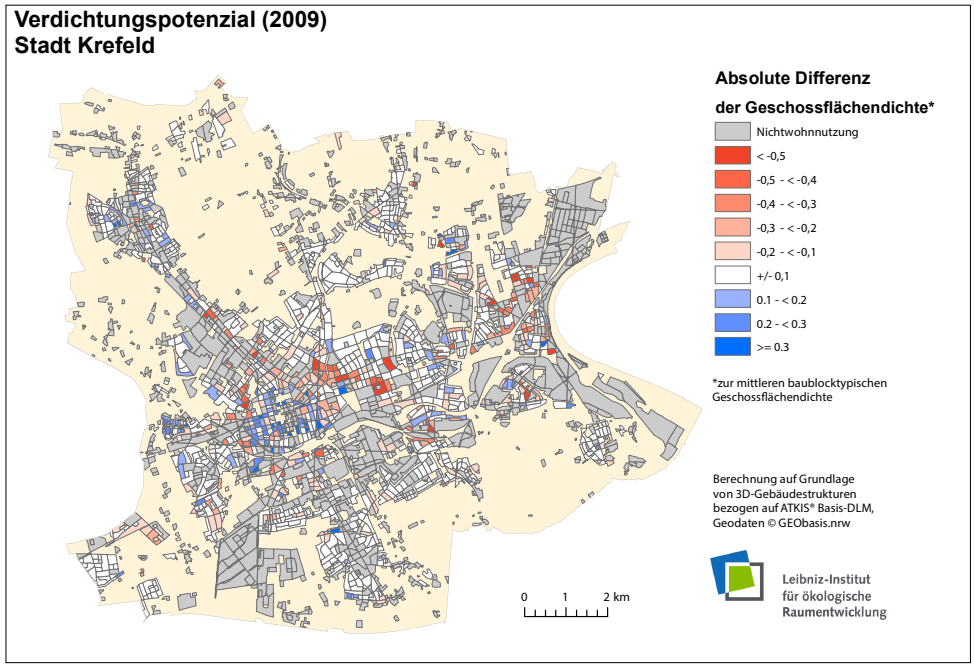

Abb. F-5: Visualisierung von Verdichtungspotenzialen am Beispiel der Stadt Krefeld

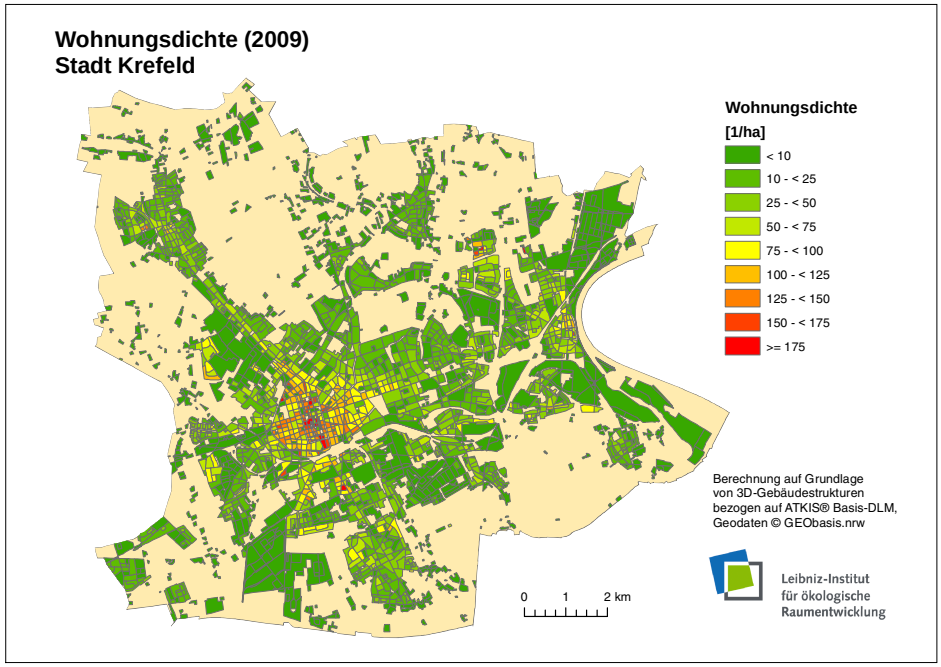

Abb. F-6: Wohnungsdichte der Stadt Krefeld

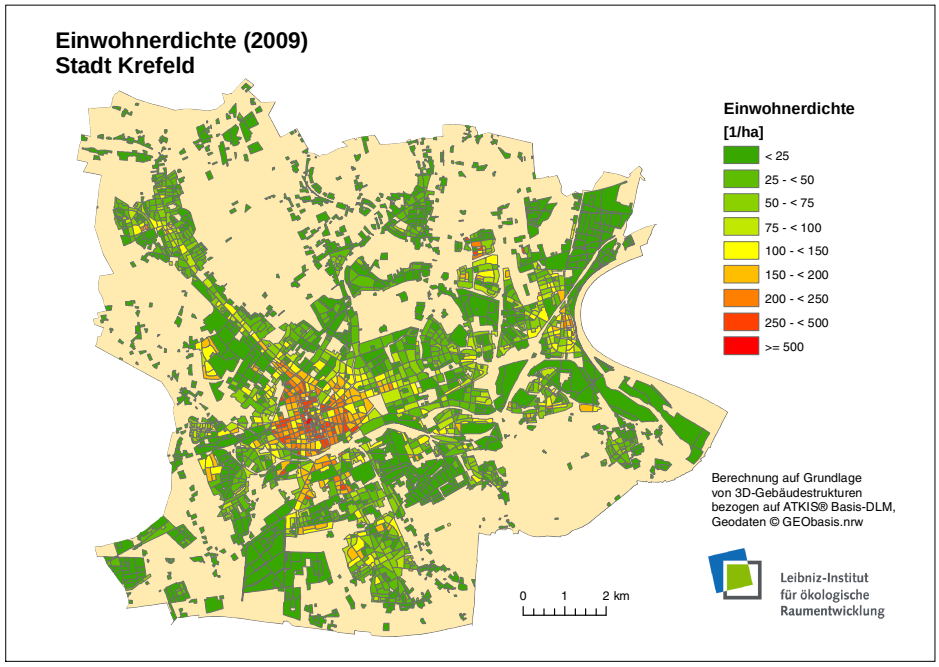

Abb. F-7: Einwohnerdichte der Stadt Krefeld

F.2. Ableitung von Bebauungsstrukturtypen

Stadtstrukturtypen sind Modellierungsbasis für viele Anwendungen in der Stadtforschung. Eine automatische Ableitung kann den Zeitaufwand im Gegensatz zu manuellen Erhebungen auf Grundlage von Luftbildern deutlich verkürzen.

Für die automatische Ableitung von Landnutzungsstrukturen existieren verschiedene Ansätze (Anders et al., 1999; Barnsley & Barr, 1997; Walde et al., 2012). Ein einfaches Verfahren, die räumlich hochaufgelöste Information mit Gebäudebezug in eine Information mit Baublockbezug zu transformieren, ist die Anwendung des Dominanzprinzips, das auch bei der manuellen Erhebung der Flächennutzung auf Grundlage einer Luftbildinterpretation zur Anwendung kommt (Meinel et al., 2008a). Dieser Ansatz folgt der klassischen Annahme eines unmittelbaren Zusammenhanges zwischen dem Gebäudetyp und der städtebaulichen Struktur[101]. Über eine Bestimmung des dominierenden Gebäudetyps im Baublock werden die Gebäudetypen in städtebauliche Bebauungsstrukturtypen überführt. Der dominierende Gebäudetyp kann über die anteilige Gebäudeanzahl oder die anteilig überbaute Fläche im Baublock bestimmt werden. Letzteres eignet sich besser, da damit großflächige Gebäudeformen entsprechend höhere Gewichte zugesprochen bekommen. Die Tab. F-4 fasst die semantische Transformation der Begriffe zusammen, die mit der Aggregation einhergeht.

Tab. F-4: Ableitung von städtebaulichen Strukturtypen mittels Flächendominanzprinzip

Dominierender Gebäudetyp im Baublock		Städtebaulicher Strukturtyp
Abkürzung	Bezeichnung	Bezeichnung
EFZH-EH	Ein- und Zweifamilienhaus als Einzelhaus	Einzelhausbebauung
EFZH-DH	Ein- und Zweifamilienhaus als Doppelhaus	Doppelhausbebauung
EFZH-RH	Ein- und Zweifamilienhaus als Reihenhaus	Reihenhausbebauung
V	Villa	Villenbebauung
MFH-HH	Hochhaus	Hochhausbebauung
MFH-TZ	Mehrfamilienhaus in traditioneller Zeilenbauweise	Traditionelle Zeilenbebauung
MFH-IZ	Mehrfamilienhaus in Plattenbauweise	Industrieller Plattenbau
MFH-G	Mehrfamilienhaus in geschlossener Bauweise	Geschlossese Mehrfamilienhausbebauung
MFH-F	Mehrfamilienhaus in offener Bauweise	Offene Mehrfamilienhausbebauung
MFH-H	Mehrfamilienhaus im historischen Ortskern	Historischer Ortskern
LH	Ländliche Hausform	Dörfliche Bebauung
WGL	Gebäude für Wirtschaft, Gewerbe und Landwirtschaft	Gewerbe- und Industriegebiete
ÖG	Öffentliche Gebäude	Flächen öffentlicher Einrichtungen

Dieser Ansatz wurde im Rahmen des REGKLAM-Projektes für die gesamte Modellregion von Dresden angewandt. Die Region umfasst das Stadtgebiet der Landeshauptstadt Dresden, die umliegenden Landkreise Meißen und Sächsische Schweiz/Osterzgebirge sowie angrenzende Teile der Landkreise Bautzen und Mittelsachsen mit der Stadt Freiberg.

[101] Dies trifft jedoch bei modernen Bebauungsstrukturen nicht immer zu (vgl. Levy, 1999).

Als Eingangsdaten für die Klassifizierung dienten die ALK-Gebäude, Hauskoordinaten und die bebaute Fläche aus dem ATKIS® Basis-DLM. Zum Trainieren des Klassifikators wurden alle vorhandenen Trainingsdatensätze der Region (Dresden, Stolpen, Diera-Zehren, Crostwitz, Rechenberg-Bienenmühle) verwendet und um weitere Referenzobjekte, die über die gesamte Untersuchungsfläche ausgewählt wurden, ergänzt. Am Ende stand ein Datensatz mit 55 119 gelabelten Trainingsobjekten zur Verfügung. Da innerhalb der Region starke Stadt-Land-Disparitäten vorlagen und der Klassifikator für Dresden eine geringe Erkennungsleistung für dörfliche Strukturen zeigte, wurde ein weiteres Merkmal auf Makroebene eingeführt, mit dem die Urbanität über die Größe des Siedlungskörpers beschrieben wird. Für die Berechnung des Merkmals wurden die Ortslagen aus dem ATKIS® Basis-DLM verwendet. Diese beschreiben zusammenhängend bebaute Flächen (AdV, 2008c) und deren Flächengröße wurde jedem Gebäude in Form eines Attributes angehangen. Mit diesem zusätzlichen Merkmal konnten Stadt-Umland-Disparitäten in der Klassifizierung berücksichtigt werden. Die Klassifizierung der 604 087 Gebäude unter Nutzung von Random Forest (200 konstruierte Bäume) erfolgte mit einer Gesamtgenauigkeit von ca. 92 % (OOB-Fehler von 7,3 %).

Das Ergebnis der Klassifizierung kann in den folgenden Karten 1-7 betrachtet werden. Karte 1 zeigt in einer Übersicht die abgeleiteten Bebauungsstrukturtypen für einen Teil der Region. In Detailkarten (Karte 2 bis 7) werden ausgewählte Siedlungen entsprechend der Stadt- und Gemeindetypen (BBSR, 2012b) in größerem Maßstab dargestellt.

- Karte 1: Dresden und sein Umland – Baublockklassifikation
- Karte 2: Dresden – Gebäude- und Baublockklassifikation (Große Großstadt)
- Karte 3: Freiberg – Gebäude- und Baublockklassifikation (Kleinere Mittelstadt)
- Karte 4: Riesa – Gebäude- und Baublockklassifikation (Kleinere Mittelstadt)
- Karte 5: Stolpen – Gebäude- und Baublockklassifikation (Kleine Kleinstadt)
- Karte 6: Lommatzsch – Gebäude- und Baublockklassifikation (Kleine Kleinstadt)
- Karte 7: Ebersbach (bei Großenhain) – Gebäude- und Baublockklassifikation (Landgemeinde)

Karte 1
Dresden und sein Umland: Baublockklassifikation

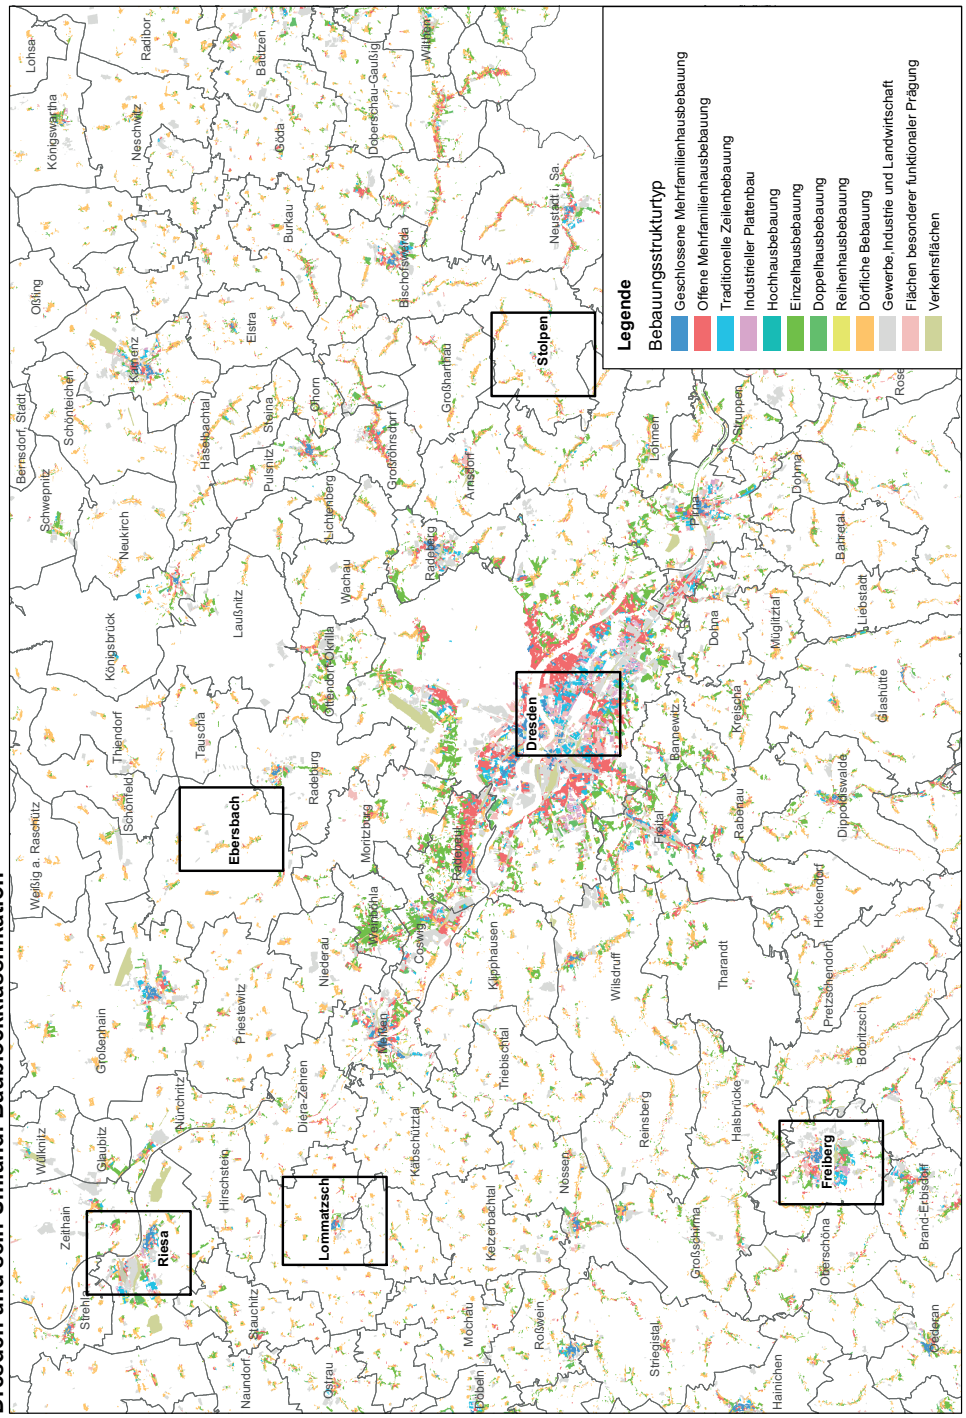

Karte 2

Dresden: Gebäude- und Baublockklassifikation

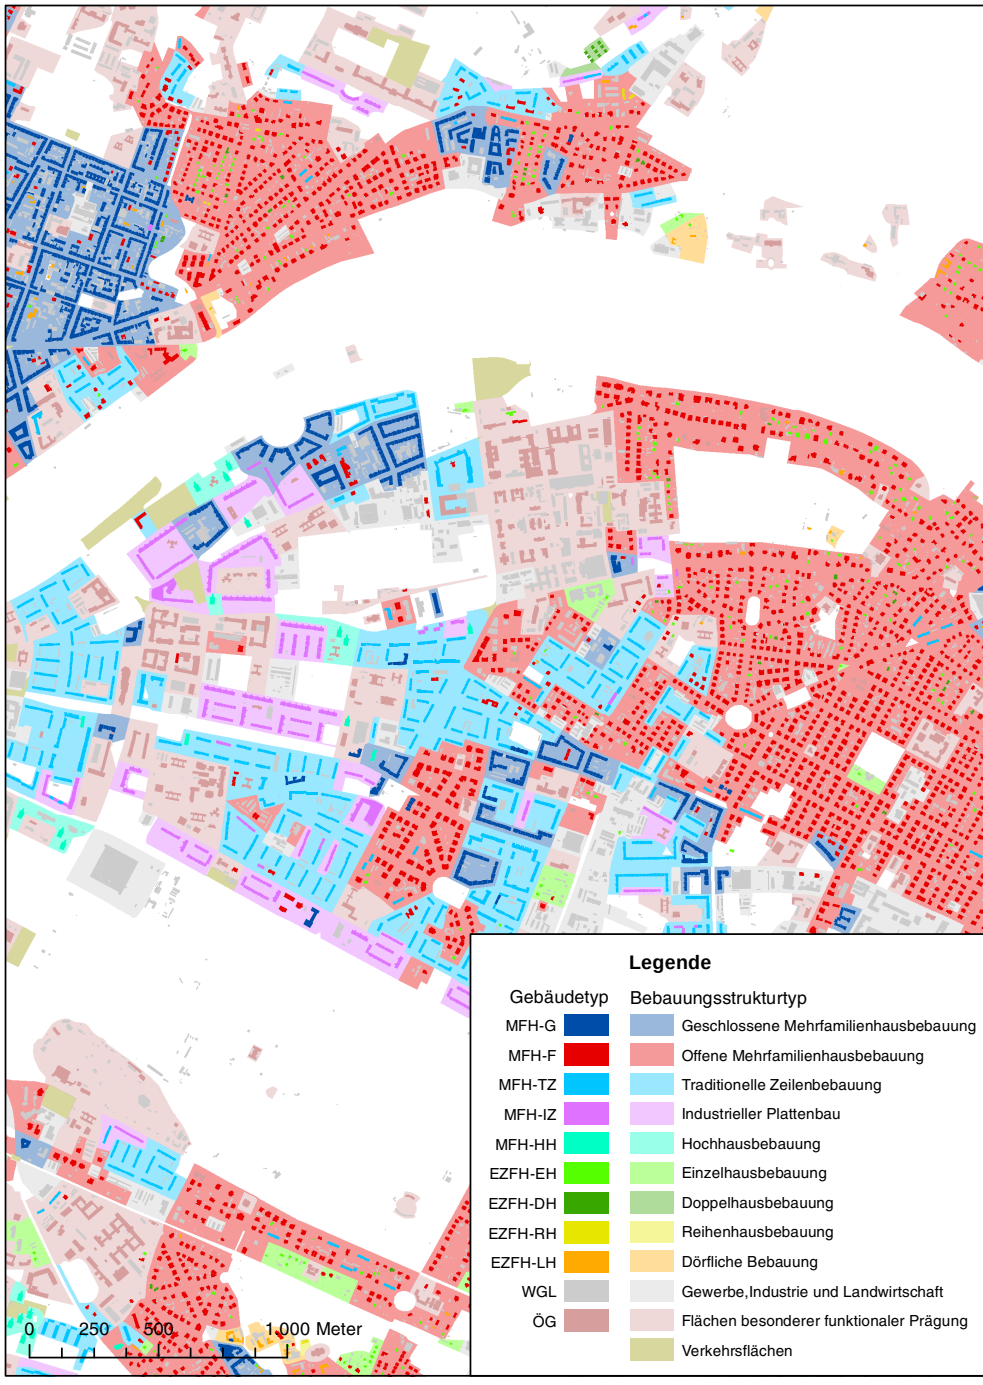

Karte 3

Freiberg: Gebäude- und Baublockklassifikation

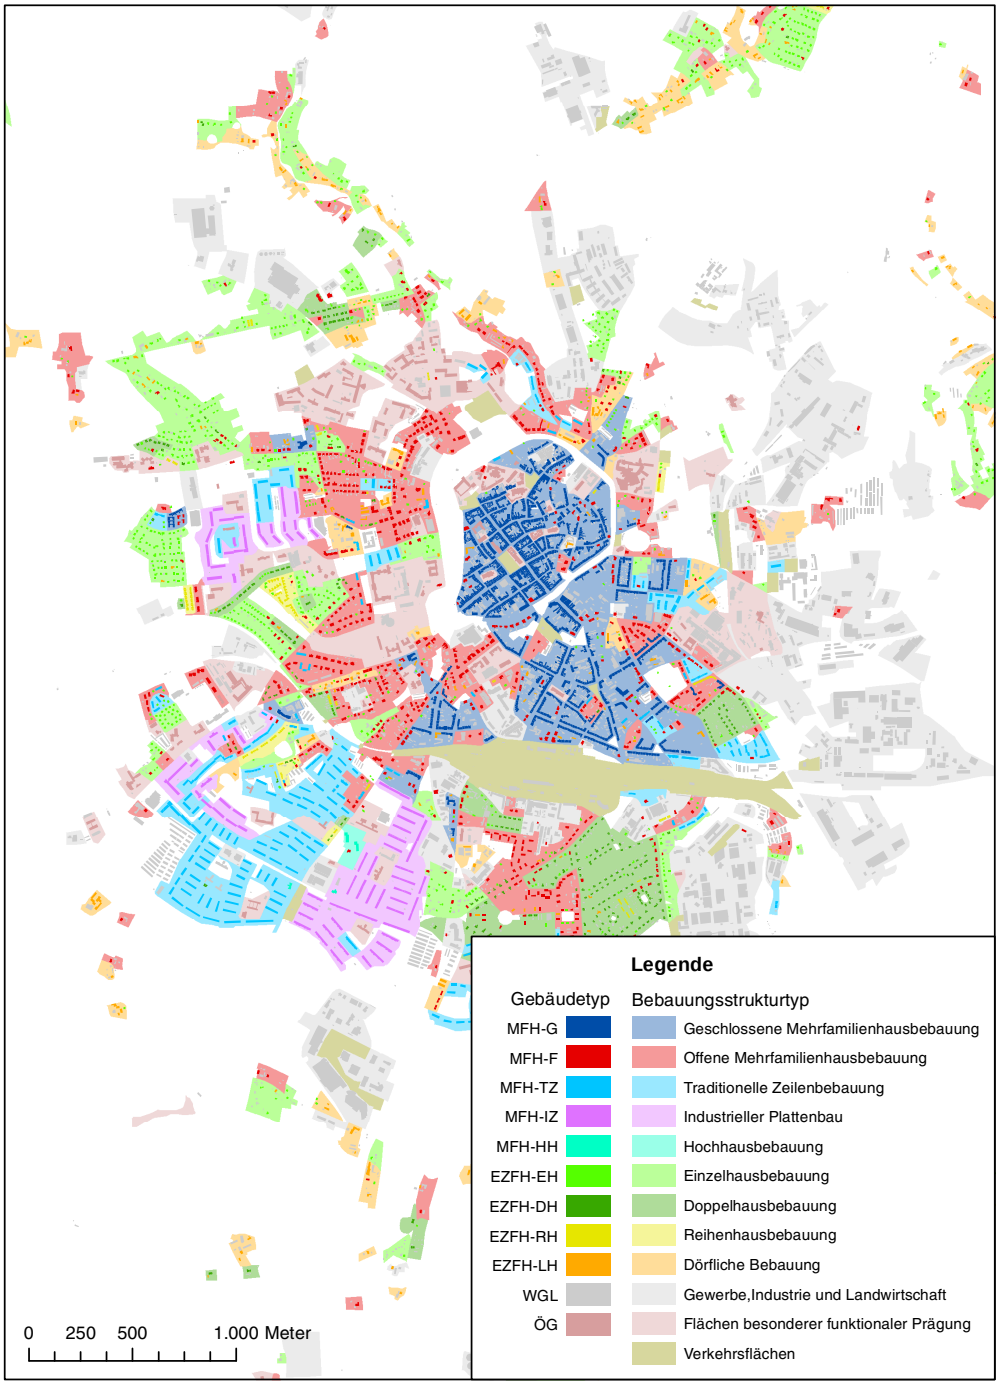

Karte 4

Riesa: Gebäude- und Baublockklassifikation

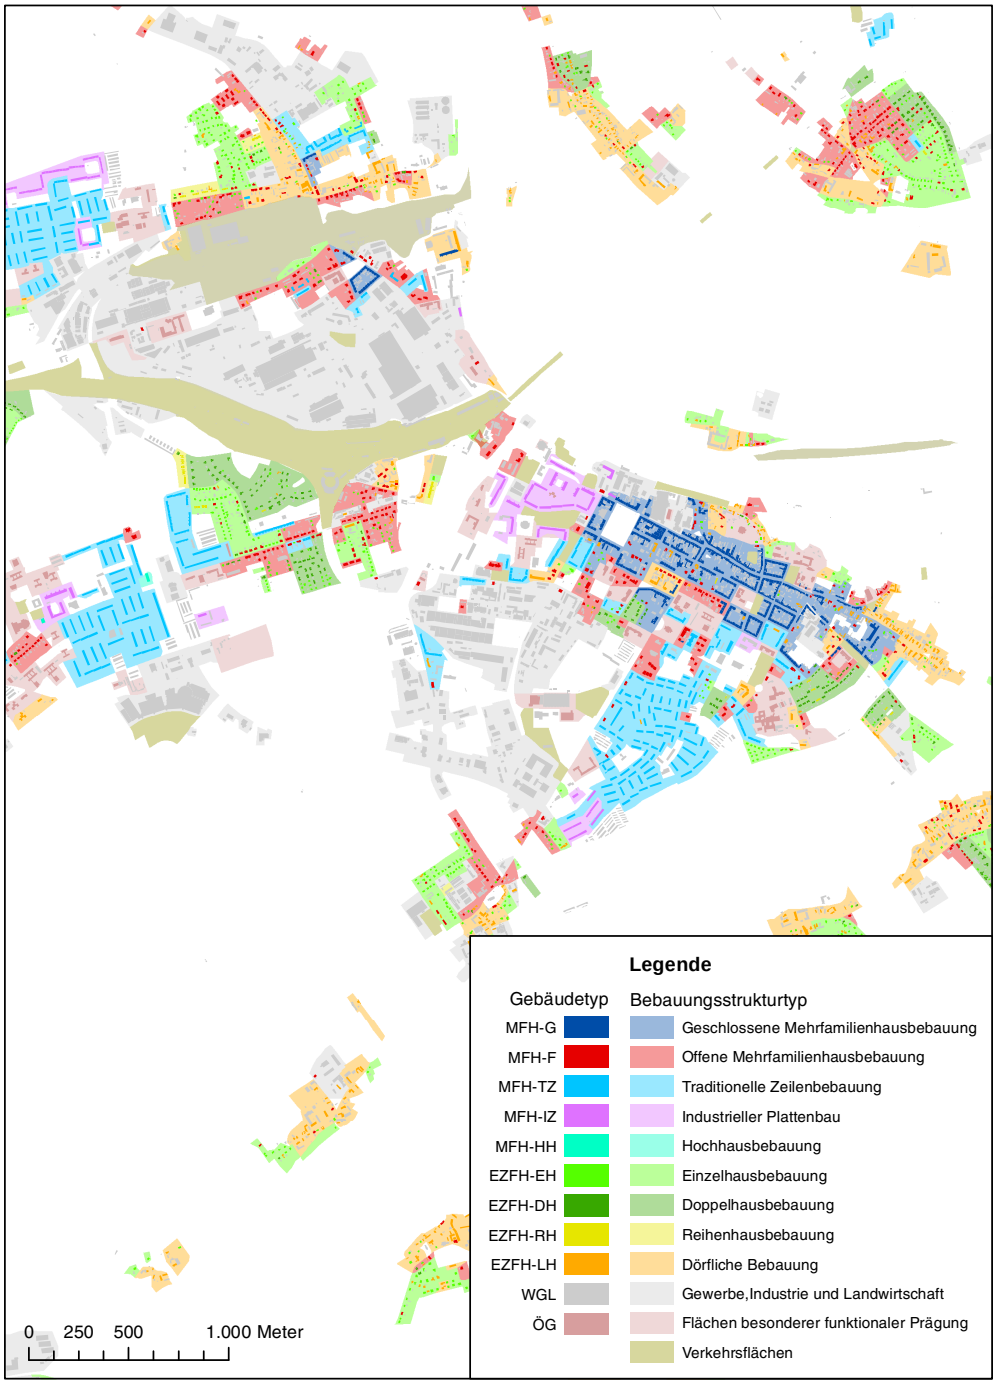

Karte 5

Stolpen: Gebäude- und Baublockklassifikation

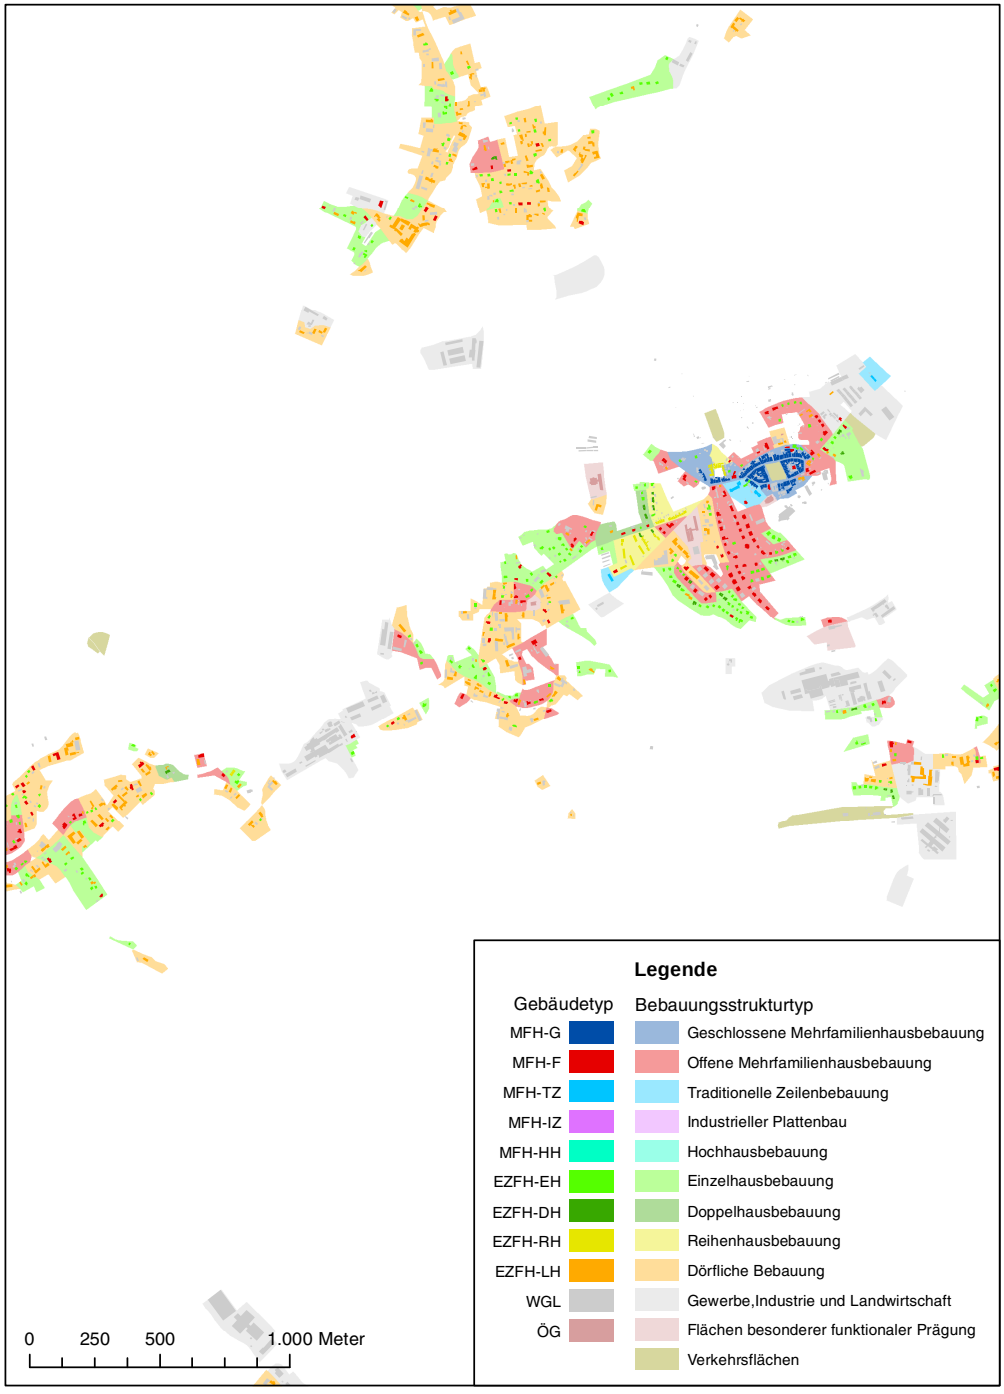

Karte 6

Lommatzsch: Gebäude- und Baublockklassifikation

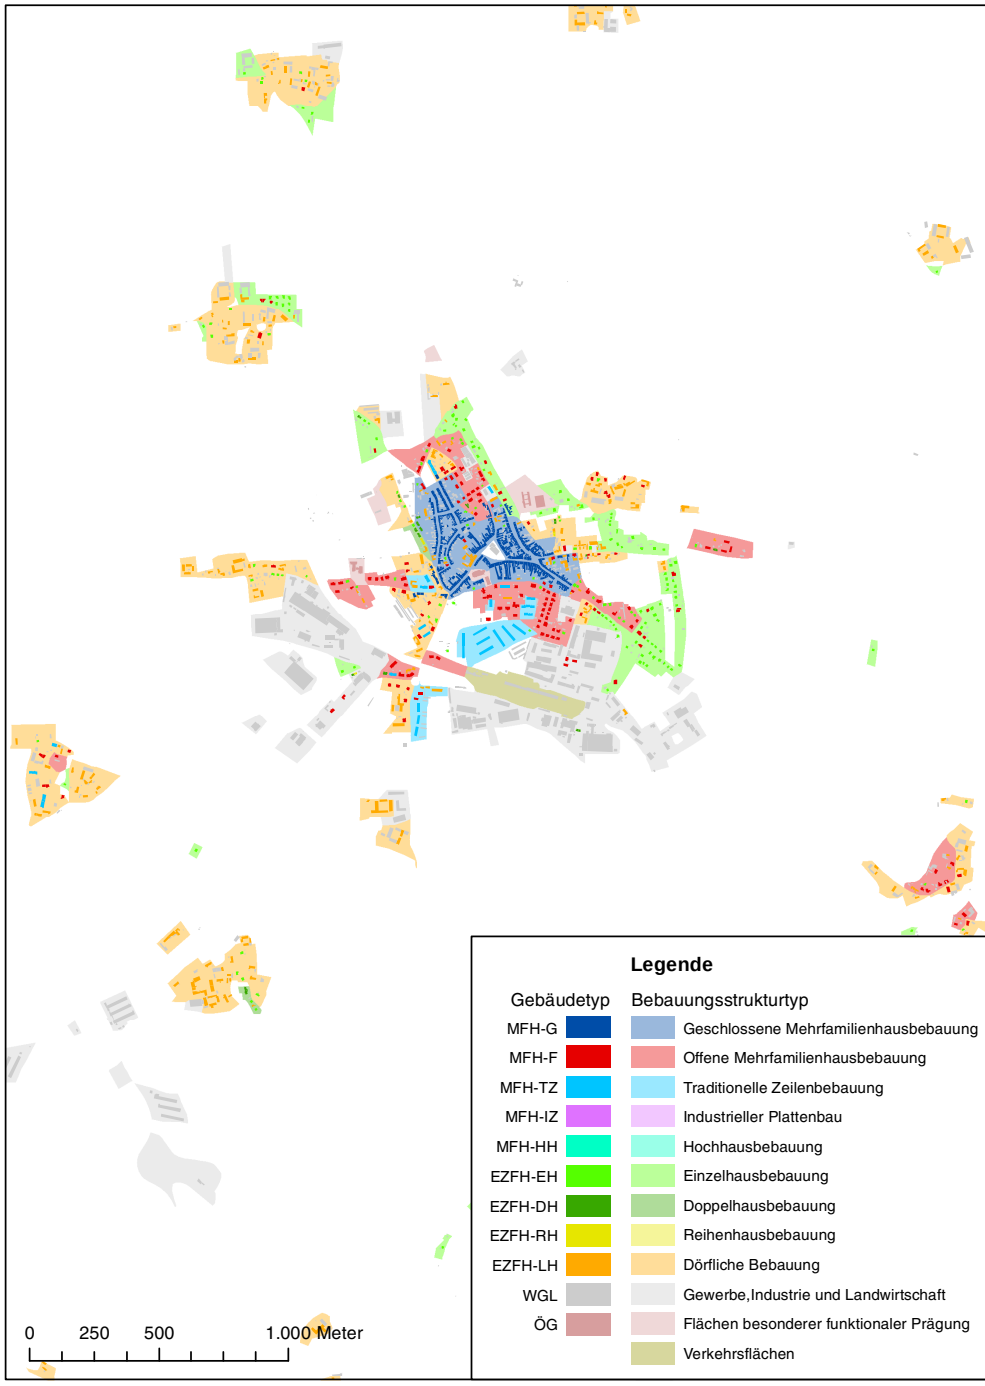

Karte 7

Ebersbach (bei Großenhain): Gebäude- und Baublockklassifikation

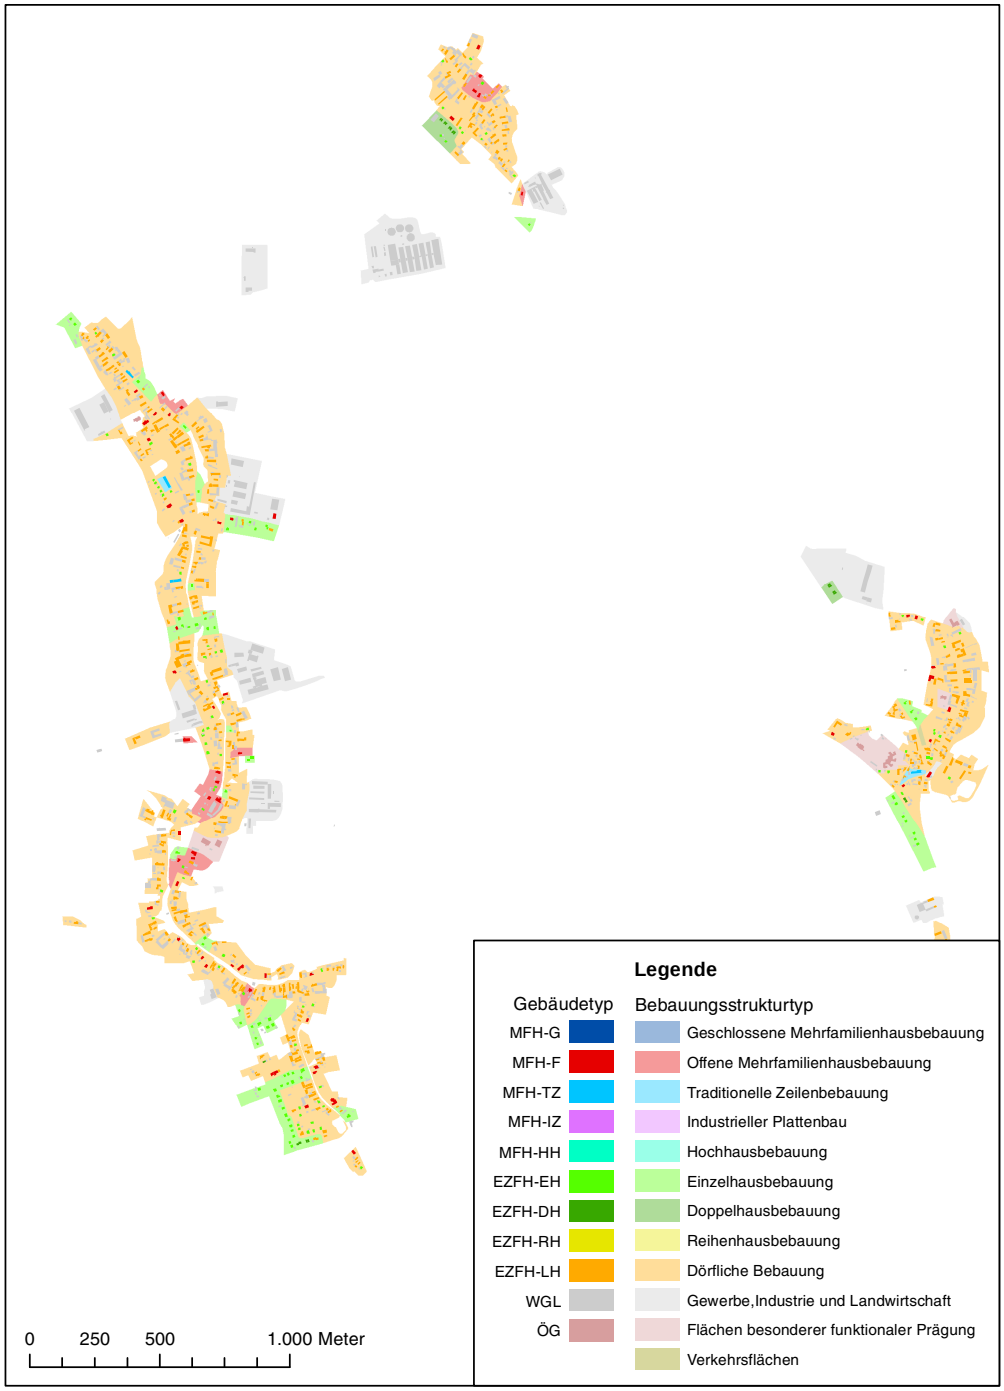

Der Autor

Robert Hecht, Jahrgang 1980.

1999-2006 Studium der Kartographie mit Vertiefung GIS an der Technischen Universität Dresden; 2002-2003 DAAD-Stipendium zum Forschungsaufenthalt am Indian Institute of Technology Kanpur (IIT Kanpur); seit 2006 wissenschaftlicher Mitarbeiter am Leibniz-Institut für ökologische Raumentwicklung in Dresden, 2013 Promotion zum Dr.-Ing. an der Technischen Universität Dresden, Fakultät Umweltwissenschaften.

IÖR Schriften

Herausgegeben vom Leibniz-Institut für ökologische Raumentwicklung e. V.

62 Kristin Klaudia Kaufmann
Komplettverkauf kommunalen Wohneigentums an internationale Investoren
Governanceanalytische Betrachtung der Folgen für Prozesse der Stadtentwicklung und des Wohnungsmarktes
Dresden 2014

61 Gotthard Meinel, Ulrich Schumacher, Martin Behnisch (Hrsg.)
Flächennutzungsmonitoring V
Methodik – Analyseergebnisse – Fächenmanagement
Dresden 2013

60 Gotthard Meinel, Ulrich Schumacher, Martin Behnisch (Hrsg.)
Flächennutzungsmonitoring IV
Genauere Daten – informierte Akteure – praktisches Handeln
Dresden 2012

59 Michael Roth
Landschaftsbildbewertung in der Landschaftsplanung –
Entwicklung und Anwendung einer Methode zur Validierung von Verfahren zur Bewertung des Landschaftsbildes durch internetgestützte Nutzerbefragungen
Dresden 2012

58 Gotthard Meinel, Ulrich Schumacher (Hrsg.)
Flächennutzungsmonitoring III
Erhebung – Analyse – Bewertung
Dresden 2011

57 Nguyen Xuan Thinh, Martin Behnisch, Otti Margraf (Hrsg.)
Beiträge zur Theorie und quantitativen Methodik in der Geographie
Dresden 2011

56 Christine Meyer
Planning for an Ageing Population –
Experiences from Local Areas in the United Kingdom
Dresden 2011

55 Stefan Dirlich
Integration der Bestandsqualität in die Zertifizierung von Gebäuden – Entwicklung eines ökonomisch-ökologischen Bewertungssystems für nachhaltiges Bauen unter besonderer Berücksichtigung von Bestansbauten und traditionellen Bauweisen
Dresden 2011

54 Elena Wiezorek
Eigentümerstandortgemeinschaften und Urban Covernance – Eine Untersuchung kollektiven Handelns in der Stadtentwicklung am Beispiel von Wohnquartieren im demografischen Wandel
Dresden 2011

53 Patrick Küpper
Regionale Reaktionen auf den Demographischen Wandel in
dünn besiedelten, peripheren Räumen
Dresden 2011

Bezug über RHOMBOS-VERLAG Berlin, Fachverlag für Forschung, Wissenschaft und Politik
www.rhombos.de bzw. über den Buchhandel