

# GLANZKORREKTURALGORITHMEN FÜR DIE GESICHTSERKENNUNG

Diplomarbeit  
am Institut für Medien- und Phototechnik  
Fakultät für Informations-, Medien- und Elektrotechnik  
Fachhochschule Köln

Autor  
Jörg Seedorfer  
aus Oberhausen  
Matrikelnummer: 11028067

Die Arbeit entstand bei der  
Viisage Technology AG (Bochum)

*Referent:* Prof. Dr. Dietmar Kunz (Fachhochschule Köln)  
*Koreferent:* Dr. Hans-Martin Bröker (Viisage Technology AG)

Köln, 21. Oktober 2004

# GLARE-CORRECTION-ALGORITHMS FOR FACE RECOGNITION

Thesis  
at the Institute of Media and Phototechnology  
Faculty of Information, Media, and Electrical Engineering  
University of Applied Sciences Cologne

Author  
Jörg Seedorfer  
from Oberhausen  
matriculation number: 11028067

The thesis was created at the  
Viisage Technology AG (Bochum)

*First Reviewer:* Prof. Dr. Dietmar Kunz (University of Applied Sciences Cologne)  
*Second Reviewer:* Dr. Hans-Martin Bröker (Viisage Technology AG)

Cologne, 21st October 2004

## Danksagung

Die vorliegende Arbeit entstand bei der Viisage Technology AG in Bochum. Für die freundliche Aufnahme und Unterstützung möchte ich mich an dieser Stelle recht herzlich bedanken.

Mein Dank gilt vor allem meinen Betreuern Prof. Dr. Dietmar Kunz und Dr. Hans-Martin Bröker für die Unterstützung, das Korrekturlesen und die hervorragende Betreuung. Für anregende Diskussionen und tatkräftige Unterstützung bedanke ich mich bei den Mitarbeitern der Viisage Technology AG, dabei besonders bei Maik Anschütz, Dr. Michael Braukmann, Dr. Michael Dose, Natalie Farantos, Dr. Michael Hüskens, Wolfgang Menk, Frank Müller und Uwe Werner.

Ein weiterer Dank gilt den Mitgliedern des Akkordeonorchesters Oberhausen. Diese haben sich zur Erstellung eines der Datensätze bereitwillig zur Verfügung gestellt.

# Inhaltsverzeichnis

<b>Danksagung</b>	<b>I</b>
<b>Zusammenfassung</b>	<b>1</b>
<b>Einleitung</b>	<b>2</b>
Ziel und Aufbau der Arbeit . . . . .	3
<b>1 Grundlagen der Gesichtserkennung</b>	<b>5</b>
1.1 Überblick über Erkennungsverfahren . . . . .	5
1.1.1 Template Matching . . . . .	5
1.1.2 Gesichtserkennung mit geometrischen Merkmalen . . . . .	6
1.1.3 Gesichtserkennung mit der zweidimensionalen Fouriertransformation	7
1.1.4 Gesichtserkennung mit neuronalen Netzen . . . . .	7
1.1.5 Gesichtserkennung mit Eigengesichtern . . . . .	9
1.1.6 Hierarchical Graph Matching . . . . .	14
1.1.6.1 Gabor Wavelets . . . . .	14
1.1.6.2 Das Finden der Landmarken / des Graphen . . . . .	17
1.1.6.3 Vergleich von Gesichtern . . . . .	18
1.2 Grenzen der Gesichtserkennung . . . . .	19
<b>2 Grundlagen der Glanzkorrektur</b>	<b>20</b>
2.1 Was ist Glanz? . . . . .	20
2.2 Glanzdetektion . . . . .	20
2.2.1 HSV-Methode auf chromatischen Bildern . . . . .	20
2.2.2 Zwei-Stufen-Methode auf Luminanzbildern . . . . .	21
2.2.3 Eigenvektor-Methode auf Luminanzbildern . . . . .	22
2.3 Einschränkungen im Praxisbetrieb . . . . .	22

2.4	Überblick über Glanzkorrekturalgorithmen . . . . .	23
2.5	Einfluss des Glanzes auf die Ähnlichkeit . . . . .	24
<b>3</b>	<b>Messmethoden und Kenngrößen</b>	<b>26</b>
3.1	Rangstatistik . . . . .	26
3.2	Die False reject/acceptation rate und die Equal error rate . . . . .	27
3.3	Unabhängigkeit zwischen Rang und EER . . . . .	30
3.4	Minimaler Fehler . . . . .	30
3.5	Weitere Messmöglichkeiten . . . . .	31
<b>4</b>	<b>Glanzkorrekturalgorithmen</b>	<b>32</b>
4.1	Glanzkorrektur durch Fill-In Methode . . . . .	32
4.2	Glanzkorrektur durch Interpolation . . . . .	33
4.2.1	Das Kantenproblem . . . . .	36
4.2.2	Flächen mit Struktur füllen (Strukturinterpolation, eigene Methode)	37
4.3	Glanzkorrektur mit Hilfe der Gauß'schen Ausgleichsrechnung . . . . .	38
4.3.1	Die Information „Gesicht“ ausnutzen . . . . .	38
4.3.2	Berechnen der Koeffizienten $\vec{k}$ . . . . .	42
4.3.2.1	Ermittlung der Koeffizienten im Sinne des kleinsten quadratischen Fehlers . . . . .	42
4.3.2.2	Singular Value Decomposition . . . . .	44
4.3.3	Die Abhängigkeit von den Trainingsdaten . . . . .	45
4.3.4	Das Problem der Redundanz oder der Korrelation . . . . .	46
4.4	Glanzkorrektur mit Hilfe von Eigengesichtern . . . . .	47
4.4.1	Nützliche Eigenschaften von Eigengesichtern . . . . .	47
4.4.2	Korrigieren mit Eigengesichtern . . . . .	49
4.4.3	Maßnahmen zur Beschleunigung des Algorithmus . . . . .	50
4.4.3.1	Standardmasken . . . . .	51
4.4.3.2	Iteratives Verfahren . . . . .	53
<b>5</b>	<b>Ergebnisse</b>	<b>55</b>
5.1	Eignung der Messmethoden prüfen . . . . .	55
5.2	Die Algorithmen in der praktischen Anwendung . . . . .	57
5.2.1	Zur Interpolation . . . . .	57
5.2.2	Zur Fill-In Methode . . . . .	58

5.2.3	Zur Ausgleichsrechnung und zu Eigengesichtern . . . . .	58
5.3	Auswertungen und Tests . . . . .	59
5.3.1	Verfahrenstest mit künstlichem Glanz . . . . .	59
5.3.1.1	Vergleich der Verfahren . . . . .	60
5.3.2	Verfahrenstest mit realen Daten . . . . .	70
5.4	Erweiterte Anwendungen . . . . .	74
<b>6</b>	<b>Diskussion und Ausblick</b>	<b>77</b>
<b>A</b>	<b>Testergebnisse der Gesichtserkennung</b>	<b>79</b>
A.1	Tests auf Datensatz 1 mit künstlichem Glanz . . . . .	79
A.2	Tests auf Datensatz 2 mit künstlichem Glanz . . . . .	90
A.3	Versuche zur Einschätzung der Verfahren . . . . .	100
A.3.1	Untersuchung der verschiedenen Messmethoden . . . . .	100
A.3.2	Abschätzung der Leistungsfähigkeit der Algorithmen . . . . .	100
A.3.3	Vergleich Korrektur mit Ausgleichsmethode und mit Eigenfaces . .	100
A.4	Versuche zum Probandeffekt . . . . .	104
A.5	Test auf wirklichen Glanzdaten . . . . .	105
A.5.1	608 gegen 152 - Test . . . . .	105
A.5.2	150 gegen 28 - Test . . . . .	107
<b>B</b>	<b>Beispielbilder</b>	<b>108</b>
B.1	Entfernung von Brillengestellen . . . . .	109
B.2	Entfernung von Pflastern . . . . .	111
B.3	Öffnen von Augen . . . . .	112
	<b>Verzeichnisse</b>	<b>113</b>
	Literaturverzeichnis . . . . .	113
	Abbildungsverzeichnis . . . . .	116
	Tabellenverzeichnis . . . . .	118
	Index . . . . .	119
	<b>Formelles</b>	<b>121</b>

## Zusammenfassung

<b>Titel:</b>	<b>Glanzkorrekturalgorithmen für die Gesichtserkennung</b>
Autor:	Jörg Seedorfer
Referenten:	Prof. Dr. Dietmar Kunz (Fachhochschule Köln) Dr. Hans-Martin Bröker (Viisage Technology AG)
Zusammenfassung:	Die Arbeit stellt verschiedene Algorithmen zur Rekonstruktion von Pixeln in Gesichtsbildern vor. Dabei werden vor allem solche Pixel betrachtet, die durch Glanz gestört sind. Des Weiteren wird der Einfluss der Algorithmen auf die Gesichtserkennungsleistung untersucht.
Stichwörter:	Glanzkorrektur, Gesichtserkennung, Glanzdetektion, Eigengesichter, Hierarisches Graph Matching, Gabor wavelets
Sperrvermerk:	Die Einsicht in die vorgelegte Arbeit ist bis zum 28. Oktober 2006 gesperrt.
Datum:	21. Oktober 2004
<b>Title:</b>	<b>Glare-correction-algorithms for face recognition</b>
Author:	Jörg Seedorfer
Advisores:	Prof. Dr. Dietmar Kunz (University of Applied Sciences Cologne) Dr. Hans-Martin Bröker (Viisage Technology AG)
Abstract:	The thesis pictures different algorithms for the reconstruction of pixels in images of faces. Primarily it shows those pixels, which are destroyed by glare. Furthermore it analyses the influence of algorithms on the face recognition performance.
Keywords:	glare correction, face recognition, glare detection, eigenfaces, hierarchical graph matching, gabor wavelet
Remark of closure:	The Thesis is closed until 28th October 2006.
Date:	21st October 2004

## Einleitung

Spätestens seit dem 11. September 2001 ist das Sicherheitsbedürfnis der Menschen geweckt worden [BDG<sup>+</sup>03]. Dies lässt sich durch den Anstieg der Umsatzzahlen für sicherheitsrelevante Produkte ablesen [Ahl03]. Durch das Überlisten des Sicherheitssystems des Flughafens konnte es erst zu einer solchen Katastrophe kommen. Politiker und Fachleute suchen seit dem nach neuen oder besseren Sicherheitssystemen, um eine solche Katastrophe in Zukunft verhindern zu können.

Eine wichtige Rolle spielt dabei die Identifizierung von Personen, die bereits als gefährlich eingestuft sind. Als Werkzeug dient dabei unter anderem die Biometrie (bios = Leben und metron = Maß [YFS01]). Nach [YFS01] ist die Biometrie als die Lehre von der Anwendung mathematischer Methoden auf die Mess- und Zahlenverhältnisse der Lebewesen und deren Körperteile definiert. Die „Kenngößen“ dieser Systeme werden biometrisches Merkmal genannt. Neben der Identifikation gibt es in der Biometrie noch die Verifikation. Bei der Identifikation soll die Frage „Wer bin ich?“ und bei der Verifikation die Frage „Bin ich wirklich ich?“ beantwortet werden [BDG<sup>+</sup>03, PS02, Hof]. Die Identifikation ist das Verfahren, das die Identität einer Person herausfindet, die vorher noch nicht bekannt war. Dagegen überprüft die Verifikation die bereits bekannte Identität auf ihren Wahrheitsgehalt. Die Identifikation und die Verifikation nehmen ein breites Spektrum ein. Bereits an der Haustür eines Privatmannes kann ein einfaches Identifikationssystem, das Haustürschloss, gefunden werden. In der Bundesrepublik Deutschland denkt man über die Einführung von biometrischen Merkmalen in den Personalausweisen nach, um die Identifikation einfacher und sicherer zu gestalten [Sic04, PS02, YFS01].

Das wohl älteste und einfachste Verfahren ist die Identifikation per Schlüssel. Von allen Menschen darf nur derjenige die Tür passieren, der den Schlüssel besitzt. Ein solches System reicht für sicherheitsrelevante Bereiche heutzutage nicht mehr aus. In der Biometrie muss sich die Person, die sich durch einen Schlüssel, Chip oder Ähnliches identifiziert hat, durch ein biometrisches Merkmal verifizieren. Das bedeutet, dass sie sich z.B. durch einen



Fingerabdruck als Eigentümer des Schlüssels ausweisen muss. Zu den bekanntesten Merkmalen gehört neben dem Fingerabdruck die Iris [PS02]. Der Mensch selber nutzt das Gesicht als Identifikationshilfe [YFS01]. Dadurch ist die Akzeptanz von Gesichtserkennungssystemen beim Benutzer größer als die von Fingerabdruck- oder Iriserkennungssystemen, welche immer wieder eine Assoziation in Richtung Vollzugsanstalt und Überwachungsstaat verursachen.

Die Gesichtserkennung nutzt auch die Viisage Technology AG (Bochum), die mich freundlicherweise bei meiner Arbeit unterstützte. Ein großer Vorteil der Gesichtserkennung ist die berührungslose Identifikation und Verifikation [PS02]. Der Wartungsaufwand der Gesichtserkennungsstation ist dadurch geringer. Fett und andere Schmutzspuren, die durch Berühren entstehen, können das System nicht behindern. Außerdem bietet die berührungslose Identifikation weitere Anwendungsmöglichkeiten. Das können z. B. die Überwachung von öffentlichen Plätzen, Stadien und Ähnlichem sein. Straftäter oder gewaltbereite Personen könnten beispielsweise aus einer Menge von Menschen herausgesucht werden. Von einigen Datenschützern wird diese Möglichkeit der Gesichtserkennung als Problem und Missbrauchsmöglichkeit gesehen.

Ein Nachteil in einem solchem Szenario ist die sich immer wieder ändernde Beleuchtungssituation. Die Erkennungsrate der Gesichtserkennung hängt unter anderem stark von der Beleuchtung ab. Insbesondere Glanzlichter scheinen Probleme zu machen.

## **Ziel und Aufbau der Arbeit**

Es ist zu erwarten, dass Glanzlichter die Erkennung beeinflussen. In dieser Arbeit soll untersucht werden, ob es Möglichkeiten gibt, den Einfluss des Glanzes auf die Gesichtserkennung zu verringern und dadurch die Erkennungsleistung zu verbessern. Dabei besteht die Idee im Wesentlichen darin, Korrekturverfahren zu entwickeln, die den wirklichen Zustand wiederherstellen. Damit die Korrekturverfahren auch das „Richtige“ korrigieren, sollen Möglichkeiten aufgezeigt werden, um Glanzlichter zu detektieren. Des Weiteren soll ermittelt werden, ob sich die Glanzkorrektur als Erweiterung einer Erkennungsmaschine eignet.

Untersucht werden insgesamt vier unterschiedliche Ansätze zur Glanzkorrektur: Interpolation, Fill-In-Methode, Korrektur mit Hilfe der Ausgleichsrechnung und ein Ansatz mit

Hilfe der Eigengesichter. Die Algorithmen wurden alle in IDL (Interactive Data Language) implementiert. Bevor die Algorithmen näher beschrieben werden, werden die Grundlagen der Gesichtserkennung und der Glanzkorrektur erläutert. In dem Abschnitt zu den Grundlagen der Glanzkorrektur wird auch der Stand der Technik festgehalten und bewertet. Im Anschluss daran werden die Ergebnisse der Tests besprochen.

# 1 Grundlagen der Gesichtserkennung

## 1.1 Überblick über Erkennungsverfahren

Es gibt unterschiedliche Algorithmen für die Gesichtserkennung: das Template Matching, die Gesichtserkennung mit geometrischen Merkmalen, die Gesichtserkennung mit zweidimensionaler Fouriertransformation, die Gesichtserkennung mit neuronalen Netzen, das Hierarchical Graph Matching und die Gesichtserkennung mit Eigengesichtern. Das Hierarchical Graph Matching wird bei der Viisage Technology AG eingesetzt und wurde daher auch in der Erkennungsmaschine für diese Arbeit als Referenz benutzt. Es wird in Kapitel 1.1.6 genau beschrieben. Die anderen Verfahren sollen hier nur kurz angerissen werden. Grundsätzlich unterscheidet man zwischen den holistischen und den Merkmal basierten Verfahren [Hof]. Holistische Verfahren unterscheiden sich gegenüber den Merkmal basierten Verfahren dadurch, dass sie nicht das Gesicht in Teile mit semantischem Inhalt wie Augen, Nase und Mund teilen. Statt dessen werden lokale Grauwertstrukturen wie Ecken, Symmetrien und Ähnliches betrachtet [Ger96].

In den folgenden Kapiteln werden die verschiedenen Gesichtserkennungsalgorithmen erläutert, wie sie auch bei [TP91, Hof, Ger96, Wis95] nachzulesen sind.

### 1.1.1 Template Matching

Das Template Matching gehört je nach Ausführungsform zu den holistischen oder den Merkmal basierten Verfahren. Wird das Gesicht als Ganzes betrachtet, gehört das Verfahren zu den holistischen Verfahren. Wird das Gesicht hingegen in Merkmale wie Mund oder Augen geteilt, gehört es zu den Merkmal basierten Verfahren [Ger96, Hof]. Dabei wird die Ähnlichkeit zwischen einem Template  $t$  (siehe Abbildung 1.2) und einem Bild  $I$  (siehe Abbildung 1.1) berechnet. Das Template  $t$  kann z.B. die Augen oder das ganze Gesicht enthalten. Dabei kann man sich das Template als Bild oder als Bildausschnitt vorstellen. In



*Abbildung 1.1: Beispiel Bild I*



*Abbildung 1.2: Beispiel Template t*

der Regel benutzt man mehrere Templates. Als Ähnlichkeit wiederum kommen verschiedene Größen in Frage. Am gebräuchlichsten ist die Differenzbildung, der euklidische Abstand und das Skalarprodukt. Die Ähnlichkeiten werden in einem Vektor zusammengefasst. Sucht man eine Person in einem Datensatz, so wird die Person ausgewählt, die die größte Ähnlichkeit über alle Merkmale aufweist. Nachteil dieses Verfahrens ist die große Rechenzeit, da  $m^2 \cdot n^2$  Vergleiche durchgeführt werden müssen, wobei  $m$  die Länge des zu untersuchenden Bildes  $I$  in Pixel und  $n$  die Länge des Templates  $t$  ist. Ein wesentlicher Vorteil des Verfahrens ist die Einfachheit des Algorithmus.

### **1.1.2 Gesichtserkennung mit geometrischen Merkmalen**

Dieses Verfahren gehört zu den Merkmal basierten Verfahren der Gesichtserkennung. Hierbei wird das Gesicht geometrisch ausgemessen wie es der Name des Verfahrens verrät. Es werden die Lagen bestimmter Merkmale, dazu können z.B. Augen, Nasenspitze oder Mundwinkel gehören, bestimmt. Die charakteristische Lage zueinander ergibt einen Vektor, der das Gesicht beschreibt. Ein erweiterter Ansatz besteht darin, dass auch Maßzahlen wie Durchmesser der Augenpupille benutzt werden, um das Gesicht geometrisch zu beschreiben [Ger96]. Diese Erweiterung wird auch als parametrisiertes Modell bezeichnet.

Probleme verursacht die genaue Positionierung der Merkmale. Als Hilfsmittel zur Positionierung dienen unter anderem die integrale Projektion und die Kantenbilder (vergleiche [Hof]).

### 1.1.3 Gesichtserkennung mit der zweidimensionalen Fouriertransformation

Dieses Verfahren kann als optimiertes Template Matching betrachtet werden. Zunächst wird das Gesicht einer zweidimensionalen Fouriertransformation unterzogen. Im Frequenzraum (siehe Abbildung 1.3) beschreiben im Wesentlichen die tieffrequenten Anteile das Gesicht. Hat man die Spektren zweier Gesichter, kann man den Unterschied der Spektren berechnen. Der Unterschied lässt sich z. B. als Differenz der Frequenzen ausdrücken. Ordnet man anschließend die berechneten Unterschiede nach ihrem Informationsgehalt, so erhält man einen Vektor, der die Ähnlichkeit beschreibt [Hof].

### 1.1.4 Gesichtserkennung mit neuronalen Netzen


Neuronale Netze liefern ein Verfahren, das dem menschlichen Nervensystem nachempfunden ist. In der Wissenschaft gibt es viele Varianten der neuronalen Netze. Daher können Erkennungssysteme stark voneinander abweichen. Man unterscheidet unter anderem zwischen Multi-Layer Perzeptron Netzen (MLP), Radial-Basis-Function Netzen (RBF) und Self Organizing Maps (SOM) [Hof].

So wie ein Nervensystem aus vielen Zellen aufgebaut ist, besteht ein neuronales Netz aus vielen Neuronen (siehe Abbildung 1.4). Neuronen haben mehrere Eingänge und einen Ausgang, der wieder mit Eingängen anderer Neuronen verbunden sein kann. Der Ausgangswert ist eine gewichtete Summe der Eingangssignale plus einer Transferfunktion  $\tau$ , deren Form von der Art des neuronalen Netzes abhängt. Als Eingangsinformation kann z. B. die Intensität ( $I$ ) eines Bildpunktes dienen. Der Ausgang ist in der Regel eine Aussage  $A$ , die zur Klassifikation genutzt werden kann. Um aus einem neuronalen Netz ein Gesichtserkennungssystem zu machen, muss es angelernt werden. Das bedeutet, dass die Gewichte in den einzelnen Neuronen bestimmt werden. Dies geschieht dadurch, dass dem neuronalen Netz eine Trainingsmenge präsentiert und der Fehler des Ausgangssignals berechnet wird. Durch ein Verfahren, das sich Gradientenabstiegsverfahren nennt, wird dann das neuronale Netz optimiert. Dies kann man sich so vorstellen, dass das Gradientenabstiegsverfahren



(a) Bild im Ortsraum

(b) absolutes Fourierspektrum



(c) Realteil des Spektrums

(d) Imaginärteil des Spektrums

*Abbildung 1.3: Beispiel eines Fourierspektrums*




Abbildung 1.4: Neuron

die Gewichtungen in den Neuronen so neu ordnet, dass der Fehler minimiert wird. Dies wird solange wiederholt, bis der Restfehler klein genug ist. Allerdings muss darauf geachtet werden, dass die Generalisierung darunter nicht leidet. Daher wird nach jedem Trainingsdurchgang der Fehler einer zweiten Trainingsmenge, die Validierungsmenge genannt wird, bestimmt. Die Validierungsmenge darf vorher nicht zur Optimierung des neuronalen Netzes genutzt worden sein. Ist der Fehler dieser Menge auch minimiert worden, so ist das Erkennungssystem fertig optimiert.

### 1.1.5 Gesichtserkennung mit Eigengesichtern

Das Verfahren mittels Eigengesichtern, das im Kapitel 4.4 auch zur Korrektur von Glanz benutzt wird, wurde erstmals 1991 von Turk und Pentland in ihrem Artikel "Eigenfaces for Recognition" [TP91] vorgestellt. Bei diesem Verfahren wird das Gesichtsbild als Vektor betrachtet. In der Regel braucht nur ein kleiner Ausschnitt des Gesamtbildes benutzt werden, da das Gesicht nur einen Teil des Bildes ausmacht. Um die Bilder exakt darstellen zu können, werden entsprechend viele Pixel (Breite  $\cdot$  Höhe) benötigt. Man könnte auch sagen, dass  $B \cdot H$  Basisvektoren gebraucht werden, um den „Bildvektorraum“ aufzuspannen. Bei einem quadratischen Bild mit einer Kantenlänge von 128 Pixel würden  $128^2 = 16384$  Basisvektoren benötigt. Sowohl für die Erkennung als auch für die Korrektur sind das äußerst unhandliche Größen.

Im Folgenden wird eine Menge von Gesichtern betrachtet, die aus möglichst vielen repräsentativen Gesichtern besteht. Diese Gesichter spannen den Vektorraum aller möglichen Bilder, den „Bildraum“, nicht komplett auf. Das lässt sich schon daran erkennen, dass es

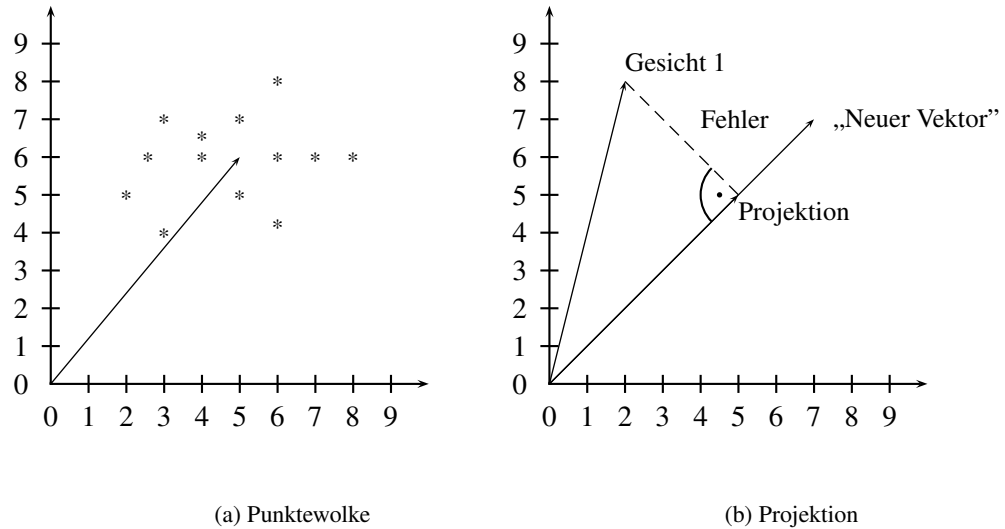
Bilder gibt, wie z. B. Bäume und Häuser, die überhaupt keine Ähnlichkeit mit Gesichtern haben. Es liegt daher nahe, nach einer Darstellung zu suchen, die für die Darstellung von Gesichtern besser geeignet ist. Eine Möglichkeit besteht darin den Vektorraum zu optimieren. Gesucht wird daher ein Untervektorraum des „Bildraumes“. Idealerweise sind dessen Basisvektoren orthogonal. Des Weiteren soll er möglichst mit weniger Basisvektoren als der ursprüngliche Vektorraum auskommen. Würde das nicht so sein, könnte genauso der ursprüngliche „Bildraum“ benutzt werden. Der neue Raum soll zusätzlich so strukturiert sein, dass er möglichst viele Gesichter optimal darstellen kann. Könnte der neue Raum das nicht, wäre er für die Anwendung in der Gesichtserkennung nutzlos.

Eine Möglichkeit, diesen Raum zu erhalten, ist die Anwendung statistischer Methoden. Dazu muss man sich die Menge der vielen repräsentativen Gesichter als Punktwolke im Raum vorstellen (siehe Abbildung 1.5). Diese Gesichter sollen nun durch, im Verhältnis zum ursprünglichen Vektorraum, wenige Vektoren dargestellt werden. Durch dieses Vorgehen entsteht ein Fehler, der möglichst klein gehalten werden soll. Die Vektoren, die später die Basisvektoren des neuen Untervektorraums sind, werden schrittweise bestimmt. Zunächst wird der Vektor gesucht, der die Gesichter der Trainingsmenge insgesamt am besten darstellt. Was gleichbedeutend damit ist, dass die Projektion der Gesichtsvektoren auf den neuen Vektor den kleinsten quadratischen Fehler verursacht (siehe Abbildung 1.5). Der Fehler kann nur noch dadurch minimiert werden, dass man die Gesichter nicht nur durch einen Vektor ersetzt, sondern durch zwei.

Dieser Vektor steht senkrecht auf dem ersten. Er ist zusätzlich der Vektor, der wiederum den kleinsten Fehler verursacht, diesmal aber auf den übrig gebliebenen Restfehlern bezogen. Man kann nun solange nach neuen Vektoren  $\vec{u}_i$  suchen, bis der Restfehler null wird. Diese Methode wird in der Literatur als Principal Component Analysis (PCA) oder Hauptachsentransformation bezeichnet.

Stellt man die Gesichter als Linearkombination der Basisvektoren des neuen Vektorraums dar, können die Koeffizienten der Linearkombination, zusammengefasst als Vektor, als Merkmalsvektor dienen. Diese Merkmalsvektoren der Gesichter können dann wieder miteinander verglichen werden.





**Abbildung 1.5:** Vektorprojektion

### Bildung des Gesichtsvektorraums

Um die PCA berechnen zu können, benötigt man eine große Menge Gesichtsbilder. Diese Menge wird üblicherweise als Trainingsmenge bezeichnet. Die Bilder werden in die Form von Vektoren gebracht. Von diesen Vektoren wird das Durchschnittsgesicht bestimmt. Das ist nichts anderes als ein arithmetisches Mittel:

$$\vec{D} = \frac{1}{N} \sum_{i=1}^N \vec{G}_i \tag{1.1}$$

Danach wird für jedes Gesicht die Abweichung vom Durchschnittsgesicht bestimmt.

$$\vec{\Delta}_i = \vec{G}_i - \vec{D} \tag{1.2}$$

Gesucht werden die  $i$ ten Vektoren  $\vec{u}_i$ , bei denen

$$\lambda_i = \frac{1}{N} \sum_{n=1}^N \left( (\vec{u}_i)^t \vec{\Delta}_n \right)^2 \tag{1.3}$$

maximal wird. Was gleichbedeutend damit ist, dass der Fehler minimal wird. Wobei

$$(\vec{u}_l)^t \vec{u}_k = \delta_{lk} = \begin{cases} 1, & \text{wenn } l = k \\ 0, & \text{sonst} \end{cases} \quad (1.4)$$

ist. Die gesuchten Vektoren sind die Eigenvektoren der Kovarianzmatrix

$$C = \frac{1}{N} \sum_{k=1}^N \vec{\Delta}_k (\vec{\Delta}_k)^t \quad (1.5)$$

$$= \frac{1}{N} X X^t \quad (1.6)$$

$$\text{mit } X = \begin{bmatrix} \vec{\Delta}_1 & \vec{\Delta}_2 & \dots & \vec{\Delta}_N \end{bmatrix} \quad (1.7)$$

$$C = \frac{1}{N} \begin{bmatrix} \sigma_{11}^2 & \sigma_{12}^2 & \dots & \sigma_{1,BH}^2 \\ \sigma_{21}^2 & \sigma_{22}^2 & \dots & \sigma_{2,BH}^2 \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{BH,1}^2 & \sigma_{BH,2}^2 & \dots & \sigma_{BH,BH}^2 \end{bmatrix} \quad (1.8)$$

Eine Kovarianzmatrix ist immer diagonalisierbar, d.h.

$$C = U \cdot \Lambda \cdot U^t = U \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \lambda_N \end{bmatrix} U^t \quad (1.9)$$

In der Drehmatrix  $U$  sind spaltenweise die Eigenvektoren enthalten. Die Matrix ist positiv definit. Das bedeutet, dass die Eigenwerte größer oder gleich null sind. Ist die Dimension der Vektoren  $\vec{\Delta}_i$  größer als die Anzahl dieser, so lassen sich die Eigenvektoren leichter bestimmen. Haben die Vektoren  $\vec{\Delta}_i$  die Dimension  $M$ , so hat die Matrix  $C$  die Größe  $M \times M$ . Die Matrix hat also  $M$  Eigenvektoren und  $M$  Eigenwerte. Da wir aber nur  $N$  Trainingsgesichter haben, sind auch nur  $N$  Eigenvektoren zu erwarten, bei denen der Eigenwert ungleich null ist. Man kann die Eigenvektoren bestimmen, indem man zunächst die Eigenvektoren einer kleineren Matrix, deren Dimension  $N \times N$  ist, bestimmt. Sind  $\vec{v}_i$  die Eigenvektoren und  $\lambda_i$  die zugehörigen Eigenwerte einer Matrix  $A = X^t X$ , muss nach der Definition von

Eigenvektoren gelten:

$$A\vec{v}_i = \lambda_i\vec{v}_i \quad (1.10)$$

$$\Leftrightarrow X^T X \vec{v}_i = \lambda_i \vec{v}_i \quad (1.11)$$

Multipliziert man die Gleichung auf jeder Seite mit  $X$ , so erhält man:

$$XX^T X \vec{v}_i = \lambda_i X \vec{v}_i \quad (1.12)$$

$$\Leftrightarrow C(X\vec{v}_i) = \lambda_i(X\vec{v}_i) \quad (1.13)$$

Die Eigenvektoren der Matrix  $C$  sind also  $\vec{u}_i = X\vec{v}_i$  und die dazugehörigen Eigenwerte sind die Eigenwerte der Matrix  $A = X^T X$ . Man braucht also nur die Eigenvektoren und Eigenwerte einer kleineren Matrix bestimmen, wodurch viel Rechenzeit gespart wird und darüber hinaus das Problem für sehr große Matrizen erst numerisch handhabbar wird.

In dem neuen Vektorraum lassen sich die „neuen“ Trainingsgesichter durch eine Matrixmultiplikation errechnen:

$$\hat{X} = U^T X \quad (1.14)$$

Dabei ist  $U$  die Matrix, in der spaltenweise die Eigenvektoren der Kovarianzmatrix  $C$  und die Matrix  $\hat{X}$  diejenige, in der spaltenweise die „neuen“ Trainingsgesichter eingetragen sind. Die neue Kovarianzmatrix lässt sich dann berechnen als

$$\hat{C} = \hat{X} \hat{X}^T \quad (1.15)$$

$$= U^T X (U^T X)^T \quad (1.16)$$

$$= U^T X X^T U \quad (1.17)$$

$$= U^T \cdot C \cdot U \quad (1.18)$$

Substituiert man nun die Matrix  $C$  durch ihre diagonalisierte Darstellung  $U\Lambda U^T$ , so erhält man:

$$\hat{C} = U^T U \Lambda U^T U \quad (1.19)$$

$$= E \Lambda E^T \quad (E = \text{Einheitsmatrix}) \quad (1.20)$$

$$= \Lambda \quad (1.21)$$

Es wurde eine Darstellung gefunden, die nicht nur mit weniger Basisvektoren auskommt, sondern in der die Gesichter nicht mehr korreliert sind.

Die Abbildung 1.6 zeigt den Mittelwert und eine Auswahl von Eigengesichtern, die von einem Datensatz berechnet worden sind, der 300 Gesichter beinhaltet. Man erkennt, dass bereits ab der 69. Ordnung keine wirklichen Gesichtsstrukturen mehr erkennbar sind. Ab Eigengesicht 230 ist kein Gesicht mehr zu erkennen. Das zeigt, dass die charakteristischen Eigenschaften in den ersten Eigengesichtern enthalten sind.

Da die Kovarianzmatrix symmetrisch ist, sind die Eigenvektoren orthogonal [Kun04]. Die Rekonstruktionskoeffizienten eines mittelwertbefreiten Gesichts  $\Delta$  können aufgrund der Orthogonalität der Eigenvektoren berechnet werden als

$$k_i = \Delta \cdot u_i^t \quad (1.22)$$

mit  $i = \{1, \dots, N\}$


Die Begründung dafür wird in Kapitel 4.4.1 beschrieben.

### 1.1.6 Hierarchical Graph Matching

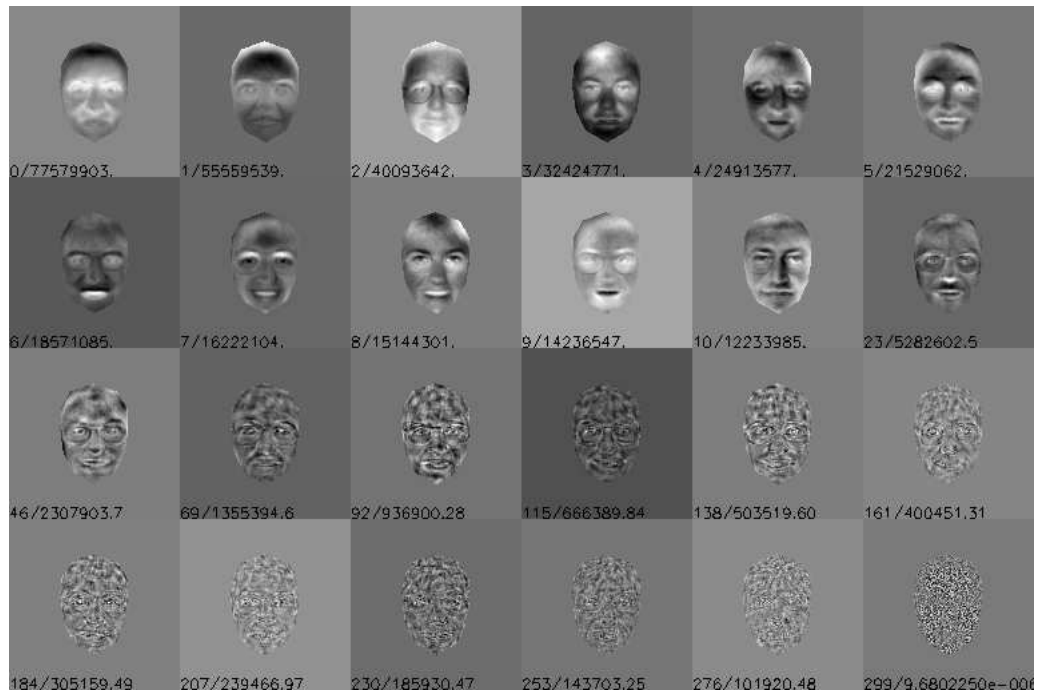
Das Hierarchical Graph Matching basiert auf dem Elastic Bunch Graph Matching, das erstmals von Laurenz Wiskott in seiner Doktorarbeit [Wis95] vorgestellt wurde. Das Verfahren gehört neben den Verfahren mit Eigengesichtern zu den führenden Gesichtserkennungsverfahren. Das Graph Matching ist dem Erkennungssystem des Menschen nachempfunden. Als Grundlage dienen die Gabor Wavelets (Kapitel 1.1.6.1). An ausgesuchten Stellen im Gesicht werden die Filterantworten der Wavelets abgenommen. Eine solche „Stelle“ wird als Landmarke bezeichnet. Die gewonnenen Informationen bilden einen Vektor, der das Gesicht charakterisiert.

#### 1.1.6.1 Gabor Wavelets

Ein Gabor Wavelet besteht aus einer ebenen Welle, die durch eine Gauss-Glocke eingehüllt ist (Abbildung 1.7). Die Gabor Wavelets haben den Vorteil, dass sie recht robust gegenüber Helligkeitsschwankungen sind. Es wird eine Familie von Gabor Wavelets definiert mit 4 unterschiedlichen Frequenzen  $\nu$  und 12 unterschiedlichen Richtungen  $\mu$ .




(a) mittleres Gesicht




(b) Eigengesichter mit Ordnungsnummern und Eigenwerten

*Abbildung 1.6: Gesichtsmittelwert und eine Auswahl von Eigengesichtern*



(a) Ortsbereich (3mal vergrößert),  
 $\nu = 0, \mu = 0$

(b) Frequenzspektrum,  $\nu = 0, \mu = 0$



(c) Ortsbereich (3mal vergrößert),  
 $\nu = 3, \mu = 0$

(d) Frequenzbereich,  $\nu = 3, \mu = 0$

**Abbildung 1.7: Gaborfilter**

$$\Psi_q(\vec{x}) = \frac{\vec{k}_q^2}{\sigma^2} \exp\left(-\frac{\vec{k}_q^2 \vec{x}^2}{2\sigma^2}\right) \left[ \exp\left(i\vec{k}_q \vec{x}\right) - \exp\left(-\frac{\sigma^2}{2}\right) \right] \quad (1.23)$$

Wobei  $\vec{k}$  der Wellenvektor ist, mit

$$\vec{k}_q(\mu, \nu) = \begin{pmatrix} k_\nu \cos \varphi_\mu \\ k_\nu \sin \varphi_\mu \end{pmatrix} \quad (1.24)$$

mit

$$k_\nu = 2^{-\frac{\nu+2}{2}} \pi, \varphi_\mu = \mu \frac{\pi}{12} \quad (1.25)$$

und

$$\mathbf{v} \in \{0, \dots, 3\}, \mu \in \{0, \dots, 11\} \quad (1.26)$$

Mit diesen 48 Wavelets wird jeweils eine Faltung mit dem Bild bzw. Gesicht durchgeführt. Die Antwort dieser 48 Filter an einer Position  $\vec{x}$  wird als Jet  $J(\vec{x})$  bezeichnet, die Antwort nur eines Filters  $\psi_q$  als Morlet  $M_q$ .

$$M_q(\vec{x}) = \int I(\vec{x}) \psi_q(\vec{x} - \vec{x}') d^2 \vec{x}' \quad (1.27)$$

$I(\vec{x})$  ist das Gesichtsbild mit den Ortskoordinaten  $\vec{x}$ . Der Jet ist der Vektor der Morlets:

$$J(\vec{x}, q) = \begin{pmatrix} M_1(\vec{x}) \\ M_2(\vec{x}) \\ \vdots \\ M_n(\vec{x}) \end{pmatrix} \quad (1.28)$$

### 1.1.6.2 Das Finden der Landmarken / des Graphen

Nachdem nun erläutert wurde, wie eine Filterantwort an einem Ort gewonnen wird, ist noch zu klären, welche Landmarken benutzt werden, bzw. wie sie gefunden werden. Die Landmarken bilden den sogenannten Graphen. Der Graph ist eine Art Gitternetz (siehe Abbildung 1.8). An jedem Schnittpunkt des Gitternetzes wird eine Filterantwort abgenommen.

Um die Position des Graphen und damit die Position der Landmarken zu bestimmen, wird ein nach Möglichkeit weitgehend allgemein gültiger Modellgraph verwendet. Man sucht nun die Position, an der der Modellgraph am besten passt. Dazu könnte die im Kapitel 1.1.6.3 beschriebene Kenngröße "Ähnlichkeit/Similarity" verwendet werden. Man kann aber auch mit Hilfe der anderen Verfahren (Template Matching, Neuronale Netze, etc.) zunächst die Landmarken suchen und ggf. den Graph durch Interpolation/Triangulation vervollständigen. Anschließend fährt man nach dem Hierarchical Graph Matching fort.

So entsteht in unserem Fall ein Gitternetz mit 169 Knoten. An jedem dieser Knoten wird der entsprechende Betrag der 48 Filterantworten geschrieben. Dieses System beinhaltet also



*Abbildung 1.8: Beispiel Gesichtsgraph*

8112 Zahlen (169 Knoten x 12 Richtungen x 4 Frequenzen). Diese spannen einen 8112-dimensionalen Vektorraum auf.

### 1.1.6.3 Vergleich von Gesichtern

Will man nun zwei Gesichter vergleichen, benötigt man ein geeignetes Maß. In einem Vektorraum bietet sich der euklidische Abstand oder der dazwischen liegende Winkel an. Die Benutzung des Winkels hat den Vorteil, dass dieser unabhängiger von Kontrast und Helligkeit ist als der euklidische Abstand. Die Ähnlichkeit  $S$  (Similarity) zweier Gesichter an einem Ort lässt sich durch das Bilden des Kosinus des Winkels (Skalarprodukt) zwischen zwei Jets  $J$  und  $J'$  bestimmen. Wobei die Ähnlichkeit zunächst an jedem Knoten  $k$  berechnet wird und anschließend über alle  $N$  Knoten aufsummiert wird. Sind  $a_J$  und  $a_{J'}$  die Amplituden der Jets, so berechnet sich die Ähnlichkeit  $S(\vec{x})$  durch

$$S_{JJ'} = \sum_{k=0}^N \frac{\vec{a}_{Jk} \cdot \vec{a}_{J'k}}{\|\vec{a}_{Jk}\| \cdot \|\vec{a}_{J'k}\|} \quad (1.29)$$

Sind zwei Gesichter identisch, ist  $S(J, J') = 1$ ; sind sie vollständig verschieden, wird  $S(J, J') = 0$ . In der Praxis werden diese Werte aber nie erreicht. Die Filterantworten der Wavelets sind komplex. Man könnte also auch die Phasen als Ähnlichkeit benutzen. Da sie aber stark vom Ort abhängen, variieren sie stark, wenn die Orte der Knoten nicht exakt übereinstimmen. Man vernachlässigt daher gern die Phase. Im Allgemeinen ist aber die Amplitudenmethode hinreichend genau.



## 1.2 Grenzen der Gesichtserkennung

Auch wenn die Erkennungssysteme recht robust gegen Schwankungen der mittleren Helligkeit sind, sind sie immer noch von der Beleuchtung abhängig. K. Brünenberg hat dies für das Elastic Bunch Graph - Verfahren in [Brü99] untersucht. Er konnte einen Fehler beim Finden der Landmarken aufgrund geänderter Beleuchtungssituationen nachweisen. Aber auch die Gabor-Wavelets reagieren auf ungleichmäßige Beleuchtung. Machen wir folgendes Gedankenexperiment:

Angenommen es gebe die Zwillinge A und B. Von beiden gibt es je ein Foto in einer Bild-datenbank. Allerdings ist bei A bei der Aufnahme ein heller Fleck auf der Stirn entstanden. Die Zwillinge sollen nun nocheinmal vor eine Kamera treten. Ein Erkennungssystem soll nun entscheiden, ob es sich um den einen oder den anderen Zwilling handelt. Schicken wir nun Zwilling A in die Erkennung. Die Aufnahme erfolgt tadellos. Das System wird Zwilling B als den Richtigen präsentieren. Beide sehen sich bis auf den Fleck ähnlich. Da Zwilling A aber in der Datenbank einen Fleck hat, sinkt seine Ähnlichkeit um diesen. Die Aufnahme in der Datenbank von Zwilling B kann ihre Ähnlichkeit halten. Logischerweise hat B jetzt eine größere Ähnlichkeit. Das System entscheidet sich dafür, dass Zwilling „A“ Zwilling „B“ ist.

Diese und andere Phänomene treten bei der Erkennung auf. Es ist daher ratsam, immer ungestörte Fotos zu benutzen. Dies ist aber nicht immer möglich. Man versucht daher, sich dem ungestörten Zustand mit Hilfe von Korrekturverfahren anzunähern.

## 2 Grundlagen der Glanzkorrektur

Bevor man sich mit den Algorithmen beschäftigt, sollte man sich klar machen, womit man es zu tun hat. In diesem Kapitel wird zunächst “Glanz” definiert (Kapitel 2.1). Danach wird eine Möglichkeit der Detektion aufgezeigt (Kapitel 2.2). Des Weiteren sollen hier die Möglichkeiten der Anwendung erläutert werden und die daraus entstehenden Einschränkungen für die Korrekturalgorithmen (Kapitel 2.3). Zum Schluss soll der Stand der Technik analysiert und für den Anwendungszweck bewertet (Kapitel 2.4) sowie der Einfluss des Glanzes dargestellt werden (Kapitel 2.5).

### 2.1 Was ist Glanz?

“In der digitalen Bildverarbeitung wird häufig angenommen, dass eine Szene nur aus matten (Lambertschen) Objekten besteht [Kos97].“ Nach [VPS<sup>+</sup>02] entsteht Glanz durch übermäßige Reflektion an spiegelnden Flächen. Hier soll Glanz ebenso verstanden werden. Diese Reflektion überdeckt die ursprüngliche Oberflächenstruktur des Objekts, in unserem Fall das Gesicht. Das kann z. B. entstehen, wenn die Strahlungsverteilung vom Lambertschen Strahler abweicht und die Leuchtdichte des Objekts gebündelt in eine Richtung zurückgeworfen wird. Das ist für unsere Anwendung störend, da wir gerne die Oberflächenstruktur der Person messen wollen und nicht das Umgebungslicht.

### 2.2 Glanzdetektion

#### 2.2.1 HSV-Methode auf chromatischen Bildern

Wird Glanz wie in Kapitel 2.1 betrachtet, kann dieser im HSV-Farbraum detektiert werden [o.V01]. Überlicherweise spiegelt sich Glanz in hohen Helligkeitswerten und niedrigen

Sättigungen wieder. Der HSV-Raum ist ein dreidimensionaler Farbraum. Die drei Basisvektoren sind die Helligkeit, die Sättigung und der Farbton. Typischerweise ist die Helligkeit  $V$  und die Sättigung  $S$  im Wertebereich  $[0, 1]$  definiert und der Farbton  $H$  im Bereich von  $[0^\circ, 360^\circ]$ . Aus dem RGB-Raum kann mit Hilfe der Transformationsgleichungen der HSV-Raum gewonnen werden.

$$\begin{aligned} H &= \frac{(90 - \arctan(\frac{F}{\sqrt{3}}) + C)}{360} \\ S &= 1 - \frac{\min(R, G, B)}{V} \\ V &= \frac{R + G + B}{3} \end{aligned} \quad (2.1)$$

mit  $F = \frac{2R - G - B}{G - B}$  und  $C = 0$ , wenn  $G > B$  bzw.  $C = 180$ , wenn  $G < B$  [Mag02]

Führt man nun Schwellen für  $S$  und  $V$  ein, kann man die Pixel herausfinden, die Glanz beinhalten. Typischerweise sinkt an solchen Stellen die Sättigung während die Helligkeit steigt.

### 2.2.2 Zwei-Stufen-Methode auf Luminanzbildern

Auf Luminanzbildern fehlt die Farbinformation. Glanz kann hier nur anhand der Helligkeit detektiert werden. Würde man hier einen „einfachen“ Schwellenwert einführen, so fände man schnell auch Pixel, die nur hell aber kein Glanz sind. Bei dem nachfolgend beschriebenen Verfahren nutzt man aus, dass sich Glanz in der Regel durch eine Art Gaussglocke kennzeichnet. Im Zentrum ist Glanz deutlich heller als an seinem Rand.

Man sucht im Bild Punkte, die über einem relativ hohen Schwellenwert  $s_1$  liegen. Diesen Schwellenwert sollte man von dem Bildmittelwert abhängig gestalten. Man erhält eine Menge  $G$  von Pixeln, die diese Anforderung erfüllen. Um die Pixel der Menge  $G$  herum sucht man nun Pixel, die über einem zweiten Schwellenwert  $s_2$  ( mit  $s_2 < s_1$ ) liegen. Diese Pixel werden der Menge  $G$  hinzugefügt. Man wiederholt den zweiten Schritt mit dem Schwellenwert  $s_2$  solange, bis keine Pixel mehr gefunden werden. Die Pixel der Menge  $G$  am Ende des Verfahrens sind die gesuchten Glanzpixel.

### 2.2.3 Eigenvektor-Methode auf Luminanzbildern

Es soll ein Vektorraum  $V_{oG}$  definiert werden, der durch die Eigenvektoren  $\vec{u}_i$  (mit  $i \in \{1, \dots, n\}$ ) aufgespannt wird. Wurden die Eigenvektoren  $\vec{u}_i$  aus einer Menge von Gesichtern erstellt (siehe 1.1.5 auf Seite 11), die keinen Glanz beinhalten, so sollten, wenn  $n$  groß genug ist, alle Gesichter in diesem Raum darstellbar sein. Versucht man ein Gesicht  $\vec{x}$  mit Glanz als Linearkombination der Basisvektoren des Vektorraums darzustellen, so wird einem das nur bedingt gelingen. Glanz ist in dem Vektorraum nicht darstellbar. Berechnet man die Differenz des Originalgesichts und der Linearkombination, die wir hier als Rekonstruktion bezeichnen wollen, so ist überall dort, wo die Differenz größer als null ist, Glanz. Mathematisch heißt das:

$$\vec{x}_r = \sum_{i=0}^n k_i \vec{u}_i \quad (2.2)$$

mit  $k_i \in \mathbb{R}$  (Die Berechnung von  $k_i$  wurde im Kapitel 1.1.5 erläutert).  $\vec{x}_r$  ist die Rekonstruktion. Die Lösungen für  $(x,y)$  der Gleichung

$$\begin{aligned} |\vec{x}_r(x,y) - \vec{x}(x,y)| &> c \\ c &= \text{const.} \end{aligned} \quad (2.3)$$

sind die Orte des Glanzes. Die Differenz in der Gleichung 2.3 wird auch als Residuum bezeichnet.

Die Praxis hat gezeigt, dass die Kombination der beiden Verfahren die besten Ergebnisse auf Luminanzbildern liefert. Bei der Kombination wird zunächst das Differenzbild berechnet. In der Praxis ist dieses Bild nicht idealerweise null, wenn an der Stelle kein Glanz ist. In diesem Bild wird nach der Zwei-Stufen-Methode nach den größten Differenzen gesucht. Die Zwei-Stufen-Methode wird dadurch um eine Unabhängigkeit gegenüber lokalen, natürlichen Helligkeitsveränderungen verbessert.

## 2.3 Einschränkungen im Praxisbetrieb

Die Korrekturalgorithmen in dieser Arbeit sollen, wie bereits erwähnt, die Erkennungsmaschine für Gesichtserkennung robuster gegen Glanz machen. Standardanwendungen der Gesichtserkennung sind mit einem Türschloss vergleichbare Anwendungen, datenbankbasierte Anwendungen in Bilddatenbanken, Überwachungen von Gebäuden und Plätzen sowie

die Fahndung. Daraus resultieren bestimmte Prämissen für das Korrektursystem:

- Die Beleuchtungssituation ist gänzlich unbekannt. In Ausweisdatenbanken ist die nachträgliche Rekonstruktion von Beleuchtungssituationen nicht möglich. Eine kontrollierte Beleuchtungssituation zukünftiger Passbilder erscheint fast unmöglich, wenn man allein die große Anzahl von Fotostudios für Passbilder betrachtet.
- Bilder von Personen liegen in der Regel in einfacher Ausfertigung vor.
- Beleuchtungssituationen können variieren (z.B. durch Tageszeit bedingte Änderung der Beleuchtung auf öffentlichen Plätzen).

## 2.4 Überblick über Glanzkorrekturalgorithmen

Natürlich haben sich bereits andere Personen über Glanzkorrektur und Glanzdetektion Gedanken gemacht. Dabei scheint es fast so, als ob der Glanz, neben der Mustererkennung, vor allem Bilder, die für medizinische Anwendungen produziert wurden, beeinflusst. Im Folgenden seien ein paar Ansätze kurz erläutert.

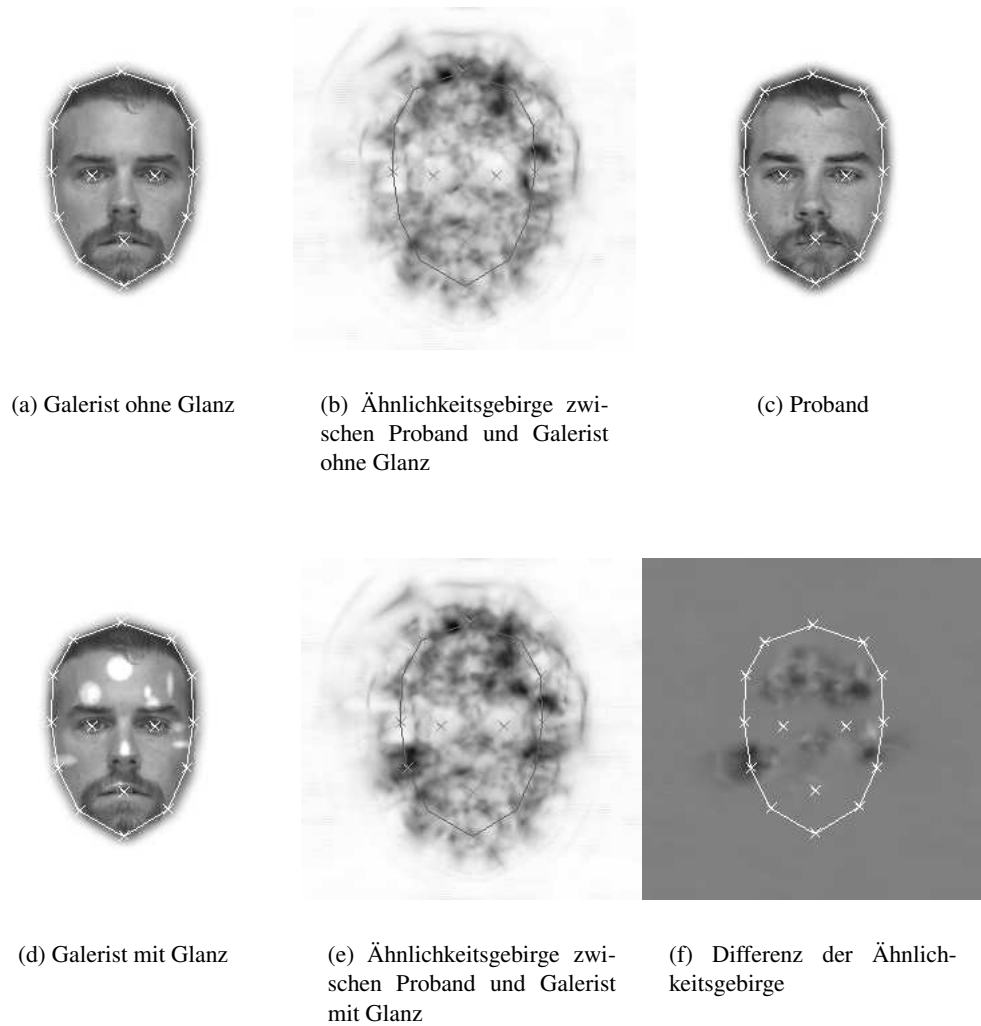
In [VPS<sup>+</sup>02] erläutert eine Gruppe von Wissenschaftlern ihre Methode zur Glanzlichtsubstitution in endoskopischen Bildern. Die Detektion erfolgt wie in Kapitel 2.2 beschrieben. Danach wird eine Vertrauenskarte eingeführt, die an den Stellen mit Glanzeffekten null und sonst eins ist. Aus den aufgenommenen Bildern erzeugen die Wissenschaftler ein 3D-Modell, um eine Diagnose stellen zu können. Beim Blockmatching zur 3D-Rekonstruktion werden die Pixel, die in der Vertrauenskarte als 0 markiert sind, nicht verwendet. Überhaupt nicht rekonstruierbare Pixel werden interpoliert.

Andreas Koschan stellt in [Kos97] mehrere Korrekturverfahren vor. Sie alle basieren auf dem Dichromatischen Reflexionsmodell. Man geht davon aus, dass sich Beleuchtungs- und Oberflächenfarbe hinreichend gut unterscheiden und so im Farbraum trennbar sind. Ist eine der beiden Farben bekannt, kann je nach Verfahren (z.B. durch Projektion im Vektorraum oder Farbdreieck) die andere berechnet werden. Soll das matte Bild gewonnen werden, muss die Beleuchtungsfarbe bekannt sein.

Beide Verfahren sind für die Gesichtserkennung ungeeignet, da keine Aussagen über Beleuchtung gemacht werden können und keine Bildsequenzen vorhanden sind (vgl. Kapitel 2.3).

## 2.5 Einfluss des Glanzes auf die Ähnlichkeit

Der Einfluss von Glanz auf die Ähnlichkeit von Gesichtern soll an einer Stichprobe erläutern werden. Von einer zu betrachtenden Person existieren zwei Aufnahmen. Eine der beiden Aufnahmen wird künstlich verglanzt. Wie das geschehen kann ist in Kapitel 5.1 beschrieben. Berechnet man die Ähnlichkeit zwischen dem ersten Bild und dem unverglanzten zweiten Bild sowie dem verglänzten Bild, an jedem Punkt des Gesichts, so erhält man ein Ähnlichkeitsgebirge wie es in Abbildung 2.1 zu sehen ist. Anschließend bildet man die Differenz beider Ähnlichkeitsgebirge. Man kann erkennen, dass sich der Einfluss des Glanzes vorwiegend in einer niedrigeren Ähnlichkeit niederschlägt. Aber es ist auch möglich, dass die Ähnlichkeit steigt. Der Einfluss von Glanz ist nicht so trivial, wie man es vielleicht im ersten Augenblick vermutet.



---

**LEGENDE Ähnlichkeitsgebirge:** schwarz = geringe Ähnlichkeit, weiss = große Ähnlichkeit; **Differenzbild:** grau = keine Differenz, schwarz = Ähnlichkeitsgebirge mit Glanz kleiner, weiss = Ähnlichkeitsgebirge mit Glanz grösser

---

*Abbildung 2.1: Einfluss des Glanzes auf die Ähnlichkeit*

## 3 Messmethoden und Kenngrößen

Um die im Kapitel 4 beschriebenen Verfahren auf ihre Tauglichkeit für die Gesichtserkennung zu prüfen, sind Größen notwendig, die objektiv gemessen werden können.

Um ein Verfahren zu testen, wird eine Gesichtsdatenbank genutzt. Diese Datenbank enthält von einer Person mehrere Ablichtungen. Je nach „Schwierigkeitsgrad“ des Tests variieren die Ablichtungen in der Aufnahmequalität, dem Aufnahmeort und dem zeitlichen Abstand der Aufnahmen. Die Datenbank wird in zwei Mengen unterteilt. Diese werden üblicherweise als Probe und Galerie bezeichnet. Die Galerie sollte nur jeweils ein Bild einer Person enthalten. Die Personen in der Probe sollen einer Person in der Galerie zugeordnet werden. Diese Zuordnung muss eindeutig sein. Die Eintragungen in der Probe sind fast beliebig. Repräsentative Aussagen können aber nur gemacht werden, wenn in der Probe jede Person gleich oft vertreten ist. Im Folgenden werden, wegen der Übersichtlichkeit, nur solche Datenbanken betrachtet, die jeweils von jeder Person ein Bild in Probe und Galerie haben. Für den Fall, dass es mehrere Variationen einer Person gibt, gelten die folgenden Ausführungen genauso. Hier ist nur zusätzlich darauf zu achten, dass die Zuordnung zwischen Probanden und Galeristen eindeutig gewährleistet ist. Dies wird erreicht, indem eine Personal Identification Number (PIN) eingeführt wird.

### 3.1 Rangstatistik

Um die Rangstatistik ausrechnen zu können, muss zunächst die Ähnlichkeit  $s(P, G)$  (siehe Kapitel 1.1.6.3) von allen Probanden  $P_i$  mit jedem Galeristen  $G_k$  berechnet werden. Man erhält die Tabelle 3.1.

Man sortiert nun die Zeilen der Tabelle der Größe nach, sodass gilt  $s_{ik_1} > s_{ik_2} > \dots > s_{ik_n}$ . Den größten Wert einer Zeile bezeichnet man als Rang 1, den zweiten als Rang 2 usw. Als den Rang eines Probanden bezeichnet man den Rang des Galeristen, der dem Probanden entspricht. Die Anzahl der Probanden, die ihren Partner in der Galerie auf Rang 1 haben,



	$G_1$	$G_2$	...	$G_n$
$P_1$	$s(1,1)$	$s(1,2)$	...	$s(1,n)$
$P_2$	$s(2,1)$	$s(2,2)$	...	$s(2,n)$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$P_n$	$s(n,1)$	$s(n,2)$	...	$s(n,n)$

*Tabelle 3.1: Ähnlichkeitsmatrix*


ergibt den Rang 1 - Wert. Dieser wird normalerweise in Prozent angegeben. Der Wert der folgenden Ränge ergibt sich, indem die Anzahl der Probanden auf Rang  $n+1$  in Prozent und den Wert für Rang  $n$  (in Prozent) summiert werden. Daraus ergibt sich, dass Rang  $n$  bei  $n$  Galeristen 100% ist.

Denkbar ist auch, dass ein Proband keinen passenden Galeristen hat. Das wäre z. B. dann der Fall, wenn eine Person versucht, einen Bereich zu betreten, in den sie nicht hinein darf. Sie ist deshalb nicht in der Menge der zu akzeptierenden Personen (=Galerie) enthalten. In einem solchem Fall würde das System auch einen Galeristen auf Rang 1 setzen. Idealerweise sollte dieser dann aber eine kleinere Ähnlichkeit haben als andere Probanden, die einen passenden Galeristen besitzen. Hat der Proband aber einen passenden Galeristen, sollte dieser im Idealfall immer den Rang 1 belegen.

### **3.2 Die False Reject Rate (FRR), die False Acceptance Rate (FAR) und die Equal Error Rate (EER)**

Diese Kenngrößen können am besten anhand einer Zutrittskontrolle erklärt werden. Eine Gesichtserkennungsstation ist an einer Tür installiert. Sie soll nur den Personen (entspricht der Probe) die Tür öffnen, die sie in ihrer Datenbank hat (entspricht der Galerie). Es gibt nun zwei Fehlerarten. Die erste Möglichkeit ist, dass das System eine berechnete Person nicht hineinlässt. Diesen Fall bezeichnet man als falsche Rückweisung oder Fehler Typ I [MW02]. Die zweite Möglichkeit ist, dass eine unberechtigte Person die Tür passiert. Dieser Fall wird Falschakzeptanz oder Fehler Typ II genannt.

Um die Größen zu bestimmen machen wir folgendes Experiment. Eine Menge von Personen versucht eine Tür, die durch eine Gesichtserkennung geschützt ist, zu passieren. Die Tür passieren dürfen nur jene Personen, die in der Galerie der Gesichtserkennungsstation



(a) Ideale Ähnlichkeitsmatrix

(b) reale Ähnlichkeitsmatrix

Abbildung 3.1: Beispiel Ähnlichkeitsmatrix

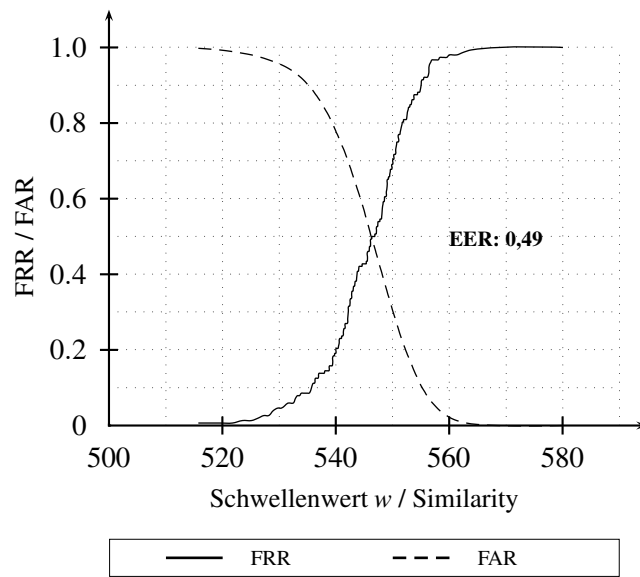


Abbildung 3.2: Beispiel FRR/FAR Kurve

gespeichert sind. Die Menge enthält sowohl berechnete als auch unberechnete Personen. Um zu bestimmen, ob eine Person in der Galerie ist, werden die Ähnlichkeiten der Person mit allen Galeristen berechnet. Ist die Ähnlichkeit zwischen einer Person, die die Tür passieren will, und einem Galeristen größer als ein eingestellter Schwellenwert, so geht man davon aus, dass die Person berechnete ist die Tür zu passieren. Je nachdem, wie groß der Schwellenwert ist, ist der eine oder der andere Fehler größer. Stellt man den Schwellenwert klein ein, so werden weniger berechnete Personen zurückgewiesen, aber mehr unberechnete Personen akzeptiert. Wird er auf einen höheren Wert gesetzt, passiert das Gegenteil. Daraus berechnet man die Kenngrößen FAR (False acceptance rate) und FRR (False reject rate):

$$FRR = \frac{\text{Anzahl der falsch zurückgewiesenen Eintrittsversuche}}{\text{Anzahl der berechtigten Eintrittsversuche}} \quad (3.1)$$

$$FAR = \frac{\text{Anzahl der falsch akzeptierten Eintrittsversuche}}{\text{Anzahl der unberechtigten Eintrittsversuche}} \quad (3.2)$$


Ist die FAR gleich der FRR, so wird diese Größe als EER (equal error rate) bezeichnet. Das ist der Punkt, an dem prozentual gleich viele Personen falsch zurückgewiesen bzw. falsch akzeptiert werden. Je kleiner die EER ist, umso besser ist das System.

Die Berechnung der Kenngrößen False reject rate (Falsche Rückweisung), False acceptance rate (Falschakzeptanz) und equal error rate (Gleiche Fehlerrate) kann anhand der Tabelle 3.1 erfolgen. Die Ähnlichkeiten, die auf der Matrixdiagonalen liegen, sind diejenigen, bei denen Galerist und Person die gleiche Identität haben, also genau diejenigen, die den Fehler Typ I bestimmen. Diese Ähnlichkeiten bezeichnet man auch als die Ähnlichkeiten der Clients, die übrigen als die Ähnlichkeiten der Impostor. Die FRR oder FAR kann nur bei einem gegebenen Schwellenwert  $w$  für die Ähnlichkeit berechnet werden. Die Anzahl der falsch zurückgewiesenen Personen ist dann gleich der Menge an Ähnlichkeiten, für die gilt:

$$s_{ii} < w \quad (3.3)$$

Für die falsch akzeptierten Personen gilt entsprechend:

$$s_{ik} \geq w \text{ mit } i \neq k \quad (3.4)$$



**Abbildung 3.3:** Unabhängigkeit zwischen Rang und EER

Berechnet man die FAR und die FRR für alle  $w$ , so gilt:

$$\begin{aligned}
 EER(w_0) &= FAR(w_0) \\
 \text{bzw. } EER(w_0) &= FRR(w_0) \\
 \text{wenn } FRR(w_0) &= FAR(w_0)
 \end{aligned}
 \tag{3.5}$$

### 3.3 Unabhängigkeit zwischen Rang und EER

Ein gutes Erkennungssystem hat im Idealfall eine Rang 1 - Statistik von 100% und eine gleiche Fehlerrate von 0%. Diese Größen sind unabhängig voneinander. Ein Gesichtserkennungssystem mit einer Rang 1 - Statistik von 100% muss nicht automatisch eine gute EER haben. Sind die Ähnlichkeiten wie in Abbildung 3.3 verteilt, kann die Schwelle beliebig variiert werden und trotzdem gibt es immer entweder eine Falschakzeptanz oder eine falsche Zurückweisung. Im Extremfall kann eine der beiden Größen sogar sehr groß werden.

### 3.4 Minimaler Fehler

Eine weitere Messgröße, die aber in der Gesichtserkennung eher unüblich ist, ist der minimale Fehler. Als Grundlage dieser Größe dienen die FAR und die FRR (siehe Kapitel 3.2 ). Zunächst wird die Summe von FRR und FAR bei einem jeweils eingestellten Schwellenwert  $w$  berechnet.

$$\zeta(w_i) = FRR(w_i) + FAR(w_i)$$

Der minimale Fehler ist das Minimum über alle Summen.

$$\xi = \min(\zeta_w) = \min(FRR_w + FAR_w)$$

### 3.5 Weitere Messmöglichkeiten

Da nicht zu erwarten ist, dass sich die Rang 1 - Statistik oder EER aufgrund kleiner Veränderungen, wie z. B. der Glanzkorrektur, sichtbar ändert, müssen zusätzliche Messgrößen betrachtet werden. Zunächst kann untersucht werden, ob sich die Ähnlichkeit zweier Gesichter durch die Korrektur verbessert. Kann sich hier bereits kein Erfolg einstellen, werden sich auch die anderen Größen nicht verbessern. Hier muss nur aufgepasst werden, dass Misserfolg nicht mit Erfolg verwechselt wird. Zwei Gesichter, die korrigiert werden, indem das Bild schwarz gemacht wird, steigen dadurch sehr gut in ihrer Ähnlichkeit.

Erfolg kann nicht nur in der Gesamtänderung der Rangstatistik gesehen werden. Die Bildung der Differenz zwischen dem Rang  $R$  eines unkorrigierten und des korrigierten Gesichts ist ebenfalls ein Maß für den Erfolg der Korrekturmaßnahme. Wird diese Größe  $\Delta R$  über alle Gesichter gemittelt, so ist das Ergebnis die durchschnittliche Rangänderung  $\overline{\Delta R}$ .

$$\begin{aligned}\Delta R &= R_{\text{unkorrigiert}} - R_{\text{korrigiert}} \\ \overline{\Delta R} &= \frac{1}{N} \sum_{i=0}^N R_i\end{aligned}\tag{3.6}$$

## 4 Glanzkorrekturalgorithmen

Im folgenden Kapitel sollen die untersuchten Korrekturalgorithmen erläutert werden. Durch den Glanz werden die entsprechenden Informationen, die in den Pixeln stecken, unbrauchbar. Es gibt nun zwei Möglichkeiten dieses Problem zu lösen. Die erste Möglichkeit besteht darin, die Benutzung der Pixel zu vermeiden. Die andere Möglichkeit ist, dass die Information, die ohne Glanz vorhanden wäre, durch ein Korrekturverfahren angenähert wird. Den ersten Weg bestreitet die Fill-In Methode, den zweiten die anderen Korrekturverfahren. Bevor die Verfahren greifen können, müssen Pixel, die durch Glanz gestört sind, herausgesucht werden. Dies geschieht mit Hilfe eines der bereits beschriebenen Detektoren. Das Ergebnis des benutzten Detektors wird in einer Vertrauenskarte notiert. Die Vertrauenskarte ist ein Bild der gleichen Größe wie das zu untersuchende Bild. Die Farbtiefe ist 1bit. Ist ein Pixel durch Glanz gestört, so wird an der entsprechenden Stelle in der Vertrauenskarte eine eins notiert, andernfalls eine null. Alle Pixel, die als Glanzpixel markiert sind, werden durch einen Wert ersetzt, der durch die Werte der Pixel ohne Glanz berechnet wird oder der Wert wird nicht benutzt. Die Berechnung erfolgt jeweils typisch für das entsprechende Verfahren.

### 4.1 Glanzkorrektur durch Fill-In Methode

Bei diesem Verfahren muss vorausgesetzt werden, dass die Galerie glanzfrei ist. Dadurch bleibt der Einfluss des Glanzes bei der Berechnung der Ähnlichkeiten zwischen einem Probanden und den Galeristen konstant. Fällt ein Knotenpunkt (Landmarke) des gerade zu untersuchenden Probanden auf einen defekten Pixel, wird die errechnete Similarity an diesem Punkt durch eine Konstante  $c_0$  ersetzt. Ist  $s(g, p)$  die Gesamtähnlichkeit zwischen Proband  $p$  und Galerist  $g_i$  und sind  $\tilde{s}_i(g, p)$  die Ähnlichkeiten im Knotenpunkt  $i$ , so berechnet sich die Gesamtähnlichkeit im unkorrigierten Fall als

$$s_{oK}(g, p) = \sum_{i=0}^n \tilde{s}_i(g, p) \quad (4.1)$$

Sind  $k$  die  $m$  defekten und  $j$  die  $n$  sauberen Knotenpunkte, so ist die Gesamtähnlichkeit im korrigierten Fall:

$$\begin{aligned} s_{mK}(g, p) &= \sum_{j=0}^n \tilde{s}_j(g, p) + \sum_{k=0}^m c_0 \\ &= \sum_{j=0}^n \tilde{s}_j(g, p) + m \cdot c_0 \end{aligned} \quad (4.2)$$

Der Betrag  $m \cdot c_0$  hat keinen Einfluss auf die Rangstatistik, da er bei jeder Berechnung der Ähnlichkeit zwischen dem Probanden und einem Galeristen gleich groß ist. Lediglich der glanzfreie Teil  $\sum_{j=0}^n \tilde{s}_j(g, p)$  bestimmt die Rangstatistik unter der Prämisse, dass die Galerie glanzfrei ist. Die EER hingegen wird über alle Ähnlichkeiten hinweg berechnet. Durch das vom Probanden abhängende  $m(P) \cdot c_0$  ändert sich auch die EER. Wird  $c_0$  anders eingestellt, kann sich auch die EER ändern.


Sind im Gegensatz zur Voraussetzung auch die Galeristen verglänzt, so ändert sich auch die Rangstatistik. Die Menge der Glanzpunkte variiert bei jeder Berechnung der Ähnlichkeit. Der Summand  $m \cdot c_0$  ist nicht mehr konstant, wodurch die Größe  $c_0$  einen großen Einfluss auf die Differenz der Ähnlichkeiten untereinander hat. Das Verfahren ist daher zur Korrektur von Galeristen nicht geeignet.

Wird  $c_0$  in dem Fall, dass die Galeristen nicht gestört sind, auf eins gesetzt, so ist das mit dem Folgenden vergleichbar: Der Ausschnitt des Probanden an der entsprechenden Stelle wird dem Galeristen, mit dem eine Ähnlichkeitsberechnung durchgeführt wird, eingesetzt.

Es gibt dann noch ein weiteres Problem. Da die Filter an den Knotenpunkten recht weit schauen, wird ein Fehler gemacht, wenn nur die Knotenpunkte berücksichtigt werden, die direkt auf einem Glanzpunkt liegen. Dieser Fehler wird hingenommen, da es dazu bis jetzt keine sinnvolle Alternative gibt. Eine Annäherung an die Wirklichkeit kann erfolgen, wenn man die Glanzbereiche der Vertrauenskarte vor der Korrektur erweitert.

## 4.2 Glanzkorrektur durch Interpolation

Die Korrektur durch Interpolation ist eine der einfachen Methoden um unbekannte Werte zu schätzen. Nach [Jäh02] beruht die Interpolation darauf, zunächst das kontinuierliche Bild



**Abbildung 4.1:** Gesuchte Nachbarpixel


zu rekonstruieren, das anschließend neu abgetastet wird. Die Rekonstruktion des kontinuierlichen Bildes gelingt nur dann eindeutig, wenn das Abtasttheorem (Nyquist-Shannon-Theorem) nicht verletzt wird. Das Abtasttheorem besagt, dass die höchste im Bild vorkommende Frequenz mindestens an zwei Stellen abgetastet werden muss.

Betrachten wir die Korrektur für einen defekten Pixel  $G$ . Da dieser vorzugsweise nicht alleine defekt ist, werden die Nachbarpixel gesucht, die nicht als Glanz markiert worden sind. In unserem Fall suchen wir die acht nächsten Pixel  $O_i$  wie in der Abbildung 4.1 zu sehen ist. Die Menge der Pixel kann beliebig variieren. Allerdings haben die gezeigten Positionen den Vorteil, dass sie leicht in der Bildmatrix zu finden sind. Die Koordinaten des Pixels  $G$  müssen nur variiert werden. Je nachdem ob nur die  $x$ -, die  $y$ -Koordinate oder beide variiert werden, erhält man den entsprechenden Pixel  $O_i$ .

$G$  soll als Linearkombination von den Punkten  $O_i$  dargestellt werden. Die Gewichtung lässt sich aus den Abständen bestimmen. Die Koordinaten der Pixel seien  $x$  und  $y$ .  $\Delta d_i$  sei der Abstand zwischen  $G$  und  $O_i$ . Dann ist

$$\Delta d_i = \sqrt{(x_G - x_{O_i})^2 + (y_G - y_{O_i})^2} \quad (4.3)$$





**Abbildung 4.2:** Glanzkorrektur durch Interpolation

Der Grauwert von  $G$  lässt sich dann als gewichtete Summe der Grauwerte  $O_i$  darstellen.

$$G = \frac{1}{\sum_{i=1}^8 \Delta d_i} (O_1 \Delta d_5 + O_2 \Delta d_6 + O_3 \Delta d_7 + O_4 \Delta d_8 + O_5 \Delta d_1 + O_6 \Delta d_2 + O_7 \Delta d_3 + O_8 \Delta d_4) \quad (4.4)$$

Wenn die Nachbarpixel nicht als Glanz detektiert worden sind, werden Sie dennoch von den Glanzeffekten beeinflusst sein. Es ist daher ratsam, die Nachbarpixel nicht direkt an der Grenze zu suchen, um den gewünschten Effekt zu erzielen.

Das Vorgehen, dass ein neuer Pixel aus den umliegenden Nachbarn berechnet wird, wird in der Literatur als inverse Interpolation oder Rückwärtsinterpolation bezeichnet [Jäh02]. Die beschriebene Berechnung der neuen Pixel ist als Lagrangesche Interpolation bekannt [Sch95]. Durch dieses Vorgehen wird allerdings das Abtastgitter vergrößert. Dadurch erhält man einen Tiefpass und Aliaseffekte, die man eigentlich nicht haben will [Sch95]. Vermeiden lassen sich diese jedoch nicht, da wir keinen Abtastpunkt innerhalb des Glanzes benutzen können. Durch die Fehler erhält man z. B. kein Auge zurück, sondern nur eine grobe Helligkeitsänderung am Glanzort (siehe 4.2). Im Kapitel 5 wird dann zu untersuchen sein, ob der Fehler, der durch den Glanz entsteht, oder der Fehler, der durch die Unterabtastung produziert wird, größer ist. Ist der Fehler der Unterabtastung geringer, so müsste eine bessere Erkennung möglich sein.

## 4.2.1 Das Kantenproblem

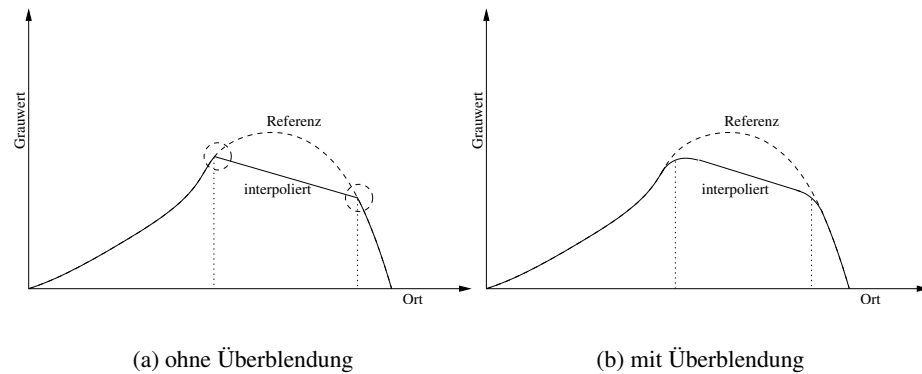


Abbildung 4.3: Kantenproblem

Am Übergang der Glanzumgebung zum Originalgesicht kann es zu ungewollten Kanten kommen. Das wird dadurch verursacht, dass ein gegebener Funktionsverlauf durch einen anderen ersetzt wird (vergleiche Abbildung 4.3). Solche Funktionen sind oft an der Übergangsstelle nicht differenzierbar. Die Abbildung 4.3 zeigt gestrichelt den unkorrigierten und durchgezogen den korrigierten Verlauf. Im Original würden sich keine Ecken oder Kanten ergeben. Da man den Bereich zwischen den gepunkteten Linien korrigieren muss, kommt es an der Übergangsstelle durch den linearen Verlauf der „Korrekturkurve“ zu undifferenzierbaren Stellen. Diese Stellen, die im Bild als Kanten sichtbar werden, sind immer eine Summe vor allem hoher Frequenzen. Eine solche Antwort würden auch die Gaborfilter liefern. Diese Antwort hat jedoch nichts mit den Gesichtseigenschaften zu tun. Aber dieser Fehler kann minimiert werden, indem man im Grenzbereich beide Bilderteile (original und korrigierte Fassung) überblendet. Haberäcker bezeichnet das als die einfachste Form des Mosaicing, wie das Zusammenfügen zweier Bilder genannt wird [Hab95]. Man erhält durch die Überblendung eine über den ganzen Definitionsbereich differenzierbare Funktion. Allerdings muss auch ein Kompromiss in der Ausdehnung der Überblendung gefunden werden. Eine weit ausgedehnte Überblendung würde eine Korrektur in schmalen, gestörten Bereichen kaum sichtbar machen, da die Korrektur im Übergangsbereich nur ein Bruchteil von der eigentlich möglichen ist. Abhilfe schafft hier eine Ausdehnung der Vertrauenskarte. Das hat allerdings zur Folge, dass ungestörte Bereiche mit korrigiert werden, aber diese will man eben gerne behalten. Nach [Hab95] kann das vermieden werden, indem man die

Überblendung in Laplace-Pyramiden implementiert.

Die Laplace-Pyramide ist eine Art Umsortierung des Bildes. Das Bild wird in Bilder zerlegt, die den tiefen, verschiedenen mittleren und den hohen Bereichen im Frequenzraum entsprechen. Vermeidung von Aliasing wird durch abgestimmte Hoch- und Tiefpässe erreicht [Kun02]. Das genaue Vorgehen ist in [Hab95, Sch95, Jäh02] beschrieben. An dieser Stelle sollte der Aufbau der Pyramide reichen.

$I_o(x,y)$  und  $I_c(x,y)$  seien die Eingangsbilder für das Mosaicing und  $L^{(o)}$  und  $L^{(c)}$  die berechneten Laplace-Pyramiden. Aus diesen wird nun eine neue Pyramide berechnet. Dazu muss zunächst eine Vertrauenskarte  $v(x,y)$  eingeführt werden. Je nachdem, welches Bild genutzt werden soll, enthält die Vertrauenskarte eine 1 oder eine 0. Der Rand wird mit einer 2 markiert. Nach [Hab95] berechnet sich die neue Laplace-Pyramide als

$$L_i^{(neu)}(x,y) = \begin{cases} L_i^{(o)}(x,y), & \text{falls } v(x,y) = 0 \\ \frac{L_i^{(o)}(x,y) + L_i^{(c)}(x,y)}{2}, & \text{falls } v(x,y) = 2 \\ L_i^{(c)}(x,y), & \text{falls } v(x,y) = 1 \end{cases} \quad (4.5)$$

Die neue Laplace-Pyramide  $L_i^{(neu)}$  ist dann nur noch in ein „normales“ Bild zurück zu überführen.

#### 4.2.2 Flächen mit Struktur füllen (Strukturinterpolation, eigene Methode)

Die bilineare Interpolation hat die Eigenschaft, dass sie recht homogene Fläche herstellt. Das wird durch den in der Interpolation automatisch integrierten Tiefpass verursacht (siehe Kapitel 4.2). Gesichter sind allerdings selten homogen. Sie bestehen aus Poren, Haaren usw. . Wird Glanz auf Augen, Zähne oder Ähnlichem korrigiert, wird durch die Interpolation schnell die Information der geometrischen Struktur von den besagten Objekten zerstört. Ein Bild eines Gesichts entsteht durch die Variation seines Reflektionsfaktors  $\rho$  abhängig vom Ort. Durch lokales Ändern der Beleuchtungsstärke  $E$  oder durch die Abhängigkeit von  $\rho$  vom Betrachtungswinkel  $\alpha$  entsteht ein typisches Glanzmuster.

$$L(x,y) = \rho(x,y,\alpha)E(x,y) \quad (4.6)$$

Man kann versuchen die Information aus  $\rho$  zumindest ansatzweise zurückzugewinnen. Die Gleichung kann man auch so formulieren:

$$L(x, y) = f(x, y) + g(x, y) + r(x, y) \quad (4.7)$$

Dabei ist  $f(x, y)$  die gesichtsspezifische Änderung der Leuchtdichte,  $g(x, y)$  ist das ungewünschte Glanzverhalten und  $r(x, y)$  der durch die Umformung verursachte Restfehler.  $g(x, y)$  wird in der Regel einen sehr glatten Verlauf haben,  $f(x, y)$  wird sich durch die Unebenheiten der Haut und die im Gesicht vorhandenen Kanten schnell ändern. Faltet man nun die Glanzstellen mit einem Tiefpass, so sollte man ungefähr  $g(x, y)$  erhalten. Durch Subtraktion erhält man  $f(x, y)$ .

$$f(x, y) \approx L(x, y) - g(x, y) \quad (4.8)$$

Die neue Helligkeitsverteilung erhält man, indem man die Grauwerte der Interpolation  $i(x, y)$  zu  $f(x, y)$  addiert.

$$L_{neu}(x, y) = i(x, y) + f(x, y) \quad (4.9)$$

Man erhält so eine Korrektur, bei der markante Strukturen erhalten bleiben.  $i(x, y)$  kann hier auch als rekonstruierter Gleichanteil betrachtet werden. Diese Methode wurde von mir Strukturinterpolation genannt. Das Ergebnis dieser Methode zeigt Abbildung 4.4.

### 4.3 Glanzkorrektur mit Hilfe der Gauß'schen Ausgleichsrechnung

Die Ausgleichsrechnung wurde von dem berühmten Mathematiker Carl Friedrich Gauß (1777-1855) entwickelt [Küc00]. Gleichungssysteme, die aufgrund von Messfehlern nicht exakt lösbar sind, können mit Hilfe der Ausgleichsrechnung im Sinne des kleinsten quadratischen Fehlers gelöst werden.

#### 4.3.1 Die Information „Gesicht“ ausnutzen

Bisher wurde versucht, aus den Nachbarn die Größe und den Grauwertverlauf der gestörten Pixel zu berechnen. Wenn man sich aber ein Gesicht anschaut, wird man feststellen,



**Abbildung 4.4:** Glanzkorrektur durch Strukturinterpolation

dass es einem bestimmten Muster folgt. Augen, Nase und Mund sind nahezu immer an derselben Stelle. Aufgrund dieser Tatsache werden auch die Grauwerte in gewissen Grenzen ähnlich verlaufen. Das erkennt man z. B. daran, dass die Varianz in einem Gesichtsdatensatz nicht sonderlich hoch ist. In dem Test der Messungen (siehe A.19 auf Seite 101) lag die Varianz bei nur 1,6 bei einer mittleren Ähnlichkeit von 48,50. Diese bedeutende Information wurde bis jetzt in keinem Algorithmus verwendet.

$I(x, y)$  sei das Grauwertbild eines Gesichts. Des Weiteren benötigt man einen Datensatz, der aus  $n$  ungestörten Gesichtern  $t_i(x, y)$  besteht.  $I(x, y)$  lässt sich annähernd schreiben als

$$I(x, y) \approx \sum_{i=1}^n k_i t_i(x, y) \text{ mit } k_i \in \mathbb{R} \quad (4.10)$$

Die Funktionen  $t_i(x, y)$  werden üblicherweise Trainingsgesichter genannt. Hat man genügend, so kann man schreiben

$$I(x, y) = \sum_{i=1}^{\infty} k_i t_i(x, y) \text{ mit } k_i \in \mathbb{R} \quad (4.11)$$

Die Berechnung von  $k_i$  erfolgt in 4.10 mit Hilfe der Ausgleichsrechnung. Man erhält so die bestmögliche Rekonstruktion, die aus den gegebenen Trainingsdaten möglich ist.  $I(x, y)$  muss nicht das ganze Gesicht beinhalten. Einzelne Teile des Gesichts wie Auge oder Nasen-



(a) künstlich verglanzt



(b) original




(c) Ausgleich mit 10 Gesichtern



(d) Ausgleich mit 200 Gesichtern

**Abbildung 4.5:** Glanzkorrektur mit Hilfe der Ausgleichsrechnung

flügel können ebenfalls als  $I(x,y)$  betrachtet werden. Egal ob man das ganze Gesicht oder einen Teil davon betrachtet, es wird immer versucht, Glanz mit zu rekonstruieren. Enthalten die Trainingsdaten keinen Glanz, ist es äußerst schwierig das „Original“ zu kopieren. Abbildung 4.6 zeigt denkbare Rekonstruktionsversuche. Die normal gestrichelte Gerade wäre das gewünschte Verhalten. Das wird durch die Ausgleichsrechnung aufgrund des Glanzes



**Abbildung 4.6:** Ausgleichsversuche

nicht realisiert. Würde man die entsprechenden Pixel der Ausgleichsrechnung vorenthalten, könnte man das gewünschte Verhalten erzwingen.

Gegeben sei das zu korrigierende Gesicht  $I(x,y)$ , die Trainingsgesichter  $t_i(x,y)$  und die Vertrauenskarte. Um nur einen Teil des Gesichtes zu betrachten, um damit z. B. Rechenzeit zu sparen, werden die Glanzpunkte einzeln prozessiert. Ein Glanzpunkt ist hier eine zusammenhängende Region in der Vertrauenskarte. Benötigt werden die Nachbarpixel der Region. Diese können gewonnen werden, indem man die Region in der Maske erweitert und hiervon die Glanzregion abzieht. Dabei ist darauf zu achten, dass nicht ggf. Glanzpunkte, die in der Nähe liegen, mit gekennzeichnet werden. Die „Nachbarpixel“ werden in eindimensionale Vektoren überführt. Dies gelingt z. B. dadurch, dass man die Zeilen hintereinander schreibt. Um das Bild später wieder zurück zu bekommen merkt man sich 2D-Koordinaten für jeden Eintrag in den neuen Vektoren  $\vec{I}$  und  $\vec{t}_i$ . Schreibt man die Trainingsdaten in Form einer Matrix

$$T = \begin{bmatrix} \vec{t}_1 & \vec{t}_2 & \dots & \vec{t}_n \end{bmatrix} \quad (4.12)$$

so kann man das Problem als Gleichungssystem beschreiben:

$$\vec{I} = T \cdot \vec{k} \quad (4.13)$$

$\vec{k}$  kann mit Hilfe der Ausgleichsrechnung berechnet werden. Geht man nun von der Annahme aus, dass die „Löcher“ ebenfalls mit den Koeffizienten  $\vec{k}$  rekonstruiert werden können, so lässt sich der Gesichtteil vollständig aus den Trainingsdaten rekonstruieren. Der Unterschied ist nur der, dass der rekonstruierte Gesichtteil im Idealfall keinen Glanz mehr beinhaltet.

### 4.3.2 Berechnen der Koeffizienten $\vec{k}$

Das zu lösende Gleichungssystem 4.13 hat mehr Gleichungen als Unbekannte, da in der Regel die Anzahl der Bildpixel um ein Vielfaches höher ist als die Anzahl der Trainingsgesichter. In den meisten Fällen wird es für dieses Gleichungssystem keine exakte Lösung geben, da es überbestimmt ist. Man kann aber nach der „bestmöglichen“ Lösung suchen.

#### 4.3.2.1 Ermittlung der Koeffizienten im Sinne des kleinsten quadratischen Fehlers

Gegeben ist das überbestimmte Gleichungssystem aus Kapitel 4.3.1

$$T\vec{k} = \vec{I} \quad (4.14)$$

Das Gleichungssystem ist nicht exakt lösbar. Es ist nur bis auf einen Fehlervektor  $\vec{r}$  berechenbar.

$$T\vec{k} = \vec{I} + \vec{r} \quad (4.15)$$

Man möchte das Gleichungssystem aber nach Möglichkeit ohne bzw. mit sehr kleinen Fehlern lösen. Man führt daher das quadratische Fehlermaß  $Q$  ein.

$$Q = \|\vec{r}\|^2 \quad (4.16)$$

$$= \left\| T\vec{k} - \vec{I} \right\|^2 \quad (4.17)$$

$$= \left( T\vec{k} - \vec{I} \right)^2 \quad (4.18)$$



$Q$  wird minimal, wenn der Gradient  $grad_{\vec{k}}(Q)$  null wird.

$$grad_{\vec{k}}(Q) = \vec{0}^t \quad (4.19)$$

$$grad_{\vec{k}}\left(\left(T\vec{k} - \vec{I}\right)^2\right) = \vec{0}^t \quad (4.20)$$

Durch Bestimmen des Gradienten mit Hilfe der Produktregel erhält man

$$grad_{\vec{k}}\left(\left(T\vec{k} - \vec{I}\right)^2\right) = \vec{0}^t \quad (4.21)$$

$$2\left(T\vec{k} - \vec{I}\right)^t \cdot T = \vec{0}^t \quad | :2 \quad (4.22)$$

$$\left(T\vec{k} - \vec{I}\right)^t \cdot T = \vec{0}^t \quad | ^t \quad (4.23)$$

$$\left[\left(T\vec{k} - \vec{I}\right)^t \cdot T\right]^t = \vec{0} \quad (4.24)$$

$$T^t \left(T\vec{k} - \vec{I}\right) = \vec{0} \quad (4.25)$$

$$T^t T\vec{k} - T^t \vec{I} = \vec{0} \quad (4.26)$$

$$T^t T\vec{k} = T^t \vec{I} \quad | (T^t T)^{-1} \quad (4.27)$$

$$(T^t T)^{-1} T^t T\vec{k} = (T^t T)^{-1} T^t \vec{I} \quad (4.28)$$

$$\vec{k} = (T^t T)^{-1} T^t \vec{I} \quad (4.29)$$

$$\vec{k} = G\vec{I} \quad (4.30)$$

Die Matrix  $G$  wird auch Pseudoinverse genannt [Jäh02]. Die gleiche Matrix erhält man auch, wenn das Gleichungssystem exakt lösbar wäre.

$$T\vec{k} = \vec{I} \quad (4.31)$$

$$T^t T\vec{k} = T^t \vec{I} \quad (4.32)$$

$$(T^t T)^{-1} T^t T\vec{k} = (T^t T)^{-1} T^t \vec{I} \quad (4.33)$$

$$\vec{k} = G\vec{I} \quad (4.34)$$

Hat man die Koeffizienten  $\vec{k}$  berechnet, kann man das Korrekturgesicht aus den vollständi-

gen Trainingsgesichtern berechnen.

$$\vec{I}_{\text{koriigiert}} = T_v \vec{k} \quad (4.35)$$

$T_v$  ist die Trainingsmatrix, die die vollständigen Trainingsgesichter spaltenweise enthält. Dadurch werden auch die Glanzstellen neu berechnet.

#### 4.3.2.2 Singular Value Decomposition

Die Matrix  $T^t T$  ist in der Regel sehr schwer numerisch zu invertieren. Man geht daher gerne den Umweg über die Singulärwertzerlegung. Dieser liegt der folgende mathematische Satz zu Grunde: Jede  $m \times n$  Matrix  $F$  (mit  $m \geq n$ ) lässt sich zerlegen in ein Matrixprodukt aus drei Matrizen  $H$ ,  $Y$  und  $V^t$ .  $H$  ist eine spaltenorthogonale  $m \times n$  Matrix,  $Y$  ist eine  $n \times n$  Diagonalmatrix, auf deren Diagonale die Singulärwerte  $y_i$  der Matrix  $F$  stehen, und  $V$  ist eine  $n \times n$  Orthogonalmatrix. Die Matrizen  $H$  und  $V$  sind zusätzlich orthonormiert. Der Algorithmus zur Bestimmung dieser sogenannten „Singular Value Decomposition“-Darstellung (Singulärwertzerlegung) ist sehr kompliziert. Die Zerlegung soll daher hier nur als „black box“ betrachtet werden. Sowohl für IDL als auch für C sind aber entsprechende Implementierungen verfügbar [PTVF95]. Zur Bestimmung der Pseudoinversen  $\Gamma$  der Matrix  $F$  schreibt man die Matrix  $F$  als Singulärwertzerlegung

$$F = H \begin{pmatrix} y_1 & & & \\ & y_2 & & \\ & & \dots & \\ & & & y_n \end{pmatrix} V^t \quad (4.36)$$

Die Pseudoinverse  $\Gamma$  der Matrix  $F$  lässt sich sehr leicht berechnen. Gegeben sei das Gleichungssystem

$$\vec{I} = F \vec{k} \quad (4.37)$$

Aufgrund der Orthonormalität gilt  $H^t H = E$  und  $V V^t = E$ . Die Diagonalmatrix  $Y$  lässt sich invertieren, indem jeweils an der Stelle, an der die Matrix ungleich null ist, der Kehrwert der Einträge geschrieben wird. Substituiert man die Matrix  $F$  durch ihre Singulärwertzerlegung

erhält man:

$$\vec{I} = HYV^t \vec{k} | H^t \quad (4.38)$$

$$H^t \vec{I} = \underbrace{H^t H Y V^t}_E \vec{k} \quad (4.39)$$

$$H^t \vec{I} = Y V^t \vec{k} | Y^{-1} \quad (4.40)$$

$$Y^{-1} H^t \vec{I} = \underbrace{Y^{-1} Y V^t}_E \vec{k} | V \quad (4.41)$$

$$V Y^{-1} H^t \vec{I} = \underbrace{V V^t}_E \vec{k} \quad (4.42)$$

$$\Gamma \vec{I} = \vec{k} \quad (4.43)$$

Damit ist die Pseudoinverse  $\Gamma$  der Matrix  $F$

$$\Gamma = V \begin{pmatrix} \frac{1}{y_1} & & & \\ & \frac{1}{y_2} & & \\ & & \dots & \\ & & & \frac{1}{y_n} \end{pmatrix} H^t \quad (4.44)$$

### 4.3.3 Die Abhängigkeit von den Trainingsdaten

Im Kapitel 4.3.1 wurde die Gleichung 4.13 als eindeutig lösbar angenommen. In der Praxis ist das leider nicht gegeben. Die Gleichung kann nur bis auf einen Restfehler gelöst werden. Das Negative des Restfehlers bezeichnet man als Residuum. Der Fehler wird berechnet durch

$$\vec{r} = T \cdot \vec{k} - \vec{I} \quad (4.45)$$

Man muss nun zwischen zwei Sorten der Restfehler unterscheiden. Einmal gibt es den Fehler  $\vec{r}_s$  der entsteht, wenn man einen ungestörten Gesichtsteil rekonstruieren will, und das andere Mal haben wir den Fehler  $\vec{r}_v$  der entsteht, wenn man ein gestörtes Gesicht rekonstruiert.  $\vec{r}_s$  gibt den Systemfehler an. Kann ein Gesichtsteil nicht durch die Trainingsdaten dargestellt werden, wird man mit dem Korrekturverfahren auch keinen Glanz entfernen können. Man wird sogar das Original im schlimmsten Fall zerstören.  $\vec{r}_s$  hängt im Wesentlichen von der Menge der Trainingsdaten ab. Aber auch Unschärfe, Posen, Verschiebungen oder Ähnliches können die Qualität beeinflussen. Des Weiteren trägt die Form der Trainingsmen-

ge zu dem Fehler bei. Sind die Gesichter nicht so normiert, dass sie die gleiche Größe haben oder markante Punkte wie Augen, Mund und Nase nicht an der gleichen Stelle liegen, erhöht sich der Fehler. Ist die Anzahl der Gesichter der Trainingsmenge gleich der Anzahl der zu rekonstruierenden Pixel entsteht ein quadratisches Gleichungssystem, welches eindeutig lösbar sein sollte. Die Residuen sind hier null.

#### 4.3.4 Das Problem der Redundanz oder der Korrelation

Die Nachrichtentechniker definieren Information als das Neue in einer Nachricht [Sto02]. Redundanz ist eine Maßzahl dafür, wieviel in einer Nachricht überflüssig ist, um eine Entscheidung zu treffen. Bei dem soeben beschriebenen Verfahren nutzen wir aus, dass ein Gesicht immer ähnlich beschaffen ist. Haben wir genügend „Informationen“ über das Gesicht, können wir den Rest dazudenken. Das klingt zunächst einmal gut. Allerdings genügt es zur Gesichtserkennung nicht nur zu wissen, ob es z. B. eine breite oder schmale Nase ist, sondern wir müssen viel mehr darüber wissen. Wenn man versucht, Gesichter mit einigen wenigen Begriffen zu beschreiben, wird man schnell feststellen, dass sich die Beschreibungen wiederholen. Bei dem Korrekturverfahren ist also wichtig, dass die „Nachbarn“ genügend über das zu korrigierende Gebiet aussagen. Um ein Gebiet zu korrigieren, muss die entsprechende Redundanz für die verloren gegangene Information gefunden werden. Ist die Redundanz nicht in den Nachbarpixeln, stellt sich das als fehlerhafte Korrektur dar, da wir nur dort nach der Redundanz suchen. Ein Auge sagt nichts über die Nase der Person aus. Weiß man, dass ein Gesicht symmetrisch ist, kann eine komplette Gesichtshälfte fehlen und es ist trotzdem möglich das Gesicht vollständig zu rekonstruieren. Man muss darauf achten, dass der Bereich, der zur Berechnung dient

1. relativ groß gegenüber der zu korrigierenden Fläche ist und
2. auch geeignet ist, die Rekonstruktionskoeffizienten des zu korrigierenden Bereiches zu bestimmen.

Das bedeutet z. B., dass man nicht versuchen sollte, die Nase aus dem Rest des Gesichtes zu berechnen. Diese Information ist in den restlichen Pixeln nicht vorhanden. Die Nase liegt auf der Symmetrieachse des Gesichtes. Es gibt keine Stelle im Gesicht, die noch etwas über die Nase aussagen kann. Bewegt man sich von der Symmetrieachse weg, so ist in der

Regel die Information auf der gegenüberliegenden Seite der Achse noch einmal vorhanden. Eine verglänzte Wange sollte daher rekonstruiert werden können, wenn die andere Wange glanzfrei ist.

## 4.4 Glanzkorrektur mit Hilfe von Eigengesichtern

Die Glanzkorrektur mit Eigengesichtern funktioniert ähnlich wie die Glanzkorrektur mit dem Gauss'schen Ausgleichsverfahren. Das Ausgleichsverfahren ist hier Teil des Verfahrens.

Bisher wurde jedes Trainingsgesicht gleich behandelt. Um die Qualität des Ergebnisses zu verbessern, musste die Trainingsmenge vergrößert werden. Das verursacht allerdings auch eine Verlängerung der Rechenzeit, die potenziell ansteigt. Geschickt wäre es, die Trainingsdaten so neu zu sortieren, dass die wichtigsten Eigenschaften der Trainingsdaten in einem nur noch kleinen Teil der Gesamtdaten vorhanden sind, sodass entsprechend weniger Gesichter benutzt werden müssen. Wenn dies gelänge, könnte die Qualität verbessert werden, obwohl die Anzahl der Trainingsgesichter gleich bleibt. Ein solches Werkzeug haben Turk und Pentland in [TP91] vorgeschlagen.

Bevor die Trainingsdaten genutzt werden können, müssen sie vorverarbeitet werden. Von einem möglichst großen Datensatz werden der Mittelwert und die Eigengesichter berechnet. Das Verfahren wurde in Kapitel 1.1.5 beschrieben. Der neue Trainingsdatensatz besteht nun nicht mehr aus realen Gesichtern, sondern aus dem Gesichtsmittelwert und den Eigengesichtern.

Will man ein ungestörtes Gesicht rekonstruieren, so muss man zunächst den Mittelwert abziehen. Mit dem mittelwertbefreiten Gesicht und den Eigengesichtern kann wie im Kapitel 4.3 verfahren werden. Man erhält so die gesuchte Linearkombination.

### 4.4.1 Nützliche Eigenschaften von Eigengesichtern

Zusätzlich zur Verkleinerung der notwendigen Datenmenge gibt es weitere Eigenschaften, die unter bestimmten Bedingungen nützlich sind. Will man ein ungestörtes Gesicht rekonstruieren, kann man sich die Orthogonalität der Eigengesichter zu nutze machen. Das mittelwertfreie Gesicht  $\Delta$  lässt sich, wie gesagt, als Linearkombination der Eigengesichter  $\vec{u}_i$

darstellen

$$\Delta = k_1 \vec{u}_1 + k_2 \vec{u}_2 + \dots + k_n \vec{u}_n \text{ mit } k_i \in \mathbb{R} \quad (4.46)$$

Um  $k_1$  zu berechnen, multiplizieren wir zunächst  $\vec{u}_1$  auf beiden Seiten. Man erhält

$$\Delta \cdot \vec{u}_1 = k_1 \vec{u}_1 \vec{u}_1 + k_2 \vec{u}_2 \vec{u}_1 + \dots + k_n \vec{u}_n \vec{u}_1 \quad (4.47)$$

da

$$\vec{u}_a \cdot \vec{u}_b = 0 \text{ wenn } a \neq b \quad (4.48)$$

$$\vec{u}_a \cdot \vec{u}_b = 1 \text{ wenn } a = b \quad (4.49)$$

ist

$$k_1 = \Delta \cdot \vec{u}_1 \quad (4.50)$$

Allgemein gilt dann

$$k_i = \Delta \cdot \vec{u}_i \text{ mit } i \in \mathbb{N} \quad (4.51)$$

Ein Skalarprodukt lässt sich recht schnell berechnen. Des Weiteren haben die Eigengesichter die Eigenschaft, dass die charakteristischen Eigenschaften des Datensatzes nur in den ersten Eigensichtern vorhanden sind (siehe Abbildung 1.6 auf Seite 15). Man kann so das Problem in der Dimension verkleinern, ohne nennenswerte Qualitätsverluste einbüßen zu müssen. Der Fehler lässt sich berechnen, wenn das zu rekonstruierende Gesicht bei der Berechnung der Eigengesichter verwendet wurde. Das zu rekonstruierende Gesicht muss also ein Gesicht der Trainingsmenge sein. Nach [Con01] lässt sich der quadratische Fehler berechnen als

$$r^2 = \sum_{m=M+1}^N \lambda_m \text{ mit } M, N \in \mathbb{N} \text{ und } M \leq N \quad (4.52)$$

Den Verlauf der Funktion zeigt Abbildung 4.7.

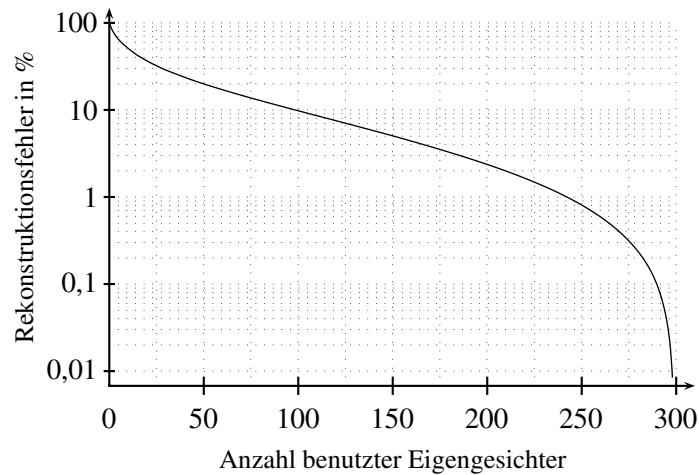


Abbildung 4.7: Abhängigkeit des Fehlers  $r^2$  von der Menge der Eigenvektoren

#### 4.4.2 Korrigieren mit Eigengesichtern

Um ein gestörtes Gesicht mit Eigengesichtern zu korrigieren, muss man zunächst wieder den Mittelwert subtrahieren. Anschließend wandelt man das zu korrigierende Gesicht und die Eigengesichter in Vektoren um. Dies kann dadurch geschehen, indem die Pixelwerte zeilenweise in den Vektor geschrieben werden. Ist  $i(x,y)$  der Grauwert am Ort  $(x,y)$ , so schreibt sich der Vektor als

$$\vec{I} = \begin{pmatrix} i(x_1, y_1) \\ \vdots \\ i(x_n, y_1) \\ i(x_1, y_2) \\ i(x_2, y_2) \\ \vdots \\ i(x_n, y_2) \\ \vdots \\ i(x_n, y_n) \end{pmatrix} \quad (4.53)$$

Die Einträge der Pixel, die durch Glanz gestört sind, werden wieder aus dem Vektor entfernt. Wäre in dem Vektor in Gleichung 4.53 der Pixel  $i(x_1, y_2)$  durch Glanz gestört, würde sich der Vektor jetzt schreiben lassen als


$$\vec{\tilde{I}} = \begin{pmatrix} i(x_1, y_1) \\ \vdots \\ i(x_n, y_1) \\ i(x_2, y_2) \\ \vdots \\ i(x_n, y_2) \\ \vdots \\ i(x_n, y_n) \end{pmatrix} \quad (4.54)$$

Sind mehr als ein Pixel verglanzt, werden entsprechend mehr Einträge entfernt. Dadurch verliert man leider die Eigenschaft, dass Eigengesichter orthogonal zueinander sind. Daher ist eine Ausgleichsrechnung durchzuführen, die die Koeffizienten liefert, um den Gesichtsvektor als Linearkombination der Eigengesichter darzustellen. Bei der Rekonstruktion durch die Linearkombination werden die ganzen Eigengesichter verwendet. Da die Trainingsdaten keinen Glanz beinhalten, sollte in dem rekonstruierten Gesicht der Glanz entfernt sein (siehe Abbildung 4.8). Der Vorteil, dass weniger Eigengesichter benötigt werden, geht auch dadurch nicht verloren. Der Algorithmus ist daher schneller als ein vergleichbarer Algorithmus nur mit Ausgleichsrechnung.

#### 4.4.3 Maßnahmen zur Beschleunigung des Algorithmus

Da der Glanz nicht in jedem Bild konstant an der gleichen Stelle ist, muss jedes Mal die SVD - Matrix neu berechnet werden. Dieser Vorgang dauert auf einem Pentium II 500Mhz mit 256MB RAM ca. 20 Minuten mit 1000 Eigengesichtern. Diese Zeit ist natürlich nicht praktikabel. Im Folgenden werden zwei Ansätze beschrieben, um die Rechenzeit zu beschleunigen.





*Abbildung 4.8: Glanzkorrektur mit Eigengesichtern*

#### 4.4.3.1 Standardmasken

Bisher wurden die verglänzten Pixel aus den Vektoren entfernt. Dadurch verliert man die Orthogonalität der Eigengesichter und muss eine Ausgleichsrechnung durchführen. Ist die Form und Position der Glanzlichter bekannt, kann man die Umrechnung bereits im Vorfeld durchführen. Das kann einem dadurch gelingen, indem man feste Bereiche im Bild definiert. Liegt Glanz in einem Bereich, so gilt der ganze Bereich als verglanzt. Um die Rekonstruktion berechnen zu können, benötigt man die vollständigen Trainings- und Eigengesichter, bei denen der definierte Bereich fehlt. Des Weiteren ist eine Matrix zu berechnen, mit der man die über die Eigengesichter berechneten Rekonstruktionskoeffizienten für die Trainingsgesichter bestimmen kann. Mit Hilfe der neuen Koeffizienten wird das Gesicht, bzw. der Glanzbereich, rekonstruiert.

Um zu sehen wie die Matrix aufgebaut werden muss, schaut man sich am besten einmal an, wie die Eigengesichter aus den Trainingsgesichtern entstehen. Dieses Verfahren kann nur funktionieren, wenn die Eigengesichter vollständig aus den Trainingsgesichtern darstellbar sind. Das ist zunächst zu zeigen. Nach Definition von Eigenvektoren gilt: ( $C$  sei die Kova-

rianzmatrix,  $\vec{u}$  die Eigenvektoren,  $\lambda$  die Eigenwerte,  $\vec{t}$  die Trainingsgesichter)

$$C\vec{u} = \lambda\vec{u} \quad (4.55)$$

$$\Leftrightarrow \left( \frac{1}{M} \sum_{j=1}^M \vec{t}_j \vec{t}_j^T \right) \vec{u} = \lambda\vec{u} \quad \left| \cdot \frac{1}{\lambda} \right. \quad (4.56)$$

$$\Leftrightarrow \left( \sum_{j=1}^M \left[ \frac{1}{\lambda M} \vec{t}_j \vec{t}_j^T \right] \vec{t}_j \right) = \vec{u} \quad (4.57)$$

mit

$$\frac{1}{\lambda M} \vec{t}_j \vec{t}_j^T \vec{u} = \gamma_j \text{ mit } \gamma_j \in \mathbb{R} \quad (4.58)$$

durch Substitution erhält man

$$\left( \sum_{j=1}^M \gamma_j \vec{t}_j \right) = \vec{u} \quad (4.59)$$

Die Umrechnungsmatrix  $Q$  berechnet sich daher wie folgt:

$$Q_{ji} = \frac{1}{\lambda M} \vec{t}_j \vec{u}_i \quad (4.60)$$

Wobei  $\vec{u}$  die Eigengesichter sind, bei denen ein definierter „Standardglanzbereich“ fehlt. Damit das Skalarprodukt berechenbar ist, muss auch bei den Trainingsgesichtern  $\vec{t}$  dieser Bereich fehlen.

Durch die Rekonstruktion eines zu korrigierenden Gesichtes erhält man den Vektor  $\vec{k}$ , der die Rekonstruktionskoeffizienten beinhaltet. Diese Rekonstruktion wird mit den Eigengesichtern berechnet, bei denen schon bei der Erstellung der definierte Glanzbereich fehlte. Die neuen Koeffizienten erhält man durch Matrixmultiplikation

$$\vec{k}_{neu} = Q\vec{k} \quad (4.61)$$

Es wird angenommen, dass die Koeffizienten  $\vec{k}_{neu}$  auch für die kompletten Trainingsgesichter näherungsweise gelten. Das zu korrigierende Gesicht muss dann nur noch aus den vollständigen Trainingsgesichtern rekonstruiert werden.

Probleme bei diesen Verfahren verursacht das in Kapitel 4.3.4 beschriebene Problem der Redundanz. Des Weiteren muss darauf geachtet werden, dass bei der Rekonstruktion keine weiteren Glanzfelder benutzt werden. Wird beides penibel beachtet, wird dieses Verfahren

beliebig kompliziert. Die Rechenzeit ist allerdings deutlich kürzer. Aufgrund der beschriebenen Einschränkungen konnte in Experimenten kein Erfolg beobachtet werden. Man musste sogar eine Verschlechterung der Rangstatistik feststellen.

#### 4.4.3.2 Iteratives Verfahren

Um den Vorteil der Orthogonalität nicht zu verlieren, kann man versuchen, sich der Rekonstruktion anzunähern. Zunächst rekonstruiert man das vollständige, gestörte Gesicht aus den Eigengesichtern. Man berechnet anschließend den Fehler an den Stellen, die als Glanz markiert worden sind. Diese werden eine falsche Rekonstruktion verursacht haben. Mathematisch wird das folgendermaßen formuliert:

$$k_i = \vec{I}_o \cdot \vec{u}_i \quad (4.62)$$

$$\vec{I}_r = \sum_{i=1}^N k_i \vec{u}_i \quad (4.63)$$

$$\Rightarrow \vec{r} = \vec{I}_o - \vec{I}_r \quad (4.64)$$

$$\Rightarrow \vec{I}_n = \vec{I}_o - \vec{r} = \vec{I}_r \quad (4.65)$$

Man wiederholt dieses für  $I_o \equiv I_n$  so lange, bis der Fehler  $r$  kleiner als ein Schwellenwert  $w$  ist. Man nähert sich so langsam der korrekten Rekonstruktion an. Durch die Anpassung der Glanzstellen mit Hilfe des Residuums werden die Glanzstellen automatisch korrigiert (siehe Abbildung 4.9).

Ein sinnvoller Wert für  $w$  ist 1. Da die Korrekturen in der Regel wieder als Bild abgespeichert werden, haben Zahlen, die nicht den natürlichen angehören, keine Auswirkung. Man kann daher die Rechnung hier beenden. Obwohl man einige Rekonstruktionen mehr als bei der ursprünglichen Methode durchführen muss, kann ein Rechenzeitgewinn in der Programmiersprache IDL um einen Faktor 10 beobachtet werden.



(a) künstlich verglanzt und  
verkleinert



(b) original



(c) Iteratives Verfahren

**Abbildung 4.9:** *Glanzkorrektur mit iterativem Verfahren*

## 5 Ergebnisse

### 5.1 Eignung der Messmethoden prüfen

Bevor man die eigentlichen Messungen durchführt, sollte man immer seine Messapparate darauf hin überprüfen, ob diese den erwarteten Effekt messen können. So wurde überprüft auf welche Art und Weise die Erkennungsmaschine darauf reagiert, wenn einzelne oder alle Bilder mit künstlichem Glanz gestört sind. Der künstliche Glanz wurde dabei zufällig zu den Bildern dazu gefügt. Der verwendete Glanz folgt dabei einer modifizierten, zweidimensionalen Gaussfunktion.

$$g(x,y) = \left( \exp \left( -\frac{\frac{(x-x_m)^2}{\sigma_x} + \frac{(y-y_m)^2}{\sigma_y}}{2} \right) \right)^\alpha \quad (5.1)$$

Dabei ist

$x_m \equiv$  x-Position des Glanzpunktes

$y_m \equiv$  y-Position des Glanzpunktes

$\sigma_x \equiv$  Ausdehnung in x-Richtung

$\sigma_y \equiv$  Ausdehnung in y-Richtung

$\alpha \equiv$  Steilheit der Kante

Die Parameter wurden per Zufallsgenerator ausgewählt. Sie wurden nur jeweils durch ein Intervall begrenzt, damit das Ergebnis kontrollierbar ist. Nur so können später die Verfahren auf kleinen und großen Glanzpunkten getestet werden. Das neue Bild berechnet sich entweder als

$$f_{neu}(x,y) = \begin{cases} g_i(x,y) & \text{wenn } g_i(x,y) \geq f_{alt}(x,y) \\ f_{alt}(x,y) & \text{wenn } g_i(x,y) < f_{alt}(x,y) \end{cases}$$

wobei  $i \in \{1, \dots, N\}$  und  $N$  die Anzahl der Glanzpunkte ist, oder als

$$f_{neu}(x, y) = f_{alt}(x, y) \cdot \left( 1 + \frac{g_{ges}(x, y)}{c_0 \cdot \max(g_i(x, y))} \right)$$

wobei  $g_{ges}(x, y) = \max(g_i(x, y))$  und  $i \in \mathbb{N}$  und  $c_0 = const.$  und  $c_0 \in \mathbb{R}$ . Die künstliche Verglanzung hat den Vorteil, dass man

1. unabhängig vom Detektor ist und
2. den Glanz auf identischen Bildern variieren kann.

In dem im Kapitel 3.1 beschriebenen Proband/Galerist Szenario sind unterschiedliche Möglichkeiten denkbar, wie sich die Störung auf die Personen verteilt:

- Die Probanden und Galeristen sind überhaupt nicht gestört
- Es sind nur die Galeristen gestört
- Es sind nur die Probanden gestört
- Die Probanden sind ungestört, aber der jeweils zugehörige Galerist ist verglanzt
- Der Proband und der jeweils zugehörige Galerist sind verglanzt
- Probe und Galerie sind verglanzt

Diese unterschiedliche Verteilung wirkt sich auch deutlich auf die Rangstatistik und die EER aus. Die Tabelle 5.1 zeigt die Ergebnisse eines Versuchs, bei dem die Störung jeweils unterschiedlich verteilt wurde. Nicht verwunderlich ist, dass der ungestörte Datensatz die besten Ergebnisse aufweisen kann. Interessant ist jedoch, dass eine Störung des Probanden im Verhältnis zu den anderen Größen kaum etwas an den Ergebnissen ändert. Wird nur die Probe verglanzt, sinkt die Rang 1 - Statistik um 10% ab. Erhält hingegen die Galerie vergleichbaren Glanz, sinkt der Rang 1 - Wert bereits um 25% ab. Wenn jeweils der zugehörige Galerist gestört ist, „merkt“ das Erkennungssystem nicht mehr, ob auch der Proband verglanzt ist. Der Unterschied liegt hier bei gerade mal 3,5%.

Dieser Effekt lässt sich dadurch erklären, dass die Störung, die durch den Glanz im Probanden verursacht wird, für alle Galeristen konstant bleibt. Das liegt einmal daran, dass ein

<b>200 Gesichtspaare, 40 Knotenpunkte, quadratische Graphen</b>	<b>Rang 1</b>	<b>EER</b>
ungestört	74,5%	13,0%
Galerie verglanzt	49,5%	16,6%
Probe verglanzt	64,5%	20,9%
jeweils zum Probanden zugehörige Galerist verglanzt	31,0%	27,1%
Proband und zugehöriger Galerist verglanzt	27,5%	31,0%
Probe und Galerie verglanzt	40,0%	25,0%

*Tabelle 5.1: Ergebnisse des Versuchs zur Störungsverteilung*

Glanzpunkt kaum einer Gesichtspartie ähnlich ist. Die verursachte Störung bleibt somit bei allen Galeristen für jeden Knotenpunkt gleich. Der Ort des Glanzes ändert sich nicht. Es wird zwar die Ähnlichkeit sinken, die Verhältnisse zwischen den Personen ändern sich aber kaum.

## 5.2 Die Algorithmen in der praktischen Anwendung

Bei der Implementierung theoretisch entwickelter Algorithmen treten immer mal wieder Probleme auf, die die Theorie nicht liefert, sondern aufgrund der Implementierung entstehen oder erst in der praktischen Anwendung sichtbar werden. In dem folgenden Kapitel sollen die benutzten Algorithmen in ihrer praktischen Anwendung beschrieben werden.

### 5.2.1 Zur Interpolation

Der implementierte Algorithmus zur Interpolation nutzt, wie auch im theoretischen Teil beschrieben, acht Nachbarpixel. Der Übergang wurde auf 3 Pixel gesetzt und die Vertrauenskarte wurde vorher um 5 Pixel vergrößert. Auf die Implementierung der Laplace-Pyramide wurde verzichtet. Der dadurch zu erzielende Erfolg schien kleiner zu sein als der Aufwand der Rechenzeit, die die Berechnung der Laplace-Pyramide benötigt. Erste Versuche zeigten, dass durch die Änderung der Stützstellen der Interpolation bei jedem Pixel die Bildmatrix Struktur schnell sichtbar wird. Daher wurde das korrigierte Material vor dem Einsetzen unscharf gefiltert, um dadurch eine glatte Bildfunktion zu erzwingen. Informationen gehen durch diese Maßnahme nicht verloren, da das Korrekturmateriale keine höheren Frequenzen

enthält. Es wurde ein Filter mit einem Filterkern der Form

$$\frac{1}{n^2} \begin{pmatrix} 1 & \cdots & 1 \\ \vdots & \ddots & \vdots \\ 1 & \cdots & 1 \end{pmatrix} \quad (5.2)$$

mit der Größe  $n \times n$  genutzt.

### 5.2.2 Zur Fill-In Methode

Zunächst wird bei dieser Methode so verfahren, als ob eine „normale“ Erkennung nach dem Hierarchical Graph Matching (Kapitel 1.1.6) durchgeführt würde. Allerdings wird bei der Berechnung überprüft, ob es sich um einen Glanzpunkt handelt oder nicht. Wenn das nicht der Fall ist, fährt die Erkennung wie gewohnt fort. Im anderen Fall wird das Ergebnis, egal was es normalerweise liefern würde, auf eins gesetzt. Das ist anschaulich damit zu vergleichen, als ob jeder Galerist an Glanzstellen in den Probanden eingeklebt wird.

### 5.2.3 Zur Ausgleichsrechnung und zu Eigengesichtern

Die Algorithmen mit Hilfe der Ausgleichsrechnung und mit Hilfe von Eigengesichtern können in einem Paket betrachtet werden. Je nachdem, ob Eigengesichter oder „normale“ Trainingsbilder benutzt werden, handelt es sich um die eine oder andere Methode. Zur Berechnung der Eigengesichter wurden unterschiedlich viele Trainingsgesichter benutzt. Standardmäßig wurden jedoch von zweitausend Gesichtern die Eigengesichter berechnet. Um gute Ergebnisse zu erzielen, wurde auf Bildern gearbeitet, die der bereits bei der Viisage Technology AG vorhandene Facerecognition-Algorithmus vorverarbeitet hat. Dieses Vorgehen hat im Wesentlichen zwei Vorteile:

1. Die Knotenpunkte konnten wieder eingelesen werden. Für das Finden der Knotenpunkte musste somit keine neue Routine geschrieben werden.
2. Die Bilder sind so skaliert, dass die Gesichter ungefähr die gleiche Größe haben. Die Augen liegen annähernd an der gleichen Stelle. Der Hintergrund ist ausgeblendet und kann somit die Erkennung nicht mehr beeinflussen. Kontrast und Helligkeit sind optimiert.



Ein Problem, welches sich beim Berechnen der Eigengesichter ergab, ist folgendes. Durch die exponentiell wachsende Matrix, die während der Berechnung entsteht, wird viel Hauptspeicher benötigt. Will man alle 2000 Eigengesichter des zur Verfügung stehenden Datensatzes (siehe Kapitel 5.3) berechnen, so muss man die Gesichter auf  $128^2$  Pixel verkleinern.

### 5.3 Auswertungen und Tests

Um die Methoden testen zu können, wurden im Wesentlichen zwei Vorgehensweisen gewählt.

1. Tests basierend auf künstlichem Glanz (wie in Kapitel 5.1 beschrieben)
2. Tests basierend auf realen Daten

Es standen zwei Datensätze zur Verfügung. Der erste Datensatz besteht aus 1000 Gesichtspaaren. Dieser Datensatz wurde auch zur Berechnung der Eigengesichter genutzt. Um auch die Eigengesichtermethode und die Methode mit Hilfe der Ausgleichsrechnung zu testen, wurde dieser Datensatz noch einmal geteilt. Ein Teil wird zur Berechnung der Eigengesichter benötigt. Zur Bestimmung der Erkennungsleistung wurde der andere Teil verwendet. Dieser Datensatz ist ein firmeninterner Datensatz. Daher können keine Beispiele gezeigt werden. Der zweite Datensatz besteht aus 152 Personen. Von jeder Person gibt es eine Ablichtung, die unter Studiobedingungen aufgenommen wurde. Diese Bilder bilden die Galerie. Der andere Teil besteht aus Bildern, die ohne Beachtung von „Photografenregeln“ aufgenommen wurden. Die Bilder enthalten somit alle möglichen Störungen der Fotografie (Überbelichtung, Glanz, Schatten, Gegenlicht, ...). Von jeder Person gibt es zwei bis sieben solcher Bilder. Die Probe, die aus diesen Bildern besteht, hat dadurch eine Größe von 608 Bildern.

#### 5.3.1 Verfahrenstest mit künstlichem Glanz

Als künstlicher Glanz wurde das in Kapitel 5.1 beschriebene Verfahren benutzt. Dieses Vorgehen hat den Vorteil, dass man unabhängig von den Detektoren ist. Fehler, die durch diese entstehen, beeinflussen somit die Versuche nicht. Nachteil ist natürlich, dass eventuell realer Glanz nur unzureichend modelliert wird. Diese Tests sollen daher zunächst nur zeigen,


ob die Verfahren grundsätzlich funktionieren. Des Weiteren kann die Stärke des Glanzes variiert werden, wodurch Schwächen und Stärken der Algorithmen gesucht werden können. Des Weiteren ist die maximal mögliche Erkennungsleistung bekannt, die die Verfahren erreichen können.

### 5.3.1.1 Vergleich der Verfahren

Bei beiden Datensätzen wurde der Glanz zunächst den Originalbildern zugefügt. „Original“ sei hier als vollständig unbehandelte Bilder definiert. Sowohl die Originalbilder als auch die verglänzten Bilder, die im Folgenden als unkorrigierte Bilder bezeichnet werden, werden einer Gesichtserkennung unterzogen. Die Differenz zeigt den Einfluss der künstlichen Glanzstellen. Je größer diese ist, umso stärker ist der Einfluss des Glanzes. Anschließend werden die Glanzstellen mit den unterschiedlichen Verfahren korrigiert. Im Idealfall sollte wieder der Originalwert erreicht werden. Erfolg ist dann zu verzeichnen, wenn die korrigierten besser als die unkorrigierten Werte sind. Im realen Szenario hätten die Messwerte der Originalwerte keine Bedeutung, da sie nicht bekannt sind.

**Datensatz 1** Wie im Anhang in Tabelle A.20 zu erkennen, sinkt in diesem Versuch die Rang 1 - Statistik von 84,90 % auf 44,97% bzw. 66,14% ab. Der Unterschied liegt an den eingestellten Parametern der Formel, die den künstlichen Glanz beschreibt. Die Parameter sind im Anhang zu jedem Versuch benannt. Die Methode mit Hilfe von Eigengesichtern konnte auf diesen Datensatz, aufgrund der bereits beschriebenen Rechenprobleme, nicht durchgeführt werden. Als bestes Verfahren stellt sich das Verfahren mit Hilfe der Ausgleichsrechnung heraus. Auch wenn man nur 10 Gesichter benutzt, erreicht man bereits bessere Erkennungsraten als bei den anderen Verfahren. Man kann aber auch deutlich die Abhängigkeit der Qualität des Verfahrens von der Anzahl der Trainingsgesichter erkennen. Werden mehr Gesichter benutzt, verbessert sich auch die Erkennungsleistung. Vergrößert man den Trainingsdatensatz entsprechend, so können auch mehr Unterschiede in den Gesichtern rekonstruiert werden. Außerdem kann sich dadurch die Rekonstruktion näher an das Original halten, was ebenfalls zur Verbesserung der Korrektur beiträgt.

Um die Qualität der Eigengesichtermethode abschätzen zu können, wurde das Verfahren auf 200 verkleinerten Bildern getestet (vergleiche Tabelle A.21 auf Seite 103). Die Eigengesichtermethode kann gegenüber der Ausgleichsmethode noch einmal zulegen.



Grafik basiert auf Tabelle A.1 auf Seite 81

Die Glanznummern bezeichnen unterschiedliche Glanzarten, die im Anhang genau beschrieben sind.

**Abbildung 5.1:** Ergebnisse (Rang 1) Glanzkorrektur Datensatz 1






Abbildung 5.2: Ergebnisse (Rangstatistik) auf Datensatz 1 / Glanznummer 1



Die Glanznummern bezeichnen unterschiedliche Glanzarten, die im Anhang genau beschrieben sind.

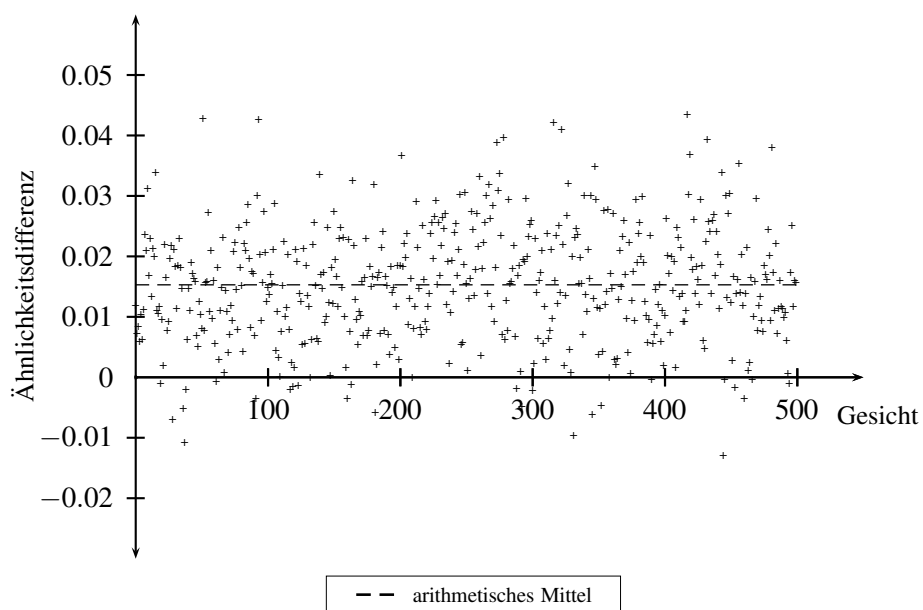
**Abbildung 5.3:** Ergebnisse Glanzkorrektur Datensatz 1 (EER)

Um die Stärken und Schwächen der Verfahren zu suchen, wurde der gesamte Datensatz mit Hilfe von künstlichem Glanz getestet. Dabei variiert der Glanz in der Größe und der Menge der Glanzpunkte (siehe Anhang A.1). Die Ergebnisse sind in Abbildungen 5.1, 5.2, 5.3, 5.4 und 5.5 zusammengefasst. Die Verfahren sind vor allem bei mittelstarken Glanz erfolgreich. Wenn zu viele Pixel defekt sind, können die Verfahren keine sinnvolle Korrektur mehr produzieren. Die beiden Interpolationsmethoden versagen hier vollständig. Die Strukturinterpolation scheint vor allem in großen Glanzbereichen besser als die „normale“ Interpolation zu funktionieren. Ansonsten zeigten sich, auch im Verhältnis zur Interpolation ohne Struktur, die schlechtesten Ergebnisse. Sind weniger Pixel defekt, können bereits neunzig Prozent der Originalerkennungsleistung erreicht werden. Wird die Zerstörung durch den Glanz weiter reduziert, kann sogar die Originalerkennungsleistung wieder erreicht werden.




Differenz zwischen: unkorrigiert (künstlicher Glanz 1) und korrigiert mit 250 Eigengesichtern  
positiver  $\Delta \text{Rang}$  bedeutet Rangverbesserung

*Abbildung 5.4:  $\Delta \text{Rang}$  Datensatz 1*



Differenz zwischen: unkorrigiert (künstlicher Glanz 1) und korrigiert mit 250 Eigengesichtern  
positive Ähnlichkeitsdifferenz bedeutet Verbesserung der Ähnlichkeit durch Korrektur

**Abbildung 5.5:** Ähnlichkeitsdifferenz, Datensatz 1




Differenz zwischen: unkorrigiert (künstlicher Glanz 1) und korrigiert mit 250 Eigengesichtern  
positiver  $\Delta$  Rang bedeutet Rangverbesserung

**Abbildung 5.6:**  $\Delta$  Rang Datensatz 2

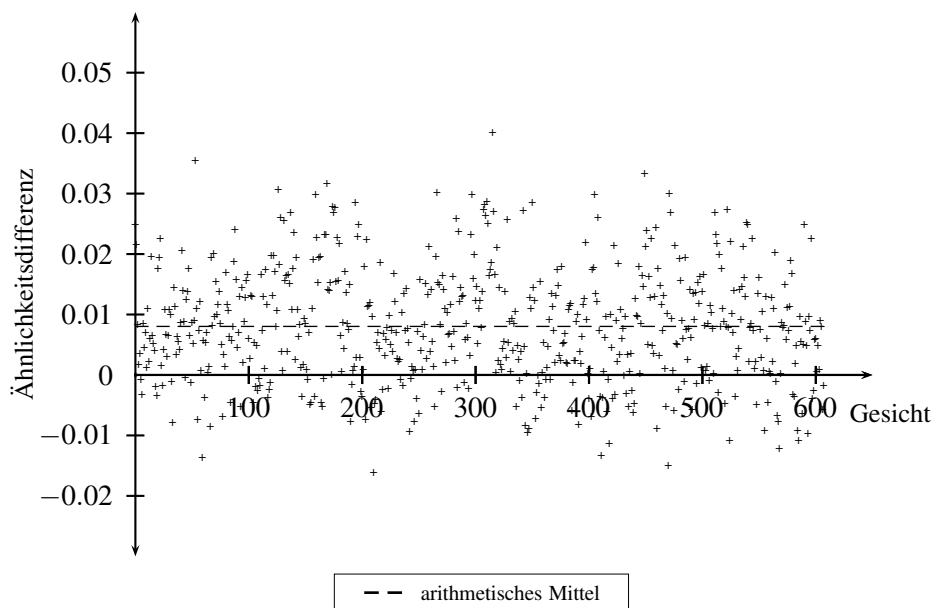
**Datensatz 2** Auch beim Datensatz 2 sind ähnliche Erfolge wie beim Datensatz 1 erkennbar (siehe Abbildungen 5.6, 5.7, 5.8, 5.9 und 5.10). Auf künstlichen Glanz erhält man einen ähnlichen Erfolg wie bei Datensatz 1, was zeigt, dass die Verfahren auch auf anderen Gesichtsbildern funktionieren sollten. Dieser Datensatz scheint schwieriger für die Verfahren zu sein, da die Originalerkennungsleistung später als bei Datensatz 1 erreicht wird.






Die Glanznummern bezeichnen unterschiedliche Glanzarten, die im Anhang genau beschrieben sind.

**Abbildung 5.7:** Ergebnisse Glanzkorrektur Datensatz 2 (EER)



Differenz zwischen: unkorrigiert (künstlicher Glanz 1) und korrigiert mit 250 Eigengesichtern  
positive Ähnlichkeitsdifferenz bedeutet Verbesserung der Ähnlichkeit durch Korrektur

**Abbildung 5.8:** Ähnlichkeitsdifferenz, Datensatz 2



Grafik basiert auf Tabelle A.10 auf Seite 91 und A.13 auf Seite 94

Die Glanznummern bezeichnen unterschiedliche Glanzarten, die im Anhang genau beschrieben sind.

**Abbildung 5.9:** Ergebnisse (Rang 1) Glanzkorrektur Datensatz 2






Abbildung 5.10: Ergebnisse (Rangstatistik) auf Datensatz 2 / Glanznummer 1

### 5.3.2 Verfahrenstest mit realen Daten

Um die Verfahren auf echten Daten zu testen, wurde Datensatz 2 verwendet. Dieser enthält vor allem in der Probe Glanz, der durch die schlechten Aufnahmebedingungen entstanden ist. Es ist zu untersuchen, ob die Glanzkorrektur das Originalergebnis verbessern kann. Als Korrektur wurden die Eigengesichterverfahren verwendet, da sie sich in den vorherigen Versuchen als die erfolgreichsten heraus stellten.


Durch das Wegfallen der Glanzerzeugung muss nun auch Glanz detektiert werden. Dies wurde mit den in Kapitel 2.2 beschriebenen Detektoren durchgeführt. Da auf den künstlichen Daten die Eigengesichtermethode die erfolgreichste Methode war, wurde auf den realen Daten nur noch diese verwendet. Auf den realen Daten ist zunächst kein Erfolg zu erkennen ( siehe Tabelle A.23 auf Seite 106 ). Das liegt allerdings nicht am Verfahren selbst, sondern an der mangelnden Rekonstruktionsfähigkeit des vorliegenden Datensatzes, der zur Berechnung der Eigengesichter dient. Vergleicht man die Ergebnisse der rekonstruierten Gesichter mit und ohne Glanz steigt die Rangstatistik um ein bis zwei Prozent (siehe Abbildungen 5.11, 5.12 und 5.13). Ähnlich verhält es sich, wenn man nur die defekten Pixel ersetzt.

Es wurde zusätzlich ein dritter Datensatz selber hergestellt. Dieser besteht aus 28 Personen in der Galerie und 150 Personen in der Probe. Bei den Personen handelt es sich um Mitarbeiter der Viisage Technology AG. Den Galeristen wurde mit Hilfe einer Leuchte bei der Aufnahme ein Glanzpunkt im Gesicht produziert. Diese Glanzpunkte wurden anschließend automatisch detektiert und mit der Eigengesichtermethode korrigiert. Durch die Korrektur konnte die Rang 1 - Statistik von 98,00% auf 98,67 % gesteigert werden. Der geringe Erfolg ist auf die kleine Galeriegröße zurückzuführen. Deutlich erkennbar ist aber die Steigerung der Ähnlichkeit wie in Abbildung 5.14 zu erkennen ist.




Grafik basiert auf Tabelle A.23 auf Seite 106

**Abbildung 5.11:** Ergebnisse (Rangstatistik) auf wirklichen Daten (Datensatz 2)



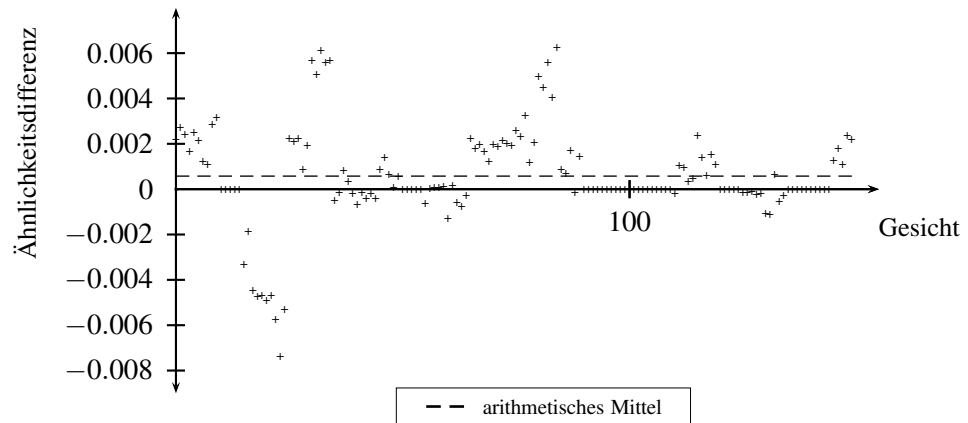
Differenz zwischen: unkorrigiert und korrigiert mit 1000 Eigengesichtern  
positiver  $\Delta$  Rang bedeutet Rangverbesserung

**Abbildung 5.12:**  $\Delta$  Rang auf wirklichen Daten (Datensatz 2)




Differenz zwischen: unkorrigiert (künstlicher Glanz 1) und korrigiert mit 250 Eigengesichtern  
positive Ähnlichkeitsdifferenz bedeutet Verbesserung der Ähnlichkeit durch Korrektur

**Abbildung 5.13:** Ähnlichkeitsdifferenz auf wirklichen Daten (Datensatz 2)



Differenz zwischen: unkorrigiert und korrigiert mit 300 Eigengesichtern  
positive Ähnlichkeitsdifferenz bedeutet Verbesserung der Ähnlichkeit durch Korrektur

**Abbildung 5.14:** Ähnlichkeitsdifferenz auf wirklichen Daten (Datensatz 3)



*Abbildung 5.15: Entfernung von Brillengestellen*

## 5.4 Erweiterte Anwendungen

Wir bereits in Kapitel 4 beschrieben ersetzen die Algorithmen defekte Pixel. Bisher wurden defekte Pixel gleichgesetzt mit Glanzbereichen. Für die Algorithmen ist es aber völlig egal um welche Pixel es sich handelt. So ist es denkbar, diese Verfahren auch zur Entfernung von Brillen und Ähnlichem einzusetzen.

Um diese Möglichkeit zu untersuchen wurde ein Datensatz zusammengestellt, bei dem die Personen Brillen tragen, ein Pflaster im Gesicht haben oder die Augen geschlossen sind. Aufgenommen wurden die Bilder unter unkontrollierten Bedingungen. Nach Vorverarbeitung wurden die „Störstellen“ von Hand markiert und automatisch von dem Verfahren mit Eigengesichtern korrigiert. Ausschnitte der Ergebnisse sind in den Abbildungen 5.15, 5.16, 5.17 und 5.18 dargestellt.

Man erkennt, dass die Verfahren auch geeignet sind andere Störstellen zu beseitigen. Durch die größere Ausdehnung der Störstellen kommt es teilweise zu unerwünschten Effekten. Sind beide Augen als „defekt“ markiert, geht die Korrektur schief, da keine Informationen über das Aussehen der Augen vorhanden sind. Dieser Effekt ist in Abbildung 5.18 dargestellt. Auch bei größeren Störstellen an anderer Stelle kann es zu ungewünschten Effekten kommen. Die Betonung liegt hier auf „kann“. Es kann zwar zu ungewünschten Effekten kommen, aber es kann genauso ein gutes Ergebnis erzielt werden. Vermutlich liegt das daran, wie die Person aus den Eigengesichtern dargestellt wird. Wenn ein Eigengesicht einen





(a) Originalbild



(b) korrigiertes Bild

**Abbildung 5.16: Entfernung von Pflastern**



(a) Originalbild



(b) korrigiertes Bild

**Abbildung 5.17: Öffnung von Augen**



(a) Originalbild



(b) korrigiertes Bild

**Abbildung 5.18:** Probleme beim Öffnen von Augen

Gesichtsbereich gut rekonstruiert hat, kann es trotzdem sein, dass die Rekonstruktion an anderer Stelle etwas verändert hat. Wenn das sehr häufig auftritt, sagt die Rekonstruktion sehr wenig über Störstellen, die als Lücken in der Rekonstruktion betrachtet werden, aus. Bei großen Störstellen kann es daher zu den ungewünschten Effekten kommen.

Bei der Entfernung von Brillen handelt es sich um wenig ausgedehnte Störstellen. Die Entfernung funktioniert daher gut. Das zeigt auch die Auswertung des Tests. Die Entfernung von Brillen konnte mindestens als brauchbar bewertet werden. Ein Großteil der Bilder ist sogar sehr gut gelungen.

## 6 Diskussion und Ausblick

In der vorliegenden Arbeit wurden verschiedene Glanzkorrekturverfahren entwickelt und getestet. Die Methoden mit Hilfe von Eigengesichtern und mit Hilfe der Ausgleichsrechnung konnten durch ihre Robustheit gegenüber Fehldetektion überzeugen. Diese Verfahren waren auch die besten unter den untersuchten Verfahren. Sowohl der visuelle Eindruck als auch die Erkennungsleistung war den anderen Verfahren überlegen. Im Gegensatz zu den anderen Verfahren blieb hier die Erkennungsleistung stabil. Die Interpolation und die Fill-In-Methode zeigten sowohl bei der Erkennungsleistung als auch im visuellen Eindruck keine guten Ergebnisse. Auch war die Streuung der Ergebnisse sehr hoch. Von Verschlechterung bis exzellente Verbesserung waren alle Möglichkeiten in den Ergebnislisten zu lesen. Diese Verfahren eignen sich daher für eine Gesichtserkennungsstation nicht.

Es konnte auch gezeigt werden, dass diese Korrekturverfahren stark von der Form und der Größe der Trainingsdaten abhängen. In der Arbeit konnten Probleme mit der Rekonstruktion von Gesichtsdaten aufgezeigt werden. Um die Korrektur weiter zu optimieren, könnte untersucht werden, wie genau die Trainingsdaten auszusehen haben, damit eine gute Korrektur durchgeführt werden kann.

Da die beschriebenen Verfahren Pixel ersetzen, könnten sie auch als anderweitige Korrekturalgorithmen benutzt werden. Diese Möglichkeit wurde ansatzweise in Kapitel 5.4 untersucht. Der Einfluss von Brillen, Pflastern usw. ist noch ein offener Punkt, der aufgrund fehlender Daten nicht untersucht werden konnte. Die Korrekturen mit den vorliegenden Daten sind aber ziemlich überzeugend, so dass hier weitere Untersuchungen sinnvoll erscheinen.

Ein Nachteil der Glanzkorrekturalgorithmen ist die lange Rechenzeit. Mit den schnell wachsenden Rechnerleistungen könnte es vielleicht in Zukunft möglich sein, die Verfahren in akzeptabler Zeit erfolgreich laufen zu lassen. Der Effekt, dass sich Störungen in der Probe gering auswirken, könnte insofern ausgenutzt werden, als dass die Korrekturmaßnahmen nur auf den Galeristen durchgeführt werden müssten. Diese stehen dem System dauerhaft zur Verfügung. Die Korrektur könnte in „Erkennungspausen“ berechnet werden.

Die Algorithmen wurden bisher unter dem Gesichtspunkt der Erkennungsleistung gesehen. Vor allem die Eigengesichtermethode könnte durchaus als Retuschewerkzeug dienen. Auch wenn die Gaborfilter immer noch Unterschiede erkennen, im visuellen Eindruck überzeugte das Verfahren durchaus. Man konnte teilweise nur Unterschiede erkennen, wenn man wusste was korrigiert wurde.

Das Entfernen von Brillen und anderen Störobjekten im Gesicht könnte sich als unterstützendes Mittel in der Phantombilderstellung eignen, wenn man die erworbenen Kenntnisse weiter optimiert.

## Anhang A

### Testergebnisse der Gesichtserkennung

#### A.1 Tests auf Datensatz 1 mit künstlichem Glanz

**Zum Datensatz** Der Datensatz besteht aus 500 Galeristen und 500 Probanden.

**Zu den Versuchen:**

**Erster Teil** Es wurden die Gesichtsbilder mit verschiedenen künstlichen Glanzpunkten versehen. Die Parameter der Glanzpunkte waren Folgende:

Glanz 1:  $\alpha = 5,5, \sigma_{min} = 5, \sigma_{\Delta} = 3$ , insgesamt 15 Glanzpunkte

Glanz 2:  $\alpha = 5,5, \sigma_{min} = 3, \sigma_{\Delta} = 3$ , insgesamt 15 Glanzpunkte

Glanz 3:  $\alpha = 5,5, \sigma_{min} = 2, \sigma_{\Delta} = 2$ , insgesamt 10 Glanzpunkte

Glanz 4:  $\alpha = 5,5, \sigma_{min} = 4, \sigma_{\Delta} = 4$ , insgesamt 3 Glanzpunkte

Glanz 5:  $\alpha = 5,5, \sigma_{min} = 2, \sigma_{\Delta} = 3$ , insgesamt 5 Glanzpunkte

Glanz 6:  $\alpha = 5,5, \sigma_{min} = 2, \sigma_{\Delta} = 3$ , insgesamt 3 Glanzpunkte

Glanz 7:  $\alpha = 5,5, \sigma_{min} = 2, \sigma_{\Delta} = 2$ , insgesamt 2 Glanzpunkte

Glanz 8:  $\alpha = 5,5, \sigma_{min} = 2, \sigma_{\Delta} = 2$ , insgesamt 1 Glanzpunkte

Glanz 9:  $\alpha = 5,5, \sigma_{min} = 1, \sigma_{\Delta} = 1$ , insgesamt 1 Glanzpunkte

Gearbeitet wurde auf rotierten und kontrastkorrigierten Bildern. Der Hintergrund wurde ausgeblendet. Es wurde die Erkennungsrate und die EER der Originaldaten, der unkorrigierten (verglanzten) Daten und die mit unterschiedlichen Verfahren korrigierten Daten bestimmt.

**Zweiter Teil** Es wurde eine Korrektur mit Ausgleichsrechnung mit und ohne Eigengesichter auf normierte, rotierte und angegliche Gesichter durchgeführt. Die Augen liegen im Bild an der selben Position. Die Bildgröße ist 128 x 128 Pixel.

<b>Rang 1 in %</b>		<b>Glare 1</b>	<b>Glare 2</b>	<b>Glare 3</b>	<b>Glare 4</b>	<b>Glare 5</b>	<b>Glare 6</b>	<b>Glare 7</b>	<b>Glare 8</b>	<b>Glare 9</b>
ORIGINAL		75,40	75,40	75,40	75,40	75,40	75,40	75,40	75,40	75,40
UNKORRIGIERT	Pg	56,00	60,40	70,40	71,60	71,00	74,00	74,40	75,40	75,40
	pG	64,40	65,80	73,00	73,20	73,80	74,80	75,20	75,00	75,20
	pg	40,00	45,80	63,60	67,40	68,40	72,00	74,40	75,00	74,80
	Plg	20,80	30,00	60,40	65,80	65,80	69,40	72,60	74,60	75,60
	p1g	42,80	51,00	64,00	65,40	65,40	69,40	73,40	74,40	76,00
ITERATIONS- METHODE MIT 1000 EIGEN- GESICHTERN (Glanz als Ganzes betrachtet)	Pg	59,80	71,00	74,60	74,40	75,20	75,60	75,80	75,40	75,60
	pG	61,80	71,40	74,40	73,80	73,80	75,40	75,60	75,00	75,40
	pg	44,20	64,60	73,00	70,80	73,80	75,00	75,40	75,80	75,40
	Plg	49,00	67,00	74,20	73,80	75,20	75,40	75,60	74,60	75,40
	p1g	41,00	64,00	73,00	69,80	73,40	75,00	75,20	74,40	75,40
KORREKTUR MIT 250 EIGENGESICHTERN (nur defekte Pixel korrigiert)	Pg	63,00	71,80	74,80	73,80	75,00	75,60	75,00	75,60	75,80
	pG	60,80	70,80	74,60	73,60	74,00	75,40	75,40	75,40	75,40
	pg	48,60	66,60	73,40	71,80	74,00	75,60	75,00	75,40	75,80
	Plg	58,00	69,00	74,80	73,60	75,20	74,80	75,00	75,20	75,40
	p1g	50,20	65,40	74,40	70,80	74,20	75,20	75,20	75,40	75,40
AUSGLEICH MIT 200 TRAININGS- GESICHTERN (Glanzpunkte einzeln korrigiert)	Pg	63,80	72,80	76,00	75,20	75,80	76,00	75,20	75,60	75,80
	pG	61,20	70,00	75,20	73,20	74,20	75,20	75,40	75,60	75,60
	pg	45,00	64,60	74,80	72,80	74,60	74,60	75,00	76,00	76,00
	Plg	52,20	68,80	74,00	74,20	75,20	75,00	76,00	76,00	75,60
	p1g	42,60	59,80	73,80	71,40	73,80	74,60	75,60	75,80	75,40
FILL-IN	pG	69,00	70,60	75,60	72,80	75,00	75,20	75,60	75,40	75,20

LEGENDE: Pg = Galerie verglanzt, pG = Probe verglanzt, pg = Galerie und Probe verglanzt, Plg = Nur der Galerist, der dem aktuellen Proband entspricht, ist verglanzt, p1g = wie Plg nur die Probe ist zusätzlich verglanzt

*Tabelle A.1: Ergebnis Test Datensatz 1, Rang 1 (Teil 1)*

Rang 1 in %		Glare 1	Glare 2	Glare 3	Glare 4	Glare 5	Glare 6	Glare 7	Glare 8	Glare 9
INTERPOLATION	Pg	34,60	57,80	74,60	69,00	67,60	73,20	75,20	75,00	76,00
OHNE STRUKTUR	pG	49,80	64,40	72,40	71,20	72,60	73,80	74,40	75,20	75,40
	pg	16,40	40,40	68,40	64,20	69,20	71,20	74,60	75,40	75,80
	P1g	8,40	31,20	63,80	52,00	67,60	70,40	73,20	74,60	75,60
	p1g	10,00	29,00	61,60	57,00	65,20	68,40	73,40	74,80	76,00
INTERPOLATION	Pg	49,80	58,20	70,60	71,00	72,20	74,00	74,40	75,60	75,60
MIT STRUKTUR	pG	56,80	63,40	72,40	72,40	73,40	73,60	75,40	75,00	75,40
	pg	29,80	39,80	64,00	66,80	68,20	71,80	74,00	75,20	74,80
	P1g	16,80	26,60	61,00	64,20	66,80	70,00	73,00	74,40	75,60
	p1g	21,20	35,00	60,40	60,80	63,60	68,40	74,00	74,60	76,00

**LEGENDE** Pg = Galerie verglanzt, pG = Probe verglanzt, pg = Galerie und Probe verglanzt, P1g = Nur der Galerie, der dem aktuellen Proband entspricht, ist verglanzt, p1g = wie P1g nur Probe zusätzlich verglanzt

*Tabella A.2: Ergebnis Test Datensatz 1, Rang 1 (Teil 1)*



<b>EER in %</b>		<b>Glare 1</b>	<b>Glare 2</b>	<b>Glare 3</b>	<b>Glare 4</b>	<b>Glare 5</b>	<b>Glare 6</b>	<b>Glare 7</b>	<b>Glare 8</b>	<b>Glare 9</b>
ORIGINAL		11,38	11,38	11,38	11,38	11,38	11,38	11,38	11,38	11,38
UNKORRIGIERT	Pg	15,37	14,91	13,05	11,58	12,07	11,96	12,59	12,42	12,48
	pG	15,16	14,06	12,44	12,10	12,45	12,79	11,62	12,09	11,19
	pg	18,59	16,64	14,96	12,71	13,05	12,22	12,58	12,12	12,42
	P1g	23,89	20,90	15,00	13,52	13,17	13,04	12,27	12,79	12,26
	p1g	17,08	14,80	14,35	12,51	13,59	12,24	12,24	12,38	12,42
ITERATIONS-	Pg	14,41	13,60	12,46	12,28	12,25	11,84	12,30	12,09	11,39
METHODE MIT	pG	16,00	13,48	12,18	12,96	11,83	11,30	11,62	12,15	11,52
1000 EIGEN-	pg	18,94	14,07	12,12	12,94	12,17	11,61	11,66	11,90	11,54
GESICHTERN	P1g	16,06	13,59	12,36	11,96	12,14	12,26	11,79	11,91	11,39
(Glanz als Ganzes betrachtet)	p1g	18,42	14,07	12,63	13,22	11,95	12,39	11,59	11,71	11,53
KORREKTUR MIT	Pg	14,80	13,00	12,20	12,00	12,42	12,20	12,00	11,80	11,47
250 EIGENGESICHTERN	pG	15,60	13,00	12,02	12,60	11,97	11,80	11,60	11,60	11,54
(nur defekte Pixel korrigiert)	pg	17,40	14,01	12,40	12,41	12,40	12,20	11,98	11,62	11,53
	P1g	14,80	13,00	12,20	12,00	12,39	12,16	12,00	11,80	11,39
	p1g	16,20	13,37	12,20	12,40	12,40	12,20	11,96	11,61	11,54
AUSGLEICH	Pg	16,17	13,62	12,29	12,85	12,38	12,30	12,24	11,98	11,48
MIT 200	pG	16,53	13,80	12,02	12,28	12,39	12,31	11,61	11,56	11,48
TRAININGS-	pg	19,02	15,21	12,37	12,92	12,71	12,18	12,10	11,81	11,48
GESICHTERN	P1g	15,80	13,55	11,84	11,99	12,41	12,27	11,81	11,55	11,39
(Glanzpunkte einzeln korrigiert)	p1g	17,91	15,12	12,58	13,15	12,74	12,13	11,84	11,65	11,39
FILL-IN	pG	17,71	13,86	12,50	13,00	11,91	11,95	11,78	12,28	11,26

LEGENDE: Pg = Galerie verglanzt, pG = Probe verglanzt, pg = Galerie und Probe verglanzt, P1g = Nur der Galerist, der dem aktuellen Proband entspricht, ist verglanzt, p1g = wie P1g nur Probe zusätzlich verglanzt

*Tabelle A.3: Ergebnis Test Datensatz 1, EER (Teil 1)*

EER in %		Glare 1	Glare 2	Glare 3	Glare 4	Glare 5	Glare 6	Glare 7	Glare 8	Glare 9
INTERPOLATION	Pg	17,34	13,71	12,84	12,08	11,92	11,18	12,10	12,04	12,41
OHNE STRUKTUR	pG	19,06	15,74	12,41	14,16	12,63	11,98	12,24	12,23	11,41
	pg	24,93	17,85	12,90	13,73	13,36	12,49	11,89	12,10	12,35
	PIg	34,91	21,25	14,71	13,97	13,85	12,89	12,36	11,87	12,18
	pIlg	32,63	22,27	14,82	15,96	14,38	12,56	11,99	11,80	12,19
INTERPOLATION	Pg	15,43	14,11	12,67	12,17	12,50	11,97	12,64	12,54	12,46
OHNE STRUKTUR	pG	17,20	14,29	13,10	12,45	12,66	12,39	11,53	11,39	11,25
	pg	21,76	18,31	13,81	12,09	13,15	12,89	12,55	11,48	12,46
	PIg	26,71	21,08	14,91	13,80	14,03	12,27	12,15	12,60	12,26
	pIlg	24,06	19,78	14,75	13,95	15,03	13,13	11,74	11,37	12,39

LEGENDE Pg = Galerie verglanzt, pG = Probe verglanzt, pg = Galerie und Probe verglanzt, PIg = Nur der Galerist, der dem aktuellen Proband entspricht, ist verglanzt, pIlg = wie PIg nur Probe zusätzlich verglanzt

*Tabelle A.4: Ergebnis Test Datensatz 1, EER (Teil 1)*

FAR bei FRR=0 in %		Glare 1	Glare 2	Glare 3	Glare 4	Glare 5	Glare 6	Glare 7	Glare 8	Glare 9
ORIGINAL		2,73	2,73	2,73	2,73	2,73	2,73	2,73	2,73	2,73
UNKORRIGIERT	Pg	5,22	4,81	3,51	3,11	3,18	2,93	2,78	2,83	2,77
	pG	5,36	4,73	3,52	2,99	3,20	2,83	2,69	2,80	2,79
	pg	7,72	6,45	4,21	3,40	3,74	3,02	2,78	2,90	2,82
	Plg	14,06	10,52	4,67	3,91	3,96	3,33	2,94	2,94	2,70
	p1g	7,01	5,45	4,32	3,94	4,17	3,30	2,85	2,99	2,76
ITERATIONSMETHODE	Pg	4,98	3,79	3,01	3,01	2,92	2,82	2,77	2,76	2,74
	pG	4,14	3,17	2,86	3,03	2,85	2,77	2,74	2,73	2,74
	pg	6,43	4,17	3,17	3,35	3,05	2,87	2,77	2,77	2,74
	Plg	5,29	3,59	2,92	2,97	2,83	2,77	2,76	2,76	2,73
(Glanz als Ganzes betrachtet)	p1g	5,49	3,63	3,03	3,23	2,91	2,80	2,77	2,76	2,73
KORREKTUR MIT	Pg	4,50	3,46	2,97	2,89	2,91	2,81	2,76	2,77	2,73
	pG	3,98	3,11	2,86	2,98	2,79	2,74	2,72	2,71	2,73
	pg	5,71	3,84	3,15	3,19	2,99	2,83	2,76	2,75	2,73
	Plg	4,14	3,14	2,87	2,79	2,80	2,72	2,72	2,76	2,73
	p1g	4,35	3,22	3,00	2,98	2,85	2,73	2,73	2,74	2,72
AUSGLEICH	Pg	4,61	3,66	2,98	2,98	2,93	2,80	2,77	2,76	2,73
	pG	4,24	3,27	2,84	2,97	2,81	2,78	2,69	2,69	2,73
	pg	5,96	4,08	3,10	3,19	3,01	2,88	2,76	2,74	2,72
	Plg	4,72	3,55	2,88	2,92	2,88	2,80	2,79	2,75	2,72
(Glanzpunkte einzeln korrigiert)	p1g	5,52	3,75	2,98	3,08	2,95	2,87	2,76	2,73	2,72

LEGENDE Pg = Galerie verglanz, pG = Probe verglanz, pg = Galerie und Probe verglanz, Plg = Nur der Galerist, der dem aktuellen Proband entspricht, ist verglanz, p1g = wie Plg nur Probe zusätzlich verglanz; Der Schwellenwert wird für jeden Galeristen neu berechnet (Schwellenwert = Ähnlichkeit aktueller Proband/Galerist).

**Tabelle A.5: Ergebnis Test Datensatz 1, FAR bei FRR=0 (Teil 1)**

FAR bei FRR=0 in %		Glare 1	Glare 2	Glare 3	Glare 4	Glare 5	Glare 6	Glare 7	Glare 8	Glare 9
INTERPOLATION	Pg	5,79	4,16	3,17	3,20	2,95	2,84	2,70	2,71	2,77
OHNE STRUKTUR	pG	8,37	4,93	3,28	3,70	3,11	3,00	2,83	2,80	2,77
	pg	15,31	7,88	3,78	4,38	3,44	3,17	2,80	2,78	2,80
	Plg	2,79	10,49	4,38	4,57	3,57	3,19	2,90	2,83	2,73
	p1g	2,47	12,42	4,76	5,68	4,00	3,47	2,99	2,90	2,77
INTERPOLATION	Pg	5,21	4,57	3,49	3,16	3,08	2,94	2,75	2,81	2,76
MIT STRUKTUR	pG	6,39	5,04	3,70	3,16	3,29	2,95	2,73	2,78	2,78
	pg	10,09	7,47	4,37	3,71	3,73	3,11	2,70	2,86	2,83
	Plg	16,86	10,85	4,90	4,07	4,00	3,40	2,97	2,96	2,71
	p1g	13,36	9,54	4,95	4,57	4,44	3,49	2,88	3,01	2,76

LEGENDE Pg = Galerie verglanzt, pG = Probe verglanzt, pg = Galerie und Probe verglanzt, Plg = Nur der Galerist, der dem aktuellen Proband entspricht, ist verglanzt, p1g = wie Plg nur Probe zusätzlich verglanzt; Der Schwellenwert wird für jeden Galeristen neu berechnet (Schwellenwert = Ähnlichkeit aktueller Proband/Galerist).

**Tabelle A.6: Ergebnis Test Datensatz 1, FAR bei FRR=0 (Teil 1)**

$\Delta$ Rang		Glare 1	Glare 2	Glare 3	Glare 4	Glare 5	Glare 6	Glare 7	Glare 8	Glare 9
UNKORRIGIERT		Bezugspunkt (+ = besserer Rang in der Korrektur)								
ITERATIONSMETHODE	P <sub>g</sub>	5,92	9,23	3,63	0,41	1,65	0,68	0,09	0,37	0,03
MIT 2000 EIGEN-	p <sub>G</sub>	0,70	4,25	1,87	-0,47	0,77	0,18	-0,09	0,10	0,07
GESICHTERN	p <sub>g</sub>	7,23	13,11	6,28	-0,07	3,09	0,72	-0,02	0,47	0,10
1000 BENUTZT	P <sub>1g</sub>	43,58	33,24	8,02	3,77	4,86	2,34	0,60	0,55	-0,20
(Glanz als Ganzes betrachtet)	p <sub>1g</sub>	0,71	5,08	4,85	2,25	4,48	1,94	0,35	0,59	-0,17
KORREKTUR MIT	P <sub>g</sub>	9,20	10,82	4,02	0,99	1,67	0,73	0,12	0,29	0,05
250 EIGENGESICHTERN	p <sub>G</sub>	0,52	3,74	1,74	-0,64	0,64	0,18	-0,02	0,16	0,08
(nur defekte Pixel korrigiert)	p <sub>g</sub>	10,82	14,86	6,45	0,58	2,97	0,81	0,03	0,45	0,15
	P <sub>1g</sub>	49,35	35,60	8,41	4,46	4,94	2,42	0,63	0,50	-0,17
	p <sub>1g</sub>	6,38	7,12	5,13	3,08	4,42	2,07	0,48	0,57	-0,15
AUSGLEICH	P <sub>g</sub>	7,36	9,79	3,71	1,21	1,57	0,74	0,03	0,43	0,05
MIT 200	p <sub>G</sub>	-0,51	2,78	1,61	-0,93	0,79	-0,03	0,04	0,17	0,09
TRAININGS-	p <sub>g</sub>	7,20	12,35	6,00	0,68	3,05	0,59	-0,02	0,61	0,15
GESICHTERN	P <sub>1g</sub>	46,40	33,99	8,11	4,47	4,62	2,21	0,43	0,59	-0,19
(Glanzpunkte einzeln korrigiert)	p <sub>1g</sub>	0,91	3,93	4,56	2,85	4,25	1,68	0,35	0,72	-0,15

LEGENDE P<sub>g</sub> = Galerie verglanzt, p<sub>G</sub> = Probe verglanzt, p<sub>g</sub> = Galerie und Probe verglanzt, P<sub>1g</sub> = Nur der Galerist, der dem aktuellen Proband entspricht, ist verglanzt, p<sub>1g</sub> = wie P<sub>1g</sub> nur Probe zusätzlich verglanzt.

**Tabelle A.7: Ergebnis Test Datensatz 1, Rangänderung (Teil 1)**

$\Delta$ Rang		Glare 1	Glare 2	Glare 3	Glare 4	Glare 5	Glare 6	Glare 7	Glare 8	Glare 9
UNKORRIGIERT		Bezugspunkt (+ = besserer Rang in der Korrektur)								
INTERPOLATION	Pg	-7,99	3,48	2,26	-0,39	1,53	1,02	0,59	0,39	0,00
OHNE STRUKTUR	pG	-7,49	-0,45	0,01	-1,58	-0,42	-0,59	-0,48	-0,24	-0,09
	pg	-34,95	-3,93	2,89	-2,37	1,56	0,15	-0,02	0,19	-0,05
	P1g	-69,35	-0,44	1,27	-2,78	1,84	0,82	0,18	0,21	-0,10
	p1g	-87,63	-32,19	-2,86	-5,96	0,18	-0,35	-0,42	-0,12	-0,19
INTERPOLATION	Pg	-0,48	1,37	-0,03	0,36	0,19	-0,04	0,03	0,07	0,01
MIT STRUKTUR	pG	-3,37	-0,87	-0,40	-0,69	-0,23	-0,22	-0,27	-0,14	-0,06
	pg	-9,15	-3,68	-0,19	-0,46	0,26	-0,32	-0,23	-0,01	-0,03
	P1g	-12,82	-1,68	-1,10	-0,45	-0,37	-0,39	-0,40	-0,13	-0,03
	p1g	-27,41	-17,92	-2,35	-1,87	-1,13	-0,87	-0,40	-0,25	-0,04

LEGENDE Pg = Galerie verglanzt, pG = Probe verglanzt, pg = Galerie und Probe verglanzt, P1g = Nur der Galerie, der dem aktuellen Proband entspricht, ist verglanzt, p1g = wie P1g nur Probe zusätzlich verglanzt.

*Tabelle A.8: Ergebnis Test Datensatz 1, Rangänderung (Teil 1)*

		<b>Rang 1</b>	<b>EER</b>
ORIGINAL		67,5%	10,98%
UNKORRIGIERT	MIT GLANZ	60,20%	12,13%
	GLANZ DURCH BILDMITTELWERT ERSETZT	60,00%	12,27%
KORRIGIERT	1000 EIGENGESICHTER BENUTZT	64,20%	11,05%
MIT EIGENGESICHTERN	500 EIGENGESICHTER BENUTZT	62,40%	12,48%
(MOSAICING)	250 EIGENGESICHTER BENUTZT	63,00%	11,80%
	100 EIGENGESICHTER BENUTZT	62,60%	12,20%
	10 EIGENGESICHTER BENUTZT	61,80%	11,63%
	1 EIGENGESICHT BENUTZT	63,20%	12,52%
KORRIGIERT	1000 GESICHTER BENUTZT	64,20%	11,07%
OHNE PCA	500 GESICHTER BENUTZT	63,60%	11,71%
(MOSAICING)	250 GESICHTER BENUTZT	63,40%	12,03%
	100 GESICHTER BENUTZT	62,40%	12,45%
	10 GESICHTER BENUTZT	61,60%	12,25%
	1 GESICHT BENUTZT	59,40%	12,79%

**Tabelle A.9:** Ergebnisse Test Datensatz 1 - Teil 2

## A.2 Tests auf Datensatz 2 mit künstlichem Glanz

**Zum Datensatz** Der Datensatz besteht aus 152 Galeristen und 608 Probanden.

**Zu den Versuchen:**

**Erster Teil** Es wurden die Gesichtsbilder mit verschiedenen künstlichen Glanzpunkten versehen. Die Parameter der Glanzpunkte waren Folgende:

Glanz 1:  $\alpha = 5,5, \sigma_{min} = 5, \sigma_{\Delta} = 3$ , insgesamt 15 Glanzpunkte

Glanz 2:  $\alpha = 5,5, \sigma_{min} = 3, \sigma_{\Delta} = 3$ , insgesamt 15 Glanzpunkte

Glanz 3:  $\alpha = 5,5, \sigma_{min} = 2, \sigma_{\Delta} = 2$ , insgesamt 10 Glanzpunkte

Glanz 4:  $\alpha = 5,5, \sigma_{min} = 4, \sigma_{\Delta} = 4$ , insgesamt 3 Glanzpunkte

Glanz 5:  $\alpha = 5,5, \sigma_{min} = 2, \sigma_{\Delta} = 3$ , insgesamt 5 Glanzpunkte

Glanz 6:  $\alpha = 5,5, \sigma_{min} = 2, \sigma_{\Delta} = 3$ , insgesamt 3 Glanzpunkte

Glanz 7:  $\alpha = 5,5, \sigma_{min} = 2, \sigma_{\Delta} = 2$ , insgesamt 2 Glanzpunkte

Glanz 8:  $\alpha = 5,5, \sigma_{min} = 2, \sigma_{\Delta} = 2$ , insgesamt 1 Glanzpunkte

Glanz 9:  $\alpha = 5,5, \sigma_{min} = 1, \sigma_{\Delta} = 1$ , insgesamt 1 Glanzpunkte

Gearbeitet wurde auf rotierten und kontrastkorrigierten Bildern. Der Hintergrund wurde ausgeblendet. Es wurde die Erkennungsrate und die EER der Originaldaten, der unkorrigierten (verglanzten) Daten und die mit unterschiedlichen Verfahren korrigierten Daten bestimmt.

**Zweiter Teil** Korrektur mit Ausgleichsrechnung mit und ohne Eigengesichter auf normierte, rotierte und angeglichene Gesichter. Die Augen liegen im Bild an der selben Position. Die Bildgröße ist 128 x 128 Pixel. Um die SVD zu beschleunigen wurde auf festen Glanzmasken gearbeitet.



<b>Rang 1 in %</b>		<b>Glare 1</b>	<b>Glare 2</b>	<b>Glare 3</b>	<b>Glare 4</b>	<b>Glare 5</b>	<b>Glare 6</b>	<b>Glare 7</b>	<b>Glare 8</b>	<b>Glare 9</b>
ORIGINAL		41,11	41,11	41,11	41,11	41,11	41,11	41,11	41,11	41,11
UNKORRIGIERT	Pg	18,42	18,75	28,94	32,73	34,87	37,34	37,17	40,46	40,62
	pG	14,14	14,80	26,48	33,71	31,74	34,54	35,86	38,81	39,63
	pg	8,38	10,03	17,76	27,30	26,81	32,73	34,20	38,15	39,80
	Plg	6,25	9,54	24,51	30,26	28,62	34,38	36,51	38,82	41,61
	p1g	22,36	26,32	26,97	29,28	27,30	31,91	33,22	36,68	41,12
ITERATIONSMETHODE MIT 2000 EIGEN- GESICHTERN 1000 BENUTZT (Glanz als Ganzes betrachtet)	Pg	28,12	34,87	37,50	37,66	38,49	39,47	39,80	40,62	41,44
	pG	20,89	32,07	37,82	37,50	38,65	40,46	40,46	40,62	40,95
	pg	19,20	30,26	35,20	34,54	35,20	38,00	39,47	39,31	41,28
	Plg	25,00	33,55	38,49	37,50	38,32	39,47	40,13	40,78	41,61
	p1g	21,38	32,24	36,02	34,05	36,51	38,32	39,47	40,13	41,11
KORREKTUR MIT 250 EIGENGESICHTERN (nur defekte Pixel korrigiert)	Pg	26,48	35,20	38,32	37,34	38,49	40,46	41,11	41,61	41,44
	pG	30,26	36,84	39,14	38,16	38,16	40,13	39,63	41,12	40,62
	pg	19,24	31,25	37,34	34,21	36,68	38,98	39,96	40,95	41,11
	Plg	28,78	35,20	38,49	38,49	37,99	39,14	41,11	41,28	41,77
	p1g	23,36	32,57	37,34	35,36	37,00	37,83	40,29	40,78	41,12
AUSGLEICH MIT 200 TRAININGS- GESICHTERN (Glanzpunkte einzeln korrigiert)	Pg	28,28	36,34	37,50	37,07	39,31	40,46	40,13	41,61	41,45
	pG	26,31	33,05	38,82	37,34	38,65	40,79	41,28	41,28	41,28
	pg	19,90	31,57	35,69	35,36	38,16	39,80	40,46	41,28	40,78
	Plg	26,31	33,88	38,65	38,32	39,64	40,46	40,62	41,28	41,61
	p1g	20,72	29,44	35,53	35,03	38,16	39,80	40,46	41,45	41,12
FILL-IN	pG	20,72	19,24	30,59	35,03	32,40	35,69	36,51	38,49	39,14

LEGENDE Pg = Galerie verglanzt, pG = Probe verglanzt, pg = Galerie und Probe verglanzt, Plg = Nur der Galerist, der dem aktuellen Proband entspricht, ist verglanzt, p1g = wie Plg nur Probe zusätzlich verglanzt

*Tabelle A.10: Ergebnis Test Datensatz 2, Rang 1 (Teil 1)*

Rang 1 in %		Glare 1	Glare 2	Glare 3	Glare 4	Glare 5	Glare 6	Glare 7	Glare 8	Glare 9
INTERPOLATION	Pg	20,88	26,97	33,22	32,24	37,01	37,60	39,14	38,98	40,79
OHNE STRUKTUR	pG	16,77	24,01	31,09	35,03	34,38	37,50	37,83	39,64	39,31
	pg	9,04	16,94	27,46	30,26	31,57	34,86	37,17	38,32	39,31
	P1g	6,58	16,28	28,78	29,28	31,91	34,54	37,83	39,14	41,28
	p1g	8,06	15,46	26,32	26,81	28,78	33,38	36,35	37,17	38,31
INTERPOLATION	Pg	21,21	23,35	28,78	34,38	36,18	36,35	37,99	40,62	40,46
MIT STRUKTUR	pG	17,26	20,89	28,62	33,39	33,22	35,53	35,69	38,48	39,47
	pg	12,50	13,49	20,07	29,93	27,96	32,24	35,36	37,34	39,97
	P1g	7,40	10,20	21,71	28,45	26,15	32,40	35,53	37,83	41,45
	p1g	9,37	15,46	21,71	25,99	25,00	29,77	33,55	36,35	40,13

LEGENDE Pg = Galerie verglanzt, pG = Probe verglanzt, pg = Galerie und Probe verglanzt, P1g = Nur der Galerie, der dem aktuellen Proband entspricht, ist verglanzt, p1g = wie P1g nur Probe zusätzlich verglanzt

*Tabelle A.11: Ergebnis Test Datensatz 2, Rang 1 (Teil 1)*

EER in %		Glare 1	Glare 2	Glare 3	Glare 4	Glare 5	Glare 6	Glare 7	Glare 8	Glare 9
ORIGINAL		23,99	23,99	23,99	23,99	23,99	23,99	23,99	23,99	23,99
UNKORRIGIERT	Pg	26,74	26,64	25,09	23,69	24,34	23,58	24,06	24,08	24,10
	pG	30,62	30,18	26,80	25,83	26,12	24,58	24,70	24,20	24,07
	pg	33,76	32,58	27,49	26,41	26,33	24,55	24,00	23,80	24,42
	P1g	35,16	33,19	26,72	25,14	26,04	24,42	24,24	24,10	23,86
	p1g	24,66	23,89	24,66	26,47	26,06	24,99	24,18	24,12	24,04
ITERATIONSMETHODE MIT 2000 EIGEN- GESICHTERN 1000 BENUTZT (Glanz als Ganzes betrachtet)	Pg	26,57	24,79	24,80	24,51	24,45	24,09	24,21	24,20	23,96
	pG	27,32	25,15	24,05	24,65	24,33	24,17	24,07	23,85	24,00
	pg	28,31	25,87	24,10	24,59	24,14	24,36	24,60	24,25	23,99
	P1g	26,71	25,02	24,87	24,53	24,24	24,16	24,17	24,28	23,99
	p1g	27,64	25,24	23,87	24,74	24,51	24,31	24,62	24,24	24,00
KORREKTUR MIT 250 EIGENGESICHTERN (nur defekte Pixel korrigiert)	Pg	26,95	24,39	24,33	24,06	23,89	24,03	24,02	24,02	24,00
	pG	25,66	24,61	23,73	24,06	24,09	24,14	23,95	24,03	23,93
	pg	28,60	24,83	24,41	24,04	24,17	24,10	23,84	24,12	24,10
	P1g	26,02	25,33	24,12	24,15	24,09	24,09	23,97	24,03	24,00
	p1g	27,82	24,41	24,10	23,82	24,06	23,77	23,85	24,16	24,11
AUSGLEICH MIT 200 TRAININGS- GESICHTERN (Glanzpunkte einzeln korrigiert)	Pg	25,26	24,93	24,43	24,37	24,25	23,99	24,05	24,07	23,99
	pG	26,76	25,41	24,43	24,23	24,45	24,04	24,07	23,82	25,11
	pg	28,20	25,67	25,01	24,83	24,43	24,10	24,03	23,90	25,18
	P1g	26,95	25,08	25,00	24,69	24,37	24,05	24,07	24,97	23,98
	p1g	28,09	25,93	25,50	24,43	24,83	24,17	24,06	23,90	24,14
FILL-IN	pG	33,07	30,24	27,17	27,51	26,00	25,18	24,29	24,56	23,65

LEGENDE Pg = Galerie verglanzt, pG = Probe verglanzt, pg = Galerie und Probe verglanzt, P1g = Nur der Galerist, der dem aktuellen Proband entspricht, ist verglanzt, p1g = wie P1g nur Probe zusätzlich verglanzt

*Tabelle A.12: Ergebnis Test Datensatz 2, EER (Teil 1)*

EER in %		Glare 1	Glare 2	Glare 3	Glare 4	Glare 5	Glare 6	Glare 7	Glare 8	Glare 9
INTERPOLATION	Pg	26,78	25,15	24,59	24,32	24,55	24,48	23,98	23,77	23,97
OHNE STRUKTUR	pG	30,11	27,87	25,08	24,63	24,82	24,35	24,08	24,11	23,41
	pg	31,50	28,40	25,72	25,31	24,86	24,34	24,60	24,56	23,87
	Plg	36,38	30,03	26,15	26,53	25,48	25,26	24,46	24,00	23,84
	p1g	34,60	29,68	26,70	26,99	25,46	25,75	24,87	24,67	23,69
INTERPOLATION	Pg	26,08	25,87	25,63	23,84	24,84	23,87	24,18	23,89	24,11
MIT STRUKTUR	pG	30,00	29,22	26,80	24,69	25,69	25,21	24,63	24,23	24,02
	pg	31,63	30,59	28,01	25,02	26,63	24,26	24,69	24,12	24,47
	Plg	34,84	33,28	27,94	25,65	26,33	24,83	24,84	24,40	24,01
	p1g	33,30	30,29	27,09	26,72	28,08	25,54	25,16	24,74	23,50

**LEGENDE** Pg = Galerie verglanzt, pG = Probe verglanzt, pg = Galerie und Probe verglanzt, Plg = Nur der Galerist, der dem aktuellen Proband entspricht, ist verglanzt, p1g = wie Plg nur Probe zusätzlich verglanzt

*Tabelle A.13: Ergebnis Test Datensatz 2, EER (Teil 1)*

FAR bei FRR=0 in %		Glare 1	Glare 2	Glare 3	Glare 4	Glare 5	Glare 6	Glare 7	Glare 8	Glare 9
ORIGINAL		13,74	13,74	13,74	13,74	13,74	13,74	13,74	13,74	13,74
UNKORRIGIERT	Pg	17,18	16,50	15,31	13,87	14,38	13,90	13,83	13,76	13,74
	pG	22,10	21,77	18,10	16,24	16,92	15,40	14,67	14,39	14,13
	pg	25,03	24,24	19,52	16,45	17,59	15,55	14,79	14,47	14,16
	P1g	30,56	26,82	17,56	15,98	16,40	15,15	14,25	13,97	13,52
	p1g	15,10	14,72	16,66	16,99	17,58	16,02	14,95	14,61	13,90
ITERATIONSMETHODE MIT 2000 EIGEN- GESICHTERN 1000 BENUTZT (Glanz als Ganzes betrachtet)	Pg	15,99	14,59	14,04	14,23	13,83	13,77	13,79	13,85	13,77
	pG	17,77	15,41	14,16	14,34	14,11	13,96	13,89	13,85	13,76
	pg	19,53	16,03	14,41	14,81	14,20	13,95	13,97	13,97	13,79
	P1g	17,07	14,75	14,28	14,43	13,95	13,93	13,85	13,86	13,76
	p1g	18,34	15,40	14,53	14,93	14,28	14,13	14,01	13,98	13,78
KORREKTUR MIT 250 EIGENGESICHTERN (nur defekte Pixel korrigiert)	Pg	15,92	14,48	13,93	14,01	13,82	13,72	13,70	13,78	13,76
	pG	17,29	15,34	14,24	14,29	14,06	13,88	13,80	13,79	13,74
	pg	19,32	15,77	14,38	14,52	14,13	13,84	13,76	13,81	13,77
	P1g	16,59	14,79	14,09	14,12	13,95	13,91	13,75	13,79	13,74
	p1g	17,96	15,38	14,44	14,52	14,21	14,01	13,83	13,82	13,74
AUSGLEICH MIT 200 TRAININGS- GESICHTERN (Glanzpunkte einzeln korrigiert)	Pg	15,76	14,52	14,08	14,12	13,88	13,74	13,76	13,79	13,75
	pG	17,50	15,35	14,17	14,50	14,12	13,95	13,78	13,73	13,70
	pg	19,16	16,02	14,46	14,83	14,25	13,97	13,77	13,77	13,72
	P1g	16,42	14,84	14,28	14,30	13,99	13,84	13,76	13,78	13,72
	p1g	19,14	16,08	14,66	14,95	14,35	14,03	13,79	13,77	13,70

LEGENDE Pg = Galerie verglanz, pG = Probe verglanz, pg = Galerie und Probe verglanz, P1g = Nur der Galerist, der dem aktuellen Proband entspricht, ist verglanz, p1g = wie P1g nur Probe zusätzlich verglanz; Der Schwellenwert wird für jeden Galeristen neu berechnet (Schwellenwert = Ähnlichkeit aktueller Proband/Galerist).

**Tabelle A.14: Ergebnis Test Datensatz 2, FAR bei FRR=0 (Teil 1)**

FAR bei FRR=0 in %		Glare 1	Glare 2	Glare 3	Glare 4	Glare 5	Glare 6	Glare 7	Glare 8	Glare 9
INTERPOLATION	Pg	16,59	15,19	14,21	13,78	13,83	13,70	13,68	13,76	13,75
OHNE STRUKTUR	pG	21,06	17,97	15,83	15,11	15,20	14,68	14,37	14,12	14,02
	pg	23,23	18,98	16,24	15,23	15,23	14,67	14,30	14,14	14,06
	Plg	30,62	22,15	16,35	16,65	15,27	14,75	14,21	14,05	13,68
	p1g	28,18	21,34	17,14	17,89	16,28	15,58	14,77	14,42	13,95
INTERPOLATION	Pg	16,15	15,94	15,09	13,80	14,29	13,84	13,82	13,75	13,73
MIT STRUKTUR	pG	21,16	20,00	17,94	15,71	16,46	15,23	14,67	14,36	14,14
	pg	23,38	22,38	19,31	15,82	17,05	15,33	14,80	14,45	14,16
	Plg	28,65	26,46	18,91	16,35	16,86	15,47	14,63	14,23	13,53
	p1g	25,92	22,25	19,10	18,10	18,51	16,51	15,39	14,86	13,93

LEGENDE Pg = Galerie verglanzt, pG = Probe verglanzt, pg = Galerie und Probe verglanzt, Plg = Nur der Galerist, der dem aktuellen Proband entspricht, ist verglanzt, p1g = wie Plg nur Probe zusätzlich verglanzt; Der Schwellenwert wird für jeden Galeristen neu berechnet (Schwellenwert = Ähnlichkeit aktueller Proband/Galerist).

**Tabelle A.15: Ergebnis Test Datensatz 2, FAR bei FRR=0 (Teil I)**

$\Delta$ Rang		Glare 1	Glare 2	Glare 3	Glare 4	Glare 5	Glare 6	Glare 7	Glare 8	Glare 9
UNKORRIGIERT		Bezugspunkt (+ = besserer Rang in der Korrektur)								
ITERATIONSMETHODE	P <sub>g</sub>	7,05	8,34	2,72	1,90	1,77	1,19	0,56	-0,04	0,19
MIT 2000 EIGEN-	p <sub>G</sub>	8,08	10,14	4,89	1,99	2,77	1,57	0,93	0,38	0,14
GESICHTERN	p <sub>g</sub>	13,85	17,94	8,19	3,76	4,89	2,69	1,52	0,41	0,29
1000 BENUTZT	P <sub>1g</sub>	23,54	19,24	3,60	2,56	2,90	1,48	0,60	0,02	-0,17
(Glanz als Ganzes betrachtet)	p <sub>1g</sub>	-2,89	-0,22	2,08	3,04	3,48	2,35	1,19	0,41	-0,18
KORREKTUR MIT	P <sub>g</sub>	7,92	8,39	2,92	1,78	1,85	1,27	0,70	0,06	0,19
250 EIGENGESICHTERN	p <sub>G</sub>	8,63	10,61	4,89	1,94	2,88	1,48	0,75	0,36	0,09
(nur defekte Pixel korrigiert)	p <sub>g</sub>	15,11	18,02	8,32	3,72	5,03	2,75	1,53	0,53	0,22
	P <sub>1g</sub>	24,06	19,24	3,84	2,73	2,96	1,53	0,72	0,14	-0,17
	p <sub>1g</sub>	-2,01	-0,17	2,18	3,30	3,68	2,23	1,20	0,53	-0,21
AUSGLEICH	P <sub>g</sub>	8,31	8,57	2,85	1,85	1,74	1,29	0,77	0,17	0,29
MIT 200	p <sub>G</sub>	7,67	10,41	4,74	1,61	2,63	1,42	0,89	0,47	0,18
TRAININGS-	p <sub>g</sub>	14,83	18,31	8,14	3,36	4,68	2,71	1,69	0,74	0,39
GESICHTERN	P <sub>1g</sub>	24,22	19,25	3,65	2,60	2,84	1,62	0,85	0,23	-0,10
(Glanzpunkte einzeln korrigiert)	p <sub>1g</sub>	-3,94	-0,67	1,87	2,73	3,31	2,22	1,35	0,68	-0,07

LEGENDE P<sub>g</sub> = Galerie verglanzt, p<sub>G</sub> = Probe verglanzt, p<sub>g</sub> = Galerie und Probe verglanzt, P<sub>1g</sub> = Nur der Galerie, der dem aktuellen Proband entspricht, ist verglanzt, p<sub>1g</sub> = wie P<sub>1g</sub> nur Probe zusätzlich verglanzt.

*Tabelle A.16: Ergebnis Test Datensatz 2, Rangänderung (Teil 1)*

$\Delta$ Rang		Glare 1	Glare 2	Glare 3	Glare 4	Glare 5	Glare 6	Glare 7	Glare 8	Glare 9
UNKORRIGIERT		Bezugspunkt (+ = besserer Rang in der Korrektur)								
INTERPOLATION	P <sub>g</sub>	2,28	5,57	1,90	1,50	1,59	1,14	0,37	-0,23	0,03
OHNE STRUKTUR	p <sub>G</sub>	3,90	7,43	3,19	1,06	1,53	0,67	0,25	0,17	0,02
	p <sub>g</sub>	5,10	12,22	5,55	2,60	3,56	1,83	0,70	0,08	0,05
	P1 <sub>g</sub>	-0,36	8,33	1,16	-0,09	1,46	0,74	0,13	-0,15	-0,15
	p1 <sub>g</sub>	-19,68	-8,60	-0,69	-0,26	1,31	0,82	0,26	0,02	-0,21
INTERPOLATION	P <sub>g</sub>	2,83	3,55	0,64	1,31	0,57	0,69	0,13	-0,08	0,01
MIT STRUKTUR	p <sub>G</sub>	3,12	3,88	0,47	0,67	0,54	0,16	0,03	-0,04	-0,02
	p <sub>g</sub>	5,32	5,69	1,01	2,11	1,03	0,65	0,12	-0,13	0,03
	P1 <sub>g</sub>	3,79	1,05	-1,95	0,02	-0,74	-0,25	-0,37	-0,36	0,02
	p1 <sub>g</sub>	-15,06	-10,03	-2,87	-0,51	-1,29	-0,62	-0,51	-0,40	-0,04

LEGENDE: P<sub>g</sub> = Galerie verglanzt, p<sub>G</sub> = Probe verglanzt, p<sub>g</sub> = Galerie und Probe verglanzt, P1<sub>g</sub> = Nur der Galerist, der dem aktuellen Proband entspricht, ist verglanzt, p1<sub>g</sub> = wie P1<sub>g</sub> nur Probe zusätzlich verglanzt.

*Tabelle A.17: Ergebnis Test Datensatz 2, Rangänderung (Teil 1)*



		<b>Rang 1</b>	<b>EER</b>
ORIGINAL		33,72%	24,38%
UNKORRIGIERT	MIT GLANZ	17,60%	28,66%
	GLANZ DURCH BILDMITTELWERT ERSETZT	20,23%	27,81%
KORRIGIERT	1000 EIGENGESICHTER BENUTZT	28,78%	26,05%
MIT EIGENGESICHTERN	500 EIGENGESICHTER BENUTZT	28,29%	26,54%
(MOSAICING)	250 EIGENGESICHTER BENUTZT	28,61%	25,40%
	100 EIGENGESICHTER BENUTZT	28,13%	25,60%
	10 EIGENGESICHTER BENUTZT	23,35%	26,68%
	1 EIGENGESICHT BENUTZT	24,18%	26,73%
KORRIGIERT	1000 GESICHTER BENUTZT	28,95%	25,79%
OHNE PCA	500 GESICHTER BENUTZT	26,97%	25,26%
(MOSAICING)	250 GESICHTER BENUTZT	25,16%	25,33%
	100 GESICHTER BENUTZT	22,53%	25,81%
	10 GESICHTER BENUTZT	22,86%	27,53%
	1 GESICHT BENUTZT	20,39%	27,77%

**Tabelle A.18:** Ergebnisse Test Datensatz 2 - Teil 2

### A.3 Versuche zur Einschätzung der Verfahren

#### A.3.1 Untersuchung der verschiedenen Messmethoden

**Zum Datensatz** Der benutzte Datensatz besteht aus 100 Gesichtspaaren. Die Gesichter wurden normiert, rotiert und skaliert, sodass die Augen exakt an der gleichen Stelle liegen. Da die vorhandenen Knotenpositionen nicht mehr passten, wurde ein quadratischer Graph mit 40 Knotenpunkten verwendet.

#### A.3.2 Abschätzung der Leistungsfähigkeit der Algorithmen

**Zum Datensatz** Der verwendete Datensatz besteht aus 189 Gesichtspaaren aus Datensatz 1. Bei allen folgenden Testreihen wurde Glanz nur auf dem Galeristen in einer Zeile hinzugefügt, der auch dem Probanden in Reihe entspricht. Es wurde ein angepasster Graph mit 169 Knoten benutzt.

**Zum künstlichen Glanz** Es wurden zwei Datensätze verwendet, bei denen künstlicher Glanz hinzugefügt wurde. Die Glanzpunkte unterscheiden sich durch unterschiedlich eingestellte Parameter:

Variation 1:

Glanzfläche 2,03% der Bildfläche, 15 Glanzpunkte, Größe der Glanzpunkte  $\approx 109,27px^2$ .

Variation 2:

Glanzfläche 0,59% der Bildfläche, 15 Glanzpunkte, Größe der Glanzpunkte  $\approx 27,63px^2$ .

#### A.3.3 Vergleich Korrektur mit Ausgleichsmethode und mit Eigenfaces

**Zum Datensatz** Der verwendete Datensatz besteht aus 200 Gesichtspaaren aus Datensatz 1. Bei allen folgenden Testreihen wurde Glanz nur auf dem Galeristen in einer Zeile hinzugefügt, der auch dem entsprechenden Probanden in Reihe entspricht. Es wurde ein angepasster Graph mit 169 Knoten benutzt.

**Zum künstlichen Glanz** Die Glanzpunkte haben die folgenden Parameter:

$\alpha = 500, \sigma_{min} = 5, \sigma_{\Delta} = 100$ , insgesamt 4 Glanzpunkte

Ausschnitt Datensatz 1 (200 Gesichter)	unkorrigiert			korrigiert mit Eigengesichtern		
Gesichter normiert	Rang 1	EER	$\bar{s}$ bei g=p	Rang 1	EER	$\bar{s}$ bei g=p
OHNE GLANZ	74,5%	13,0%	48,50 ±1,6	74,5%	13,0%	48,50 ±1,6
PROBAND MIT GLANZ	64,5%	20,9%	46,85±1,7	71,5%	15,5%	48,22±1,6
ALLE GALERISTEN MIT GLANZ	49,5%	16,6%	46,96±1,5	73,0%	14,5%	48,25±1,5
EIN GALERIST (G=P) MIT GLANZ	31,0%	27,1%	46,96±1,5	72,5%	14,5%	48,25±1,5
PROBANDEN UND GALERISTEN MIT GLANZ	40,0%	25,0%	45,80±1,6	70,0%	16,5%	48,11±1,5
PROBANDEN UND EIN GALERIST (G=P) MIT GLANZ	27,5%	31,0%	45,80±1,6	70,5%	16,0%	48,11±1,5

*Tabelle A.19: Ergebnisse „verschiedene Messmethoden“*

	Variation 1				Variation 2			
	Rang 1	Differenz	EER	Differenz	Rang 1	Differenz	EER	Differenz
ORIGINAL (OHNE GLANZ)	84,90%	+39,93%	11,64%	-10,58%	84,90%	+22,47%	11,64%	-5,82%
UNKORRIGIERT (MIT GLANZ)	44,97%	Bezug	22,22%	Bezug	62,43%	Bezug	17,46%	Bezug
AUSGLEICH 200 GESICHTER	80,42%	+35,45%	11,64%	-10,58%	85,19%	+22,76%	12,13%	-5,33%
AUSGLEICH 10 10 GESICHTER	73,55%	+28,58%	14,28%	-24,86%	83,07%	+20,64%	12,70%	-4,76%
INTERPOLATION MIT UNSCHÄRFEFILTER	67,20%	+22,23%	18,45%	-3,77%	79,30%	16,87%	13,70%	-3,76%
STRUKTURINTERPOLATION MIT UNSCHÄRFEFILTER	66,14%	+21,17%	17,99%	-4,23%	74,07%	11,64%	14,81%	-2,65%

Tabelle A.20: Ergebnisse „Abschätzung der Leistungsfähigkeit der Algorithmen“

	Korrektur			
	mit Ausgleichsrechnung		mit Eigenfaces	
	Rang 1	EER	Rang 1	EER
ORIGINAL (OHNE GLANZ)	74,50%	13,00%	74,50%	13,00%
UNKORRIGIERT (MIT GLANZ)	31,00%	27,12%	31,00%	27,12%
KORRIGIERT	69,50%	15,00%	72,50%	14,50%

**Tabelle A.21:** Ergebnisse „Vergleich Ausgleichsrechnungs- und Eigenface-Korrektur“

Ausschnitt Datensatz 2 (2*152 Gesichter)	original	gespiegelte Matrix
RANG 1 STATISTIK	32,89%	26,97%
EER	24,67%	24,67%
FAR BEI FRR=0 BEI ANGEPASSTEN SCHWELLENWERT	14,40%	8,33%
MITTLERER RANG	12,59%	21,74%

*Tabelle A.22: Ergebnisse „transponierte Ähnlichkeitsmatrix“*

#### **A.4 Versuche zum Probandeffekt**

Aus dem Datensatz 2 wurde ein quadratischer Datensatz erstellt. Dazu wurde jeweils der erste Proband zu jedem Galeristen verwendet. Man erhält so 152 Galeristen und 152 Probanden. Das ist nötig um die Ähnlichkeitsmatrix an der Diagonalen (oben links nach unten rechts) spiegeln zu können (Transponierte Matrix). Sind die Bilder von ähnlicher Qualität erwartet man keine große Änderung an den Ergebnissen. Da die Bilder der Probe deutlich schlechter als die der Galerie sind, erkennt man einen deutlichen Unterschied. Dies kommt durch den in Kapitel 5.1 beschriebenen Effekt.

## A.5 Test auf wirklichen Glanzdaten

### A.5.1 608 gegen 152 - Test

**Zum Datensatz** Der Datensatz besteht aus 608 Probanden und 152 Galeristen. Zur Detektion wurde eine Kombination aus den beiden Luminanz-Detektoren benutzt.

Tabelle A.23: Ergebnisse auf wirklichen Daten

in %	unbehandelte Originaldaten	rekonstruiert aus 1000 Eigengesichtern (mit Glanz)	korrigiert mit 1000 Eigengesichtern	korrigiert mit 1000 Eigengesichtern und Mosaicing	iterative Methode mit 2000 Eigengesichtern
RANG 1	41,11	23,52	24,51	40,79	40,13
RANG 2	50,16	33,22	34,38	50,82	50,00
RANG 3	55,43	39,31	42,43	55,59	56,41
RANG 4	60,20	44,08	46,55	60,20	61,02
RANG 5	62,83	47,53	49,18	63,49	63,16
RANG 6	65,79	50,16	51,81	65,63	65,46
RANG 7	67,60	51,81	53,78	68,75	68,59
RANG 8	69,57	54,11	56,09	71,38	71,05
RANG 9	71,38	56,09	57,89	72,86	73,19
RANG 10	73,36	57,24	59,21	74,67	74,18
RANG 11	74,51	59,21	60,69	75,66	75,16
RANG 12	75,49	61,51	61,51	76,64	76,81
RANG 13	76,48	62,83	63,32	76,97	77,80
RANG 14	77,47	64,14	64,64	77,63	78,29
RANG 15	78,29	65,13	65,13	78,61	78,62
RANG 16	79,28	65,78	66,45	79,61	79,77
RANG 17	80,10	66,94	67,60	80,26	80,43
RANG 18	80,92	68,09	68,26	81,09	81,09
RANG 19	82,24	68,26	69,57	82,24	82,40
RANG 20	82,57	69,57	70,39	82,89	83,39
EER	23,99	30,40	29,73	23,92	23,68
$\Delta$ Rang	Bezugspunkt	+9,00	+7,72	-0,55	-0,42

A Testergebnisse der Gesichtserkennung



in %	original	korrigiert mit 300 Eigengesichtern	original	korrigiert mit 300 Eigengesichtern
			nur Galerist mit gleicher Identität wie Proband mit Glanz	
RANG 1	98,00%	98,67%	100%	100%
EER	2,02%	2,95%	2,9%	2,6%

*Tabelle A.24: Ergebnisse auf wirklichen Daten: 150 gegen 28 Personen*

### A.5.2 150 gegen 28 - Test

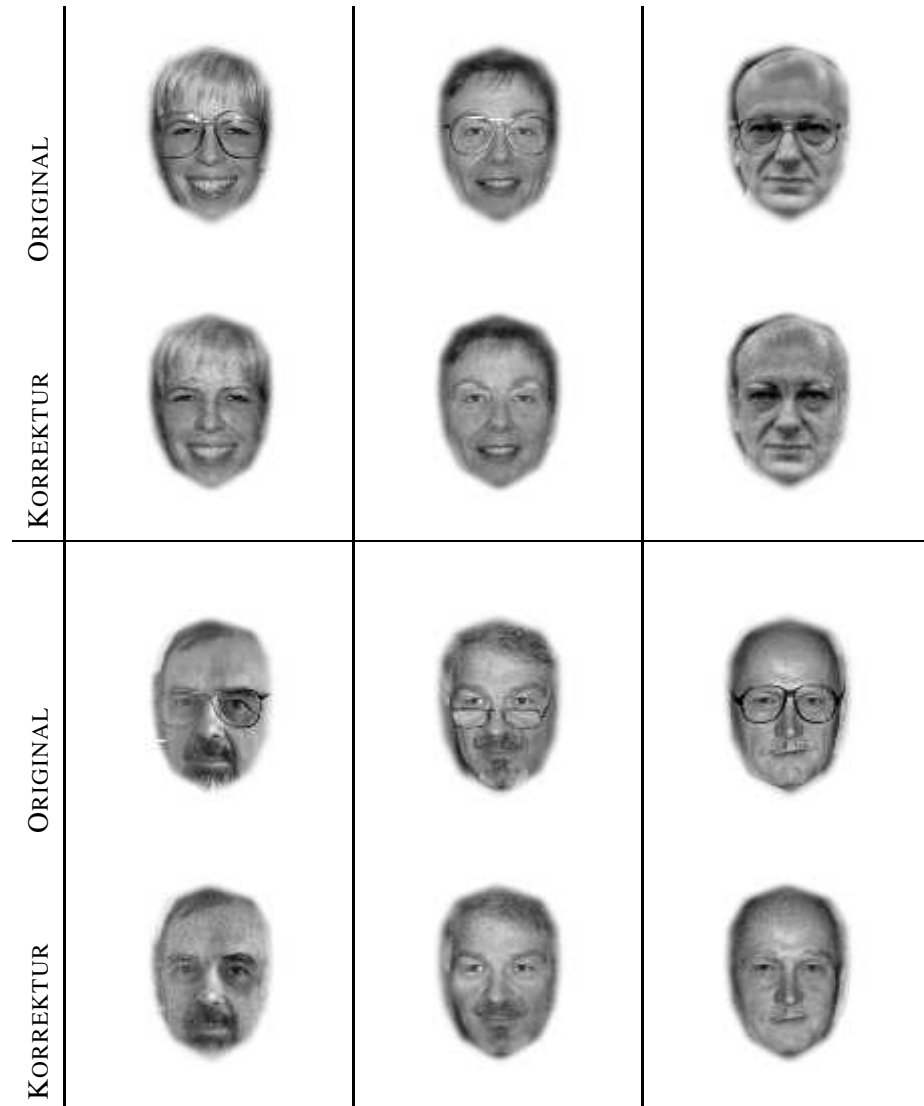
**Zum Datensatz** Der Datensatz besteht aus 150 Probanden und 28 Galeristen der Viisage Technology AG. Der Glanz wurde mit Hilfe einer Beleuchtungseinrichtung während der Aufnahme bewusst hinzugefügt. Zur Detektion wurde der Zweit-Stufen-Detektor benutzt.

## **Anhang B**

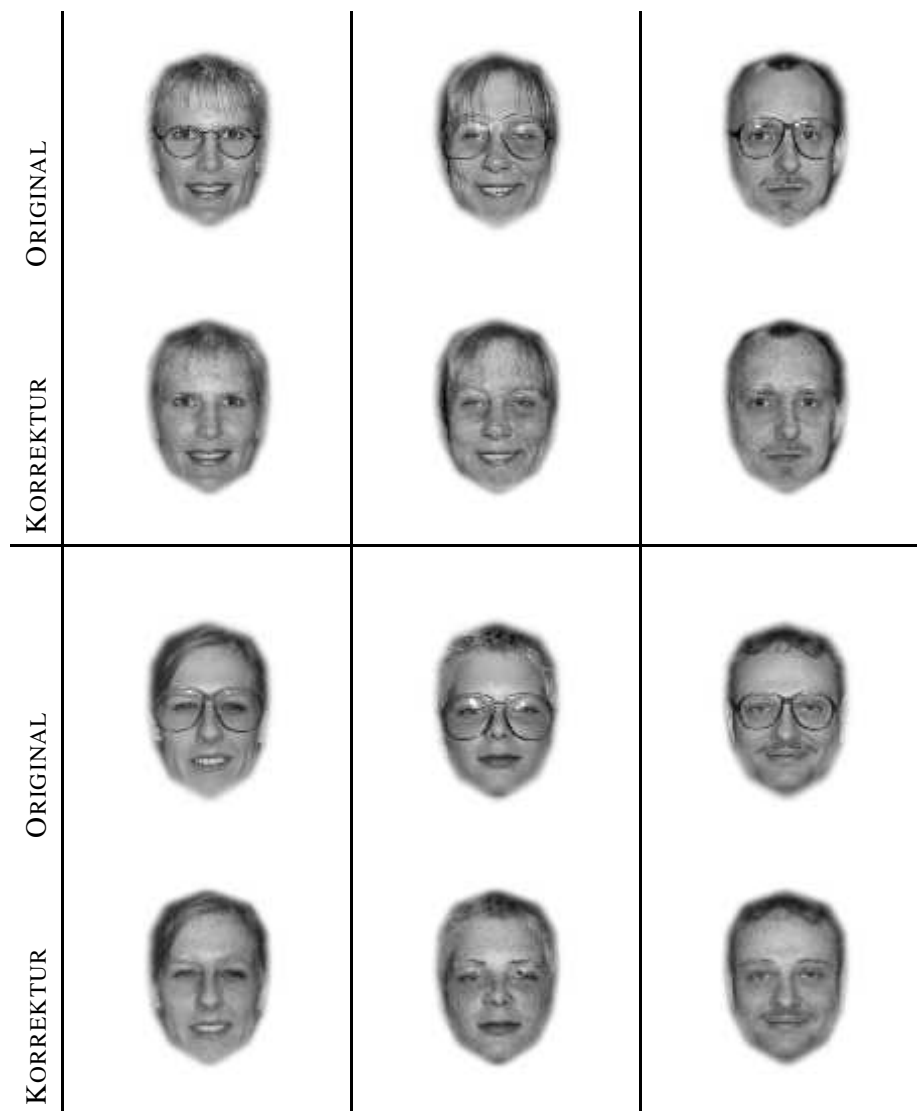
### **Beispielbilder**

Im folgenden Abschnitt sind einige Bilder aufgelistet, auf denen die Algorithmen zur Entfernung von Brillengestellen, Pflastern, sowie das Öffnen von Augen getestet wurden. Die Bilder wurden unter unkontrollierten Bedingungen aufgenommen. Da für Brillen, Pflaster und geschlossene Augen kein Detektor entwickelt wurde, wurden die entsprechenden Bereiche per Hand markiert, d.h. es wurde eine entsprechende Maske angefertigt. Diese Maske ist 1, wenn der Pixel fehlerhaft ist bzw. dort eine Brille ist und 0, wenn dort kein Fehler vorhanden ist. Das Verfahren mit Hilfe der Eigengesichter erhielt nun diese Information und sollte die „Störstellen“ entfernen. Einen Ausschnitt aller Bilder sehen sie auf den folgenden Seiten.

### B.1 Entfernung von Brillengestellen

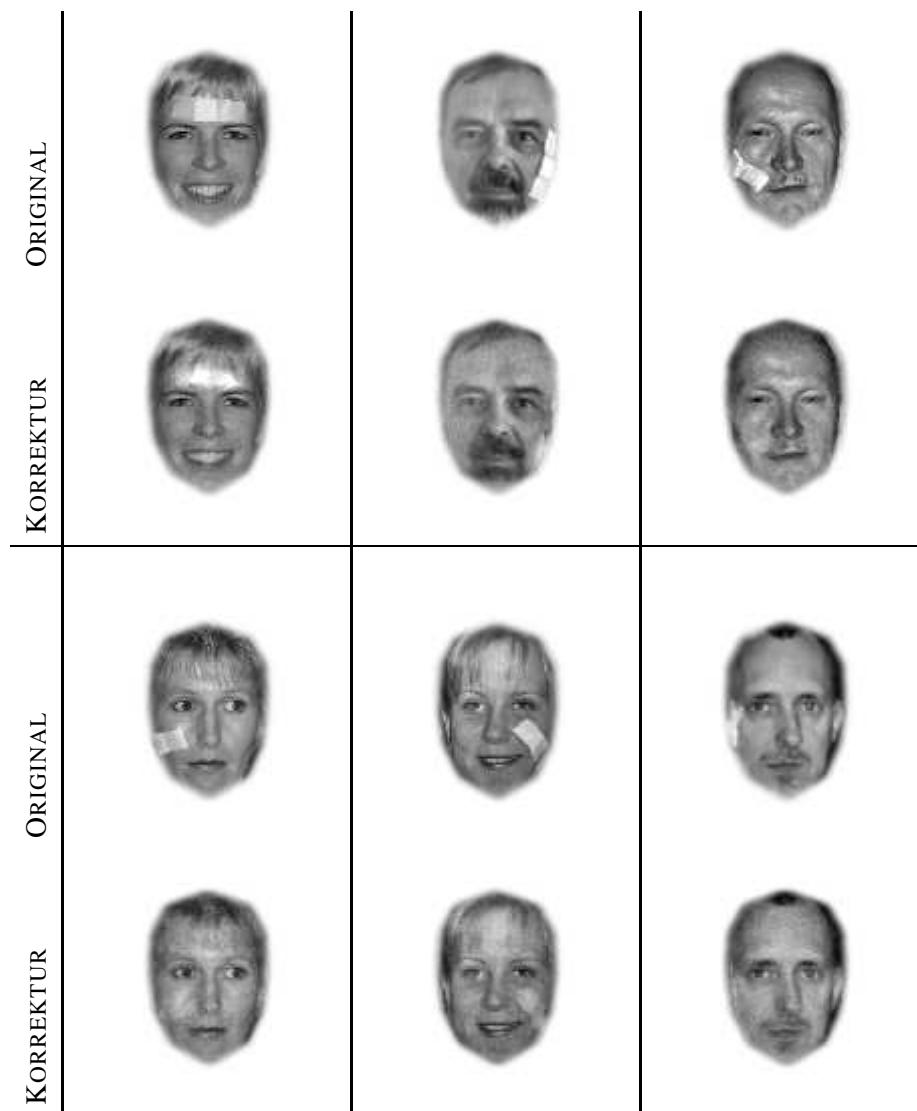


**Abbildung B.1:** Übersicht Korrekturbilder: Entfernung von Brillengestellen Teil 1



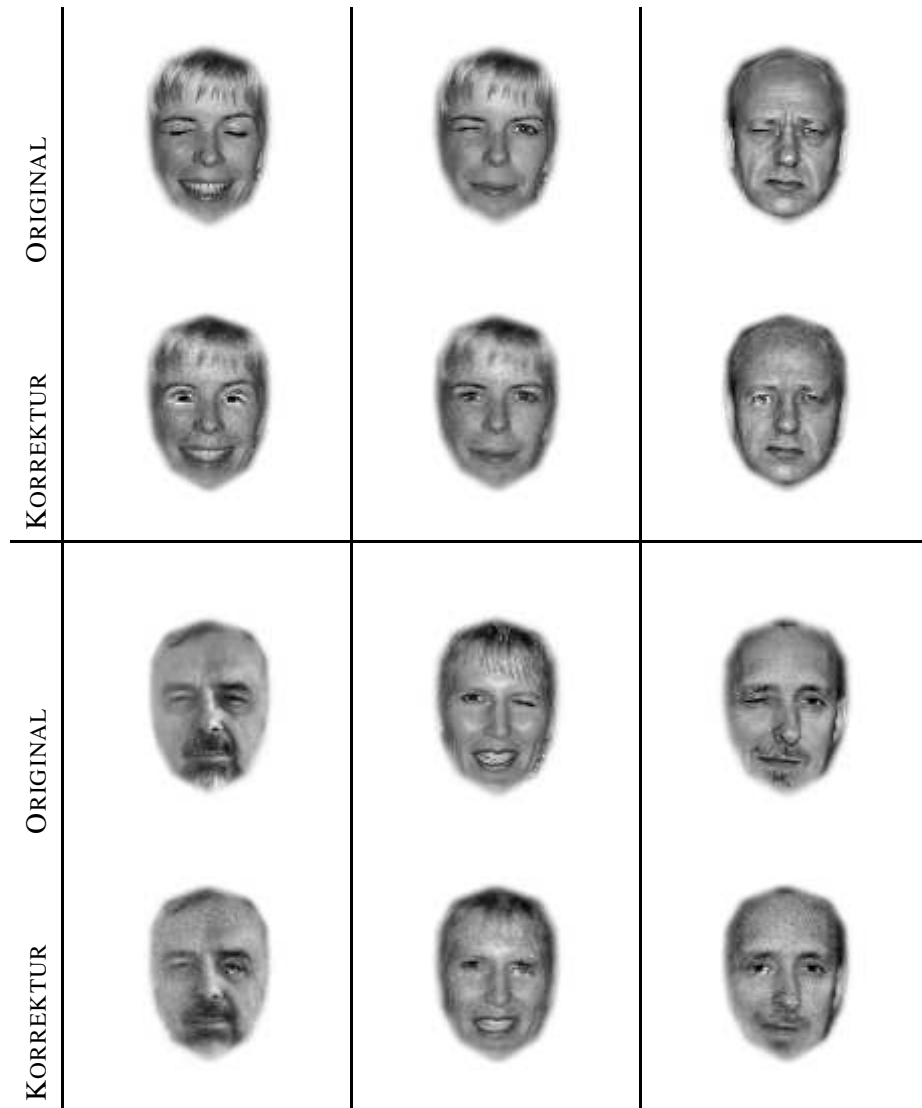
**Abbildung B.2:** Übersicht Korrekturbilder: Entfernung von Brillengestellen Teil 2

## B.2 Entfernung von Pflastern



*Abbildung B.3: Übersicht Korrekturbilder: Entfernung von Pflastern*

### B.3 Öffnen von Augen



*Abbildung B.4: Übersicht Korrekturbilder: Öffnung von Augen*

## Literaturverzeichnis

- [Ahl03] AHLERS, Benedikt H.: *Kompetenzzentrum Biometrie / Bundesdruckerei*. 2003. – Bericht. <http://www.berlin.de/senwiarbfrau/projektzukunft/sit/bundesdruckerei.pdf>, verfügbar am 10.09.04
- [BDG<sup>+</sup>03] BUSCH, Christoph ; DAUM, Henning ; GRAF, Frank ; MARTIN, Manfred ; MUNDE, Axel ; PRETZEL, Andrew ; REINEFELD, Tom ; SALAMON, René ; VOGEL, Christoph ; WIEGAND, Mike: *BioFace - Vergleichende Untersuchung von Gesichtserkennungssystemen / Bundesamt für Sicherheit in der Informationstechnik*. 2003. – Öffentlicher Abschlussbericht
- [Brü99] BRÜNENBERG, Kai: *Untersuchungen zur Beleuchtungsunabhängigkeit am Beispiel der Gesichtserkennung / Institut für Neuroinformatik an der Ruhr-Universität Bochum*. 1999 ( IR-INI 99-07). – Forschungsbericht
- [Con01] CONDE, José Emilio S.: *Optische Raumüberwachung*, Gerhard-Mercator-Universität - Gesamthochschule Duisburg, Dissertation, 2001
- [Ger96] GERL, Susanne: *3D-Gesichtserkennung mit selbstorganisierendem mehrkanaligem Matching-Verfahren*, Universität Stuttgart, Dissertation, 1996
- [Hab95] HABERÄCKER, Peter: *Praxis der Digitalen Bildverarbeitung und Mustererkennung*. Carl Hanser Verlag München Wien, 1995. – ISBN 3-446-155171
- [Hof] HOFMANN, Markus: *Grundsätzliche Untersuchungen von Bildverarbeitungs-algorithmen zur Gesichtserkennung*, Fachhochschule Regensburg, Diplomarbeit. – <http://www.markus-hofmann.de/>, verfügbar am 02.04.2004
- [Jäh02] JÄHNE, Bernd: *Digitale Bildverarbeitung*. 5., überarbeitete und erweiterte Auflage. Springer-Verlag Berlin Heidelberg, 2002. – ISBN 3-540-41260-3

- [Kos97] KOSCHAN, Andreas: Analyse von Glanzlichtern in Farbbildern. In: D.PAULUS (Hrsg.) ; T.WAGNER (Hrsg.): *3. Workshop Farbbildverarbeitung*, 1997
- [Kun02] KUNZ, Dietmar: *Digitale Bildverarbeitung* / Fachhochschule Köln. 2002. – Vorlesungsscript
- [Kun04] KUNZ, Dietmar: *Mathematik* / Fachhochschule Köln. 2004. – Vorlesungsscript
- [Küc00] KÜCHEL, Michael: *Optische Messtechnik 2* / Fachhochschule Aalen. 2000. – Vorlesungsscript
- [Mag02] MAGLOIRE, Lionel: *Grundlagen der Farbtechnik* / Fachhochschule Köln. 2002. – Begleitmaterial zur Vorlesung
- [MW02] MANSFIELD, A.J. ; WAYMAN, J.L.: *Best Practises in Testing and Reporting Performance of Biometric Devices* / Centre for Mathematics and Scientific Computing, National Physical Laboratory. Teddington, Middlesex, UK, August 2002 ( CMSC 14/02). – Forschungsbericht. – ISSN 1471–0005
- [o.V01] o.V.: *Shadow and glare detection in an image*. 2001. – U.S. Provisional Application No. 60/338,215
- [PS02] PETERMANN, Thomas ; SAUTER, Arnold: *Biometrische Identifikationssysteme* / Büro für Technikfolgen-Abschätzung beim Deutschen Bundestag. 2002 ( 76). – Sachstandsbericht
- [PTVF95] PRESS, William H. ; TEUKOLSKY, Saul A. ; VETTERLING, William T. ; FLANNERY, Brian P.: *Numerical Recipes in C*. Cambridge University Press, 1995
- [Sch95] SCHMID, Reiner ; SCHNEIDER, Wolfgang (Hrsg.): *Industrielle Bildverarbeitung*. Friedr. Vieweg und Sohn Verlagsgesellschaft mbH, 1995. – ISBN 3–528–04945–6
- [Sie04] SIETMANN, Richard: Teure Biometrie. In: *c't - Magazin für Computer und Technik* (2004), Juni, Nr. 13, S. 60–61
- [Sto02] STOLLENWERK, Franz: *Tontechnik* / Fachhochschule Köln. 2002. – Vorlesungsskript



- [TP91] TURK, Matthew ; PENTLAND, Alex: *Eigenfaces for Recognition* / Massachusetts Institute of Technology. 1991. – Forschungsbericht
- [VPS<sup>+</sup>02] VOGT, F. ; PAULUS, D. ; SCHOLZ, I. ; NIEMANN, H. ; SCHICK, C. H.: Glanzlichtsubstitution durch Lichtfelder. In: MEILER, M. (Hrsg.) ; HANDELS, H. (Hrsg.) ; F.KRUGGEL (Hrsg.) ; LEHMANN, T. (Hrsg.) ; D.SAUPE (Hrsg.): *6. Workshop Bildverarbeitung für die Medizin*. Leipzig : Springer Berlin,Heidelberg,New York, März 2002, S. 103–106
- [Wis95] WISKOTT, Laurenz: *Labeled Graphs and Dynamic Link Matching for Face Recognition and Scene Analysis*. Frankfurt am Main, Dissertation, 1995
- [YFS01] YON, Marcel ; VON FOERSTER, Michael ; SCHÄPERS, Kathrin: *Biometrie im Personalausweis* / ZN Vision Technologies (heute: Viisage Technology AG). 2001. – Forschungsbericht

## Abbildungsverzeichnis

1.1	Beispiel Bild I . . . . .	6
1.2	Beispiel Template t . . . . .	6
1.3	Beispiel eines Fourierspektrums . . . . .	8
1.4	Neuron . . . . .	9
1.5	Vektorprojektion . . . . .	11
1.6	Gesichtsmittelwert und eine Auswahl von Eigengesichtern . . . . .	15
1.7	Gaborfilter . . . . .	16
1.8	Beispiel Gesichtsgraph . . . . .	18
2.1	Einfluss des Glanzes auf die Ähnlichkeit . . . . .	25
3.1	Beispiel Ähnlichkeitsmatrix . . . . .	28
3.2	Beispiel FRR/FAR Kurve . . . . .	28
3.3	Unabhängigkeit zwischen Rang und EER . . . . .	30
4.1	Gesuchte Nachbarpixel . . . . .	34
4.2	Glanzkorrektur durch Interpolation . . . . .	35
4.3	Kantenproblem . . . . .	36
4.4	Glanzkorrektur durch Strukturinterpolation . . . . .	39
4.5	Glanzkorrektur mit Hilfe der Ausgleichsrechnung . . . . .	40
4.6	Ausgleichsversuche . . . . .	41
4.7	Abhängigkeit des Fehlers $r^2$ von der Menge der Eigenvektoren . . . . .	49
4.8	Glanzkorrektur mit Eigengesichtern . . . . .	51
4.9	Glanzkorrektur mit iterativem Verfahren . . . . .	54
5.1	Ergebnisse (Rang 1) Glanzkorrektur Datensatz 1 . . . . .	61
5.2	Ergebnisse (Rangstatistik) auf Datensatz 1 / Glanznummer 1 . . . . .	62
5.3	Ergebnisse Glanzkorrektur Datensatz 1 (EER) . . . . .	63
5.4	$\Delta$ Rang Datensatz 1 . . . . .	64
5.5	Ähnlichkeitsdifferenz Datensatz 1 . . . . .	65
5.6	$\Delta$ Rang Datensatz 2 . . . . .	66

5.7	Ergebnisse Glanzkorrektur Datensatz 2 (EER) . . . . .	67
5.8	Ähnlichkeitsdifferenz Datensatz 2 . . . . .	67
5.9	Ergebnisse (Rang 1) Glanzkorrektur Datensatz 2 . . . . .	68
5.10	Ergebnisse (Rangstatistik) auf Datensatz 2 / Glanznummer 1 . . . . .	69
5.11	Ergebnisse (Rangstatistik) auf wirklichen Daten (Datensatz 2) . . . . .	71
5.12	$\Delta$ Rang auf wirklichen Daten (Datensatz 2) . . . . .	72
5.13	Ähnlichkeitsdifferenz auf wirklichen Daten (Datensatz 2) . . . . .	73
5.14	Ähnlichkeitsdifferenz auf wirklichen Daten (Datensatz 3) . . . . .	73
5.15	Entfernung von Brillengestellen . . . . .	74
5.16	Entfernung von Pflastern . . . . .	75
5.17	Öffnung von Augen . . . . .	75
5.18	Probleme beim Öffnen von Augen . . . . .	76
B.1	Übersicht Korrekturbilder: Entfernung von Brillengestellen Teil 1 . . . . .	109
B.2	Übersicht Korrekturbilder: Entfernung von Brillengestellen Teil 2 . . . . .	110
B.3	Übersicht Korrekturbilder: Entfernung von Pflastern . . . . .	111
B.4	Übersicht Korrekturbilder: Öffnung von Augen . . . . .	112

## Tabellenverzeichnis

3.1	Ähnlichkeitsmatrix . . . . .	27
5.1	Ergebnisse des Versuchs zur Störungsverteilung . . . . .	57
A.1	Ergebnis Test Datensatz 1, Rang 1 (Teil 1) . . . . .	81
A.2	Ergebnis Test Datensatz 1, Rang 1 (Teil 1) . . . . .	82
A.3	Ergebnis Test Datensatz 1, EER (Teil 1) . . . . .	83
A.4	Ergebnis Test Datensatz 1, EER (Teil 1) . . . . .	84
A.5	Ergebnis Test Datensatz 1, FAR bei FRR=0 (Teil 1) . . . . .	85
A.6	Ergebnis Test Datensatz 1, FAR bei FRR=0 (Teil 1) . . . . .	86
A.7	Ergebnis Test Datensatz 1, Rangänderung (Teil 1) . . . . .	87
A.8	Ergebnis Test Datensatz 1, Rangänderung (Teil 1) . . . . .	88
A.9	Ergebnisse Test Datensatz 1 - Teil 2 . . . . .	89
A.10	Ergebnis Test Datensatz 2, Rang 1 (Teil 1) . . . . .	91
A.11	Ergebnis Test Datensatz 2, Rang 1 (Teil 1) . . . . .	92
A.12	Ergebnis Test Datensatz 2, EER (Teil 1) . . . . .	93
A.13	Ergebnis Test Datensatz 2, EER (Teil 1) . . . . .	94
A.14	Ergebnis Test Datensatz 2, FAR bei FRR=0 (Teil 1) . . . . .	95
A.15	Ergebnis Test Datensatz 2, FAR bei FRR=0 (Teil 1) . . . . .	96
A.16	Ergebnis Test Datensatz 2, Rangänderung (Teil 1) . . . . .	97
A.17	Ergebnis Test Datensatz 2, Rangänderung (Teil 1) . . . . .	98
A.18	Ergebnisse Test Datensatz 2 - Teil 2 . . . . .	99
A.19	Ergebnisse „verschiedene Messmethoden“ . . . . .	101
A.20	Ergebnisse „Abschätzung der Leistungsfähigkeit der Algorithmen“ . . . . .	102
A.21	Ergebnisse „Vergleich Ausgleichsrechnungs- und Eigenface-Korrektur“ . . . . .	103
A.22	Ergebnisse „transponierte Ähnlichkeitsmatrix“ . . . . .	104
A.23	Ergebnisse auf wirklichen Daten . . . . .	106
A.24	Ergebnisse auf wirklichen Daten: 150 gegen 28 Personen . . . . .	107

## Index

### A

Abstand der Pixel, 34  
Abtasttheorem, 34  
Ähnlichkeit  
    Similarity, 18  
    Similaritymatrix, 27  
Ausgleichsrechnung, 38

### B

Biometrie, 2  
biometrisches Merkmal, 2

### C

Client, 29  
Covarianz, 12  
    Covarianzmatrix, 12

### E

Eigengesicht  
    Basisvektor, 9  
Eigenvektor, 9  
    Abweichung vom Durchschnittsgesicht,  
        11  
    arithmetisches Mittel, 11  
    Bildung des Gesichtsvektorraum, 11  
    Covarianzmatrix, 12  
    Detektor, 22  
    Durchschnittsgesicht, 11  
    Orthogonalität, 14

Principal Component Analysis, 10

Rekonstruktionskoeffizienten, 14

Residuen, 22

equal error rate, 27

EER, 30

### F

false acceptance rate, 27

FAR, 29

false reject rate, 27

FRR, 29

Fill-In Methode, 32

### G

Gabor Wavelets, 14

Galerie, 26

Gallerist, 26

geometrische Merkmale, 6

Gesichtserkennungsverfahren, 5

Eigengesicht, 9

Fouriertransformation, 7

geometrische Merkmale, 6

Hierarchical Graph Matching, 14

Holistische Verfahren, 5

Merkmal basierte Verfahren, 5, 6

neuronale Netze, 7

Parametrisiertes Modell, 6

Template Matching, 5

- 
- Gesichtsvektorraum, Bildung des, 11  
Gewichtete Summe, 35  
Glanz, 20  
    Detektion, 20  
Glanzkorrekturalgorithmen, 32  
    Ausgleichsrechnung, 38  
    Eigengesichter, 47  
    Fill-In Methode, 32  
    Interpolation, 33  
    Strukturinterpolation, 37  
Graph Matching, 14
- H**
- Holistische Verfahren, 5  
HSV-Methode, 20  
HSV-Raum, 21  
    Transformationsgleichungen, 21
- I**
- Identifikation, 2  
Impostor, 29  
Interpolation, 33  
inverse Interpolation, 35  
Iteratives Verfahren, 53
- K**
- Kantenproblem, 36  
kleinster quadratischer Fehler, 42
- L**
- Lagrangesche Interpolation, 35  
Landmarken, 17  
Laplace Pyramide, 37  
Leuchtdichte, 37
- M**
- Merkmal basierte Verfahren, 5  
Messmethoden, 26  
Mosaicing, 36
- N**
- Neuron, 7  
Neuronale Netze, 7
- P**
- Parametrisiertes Modell, 6  
Principal Component Analysis, 10  
Probe, 26  
    Proband, 26  
Pseudoinverse, 43
- R**
- Rückwärtsinterpolation, 35  
Rangänderung,durchschnittliche, 31  
Rangstatistik, 26  
Redundanz, 46  
Residuen, 22  
Residuum, 45
- S**
- Similarity, 18  
Singular Value Decomposition, 44  
Standardmasken, 51  
Strukturinterpolation, 37
- T**
- Template Matching, 5  
    optimiertes , 7  
Trainingsmenge, 7, 11  
Transferfunktion, 7
- V**
- Validierungsmenge, 9  
Verifikation, 2  
Vertrauenskarte, 32
- Z**
- Zwei-Stufen-Methode, 21
-

### **Eidesstattliche Erklärung**

Ich versichere hiermit, die vorgelegte Arbeit in dem gemeldeten Zeitraum ohne fremde Hilfe verfasst und mich keiner anderen als der angegebenen Hilfsmittel und Quellen bedient zu haben.

Köln, den 21. Oktober 2004

Seedorfer, Jörg

### **Sperrvermerk**

Die Einsicht in die vorgelegte Arbeit ist bis zum 28. Oktober 2006 gesperrt.

### **Weitergabeerklärung**

Ich erkläre hiermit mein Einverständnis, dass das vorliegende Exemplar oder eine Kopie hiervon für wissenschaftliche Zwecke verwendet werden darf.

Köln, den 21. Oktober 2004

Seedorfer, Jörg