

JOHANNES KEPLER UNIVERSITÄT LINZ Netzwerk für Forschung, Lehre und Praxis



Personenidentifikation mittels Principal Component Analysis von Irisbildern

DIPLOMARBEIT

zur Erlangung des akademischen Grades

DIPLOMINGENIEUR

in der Studienrichtung

Informatik

Angefertigt am Institut für Computational Perception

Betreuung:

a. Univ.-Prof. Dr. Josef Scharinger

Eingereicht von:

Matthias Schmidl

Linz, 03/2005

Danksagung

Mein Dank ergeht an:

a. Univ. Prof. Dr. Josef Scharinger dafür, dass ich dieses Thema mit seiner Unterstützung bearbeiten durfte.

Meine Eltern.

Meine Korrekturleserin: OSTR. Mag. Evelyn Girtler

Alle Freiwilligen, die sich als Testpersonen zur Verfügung gestellt haben:

Elisabeth Baldauf, Lukas Baldauf, Martin Gotthartsleitner, Christian Hackl, Patrick Haruksteiner, Ingo Horejs, Eva Höritzauer, Thomas Köckerbauer, Clemens Kogler, Gabriel Kronberger, Dipl. Ing. (FH) Stefan Leitner, Sigrid Limberger, Gerald Lindinger, David Mitterhuber, Lukas Oberdammer, Dominik Punz, Mag. Claudia Schmidl, Dipl. Ing. Gunther Schmidl, Prim. Dr. Jörg Schmidl, Petra Thon, Christian Watzl, Norbert Watzl, Johannes Zarl.

Teile dieser Arbeit verwenden die CASIA Iris Bilder Datenbank, die vom Institute of Automation, Chinese Academy of Sciences zusammengestellt wurde.

Zusammenfassung

Biometrische Identifikation durch Vermessen der Iris ist ein erfolgreicher Ansatz zur biometrischen Identifikation, der derzeit faktisch nur über Extraktion von Merkmalen basierend auf Gabor-Wavelets realisiert wird (und in dieser Form durch existierende Patente abgedeckt ist). Marktbeherrschend sind Systeme die nach John Daugmans Methode des Iris Codes funktionieren¹.

Obwohl diese sehr gute Erkennungsraten bei gleichzeitig hoher Geschwindigkeit aufweisen, wäre ein System, das mit einem nicht patentierten Verfahren arbeitet als frei zugängliche Alternative interessant und wünschenswert. In dieser Arbeit soll also untersucht werden wie gut die Principal Component Analysis (PCA) als Alternative zur Merkmalsextraktion basierend auf Gabor Wavelets für solche Aufgaben genutzt werden kann.

Im Verlauf des Textes wird die Entwicklung eines biometrischen Systems, gegliedert in seine wichtigsten Einzelkomponenten - wie Techniken zur Bildaufnahme, Bildverbesserungsmaßnahmen, Segmentierung und Lokalisierung und schließlich die Principal Component Analysis - beschrieben und eine abschließende Bewertung gegeben.

¹"How Iris Recognition Works" by J. Daugman.

Abstract

Biometric identification based on iris measurements is a successful approach for biometric identification, which is, at the time, practically only accompished by means of feature extraction via Gabor-Wavelets (and in this form covered by existing patents). Dominating the market are systems using John Daugman's Iris Code².

Even though these systems combine high recognition rates with high recognition speed, a system not using patented technologies whould be interesting and desireable as a freely available alternative. This work examines inhowfar the Principal Component Analysis (PCA) is suitable as an alternative to feature extraction via Gabor Wavelets.

Throughout this work the design of a biometric system, divided into its most important components - like image acquisition, image emhancement, segmentation, localisation and finally the Principal Component Analysis is decribed and the performance evaluated.

²"How Iris Recognition Works" by J. Daugman.

Inhaltsverzeichnis

1	Einleitung 15			
	1.1	Biometrische Systeme	15	
	1.2	Die menschliche Iris	16	
	1.3	Iriserkennungssysteme	18	
	1.4	Aufgabenstellung	19	
2	Bilo	laufnahme	21	
	2.1	Überblick	21	
	2.2	Implementierung	21	
	2.3	Qualitätskriterien	22	
3	Vor	Vorverarbeitung 2		
	3.1	Überblick	25	
	3.2	Reflexionen entfernen	25	
	3.3	Medianfilter	27	
	3.4	Histogramm strecken	27	
	3.5	Kantenerkennung	28	
	3.6	Augenlider entfernen	29	
	3.7	Histogram Equalization	29	
4	Nor	rmalisierung	33	
	4.1	Überblick	33	
	4.2	Lokalisierung von Iris und Pupille	33	
	4.3	Circular Hough Transformation	34	
	4.4	Segmentierung	37	
5	Pri	ncipal Component Analysis	41	
	5.1	Überblick	41	
	5.2	Herleitung	43	
	5.3	Implementierung	46	
	5.4	Beispiel	47	

6	Klassifizierung516.1Überblick526.2Methoden zur Abstandsberechnung52					
7	Systembeschreibung 55 7.1 Überblick 55 7.2 Implementierung 55 7.3 Datenspeicherung 55					
8	Experimentelle Ergebnisse598.1Überblick598.2Maßzahlen zur Bewertung598.3Testdaten638.4Parametertests648.4.1Abmessungen des Irisstreifen668.4.2Abmessungen der Überdeckungen für Augenlider678.4.3Anzahl der Shifts688.4.4Anzahl der Shifts708.4.5Anzahl der verwendeten Eigenvektoren718.5Zusammenfassung72))) 				
9 A	Abschluss779.1Zusammenfassung779.2Erkenntnisse aus der Arbeit789.3Zukünftige Arbeit80Tabellen und Diagramme83	, ; ; ; ;				
Le Ei	benslauf 97 desstattliche Erklärung 99	,)				
n	101 101	-				

10

Abbildungsverzeichnis

1.1	Das menschliche Auge	17
2.1	Lims System zur Bildaufnahme $[\underline{\text{Lim01}}]$	22
3.1 3.2 3.3 3.4 3.5	Ablauf der Vorverarbeitung, Lokalisierung und SegmentierungHistogramm vor und nach StreckungErgebnis der KantendetektionIrisstreifen mit ausgeschnittenem BereichErgebniss der Histogramm Equalization	26 31 31 31 31
4.14.24.3	Parameterraum bei der Circular Hough Transformation [You04] Circular Hough Transformation unter Verwendung der Gra- dienten Information	35 36 38
5.1	Beispiel für Eigeniriden	43
6.1	Vergleich von euklidischer Distanz und Mahalanobis-Distanz .	52
7.1 7.2	Ein Überblick über die einzelnen Klassen des Iriserkennungs- systems und deren Abhängigkeiten Das Datenmodell zur Speicherung der Benutzerdaten	$56 \\ 57$
 8.1 8.2 8.3 8.4 8.5 8.6 8.7 	False Acceptance Rate und False Rejection RateEqual Error RateEinige Beispielbilder aus der CASIA DatenbankIntraclass-Verteilung ohne ShiftsIntraclass-Verteilung mit 2 ShiftsProzent der Gesamtvarianz, die durch die einzelnen Eigenvektoren erklärt wirdVerlauf von FAR und FRR bei verschiedenen Schwellwerten	61 63 65 69 69 71 74
A.1	Decidability bei einer groben Suche nach den besten Abmes- sungen des Irisstreifens, mit $x_{ul} = 6.25\%, y_{ul} = 59\%, x_{ol} = 20\%, y_{ol} = 95\%, n_s = 2, p_{EV} = 1, n_{eyes} = 1 \dots \dots \dots \dots$	84

ABBILDUNGSVERZEICHNIS

A.2	Decidability bei einer feinen Suche nach den besten Abmes-	
	sungen des Irisstreifens, mit $x_{ul} = 6.25\%, y_{ul} = 59\%, x_{ol} =$	
	$20\%, y_{ol} = 95\%, n_s = 2, p_{EV} = 1, n_{eyes} = 1 \dots \dots \dots$	85
A.3	Decidability bei einer groben Suche nach den optimalen Ab-	
	messungen der Überdeckungen für das untere Augenlid, mit	
	$x_{xs} = 340, y_{ys} = 170, x_{ol} = 20\%, y_{ol} = 95\%, n_s = 2, p_{EV} = 10\%$	0.0
	$1, n_{eyes} = 1 \qquad \dots \qquad$	86
A.4	Decidability bei einer feinen Suche nach den optimalen Ab-	
	messungen der Uberdeckungen für das untere Augenlid, mit	
	$x_{xs} = 340, y_{ys} = 170, x_{ol} = 20\%, y_{ol} = 95\%, n_s = 2, p_{EV} = 10\%$	07
	$1, n_{eyes} = 1 \qquad \dots \qquad$	87
A.5	Decidability bei einer groben Suche nach den optimalen Ab-	
	messungen der Überdeckungen für das obere Augenfid, mit $7607 \text{ m} = 7607 \text{ m} = 2 \text{ m}$	
	$x_{xs} = 540, y_{ys} = 110, x_{ul} = 170, y_{ul} = 1070, n_s = 2, p_{EV} = 1070, n_s = 1$	00
A G	$1, n_{eyes} = 1$	00
A.0	becidability bei einer leinen Suche hach den optimalen Ab-	
	messungen der Oberdeckungen für das obere Augenna, mit $m = -\frac{340}{2} u_{\pm} = -\frac{170}{2} u_{\pm} = -\frac{767}{2} u_{\pm} = -\frac{767}{2} u_{\pm} = -\frac{2}{2} n_{\pm} = -\frac{1}{2}$	
	$x_{xs} = 540, y_{ys} = 110, x_{ul} = 170, y_{ul} = 1070, n_s = 2, p_{EV} = 1, n_s = -1$	80
Δ 7	$1, n_{eyes} - 1$	09
1.1	ontimalen Parametersetzungen	۹N
Δ 8	Intraclass-Standardabweichung bei verschiedener Anzahl von	50
11.0	Shifts bei optimalen Parametersetzungen	90
AQ	Inter- und Intraclass-Verteilungen hei steigender Anzahl von	50
11.0	Augen fürs Enrollment und optimalen Parametersetzungen	92
	ragon rais Emonitorio and optimation ranamotoriseizungen	02

12

Tabellenverzeichnis

8.1	False Acceptance Rate und False Rejection Rate bei unter- schiedlichen Schwellwerten. (EER ist in Fettdruck gekenn- zeichnet.)	74
A.1	Decidability bei einer groben Suche nach den besten Abmes- sungen des Irisstreifens, mit $x_{ul} = 6.25\%, y_{ul} = 59\%, x_{ol} = 20\%, y_{ol} = 95\%, n_s = 2, p_{FV} = 1, n_{eves} = 1, \dots, \dots$	84
A.2	Decidability bei einer feinen Suche nach den besten Abmessungen des Irisstreifens, mit $x_{ul} = 6.25\%, y_{ul} = 59\%, x_{ol} = 20\%, u_l = 95\%, n_s = 2, n_{EV} = 1, n_{EV} = 1$	85
A.3	Decidability bei einer groben Suche nach den optimalen Ab- messungen der Überdeckungen für das untere Augenlid, mit $r_{\perp} = 340$ $u_{\perp} = 170$ $r_{\perp} = 20\%$ $u_{\perp} = 95\%$ $n_{\perp} = 2$ nm =	00
A.4	$x_{xs} = 545, g_{ys} = 110, x_{ol} = 2070, g_{ol} = 5570, n_s = 2, p_{EV} = 1, n_{eyes} = 1$ Decidability bei einer feinen Suche nach den optimalen Ab-	86
Λ 5	$x_{xs} = 340, y_{ys} = 170, x_{ol} = 20\%, y_{ol} = 95\%, n_s = 2, p_{EV} = 1, n_{eyes} = 1 \dots \dots$	87
A.0	messungen der Überdeckungen für das obere Augenlid, mit $x_{xs} = 340, y_{ys} = 170, x_{ul} = 7\%, y_{ul} = 76\%, n_s = 2, p_{EV} =$	0.0
A.6	1, $n_{eyes} = 1$ Decidability bei einer feinen Suche nach den optimalen Ab- messungen der Überdeckungen für das obere Augenlid, mit $x_{xs} = 340, y_{us} = 170, x_{ul} = 7\%, y_{ul} = 76\%, n_s = 2, p_{EV} =$	88
	$1, n_{eyes} = 1 \dots \dots$	89
A.7	Auswirkung von Shifts auf verschiedene Optimierungsmaß- zahlen bei optimalen Parametersetzungen	91
A.8	Anzahl der Augen für das Enrollment vs. verschiedene Opti- mierungsmaßzahlen bei optimalen Parametersetzungen	92
A.9	Prozent der erklärten Varianz vs. FRR und FAR bei optima-	0.2
	len Farametersetzungen	93

Kapitel 1

Einleitung

1.1 Biometrische Systeme

Traditionelle Systeme zur Identifikation von Personen beruhen entweder auf Besitz (Schlüssel, Ausweise, etc.) oder auf Wissen (Passwörter, PINs, etc.). Diese Methoden haben aber einige Probleme. Schlüssel können verloren gehen, Ausweise gefälscht werden. Passwörter und Zahlencodes können hingegen vergessen oder ausspioniert werden.

Im Gegensatz dazu ermöglicht es ein biometrisches System eine Person anhand eines biologischen Merkmals zu erkennen. Das Vergessen oder Verlieren scheidet, unter normalen Umständen, als Fehlerquelle praktisch aus. Auch wenn die Täuschung eines Systems durch Fälschungen natürlich nicht ausgeschlossen werden kann, können die meisten biometrischen Systeme mit einfachen Mitteln gegen Missbrauch gesichert werden. Biometrische Systeme bieten also eine einerseits komfortable und andererseits sichere Alternative zur herkömmlichen Identifikation.

Übliche Erkennungsmerkmale sind z.B: Fingerabdrücke, das Gesicht, das Venengeflecht der Retina, Unterschriften, die DNA, Handgeometrie, die Stimme oder die Iris. Es finden sich aber auch eher ungewöhnliche Merkmale wie die Gangart, der Geruch einer Person oder die Struktur ihrer Ohren.

Unabhängig davon, welches Merkmal gewählt wird, ist bei allen biometrischen Systemen der generelle Ablauf sehr ähnlich. Als erster Schritt muss das Merkmal in geeigneter Form aufgenommen werden. In vielen Fällen wird ein Bild des Merkmals aufgenommen, bei der Stimmerkennung würde ein kurzer gesprochener Text aufgenommen. Anschließend wird aus der Aufnahme ein biometrisches Template berechnet, welches das Merkmal in einer stark diskriminierenden, normalisierten und kompakten Art darstellt und es erlaubt das Merkmal objektiv mit anderen zu vergleichen. Üblicherweise arbeiten biometrische Systeme in zwei unterschiedlichen Modi. Einerseits existiert ein Enrollment Modus, in dem Personen neu in das System aufgenommen werden und andererseits ein Identifikationsmodus, in dem das aktuelle Template mit den bekannten, im System vorhanden, verglichen wird und so eine Identifikation stattfindet. Der offensichtlich wichtigste Entscheid beim Design eines biometrischen System ist die Wahl eines geeigneten Merkmals. Die wichtigsten Kriterien sind im nächsten Absatz zusammengefasst.

Ein gutes biometrisches Merkmal zeichnet sich durch verschiedene Eigenschaften aus. Es soll für unterschiedliche Personen sehr stark verschieden und einzigartig sein, sodass die Chance, dass zwei Personen die gleiche Ausprägung des Merkmals aufweisen, sehr klein ist. Es soll stabil bleiben, sich also im Verlauf der Zeit nicht wesentlich verändern. Weiters soll es nicht möglich sein das System mit einer Fälschung zu täuschen. Außerdem soll das Merkmal schnell und einfach aufgenommen werden können, damit die Erkennung nicht unangenehm für den Benutzer ist.

1.2 Die menschliche Iris

Der Augapfel wird von außen nach innen von der Lederhaut, der Aderhaut und der Netzhaut umgeben. Die Lederhaut geht an der Vorderseite des Auges in die durchsichtige Hornhaut über. In der Mitte des Auges, unter der Hornhaut, befindet sich die Iris (Regenbogenhaut). Sie liegt ringförmig auf der Linse des Auges auf und umschließt so die Pupille. In der Iris eingelagerte Pigmente geben dem Auge seine charakteristische Färbung. Durch feine Muskel kann die Größe der Iris und somit der Lichteinfall ins Auge geregelt werden, was die Hauptaufgabe der Iris darstellt [Lex93].

Die Pupille kann dabei zwischen 10% und 80% der Größe der Iris einnehmen [Dau02]. Abbildung 1.1 auf der nächsten Seite zeigt eine Frontansicht des menschlichen Auges und dessen für die Iriserkennung wichtigste Teile.

Bei näherer Betrachtung unterteilt sich die Iris in mehrere Schichten. Die unterste ist die Ephithel-Schicht und enthält dicht gepackte Pigmentzellen. Darüber liegt die stromale Schicht, die Blutgefäße, Pigmentzellen und die Muskel der Iris enthält. Bei jedem Menschen entwickeln sich diese Blutgefäße und Muskeln anders, was der Iris ihr einzigartiges Muster gibt. Die Dichte der Pigmentierung in dieser Schicht bestimmt die Farbe der Iris. So erscheinen zum Beispiel Augen, bei denen hier fast keine Pigmente eingelagert sind, blau.

Die oberste, nach außen sichtbare Schicht unterteilt sich in zwei Zonen, die sich teilweise in der Farbe unterscheiden. Die äußere cilliäre Zone und die innere pupilläre Zone, die von dem Collarette getrennt werden. Es ist als Zick-Zack-Muster in der Iris sichtbar.

Die Kombination aus den Blutgefäßen und Muskeln in der stromalen Schicht und der einzigartige Aufbau des Collarette bieten eine fast unendliche Viel-



Abbildung 1.1: Das menschliche Auge

falt an unterschiedlichen Mustern, die zur Unterscheidung von Personen herangezogen werden können [Wol76].

Die Iris hat einige Eigenschaften, die sie, unter den Gesichtspunkten für gute biometrische Merkmale am Ende des vorigen Kapitels, besonders geeignet für die Biometrie machen.

Die charakteristischen Muster sind bei der Geburt schon vorhanden, die Pigmentierung ist im Verlauf des ersten Lebensjahres abgeschlossen. Die Iris bleibt ab diesem Zeitpunkt das ganze Leben lang insofern stabil, als dass sie bis zum Erwachsenenalter nur mehr mit dem Auge mitwächst. Verletzungen am Auge sind eher selten, und es gibt auch keine Abnützungserscheinungen oder Verschmutzungen wie zum Beispiel bei Fingerabdrücken [Dau02].

Ein zweiter sehr wichtiger Punkt ist, dass die Muster der Iris nicht genetisch beeinflusst sind. Es handelt sich also um ein sogenanntes phänotypisches Merkmal, bei dem es keine genetische Durchdringung gibt [Wil97]. Anders als bei genotypischen Merkmalen, das sind Merkmale, die in Verbindung mit der genetischen Beschaffenheit stehen, sind auch bei Zwillingen die Irismuster gänzlich verschieden. Da ca. 1/100 aller Geburten Zwillingsgeburten sind, ergibt sich bei einem rein genotypischen Merkmal automatisch ein False Acceptance Rate $(FAR)^1$ von 1%. Das ist bei der Verwendung von Irismustern nicht der Fall. Es ergibt sich also eine enorme Vielfalt von stark verschiedenen Mustern. Angeblich liegt die Wahrscheinlichkeit für das Auftreten von zwei gleichen Iriden bei rund 1 zu 10⁷⁸ [Way02].

Was die Iris weiters geeignet für die Verwendung als biometrisches Merk-

 $^{{}^{1}\}text{FAR} = \text{Anteil}$ der Vergleiche bei der eine Person vom System fälschlich akzeptiert wird. Sie steht in umgekehrt proportionalem Verhältnis zur False Rejection Rate (FRR) die ausdrückt, wie viele Prozent der Personen fälschlich vom System abgewiesen werden.

mal macht, sind die relativ einfachen "Life Checks". Sie überprüfen, ob es sich bei dem präsentierten Objekt wirklich um die Iris bzw. das Auge eines lebendigen Menschen handelt. Es kann zum Beispiel das Auge kurz mit einem Lichtstrahl beleuchtet und dabei beobachtet werden, ob sich die Pupille verengt, oder mit einem kurzen Luftstoss das Auge zum Zwinkern angeregt werden.

Der letzte wichtige Punkt ist die einfache Merkmalsaufnahme. Mit sehr guten Kameras kann die Iris, obwohl durchschnittlich nur 12mm groß, trotzdem von einer Entfernung von bis zu 1m aufgenommen werden [Dau02]. Eher üblich sind allerdings Abstände von ca. 30cm, was im Allgemeinen von den Benutzern noch nicht als unangenehm nahe empfunden wird.

1.3 Iriserkennungssysteme

Im Vergleich zu anderen biometrischen Systemen wie Gesichterkennung, Fingerabdruck, Sprache, DNA Analyse wird die Iriserkennung als eine der zuverlässigsten Methoden betrachtet.

Biometrische Systeme zur Erkennung der Iris unterscheiden sich im Aufbau in den groben Einzelschritten nicht von anderen biometrischen Systemen. Es muss ein Bild der Iris aufgenommen werden. Dieses wird dann meist in verschiedenen Vorverarbeitungsschritten für die Lokalisierung und Segmentierung vorbereitet. Nachdem die Iris im Bild isoliert wurde, muss ein biometrisches Template berechnet werden, das dann, in einer Datenbank abgespeichert, zum Vergleich mit anderen Iriden herangezogen wird.

Generell unterscheiden sich die bekannten Systeme nur in der Art der Berechnung des Templates. Das erste gut funktionierende System wurde 1994 von John Daugman zum Patent angemeldet und ist heute das bekannteste und verbreitetste System zur Iriserkennung (siehe [Dau93], [Dau94] und [Dau02]). Daugman berechnet als biometrisches Template den sogenannten Iriscode, der sich über die Verwendung von Gabor-Wavelets berechnen lässt. Der Iriscode erlaubt sehr schnelle und äußerst zuverlässige Erkennung. Daugmans Patent gehört zur Zeit der Firma Iridian Technologies.

Trotz des großen Erfolgs von Daugmans System existieren noch verschiedene andere Systeme, die auch zum Teil unter Patentschutz stehen. Die wichtigsten sind wohl Wildes et al. [Wil97], Boles und Boashash [WB98], Lim et al. [Lim01] und Noh et al. [Noh02].

Wildes bedient sich einer isotropischen Bandpass Dekomposition, die aus der Anwendung von "Laplacian of Gaussian" Filtern abgeleitet wird. Boles und Boashash entwickelten eine Methode, "die die 1D normalisierte Iris Signaturen auf einigen verschiedenen Auflösungen zerlegt und mittels Zero-Crossing der dyadischen Wavelet Transformationen dieser Signaturen ein Template berechnet [Noh02]." Lims System arbeitet ebenfalls mit einem aus der Wavelettransformation berechneten Template. Noh verwendet die Multiresolution Independent Component Analysis M-ICA. Diese hätte den Vorteil, dass keine fixen Basisvektoren wie bei den verschiedenen Wavelet Transformationen verwendet werden, leider zeigen die experimentellen Ergebnisse der Forscher aber, dass zum Beispiel bei der Verwendung von Haar Wavelets eine besser Klassentrennung als bei der M-ICA erreicht werden kann.

1.4 Aufgabenstellung

Die Principal Component Analysis (PCA) wird zur Zeit erfolgreich im Bereich der Gesichtserkennung eingesetzt. Es handelt sich dabei, im Gegensatz zu den auf Wavelets basierenden Methoden, um ein statistisches, variabelorientiertes Verfahren. Mit Hilfe einer Linearkombination der Hauptkomponenten der Ausgangsdaten (Irisbilder) wird ein biometrisches Template erstellt. Dabei findet eine Dekorrelation der Ausgangsdaten sowie eine Datenreduktion statt. Näheres zur PCA ist Kapitel 5 zu entnehmen.

In dieser Arbeit soll untersucht werden, inwieweit sich die PCA für Zwecke der Iriserkennung einsetzen lässt. Kapitel 2 beschäftigt sich mit der hier verwendeten Technik zur Bildaufnahme. Kapitel 3 beschreibt die Vorverarbeitungsschritte, die für die Lokalisierung der Iris und Pupille nötig sind, und die bildverbessernden Maßnahmen, die das Bild für die Merkmalsextraktion vorbereiten. Kapitel 4 erklärt die Normalisierung und die damit verbundenen Methoden zur Lokalisierung und Segmentierung der Iris. In Kapitel 5 wird die Technik zur Merkmalsextraktion, die Principal Component Analysis, genau beschrieben. Kapitel 6 befasst sich mit Methoden zur Klassifizierung der einzelnen Iriden. Kapitel 7 gibt eine Systembeschreibung der für diese Arbeit verwendeten Software und Hardware. Kapitel 8 beschreibt die experimentellen Ergebnisse der Arbeit und Kapitel 9 fasst noch einmal die wesentlichen Erkenntnisse dieser Arbeit zusammen und liefert einen Ausblick auf mögliche Verbesserungen der hier beschriebenen Verfahren.

Kapitel 2

Bildaufnahme

2.1 Überblick

Für die Iriserkennung sind sehr gute Aufnahmen des Auges eine zwingende Voraussetzung, um gute Erkennungsergebnisse zu erreichen. Daher wurde bei der Literaturrecherche im Vorfeld dieser Arbeit ein besonderer Fokus auf die verschiedenen Bildaufnahmetechniken gelegt. Sowohl Daugman als auch Zhu et al. [Zhu99] und Tisse [Tis02] verwenden ein System, das Bilder im Nahe-Infrarot Bereich (750-960nm Wellenlänge) aufnimmt. Dies hat den Vorteil, dass die Muster sehr dunkler Augen auch ohne starke Beleuchtung gut sichtbar sind.

Wildes [Wil97] arbeitet mit Kombination von 8 Halogen-Lichtquellen, einem Diffusionsfilter, der für gleichmäßige Beleuchtung des Auges sorgt, und einem zirkulären Polarisationsfilter vor der Kamera, der die Lichtreflexionen auf der Augenoberfläche filtert.

2.2 Implementierung

Beide oben genannten Methoden ergeben nach Angaben der Autoren sehr gute Ergebnisse, sind aber leider zu teuer für einen Nachbau. Deshalb fiel die Wahl auf ein technisch einfacheres System.

Lim et al. [Lim01] stellten eine Methode zur Bildaufnahme vor, die trotz kleiner Abstriche in der Bildqualität, durchaus gute Bilder liefert und einfach im Aufbau ist. Im Abstand von 64cm werden 2 Halogen-Strahler gegenüberliegend montiert. In der Mitte werden Kamera und Auge in jeweils 10cm Abstand zum imaginären Schnittpunkt rechtwinklig in Position gebracht. Abbildung 2.1 auf der nächsten Seite zeigt schematisch den Aufbau.

Der Aufbau wurde mit zwei Änderungen übernommen. Zum einen dient



Abbildung 2.1: Lims System zur Bildaufnahme [Lim01]

zur Bildaufnahme eine gewöhnliche Digitalkamera¹ mit einer Auflösung von 2048×1536 Pixel. Die Iris wird so mit einem Durchmesser von ca. 250 Pixel aufgenommen. Das entspricht etwas 500 dpi und ist für die Iriserkennung durchaus ausreichend.

Die zweite Änderung betrifft die Helligkeit der Halogen-Strahler. Hier werden statt 50W nur 20W starke Strahler eingesetzt, da diese immer noch hell genug sind und den Benutzer weniger stark blenden.

Der Aufbau funktioniert prinzipiell gut, da auch dunkle Augen gut ausgeleuchtet werden, wobei allerdings auch auf einen Nachteil dieser Methode hingewiesen sein soll: Daugman und Wildes können durch geschickte Konfigurationen das Auge frontal beleuchten und so Reflexionen in der Zone der Iris vermeiden, ohne den Benutzer extrem zu blenden. Hier wird versucht dies zu vermeiden, indem die Lampen seitlich angeordnet sind. Dadurch ergibt sich allerdings zwangsweise eine Reflexion in den äußeren Randzonen der Iris, was einen kleinen Teil der Iris unbenutzbar für die Iriserkennung macht (siehe Abbildung 1.1 auf Seite 17).

2.3 Qualitätskriterien

Um ein so aufgenommenes Bild für die Iriserkennung geeignet zu machen, muss auf einige Qualitätskriterien geachtet werden. Um die Erkennungsgeschwindigkeit hoch zu halten, ist es günstig, dem System einen Bildausschnitt zu präsentieren, der nur mehr das Auge enthält. Es muss vor allem darauf geachtet werden, dass im Bild keine Unschärfe vorhanden ist. Es wurde beobachtet, dass unscharfe Bilder beim Erkennungsprozess quasi als

 $^{^1\}mathrm{Minolta}$ Dimage S304

universale Maske agieren und so zu vielen verschiedenen Irismustern passen.

Außerdem muss hier auf eine Einschränkung im Umgang mit dem System hingewiesen werden. Bei Systemen, die Daugmans Methode ähneln, ist ein pixelweiser Ausschluss der Regionen, die von Überdeckungen durch Augenlider betroffen sind, möglich. Das ist bei Verwendung der Principal Component Analysis (PCA) praktisch nicht möglich. Bei jeder Erkennung wäre beachtlicher Rechenaufwand nötig um die PCA neu für die eingeschränkte Region zu berechnen. Um dies zu erklären ist ein Vorgriff nötig, der sehr unscharf den Ablauf der PCA umreißt.

Alle vorhandenen Irismuster spannen einen n-dimensionalen Raum auf, wobei n der Anzahl der Bildpunkte entspricht. Die PCA berechnet aus den vorhandenen Irismustern eine "optimale" Basis für diesen Raum. Die Irismuster können dann als Linearkombinationen dieser Basisvektoren dargestellt werden. Im 3-dimensionalen Raum ist dieser Vorgang einfach zu veranschaulichen.

Für die Vektoren
$$\begin{pmatrix} 6\\1\\8 \end{pmatrix}, \begin{pmatrix} 1\\3\\3 \end{pmatrix}, \begin{pmatrix} 2\\5\\8 \end{pmatrix}$$
 ist $\begin{pmatrix} 1\\0\\0 \end{pmatrix}, \begin{pmatrix} 0\\1\\0 \end{pmatrix}, \begin{pmatrix} 0\\0\\1 \end{pmatrix}$ eine Basis

Basis.

Durch deren Linearkombination lässt sich jeder dieser Vektoren darstellen. Zum Beispiel:

$$6 \cdot \begin{pmatrix} 1\\0\\0 \end{pmatrix} + 1 \cdot \begin{pmatrix} 0\\1\\0 \end{pmatrix} + 8 \cdot \begin{pmatrix} 0\\0\\1 \end{pmatrix} = \begin{pmatrix} 6\\1\\8 \end{pmatrix}$$

Ebenso funktioniert die Linearkombination im *n*-dimensionalen Raum.

Würde man versuchen, die Überdeckungen durch Augenlider vom Vergleich auszunehmen, müsste für jeden Vergleich ein neuer (n - x)-dimensionaler Raum aufgestellt werden, wobei x der Anzahl der überdeckten Bildpunkte entspricht. Es müsste also bei jedem Vergleich die PCA völlig neu berechnet werden, was sehr rechenintensiv ist.

Deshalb ist es nur möglich, einen fixen Bereich in allen Bildern vom Vergleich auszunehmen, was zwar dazu führt, dass oft ein grösserer Teil als bei dem aktuellen Bild nötig wäre, ausgenommen wird; andererseits können bei Verwendung der PCA nur so gute Vergleiche ohne Einfluss der Augenlider durchgeführt werden.

Würde man die Verdeckungen einfach in den Vergleich miteinbeziehen, würden die Bilder mit großer Sicherheit nicht anhand der Irismuster einander zugewiesen, sondern anhand der Größe und Position der Verdeckungen, da diese mehr Unterscheidungspotential haben als die doch sehr feinen Muster der Iris.

Das Problem der zu grossen Überdeckungen kann gelindert werden, indem man fordert, dass beim Enrollment kaum Verdeckungen auftreten, sprich die Augen weit geöffnet werden. Es wurde zwar festgestellt, dass manche Testpersonen ihre Augen nicht so weit öffnen können, dass keine Verdeckungen mehr auftreten, aber kleine, überdeckte Bereiche stellen kein Hinderniss für die Erkennung dar.

Diese Qualitätskriterien zu überwachen, obliegt dem Benutzer des Systems, da im Unterschied zu anderen Systemen kein Schnittstelle zwischen Kamera und Computer (Framegrabber), die eine Echtzeitkontrolle der aufgezeichneten Bilder erlauben würde, eingesetzt werden konnte.

24

Kapitel 3

Vorverarbeitung

3.1 Überblick

Wird nun dem System ein Graustufenbild zugeführt, das den obigen Qualitätsansprüchen genügt, werden einige Schritte durchgeführt, die das Bild für die anschließende Lokalisierung der Pupille und der Iris und die Segmentierung vorbereiten.

Das Ergebnis der Segmentierung soll dann ein Bild sein, das nur mehr für die Merkmalsextraktion wichtige Daten enthält, also nur mehr die Iris. Die Schritte der Vorverarbeitung helfen dabei die Qualität der Lokalisierung der Pupille und Iris und somit auch der Segmentierung zu verbessern. Die folgenden Abschnitte beschreiben genauer, inwiefern die einzelnen Schritte unterstützend wirken. Abbildung 3.1 auf der nächsten Seite zeigt den Ablauf der Vorverarbeitung, Lokalisierung und Segmentierung, ausgehend vom Originalbild bis zum fertig segmentierten Endergebnis, dem sogenannten Irisstreifen, um das Zusammenwirken der Vorverarbeitungsschritte zu verdeutlichen.

3.2 Reflexionen entfernen

Wie schon erwähnt, ist in den bei der Bildaufnahme gewonnenen Augen immer eine kleine Reflexion des Halogen-Strahlers zu sehen (siehe Abildung 1.1 auf Seite 17). Für sie gilt dasselbe wie für die Verdeckungen durch die Lider. Es hätte keinen Sinn, diese aus dem zu vergleichenden Bild auszunehmen, da der Aufwand sie zu entfernen zu groß ist. Da sie aber, im Unterschied zu den Lidern, nur einen sehr kleinen Teil des Bildes ausmachen (ca. 1-2 Prozent), können die Relflexionen als Fehlerquelle toleriert werden. Damit diese sehr helle Stelle später nicht die Verbesserung des Kontrasts behindert, wird im ersten Schritt der Vorverarbeitung ein Schwellwert festgesetzt. Alle Pixel, deren Helligkeit grösser als dieser ist, werden auf einen Wert neutraler Helligkeit gesetzt.



Abbildung 3.1: Ablauf der Vorverarbeitung, Lokalisierung und Segmentierung

Das so gewonnene Bild - ohne störenden Einfluss von Reflexionen - wird dann einerseits als Ausgangspunkt für die weiteren Vorverarbeitungsschritte, die die Lokalisierung verbessern, eingesetzt, andererseits als Quelldatum für die anschliessende Segmentierung.

3.3 Medianfilter

Optimal für die Lokalisierung und Segmentierung ist ein Bild, das grosse, einheitliche Flächen aufweist, die sich stark voneinander unterschieden. So können die Zone der Pupille, der Iris und der Rest des Auges sicher unterschieden werden.

Der Medianfilter kann genau dies im Bild erreichen. Er arbeitet mit einer Filtermaske anpassbarer Grösse, die sozusagen über das Bild geschoben wird. Alle Pixel, die sich unter der Filtermaske befinden, werden nach Helligkeitswert geordnet, und der mittlerste Wert (Median) als neuer Helligkeitswert für das zentrale Pixel unter der Filtermaske ausgewählt.

Die Auswahl des Medians, gegenüber zum Beispiel der des arithmetischen Mittels, hat den Vorteil, dass diese Methode sehr ausreisserstabil ist. Wenn sich unter der Filtermaske viele Pixel gleicher Helligkeit befinden und einzelne sehr verschiedene, so haben diese keinen Einfluss auf den resultierenden Helligkeitswert.

So wird eine verlässliche Glättung des Bildes erreicht, da benachbarte Pixel meist die gleichen oder zumindest ähnliche Helligkeitswerte erhalten.

Obwohl der Medianfilter in der Berechnung aufwändiger ist als vergleichbare Filter zur Glättung, wie etwa der Mittelwertfilter oder der Blurfilter, sind die Ergebnisse der Glättung doch beachtlich besser, was den Mehraufwand rechtfertigt.

3.4 Histogramm strecken

Um nach der Glättung des Bildes den Kontrast zwischen den Regionen zu verbessern, wird das Histogramm¹ gestreckt. Ein Bild mit durchschnittlichem Kontrast nutzt typischerweise nicht die gesamte Breite des Histogramms aus. Um den Kontrast zu verbessern wird das Histogramm auf die gesamte mögliche Breite gestreckt. Es werden also alle Werte unter bzw. über einem bestimmten Wert auf den kleinsten bzw. größten Helligkeitswert gesetzt und die Werte zwischen den Grenzen auf die volle Breite des Histogramms gestreckt. Die Grenzen werden bei einem Prozentwert festgelegt,

¹Diagramm über die Helligkeitsverteilung im Bild

zum Beispiel die fünf dunkelsten Prozent, um einerseits stabil gegenüber Ausreissern zu sein und andererseits die Grenzen nicht bei einem fixen Helligkeitswert zu setzten, was den Erfolg der Kontrastverbesserung schmälern könnte.

Abbildung 3.2 auf Seite 31 zeigt ein Histogramm vor und nach der Streckung.

3.5 Kantenerkennung

An jeder Kante im Bild gibt es einen starken Anstieg oder Abfall der Helligkeit im Bild. Es gibt zwei Arten, wie solche Helligkeitssprünge erkannt werden können. Entweder mittels der Gradienten² oder der Laplace'schen Methode. Die Gradientenmethode sucht nach Extrema in der ersten Ableitung, die Laplace'sche Methode nach Nullstellen in der zweiten Ableitung. Die Methoden sind mathematisch gleichwertig. Interessant sind die Filtermasken, die verwendet werden um die erste bzw. zweite Ableitung zu approximieren. Grundsätzlich sind mehrere verschiedene Masken zur Gradientenberechnung einsetzbar: LaPlace, Kirsch, Prewitt, ...

Hier wird auf den Sobel Operator zurückgegriffen, der aus den folgenden zwei 3x3 Masken besteht:

-1	0	1	-1	0	1
-2	0	2	-2	0	2
-1	0	1	-1	0	1
Gx				Gy	

Eine schätzt den Gradienten in X-Richtung (gx), die andere in Y-Richtung (gy). Berechnet man den Betrag des Gradientenvektors (gx, gy), so erhält man die Länge des Vektors, der gleichzeitig auch der Stärke des Helligkeitssprunges im Bild entspricht.

Abbildung 3.3 auf Seite 31 zeigt ein Beispiel für eine Kantenerkennung.

Sowohl die Gradientenvektoren als auch die Länge des Vektors bieten wichtige Information und werden für die spätere Lokalisierung gespeichert.

Die Länge der Vektoren wird verwendet um bestehendes Rauschen im Bild zu unterdrücken. Es werden dabei zwei Techniken eingesetzt.

Erstens werden nur Vektoren mit einer Länge über einem Schwellwert gespeichert. Zweitens werden mittels Non-Maximum-Unterdrückung Vektoren

 $^{^{2}}$ Der Gradient ist eine Funktion, der die Änderungsrate und die Richtung des grössten Helligkeitsanstiegs oder -abfalls im Bild angibt. Der Gradientenvektor gibt zu einem Ursprungspunkt die Richtung und Grösse des stärksten Helligkeitsanstiegs oder -abfalls an.

gelöscht, die einen benachbarten Vektor haben, der länger ist als sie selbst. Man erreicht so eine Reduktion der Vektoren, da nur die längsten und somit aussagekräftigsten Vektoren in einer Nachbarschaft erhalten bleiben. So wird die Lokalisierung nicht nur präziser sondern auch schneller, da nicht mehr so viele Vektoren beachtet werden müssen.

Die Gradientenvektoren werden ebenfalls dazu verwendet, den Rechenaufwand der Lokalisierung zu senken, wie im folgenden Kapitel über die Circular Hough Transformation genau erklärt wird.

3.6 Augenlider entfernen

Um die für die Iriserkennung störenden Einflüsse der Augenlider auszuschalten, wird in dieser Phase der Vorverarbeitung ein fixer Bereich des Bildes entfernt. Praktisch wird dabei nicht wie bei anderen Systemen ein Teil des Bildes einheitlich eingefärbt, sondern die Datenstruktur, die den Irisstreifen enthält, um den Bereich der Überdeckung verkleinert. Das hat den Vorteil, dass der aufwändig zu berechnenden PCA weniger Daten zugeführt werden, was wiederum die Berechnung beschleunigt. Um möglichst wenig relevante Information zu verlieren, werden halbe Ellipsen verwendet um die Form der Augenlider möglichst genau nachzuempfinden. Die Form und Grösse des ausgeschnittenen Teiles des Bildes sind in Abbildung 3.4 auf Seite 31 schwarz gekennzeichnet.

3.7 Histogram Equalization

Obwohl im Effekt ähnlich der Histogrammstreckung, unterscheidet sich die Histogram Equalization doch im Prinzip davon. Die Histogram Equalization wird weniger dazu eingesetzt nur den Kontrast zu verbessern, sondern viel mehr dazu das Histogramm zu normalisieren. Es wird dabei versucht eine Gleichverteilung im Histogramm zu erreichen, sodass alle Helligkeitswerte gleich oft im Bild auftreten. Das ist besonders nützlich, wenn, wie hier, zwei oder mehrere Bilder verglichen werden sollen, die unter leicht variirenden Umständen aufgenommen wurden.

Scott Umbaugh [Umb99] beschreibt den Ablauf der Histogram Equalization an einem Beispiel wie folgt:

Grauwert	Anzahl der Pixel
0	10
1	8
2	9
3	2
4	14
5	1
6	5
7	2

- 1. Erstelle die laufende Summe des Histogramms. (Erster Wert = 10, Zweiter Wert = 10+8 = 18, usw. Hier ergibt sich 10, 18, 27, 29, 43, 44, 49, 51)
- 2. Normalisiere die Werte mittels Division durch die Gesamtsumme. $(\frac{10}{51}, \frac{18}{51}, \frac{27}{51}, \frac{29}{51}, \frac{43}{51}, \frac{44}{51}, \frac{49}{51}, \frac{51}{51})$
- 3. Multipliziere diese Werte mit dem hellstmöglichen Grauwert, in diesem Fall 7, und runde anschließend auf die nächste Ganzzahl. (1,2,4,4,6,6,7,7)
- 4. Ersetzte die originale Grauwertspalte im Histogramm durch die gerade errechneten Werte. (Alle Pixel die im originalen Bild den Grauwert 0 hatten, haben jetzt Wert 1, 1 wird zu 2, 2 zu 4, usw.)

Das so veränderte Histogramm ist zwar im Normalfall nicht flach, aber zumindest näher an einer Gleichverteilung als das Original. Um das Histogramm noch weiter zu glätten, können auch zufällig ausgewählte Pixel aus überbesetzten Histogrammwerten in benachbarte, unterbesetzte Regionen verschoben werden. Üblicherweise ist dies aber nicht nötig. Abbildung 3.5 auf der nächsten Seite zeigt das Ergebnis einer Histogramm Equalization an einem realen Bild.



Abbildung 3.2: Histogramm vor und nach Streckung



Abbildung 3.3: Ergebnis der Kantendetektion



Abbildung 3.4: Irisstreifen mit ausgeschnittenem Bereich



Abbildung 3.5: Ergebniss der Histogramm Equalization

Kapitel 4

Normalisierung

4.1 Überblick

Für den Vergleich zwischen den verschieden Iriden ist es wichtig, eine normierte Darstellung zu finden, in der diese möglichst ohne störende Einflüsse der Bildaufnahme verglichen werden können. Dazu wird die Bildvorverarbeitung durchgeführt.

Ausserdem sollen nur die Teile des Bildes verwendet werden, die wirklich Information beinhalten. So bieten zum Beispiel die Pupille und die Lederhaut keinerlei biometrische Information und sollten somit beim Verleich auch nicht berücksichtigt werden. Dazu ist es nötig die Iris in geeigneter Form aus dem Bild zu extrahieren. Beim Prozess der Segmentierung kann die Iris auch in ein einheitliches Format gebracht werden, was den späteren Vergleich erleichtert.

4.2 Lokalisierung von Iris und Pupille

Um eine erfolgreiche Segmentierung der Iris vom Rest des Auges durchführen zu können, ist eine präzise Lokalisierung von Iris und Pupille Voraussetzung. Beide können als Kreise angenähert werden, es kann allerdings nicht angenommen werden, dass diese konzentrisch sind. Oft liegt die Pupille etwas nach unten und zur Nase hin verschoben, was es notwendig macht das Zentrum der Kreise für Iris und Pupille einzeln zu bestimmen [Dau02]. Wie aus Abbildung 3.1 auf Seite 26 zu ersehen ist, sind einige Vorverarbeitungsschritte, auf die im vorhergehenden Kapitel genau eingegangen wird, nötig um die Qualität der Lokalisierung zu verbessern.

Die Lokalisierung an sich wird mittels der Circular Hough Transformation erreicht.

4.3 Circular Hough Transformation

Die Hough-Transformation ist ein Standardalgorithmus, der in vielen Anwendungen zur Objekterkennung eingesetzt wird. Sie gehört zur Klasse der "Voting"-Techniken und wird dazu verwendet, die Parameter von Objekten in einem Bild zu bestimmen. Im Fall der Circular Hough Transformation (CHT) [You04] sind das der Radius und die Position eines Kreises.

Die Idee hinter der CHT ist es, einen Parameterraum aufzustellen, in dem die Erkennung einfacher ist als im originalen Bild. Die Koordinaten im Parameterraum entsprechen dann den Parametern für das gesuchte Objekt im Bild.

So würde bei der klassischen CHT ein dreidimensionaler Parameterraum aufgestellt werden, in dem die Achsen dem Radius und dem Mittelpunkt des Kreises, in X- und Y-Koordinaten, zugeordnet werden. Die Erkennung des Kreises reduziert sich dann auf ein Clustering Problem. (Durch diverse Optimierungen lässt sich der Aufwand noch weiter senken, wie später beschrieben wird.)

Allgemein lässt sich der Algorithmus in drei Schritten beschreiben:

- 1. Jeder Pixel im originalen Bild wird in eine Kurve oder eine Oberfläche, abhängig von der Anzahl der Parameter, transformiert. Diese Kurve bzw. Oberfläche im Parameterraum hat dieselben Parameter wie das gesuchte Objekt im Bild, mit dem Unterschied, dass im Parameterraum alle Parameter variabel sind. (Abbildung 4.1 auf der nächsten Seite gibt eine Vorstellung, wie so eine Oberfläche im Parameterraum für einen Pixel bei der Kreiserkennung aussieht. Sowohl der Radius als auch der Mittelpunkt eines Kreises auf dem der aktuelle Pixel liegen könnte, sind variabel. Es ergibt sich eine kegelartige Oberfläche.)
- 2. Der Parameterraum, der auch Akkumulator genannt wird, wird in Zellen eingeteilt und jede Zelle mit dem Wert Null belegt. Immer wenn ein Punkt auf der eben berechneten Kurve bzw. Oberfläche in eine der Zellen fällt, wird eine Stimme für diese Zelle abgegeben, also der Wert der Zelle um 1 erhöht. (Daher der Begriff Voting-Technik)
- 3. Die Zelle, die zum Schluss die meisten Stimmen erhalten hat, wird ausgewählt und ihre Koordinaten werden als Parameter für das gesuchte Objekt verwendet.

Die Hough-Transformation gilt als sehr stabil gegenüber Überdeckungen und Rauschen, was sie für den Einsatz bei der Lokalisierung von Iris und Pupille sehr geeignet macht. Durch die Augenlider können grosse Verdeckungen auftreten und die Muster der Iris führen, trotz aller Vorverarbeitungsschritte,



Abbildung 4.1: Parameterraum bei der Circular Hough Transformation [You04]

zu Rauschen im Bild. Beides verringert zwar die Qualität der Hough Transformation, macht die Lokalisierung aber nur in Extremfällen unmöglich.

Ein grosses Problem der Hough-Transformation ist aber, dass es sich um einen exhaustiven Ansatz handelt, der sehr viel Rechenzeit in Anspruch nimmt. Es werden hier deshalb verschiedene Techniken eingesetzt um den Aufwand zu senken.

Der erste Ansatz um den Aufwand deutlich zu senken, ist die Information aus den Gradientenvektoren, die bei der Kantenerkennung berechnet wurden, zu nutzen. Anhand Abbildung 4.2 auf der nächsten Seite soll erklärt, werden wie diese genutzt werden kann.

Abgebildet ist ein schematisches Abbild des Auges durch den inneren, grau ausgefüllten Kreis, der die Pupille symbolisiert und den umgebenden Kreis, der die Außengrenze der Iris darstellt. Die vier kleineren Kreise im linken Bild zeigen alle Stimmen, die für die vier Punkte in deren Zentren für einen fixen Radius abgegeben werden müssen. (Das Bild kann als eine Ebene in Abbildung 4.1 betrachtet werden.)

Alle Punkte auf den kleinen Kreise müssen also als mögliches Zentrum des eigentlich gesuchten Kreises betrachtet werden. Der Schnittpunkt der kleinen Kreise, der gleich dem Punkt mit den meisten Stimmen ist, ist der wahre Mittelpunkt des Kreises, auf dem die 4 eingezeichneten Punkte liegen.

Das rechte Bild zeigt die CHT unter Verwendung der Gradienteninformation. Da die Pupille immer dunkler als die Iris und die Iris immer dunkler als



Abbildung 4.2: Circular Hough Transformation unter Verwendung der Gradienteninformation

die umgebende Lederhaut ist und beide nahezu rund sind, kann man idealisiert annehmen, dass der Gradientenvektor an den umgebenden Kreisen immer zur Mitte der Pupille bzw. Iris zeigt.

Durch diverse Störungen im Bild kommt es zu leichten Abweichungen; wenn man allerdings mehrere Punkte in Richtung des Gradientenvektors mit ca. 3° Abweichung in beide Richtungen wählt, erlangt man schneller ein robusteres Ergebnis der CHT als mittels des konventionellen Schemas, da nicht mehr alle Punkte auf den kleinen Kreisen in das Voting mit einbezogen werden müssen, sondern nur mehr der Teil, der in Richtung des Gradientenabstiegs liegt.

Eine weitere Optimierung betrifft den dritten Schritt der Hough Transformation, das Wählen der Zelle mit den meisten Stimmen. Verwendet man, wie oben beschrieben, einen dreidimensionalen Raum als Parameterraum, so ist das Finden der zwei Kreise für Iris und Pupille nicht einfach. Es müssten mittels dreidimensionalem Clustering¹ die Zentroide² der zwei dichtesten Cluster gefunden werden, was eine nicht triviale Aufgabe ist, die viele Fehler ergeben kann.

Deshalb wird auf eine einfachere und bei weitem robustere Variante der Hough-Transformation zurückgegriffen. Wie in [You04] vorgeschlagen, wird anstatt eines dreidimensionalen Raumes nur ein zweidimensionaler Parameterraum verwendet. Dabei wird die Dimension des Radius eliminiert und alle Stimmen für alle Radien in einer einzigen Ebene vermerkt.

Es wurde beobachtet, dass es nicht einmal nötig ist, die Stimmen für alle

¹Eine Cluster ist eine Punktewolke im Raum, die als eine Einheit betrachtet werden kann. Clustering ist der Vorgang des Zusammenfassens von Clustern

²Das Zentrum eines Clusters
4.4. SEGMENTIERUNG

möglichen Radien zu beachten; es ist ausreichend, nur jeden dritten Radius an der Wahl teilnehmen zu lassen. Das bedeutet einen weiteren Geschwindigkeitzuwachs.

So können jetzt sehr einfach im zweidimensionalen Raum mittels Virtual Circle Validation sowohl die zwei Zentrumspixel als auch die Radien für die zwei gesuchten Kreise bestimmt werden.

Es werden die 10% der möglichen Mittelpunkte mit den meisten Stimmen ausgewählt und der Virtual Circle Validation [Lim01] zugeführt. Dabei werden, vom Mittelpunkt ausgehend, immer grösser werdende imaginäre Kreise über das Kantenbild (3.3 auf Seite 31) gelegt und man prüft, wieviele Pixel im Kantenbild mit den Pixeln auf dem Kreisumfang übereinstimmen. Die zwei Mittelpunkte, die, bei stark verschiedenen Radien, prozentual am besten mit den Kreisen im Kantenbild übereinstimmen, ergeben dann die Parameter für die gesuchten Kreise.

Sind nun die Mittelpunkte und Radien der Iris und der Pupille bekannt, so kann mit der Segmentierung begonnen werden.

4.4 Segmentierung

Um eine normierte Darstellung der Iris zu erhalten, die für die anschliessende Merkmalsextraktion verwendet werden kann, ist es wichtig eine Invarianz gegenüber Grösse und Orientierung des Auges im Bild zu erreichen. Durch den variierenden Abstand des Auges von der Kamera oder unterschiedliche Vergrösserungsfaktoren der Linse kann das Auge im Bild unterschiedlich gross abgebildet sein. Unterschiedliche Beleuchtungsverhältnisse führen dazu, dass die Pupille im Vergleich zur Iris unterschiedlich groß ist. Eine Neigung des Kopfes zur Seite lässt das Auge rotiert erscheinen. All diesen Störeinflüssen wird mittels der Segmentierung entgegengewirkt.

Wie aus Abbildung 3.1 auf Seite 26 entnommen werden kann, wird dafür auf das originale Bild des Auges ohne die Reflexionen der Beleuchtung zurückgegriffen. Alle anderen Vorverarbeitungsschritte bereiten das Bild nur auf die Lokalisierung von Iris und Pupille vor.

Zur Segmentierung wird, angelehnt an Daugman [Dau02] oder Lim [Lim01], eine homogene Rubber-Sheet Transformation durchgeführt. Ziel ist es das Ausgangsbild in ein polares Koordinatensystem konstanter Dimensionen $\phi \times r$ zu transformieren (siehe Abbildung 4.3 auf der nächsten Seite).

Dazu wird das Bild radial abgetastet und in das neue Koordinatensystem übertragen.

Zuerst muss der aktuelle Abstand (r') zwischen dem Rand der Iris und der



Abbildung 4.3: Rubber-Sheet Transformation

Pupille beim aktuellen Winkel berechnet werden. So kann nun ein Skalierungsfaktor $s = \frac{r'}{r}$ berechnet werden, der die aktuelle Schrittweite bei der Abtastung des Originalbildes angibt. Ausgehend vom Rand der Pupille $\begin{pmatrix} x_1 \\ y_1 \end{pmatrix}$ kann mittels der Geradengleichung $\begin{pmatrix} x_1 \\ y_1 \end{pmatrix} + s \cdot \begin{pmatrix} r_n \\ r_n \end{pmatrix}$ eine konstante Zahl von Pixel berechnet und so die Breite der Iris normiert werden. (Wobei n von $1 \dots r$, der fixen Breite der Iris, läuft).

Dieser Vorgang wird mit einer Schrittweite von 1° für alle Winkel wiederholt.

Als Ergebnis der Transformation entsteht ein rechteckiger Irisstreifen, der immer konstante Dimensionen von $\phi \times r$ Pixel hat. So können gleich 3 Störeinflüsse behoben werden. Wie schon erwähnt wurde, liegt einerseits die Iris nicht konzentrisch um die Pupille, andererseits ist die Pupille bei unterschiedlicher Beleuchtungsintensität unterschiedlich groß. Das führt dazu, dass der Abstand (r') zwischen Außenrand der Pupille und Iris variiert. Bei der Transformation wird dieser Abstand vereinheitlicht. Auch die unterschiedliche Größe des gesamten Auges durch unterschiedliche Distanzen bei der Aufnahme wird so ausgeglichen.

Die eventuelle Rotation des Auges durch eine Neigung des Kopfes zur Seite, und somit eine Verschiebung des Irisstreifens nach links oder rechts, wird erst beim Vergleich zwischen den Iriden ausgeglichen, indem die zu vergleichende Iris mehrmals leicht verschoben verglichen wird. Dieser Vorgang wird später im Text auch als Shifting bezeichnet.

Bevor nun die Normalisierung abgeschlossen ist, wird noch eine Histogram Equalization und das Entfernen der Augenlider, wie in Kapitel 3 beschieben,

38

4.4. SEGMENTIERUNG

durchgeführt, um den Einfluss unterschiedlicher Beleuchtung und der für die Iriserkennung störenden Augenlider möglichst auszugleichen.

Kapitel 5

Principal Component Analysis

5.1 Überblick

Die Principal Component Analysis (PCA) ist eine Faktoranalyse und somit eine Methode der multivarianten Verfahren in der Statistik zur Analyse von Datensätzen. Sie kann aber auch dazu eingesetzt werden, ein biometrisches Template zu berechnen, wie das folgende Kapitel erläutert. Die PCA wurde 1933 von Harold Hotelling [Hot33] basierend auf Arbeiten von Karl Pearson eingeführt, wird aber erst seit den siebziger Jahren häufiger benützt, da sie bei größeren Datenmengen sehr aufwändig in der Berechnung ist.

Ziel ist es, die Originalvariablen eines Datensatzes durch eine kleinere Anzahl "dahinter liegender" Variablen zu ersetzen. Es soll also die Information, die in einer Menge von unabhängigen Variablen enthalten ist, komprimiert werden.

Dazu wird eine lineare Transformation der ursprünglichen, teilweise korrelierten Variablen in eine neue Menge unkorrelierter Variablen, die Principal Components oder Hauptkomponenten, durchgeführt. Wenn ein Datensatz stark korrelierte Variablen enthält, sagen diese im Wesentlichen dasselbe aus und bieten keine neue Information.

Die Varianz ist ein Maß, mit dem man eine Korrelation zwischen Variablen festgestellen kann. Ist die Varianz klein, so sind die Werte der Variablen einander ähnlich. Stellt man so eine Korrelation zwischen zwei Variablen fest, kann man, da dabei nur wenig Information verloren geht, nur eine der stark korrelierten Variablen erhalten und die andere aus dem Datensatz streichen.

Es kann für jede Variable geprüft werden, wie viel der erklärten Varianz verloren geht, wenn diese Variable aus dem Datensatz gestrichen wird. Um

eine möglichst gute Datenreduktion zu erreichen versucht man, mit einer möglichst kleinen Zahl von neuen Variablen die maximale Varianz aufzuklären.

Bei der Durchführung der PCA geht man nach genau diesem Muster vor. Man versucht zuerst eine Dekorrelation der Daten zu erreichen; die neuen Variablen, die danach eine kleine Varianz haben, werden gestrichen.

Hilfreich zum Verständnis der Berechnung dieser neuen Variablen ist eine Veranschaulichung im dreidimensionalen Raum. Ausgegangen wird von einer Menge von Punkten im Raum. Wie schon in Abschnitt 2.3 auf Seite 23 an einem Beispiel gezeigt wurde, ist es durch Linearkombination von 3 zueinander orthogonal stehenden Basisvektoren (Principal Components) möglich, alle Punkte im Raum zu erreichen. Diese 3 Vektoren sind dadurch, dass sie orthogonal zueinander stehen gänzlich unkorreliert und sie klären 100% der Varianz auf.

Bei der Durchführung der PCA werden die Basisvektoren allerdings, nicht wie in diesem Beispiel, willkürlich festgelegt. Ausgehend von einer n-dimensionalen Punktewolke wird ein neues Koordinatensystem in die Punktwolke gelegt, wobei die Achsen sukzessive nach folgenden Regeln gewählt werden:

Die erste Achse wird so in die Punktewolke gelegt, dass die Varianz der Daten in diese Richtung maximal wird. Die folgenden Achsen werden so gewählt, dass sie erstens senkrecht auf die bisher gewählten Achsen stehen, und zweitens die verbleibende Varianz maximal erklären.

So ergeben sich im n-dimensionalen Raum n neue Achsen die alle orthogonal zueinander stehen. Die Gesamtvarianz der Daten ergibt sich aus der Summe der einzelnen Varianzen, die jede Achse erklärt. Wird nun durch die ersten p Achsen ein Großteil (95-99%) der Varianz abgedeckt, sind die Faktoren, die durch die neuen Achsen repräsentiert werden, ausreichend für die Darstellung der Originaldaten. Die übrigen Achsen können eliminiert werden, da sie fast keine zusätzliche Information bieten. Dabei ist zu erwähnen, dass diese Faktoren, in Bezug auf die in der Gesichtserkennung übliche Bezeichnung "Eigenface" hier wohl am besten "Eigeniris" genannt, inhaltlich nicht unmittelbar interpretierbar sind, wie das die ursprünglichen Achsen waren. (Abbildung 5.1 auf der nächsten Seite gibt eine Vorstellung, wie diese neuen Achsen aussehen).

Ordnet man die Achsen nach erklärter Varianz absteigend, lässt sich mittels der PCA eine gewissermassen optimale Datenreduktion finden. Die Daten können mit einer minimalen Anzahl von Koeffizienten, optimal in Bezug auf den mittleren quadratischen Fehler, dargestellt werden, da immer die unwichtigsten Achsen eliminiert werden. Es lässt sich also die beste Appro-



(a) Eigeniris hoher Ordnung





Abbildung 5.1: Beispiel für Eigeniriden

ximation bei der gleichzeitig besten Dekorrelation finden.

Wenn auf diese Weise eine neue Basis gefunden wurde, können die Daten, wie zuvor am Beispiel im dreidimensionalen Raum erklärt, in dieser neuen Basis dargestellt werden. Im Fall der Iriserkennung wird so das biometrische Template zum Vergleich von Iriden berechnet. Die Koeffizienten, die sich bei der Darstellung in der neuen Basis ergeben, bilden das biometrische Template.

Hier zeigt sich ein weiterer Vorteil bei der Verwendung der PCA zur Berechnung des biometrischen Templates: Es speichert keine sensitiven Personendaten. Alleine mit den Daten des Templates kann das originale Auge nicht rekonstruiert werden. Dazu müssen zusätzlich die Eigenvektoren bekannt sein. Der Verlust oder Diebstahl des Templates stellt an sich keine Gefährdung sensitiver Personendaten dar.

5.2 Herleitung

Dieser Abschnitt soll einen Einblick in die Funktionsweise der PCA geben und dabei helfen, den im folgenden Kapitel erklärten Ablauf der PCA besser zu verstehen. Die Herleitung wurde, mit kleinen Änderungen und Ergänzungen des Autors, aus [Cas98] entnommen.

Gesucht wird eine Basis u für einen Zufallsvektor $x \in \Re^n$, in diesem Fall ein Irisstreifen, dargestellt als eindimensionaler Vektor, sodass daraus mittels Linearkombination der m orthogonalen Basisvektoren eine Annäherung des Vektors wie folgt berechnet werden kann:

$$\hat{x} = y_1 u_1 + y_2 u_2 + \ldots + y_m u_m \tag{5.1}$$

wobei m < n und y_j der Koeffizient des Basisvektors u_j ist und sich aus dem inneren Produkt von x und u_j berechnet:

$$y_j = x^T u_j \tag{5.2}$$

Durch Aufstellen einer $k \times n$ Beobachtungsmatrix X (eine Sammlung aller dem System bekannten Irisstreifen), deren Reihen einzelne Beobachtungen x_k^T sind, können Gleichungen 5.1 auf der vorherigen Seite und 5.2 so ausgedrückt werden:

$$\hat{X} = Y U_m^T \tag{5.3}$$

$$Y_m = XU_m \tag{5.4}$$

wobei U_m eine $n \times m$ Matrix ist, deren Spalten eine unkorrelierte Basis für X darstellt, und Y_m eine $k \times m$ Matrix, deren Spalten die Koeffizienten für jeden Spaltenvektor in U_m sind.

Durch die Orthogonalität von U_m und die zusätzliche Bedingung, dass die Spalten von U_m den Betrag 1 haben, also $||U_j|| = 1$, folgt, dass:

$$U_m^T U_m = I_m \tag{5.5}$$

wobei I_m die $m \times m$ Einheitsmatrix ist.

Das Problem beim Berechnen einer PCA ist also, die Matrix U_m so aufzustellen, dass der Fehler ε , der bei der Approximation von x mit \hat{x} gemacht wird, minimal ist:

$$\varepsilon = x - \hat{x} = \sum_{j=m+1}^{n} y_j u_j \tag{5.6}$$

wobei ε die Darstellung aller unbenutzten Vektoren, und somit der Fehler bei der Approximation, ist. Der mittlere quadratische Fehler ξ ist ein geeignetes Maß, um den Fehler, der bei der Approximation gemacht wird, zu schätzen:

$$\xi = E[|\varepsilon|^2] = E[|x - \hat{x}|^2]$$
(5.7)

wobei der Erwartungswert E einer beliebigen Funktion, f(x), so definiert ist:

$$E[f(x)] = \int_{-\infty}^{\infty} f(x)p(x)dx$$
(5.8)

wobei p(x) die Wahrscheinlichkeitsdichtefunktion der Zufallsvariable x ist.

Weil der Erwartungswert linear ist und die Spalten von U_m orthogonal zu einander stehen, folgt dass:

$$\xi = E\left[\varepsilon^{T}\varepsilon\right] = E\left[\left(\left(\sum_{i=m+1}^{n} y_{i}u_{i}\right)^{T}\right)\left(\sum_{j=m+1}^{n} y_{j}u_{j}\right)\right] = \sum_{j=m+1}^{n} E[y_{j}^{2}] \quad (5.9)$$

woraus wiederum folgt:

$$E[y_j^2] = E[(u_j^T x)(x^T u_j)] = u_j^T E[xx^T]u_j = u_j^T \Lambda u_j$$
(5.10)

wobei Λ die Korrelationsmatrix von x ist.

Durch Einsetzen von Gleichung 5.10 in Gleichnung 5.9 erhält man das zu minimierende Maß $\xi:$

$$\xi = \sum_{j=m+1}^{n} u_j^T \Lambda u_j \tag{5.11}$$

Diese Minimierung kann man mit Hilfe einer multivarianten Differenzialgleichung unter Verwendung von Lagrange-Multiplikatoren λ_j berechnen, indem man die erste Ableitung des Erwartungswertes für den mittleren quatdratischen Fehler bezüglich der Basisvektoren u_j auf 0 setzt.

$$\frac{\partial}{\partial u_j}\xi = 2(\Lambda u_j - \lambda_j u_j) = 0 \qquad \text{mit } j = m + 1, \dots, n \qquad (5.12)$$

Es ist bekannt, dass die Lösungen für diese Gleichung den Eigenvektoren der Korrelationsmatrix Λ entsprechen.

Es ist außerdem interessant, dass die Korrelationsmatrix Λ und die Kovarianzmatrix C bei einem zentrierten Datensatz, das heißt, dass der Mittelwert jeder Zeile von den einzelnen Spaltenwerten von X abgezogen wurde, äquivalent sind. Um die Eigenwerte und Eigenvektoren zu berechnen, muss nur noch eine Eigenwertzerlegung der Kovarianzmatrix C berechnet werden.

Die Eigenvektoren mit den größten Eigenwerten entsprechen dann den Basisvektoren, in deren Richtung im Zufallsvektor X die Varianz maximal ist. Folglich entsprechen die Spalten der Matrix U den Eigenvektoren und der Fehler, der bei der Approximation gemacht wird, lässt sich durch die Summe der Eigenwerte a_j des unbenutzten Teils der Basis dargestellen:

$$\xi = \sum_{j=m+1}^{n} a_j \tag{5.13}$$

Die Minimierung vereinfacht sich also auf das Sortieren der Basisvektoren u_j nach Grösse der zugehörigen Eigenwerte. Die Spalten mit den kleinsten Eigenwerten treten im unbenutzten Teil der Basis U auf. Die Spalten von U_m , die für die Rekonstruktion verwendet werden, korrespondieren mit den m größten Eigenwerten.

5.3 Implementierung

Bei der Implementierung der PCA wird das Wissen aus der Herleitung benutzt um die Berechnung möglichst einfach zu machen. Durch das Zentrieren der Daten kann zur Berechnung der Eigenwerte anstatt der Korrelationsmatrix die Kovarianzmatrix verwendet werden. Durch eine weitere Vereinfachung, die im folgenden Text beschrieben ist, kann der Aufwand bei der Berechnung nochmals gesenkt werden.

- 1. Alle n dem System bekannten Irisstreifen x vom Format $a \times b$ werden in Vektoren vom Format $ab \times 1$ umgeformt und in einer neuen $ab \times n$ Matrix X zusammengefasst.
- 2. Um einen zentrierten Datensatz zu erhalten, was die folgenden Berechnungen vereinfacht, wird ein Durchschnittsvektor Ψ berechnet. Seine Elemente entsprechen den Mittelwerten der einzelnen Spalten der Matrix X.
- 3. Ψ wird jetzt von jeder einzelnen Spalte in X abgezogen und man erhält einen zentrierten Datensatz A im Format $ab \times n$.
- 4. Wie aus der Herleitung der PCA bekannt ist, kann zur Berechnung der Eigenwerte und Eigenvektoren die Kovarianzmatrix verwendet werden. Weil A zentriert ist, berechnet sich die $ab \times ab$ Kovarianzmatrix C sehr einfach aus $C = AA^{T}$.
- 5. In diesem Schritt wird die Eigenwertzerlegung von C berechnet, um die Eigenwerte und Eigenvektoren u_i zu erhalten. Da diese Berechnung in der Praxis sehr aufwändig ist, es muss als Teilschritt eine $ab \times ab$ Matrix diagonalisiert werden (im hier betrachteten System eine ca. 21100 × 21100 Matrix), wird auf eine weniger aufwändige Technik zurückgegriffen:
 - (a) Dazu wird die Matrix $A^T A$ $(n \times n)$ verwendet.
 - (b) Man berechnet nun die Eigenvektoren v_i von $A^T A$:

$$A^T A v_i = \mu_i v_i$$

(c) AA^T und A^TA stehen dabei in folgendem folgendem Verhältnis:

 $\begin{aligned} A^T A v_i &= \mu_i v_i \\ A A^T A v_i &= \mu_i A v_i \\ C A v_i &= \mu_i A v_i \\ C u_i &= \mu_i u_i \text{ wobei } u_i = A v_i \end{aligned}$

 AA^T und A^TA haben also die gleichen Eigenwerte und die Eigenvektoren stehen im Verhältnis $u_i=Av_i$

- (d) Dazu ist noch Folgendes anzumerken:
 - $A^T A$ hat bis zu ab (hier ca. 21100) Eigenwerte und Eigenvektoren
 - AA^T hat bis zu n (richtet sich nach der Anzahl der bekannten Personen) Eigenwerte und Eigenvektoren
 - Die n Eigenwerte von $A^T A$ und deren Eigenvektoren korrespondieren mit den n grössten Eigenwerten und Eigenvektoren von AA^T
- (e) Man berechnet jetzt also die m besten Eigenvektoren u_i von AA^T : $u_i = Av_i$ die die gewünschten 95-99% der Varianz erklären und normiert diese auf Länge 1 ($|u_i| = 1$).
- 6. Zur späteren Rekonstruktion der Daten speichert man nun den Durchschnittsvektor Ψ und die ersten *m* Eigenvektoren, welche die geforderte Varianz erklären.

Will man nun zur Klassifizierung eines bestimmten Irisstreifens \hat{x} das Template berechnen, so muss nur die aus der Herleitung bekannte Gleichung $\hat{x} = y \cdot U^T$ gelöst werden. Das entspricht einer Darstellung des Irisstreifens in der neu berechneten Basis. Der Koeffizientenvektor y mit nur mElementen wird als Template gespeichert und für den Vergleich der Iriden verwendet. Das Template ist sehr kompakt im Vergleich zum Ausgangsbild, ermöglicht aber gleichzeitig die beste Rekonstruktion in Bezug auf den mittleren quadratischen Fehler. Mit Hilfe des Templates ist es jetzt auch möglich die Iriden einfach mit einander zu vergleichen. Der Abstand zwischen zwei Templates gibt ein Maß für die Ähnlichkeit verschiedener Iriden. Der Abschnitt Klassifizierung beschäftigt sich mit der Berechnung dieses Abstands.

5.4 Beispiel

Das folgende Beispiel soll nochmals die Berechung des biometrischem Templates mittels der PCA zum Vergleich von Iriden erläutern. Aus Gründen der Übersichtlichkeit wurden für das Beispiel allerdings sehr viel kompaktere Datensätze verwendet. Man könnte sich für das Beispiel vorstellen, dass die Iriden nur anhand von 7 Merkmalen voneinander unterschieden werden, nicht wie in der Realität an den ca. 21100 Pixeln des Abbildes der Iris, und dass dem System nur 5 Iriden bekannt sind.

1. In der Matrix X sind also diese 5 Iriden mit ihren 7 Merkmalen zusammengefasst, die als Ausgangspunkt für die Berechnung der PCA dient.

$$X = \begin{pmatrix} 2 & 5 & 3 & 4 & 1 \\ 2 & 7 & 3 & 5 & 3 \\ 5 & 3 & 4 & 8 & 5 \\ 3 & 9 & 3 & 2 & 3 \\ 8 & 5 & 6 & 9 & 7 \\ 3 & 4 & 3 & 2 & 3 \\ 5 & 3 & 5 & 2 & 5 \end{pmatrix}$$

2. Der Durchschnittsvektor Ψ lautet:

$$\Psi = \begin{pmatrix} 3\\4\\5\\4\\7\\3\\4 \end{pmatrix}$$

3. Durch spaltenweise Subtraktion des Durchschnittsvektors Ψ von X erhält man den zentrierten Datensatz A.

$$A = \begin{pmatrix} -1 & 2 & 0 & 1 & -2 \\ -2 & 3 & -1 & 1 & -1 \\ 0 & -2 & -1 & 3 & 0 \\ -1 & 5 & -1 & -2 & -1 \\ 1 & -2 & -1 & 2 & 0 \\ 0 & 1 & 0 & -1 & 0 \\ 1 & -1 & 1 & -2 & 1 \end{pmatrix}$$

5.4. BEISPIEL

4. Die Multiplikation $A^T A$ ergibt die "kleine" Kovarianzmatrix C.

$$C = AA^{T} = \begin{pmatrix} 8 & -16 & 3 & -1 & 6 \\ -16 & 48 & -5 & -14 & -13 \\ 3 & -5 & 5 & -6 & 3 \\ -1 & -14 & -6 & 24 & -3 \\ 6 & -13 & 3 & -3 & 7 \end{pmatrix}$$

5. Durch die Eigenwertzerlegung ergibt sich folgende Eigenwert- und Eigenvektormatrix:

$$\mu = \begin{pmatrix} 61.6314 & 0. & 0. & 0. & 0. \\ 0. & 26.5245 & 0. & 0. & 0. \\ 0. & 0. & 2.48281 & 0. & 0. \\ 0. & 0. & 0. & 1.36126 & 0. \\ 0. & 0. & 0. & 0. & 0. \end{pmatrix}$$

$$V = \begin{pmatrix} -0.287117 & -0.269915 & 0.312182 & -0.739765 & 0.447214 \\ 0.880605 & 0.0785941 & 0.12731 & -0.0463752 & 0.447214 \\ -0.0743944 & -0.334657 & -0.822786 & 0.0741182 & 0.447214 \\ -0.289844 & 0.84206 & -0.0690256 & 0.0464827 & 0.447214 \\ -0.229249 & -0.316083 & 0.45232 & 0.665539 & 0.447214 \end{pmatrix}$$

6. Durch Multiplikation $A \cdot V$ und Normierung der einzelnen Vektoren auf Länge 1 erhält man die eigentlich gesuchten Eigenvektoren U. Wie man aber anhand der Eigenwerte sieht, sind die ersten 4 Vektoren ausreichend, um die Varianz zu 100% erklären. Zur Berechung des biometrischen Templates t_x werden also nur die ersten 4 Vektoren U'verwendet.

$$U' = \begin{pmatrix} -0.282398 & 0.369176 & 0.65446 & -0.546469 \\ -0.411416 & 0.440452 & -0.0374477 & 0.554739 \\ 0.325626 & 0.524961 & -0.229163 & 0.13549 \\ -0.709945 & -0.0719381 & -0.528583 & -0.278329 \\ 0.325278 & 0.309051 & -0.471092 & -0.538401 \\ -0.149091 & -0.14824 & -0.124603 & -0.0795883 \\ 0.113581 & -0.521023 & 0.0301725 & -0.0400245 \end{pmatrix}$$

7. Für den ersten Vektor x_1 in X ergibt sich als Template zum Beispiel:

$$t_1 = x_1 \cdot U' = (0.833527, 3.45082, -5.48922, -4.88709)$$

Aus den 4 Werte des Templates t_1 kann x_1 durch Multiplikation von t_1 mit u'^T rekonstruiert werden. Ausserdem dient es wie schon erwähnt zum Vergleich der verschieden Iriden.

Kapitel 6

Klassifizierung

6.1 Überblick

Der Begriff der Klassifizierung beschreibt allgemein den Vorgang des Einteilens einer Menge in einzelne, voneinander verschiedene Klassen, anhand bestimmter diskriminierender Merkmale. In diesem Fall ist das Ziel der Klassifizierung eine Zuteilung einer Iris zu genau einem Benutzer. Als Merkmal zur Unterscheidung der verschiedenen Iriden wird dabei das zuvor berechnete biometrische Template herangezogen.

Für jeden Benutzer, der vom System erkannt werden soll, muss natürlich ein bekanntes Template vorliegen, das dem System beim Enrollment-Prozess, der Neuaufnahme eines Benutzers, präsentiert wurde. Ein solches Template ist nichts anderes als ein hochdimensionaler Vektor. Um zwei Iriden zu vergleichen, muss nur der Abstand ihrer Templatevektoren berechnet werden. Um eine Klassifizierung einer unbekannten Iris durchzuführen, wird angenommen, dass die Templates mit dem absolut kleinsten Abstand am ehesten der gleichen Iris entsprechen, und so eine Zuordnung vorgenommen.

6.2 Methoden zur Abstandsberechnung

Zur Berechnung des Abstandes zwischen den Templates sind verschiedene Ansätze denkbar. Vorerst soll die Mahalanobis-Distanz besprochen werden, da diese, vom theoretischen Standpunkt betrachtet, sehr gute Ergebnisse bei der Unterscheidung ermöglicht. Bei einer praktischen Betrachtung stellt sich allerdings heraus, dass sie zu rechenaufwändig ist, um zur Klassifizierung eingesetzt zu werden. Deshalb wird im System der euklidische Abstand (6.1 auf der nächsten Seite), der sehr einfach und schnell zu berechnen ist, verwendet.



Abbildung 6.1: Vergleich von euklidischer Distanz und Mahalanobis-Distanz

$$d_E(x_1, \dots, x_n, y_1, \dots, y_n) = \frac{1}{n} \sqrt{\sum_{i=0}^n (x_i - y_i)^2}$$
(6.1)

Trotzdem sollen Berechnung und Einsatz der Mahalanobis-Distanz erklärt werden, da diese einen sehr interessanten theoretischen Vorteil gegenüber dem euklidischen Abstand hat. Da es sich bei der Menge der verschiedenen Templates nicht um eine willkürliche Verteilung handelt, lässt sich mit Hilfe der Statistik die Berechnung des Abstandes verfeinern.

Die Mahalanobis-Distanz [Rob04] ist sehr gut dazu geeignet, den Abstand einer Menge von bekannten Werten von einem unbekannten Wert zu berechnen. Sie berücksichtigt bei der Berechnung des Abstandes, anders als der euklidische Abstand, die statistische Verteilung der Werte und bezieht Mittelwert, Varianz und Kovarianz in die Berechnung mit ein. Das Ergebnis ist ein dimensionsloses Maß, das frei von Korrelation zwischen den Templates ist.

Um diese Eigenschaft zu erklären, hilft Abbildung 6.1.

Aus der Formel zur Berechnung der euklidischen Distanz folgt, dass alle Punkte, die den gleichen Abstand von einem Punkt haben, auf einem Sphäriod, im zweidimensionalen Fall einem Kreis, liegen. Wie man im linken Teil der Abbildung 6.1 sieht, wäre mit Hilfe der euklidischen Distanz nicht entscheidbar, welcher der zwei Punkte vom Zentrum der Punktewolke aus gemessen besser zu der Klasse, die von dieser Punktewolke gebildet wird, passt. Es wäre also von Vorteil, die Achsen mit hoher Varianz weniger stark zu gewichten als die Achsen, auf denen die Varianz eher klein ist. Wenn man die Achsen mit deren jeweiliger Varianz gewichtet, ergibt sich anstatt eines Sphäroids ein Ellipsoid, auf dem alle Punkte gleich weit vom Zentrum entfernt sind. Dies ist im rechten Teil der Abbildung 6.1 auf der vorherigen Seite veranschaulicht. Durch die Neugewichtung der Achsen gelten alle Punkt auf der Ellipse als gleich weit vom Zentrum entfernt, Punkt x_2 ist also eindeutig näher als Punkt x_1 .

Die Formel für die Mahalabobis-Distanz 6.2 beinhaltet genau die soeben angesprochene Neugewichtung der Achsen durch die Multiplikation mit der invertierten Kovarianzmatrix.

$$d_t(x) = \sqrt{(x - m_t)^T S_t^{-1}(x - m_t)}$$
(6.2)

 d_t ist die Mahalanobis-Distanz.

 S_t ist die Kovarianzmatrix der Gruppe von bekannten Templates.

 m_t ist ein Vektor der Mittelwerte der Koeffizienten der bekannten Templates.

x ist der Vektor der Koeffizienten des unbekannten Templates.

Bei der Berechnung des Abstandes zwischen den Templates wird die Mahalanobis Distanz sehr ähnlich zum gerade angeführten Beispiel genutzt. Im Beispiel soll festgestellt werden, ob Punkte zu einer Klasse gehören; es wird also nur die Verteilung der einen Klasse berücksichtigt.

Für die Berechnung des Abstandes der einzelnen Templates, will man die Beziehungen der einzelnen Klassen zueinander berücksichtigen und benützt daher die Daten aller Klassen. Durch die Neugewichtung der Achsen erreicht man eine deutlichere Trennung der Klassen und kann somit ein unbekanntes Template besser einer Klasse zuordnen.

Bei Testläufen mit kleinen Datensätzen stellte sich heraus, dass die Mahalanobis-Distanz bessere Erkennungsleistungen zulässt als der euklidsche Abstand, ein großes Problem ergibt sich allerdings daraus, dass bei jeder Berechnung der Mahalanobis-Distanz alle vorhandenen Templates in die Berechnung miteinbezogen werden müssen. Bei grösseren Datensätzen wird die Berechnung daher sehr rechenintensiv und eine Klassifizierung ist nicht in angemessener Zeit möglich.

Kapitel 7

Systembeschreibung

7.1 Überblick

Das Iriserkennungssystem wurde in Java Version 1.5.0-b64 implementiert und verwendet die Java Advanced Imaging Library in der Version 1.1.2. Zur Benutzerverwaltung wird eine MySQL Datenbank Version 4.0.20d verwendet. Außerdem wurden Teile des Public Domain Projektes JAMA zur Berechnung der Eigenwertzerlegung verwendet.

Alle Berechnungen wurden auf einem Intel Centrino 1500MHz, 512MB RAM und einem AMD Athlon XP3000+ 2167MHz, 1024MB RAM durchgeführt.

Zur statistischen Auswertung wurde Microsoft Excel 2000 verwendet.

7.2 Implementierung

Das System teilt sich in mehrere logisch getrennte Klassen (siehe Abbildung 7.1 auf der nächsten Seite). Die Klasse UserHandling enthält Methoden zum Enrollment und zum Matching von Personen und benutzt alle weiteren Klassen. Die Klasse Imaging enthält alle Methoden, welche die Bildvorverarbeitungsschritte aus Kapitel 2 umfassen. Detection dient der Lokalisierung und Segmentierung. MatrixMath enthält alle Methoden zur Durchführung der PCA und zur Abstandsberechnung und benutzt dabei die Methoden der Klasse EigenvalueDecomposition. DBconn dient der Speicherung der Daten in Datenbank und auf Festplatte.

7.3 Datenspeicherung

Die Daten, die für das Enrollment und das Erkennen von Personen wichtig sind, werden je nach Zugriffshäufigkeit und Speicherplatzbedarf entweder auf Festplatte oder in der MySQL-Datenbank gespeichert.



Abbildung 7.1: Ein Überblick über die einzelnen Klassen des Iriserkennungssystems und deren Abhängigkeiten



Abbildung 7.2: Das Datenmodell zur Speicherung der Benutzerdaten

Abbildung 7.2 zeigt die Daten, die in der Datenbank gespeichert werden. Für jeden Benutzer wird eine ID vergeben, der Name und, um Verwechslungen vorzubeugen, der Geburtstag gespeichert. Eine zweite Tabelle verwaltet die Irisstreifen, mit denen die Benutzer enrollt wurden. Auch sie erhalten eine ID. Über einen Fremdschlüssel werden die Irisstreifen mit den Benutzern assoziiert. In der Spalte für die Beschreibung kann zum Beispiel festgehalten werden, ob es sich um das linke oder das rechte Auge handelt, falls beide Augen überprüft werden sollen. Die "inserted" Spalte hält fest, wann das betreffende Auge registriert wurde. Auf Wunsch können so die Bilder periodisch aktualisiert werden, auch wenn das vom biologischen Standpunkt her nicht nötig wäre. Über die ID des Irisstreifens ist das zugehörige Template wieder auffindbar.

Das Template und der fertig vorverarbeitete Irisstreifen, für eine eventuelle Neuberechnung der PCA, werden binär auf Festplatte gespeichert, da der Zugriff auf die Festplatte bedeutend schneller ist als der auf die Datenbank.

Schliesslich müssen noch alle Daten gespeichert werden, die für das Matching gebraucht werden. Das sind die Eigenvektoren und der Durchschnittsvektor der bisher bekannten Benutzer. Diese werden ebenfalls auf der Festplatte gespeichert.

Kapitel 8

Experimentelle Ergebnisse

8.1 Überblick

In diesem Kapitel wird die Gesamtleistung des hier präsentierten Systems untersucht. Um später bestätigen zu können, dass die Iris einzigartig und ein geeignetes Maß zur Unterscheidung von Personen ist, wird das Konzept der False Acceptance Rate (FAR) und der False Rejection Rate (FRR) erklärt. Mit Hilfe einer vom Institute of Automation der Chinese Academy of Sciences [oSIoA05] gesammelten Irisdatenbank werden in verschieden Testläufen die optimalen Parametersetzungen gesucht, um die beste Erkennungsleistung des Systems zu finden. Dazu gehören die Anzahl der Verschiebungen in jede Richtung um eine eventuelle Drehung des Auges auszugleichen, die Größe der Regionen, die ausgeschnitten werden, um den Störeinfluss der Augenlider zu beseitigen, die Anzahl der Templates, die zum Enrollment benützt werden und die Größe des Irisstreifens, also der Auflösung bei der Erstellung des Irisstreifens.

8.2 Maßzahlen zur Bewertung

Bei jeder Messung biometrischer Daten herrschen leicht unterschiedliche Bedingungen. Beleuchtungseinflüsse, Kameraoptik und der Benutzer selbst beeinflussen die Erfassung des biometrischen Merkmals. Das führt dazu, dass auch Aufnahmen desselben Merkmales nie genau gleich erscheinen. Es besteht also auch beim Vergleich zweier Aufnahmen der gleichen Iris ein Abstand zwischen den berechneten Templates. Dieser wird der Intraclass-Abstand genannt. Im Unterschied dazu gibt es den Interclass-Abstand, der beim Vergleich von zwei verschiedenen Iriden autritt.

Aufgabe jedes Iriserkennungssystems ist es eine klare Trennung zwischen diesen zwei Verteilungen herzustellen. Wenn eine Trennung besteht, kann ein Schwellwert (Grenzabstand) gewählt werden, der eine genaue Entscheidung zulässt, ob ein Template der einen oder der anderen Verteilung angehört, wenn zwei Templates verglichen werden. Wenn der Abstand zwischen zwei Templates kleiner ist als der Schwellwert, stammen die beiden Templates von der gleichen Quelle. Liegt der Abstand über dem Grenzwert, so stammen die Templates von verschiedenen Augen.

Um messen zu können, wie gut die Trennung zwischen der Interclass-Verteilung und der Intraclass-Verteilung und damit die Leistung des Iriserkennungssystems ist, muss eine geeignete Metrik gefunden werden. Denkbar wäre es einfach den Abstand zwischen maximaler Interclass-Distanz und maximaler Intraclass-Distanz zu messen, dieses Maß wäre allerdings zu empfindlich gegenüber Ausreißern.

Besser eignet sich dazu die Decidability [Dau02], die wie folgt definiert ist:

$$d = \frac{|\mu_1 - \mu_2|}{\sqrt{\frac{(\sigma_1^2 + \sigma_2^2)}{2}}} \tag{8.1}$$

wobei μ_1 und μ_2 die Mittelwerte und σ_1 und σ_2 die Standardabweichungen der Interclass- und Intraclass-Verteilung sind. Wie man der Formel entnehmen kann, drückt die Decidability den Abstand zwischen den Mittelwerten der beiden Verteilungen, gewichtet mit der gemittelten Varianz aus. Sie ist somit ein ausreißerstabiles Mass und eignet sich gut, um die Trennschärfe der beiden Verteilungen zu bewerten.

Mit Hilfe der Decidability lässt sich besser als zum Beispiel durch Zählen von falschen Erkennungen die Leistung eines biometrischen Systems beziffern. Sie ist deshalb auch eine wichtige Hilfe beim Einstellen von Parametern.

Unter optimalen Bedingungen sollte also die Streuung des Intraclass-Abstandes sowie des Interclass-Abstandes, bei Vergleich sehr vieler Irispaare, so klein sein, dass keine Überschneidungen der Wertebereiche auftritt. Im Realfall ist das allerdings selten so. Abbildung 8.1 auf der nächsten Seite zeigt eine typische Verteilung von gemessenen Abständen.

Sobald eine Überschneidung der Wertebereiche zwischen Intraclass-Verteilung und Interclass-Verteilung auftritt, ist nicht mehr exakt entscheidbar, zu welcher Klasse ein Template zugeordnet werden soll. Es treten also zwangsläufig Fehler auf. Wie in Abbildung 8.1 auf der nächsten Seite gekennzeichnet ist, sind 2 Arten von Fehlern zu unterscheiden.

Die False Acceptance Rate (FAR) und die False Rejection Rate (FRR).

Liegt bei der Erkennung einer Iris der kleinste gefundene Abstand und somit das am ehesten passende Template über dem Grenzwert, so wird es



Abbildung 8.1: False Acceptance Rate und False Rejection Rate

auch abgelehnt, wenn die Klassifizierung eigentlich richtig gewesen wäre. Man spricht hier von einer False Rejection (FR). Templates, die eigentlich nicht mit dem zu klassifizierenden Template übereinstimmen, aber trotzdem den kleinsten Abstand haben und unter dem Schwellwert liegen, werden fälschlich akzeptiert. Man spricht von einer False Acceptance (FA).

Die Wahl eines geeigneten Schwellwertes hängt immer von den Anforderungen ab, die an das biometrische System gestellt werden. Würde man einen absurd hohen Schwellwert wählen (FRR geht gegen 0), ab dem ein Template abgelehnt wird, wird ein Template zwar immer der Klasse mit dem kleinsten Abstand zugeordnet und es entstehen so viele richtige Erkennungen, allerdings gibt es auch keinerlei Sicherheit, dass die Erkennung auch wirklich richtig war, und der kleinste gefundene Abstand nicht zu einem falschen Template auftritt.

Zieht man aber eine Grenze im Bereich zwischen den zwei Verteilungen, so kann es sein, dass richtige Klassifizierungen über der Grenze liegen und deshalb abgelehnt werden. Die Wahl eines niedrigen Schwellwertes verringert also die Anzahl der Erkennungen, steigert hingegen aber die Sicherheit des Systems. FAR und FRR verhalten sich invers zu einander.

FAR und FRR, und damit Sicherheit oder Toleranz eines Systems, können durch Wahl des richtigen Schwellwertes adjustiert werden. Soll das System also nur das am ehesten passende Template finden (FRR gleich 0) so ist die Erkennungsrate sehr hoch; soll allerdings mit einer gewissen Sicherheit festgestellt werden, ob diese Übereinstimmung auch korrekt ist, wird die Erkennungsrate sinken, aber die Sicherheit der Erkennung steigen.

Ein gutes Leistungsmass für ein biometrischen System ist das erreichbare Minimum bei FAR und FRR, auch wenn das nicht gleichbedeutend mit der höchsten erreichbaren Erkennungsrate ist.

FAR und FRR sind denkbar einfach zu berechnen:

$$FAR = \frac{\text{Anzahl der fälschlich akzeptierten Templates}}{\text{Gesamtanzahl der akzeptierten Templates}}$$

 $FRR = \frac{\text{Anzahl der fälschlich abgelehnten Templates}}{\text{Gesamtanzahl der abgelehnten Templates}}$



Abbildung 8.2: Equal Error Rate

Als Maßzahl für die Güte einen Systems kann die Equal Error Rate (ERR) angegeben werden, wobei gilt:

$$ERR = (FAR = FRR) \tag{8.2}$$

Die ERR ist also der Punkt an dem FAR und FRR genau gleich groß sind. (Siehe Abbildung 8.2).

Ebenfalls in der Abbildung zu sehen ist der zuvor angesprochene Punkt an dem FRR = 0 wird und die FAR sehr groß wird und sein Gegenstück an dem die FAR = 0 ist und die FRR sehr groß wird.

8.3 Testdaten

Zum Testen des Systems wurden zwei verschiedene Datensätze verwendet. Einerseits eine vom Autor im Zuge dieser Arbeit aufgebaute Datenbank, die 92 Bilder vom linken und rechten Auge von 23 Personen enthält. Diese wurden auf die in Kapitel 2 beschriebene Weise aufgenommen. Auf Grund von Problemen mit der automatischen Scharfstellung der Kamera entsprechen leider viele andere Bilder nicht den geforderten Qualitätsansprüchen. Die übrigen Bilder sind zwar von brauchbarer Qualität und zeigen, dass das System prinzipiell funktioniert, für eine aussagekräftige Bewertung des Systems waren allerdings nicht genügend Daten vorhanden. Da in absehbarer Zeit keine Datenbank mit ausreichendem Umfang aufgebaut werden kann, wird für die Leistungsbewertung des Systems daher eine andere Datenbank verwendet.

Dafür wird die CASIA Iris Image Database des Institute of Automation der Chinese Academy of Science [oSIoA05] verwendet. Diese enthält Daten von jeweils einem Auge von 108 Personen. Pro Auge wurden jeweils 7 Graustufenbilder aufgenommen, die in zwei Gruppen von 3 und 4 Bildern, die bei 2 Sitzungen im Abstand von einem Monat aufgenommen wurden. Insgesamt enthält die CASIA Datenbank also 756 Bilder. Die Bilder wurden speziell für die Forschung an Iriserkennungssystemen mit einer eigens vom National Laboratory of Pattern Recognition entwickelten digitalen Optik, aufgenommen. Die Bilder stammen zum Grossteil von Personen asiatischer Abstammung mit sehr dunkel pigmentierten Iriden und schwarzen Wimpern. Da die Bilder bei Nahe-Infrarot Beleuchtung aufgenommen wurden, ist die Iris dennoch sehr gut sichtbar und die Kontraste zwischen Iris und Pupille sehr gut und zwischen Iris und Sclera grossteils gut.

Da die CASIA Datenbank eine ausgesprochene Testdatenbank ist, sind viel Bilder inkludiert, die ein Iriserkennungssystem auf die Probe stellen sollen. Man sollte deshalb auch nicht erwarten, dass es möglich ist, alle Bilder perfekt zu erkennen. Abbildung 8.3 auf der nächsten Seite zeigt einige besonders extreme Beispiele, die diesen Punkt unterstreichen sollen. Man muss mit sehr unterschiedlichen Pupillengrössen, teilweise sehr starken und von Bild zu Bild sehr unterschiedlichen Überdeckungen durch Wimpern und Augenlider und rotierten Bildern rechnen.

Auf Grund dieser anspruchsvollen Bildauswahl in der CASIA Datenbank konnten nur 550 Bilder von 95 Personen verwendet werden, da festgestellt wurde, dass schon sehr kleine Segmentierungsfehler eine Erkennung stark behindern. Es sei darauf hingewiesen, dass mehr als die verwendeten 550 Bilder richtig segmentiert wurden, insgesamt ca. 600, für Tests mit der Datenbank war es allerdings notwendig dass mindestens 5 der 7 Bilder zu einer Person richtig segmentiert wurden. Deshalb wurden teilweise richtig segmentierte Bilder nicht für die Tests verwendet. Trotzdem sollte diese Menge an Bildern für eine Leistungsbewertung ausreichend sein.

8.4 Parametertests

Da eine Auflistung und Besprechung der Fülle der Parametersetzungen, die bis zur korrekten Segmentierung eines Bildes nötig sind, im Rahmen einer Arbeit, die sich mit einer Bewertung der Principal Component Analysis beschäftigt, zu umfangreich und für des Thema nicht interessant wäre, sollen hier nur Parametersetzungen besprochen werden, die die PCA und die Klassifizierung direkt betreffen. Parameter die also, anschliessend an eine

64



(a) Durchschnittliches Bild



(c) Sehr gute Qualität



(b) Extrem überdeckt



(d) Stark rotiert



(e) Sehr grosse Pupille



(f) Mässiger Kontrast

Abbildung 8.3: Einige Beispielbilder aus der CASIA Datenbank

korrekte Segmentierung, ausschlaggebend für die Qualität der Erkennung sind.

Wichtige Schlüsselparameter sind:

- Abmessungen des Irisstreifens (x_{is}, y_{is})
- Abmessungen der Überdeckungen für unteres und oberes Augenlid im Verhältnis zum Irisstreifen (x_{ul}, y_{ul}) und (x_{ol}, y_{ol})
- Anzahl der Shifts um Rotationen auszugleichen (n_s)
- Anzahl der Augen fürs Enrollment (n_{eyes})
- Anzahl der verwendeten Eigenvektoren (p_{EV})

Zur Parameteroptimierung der ersten 3 Parameter wurden 95 Personen aus der CASIA Datenbank mit je einem Bild aus der ersten Sitzung im System gespeichert und anschließend 95 Bilder der gleichen Personen aus der zweiten Sitzung damit verglichen. Dabei wurden verschiedene Maße wie die Anzahl der Fehlerkennungen, der Mittelwert und die Standardabweichung der Intraclass- und Interclass-Verteilung und die Decidability erhoben und so die optimalen Parametereinstellungen ermittelt. Ausgehend von Schätzwerten für die noch nicht optimierten Parameter wurden die Parameter schrittweise optimiert. Die genauen Tests zu den einzelnen Parametern sind in den folgenden Kapiteln zusammengefasst. Dazugehörige Tabellen und Diagramme sind in Anhang A zusammengefasst.

8.4.1 Abmessungen des Irisstreifen

Faktoren, welche die Qualität der Erkennung signifikant beeinflussen, sind die radiale und anguläre Auflösung des Irisstreifens, der für die Erkennung verwendet wird, weil dadurch die Menge an Daten, die zur Erkennnung zur Verfügung steht, gesteuert wird.

Deshalb wurde hier, nicht wie bei anderen Parametern von Schätzwerten ausgehend optimiert, sondern eine genaue Untersuchung über einen sehr großen Parameterbereich durchgeführt. Als Qualitätsmaß wurde die zuvor besprochene Decidability verwendet. Die Ergebnisse der vielversprechenden Regionen sind in Anhang A in Tabellen A.1 auf Seite 84 und A.2 auf Seite 85 und Abbildungen A.1 auf Seite 84 und A.2 auf Seite 85 zusammengefasst.

Tabelle A.1 auf Seite 84 zeigt eine grobe Suche nach den optimalen Abmessungen des Irisstreifens. Bei einer angulären Auflösen von 300 Pixel und einer radialen Auflösung von 200 Pixel findet man das Optimum für die Decidability bei diesen Parametersetzungen. Tabelle A.2 auf Seite 85 untersucht genauer den Bereich rund um das Optimum, das zuvor bei der Grobsuche gefunden wurde.

Das Optimum für die radiale bzw. anguläre Auflösung, das bei der Feinsuche gefunden wird, liegt bei $x_{is} = 340$ und $y_{is} = 170$. Dieses Ergebnis ist interessant, da bei anderen Systemen zum Beispiel nach Boles [WB98], Lim [Lim01] oder Daugman [Dau02], immer mit kleineren Auflösungen für den Irisstreifen gearbeitet wurde. So spricht Boles von einer radialen Auflösung von 45 Pixel, Lim 60 Pixel und Daugman von ca. 100 - 140 Pixel Auflösung. Es bleibt die Frage offen, ob bei anderen Systemen nicht in diese Richtung optimiert wurde, oder ob andere Systeme mit kleineren Auflösungen arbeiten können.

8.4.2 Abmessungen der Überdeckungen für Augenlider

Da bei allen Bildern der Augen in der CASIA Datenbank verschieden große Überdeckungen durch Augenlider auftreten, ist es nicht trivial, eine passende Größe für die Bereiche, die aus dem Bild ausgeschnitten werden, zu finden. Würde man die Bereiche an die größte auftretende Überdeckung durch das obere und untere Augenlid angepasst wählen, würde man in allen Bildern viel Information durch die zu groß ausgeschnittenen Bereiche verlieren. Wählt man die Bereiche sehr klein, würde der Störeinfluss der Augenlider im Bild ansteigen. Es muss also ein Kompromiss bei der Wahl der Größe der ausgeschnittenen Bereiche gefunden werden. Deshalb wurde auch die optimale Größe der beide Bereiche experimentell ermittelt. Ausgehend von Schätzwerten wurden die Bereiche für das obere und das untere Augenlid seperat ermittelt. In einer groben und einer feinen Suche wurde für beide Augenlider die optimale Grösse der Überdeckung bestimmt. Qualitätsmaß ist auch hier wieder die Decidability.

Für das untere Augenlid wurde ein Bereich von 70 - 150 Pixel anguläre und 10 - 50 Pixel radiale Auslösung untersucht, was etwa 41% - 88% der Gesamthöhe, und 3% - 15% der Gesamtbreite des Irisstreifens entspricht. Das entspricht nach Beobachtung der ungefähren Größe der Überdeckungen durch Augenlider in den Bildern der CASIA Datenbank. Wie vermutet ergab sich als optimale Größe nicht ein Bereich, der alle Augenlider gänzlich ausschneidet, sondern eine Überdeckung von 7% × 76%. Das entspricht 25 × 130 Pixel Auflösung und somit nur einem durchschnittlich großen, ausgeschnittenen Bereich, der in vielen Bildern nicht das gesamte Augenlid entfernt. Die genauen Ergebnisse sind wiederum Anhang A Tabellen A.3 auf Seite 86 und A.4 auf Seite 87 sowie Abbildungen A.3 auf Seite 86 und A.4 auf Seite 87 zu entnehmen.

Für das obere Lid wurde der Bereich zwischen 100 und 165 Pixel, also 59% - 97%, angulärer, und 50 - 80 Pixel, also 15% - 24% radialer Auflösung un-

tersucht. Optimal ist eine Auflösung von $19\% \times 91\%$, also 65×155 Pixel. Dieser Bereich überdeckt praktisch alle Augenlider mit Ausnahme der Wimpern komplett. Die Übersicht ist in Tabellen A.5 auf Seite 88 und A.6 auf Seite 89 sowie Abbildungen A.5 auf Seite 88 und A.6 auf Seite 89 zu finden.

8.4.3 Anzahl der Shifts

Durch Verschieben (Shiften) des Irisstreifens um einige Pixel nach links oder rechts wird versucht, leichten Rotationen des Kopfes bei der Aufnahme des Auges entgegenzuwirken. Beim Überblenden zweier Irisstreifen kann man fast immer feststellen, dass durch eine leichte Verschiebung die Übereinstimmung verbessert werden kann. Je besser dadurch die Übereinstimmung wird, desto kleiner wird der mittlere Intraclass-Abstand der Bilder und die Streuung der Werte in der Intraclass-Verteilung.

Anhand von Abbildungen 8.4 auf der nächsten Seite und 8.5 auf der nächsten Seite kann man diesen Effekt beobachten. In Abbildung 8.4 auf der nächsten Seite wurden keine Shifts vorgenommen. Dem entsprechend ist die dargestellte Intraclass-Verteilung relativ breit gestreut, da viele Irisstreifen nicht korrekt übereinander liegen. In Abbildung 8.5 auf der nächsten Seite hingegen wurden zwei Shifts nach links und rechts vorgenommen. Man kann deutlich erkennen, dass die Verteilung jetzt eine kleinere Streuung aufweist, da die Irisstreifen jetzt besser zu einander passen.

Die erreichbare Qualitätssteigerung durch Verschieben des Irisstreifens lässt sich somit am besten an der Veränderung des Mittelwerts und der Standardabweichung der Intraclass-Verteilung beobachten. Gesucht wird das Minimum für diese beiden Werte.

Abbildungen A.7 auf Seite 90 und A.8 auf Seite 90 und Tabelle A.7 auf Seite 91 zeigen die Entwicklung von Mittelwert und Standardverteilung bei ansteigender Anzahl von Shifts. Das Minimum und somit die besten Ergebnisse werden bei zwei Shifts erreicht.



Abbildung 8.4: Intraclass-Verteilung ohne Shifts



Abbildung 8.5: Intraclass-Verteilung mit 2 Shifts

8.4.4 Anzahl der Augen fürs Enrollment

Abgesehen von reinem Parametertuning gibt es noch eine weitere sehr einfache Möglichkeit die Qualität und Sicherheit der Erkennung zu steigern. Werden beim Enrollmentprozess für eine Person mehrere Bilder pro Auge - bevorzugt unter leicht unterschiedlichen Bedingungen - gespeichert, so ist es wahrscheinlicher, dass beim späteren Vergleich das Auge wiedererkannt wird. Bei der Gesichtserkennung mittels PCA ist es üblich, zwischen 3 und 16 Bilder des gleichen Gesichtes bei zum Beispiel unterschiedlicher Beleuchtung, verschiedener Kopfhaltung oder variablem Abstand von der Kamera ins System aufzunehmen.

Die Iris bietet vergleichsweise weniger Variationsmöglichkeiten und es wird auch viel Aufwand bei der Normierung der Bilder betrieben, trotzdem können Beleuchtung, Pupillengrösse, Augenlider und Rotation des Kopfes immer noch als Störfaktoren wirken. Deshalb ist auch hier die Verwendung von mehreren Augen zum Vergleich interessant.

Es soll also untersucht werden, wieviele Aufnahmen nötig sind, um alle Augen im Testdatensatz richtig zuzuordnen. Dafür wird der Schwellwert nach dem sich FAR und FRR richten, so hoch eingestellt, dass die FRR = 0 ist (siehe Abbildung 8.2 auf Seite 63). Wie bereits erwähnt wurde, wurden in den Testdatensatz nur Personen aufgenommen, bei denen es möglich war mindestens 5 der 7 Aufnahmen richtig zu segmentieren. So können 1 bis 4 Bilder beim Enrollment abgepeichert werden und jeweils 1 Bild kann damit verglichen werden.

Ziel ist es eine möglichst klare Unterscheidung zwischen Intra- und Interclass Verteilung zu erreichen. Abbildung A.9 auf Seite 92 zeigt die beiden Verteilungen in einem Diagramm zusammengefasst. Dafür wurden die beiden Häufigkeitsachsen auf einheitliche Größe skaliert. Man kann beobachten, dass bei steigender Anzahl von Augen, die beim Enrollment gespeichert werden, die Überlappung zwischen den beiden Klassen immer kleiner wird. Dabei ist zu beachten, dass nur die Größe des Bereich der Überschneidung Aussagekraft hat. Die Häufigkeit hat auf Grund der Anpassung der Skalen keine Bedeutung. Aus Tabelle A.8 ist anhand der Decidability ersichtlich, dass die besten Ergebnisse bei 4 (oder mehr) Augen zu erwarten sind. Da aber bereits bei 3 Augen eine FAR von 0% und eine FRR von 0% erreichbar ist und jedes Auge mehr einen größeren Rechenaufwand bedeutet, werden 3 Augen fürs Enrollment als idealer Wert angenommen.

8.4.5 Anzahl der verwendeten Eigenvektoren

Dieser Parameter nimmt einen besonderen Platz in der Liste der hier besprochen Parameter ein. Er dient als einziger nicht dazu die Qualität der Erkennung zu steigern, sondern um die Berechnung zu beschleunigen und die Templates effzienter zu speichern. Es soll festgestellt werden, wieviele Eigenvektoren für die Berechnung der PCA ausser Acht gelassen werden können, bevor ein Absinken der Qualität der Erkennung bemerkbar wird. Für Details sei auf das Kapitel zur Principal Component Analysis 5.1 auf Seite 41 verwiesen, hier nur die wichtigsten Fakten:

Da die Eigenvektoren verschieden wichtig für die Rekonstruktion der Originalbilder sind, ist es möglich die unwichtigsten nicht in die Berechnung der biometrischen Templates mit einzubeziehen. Ihre Wichtigkeit wird anhand der Varianz gemessen, die sie erklären. Gesucht ist die Anzahl der Eigenvektoren, die gestrichen werden können, wenn ein bestimmter Prozentsatz der Varianz erklärt werden soll. Abbildung 8.6 zeigt in einem sogenannten Scree-Plot, wieviel Prozent der Gesamtvarianz die Eigenvektoren, nach Größe geordnet, erklären. Man kann erkennen, dass die Eigenvektoren sehr schnell an Bedeutung für die Rekonstruktion verlieren.



Abbildung 8.6: Prozent der Gesamtvarianz, die durch die einzelnen Eigenvektoren erklärt wird

Wenn also nicht alle Eigenvektoren gespeichert werden müssen, lässt sich einen Datenreduktion und ein Geschwindigkeitszuwachs bei der Berechnung des Templates erreichen. Außerdem kann auch das Template kompakter gespeichert werden, da es die Koeffizienten enthält, mit denen aus den Eigenvektoren das Originalbild berechnet werden kann.

Man muss sich allerdings darüber im Klaren sein, dass man Information verliert und so die Qualität der Erkennung sinkt. Tabelle A.9 auf Seite 93 zeigt die Entwicklung von FAR und FRR und die Zahl der verwendeten Eigenvektoren, in Abhängigkeit von den Prozent der erklärten Varianz (PoV). Will man keine Qualitätseinbußen hinnehmen, können also nur 3% der Eigenvektoren vernachlässigt werden. Bei den 285 dem Testsystem bekannten Augen sind das nur 7 Eigenvektoren.

Aus anderen Quellen, die sich allerdings mit Gesichtserkennung beschäftigen, ist bekannt, dass teils nur die Eigenvektoren, die 90% der Varianz erklären, verwendet werden. Es kann nur angenommen werden, dass entweder eine umfangreichere Datenbank nötig ist, um diesen Vorteil bei der Berechnung der PCA sinnvoll nützen zu können, oder, was wahrscheinlicher ist, die Variation von Gesicht zu Gesicht kleiner ist, als die zwischen verschiedenen Augen und deshalb mehr Eigenvektoren zur korrekten Rekonstruktion nötig sind.

Hier ist der Vorteil relativ klein. Ein Eigenvektor benötigt 145 Kilobyte Platz, bei 7 nicht verwendeten Eigenvektoren kann also ca. 1 Megabyte Speicherplatz gespart werden. Das Template wird um 56 Byte kleiner, es schrumpft also in der Gesamtgröße von 2280 Byte auf 2216 Byte. Insgesamt sind das ca. 16 Kilobye Platzersparnis. Ein Geschwindigkeitsgewinn ist kaum messbar. Erst wenn mehr als 10% der Eigenvektoren vernachlässigt werden, ist ein wirklicher Vorteil erkennbar.

8.5 Zusammenfassung

Zusammengefasst ergibt sich, dass eine Auflösung von 340×170 Pixel optimal für die Größe der Irisstreifen ist. Die halbe Ellipse, die als Überdeckung für das untere Lid dient, sollte 25×130 Pixel oder $7\% \times 76\%$ der Gesamtabmessungen des Irisstreifens messen. Für das obere Lid sind die Masse $65 \times$ 155 oder $19\% \times 91\%$ am besten geeignet. Zum Ausgleichen von Rotationen des Kopfes bei der Bildaufnahmen wird der Irisstreifen beim Matching 2 Pixel nach links und rechts verschoben. Beim Enrollment muss das System mit mindestens 3 Augen pro Person trainiert werden um alle Personen richtig zuzuweisen. Hier werden 3 Augen verwendet, um die Erkennungsgeschwindigkeit hoch zu halten. Die Anzahl der für die PCA verwendeten Eigenvektoren richtet sich nach dem Prozentsatz der durch sie erklärten Varianz. Bei einer erklärten Varianz von 99.7\%, das bedeutet, dass 3% der Eigenvektoren
8.5. ZUSAMMENFASSUNG

nicht verwendeten werden (vergleiche Tabelle A.9 auf Seite 93), ist noch eine fehlerfreie Erkennung möglich.

So wie das System aktuell konfiguriert ist, wird von einer Identifikationsaufgabe ausgegangen; es sucht beim Matching nach der wahrscheinlichsten Übereinstimmung ohne Rücksicht auf die Sicherheit, mit der diese korrekt ist. Der Grenzwert ab dem ein Template abgelehnt wird, egal ob die Übereinstimmung richtig war oder nicht, liegt so hoch, dass die FRR = 0 ist. Das kann bei bestimmten Anforderungen ausreichend sein, üblicher ist es allerdings, dass das Matching auch mit einer gewissen Sicherheit durchgeführt werden soll.

Um für alle Anforderungen geeignet zu sein und eine finale Leistungsbewertung abgeben zu können wird daher der Punkt gesucht, an dem False Rejection Rate (FRR) und False Acceptance Rate (FAR) gleich groß sind, der Punkt der Equal Error Rate (EER). Dabei geht man nicht mehr von einer Identifikation aus, sondern von einer Verifikation. Es wird also nicht mehr das am besten passende Template gesucht, sondern nur mehr verglichen, ob ein Template einen Abstand hat, der höher oder niedriger als der Schwellwert ist. Templates unter dem Schwellwert werden akzeptiert, Templates über dem Schwellwert abgelehnt.

Tabelle 8.1 auf der nächsten Seite zeigt die False Acceptance und Rejection Rates für verschiedene Wertsetzungen des Schwellwertes, der über Akzeptanz oder Ablehnung des Templates entscheidet. Dabei wurden, im Unterschied zur vorangegangenen Parameteroptimierung, 255 Bilder der Augen der 95 bekannten Personen mit den im System gespeicherten Bildern verglichen. Abbildung 8.7 auf der nächsten Seite stellt den Verlauf von FAR und FRR grafisch dar und kennzeichnet den Punkt der EER. Diese liegt bei 0.4% und lässt durchaus gute Erkennnungsleistungen zu.

Ein direkter Leistungsvergleich mit Daugmans System ist schwer, da nicht bekannt ist, welcher Datensatz zum Test des Systems verwendet wurde. Glücklicherweise fand sich bei der Literaturrecherche zu diesem Thema eine Arbeit [Mas03] von Libor Masek, einem Studenten der University of Western Australia, School of Computer Science and Software Engineering. Er hat es sich zur Aufgabe gemacht, Daugmans Methode zur Berechnung des Templates, dem Iriscode, nachzuimplementieren und einer transparenteren Leistungbewertung zu unterziehen. Masek verwendet zum Test seines Systems ebenfalls die CASIA Datenbank. Ihm war es möglich eine FRR von 0.005% bei einer FAR von 0.238% zu erreichen. Auch Masek's System konnte dabei mehr als 100 Augen in der Datenbank nicht korrekt segmentieren, weshalb sicherlich auch nicht der exakt gleiche Testdatensatz verwendet wurde. Trotzdem sollen die folgenden Werte als ungefähres Vergleichsmaß zwischen

Threshold	FAR	FRR
1000	0.00%	54.90%
1050	0.00%	43.53%
1100	0.00%	37.65%
1150	0.00%	28.63%
1200	0.01%	23.53%
1250	0.02%	18.04%
1300	0.04%	12.55%
1350	0.07%	10.98%
1400	0.13%	6.67%
1450	0.21%	3.14%
1500	0.38%	0.78%
1515	0.43%	0.39%
1550	0.57%	0.39%
1600	0.85%	0.39%
1650	1.27%	0.00%
1700	1.81%	0.00%
1750	2.52%	0.00%
1800	3.34%	0.00%
1850	4.41%	0.00%
1900	5.53%	0.00%
1000		

Tabelle 8.1: False Acceptance Rate und False Rejection Rate bei unterschiedlichen Schwellwerten. (EER ist in Fettdruck gekennzeichnet.)



Abbildung 8.7: Verlauf von FAR und FRR bei verschiedenen Schwellwerten

8.5. ZUSAMMENFASSUNG

der etablierten Methode des Iriscodes und der hier vorgestellten Anwendung der PCA für Iriserkennung dienen:

Da Masek leider keine EER angibt, wurde versucht die FAR und FRR in ungefähr gleiches Verhältnis zu bringen. So ergibt sich für das hier vorgestellte System bei einer FRR von 0% eine FAR von 0.96%. Will man eine FAR von 0.23% erreichen, so liegt die FRR bei 1.96%.

Es kann also festgestellt werden, dass die PCA zwar nicht ebenso gut funktioniert wie der derzeit beste Ansatz zur Identifikation via Irismuster, John Daugmans Iriscode, aber im Vergleich zu anderen Iriserkennungssystemen und besonders im Vergleich zu anderen biometrischen Merkmalen eine gute Alternative darstellt. Dabei ist natürlich zu beachten, dass der hier vorgestellte Ansatz noch jung ist. John Daugmans System wurde über Jahre weiterentwickelt und optimiert.

Kapitel 9

Abschluss

9.1 Zusammenfassung

In der vorliegenden Arbeit wurde ein System zur Erkennung von Irismustern zum Zweck der biometrischen Identifikation vorgestellt. Ziel war es zu zeigen, dass die Principal Component Analysis (PCA) dafür geeignet ist, ein biometrisches Template zu erstellen, anhand dessen verschiedene Iriden mit einander verglichen und so von einander unterschieden werden können.

Es wurde eine Technik zur Bildaufnahme vorgestellt, die es erlaubt, Bilder des Auges unter vorteilhaften Bedingungen zu gewinnen. Dafür wurde das Auge von beiden Seiten mit einer Halogenlampe angestrahlt und mit einer Digitalkamera aus ca. 30cm Abstand photographiert.

Anschliessend an die Bildaufnahme wurden verschiedene Vorverarbeitungsschritte durchgeführt, um das Bild auf die automatisierte Weiterverarbeitung vorzubereiten.

Der nächste Schritt war die Anwendung eines Algorithmus zur automatisierten Lokalisierung von Iris und Pupille im Bild. Es wurde ein Filter zur Kantendetektion und die Circular Hough Transformation eingesetzt, um Kreise an die Grenzen zwischen Pupille und Iris beziehungsweise Iris und Lederhaut anzupassen.

Zur Extraktion der für die Iriserkennung wichtigen Daten und der weiteren Normalisierung des Bildes wurde, mittels einer Rubbersheet Transformation, der kreisförmige Bereich der Iris in einen Streifen einheitlicher Breite und Höhe transformiert.

Um den für die Erkennnung hinderlichen Einfluss der Augenlider zu lindern, wurden zwei Bereiche, die oberes und unteres Augenlid umfassen, aus dem Bild entfernt.

Schließlich wurde die PCA dazu verwendet, für jedes Auge ein biometrisches Template zu berechnen. Die euklidische Distanz zwischen den Templates dient dabei als Unterscheidungsmaß.

In einer statistischen Auswertung unter der Verwendung der CASIA Iristestdatenbank wurde festgestellt, dass die PCA geeignet ist, als Grundlage für ein biometisches Iriserkennungssystem zu dienen. Das System erreicht eine Equal Error Rate von 0.4%.

9.2 Erkenntnisse aus der Arbeit

Im Zuge der Arbeit hat sich herausgestellt, dass die wichtigsten Punkte beim Erkennungsprozess die Bildaufnahme und die Segmentierung sind. Qualitative Mängel, die bei der Bildaufnahme entstehen, können später kaum noch ausgeglichen werden. Besonders negativ wirken sich dabei Unschärfen aus, da die feinen Muster der Iris schon bei geringer Defokussierung nicht mehr klar erkenntlich sind. Auch anderen überraschenden Einflüssen, wie zum Beispiel dem Schattenwurf der Augenlider oder Reflexionen durch das helle Gehäuse der zur Bildaufnahme verwendeten Kamera muss unbedingt entgegengewirkt werden.

Die Segmentierung stellt ebenfalls eine grosse Herausforderung für ein automatisiertes System dar. Bei einem Datensatz, wie er vom Autor erstellt wurde, der sehr günstige Verhältnisse für die Erkennung bietet, ist eine hohe Erfolgsrate bei der Segmentierung möglich. Bei der CASIA Datenbank allerdings, die speziell dazu entwickelt wurde, Iriserkennungssyteme auf die Probe zu stellen, ist das allerdings bedeutend schwieriger. So konnten trotz großem Aufwand und viel Detailarbeit nur ca. 80% der Bilder korrekt segmentiert werden. Das liegt großteils an Überdeckungen durch Augenlider und Wimpern, aber auch an teils schlechten Kontrastverhältnissen, wiederum Störeinflüsse, denen schon bei der Bildaufnahme begegnet werden muss. Arbeitet man dann auf einem Datensatz mit optimal aufbereiteten Bildern, ist einen hohe Erkennungsrate möglich.

Weiters interessant sind zwei eher kleine Details. Erstens stellte sich auf Grund einer sehr breiten Suche nach den optimalen Abmessungen für den Irisstreifen heraus, dass die besten Ergebnisse nicht mit den realen Längenzu Breitenverhältnissen, etwa 8:1 bis 10:1, erreichbar sind. Am besten eignet sich hier interessanterweise ein Verhältnis von 2:1. Die Vermutung des Autors ist, dass bei diesem Seitenverhältnis die Muster der Iris deutlicher hervortreten, als bei den originalen Seitenverhältnissen.

78

Der zweite Punkt betrifft ein Detail der PCA. In verschiedenen Literaturquellen ist zu lesen, dass bei der Anwendung der PCA im Bereich der Gesichtserkennung nur die Eigenvektoren, die 90% der Gesamtvarianz aufklären, zur Rekonstruktion der Originalbilder verwendet werden. Hier wurde allerdings festgestellt, dass für einen Rekonstruktion ohne Qualitätsverlust 99.7% der Gesamtvarianz durch die verwendeten Eigenvektoren erklärt sein muss.

Ausserdem sind noch zwei Einschränkungen bei der Verwendung der PCA aufgefallen. Wie schon an anderer Stelle ausführlich erläutert wurde, ist es nicht sinnvoll die störenden Augenlider und Wimpern exakt zu entfernen, da der entfernte Bereich, im Unterschied zu z.B. Daugman, immer gleich groß sein muss. Daugman hat den Vorteil, dass immer nur zwei Templates verglichen werden. Die Überdeckungen können exakt berechnet und nicht in den Vergleich beider Bilder einbezogen werden. Will man die PCA nicht für jeden Vergleich neu berechen, muss man immer mit den gleichen Überdeckungen vergleichen. Inwieweit sich dieser Nachteil auf die Erkennungsleistung auswirkt, ist leider nicht bekannt.

Der zweite Kritikpunkt im Umgang mit der PCA betrifft den hohen Aufwand bei deren Berechnung. Da hier die theoretische Möglichkeit untersucht wurde, die PCA für die Iriserkennung einzusetzen, wurde das System auf optimale Erkennungsleistungen getrimmt. Eine hohe Erkennungsgeschwindigkeit war dabei nicht das Ziel. Trotzdem soll erwähnt sein, dass die PCA im Punkt Geschwindigkeit entscheidende Nachteile gegenüber anderen Ansätzen hat. Daugman gibt an, dass die Berechnung des Iriscodes auf einer 300 MHz Sun Workstation ca. 100 ms dauert [Dau02]. Einen Benutzer neu in die Datenbank aufzunehmen dauert ca. 500 ms.

Wird unter Verwendung der PCA ein Benutzer neu in das System aufgenommen, sollte¹ die PCA neu berechnet werden. Das bedeutet, dass für den neuen Benutzer nicht unabhängig von allen anderen Benutzern ein Template berechnet und abgespeichert werden kann, sondern, dass die Templates aller Benutzer neu berechnet werden müssen. Je nach Anzahl der Benutzer und Templategröße bedeutet das, dass mehrerer Rechenschritte mit Matrizen mit sehr großen Dimensionen durchgeführt werden müssen. (Bei 500 Benutzern und der hier benutzten Templategrösse zum Beispiel eine Matrixmulitplikation von zwei Matrizen mit 500 \times 21100 Einträgen.)

Auch wenn nur ein Template für einen unbekannten Benutzer berechnet

¹Sind dem System bereits sehr viele Benutzer bekannt, kann das Template auch aus den bisher berechneten Eigenvektoren erstellt werden. Die PCA muss also nicht unbedingt für jeden neuen Benutzer neu berechnet werden, da sich die Eigenvektoren durch einen neuen Benutzer bei vielen bestehenden Benutzern nicht wesentlich ändern.

werden soll, beinhaltet das Berechnungen mit einer Matrix derselben Dimension. Selbst auf einem Rechner mit 2 GHz Takt dauert das ca. 1 s. Der Aufwand zur Templateberechnung ist also nicht vergleichbar.

Für Echtzeitsysteme ist die PCA derzeit also nicht geeignet.

9.3 Zukünftige Arbeit

Obwohl das System gut funktioniert, gibt es noch einige Punkte, die angemerkt werden sollten oder Ansätze zu weiteren Verbesserungen des Systems bieten.

Wie im letzten Abschnitt erklärt wurde, ist die PCA sehr rechenintensiv. Im Zuge dieser Arbeit wurde das Hauptaugenmerk auf die Qualtität der Erkennung gelegt. In einer zukünftigen Weiterentwicklung könnten einerseits Optimierungsmöglichkeiten im Code gesucht werden, welche die Berechnung beschleunigen. Interessanter wäre es allerdings, Parameter zu suchen, die gute, nicht perfekte, Erkennungsleistungen zulassen, dabei aber einen Geschwindigkeitsvorteil versprechen. Das größte Potenzial bieten dabei die Lokalisierung und die PCA selbst.

Weiters verbesserungswürdig ist die Bildaufnahme. Hier wurde mit einfachen Mitteln gearbeitet. Im direkten Vergleich zwischen den für die Arbeit aufgenommenen Bilderen und den Bildern in der CASIA Datenbank fällt zum Beispiel auf, dass die Beleuchtung im Nahe-Infrarot Bereich bessere Ergebnisse zulässt, als die Beleuchtung mit Halogenstrahlern, auch wenn die Qualität immer noch ausreichend ist. Außerdem würde der Einsatz einer CRT-Kamera in Verbindung mit einem Framegrabber, anstatt einer Digitalkamera, die Bedienung erleichtern.

Letztlich beinhaltet das System keine Sicherheitsmechanismen, die ein umgehen der Iriskontrolle verhindern sollen. Beim aktuellen Aufbau ist die Gefahr der Umgehung aber relativ klein, da bei der Bildaufnahme ein Betreiber anwesend sein muss.

Sollte das System allerdings vollautomatisch, zum Bespiel für Zugangskontrollen eingesetzt werden, so müsste es gegen verschiedene Gefahren abgesichert werden. Die Iris ist glücklicherweise, was ihre Fälschung anbelangt, von sich aus ein eher sicheres Merkmal. Bisher sind nicht besonders viele Angriffe bekannt, mit denen ein Iriserkennungsystem erfolgreich getäuscht werden kann. All diesen Angriffen kann mittels realtiv einfachen Life-Checks entgegengewirkt werden, sofern eine Videosequenz des präsentierten Auges untersucht werden kann. Denkbare Angriffe sind der Versuch das System mit einem Photo oder einer Videosequenz eines anderen Auges zu täuschen. Eine andere Möglichkeit sind undurchsichtige Kontaktlinsen, die mit dem Muster einer fremden Iris bedruckt sind.

Gegenmaßnahmen sind zum Beispiel ein zeitlich zufallsgesteuerter Luftstoß, der das Auge zum Zwinkern anregt, oder gezielte Beleuchtung unter Beobachtung der Pupille, die sich dabei verengen sollte. Weiters kann auch ein Punkt projeziert werden, dessen Bewegung der Benutzer mit dem Auge folgen muss.

Wildes [Wil97] berichtet, dass sich die Pupille ständig mit einer Frequenz von ca. 0.5Hz etwas weitet und wieder verengt, was ein Photo ebenfalls als Fälschung entlarven würde.

Es gibt also, sollte die Notwendigkeit entstehen, viele Möglichkeiten, das System gegen Eindringlinge abzusichern. Außerdem muss auch bedacht werden, dass es im Unterschied etwa zu Fingerabdrücken, Unterschriften oder DNA alleine schon schwer ist, ohne das Wissen des Betroffenen ein Abbild des Auges von ausreichender Qualität zu gewinnen.

Anhang A

Tabellen und Diagramme



Abbildung A.1: Decidability bei einer groben Suche nach den besten Abmessungen des Irisstreifens, mit $x_{ul} = 6.25\%, y_{ul} = 59\%, x_{ol} = 20\%, y_{ol} = 95\%, n_s = 2, p_{EV} = 1, n_{eyes} = 1$

	80	100	120	140	160	180	200	220	240
100	2.0900	2.0327	1.9940	2.1540	2.1181	2.0954	2.0230	1.9849	1.9921
200	2.3530	2.2129	2.2688	2.3687	2.3214	2.2040	2.2197	2.2595	2.2870
300	2.3426	2.4512	2.3781	2.3379	2.3703	2.4323	2.4560	2.3993	2.3767
400	2.4066	2.3824	2.3285	2.4237	2.3900	2.4009	2.3701	2.3045	2.3664
500	2.3509	2.2940	2.3836	2.3493	2.3415	2.2848	2.3000	2.3441	2.3926
600	2.2665	2.3777	2.3376	2.2797	2.2793	2.3292	2.3716	2.3307	2.3378

Tabelle A.1: Decidability bei einer groben Suche nach den besten Abmessungen des Irisstreifens, mit $x_{ul} = 6.25\%, y_{ul} = 59\%, x_{ol} = 20\%, y_{ol} = 95\%, n_s = 2, p_{EV} = 1, n_{eyes} = 1$



Abbildung A.2: Decidability bei einer feinen Suche nach den besten Abmessungen des Irisstreifens, mit $x_{ul} = 6.25\%, y_{ul} = 59\%, x_{ol} = 20\%, y_{ol} = 95\%, n_s = 2, p_{EV} = 1, n_{eyes} = 1$

	60	70	80	90	100	110	120	130	140
220	2.3598	2.3685	2.3386	2.2798	2.2868	2.2868	2.3668	2.3970	2.3970
240	2.4236	2.3591	2.3295	2.3321	2.3185	2.4118	2.4299	2.3975	2.3399
260	2.4075	2.3399	2.2862	2.3108	2.4132	2.4252	2.4099	2.3890	2.3515
280	2.3918	2.3635	2.3268	2.3873	2.4467	2.4293	2.3836	2.3598	2.3673
300	2.3891	2.3499	2.3426	2.4276	2.4512	2.4032	2.3781	2.3592	2.3379
320	2.3529	2.3321	2.4105	2.4533	2.4301	2.3793	2.3701	2.3482	2.3274
340	2.3694	2.3215	2.4281	2.4588	2.4139	2.3996	2.3472	2.3333	2.3427
360	2.3462	2.3711	2.4116	2.4200	2.4080	2.3856	2.3650	2.3444	2.4010
380	2.3241	2.3824	2.4099	2.3635	2.3757	2.3623	2.3201	2.3797	2.3966
	150	160	170	180	190	200	210	220	230
220	2.3589	2.2694	2.2750	2.2745	2.3150	2.3035	2.2573	2.2986	2.3583
240									
- 10	2.3397	2.3360	2.3270	2.3010	2.2866	2.3010	2.3943	2.4064	2.4197
260	2.3397 2.2908	2.3360 2.3300	2.3270 2.3002	2.3010 2.3197	2.2866 2.3701	2.3010 2.4123	2.3943 2.4229	2.4064 2.4406	2.4197 2.4208
260 280	$ \begin{array}{r} 2.3397 \\ 2.2908 \\ 2.3217 \end{array} $	$2.3360 \\ 2.3300 \\ 2.3124$	$\begin{array}{r} 2.3270 \\ 2.3002 \\ 2.3508 \end{array}$	$ \begin{array}{r} 2.3010 \\ 2.3197 \\ 2.4124 \end{array} $	2.2866 2.3701 2.4112	$ \begin{array}{r} 2.3010 \\ 2.4123 \\ 2.4393 \end{array} $	$\begin{array}{r} 2.3943 \\ 2.4229 \\ 2.4579 \end{array}$	$ \begin{array}{r} 2.4064 \\ 2.4406 \\ 2.4273 \\ \end{array} $	$\begin{array}{c} 2.4197 \\ 2.4208 \\ 2.3992 \end{array}$
260 280 300	2.3397 2.2908 2.3217 2.3378	$\begin{array}{r} 2.3360 \\ 2.3300 \\ 2.3124 \\ 2.3703 \end{array}$	2.3270 2.3002 2.3508 2.4121	$\begin{array}{c} 2.3010 \\ 2.3197 \\ 2.4124 \\ 2.4323 \end{array}$	$\begin{array}{r} 2.2866 \\ 2.3701 \\ 2.4112 \\ 2.4589 \end{array}$	$\begin{array}{r} 2.3010 \\ 2.4123 \\ 2.4393 \\ 2.4560 \end{array}$	$\begin{array}{c} 2.3943 \\ 2.4229 \\ 2.4579 \\ 2.4436 \end{array}$	$\begin{array}{r} 2.4064 \\ 2.4406 \\ 2.4273 \\ 2.3993 \end{array}$	2.4197 2.4208 2.3992 2.3825
260 280 300 320	2.3397 2.2908 2.3217 2.3378 2.3631	2.3360 2.3300 2.3124 2.3703 2.4126	$\begin{array}{r} 2.3270 \\ 2.3002 \\ 2.3508 \\ 2.4121 \\ 2.4315 \end{array}$	$\begin{array}{r} 2.3010 \\ 2.3197 \\ 2.4124 \\ 2.4323 \\ 2.4583 \end{array}$	$\begin{array}{r} 2.2866 \\ 2.3701 \\ 2.4112 \\ 2.4589 \\ 2.4584 \end{array}$	$\begin{array}{r} 2.3010 \\ 2.4123 \\ 2.4393 \\ 2.4560 \\ 2.4251 \end{array}$	$\begin{array}{r} 2.3943 \\ 2.4229 \\ 2.4579 \\ 2.4436 \\ 2.3960 \end{array}$	2.4064 2.4406 2.4273 2.3993 2.3907	2.4197 2.4208 2.3992 2.3825 2.3724
260 280 300 320 340	2.3397 2.2908 2.3217 2.3378 2.3631 2.4208	2.3360 2.3300 2.3124 2.3703 2.4126 2.4407	2.3270 2.3002 2.3508 2.4121 2.4315 2.4634	2.3010 2.3197 2.4124 2.4323 2.4583 2.4583 2.4447	$\begin{array}{r} 2.2866 \\ 2.3701 \\ 2.4112 \\ 2.4589 \\ 2.4584 \\ 2.4265 \end{array}$	2.3010 2.4123 2.4393 2.4560 2.4251 2.4015	2.3943 2.4229 2.4579 2.4436 2.3960 2.3956	2.4064 2.4406 2.4273 2.3993 2.3907 2.3909	2.4197 2.4208 2.3992 2.3825 2.3724 2.3751
260 280 300 320 340 360	2.3397 2.2908 2.3217 2.3378 2.3631 2.4208 2.3980	2.3360 2.3300 2.3124 2.3703 2.4126 2.4407 2.4285	2.3270 2.3002 2.3508 2.4121 2.4315 2.4634 2.4244	$\begin{array}{c} 2.3010 \\ 2.3197 \\ 2.4124 \\ 2.4323 \\ 2.4583 \\ 2.4447 \\ 2.4079 \end{array}$	$\begin{array}{c} 2.2866\\ 2.3701\\ 2.4112\\ 2.4589\\ 2.4584\\ 2.4265\\ 2.4083\\ \end{array}$	$\begin{array}{r} 2.3010 \\ 2.4123 \\ 2.4393 \\ 2.4560 \\ 2.4251 \\ 2.4015 \\ 2.4083 \end{array}$	$\begin{array}{r} 2.3943 \\ 2.4229 \\ 2.4579 \\ 2.4436 \\ 2.3960 \\ 2.3956 \\ 2.3796 \end{array}$	$\begin{array}{c} 2.4064 \\ 2.4406 \\ 2.4273 \\ 2.3993 \\ 2.3907 \\ 2.3909 \\ 2.3702 \end{array}$	$\begin{array}{c} 2.4197\\ 2.4208\\ 2.3992\\ 2.3825\\ 2.3724\\ 2.3751\\ 2.3539\end{array}$
260 280 300 320 340 360 380	2.3397 2.2908 2.3217 2.3378 2.3631 2.4208 2.3980 2.4239	2.3360 2.3300 2.3124 2.3703 2.4126 2.4407 2.4285 2.4177	2.3270 2.3002 2.3508 2.4121 2.4315 2.4634 2.4244 2.4076	$\begin{array}{c} 2.3010\\ 2.3197\\ 2.4124\\ 2.4323\\ 2.4583\\ 2.4447\\ 2.4079\\ 2.4132\\ \end{array}$	2.2866 2.3701 2.4112 2.4589 2.4584 2.4265 2.4083 2.4092	2.3010 2.4123 2.4393 2.4560 2.4251 2.4015 2.4083 2.3787	$\begin{array}{c} 2.3943\\ 2.4229\\ 2.4579\\ 2.4436\\ 2.3960\\ 2.3956\\ 2.3796\\ 2.3675\\ \end{array}$	2.4064 2.4406 2.4273 2.3993 2.3907 2.3909 2.3702 2.3498	2.4197 2.4208 2.3992 2.3825 2.3724 2.3751 2.3539 2.3338

Tabelle A.2: Decidability bei einer feinen Suche nach den besten Abmessungen des Irisstreifens, mit $x_{ul} = 6.25\%, y_{ul} = 59\%, x_{ol} = 20\%, y_{ol} = 95\%, n_s = 2, p_{EV} = 1, n_{eyes} = 1$



Abbildung A.3: Decidability bei einer groben Suche nach den optimalen Abmessungen der Überdeckungen für das untere Augenlid, mit $x_{xs} = 340, y_{ys} = 170, x_{ol} = 20\%, y_{ol} = 95\%, n_s = 2, p_{EV} = 1, n_{eyes} = 1$

	41%	47%	53%	59%	65%	71%	76%	82%	88%
3%	2.3003	2.3122	2.3245	2.3563	2.3751	2.3900	2.3920	2.4096	2.4082
6%	2.3687	2.3904	2.4084	2.4621	2.4713	2.4862	2.4979	2.5058	2.5264
9%	2.3920	2.4026	2.3726	2.4707	2.5259	2.5556	2.5454	2.5298	2.5081
12%	2.3753	2.3586	2.4012	2.4413	2.4494	2.4280	2.4134	2.3516	2.3366
15%	2.3745	2.4070	2.4683	2.4335	2.3771	2.3066	2.2453	2.2349	2.1811

Tabelle A.3: Decidability bei einer groben Suche nach den optimalen Abmessungen der Überdeckungen für das untere Augenlid, mit $x_{xs} = 340, y_{ys} = 170, x_{ol} = 20\%, y_{ol} = 95\%, n_s = 2, p_{EV} = 1, n_{eyes} = 1$



Abbildung A.4: Decidability bei einer feinen Suche nach den optimalen Abmessungen der Überdeckungen für das untere Augenlid, mit $x_{xs} = 340, y_{ys} = 170, x_{ol} = 20\%, y_{ol} = 95\%, n_s = 2, p_{EV} = 1, n_{eyes} = 1$

	65%	68%	71%	74%	76%	79%
6%	2.4713	2.4845	2.4862	2.4973	2.4979	2.4945
7%	2.4772	2.5207	2.5392	2.5483	2.5647	2.5558
9%	2.5259	2.5413	2.5556	2.5583	2.5454	2.5437
10%	2.4891	2.4912	2.5000	2.4892	2.4708	2.4417

Tabelle A.4: Decidability bei einer feinen Suche nach den optimalen Abmessungen der Überdeckungen für das untere Augenlid, mit $x_{xs} = 340, y_{ys} = 170, x_{ol} = 20\%, y_{ol} = 95\%, n_s = 2, p_{EV} = 1, n_{eyes} = 1$



Abbildung A.5: Decidability bei einer groben Suche nach den optimalen Abmessungen der Überdeckungen für das obere Augenlid, mit $x_{xs} = 340, y_{ys} = 170, x_{ul} = 7\%, y_{ul} = 76\%, n_s = 2, p_{EV} = 1, n_{eyes} = 1$

	59%	65%	71%	76%	82%	88%	94%
15%	2.1595	2.2887	2.3590	2.4372	2.4919	2.5169	2.4930
18%	2.2163	2.3551	2.4301	2.5150	2.5537	2.5321	2.5540
21%	2.2794	2.3918	2.4811	2.5045	2.5270	2.5754	2.5556
24%	2.2975	2.4733	2.4990	2.5149	2.5412	2.5527	2.5170

Tabelle A.5: Decidability bei einer groben Suche nach den optimalen Abmessungen der Überdeckungen für das obere Augenlid, mit $x_{xs} = 340, y_{ys} = 170, x_{ul} = 7\%, y_{ul} = 76\%, n_s = 2, p_{EV} = 1, n_{eyes} = 1$



Abbildung A.6: Decidability bei einer feinen Suche nach den optimalen Abmessungen der Überdeckungen für das obere Augenlid, mit $x_{xs} = 340, y_{ys} = 170, x_{ul} = 7\%, y_{ul} = 76\%, n_s = 2, p_{EV} = 1, n_{eyes} = 1$

	76%	79%	82%	85%	88%	91%	94%	97%
17%	2.4642	2.4889	2.5493	2.5471	2.5687	2.5335	2.5465	2.5285
18%	2.5287	2.5628	2.5373	2.5690	2.5774	2.5732	2.5467	2.5700
19%	2.5292	2.5266	2.5151	2.5524	2.6169	2.6174	2.5498	2.5800
21%	2.5303	2.5155	2.5350	2.5513	2.5441	2.5759	2.5647	2.5567
22%	2.5124	2.5092	2.5486	2.4840	2.5645	2.5573	2.5451	2.5008

Tabelle A.6: Decidability bei einer feinen Suche nach den optimalen Abmessungen der Überdeckungen für das obere Augenlid, mit $x_{xs} = 340, y_{ys} = 170, x_{ul} = 7\%, y_{ul} = 76\%, n_s = 2, p_{EV} = 1, n_{eyes} = 1$



Abbildung A.7: Intraclass-Mittelwert bei verschiedener Anzahl von Shifts bei optimalen Parametersetzungen



Abbildung A.8: Intraclass-Standardabweichung bei verschiedener Anzahl von Shifts bei optimalen Parametersetzungen

	IntercMean	IntracMean	IntercStdabw.	IntracStdabw.	Decidability
0	3302	1913	635	562	2.4184
1	3316	1856	638	552	2.4457
2	3332	1778	637	538	2.6174
3	3336	1788	637	565	2.5860
4	3336	1799	638	595	2.4895
5	3336	1798	638	605	2.4709
6	3334	1801	639	625	2.4243
7	3334	1803	639	626	2.4173
8	3335	1806	640	629	2.4096
9	3337	1822	641	642	2.3598
10	3336	1820	641	639	2.3667

Tabelle A.7: Auswirkung von Shifts auf verschiedene Optimierungsmaßzah-	
len bei optimalen Parametersetzungen	



Abbildung A.9: Inter- und Intraclass-Verteilungen bei steigender Anzahl von Augen fürs Enrollment und optimalen Parametersetzungen

	IntercMean	IntracMean	IntercSt.	IntracSt.	Decidability	FRR	FAR
1	3380	1538	638	352	3.3884	0.00%	11.58%
2	2954	1158	641	266	3.6561	0.00%	9.47%
3	2826	1017	652	248	3.6621	0.00%	0.00%
4	2749	919	657	218	3.7306	0.00%	0.00%

Tabelle A.8: Anzahl der Augen für das Enrollment vs. verschiedene Optimierungsmaßzahlen bei optimalen Parametersetzungen

PoV	Anzahl d. EV	Prozent d. EV	FRR	FAR
95.00%	202	70.88%	0.00%	3.16%
95.50%	208	72.98%	0.00%	2.11%
96.00%	215	75.44%	0.00%	2.11%
96.50%	222	77.89%	0.00%	2.11%
97.00%	229	80.35%	0.00%	2.11%
97.50%	236	82.81%	0.00%	2.11%
98.00%	244	85.61%	0.00%	1.05%
98.50%	253	88.77%	0.00%	1.05%
99.00%	262	91.93%	0.00%	1.05%
99.50%	273	95.79%	0.00%	1.05%
99.60%	275	96.49%	0.00%	1.05%
99.70%	277	97.19%	0.00%	0.00%
99.80%	280	98.25%	0.00%	0.00%
99.90%	282	98.95%	0.00%	0.00%
100.00%	285	100.00%	0.00%	0.00%

Tabelle A.9: Prozent der erklärten Varianz v
s. FRR und FAR bei optimalen Parametersetzungen

Literaturverzeichnis

- [Cas98] M. Casey. Auditory Group Theory with Applications to Statistical Basis Methods for Structured Audio. Master's thesis, University of East Anglia, 1990 Norwich, U.K., 1998. pages 43
- [Dau93] J. Daugman. High confidence visual recognition of persons by a test of statistical independence. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 15, No. 11 1993. pages 18
- [Dau94] J. Daugman. Biometric personal identification system based on iris analysis. United States Patent. Patent No. 5.291.560, 1994. pages 18
- [Dau02] J. Daugman. How iris recognition works. Proceedings of 2002 International Conference on Image Processing, 1, 2002. pages 16, 17, 18, 33, 37, 60, 67, 79
- [Hot33] Harold Hotelling. Analysis of complex statistical variables into principal components. Journal of Educational Psychology, 24:417–441, 1933. pages 41
- [Lex93] Meyers Lexikonredaktion. Meyers neues Lexikon. Meyers Lexkonverlag, 1993. pages 16
- [Lim01] S. Lim. Efficient iris recognition through improvement of feature vector and classifier. *ETRI Journal*, 23, No. 2 2001. pages 11, 18, 21, 22, 37, 67
- [Mas03] L. Masek. Recognition of human iris patterns for biometric identification. Master's thesis, University of Western Australia, School of Computer Science and Software Engineering, 2003. pages 73
- [Noh02] S. Noh. Multiresolution independent component analysis for iris identification. The 2002 International Technical Conference on Circuit Systems, Computers and Communications. Phuket, Thailand, 2002. pages 18, 19

- [oSIoA05] Chinese Academy of Science Institute of Automation. http://www.sinobiometrics.com. CASIA Iris Image Database, 2005. pages 59, 64
- [Rob04] UTCS Robotics. Mahalanobis Distance. No Author given, 2004. pages 52
- [Tis02] C. Tisse. Person identification technique using human iris recognition. International Conference on Vision Interface Canada 2002, 2002. pages 21
- [Umb99] S. Umbaugh. Computer Imaging: Digital Image Analysis and Processing. CRC Press, 1999. pages 29
- [Way02] J. Wayman. Biometrics and how they work. San Jose State University, 2002. pages 17
- [WB98] B. Boashash W.W. Boles. A human identification technique using images of the iris and wavelet transform. *IEEE Trans. Signal Processing*, 46:1185–1188, No. 4 1998. pages 18, 67
- [Wil97] R. Wildes. Iris recognition: an emerging biometric technology. *Proceedings of the IEEE*, 85, No. 9 1997. pages 17, 18, 21, 81
- [Wol76] E. Wolff. Anatomy of the Eye and Orbit. H.K. Lewis & Co. LTD., 7th edition, 1976. pages 17
- [You04] David Young. Computer Vision: Lecture 6: The Hough Transform. Lecture Notes, 2004. pages 11, 34, 35, 36
- [Zhu99] Y. Zhu. Biometric personal identification system based on iris patterns. Chinese Patent Application, No. 9911025.6, 1999. pages 21

Lebenslauf

Persönliche Daten

Name	Matthias Schmidl
Geburtstag	15. Oktober 1980
Geburtsort	Kirchdorf an der Krems, Österreich
Staatsbürgerschaft	Österreich

Bildung

2000–jetzt	Student der Informatik	Johannes-Kepler Universität Linz
1999 - 2000	Zivildienst	Rotes Kreuz Kirchdorf/Krems
1991 - 1999	Gymnasium	Bundesrealgymnasium Kirchdorf/Krems
1987 - 1991	Volksschule	Volksschule II, Kirchdorf/Krems
1986 - 1987	Vorschule	Volksschule II, Kirchdorf/Krems

Arbeitserfahrung

2000–2003 Ars Electronica Center, Linz

Eidesstattliche Erklärung

Ich erkläre an Eides statt, dass ich die vorliegende Diplom- bzw. Magisterarbeit selbstständig und ohne fremde Hilfe verfasst, andere als die angegebenen Quellen und Hilfsmittel nicht benutzt bzw. die wörtlich oder sinngemäß entnommenen Stellen als solche kenntlich gemacht habe.

Linz, den 8. März 2005

Matthias Schmidl

Kolophon

Dieses Dokument wurde mit Aleksander Simoncics WinEd
t 5.3^1 unter Verwendung von ${\rm IAT}_{\rm E} X\, 2_{\mathcal{E}}$ und pdfe
T_{\rm E} X von Christian Schenk's MikT_{\rm E} X 2.2^2 auf einem Intel Centrino 1500 MHz unter Windows 2000 erstellt.

Einige Abbildungen wurden mit Alexander Larsons DIA^3 erstellt.

Die folgenden $\Bbbk\!\!\!AT_{\rm E}\!X$ Pakete wurden zum Erstellen dieses Dokuments und des finalen PDFs verwendet:

$\operatorname{amsmath}$	American Mathematical Society	$\operatorname{inputenc}$	Alan Jeffrey, Frank Mittelbach
babel	Johannes Braams	multicol	Frank Mittelbach
backref	David Carlisle, Sebastian Rahtz	pdfpages	Andreas Matthias
color	David Carlisle	psfig	Trevor Darrell
graphicx	David Carlisle	subfigure	Steven Cochran
hypcap	Heiko Oberdiek	relsize	Donald Arseneau, Matt Swift
hyperref	Heiko Oberdiek, Sebastian Rahtz	varioref	Frank Mittelbach

 $^{^{1}}$ http://www.winedt.com

²http://www.miktex.org

³http://www.gnome.org/projects/dia