

Universität Karlsruhe  
Institut für Technische Informatik  
Prof. R. Dillmann  
in Zusammenarbeit mit:  
Institut für Theoretische Informatik  
Prof. A. Waibel

Diplomarbeit

# Utilizing Illumination Classification For Robust Face Recognition

(Deutsche Kurzfassung)

Daniella Kern

August 2005

Betreuer: Prof. R. Dillmann  
Prof. A. Waibel  
M.Sc. H. K. Ekenel



Hiermit versichere ich, die vorliegende Diplomarbeit persönlich und ohne unzulässige Hilfsmittel angefertigt zu haben. Alle verwendeten Quellen sind im Literaturverzeichnis aufgeführt.

Karlsruhe, August 2005

Danielle Kern



## Zusammenfassung

Die vorliegende Arbeit zeigt ein System zur Gesichtserkennung, das vorheriges Wissen um die Beleuchtungsrichtung nutzt. Dazu muss mit Hilfe eines Clusteringverfahrens herausgefunden werden, welche Lichtrichtungen für diesen Zweck geeignet sind. Daraus ergibt sich, dass die Bilder der Gesichter in 3 Klassen geclustert werden, die drei dominante Lichtrichtungen darstellen. Dies sind frontal beleuchtete, von rechter und von linker Seite beleuchtete Bilder. Diese Beobachtung führt zu zwei grundlegenden Erkenntnissen. Zum ersten bestätigt es, dass die Beleuchtung die Hauptursache der Unterschiedlichkeit im Aussehen eines Gesichtes unter einer festen Kopfhaltung ist. Zweitens ist der Effekt der Beleuchtung auf dem Gesicht fast identisch, auch wenn die Lichtquelle zwar auf derselben Gesichtseite, aber mit unterschiedlichen Winkeln zum Gesicht angebracht ist. Dies ist auf die Symmetrie des Gesichtes mit der Symmetrieachse entlang der Nase zurückzuführen. Die durch das Clustern gewonnene Information wird zum Klassifizieren neuer Daten verwendet. Die Gültigkeit der beobachteten Cluster wird durch die Güte der Klassifikation der Lichtrichtungen bestätigt. Bei der eigentlichen Identifizierung des Bildes wird zusätzlich die Information der Lichtrichtung verwendet. Es wurden drei Arten von Ansätzen getestet, die dieses Wissen zum Vorteil nutzen. Das sind die Vorbearbeitung des Bildes entsprechend der Lichtrichtung vor der Identifizierung, die Identifikation der Bilder innerhalb der Beleuchtungsklassen und die Kombination beider Ansätze. Die vorgestellten Algorithmen werden auf drei verschiedenen Datenbanken getestet, Yale Database, die Illumination und Lighting Subsets von CMU PIE Database und die UKA ISL Roboter Datenbank. Die Ergebnisse der Experimente zeigen, dass die zusätzliche Information der Lichtrichtung die Erkennungsrate der Gesichtserkennung signifikant erhöht.



# Inhaltsverzeichnis

<b>1. EINLEITUNG</b>	<b>1</b>
1.1 Literaturüberblick	1
<b>2. GESICHTSERKENNUNG UNTER ZUHILFENAHME DER KENNTNIS DER LICHTRICHTUNG</b>	<b>2</b>
<b>3. ERLÄUTERUNG DER ALGORITHMEN</b>	<b>7</b>
3.1 Bestimmung der Beleuchtungsklasse	7
3.1.1 Beleuchtungsklassifikation ohne Datenkompression	7
3.1.2 Beleuchtungsklassifikation mit PCA	8
3.1.3 Normalverteilungsklassifikation	8
3.2 Identifikation mit Nutzen der Beleuchtungsklassen	9
3.2.1 Identifikation innerhalb der Beleuchtungsklassen	9
3.2.2 Vorbereitung für seitlich beleuchtete Bilder von Gesichtern	11
3.2.3 Kombination von Identifikation innerhalb der Beleuchtungsklassen und Vorbereitung	12
3.2.4 Experimente zum Vergleich	13
<b>4. AUSWERTUNG DER EXPERIMENTE</b>	<b>14</b>
4.1 Experimente mit CMU PIE Database	14
4.1.1 Ergebnisse des K-Means-Clusterings	14
4.1.2 Ergebnisse der Beleuchtungsklassifikation	16
4.1.3 Gesichtserkennungsergebnisse der CMU PIE Database	17
4.2 Experimente mit der Roboter Datenbank	19
4.2.1 Konstruktion der Datenbank	19
4.2.2 Tests mit automatisch gefundenen Gesichtern	20
4.2.3 Tests mit manuell ausgerichteten Bildern von Gesichtern	23
<b>5. SCHLUSSFOLGERUNGEN</b>	<b>26</b>
<b>A. ERGEBNISSE DES K-MEANS CLUSTERING AUF CMU PIE DATABASE I</b>	
<b>TABELLEN- UND ABBILDUNGSVERZEICHNIS</b>	<b>XXIII</b>
<b>LITERATURVERZEICHNIS</b>	<b>XXIV</b>





## 1. Einleitung

Die Idee, die zu dieser Arbeit führte, war die Vision eines Roboters, der die Korridore des Universitätsgebäudes entlang fährt und nach Personen Ausschau hält. Ist eine Person gefunden, fährt der Roboter auf sie zu und identifiziert sie, um dann Hilfe anbieten zu können oder als Wächter zu agieren.

Für dieses Szenario werden verschiedene Funktionen benötigt. Der Roboter muss entlang definierter Routen fahren können, er muss Gesichter von Personen finden und diese dann erkennen. Zwei dieser drei Funktionen existieren bereits in einer Form, in der sie für den Roboter zu benutzen sind, nämlich das zusammenstoßfreie Fahren und das Auffinden frontaler Gesichter. Der Gesichtserkennungsmodul muss noch erstellt werden in Form eines Moduls, das als Input das Gesicht und als Output dessen Identität hat.

In dieser Arbeit wird das Modul eines Gesichtserkenners erarbeitet, der besonders unempfindlich gegen Beleuchtungsänderungen ist, da ein fahrender Roboter zwangsläufig mit verschiedenen Beleuchtungen konfrontiert wird. Zusätzlich wird die Existenz eines frontalen Bildes des Gesichts vorausgesetzt, da der Roboter auf die Personen zufährt und diese zwangsläufig ein bewegtes Objekt direkt ansehen. Der Algorithmus soll mit zweidimensionalen Bildern arbeiten, eine dreidimensionale Gesichtserkennung wird nicht vorgenommen.

### 1.1 Literaturüberblick

Einer der ältesten und immer noch aktuellen Ansätze in der Gesichtserkennung ist Turks und Pentlands Eigenfaces Algorithmus. Dieser ist auch für diese Arbeit die Grundlage aller Algorithmen. Er basiert auf Hauptkomponentenanalyse (HKA, auch principal component analysis, PCA) [5] und wird für diese Arbeit als bekannt vorausgesetzt.

In [1] experimentierten Adini et al. mit Gesichtserkennung unter wechselnden Beleuchtungsbedingungen, dabei brachte keiner ihrer Ansätze die gewünschte Unempfindlichkeit gegen Änderungen in der Beleuchtung. Sie fanden heraus, dass die Varianz in der Erscheinung einer Person unter verschiedenen Lichtbedingungen größer ist, als die Varianz verschiedener Personen unter der gleichen Lichtbedingung [1]. Dies ist eines der größten Probleme in der Gesichtserkennung.

## 2. Gesichtserkennung unter Zuhilfenahme der Kenntnis der Lichtrichtung

Das Ergebnis von Adini et al. [1] dient als Ausgangspunkt für die Entwicklung des hier vorgestellten Gesichtserkenners. Ein Gesichtserkennung muss das Gesicht einer Person unter einer bestimmten Beleuchtung erkennen können, obwohl es dem Gesicht einer anderen Person unter derselben Beleuchtung ähnlicher sieht als dem Gesicht der richtigen Person unter anderen Beleuchtungsbedingungen. Da die Kopfhaltung als fest angenommen wird, ist die größte Quelle von Varianz in dem Erscheinungsbild des Gesichtes die Beleuchtung. Auf dieser Basis wurde eine Methode zur Gesichtserkennung entwickelt.

In dem hier entwickelten Algorithmus wird die Varianz durch Beleuchtung bewusst nicht vermieden oder minimiert, außerdem versucht der Algorithmus nicht die subdominante Varianz in Identität innerhalb der dominanten Varianz in der Beleuchtung zu finden. Ganz im Gegenteil wird versucht, Adinis Ergebnisse zum Vorteil zu verwenden. Zuerst werden die verschiedenen Arten der Beleuchtung herausgefunden und ein Klassifikationsalgorithmus wird erstellt, der Bilder von Gesichtern nach den gelernten dominanten Lichtrichtungen klassifiziert.

Bei allgemeingültiger Betrachtung von Klassifikationen gilt das Gesetz [4]

$$V_{\text{intra-class}} + V_{\text{inter-class}} = V_{\text{total}} \quad (2.1)$$

wobei  $V_{\text{intra-class}}$  die Intraklassenvarianz,  $V_{\text{inter-class}}$  die Interklassenvarianz und  $V_{\text{total}}$  die Gesamtvarianz beschreibt. Ein Beispiel für den Zusammenhang zwischen  $V_{\text{total}}$ ,  $V_{\text{intra-class}}$  und  $V_{\text{inter-class}}$  und welche Objekte einer zufällige Menge benötigt werden, um diese Werte zu berechnen, gibt Abb. 2.1.

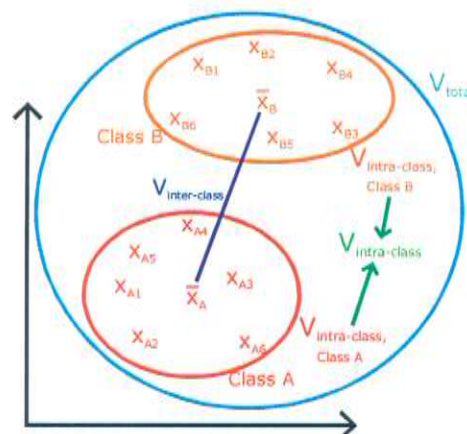


Abb. 2.1: Ein Beispiel für die Relation zwischen  $V_{\text{total}}$ ,  $V_{\text{intra-class}}$  und  $V_{\text{inter-class}}$

Diese statistische Theorie wird auf die Klassifikation von Gesichtern unter verschiedenen Lichtbedingungen übertragen. Durch die Klassifikation wird der Raum aller Bilder in Klassen mit ähnlich beleuchteten Gesichtern aufgeteilt. Aufgrund dieser Aufteilung ist innerhalb jeder Klasse die Varianz der Beleuchtung kleiner. Interklassenvarianz und

Intraklassenvarianz können berechnet werden. Da nun mit Bildern von Gesichtern gearbeitet wird, kann die Information, welches Gesicht zu welchem Individuum gehört genutzt werden, um zwei weitere Arten der Varianz zu berechnen. Die eine ist die intra-individuelle Varianz, welche die Variation in den verschiedenen Erscheinungsbildern des Gesichts einer Person beschreibt. Die zweite Varianz ist die inter-individuelle Varianz; sie beschreibt die Variationen im Erscheinungsbild von Gesichtern verschiedener Individuen. Im Moment existiert keine offensichtliche Verbindung zwischen intra-individueller/inter-individueller Varianz und Intraklassen-/Interklassenvarianz. Diese Relation wird im nächsten Schritt untersucht.

Nimmt man an, dass unter einer festen Kopfhaltung die einzige Quelle intra-individueller Varianz die Beleuchtung ist, so gilt

$$V_{\text{intra-individual}} = V_{\text{illumination}} \quad (2.2)$$

Diese Annahme ist sinnvoll, da bekannt ist, dass unterschiedliche Gesichtsausdrücke keine großen Variationen hervorrufen, solange der Gesichtsausdruck nicht übertrieben ist. Zusätzlich nimmt man an, dass die inter-individuelle Varianz nur durch die Variationen der Beleuchtung sowie die unterschiedlichen Identitäten verursacht wird

$$V_{\text{inter-individual}} = V_{\text{illumination}} + V_{\text{identity}} \quad (2.3)$$

Zur näheren Erklärung wird eine weitere Annahme getroffen, dass  $V_{\text{illumination}}$  strikt  $V_{\text{identity}}$  dominiert. Dann wird jede gute Klassifikationsmethode die Gesamtvarianz  $V_{\text{total}}$ , die  $V_{\text{inter-individual}}$  entspricht, in  $V_{\text{illumination}}$ , welche der Zwischenklassenvarianz entspricht, und  $V_{\text{identity}}$ , entsprechend der Innerklassenvarianz, aufteilen. Doch eine strikte Dominanz ist für das verwendete Modell keine haltbare Annahme, deshalb wird diese letzte Annahme zurückgenommen und in eine schwache Dominanz umgewandelt. Dies entspricht der Aussage, dass die durch Beleuchtung verursachte Varianz,  $V_{\text{illumination}}$ , größer ist als die Varianz durch Identität,  $V_{\text{identity}}$ . Unter der Annahme schwacher Dominanz ergibt eine Klassifikation, dass  $V_{\text{intra-class}}$  und  $V_{\text{inter-class}}$  nicht gleich  $V_{\text{identity}}$  und  $V_{\text{illumination}}$  sind, sondern nur Schätzwerte für diese ergeben. Diese Theorie ist graphisch in Abb. 2.2 dargestellt.

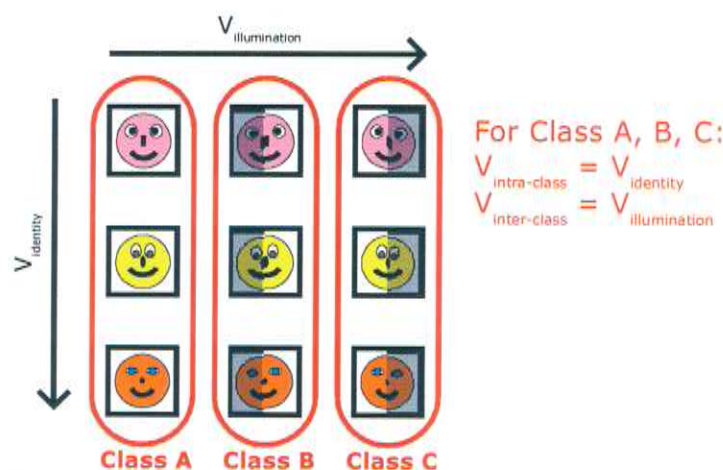


Abb. 2.2: Ein Beispiel für die Relation zwischen  $V_{\text{illumination}}$ ,  $V_{\text{identity}}$ ,  $V_{\text{intra-class}}$  und  $V_{\text{inter-class}}$

Zusammenfassend kann man sagen, wenn die Varianz der Beleuchtung die Varianz durch verschiedene Identitäten dominiert, dann teilt ein guter Klassifikationsalgorithmus die Menge der Bilder von Gesichtern auf diese Weise, dass  $V_{\text{intra-class}}$  ein Schätzer für  $V_{\text{illumination}}$ , und  $V_{\text{inter-class}}$  ein Schätzer für  $V_{\text{identity}}$  wird. Das heißt, innerhalb einer Klasse kann man erwarten, dass die intra-individuelle Varianz kleiner wird als die inter-individuelle Varianz, weil die Variationen, die durch Beleuchtung verursacht werden, von den Variationen durch verschiedene Identitäten getrennt werden.

Innerhalb einer Beleuchtungsklasse wird  $V_{\text{illumination}}$ , was gleich  $V_{\text{intra-individual}}$  ist, vernachlässigbar klein und deshalb wird  $V_{\text{inter-individual}}$ , welches die Summe von  $V_{\text{illumination}}$  und  $V_{\text{identity}}$  ist, nur durch  $V_{\text{identity}}$  erzeugt. Es ist für jede Klasse bekannt, dass

$$V_{\text{intra-individual}} < V_{\text{inter-individual}} \quad (3.4)$$

Innerhalb einer Klasse kann die Zwischenklassenvarianz, die ein Schätzwert für  $V_{\text{intra-individual}}$  ist, von der weiteren Betrachtung ausgeschlossen werden. Das Ergebnis sind Klassen, die die Beleuchtung der Bilder darstellen, sog. Beleuchtungsklassen. Dies ist natürlich nur eine ideale Anwendung der Theorie auf die Bilder von Gesichtern, trotzdem beweisen die Experimente die Gültigkeit dieser Annahme.

Nachdem nun die Beleuchtungsarten klassifiziert werden und die Varianz der Beleuchtung von der durch verschiedene Identitäten erzeugten Varianz getrennt werden, können die Gesichter selbst identifiziert werden.

Zur Identifikation wird nicht nur das Bild des Gesichtes, was die Standardinformation für Gesichtserkennung ist, sondern auch die Information über die Beleuchtungsklasse des Bildes verwendet. Die zusätzliche Information über die Beleuchtungsklasse des Bildes soll die Erkennungsrate des Algorithmus erhöhen.

Es gibt zwei unterschiedliche Methoden, die Information der Beleuchtungsklasse bestmöglich für die Identifikation zu nutzen.

Der erste Ansatz, diese Information zu nutzen, ist es die Gesichter innerhalb der Beleuchtungsklassen zu identifizieren. Für jede Klasse wird ein unabhängiger Gesichtserkennungsentwickler entwickelt, der speziell die Gesichter aus dieser Beleuchtungsklasse erkennt. Dabei heißt unabhängiger Algorithmus für jede Klasse nicht, dass für jede Klasse ein unterschiedlicher Algorithmus verwendet werden muss. Die Art des Algorithmus kann durchaus gleich sein, z.B. Eigenfaces Algorithmus, aber die Trainingsdaten für jede Klasse müssen entsprechend angepasst werden. Also wird jeder Algorithmus mit Trainingsdaten nur aus seiner Klasse trainiert. Für die Identifikation bestimmt die Beleuchtungsklasse den Algorithmus, der das Bild bearbeiten soll. Jeder Algorithmus ist deshalb so konstruiert, dass er genau mit den Beleuchtungsbedingungen seiner Klasse zurechtkommt. Durch diese Spezialisierung kann jeder Algorithmus die Erkennungsrate innerhalb seiner Klasse erhöhen und dadurch die gesamte Erkennungsrate verbessern.

Die zweite Möglichkeit, die Information der Beleuchtungsklassen zu nutzen, ist es, diese zur Entfernung des Effekts der Beleuchtung zu nutzen und danach klassische Gesichtserkennungsmethoden anzuwenden. Den Effekt der Beleuchtung auf dem Bild eines Gesichtes kann man als eine Art der Vorbearbeitung sehen, die vor der eigentlichen Gesichtserkennung stattfindet. Mit Kenntnis der Lichtrichtung, d.h. der Beleuchtungs-

klasse, kann diese Vorbearbeitung effektiver ausgeführt werden. Es ist bekannt, welche Arten der Veränderung bestimmte Beleuchtungsarten hervorrufen. Zum Beispiel erzeugt Licht von der Seite eine helle und eine dunkle Hälfte des Gesichts mit einem linearen Verlauf von der hellen zur dunklen Seite, zusätzlich entsteht ein Schlagschatten durch die Nase. Deshalb kann die Vorbearbeitung sich auf diese spezifischen Änderungen im Gesicht konzentrieren. Auf diese Weise wird nur die richtige Art der Vorbearbeitung gewählt und auch nur im notwendigen Ausmaß, um den Einfluss der Beleuchtung zu verringern. Dies stellt sicher, dass keine nützliche Information durch die Vorbearbeitung zerstört wird, was zu hohen Erkennungsraten der Gesichtserkennung führt.

Zudem ist es möglich, diese zwei genannten Ansätze zu einem dritten zu kombinieren. Dieser wird hier nicht gesondert aufgelistet, da es einfach die Anwendung beider Ansätze hintereinander ist. Zuerst werden die Bilder ihrer Beleuchtungsklasse entsprechend vorbearbeitet, analog des zweiten Ansatzes, danach werde sie innerhalb ihrer Beleuchtungsklasse mit einem speziellen Algorithmus identifiziert, was die Idee des ersten Ansatzes ist.

Besonders für die erste Art von Ansätzen werden Trainingsdaten von jeder Beleuchtungsklasse benötigt. Wenn nun aber für eine Person keine Trainingsdaten unter einer bestimmten Beleuchtung vorhanden sind, so wird ein Bild dieser Person unter der fehlenden Beleuchtungsart immer als das einer anderen Person identifiziert, die ein Trainingsbild unter der Beleuchtungsart besitzt. Man kann natürlich nicht immer voraussetzen, Trainingsbilder von allen Beleuchtungsklassen und Personen zu haben. Abhängig von der Art, wie die Trainingsdaten erzeugt werden, könnte nicht jede Person unter jeder Beleuchtungsbedingung gesehen werden. Deshalb muss ein Weg gefunden werden, wie Bilder aus einer Beleuchtungsklasse verwendet werden können, um Bilder einer anderen Beleuchtungsklasse zu identifizieren. Das Mittel dazu kann die Vorbearbeitung erfüllen. Es gibt eine Form der Vorbearbeitung, die individuelle Informationen über die Person auf dem Bild herauszieht und dabei die Information über die Beleuchtung entfernt. Diese Vorbearbeitung ist eine Konzentration auf die Konturen eines Gesichtes, ebenso wie die vertikalen oder horizontalen Linien des Gesichts, das in [9] verwendet wurde.

Das Modell des Gesichtserkenners, der in dieser Arbeit entwickelt wurde, basiert auf zwei Schritten (Abb. 2.3). Die Eingabe für den ersten Schritt ist das Bild eines frontalen Gesichtes. Der erste Schritt ist ein Klassifikationsalgorithmus, der die Beleuchtungsklasse, d.h. die Lichtrichtung, des Bildes bestimmt. Der zweite Schritt ist der Gesichtserkennner selbst, der auf eine der beiden beschriebenen Arten kreiert wird. Zusätzlich zu dem Bild erhält dieser die Information über die Beleuchtungsklasse des Bildes zur Bearbeitung. Um die effektivste Arbeitsweise des Algorithmus sicherstellen zu können, wird mindestens ein Trainingsbild pro Klasse und Person benötigt, d.h. ein Bild von jeder Person unter allen klassierten Beleuchtungsarten. Dieser Ansatz wird nun nach zwei Richtungen erforscht, die die Information der Lichtrichtung aus dem ersten Schritt nutzen:

- Der Gewinn an Erkennungsrate durch eine gute Auswahl an Trainingsbildern
- Das Problem von unzureichend vorhandenen Trainingsbilder zu überwinden

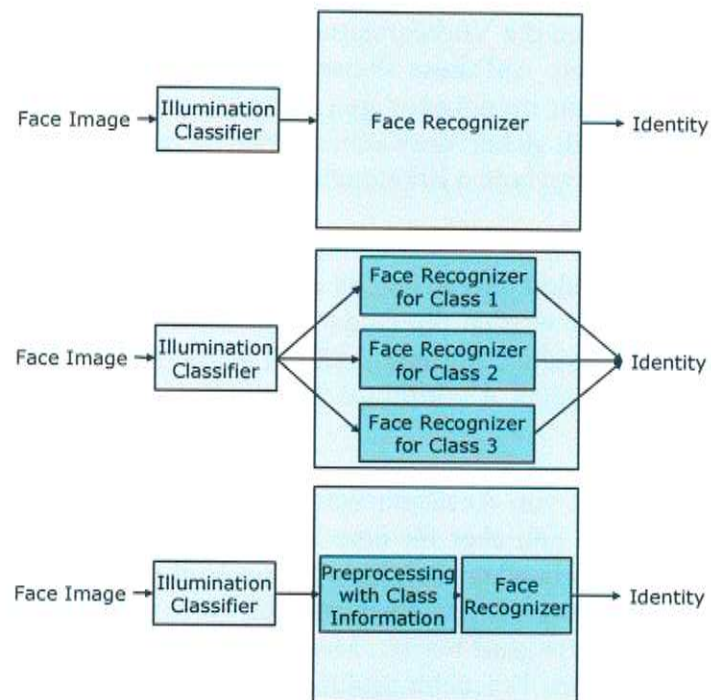


Abb. 2.3: Das Modell des Gesichtserkenners, basierend auf zwei Schritten (oben), mit Identifizierung in Klassen (Mitte), mit Vorbereitung (unten)

### 3. Erläuterung der Algorithmen

Im vorhergehenden Kapitel wurde die Idee dargestellt, wie die Leistung eines Gesichtserkenners verbessert werden kann, indem zuerst die Lichtrichtungen identifiziert werden. In diesem Kapitel wird nun die grobe Idee mit konkreten und detaillierten Algorithmen gefüllt. Die beiden Schritte der Methode, die Bestimmung der Beleuchtungsklasse und die Identifizierung des Gesichtes, werden geteilt und separat behandelt. In Kapitel 3.1 wird der erste Teil der Methode erläutert, in Kapitel 3.2 folgt dann der zweite Teil.

#### 3.1 Bestimmung der Beleuchtungsklasse

Der erste Schritt der Methode eines Gesichtserkennersystems ist die Bestimmung der Beleuchtungsklasse. Das bedeutet, die Bilder der Gesichter werden nach ihrer Beleuchtungsklasse klassifiziert. Hier entspricht jede Klasse einer Lichtrichtung. Deren Bestimmung kann auf verschiedene Weisen erfolgen. Im allgemeinen benötigen Klassifikationsalgorithmen die Information, wie die Bilder aussehen, d.h. speziell was die Bilder gemeinsam haben und in welchen Punkten sie sich unterscheiden. In statistischen Worten gesagt, der Algorithmus muss die Attribute der Objekte kennen, um sie klassifizieren zu können. Diese Information kann mit einer formalen Beschreibung, die alle Objekte einer Klasse erfüllen müssen gegeben werden, oder zum anderen mit einer Anzahl von Beispielen, anhand derer der Algorithmus die formale Beschreibung selbst herausliest. Hier erhalten drei verschiedene Ansätze diese Information durch Beispiele, also durch Trainingsbilder.

Die Beleuchtungsklassen, d.h. Lichtrichtungen, sind die Basis der präsentierten Algorithmen und müssen demnach sorgfältig gewählt werden. Um am besten zu entscheiden, was die betrachteten Lichtrichtungen sind, ist eine Analyse des Erscheinungsbildes der Lichtrichtungen notwendig. Unter der Annahme einer stetigen Änderung der Lichtrichtung im dreidimensionalen Raum muss eine Möglichkeit gefunden werden, wie die wichtigsten Lichtrichtungen zusammenzufassen sind. Die einfachste Möglichkeit die Lichtrichtungen zusammenzufassen, ist es Bilder von allen Arten der Beleuchtung zu clustern. Durch das Clustern werden die dominanten Lichtrichtungen gefunden. Zum Clustern wird der K-Means Algorithmus verwendet.

##### 3.1.1 Beleuchtungsklassifikation ohne Datenkompression

Der erste Ansatz zur Beleuchtungsklassifikation geht von der Repräsentation der Bilder als Punkte im  $n$  dimensionalen Raum aus. Dabei ist  $n$  die Anzahl der Pixel eines Bildes. Damit kann jede Klasse durch ihre statistischen Parameter beschrieben werden, wie z.B. Mittelwert oder Varianz.

Im ersten Schritt dieses Algorithmus werden für jede Klasse die Klassenmittelwerte aus den gegebenen Trainingsdaten einzeln berechnet. Um die Vergleichbarkeit aller Klassenmittelwerte zu gewährleisten, muss für jede Klasse die gleiche Anzahl an Trainings-

bildern verwendet werden, damit nicht durch eine unterschiedliche Anzahl implizit eine Wahrscheinlichkeitsverteilung zur Häufigkeit des Auftretens dieser Klasse angegeben wird. Um diese Wahrscheinlichkeit auszuschließen, wird für jede Klasse die gleiche Anzahl an Trainingsbildern verwendet, was einer Gleichverteilung, also einer neutralen Wahrscheinlichkeit, entspricht.

Im zweiten Schritt des Algorithmus werden die berechneten Klassenmittelwerte zur Klassifizierung neuer Daten verwendet. Ein  $n$  dimensionales Distanzmaß, hier die Euklidische Distanz, berechnet den Abstand zwischen einem neuen Bild mit den bestehenden Klassenmittelwerten. Danach werden die Distanzen verglichen und die minimale Distanz ausgewählt. Diejenige Klasse, deren Mittelpunkt die minimale Distanz zu dem neuen Bild hat, ist die Klasse, der dieses Bild angehört.

### 3.1.2 Beleuchtungsklassifikation mit PCA

Der zweite Ansatz versucht die Nachteile des ersten auszugleichen. Dieser Nachteil ist die hohe Rechenzeit, bedingt durch die hohe Pixelanzahl der Bilder. Aus diesem Grund wird die Dimension mit PCA verringert.

Im ersten Schritt werden die Trainingsdaten analog zum vorherigen Algorithmus gegeben, danach wird PCA gleichzeitig auf alle Trainingsdaten angewendet und die Daten werden rotiert. Danach werden wieder die Klassenmittelpunkte berechnet. Im zweiten Schritt wird ein neues Bild zuerst entsprechend den gefundenen Eigenwerten und Eigenvektoren gedreht, anschließend mit den vorhandenen Mittelwerten verglichen und der Klasse mit dem nächsten Mittelwert zugeordnet.

### 3.1.3 Normalverteilungsklassifikation

Der dritte Algorithmus zur Klassifikation berechnet die Mittelwerte sowie die Varianzen jeder Klasse. Auch dieser Algorithmus wird mit der gleichen Anzahl Bilder in jeder Klasse trainiert. Zuerst wird die Dimension mit PCA reduziert, danach mit den niedrigdimensionalen Daten der Mittelwertvektor  $\mu_i$  und der Varianzvektor  $\sigma_i$  von Klasse  $i$  berechnet. Der Varianzvektor wird noch zur Berechnung der Korrelationsmatrix  $V_i$  verwendet.

Mit diesen Daten wird für jede Klasse  $i$  eine Dichtefunktion  $\varphi_{\mu_i, \sigma_i}(x)$  einer Wahrscheinlichkeitsverteilung berechnet. Die Dichtefunktion, in Kurzschreibweise  $\varphi_i(x)$ , gibt die Wahrscheinlichkeit an, mit der Punkt  $x$  der Verteilung auf dieser Position liegt. Dies wird für alle Klassen durchgeführt und der Punkt, d.h. das Testbild, das zuvor mit PCA in der Dimension reduziert wurde, derjenigen Klasse zugeordnet, die am Wahrscheinlichsten ist. Formal geschrieben ist das:

$$x \in \text{Class } i \Leftrightarrow \varphi_i(x) > \varphi_j(x) \quad \forall j \neq i \quad (3.1)$$

Als Dichtefunktion wird die der mehrdimensionalen Normalverteilung (3.2) verwendet [2].



$$\varphi(x) = \frac{1}{|V| \cdot \sqrt{2 \cdot \pi}} \cdot e^{-\frac{1}{2} \cdot (x-\mu)^T \cdot V^{-1} \cdot (x-\mu)} \quad (3.2)$$

Formel (3.2) wird nun in Formel (3.1) eingesetzt und auf beide Seiten die Logarithmusfunktion angewendet (3.3). Die Umformung ist notwendig, um die Formel für einen Computer berechenbar zu machen.

$$\begin{aligned} x \in \text{Class } i &\Leftrightarrow \ln\left(\frac{1}{|V_i| \cdot \sqrt{2 \cdot \pi}}\right) + \left(-\frac{1}{2} \cdot (x - \mu_i)^T \cdot V_i^{-1} \cdot (x - \mu_i)\right) \\ &> \ln\left(\frac{1}{|V_j| \cdot \sqrt{2 \cdot \pi}}\right) + \left(-\frac{1}{2} \cdot (x - \mu_j)^T \cdot V_j^{-1} \cdot (x - \mu_j)\right) \quad \forall j \neq i \end{aligned} \quad (3.3)$$

Klasse  $i$ , die Formel (3.3) erfüllt, wird der Punkt  $x$ , hier das Testbild, zugeordnet.

## 3.2 Identifikation mit Nutzen der Beleuchtungsklassen

Nachdem die Beleuchtungsklasse der Bilder herausgefunden wurde, wird diese Information zusammen mit dem Bild zur Identifizierung des Bildes verwendet. Dies ist der zweite Schritt der Methode aus Kapitel 2, der auf drei verschiedene Arten stattfinden kann: Identifikation innerhalb der Klassen, Vorbearbeitung, und die Kombination von beidem. Von allen drei Arten werden Algorithmen im folgenden Teil vorgestellt.

### 3.2.1 Identifikation innerhalb der Beleuchtungsklassen

Identifikation innerhalb der Beleuchtungsklasse bedeutet, dass für jede Klasse ein unabhängiger Algorithmus verwendet wird, der trainiert wird, um speziell an die Beleuchtungsklasse angepasst zu werden.

#### 3.2.1.1 Eigenfaces Algorithmus für jede Beleuchtungsklasse

Dieser Algorithmus ähnelt demjenigen, den Pentland in [18] vorgestellt hat. Für jede Beleuchtungsklasse wird ein Eigenfaces Algorithmus mit Trainingsdaten aus der entsprechenden Beleuchtungsklasse trainiert. Die Trainingsdaten sind der einzige Unterschied zwischen den einzelnen Algorithmen. Ein Testbild wird anhand seiner Beleuchtungsklasse dem richtigen Eigenfaces Algorithmus zugeordnet und entsprechend identifiziert. Der Nachteil dieses Algorithmus ist, dass Trainingsdaten von jeder Person unter jeder Beleuchtungsbedingung benötigt werden. Der Vorteil ist, dass durch die Verwendung mehrerer Eigenspaces, wie die Bildräume der PCA-Funktion genannt werden, die Interklassenvarianz von der Betrachtung ausschließt und so die Intraklassenvarianz besser abbilden kann. Dieser Algorithmus heißt "Eigen for each class".

### 3.2.1.2 Gesichtserkennung mit der Hälfte des Gesichtes

Der zweite Algorithmus macht sich das Aussehen der Bilder zunutze, die nicht mit frontaler Beleuchtung aufgenommen wurden. Diese Bilder sind im Gegensatz zu den frontal beleuchteten Bildern nicht gleichmäßig hell, sondern weisen eine helle und eine dunkle Gesichtshälfte auf. Algorithmen, die Bilder anhand der Pixel vergleichen, werden durch diesen Umstand in die Irre geführt. Deshalb ist es sinnvoll nur die hellere Hälfte des Gesichts, die Seite ohne Einfluss der Beleuchtungsart zu verwenden, um die Bilder zu identifizieren. Auf diese Weise wird der Schlagschatten auf der dunkleren Gesichtshälfte ignoriert.

Dieser Algorithmus benötigt nur frontal beleuchtete Bilder als Trainingsdaten. Jede Hälfte des Bildes wird wie ein unabhängiges Bild betrachtet und diese drei Bilder zur Bildung dreier Eigenspaces verwendet, ein Eigenspace mit dem gesamten Bild, einer mit der linken und einer mit der rechten Bildhälfte. Im zweiten Schritt, dem Identifizieren der Testbilder, wird durch die Beleuchtungsklasse des Testbildes entschieden, ob das ganze oder nur die linke oder rechte Bildhälfte mit dem entsprechenden Eigenspace verglichen wird. Dieser Algorithmus heißt "Half Face Recognizer" und ist in Abb. 3.1 dargestellt.

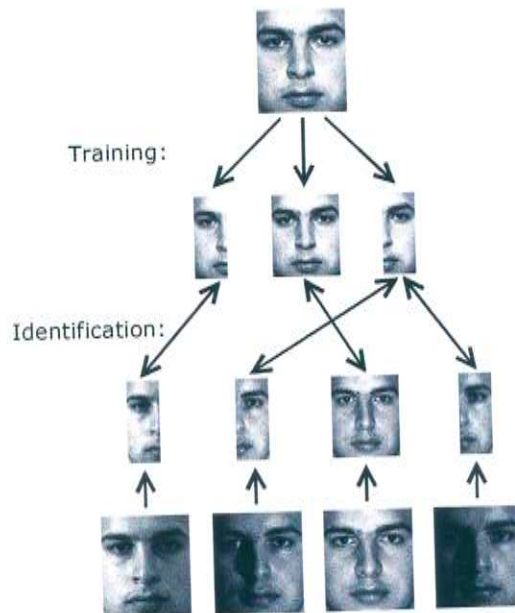


Abb. 3.1: Modell des Half Face Recognizer

### 3.2.1.3 Gesichtserkennung mit Spiegeleffekt

Der dritte Ansatz geht von der Annahme aus, dass nicht von allen möglichen aber von mehr als einer Beleuchtungsklasse Trainingsbilder vorhanden sind. Es wird die Annahme dreier Beleuchtungsklassen, d.h. Lichtrichtungen, getroffen, nämlich frontal, von links und von rechts beleuchtet, was sich bei den Experimenten als dominante Lichtrichtungen erweisen soll (Kapitel 4). Für diesen Gesichtserkennung werden Trainingsbilder der Lichtrichtungen frontal und links, oder aber frontal und rechts benötigt. Die Trainingsdaten der fehlenden Klasse werden durch Spiegelung der seitlich beleuchteten Bilder an der vertikalen Achse erzeugt. Mit den Trainingsdaten aller drei Klassen wird

jeweils ein Eigenspace erzeugt und die Testbilder mit dem Eigenspace entsprechend ihrer Beleuchtungsklasse identifiziert. Dieser Ansatz heißt "Eigen with Mirror" und ist in Abb. 4.2 schematisch dargestellt. Dieser Algorithmus setzt voraus, dass die Ähnlichkeit zwischen der linken und der rechten Gesichtshälfte einer Person größer ist als die Ähnlichkeit zwischen den Gesichtern zweier verschiedener Personen. Dies ist der Fall, weil durch die Spiegelung die Gesichtshälften für die Identifikation der fehlenden Beleuchtungsklasse vertauscht werden.

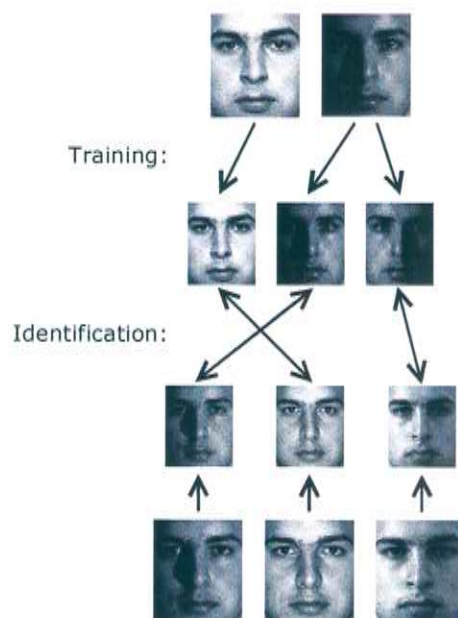


Abb. 3.2: Modell des Eigen With Mirror

### 3.2.2 Vorbereitung für seitlich beleuchtete Bilder von Gesichtern

Die Vorbereitung ist ein Zwischenschritt in der in Kapitel 3 dargestellten Methode, sie findet nach der Klassifikation der Lichtrichtung aber noch vor der eigentlichen Gesichtserkennung statt. Die Vorbereitung ist ein Mittel, um den Effekt der Beleuchtung auf einem Gesicht zu entfernen oder zumindest zu verringern. Durch die Beleuchtungsklasse wird angegeben, ob eine Vorbereitung notwendig ist oder nicht, damit auf diese Weise keine wichtige Information in dem Bild verloren geht.

Es wurde gezeigt [1, 8, 9], dass ein Bild bestehend aus horizontalen Linien eines Gesichtes weniger anfällig für Änderungen durch Lichtrichtungen ist als ein vollständiges Bild. Die horizontalen Linien sind der Teil des Gesichtsumrisses, der horizontal verläuft. Berechnet werden diese Linien durch die erste Ableitung der Pixel eines Bildes in vertikaler Richtung. Diese Ableitung erhält man durch eine Funktion mit Namen "Sobel", deshalb wird diese Art der Vorbereitung "den Sobel-Operator anwenden" genannt (Abb. 3.3).

Eine andere Art der Vorbereitung ist der Laplace-Operator. Dies Funktion berechnet die Summe der zweiten Ableitung in x- und y-Richtung eines Bildes. [11]. Das Ergebnis

des Operators sind die Umrisslinien des Gesichtes. Da sich Lichtänderungen auf die Flächen und weniger auf den Umriss eines Gesichtes auswirken, ist dieser Operator ebenfalls zu empfehlen (Abb. 3.3).




Abb. 3.3: Effekt des Laplace- und Sobel-Operators auf das Bild des Gesichtes

Diese beiden Vorbearbeitungsoperatoren werden in einen Standard Eigenfaces Algorithmus integriert. Zum Training werdend die frontal beleuchteten Trainingsbilder zusammen mit ihren bearbeiteten Gegenstücken verwendet, um einen Eigenspace zu bilden. Zum Identifizieren wird anhand der Beleuchtungsklasse des Testbildes ermittelt, ob eine Vorbearbeitung des Testbildes notwendig ist. Ist es frontal, wird die Vorbearbeitung übersprungen. Dann wird das Bild mit den Trainingsbildern verglichen. Dieser Ansatz heißt “Eigenfaces with Sobel” oder “Eigenfaces with Laplace”.

Ein dritter Vorbearbeitungsoperator ist die künstliche Generierung seitlich beleuchteter Bilder aus frontal beleuchteten Bildern. Die Beleuchtung wird mit einer linearen Funktion, die auf das Bild angewendet wird, generiert [20].

Der Effekt dieser Funktion ist in Abb. 3.4 dargestellt. Es ist eine spezielle Art der Vorbearbeitung, da sie nur im Trainingsschritt eines Algorithmus stattfinden muss, nicht aber im Testschritt. Aus diesem Grund müssen Algorithmen, die alle Beleuchtungsklassen zum Training benötigen, nicht für die Anwendung dieser Funktion geändert zu werden. Dadurch werden die Algorithmen “Eigen for each class with ArtIllu” und “Eigenfaces with ArtIllu” erzeugt.

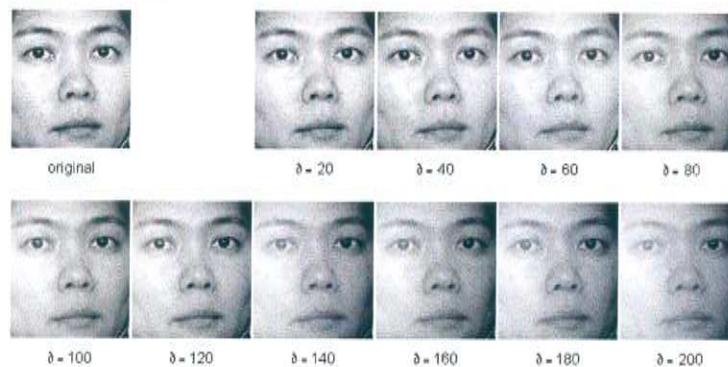


Abb. 3.4: Effekt der künstlichen Generierung von Beleuchtung

### 3.2.3 Kombination von Identifikation innerhalb der Beleuchtungsklassen und Vorbearbeitung

Die dritte Möglichkeit, die Information der Beleuchtungsklasse zu nutzen, ist die Kombination der ersten beiden Ansätze. Die Algorithmen “Eigen for each Class” und “Half

Face Recognizer" können mit den Vorbearbeitungsoperatoren Laplace und Sobel kombiniert werden. Daraus entsteht dann "Eigen for each class mit Sobel", "Eigen for each class mit Laplace", "Half Face mit Sobel" und "Half Face mit Laplace". Eine spezielle fünfte Kombination ist "Eigen for each class mit artificial illumination". Strenggenommen gehört dieser Algorithmus zu den Kombinationen, obwohl die Vorbearbeitung durch künstliche Generierung der Beleuchtung den Algorithmus nicht ändert.

### 3.2.4 Experimente zum Vergleich

Alle Algorithmen aus Kapitel 3.2.1 bis Kapitel 3.2.3 können nicht beurteilt werden, wenn nur bekannt ist, welche und wie viele Bilder sie richtig identifizieren. Sie müssen mit einem Standardalgorithmus verglichen werden. Dazu wird Standard Eigenfaces verwendet. Dieser kann auf unterschiedliche Arten trainiert werden. Die Trainingsdaten können ebenso wie die der anderen Algorithmen mit Kenntnis der Beleuchtungsklasse gewählt werden, d.h. Trainingsbilder aus jeder Klasse und von jeder Person. Die Bilder können auch ohne Kenntnis der Klassen zufällig gewählt werden, oder die Bilder werden, um unzureichend vorhandene Trainingsbilder darzustellen, nur aus einer Beleuchtungsklasse gewählt.

Tabelle 3.1: Überblick über alle Arten von Algorithmen aus Kapitel 3.2

Art der Methode	Algorithmus	Vorbearbeitung	Training
Identifizieren in Klassen	Eigen For Each Class		3 Klassen
	Mirror Front-Right		2 Klassen
	Mirror Front-Left		2 Klassen
	Half Face		1 Klasse (frontal)
Vorbearbeitung	Eigenfaces	Sobel	1 Klasse (frontal)
	Eigenfaces	ArtIllu	1 Klasse (frontal)
	Eigenfaces	Laplace	1 Klasse (frontal)
Kombination	Eigen For Each Class	Sobel	1 Klasse (frontal)
	Eigen For Each Class	ArtIllu	1 Klasse (frontal)
	Half Face	Sobel	1 Klasse (frontal)
	Eigen For Each Class	Laplace	1 Klasse (frontal)
	Half Face	Laplace	1 Klasse (frontal)
Vergleich	Eigenfaces		3 Klassen
	Eigenfaces		1 Klasse (frontal)
	Eigenfaces		1 Klasse (left)
	Eigenfaces		Zufall
	Eigenfaces		1 Klasse (right)

## 4. Auswertung der Experimente

Zum Testen der Theorie wurden drei Arten von Experimenten durchgeführt. Das erste ist ein Clusteringexperiment mit K-Means Clustering, um als Voraussetzung die Struktur der Beleuchtung zu erfassen. Das zweite ist der Test der Klassifikatoren der Beleuchtungsklassen und das dritte Experiment ist die eigentliche Gesichtserkennung. Durchgeführt wurden diese Tests mit zwei verschiedenen Datenbanken, Illumination und Lighting Subsets der CMU PIE Database und UKA ISL Roboter Datenbank.

### 4.1 Experimente mit CMU PIE Database

Um die Algorithmen zu testen, wurden die Illumination und Lighting Subsets der CMU Pose, Illumination, Expression Database (CMU PIE) [22] verwendet. Die Bilder zeigen frontal Gesichter mit neutralem Gesichtsausdruck. Das Gesicht ist auf das Bild eingepasst, die Augen befinden sich immer an der gleichen Position und der Hintergrund wurde entfernt. Die Subsets enthalten die Bilder von 68 Personen unter 45 vorgegebenen Beleuchtungsbedingungen.

#### 4.1.1 Ergebnisse des K-Means-Clusterings

Viele der 45 Beleuchtungsklassen sehen einander sehr ähnlich, deshalb ist ein Clustern notwendig, um die vorgegebenen Beleuchtungsklassen sinnvoll zusammenzufassen. Zum Clustern wurde der K-Means-Clustering Algorithmus verwendet. Um die Datenmenge handhaben zu können, wurde erst die Dimension mit Hilfe von PCA verringert. Die gewählten Parameter waren demnach: die Anzahl der Klassen  $k$  variiert von drei bis sieben, die Anzahl der Dimensionen durch PCA als vier und zehn, und jeweils zufällig gewählte Bilder als Startwerte für die Clustermittelpunkte.

Die Ergebnisse der Testläufe sind in Appendix A abgebildet. Die dortigen Tabellen zeigen die Häufigkeit der vorgegebenen Beleuchtungsklassen innerhalb der Cluster an.

Die einzelnen Testläufe mit drei, vier und fünf Clustern sind einander sehr ähnlich, bei sechs und sieben waren sie von den Startwerten abhängig. Daraus lässt sich schließen, dass die Ergebnisse bei drei und vier Clustern nahe dem globalen Optimum liegen. Die Variation der PCA-Dimension hatte keinen großen Effekt auf die Cluster selbst, einzig sind die Ergebnisse mit zehn Eigenvektoren einander ähnlicher als die mit vier Eigenvektoren, was auf eine höhere Qualität der Ergebnisse schließen lässt. Somit sind vier Eigenvektoren, die einer Erklärungsrate von 70% entsprechen, zu wenig um die Daten richtig abzubilden. Mit zehn Eigenvektoren liegt die Erklärungsrate bei 78%.

Bei Betrachtung der Verteilung der CMU-Klassen auf die Cluster (Appendix A) fällt auf, dass etwa 20% der Klassen komplett in einem Cluster sind, etwa 27% der Klassen immer über mehrere Cluster verteilt sind. Diese Klassen enthalten einander ähnliche, bzw. unähnliche Bilder. Daraus kann man schließen, dass die Bilder einer vorgegebenen Beleuchtungsklasse, die immer im gleichen Cluster sind, eine höhere Varianz in Be-

leuchtung als Varianz in Identität besitzen. Genau anders herum ist es für die Klassen mit unähnlichen Bildern. Aus Abb. 4.1 ist ersichtlich, dass Klassen mit ähnlichen Bildern von links oder rechts beleuchtete Bilder sind, während unähnliche Bilder frontal beleuchtet werden.



Abb. 4.1: Klassen mit ähnlichen (oben) und unähnlichen (unten) Bildern

Betrachtet man die Cluster selbst, so sieht man, dass die Bilder mit drei Clustern nach ihrer Beleuchtung klassifiziert werden. Ein Cluster enthält Bilder mit Beleuchtung von rechts, das zweite Bilder mit Beleuchtung von links und das dritte mit frontaler Beleuchtung (Abb. 4.2). Bei vier Clustern sind dies Beleuchtung von rechts, Beleuchtung von links und zwei Cluster mit frontaler Beleuchtung, die bei Betrachtung nicht eindeutig unterscheidbar sind (Abb. 4.3). Die dominanten Lichtrichtungen sind demnach Beleuchtung von vorn, rechts und links.



Abb. 4.2: Bilder einer Person in drei Cluster aufgeteilt




Abb. 4.3: Bilder einer Person in vier Cluster aufgeteilt

### 4.1.2 Ergebnisse der Beleuchtungsklassifikation

Mit diesen Ergebnissen werden nun die Beleuchtungsklassifikatoren trainiert. Zum Testen wird zuerst jede vorgegebene Beleuchtungsklasse der CMU PIE Database komplett in ein Cluster übernommen, und zwar in dasjenige, in dem beim Clustering die maximale Anzahl dieser Bilder war. Dies führt zu einem Fehler, der statistisch wieder herausgerechnet wird, allerdings ist auf andere Weise kein Test der Klassifikation möglich.

Die Parameter der Algorithmen (Kapitel 3.1) sind die Anzahl der Klassen (3 und 4), die Anzahl der Trainingsbilder pro Klasse (12 und 24), die Anzahl der PCA-Dimensionen (10) und die Entscheidung, ob eine Helligkeitsnormierung der Bilder durchgeführt werden muss oder nicht.

Tabelle 4.1 zeigt die Ergebnisse der Algorithmen gemittelt über alle gewählten Parameter, während der Effekt der Änderung der Parameter in Tabelle 4.2 dargestellt ist.

Tabelle 4.1: Gesamtklassifizierungsrate der Lichtklassifikationsalgorithmen

Bel.klass. ohne Datenkompr.	87,67%
Beleuchtungsklass. mit PCA	87,66%
Normalvert.klass.	65,41%

Tabelle 4.2: Klassifikationsrate der Lichtklassifikationsalgorithmen unter der Bedingung der verschiedenen Parameter

	Bel.klass. ohne Datenkompr.	Beleuchtungsklass. mit PCA	Normalvert.klass.
3 Klassen	88,47%	88,44%	65,36%
4 Klassen	86,88%	86,87%	65,47%
12 Bilder	88,48%	88,49%	64,58%
24 Bilder	86,86%	86,83%	66,25%
ohne Normierung	81,90%	81,83%	45,25%
mit Normierung	93,44%	93,48%	85,58%

Aus diesen Ergebnissen kann man sehen, dass die Wahl des Mittelwerts zum Klassieren der Bilder besser geeignet ist als die Anwendung einer Dichtefunktion. Obwohl der Lichtklassifikationsalgorithmus ohne Datenkompression leicht bessere Ergebnisse hatte, wird aufgrund der Rechenzeit dem Algorithmus mit PCA der Vorzug gegeben. Zur



weiteren Berechnung wird der Lichtklassifikationsalgorithmus mit PCA mit den besten Parametern gewählt.

### 4.1.3 Gesichtserkennungsergebnisse der CMU PIE Database

Im nächsten Schritt werden die Bilder identifiziert. Die zusätzlich benötigte Information der Beleuchtungsklasse erhält man durch Anwendung des Klassifikationsalgorithmus auf die Daten, wobei die besten Parameter gewählt werden. Die Parameter für die Gesichtserkennung müssen allerdings noch festgelegt werden. Das ist zum einen die Anzahl der Klassen. Sie wird auf drei festgelegt, wie oben beschrieben, da dies besten Ergebnisse in der Klassifikation lieferte. Da alle Algorithmen auf PCA basieren, muss die Dimension noch festgelegt werden. In [18] wurde die Benutzung von 20 Eigenvektoren empfohlen, dies wird übernommen und somit werden ca. 85% der Information der Bilder verwendet.

#### 4.1.3.1 Zusammenfassung der Gesichtserkennungsergebnisse in den Beleuchtungsklassen

Die Erkennungsrate derjenigen Algorithmen, die für jede Beleuchtungsklasse einen eigenen Eigenspace bilden, kann auch aufgeteilt auf die Klassen analysiert werden und somit erhält man für jede Klasse eine eigene Erkennungsrate. Der Mittelwert der Erkennungsrate für die drei Beleuchtungsklassen ergibt die Gesamterkennungsrate des Algorithmus, der Wert der mit den anderen Algorithmen verglichen werden kann. Alle Erkennungsraten im Überblick sind in Tabelle 4.3 abgebildet.

Tabelle 4.3: Ergebnisse der Gesichtserkennung einzeln für jede Beleuchtungsklasse

Algorithmus	Vorbearbeitung	Training	Art der Methode	Gesamtergebnis	Frontal performance	Left Performance	Right performance
Eigen For Each Class	Sobel	1 Klasse (frontal)	Kombination	79,06%	88,53%	<b>75,38%</b>	<b>70,73%</b>
Eigen For Each Class	Artlllu	1 Klasse (frontal)	Kombination	75,39%	88,53%	67,58%	67,58%
Eigen For Each Class	Laplace	1 Klasse (frontal)	Kombination	65,59%	88,53%	51,11%	52,64%
Half Face	Sobel	1 Klasse (frontal)	Kombination	74,12%	88,53%	65,92%	64,81%
Half Face	Laplace	1 Klasse (frontal)	Kombination	59,46%	88,53%	<b>39,12%</b>	45,65%
Eigen For Each Class	without	3 Klassen	Identifizieren in Klassen	82,39%	88,53%	<b>78,33%</b>	<b>78,19%</b>
Half Face	without	1 Klasse (frontal)	Identifizieren in Klassen	65,58%	88,53%	49,96%	54,17%
Mirror Front-Left	without	2 Klassen	Identifizieren in Klassen	71,48%	88,53%	<b>78,33%</b>	<b>44,24%</b>
Mirror Front-Right	without	2 Klassen	Identifizieren in Klassen	71,85%	88,53%	52,65%	<b>78,18%</b>

Für die frontal beleuchtete Klasse ist die Erkennungsrate für alle Algorithmen gleich, da diese Klasse in allen Fällen zum Training vorhanden war und deshalb der einfache Eigenfaces Algorithmus auf diese Klasse angewendet wurde. Waren Trainingsbilder aller Beleuchtungsklassen vorhanden, war "Eigen for each class" ohne Vorbearbeitung der beste Algorithmus. Es fällt auf, dass selbst mit vorhandenen Trainingsdaten die Ergeb-

nisse für die links und rechts beleuchteten Bilder etwa 10% schlechter waren als die frontal beleuchtete Klasse. Sind Trainingsbilder dieser Klassen nicht vorhanden, so ist der Sobel-Operator die beste Möglichkeit, den Missstand auszugleichen. Auch wenn zwei Beleuchtungsklassen zum Training vorhanden sind, ist es also besser, die fehlende Klasse durch Sobel-Vorbearbeitung zu ersetzen, als durch die gespiegelten Bilder der vorhandenen seitlich beleuchteten Klasse, auch wenn das Gesamtergebnis der "Eigen With Mirror" nicht schlechter ist als "Eigen for Each Class with Sobel".

#### 4.1.3.2 Zusammenfassung der Gesichtserkennungsergebnisse

Die durchschnittlichen Erkennungsraten aller getesteten Algorithmen sind in Tabelle 4.4 abgebildet. Der Unterschied in der Erkennungsrate zwischen Eigenfaces Algorithmus mit drei Klassen Trainingsdaten und Eigenfaces mit zufällig ausgewählten Trainingsdaten (Eigenfaces with random) beträgt etwa 30% und zeigt somit, wie wichtig die richtige Auswahl der Trainingsdaten für die Erkennungsrate des Algorithmus ist. Wird ein Eigenfaces Algorithmus nur mit einer Beleuchtungsklasse trainiert, so erzielt die frontal beleuchtete Klasse mit 65% Erkennungsrate die höchsten Werte. Das Ergebnis ist also besser, wenn mit frontal beleuchteten Bildern auch seitlich beleuchtete identifiziert werden als anders herum. Da die Testdaten etwa gleichmäßig auf alle Klassen verteilt waren, ist diese Aussage zulässig. Das beste Ergebnis erzielte "Eigen for each class" mit einer Erkennungsrate von 82,4%. Dieser Algorithmus setzt allerdings das Vorhandensein von Trainingsdaten aller Beleuchtungsklassen voraus. Ist dies nicht der Fall, so ist es am besten dies mit der Verwendung des Sobel-Operators auszugleichen. Der "Eigen for each class" Algorithmus mit Sobel-Operator erreicht eine Erkennungsrate von 79,1%, was das zweitbeste erreichte Ergebnis aller Algorithmen ist. Nach dem Sobel-Operator ist die künstliche Generierung von beleuchteten Bildern die zweitbeste Möglichkeit, das Fehlen von Trainingsdaten zu kompensieren. Der Laplace-Operator, sowie der "Half Face" Algorithmus sind weniger gut zum Ausgleich fehlender Trainingsdaten geeignet. Implizit wurde hierbei auch getestet, welche Art von Funktionen besser den Schatten auf einem Gesicht erzeugt bzw. beschreibt. Die Sprungfunktion, dargestellt durch den "Half Face" Algorithmus, ist schlechter dazu geeignet als die Lineare Funktion, die in der künstlichen Generierung von Licht dargestellt wurde.

Tabelle 4.4: Gesichtserkennungsergebnisse aller Algorithmen

Algorithmus	Training	Art der Methode	Gesamtergebnis
Eigen For Each Class	3 Klassen	Identifizieren in Klassen	82.39%
Eigen For Each Class with Sobel	1 Klasse (frontal)	Kombination	79.06%
Eigenfaces	3 Klassen	Vergleich	78.07%
Eigenfaces with Sobel	1 Klasse (frontal)	Vorbearbeitung	76.40%
Eigenfaces with Artillu	1 Klasse (frontal)	Vorbearbeitung	75.54%
Eigen For Each Class with Artillu	1 Klasse (frontal)	Kombination	75.39%
Half Face with Sobel	1 Klasse (frontal)	Kombination	74.12%
Mirror Front-Right	2 Klassen	Identifizieren in Klassen	71.85%
Mirror Front-Left	2 Klassen	Identifizieren in Klassen	71.48%
Eigen For Each class with Laplace	1 Klasse (frontal)	Kombination	65.59%
Half Face	1 Klasse (frontal)	Identifizieren in Klassen	65.58%
Eigenfaces	1 Klasse (frontal)	Vergleich	64.88%
Eigenfaces with Laplace	1 Klasse (frontal)	Vorbearbeitung	62.57%
Half Face with Laplace	1 Klasse (frontal)	Kombination	59.46%
Eigenfaces	1 Klasse (left)	Vergleich	51.24%
Eigenfaces	random	Vergleich	49.03%
Eigenfaces	1 Klasse (right)	Vergleich	48.40%

## 4.2 Experimente mit der Roboter Datenbank

### 4.2.1 Konstruktion der Datenbank

Die letzten Experimente wurden mit einer Datenbank durchgeführt, die mit Hilfe des Roboters gesammelt wurde, der später die Gesichtserkennungsalgorithmen verwenden soll. Dazu wurde der Roboter auf den Korridor gestellt und die Kamera wurde immer dann aktiviert, wenn jemand vorbeilief. Da der Roboter sich aber selbst nicht bewegte, war dieses Metallgestell zu unauffällig (Abb. 4.4), als dass die vorbeigehenden Personen direkt zum Roboter sehen würden. Deshalb wurde der Roboter auf künstlichem Wege interessant gemacht, indem er neu eingekleidet wurde und eine Maske als Gesicht bekam, um die Kamera als Augen identifizieren zu können (Abb. 4.5). Obwohl die Kamera Stereobilder liefern kann, war deren Verwendung nicht möglich, da Stereobilder nur in geringen Abstand korrekt aufgenommen wurden. Auf diese Möglichkeit musste allerdings verzichtet werden, weil eine geringe Distanz zwischen Roboter und Person nicht durchführbar war.

Da die Roboter Datenbank nicht unter strengen Bedingungen sondern frei aufgenommen wurde, kann die Qualität der Datenbank nicht so hoch sein, wie die der CMU PIE Database. Ein Problem war die schwache Beleuchtung auf den Korridoren, ein anderes die starken Unterschiede in der Auflösung der Gesichter auf den Bildern, die zwischen 35x45 Pixel und mehr als 100x100 Pixel schwankte. Ein zusätzliches Problem waren die häufig auftretenden Gegenlichtaufnahmen, die alle Gesichter zusätzlich verdunkelten.



Abb. 4.4: Unbekleideter Roboter



Abb. 4.5: Bekleideter Roboter

## 4.2.2 Tests mit automatisch gefundenen Gesichtern

Da die Kamera immer ein Bild des gesamten Umfelds liefert, muss das Gesicht auf diesem Bild noch mit Hilfe eines "Face Detectors", eines Algorithmus zum Auffinden der Gesichter, herausgesucht werden. Danach wurden die Gesichter manuell mit der Identitätsnummer der betreffenden Person markiert, in Graustufenbilder umgewandelt und auf Einheitsnorm normiert. Die Datenbank enthält daraufhin 892 Bilder von 30 Personen, wobei die Anzahl der Bilder pro Person stark schwankt.

### 4.2.2.1 K-Means Clustering Ergebnisse

Anders als bei der CMU PIE Database hat die Roboter Datenbank keine vorgegebenen Lichtklassen, deshalb ist ein Clustering notwendig. Die beim K-Means Clustering gewonnenen Lichtklassen werden als Vorgabe für die Bilder der Roboterdatenbank verwendet. Das Clustering wurde mit drei, vier und fünf Klassen durchgeführt, die Dimension der Bilder zuerst mit PCA auf 20 reduziert.

Die Ergebnisse des Clusterings wurden zuerst auf Stabilität hin betrachtet. Stabilität beim Clustering ist dann erreicht, wenn die durch verschiedene Startwerte erzielten Ergebnisse ähnlich oder gleich sind, damit ist das Ergebnis nahe dem globalen Optimum. Mit drei Clustern wurde für jeden Testlauf das genau gleiche Ergebnis erzielt, mit vier Clustern waren 72% aller Testläufe gleich, ließ man einen Testlauf aus, so stieg die Gleichheit auf 99%. Mit fünf Clustern waren allerdings nur 37% der Bilder identisch zugeordnet, dieses Ergebnis ist nicht stabil. Aus diesem Grund wurde die weitergehende Analyse nur mit drei Clustern durchgeführt.

Diese Analyse bezieht sich auf die Relation zwischen Cluster und Person, d.h. Tabelle 4.5 gibt die Prozente der Bilder einer Person in jedem Cluster an. Es fällt auf, dass nicht

jede Person Bilder in jedem Cluster besitzt, das bedeutet, dass die Bilder nicht nur nach Beleuchtungsunterschieden geclustert wurden (vgl. Abb. 4.6), oder dass nicht jede Person unter jeder Beleuchtungsbedingung aufgenommen wurde. Die richtige Ursache ist nicht bekannt.

Tabelle 4.5: Anteil der Bilder der Personen in den Clustern bei der Roboter Datenbank

3 Klassen	Klasse 1	Klasse 2	Klasse 3	Summe
Person 1	1	0	0	1
Person 2	0,02	0,08	0,9	1
Person 3	0	0,95	0,05	1
Person 4	0,99	0,01	0	1
Person 5	0,09	0,91	0	1
Person 6	0,92	0,08	0	1
Person 7	0,23	0,77	0	1
Person 8	0,3	0,7	0	1
Person 9	0,59	0,41	0	1
Person 10	0	1	0	1
Person 11	0,95	0,05	0	1
Person 12	0,74	0,26	0	1
Person 13	0,08	0,92	0	1
Person 14	0,83	0,04	0,13	1
Person 15	0,89	0,11	0	1
Person 16	0,54	0,25	0,21	1
Person 17	0,32	0,68	0	1
Person 18	0,95	0,05	0	1
Person 19	1	0	0	1
Person 20	0	1	0	1
Person 21	0,4	0,6	0	1
Person 22	0,78	0,22	0	1
Person 23	0	1	0	1
Person 24	0,87	0,13	0	1
Person 25	0,2	0,8	0	1
Person 26	1	0	0	1
Person 27	0,17	0,83	0	1
Person 28	0,56	0,44	0	1
Person 29	0,9	0,1	0	1
Person 30	0,25	0,75	0	1



Abb. 4.6: Bilder von drei Clustern der Roboter Datenbank

### 4.2.2.2 Ergebnisse der Beleuchtungsklassifikation

Die durch K-Means Clustering gelernten Partitionen werden nun als Grundlage für die Beleuchtungsklassifikation verwendet. Die Parameter sind identisch denen bei CMU PIE Beleuchtungsklassifikationen (Kapitel 4.1.2).

Die ersten zwei Algorithmen erreichten bei drei Klassen jeweils 83.2% und bei vier Klassen jeweils 47.9%. Der dritte Algorithmus erreichte 60.0% korrekt klassifizierte Daten bei drei Klassen und 43.1% bei vier Klassen, somit ist er schlechter als die beiden ersten Algorithmen, im Verhältnis allerdings besser bei vier Klassen, da die Differenz zwischen drei und vier Klassen bei diesem Algorithmus wesentlich kleiner ist.

### 4.2.2.3 Ergebnisse der Gesichtserkennung

Für die Experimente zur Gesichtserkennung wurde nur eine Auswahl der Algorithmen aus Kapitel 3 verwendet, und zwar diejenigen, die sich für die CMU PIE Datenbank als besonders gut erwiesen haben. Das sind Standard Eigenfaces Algorithmus mit Trainingsdaten aus drei Klassen und zufällig gewählten, "Eigen for each Class" ohne Vorbearbeitung und mit Sobel-Operator. Die Experimente wurden mit drei Klassen, 20 Eigenvektoren und ein bzw. zwei Trainingsbilder pro Person und Klasse durchgeführt. Da nicht alle Personen ein Bild aus jeder Beleuchtungsklasse besitzen, werden für fehlende Beleuchtungsklassen dieser Person zufällig aus den vorhandenen Klassen Bilder ausgewählt, um die gleiche Anzahl Trainingsbilder für jede Person zu erhalten.

Um den "Eigen for Each Class" Algorithmus anwenden zu können, mussten die Daten in die drei Beleuchtungsklassen aufgeteilt und getrennt werden. Diese Beleuchtungsklassen sind die gleichen, die bei K-Means Clustering herausgefunden wurden. Jede Beleuchtungsklasse kann als unabhängige Grundgesamtheit betrachtet werden. Auf jeder dieser Grundgesamtheiten wird nun ein Eigenfaces Algorithmus mit den Bildern der Personen durchgeführt, die in dieser Grundgesamtheit enthalten sind. Der Durchschnitt aller Ergebnisse auf den einzelnen Beleuchtungsklassen ist das Gesamtergebnis des "Eigen for Each Class" Algorithmus.

Die Ergebnisse sind in Tabelle 4.6 dargestellt. Verglichen mit den Ergebnissen der CMU PIE Datenbank sind diese Ergebnisse sehr niedrig, auch ist der beste Algorithmus nicht "Eigen for each Class", sondern "Eigenfaces" mit drei Klassen Trainingsdaten. Selbst die zufällig gewählten Trainingsdaten des "Eigenfaces random" erzielten ein besseres Ergebnis als "Eigen for each Class", was ein Hinweis darauf ist, dass die zufälligen Trainingsdaten eine gute Repräsentation der Datenbank ergeben. Das insgesamt beste Ergebnis war nicht besser als 56%. Dies lässt sich durch die Unterschiede in den Datenbanken erklären, da die CMU PIE unter strengen Bedingungen, während die Roboter Datenbank unter freien, realistischen Bedingungen aufgenommen wurde. Deshalb enthält die Roboter Datenbank auch Variationen in Kopfhaltung oder Gesichtsausdruck, zudem muss der Einfluss verschiedener Hintergründe, Bildskalierungen und schlecht in die Bilder eingepasste Gesichter berücksichtigt werden.

Tabelle 4.6: Ergebnisse der Gesichtserkennung auf der Roboter Datenbank

Algorithmus	Vorbearbeitung	Training	Art der Methode	Gesamtergebnis
Eigenfaces	without	3 Klassen	Vergleich	51,00%
Eigenfaces	without	random	Vergleich	40,50%
Eigen For Each Class	without	3 Klassen	Identifizieren in Klassen	39,43%
Eigen For Each Class	Sobel	1 Klasse (frontal)	Kombination	26,37%

### 4.2.3 Tests mit manuell ausgerichteten Bildern von Gesichtern

Da die Ergebnisse der Roboterdatenbank nicht so gut waren wie erwartet, wurden die Bilder erneut ausgewertet, diesmal mit manuell ausgerichteten Gesichtern auf den Bildern. Dazu wurden die Augen der Personen markiert und als Merkmal zum Ausrichten verwendet. Auf diese Weise war es möglich 1228 Gesichter von 30 Personen aus den Rohdaten herauszufinden.

#### 4.2.3.1 K-Means Clustering Ergebnisse mit ausgerichteten Bildern

Genau wie zuvor (Kapitel 4.2.2.1) wurde der K-Means Clustering Algorithmus mit den gleichen Parametern wie zuvor durchgeführt, und die Ergebnisse wurden auf gleiche Weise analysiert.

Die Stabilitätsbetrachtung ergab 99,8% Gleichheit bei drei Clustern und 30% Gleichheit bei vier Clustern. Die Partition in fünf Cluster war nicht mehr auswertbar. Deshalb wird weiterhin nur das stabile Ergebnis mit drei Clustern betrachtet. Danach wurde die Relation von Cluster und Person für die Einteilung in drei Cluster untersucht (Tabelle 4.7).

Nur 16,67% der Personen besitzen Bilder in allen Clustern, 76,67% immerhin noch in zwei Clustern und 6,67% der Personen sind nur in einem Cluster vertreten. Beispiele der Cluster sind in Abb. 4.7 dargestellt. Die Bilder sind daher nicht nur nach Beleuchtung, sondern ebenfalls nach einer anderen Art der Varianz geclustert.




Abb. 4.7: Bilder von drei Clustern der ausgerichteten Roboter Datenbank

Tabelle 4.7: Anteil der Bilder der Personen in den Clustern bei der Roboter Datenbank mit ausgerichteten Bildern

3 Klassen	Klasse 1	Klasse 2	Klasse 3	Summe
Person 1	0,05	0,8	0,15	1
Person 2	0,95	0	0,05	1
Person 3	0,58	0	0,42	1
Person 4	0,91	0	0,09	1
Person 5	0,64	0	0,36	1
Person 6	0,32	0,09	0,59	1
Person 7	0,37	0	0,63	1
Person 8	0,37	0	0,63	1
Person 9	0,17	0,02	0,81	1
Person 10	0,06	0	0,94	1
Person 11	0	0	1	1
Person 12	0,47	0	0,53	1
Person 13	0,07	0	0,93	1
Person 14	0,77	0	0,23	1
Person 15	0,67	0	0,33	1
Person 16	0,21	0,04	0,75	1
Person 17	0,5	0	0,5	1
Person 18	0,05	0,09	0,86	1
Person 19	0,82	0	0,18	1
Person 20	0,4	0,07	0,53	1
Person 21	0	0,06	0,94	1
Person 22	0,87	0,07	0,06	1
Person 23	0,75	0	0,25	1
Person 24	0,6	0	0,4	1
Person 25	0,4	0	0,6	1
Person 26	0,18	0	0,82	1
Person 27	0,45	0	0,55	1
Person 28	1	0	0	1
Person 29	0,3	0	0,7	1
Person 30	0,8	0	0,2	1

#### 4.2.3.2 Beleuchtungsklassifikation mit ausgerichteten Bildern

Die Information, wie die Bilder korrekt den Klassen zugeordnet werden ist vom K-Means Clustering übernommen, auch wenn die Aufteilung in Cluster nicht nur den Beleuchtungsklassen entsprechen sollte. Die Beleuchtungsklassifikation wird nur für drei Klassen durchgeführt. Die anderen Parameter bleiben wie zuvor.

Die ersten beiden Klassifikationsalgorithmen erreichten beide eine Klassifikationsrate von 86,9% für 3 Klassen, der dritte Algorithmus erreichte nur 33,2%. Die niedrige Erkennungsrate zeigt, dass dieser Klassifikator nicht für diese Art der Daten geeignet ist und sich auf die Trainingsdaten überspezialisiert.



### 4.2.3.3 Ergebnisse der Gesichtserkennung mit ausgerichteten Bildern

Die Gesichtserkennung wird auf der Roboter Datenbank mit ausgerichteten Bildern mit der gleichen Auswahl an Algorithmen durchgeführt wie zuvor mit automatisch gefundenen Gesichtern. Wie zuvor werden 3 Klassen, 20 Eigenvektoren und ein, bzw. zwei Bilder pro Person verwendet.

Tabelle 4.8 zeigt die Erkennungsrate der Gesichtserkennung. Im Vergleich zur CMU PIE Datenbank sind die Ergebnisse immer noch sehr niedrig, aber im Vergleich mit den automatisch gefundenen Gesichtern der Roboter Datenbank sind die Ergebnisse etwas besser. Auch hier ist der beste Algorithmus "Eigenfaces" mit 3 Klassen Trainingsdaten, die Steigerung zur vorhergehenden Datenbank beträgt 3%. Das schlechte Ergebnis der Verwendung des "Sobel-Operators" ist auf die Datenbank selbst zurückzuführen, da die Bilder nicht nur nach Beleuchtung klassifiziert wurden. Die Ergebnisse lassen den Schluss zu, dass die Daten sich nicht mit einer anderen Möglichkeit zum Auffinden der Gesichter verbessern lassen.

Tabelle 4.8: Ergebnisse der Gesichtserkennung der Roboter Datenbank mit ausgerichteten Bildern

Algorithmus	Vorbereitung	Training	Art der Methode	Gesamtergebnis
Eigenfaces	without	3 Klassen	Vergleich	54,50%
Eigen For Each Class	without	3 Klassen	Identifizieren in Klassen	41,27%
Eigenfaces	without	random	Vergleich	34,95%
Eigen For Each Class	Sobel	1 Klasse (frontal)	Kombination	17,49%

Die niedrige Erkennungsrate kann verschiedene Ursachen haben. Eine mögliche Ursache wäre, dass die Beleuchtung nicht die einzige und vielleicht die dominante Varianz innerhalb der Gesichter erzeugt. Trotzdem wird der Einfluss auch dieser Varianzen durch eine Klassifikation vor der Identifikation verringert. Eine andere Erklärung für die schlechten Ergebnisse ist die Farbe der Bilder. Die Kamera des Roboters nimmt farbige Bilder auf, die zum Teil sehr dunkel waren. Durch die Konvertierung in Graustufenbilder werden verschiedene dunkle Farben zu dem gleichen Grauton umgewandelt und dadurch geht zuviel Information über die Identität verloren.

## 5. Schlussfolgerungen

In dieser Arbeit wurde ein neuer Ansatz zur Gesichtserkennung gezeigt, der die Information der Lichtrichtung auf den Bildern nutzt. Dazu mussten zuerst die Lichtrichtungen herausgefunden werden, die am wichtigsten zur Darstellung sind. Diese wurden dann als Vorgabe eines Klassifizierungsalgorithmus verwendet, um weitere Bilder klassifizieren zu können. Danach wurde die Information der Lichtrichtung zusammen mit dem Bild zur Gesichtserkennung verwendet. Die durchgeführten Experimente auf der CMU PIE Database und der Roboter Datenbank zeigten, dass diese Information die Erkennungsrate stark verbessert, und die richtige Auswahl der Trainingsbilder diese Erkennungsrate stark beeinflusst. Können die Bilder nicht entsprechend den Beleuchtungsklassen ausgewählt werden, gibt es Methoden dies zu überwinden, besonders geeignet bei der CMU PIE Database hat sich der Sobel-Operator erwiesen.

Es wurde nicht nur ein einzelner Gesichtserkennungsalgorithmus entwickelt, sondern darüber hinaus ein Schema zur Gesichtserkennung, das den Einfluss wechselnder Beleuchtung auf dem Gesicht verringert. Dieses Schema besteht aus einem Beleuchtungsklassifikator und einem Gesichtserkennungsalgorithmus, der das Wissen um die Beleuchtung auf den Bildern nutzt. Der Vorteil dieses Schemas ist, dass es an die entsprechenden Umstände angepasst und mit verschiedenen Algorithmen ausgefüllt werden kann. Dies ist sinnvoll, da nicht auf jeder Datenbank die gleiche Kombination von Algorithmen das beste Ergebnis liefert. So wurde das beste Ergebnis auf der CMU PIE Database mit dem "Eigen for Each Class" Algorithmus erreicht, bei der Roboter Datenbank erzielte das beste Ergebnis der Standard Eigenfaces Algorithmus mit Trainingsdaten aus drei Klassen.

Alle vorgestellten Algorithmen haben eines gemeinsam: Durch Kenntnis der Beleuchtungsstruktur wird die Erkennungsrate signifikant erhöht.

## **A. Ergebnisse des K-Means Clustering auf CMU PIE Database**

Hier werden die Ergebnisse des K-Means Clustering Algorithmus angewandt auf die CMU PIE Datenbank gezeigt. Die Tabellen stellen die relative Häufigkeit der vorgegebenen Beleuchtungsklassen innerhalb eines Clusters an dar. Die vorgegebene Beleuchtungsklasse ist zu den Ergebnissen hinzugefügt worden, nachdem die Daten geclustert wurden, da der Algorithmus diese Information nicht verwendet.

Tabelle A.1: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 3 Clustern erhalten aus Test 1 mit 4 Eigenvektoren

Test 1 / 4 EigVal	CI 0	CI 1	CI 2	Sum
illum 02	1	0	0	1
illum 03	1	0	0	1
illum 04	1	0	0	1
illum 05	0,97	0,03	0	1
illum 06	0,16	0,84	0	1
illum 07	0,13	0,87	0	1
illum 08	0	1	0	1
illum 09	0	0,16	0,84	1
illum 10	1	0	0	1
illum 11	0	1	0	1
illum 12	0	0,16	0,84	1
illum 13	0	0	1	1
illum 14	0	0	1	1
illum 15	0	0	1	1
illum 16	0	0	1	1
illum 17	0	0	1	1
illum 18	1	0	0	1
illum 19	0,55	0,45	0	1
illum 20	0	1	0	1
illum 21	0	0,13	0,87	1
illum 22	0	0	1	1
lights 00	0	1	0	1
lights 01	0	1	0	1
lights 02	1	0	0	1
lights 03	1	0	0	1
lights 04	0,97	0,03	0	1
lights 05	0,71	0,29	0	1
lights 06	0	1	0	1
lights 07	0	1	0	1
lights 08	0	1	0	1
lights 09	0	0,84	0,16	1
lights 10	0,68	0,32	0	1
lights 11	0	1	0	1
lights 12	0	0,84	0,16	1
lights 13	0	0,06	0,94	1
lights 14	0	0,16	0,84	1
lights 15	0	0	1	1
lights 16	0	0	1	1
lights 17	0	0	1	1
lights 18	0,84	0,16	0	1
lights 19	0,13	0,87	0	1
lights 20	0	1	0	1
lights 21	0	0,55	0,45	1
lights 22	0	0,06	0,94	1
lights 23	0	1	0	1

Tabelle A.2: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 3 Clustern erhalten aus Test 2 mit 4 Eigenvektoren

Test 2 / 4 EigVal	CI 0	CI 1	CI 2	Sum
illum 02	1	0	0	1
illum 03	1	0	0	1
illum 04	1	0	0	1
illum 05	1	0	0	1
illum 06	0,23	0	0,77	1
illum 07	0,13	0	0,87	1
illum 08	0	0	1	1
illum 09	0	0,81	0,19	1
illum 10	1	0	0	1
illum 11	0	0	1	1
illum 12	0	0,81	0,19	1
illum 13	0	1	0	1
illum 14	0	1	0	1
illum 15	0	1	0	1
illum 16	0	1	0	1
illum 17	0	1	0	1
illum 18	1	0	0	1
illum 19	0,58	0	0,42	1
illum 20	0	0	1	1
illum 21	0	0,87	0,13	1
illum 22	0	1	0	1
lights 00	0	0	1	1
lights 01	0	0	1	1
lights 02	1	0	0	1
lights 03	1	0	0	1
lights 04	1	0	0	1
lights 05	0,77	0	0,23	1
lights 06	0	0	1	1
lights 07	0	0	1	1
lights 08	0	0	1	1
lights 09	0	0,06	0,94	1
lights 10	0,74	0	0,26	1
lights 11	0	0	1	1
lights 12	0	0,1	0,9	1
lights 13	0	0,87	0,13	1
lights 14	0	0,81	0,19	1
lights 15	0	1	0	1
lights 16	0	1	0	1
lights 17	0	1	0	1
lights 18	0,87	0	0,13	1
lights 19	0,16	0	0,84	1
lights 20	0	0	1	1
lights 21	0	0,32	0,68	1
lights 22	0	0,94	0,06	1
lights 23	0	0	1	1

Tabelle A.3: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 3 Clustern erhalten aus Test 3 mit 4 Eigenvektoren

Test 3 / 4 EigVal	CI 0	CI 1	CI 2	Sum
illum 02	0	1	0	1
illum 03	0	1	0	1
illum 04	0	1	0	1
illum 05	0	1	0	1
illum 06	0,77	0,23	0	1
illum 07	0,87	0,13	0	1
illum 08	1	0	0	1
illum 09	0,19	0	0,81	1
illum 10	0	1	0	1
illum 11	1	0	0	1
illum 12	0,19	0	0,81	1
illum 13	0	0	1	1
illum 14	0	0	1	1
illum 15	0	0	1	1
illum 16	0	0	1	1
illum 17	0	0	1	1
illum 18	0	1	0	1
illum 19	0,42	0,58	0	1
illum 20	1	0	0	1
illum 21	0,13	0	0,87	1
illum 22	0	0	1	1
lights 00	1	0	0	1
lights 01	1	0	0	1
lights 02	0	1	0	1
lights 03	0	1	0	1
lights 04	0	1	0	1
lights 05	0,23	0,77	0	1
lights 06	1	0	0	1
lights 07	1	0	0	1
lights 08	1	0	0	1
lights 09	0,94	0	0,06	1
lights 10	0,26	0,74	0	1
lights 11	1	0	0	1
lights 12	0,9	0	0,1	1
lights 13	0,13	0	0,87	1
lights 14	0,19	0	0,81	1
lights 15	0	0	1	1
lights 16	0	0	1	1
lights 17	0	0	1	1
lights 18	0,13	0,87	0	1
lights 19	0,84	0,16	0	1
lights 20	1	0	0	1
lights 21	0,68	0	0,32	1
lights 22	0,06	0	0,94	1
lights 23	1	0	0	1

Tabelle A.4: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 3 Clustern erhalten aus Test 1 mit 10 Eigenvektoren

Test 1 / 10 EigVal	CI 0	CI 1	CI 2	Sum
illum 02	1	0	0	1
illum 03	1	0	0	1
illum 04	1	0	0	1
illum 05	0,97	0,03	0	1
illum 06	0,13	0,87	0	1
illum 07	0,13	0,87	0	1
illum 08	0	1	0	1
illum 09	0	0,16	0,84	1
illum 10	0,97	0,03	0	1
illum 11	0	1	0	1
illum 12	0	0,16	0,84	1
illum 13	0	0	1	1
illum 14	0	0	1	1
illum 15	0	0	1	1
illum 16	0	0	1	1
illum 17	0	0	1	1
illum 18	1	0	0	1
illum 19	0,52	0,48	0	1
illum 20	0	1	0	1
illum 21	0	0,13	0,87	1
illum 22	0	0	1	1
lights 00	0	1	0	1
lights 01	0	1	0	1
lights 02	1	0	0	1
lights 03	1	0	0	1
lights 04	0,94	0,06	0	1
lights 05	0,61	0,39	0	1
lights 06	0	1	0	1
lights 07	0	1	0	1
lights 08	0	1	0	1
lights 09	0	0,81	0,19	1
lights 10	0,61	0,39	0	1
lights 11	0	1	0	1
lights 12	0	0,81	0,19	1
lights 13	0	0,06	0,94	1
lights 14	0	0,06	0,94	1
lights 15	0	0	1	1
lights 16	0	0	1	1
lights 17	0	0	1	1
lights 18	0,81	0,19	0	1
lights 19	0,1	0,9	0	1
lights 20	0	1	0	1
lights 21	0	0,52	0,48	1
lights 22	0	0,03	0,97	1
lights 23	0	1	0	1

Tabelle A.5: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 3 Clustern erhalten aus Test 2 mit 10 Eigenvektoren

Test 2 / 10 EigVal	CI 0	CI 1	CI 2	Sum
illum 02	1	0	0	1
illum 03	1	0	0	1
illum 04	1	0	0	1
illum 05	1	0	0	1
illum 06	0,26	0	0,74	1
illum 07	0,19	0	0,81	1
illum 08	0	0	1	1
illum 09	0	0,81	0,19	1
illum 10	1	0	0	1
illum 11	0	0	1	1
illum 12	0	0,81	0,19	1
illum 13	0	1	0	1
illum 14	0	1	0	1
illum 15	0	1	0	1
illum 16	0	1	0	1
illum 17	0	1	0	1
illum 18	1	0	0	1
illum 19	0,61	0	0,39	1
illum 20	0	0	1	1
illum 21	0	0,87	0,13	1
illum 22	0	1	0	1
lights 00	0	0	1	1
lights 01	0	0	1	1
lights 02	1	0	0	1
lights 03	1	0	0	1
lights 04	1	0	0	1
lights 05	0,74	0	0,26	1
lights 06	0	0	1	1
lights 07	0	0	1	1
lights 08	0	0	1	1
lights 09	0	0,06	0,94	1
lights 10	0,74	0	0,26	1
lights 11	0	0	1	1
lights 12	0	0,03	0,97	1
lights 13	0	0,81	0,19	1
lights 14	0	0,77	0,23	1
lights 15	0	0,97	0,03	1
lights 16	0	1	0	1
lights 17	0	1	0	1
lights 18	0,9	0	0,1	1
lights 19	0,16	0	0,84	1
lights 20	0	0	1	1
lights 21	0	0,26	0,74	1
lights 22	0	0,94	0,06	1
lights 23	0	0	1	1

Tabelle A.6: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 3 Clustern erhalten aus Test 3 mit 10 Eigenvektoren

Test 3 / 10 EigVal	CI 0	CI 1	CI 2	Sum
illum 02	0	1	0	1
illum 03	0	1	0	1
illum 04	0	1	0	1
illum 05	0	1	0	1
illum 06	0,74	0,26	0	1
illum 07	0,81	0,19	0	1
illum 08	1	0	0	1
illum 09	0,19	0	0,81	1
illum 10	0	1	0	1
illum 11	1	0	0	1
illum 12	0,19	0	0,81	1
illum 13	0	0	1	1
illum 14	0	0	1	1
illum 15	0	0	1	1
illum 16	0	0	1	1
illum 17	0	0	1	1
illum 18	0	1	0	1
illum 19	0,39	0,61	0	1
illum 20	1	0	0	1
illum 21	0,13	0	0,87	1
illum 22	0	0	1	1
lights 00	1	0	0	1
lights 01	1	0	0	1
lights 02	0	1	0	1
lights 03	0	1	0	1
lights 04	0	1	0	1
lights 05	0,26	0,74	0	1
lights 06	1	0	0	1
lights 07	1	0	0	1
lights 08	1	0	0	1
lights 09	0,94	0	0,06	1
lights 10	0,26	0,74	0	1
lights 11	1	0	0	1
lights 12	0,97	0	0,03	1
lights 13	0,19	0	0,81	1
lights 14	0,23	0	0,77	1
lights 15	0,03	0	0,97	1
lights 16	0	0	1	1
lights 17	0	0	1	1
lights 18	0,1	0,9	0	1
lights 19	0,84	0,16	0	1
lights 20	1	0	0	1
lights 21	0,74	0	0,26	1
lights 22	0,06	0	0,94	1
lights 23	1	0	0	1

Tabelle A.7: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 4 Clustern erhalten aus Test 1 mit 4 Eigenvektoren

Test 1 / 4 EigVal	CI 0	CI 1	CI 2	CI 3	Sum
illum 02	1	0	0	0	1
illum 03	1	0	0	0	1
illum 04	1	0	0	0	1
illum 05	0,61	0,39	0	0	1
illum 06	0	1	0	0	1
illum 07	0	1	0	0	1
illum 08	0	0,19	0,81	0	1
illum 09	0	0	1	0	1
illum 10	0,61	0,39	0	0	1
illum 11	0	0,23	0,77	0	1
illum 12	0	0	1	0	1
illum 13	0	0	0,16	0,84	1
illum 14	0	0	0,16	0,84	1
illum 15	0	0	0	1	1
illum 16	0	0	0	1	1
illum 17	0	0	0	1	1
illum 18	0,94	0,06	0	0	1
illum 19	0,06	0,94	0	0	1
illum 20	0	0,23	0,77	0	1
illum 21	0	0	0,97	0,03	1
illum 22	0	0	0,06	0,94	1
lights 00	0	0,94	0,06	0	1
lights 01	0	0,94	0,06	0	1
lights 02	1	0	0	0	1
lights 03	0,97	0,03	0	0	1
lights 04	0,61	0,39	0	0	1
lights 05	0	1	0	0	1
lights 06	0	1	0	0	1
lights 07	0	1	0	0	1
lights 08	0	0,35	0,65	0	1
lights 09	0	0	1	0	1
lights 10	0	1	0	0	1
lights 11	0	0,35	0,65	0	1
lights 12	0	0	1	0	1
lights 13	0	0	1	0	1
lights 14	0	0	1	0	1
lights 15	0	0	0,81	0,19	1
lights 16	0	0	0,03	0,97	1
lights 17	0	0	0	1	1
lights 18	0,13	0,87	0	0	1
lights 19	0	1	0	0	1
lights 20	0	0,45	0,55	0	1
lights 21	0	0	1	0	1
lights 22	0	0	1	0	1
lights 23	0	0,94	0,06	0	1

Tabelle A.8: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 4 Clustern erhalten aus Test 2 mit 4 Eigenvektoren

Test 2 / 4 EigVal	CI 0	CI 1	CI 2	CI 3	Sum
illum 02	1	0	0	0	1
illum 03	1	0	0	0	1
illum 04	1	0	0	0	1
illum 05	0,74	0	0	0,26	1
illum 06	0	0	0	1	1
illum 07	0	0	0	1	1
illum 08	0	0	0,77	0,23	1
illum 09	0	0	1	0	1
illum 10	0,74	0	0	0,26	1
illum 11	0	0	0,77	0,23	1
illum 12	0	0	1	0	1
illum 13	0	0,77	0,23	0	1
illum 14	0	0,77	0,23	0	1
illum 15	0	1	0	0	1
illum 16	0	1	0	0	1
illum 17	0	1	0	0	1
illum 18	0,97	0	0	0,03	1
illum 19	0,1	0	0	0,9	1
illum 20	0	0	0,77	0,23	1
illum 21	0	0	1	0	1
illum 22	0	0,94	0,06	0	1
lights 00	0	0	0	1	1
lights 01	0	0	0	1	1
lights 02	1	0	0	0	1
lights 03	1	0	0	0	1
lights 04	0,68	0	0	0,32	1
lights 05	0	0	0	1	1
lights 06	0	0	0	1	1
lights 07	0	0	0	1	1
lights 08	0	0	0,39	0,61	1
lights 09	0	0	1	0	1
lights 10	0	0	0	1	1
lights 11	0	0	0,39	0,61	1
lights 12	0	0	1	0	1
lights 13	0	0	1	0	1
lights 14	0	0	1	0	1
lights 15	0	0,06	0,94	0	1
lights 16	0	0,9	0,1	0	1
lights 17	0	1	0	0	1
lights 18	0,13	0	0	0,87	1
lights 19	0	0	0	1	1
lights 20	0	0	0,39	0,61	1
lights 21	0	0	1	0	1
lights 22	0	0	1	0	1
lights 23	0	0	0	1	1

Tabelle A.9: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 4 Clustern erhalten aus Test 3 mit 4 Eigenvektoren

Test 3 / 4 EigVal	CI 0	CI 1	CI 2	CI 3	Sum
illum 02	0	1	0	0	1
illum 03	0	1	0	0	1
illum 04	0	1	0	0	1
illum 05	0	1	0	0	1
illum 06	0,29	0,26	0,45	0	1
illum 07	0,32	0,23	0,45	0	1
illum 08	0,39	0	0,61	0	1
illum 09	0,23	0	0,19	0,58	1
illum 10	0	1	0	0	1
illum 11	0,35	0	0,65	0	1
illum 12	0,23	0	0,19	0,58	1
illum 13	0	0	0	1	1
illum 14	0	0	0	1	1
illum 15	0	0	0	1	1
illum 16	0	0	0	1	1
illum 17	0	0	0	1	1
illum 18	0	1	0	0	1
illum 19	0,16	0,71	0,13	0	1
illum 20	0,35	0	0,65	0	1
illum 21	0,1	0	0,13	0,77	1
illum 22	0	0	0	1	1
lights 00	0,26	0	0,74	0	1
lights 01	0,26	0	0,74	0	1
lights 02	0	1	0	0	1
lights 03	0	1	0	0	1
lights 04	0	1	0	0	1
lights 05	0,16	0,71	0,13	0	1
lights 06	0,26	0,03	0,71	0	1
lights 07	0,29	0	0,71	0	1
lights 08	0,29	0	0,71	0	1
lights 09	0,29	0	0,71	0	1
lights 10	0,16	0,74	0,1	0	1
lights 11	0,29	0	0,71	0	1
lights 12	0,29	0	0,71	0	1
lights 13	0,19	0	0,26	0,55	1
lights 14	0,19	0	0,32	0,48	1
lights 15	0,06	0	0	0,94	1
lights 16	0	0	0	1	1
lights 17	0	0	0	1	1
lights 18	0,13	0,81	0,06	0	1
lights 19	0,26	0,23	0,52	0	1
lights 20	0,29	0	0,71	0	1
lights 21	0,26	0	0,65	0,1	1
lights 22	0,1	0	0,1	0,81	1
lights 23	0,26	0	0,74	0	1

Tabelle A.10: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 4 Clustern erhalten aus Test 1 mit 10 Eigenvektoren

Test 1 / 10 EigVal	CI 0	CI 1	CI 2	CI 3	Sum
illum 02	1	0	0	0	1
illum 03	1	0	0	0	1
illum 04	1	0	0	0	1
illum 05	0,65	0,35	0	0	1
illum 06	0	1	0	0	1
illum 07	0	1	0	0	1
illum 08	0	0,19	0,81	0	1
illum 09	0	0	1	0	1
illum 10	0,65	0,35	0	0	1
illum 11	0	0,23	0,77	0	1
illum 12	0	0	1	0	1
illum 13	0	0	0,16	0,84	1
illum 14	0	0	0,16	0,84	1
illum 15	0	0	0	1	1
illum 16	0	0	0	1	1
illum 17	0	0	0	1	1
illum 18	0,97	0,03	0	0	1
illum 19	0,06	0,94	0	0	1
illum 20	0	0,23	0,77	0	1
illum 21	0	0	0,97	0,03	1
illum 22	0	0	0,06	0,94	1
lights 00	0	0,94	0,06	0	1
lights 01	0	0,94	0,06	0	1
lights 02	1	0	0	0	1
lights 03	0,97	0,03	0	0	1
lights 04	0,58	0,42	0	0	1
lights 05	0	1	0	0	1
lights 06	0	1	0	0	1
lights 07	0	1	0	0	1
lights 08	0	0,35	0,65	0	1
lights 09	0	0	1	0	1
lights 10	0	1	0	0	1
lights 11	0	0,35	0,65	0	1
lights 12	0	0	1	0	1
lights 13	0	0	1	0	1
lights 14	0	0	1	0	1
lights 15	0	0	0,81	0,19	1
lights 16	0	0	0,03	0,97	1
lights 17	0	0	0	1	1
lights 18	0,13	0,87	0	0	1
lights 19	0	1	0	0	1
lights 20	0	0,45	0,55	0	1
lights 21	0	0	1	0	1
lights 22	0	0	1	0	1
lights 23	0	0,94	0,06	0	1



Tabelle A.11: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 4 Clustern erhalten aus Test 2 mit 10 Eigenvektoren

Test 2 / 10 EigVal	CI 0	CI 1	CI 2	CI 3	Sum
illum 02	1	0	0	0	1
illum 03	1	0	0	0	1
illum 04	1	0	0	0	1
illum 05	0,77	0	0	0,23	1
illum 06	0,03	0	0	0,97	1
illum 07	0	0	0	1	1
illum 08	0	0	0,74	0,26	1
illum 09	0	0	1	0	1
illum 10	0,77	0	0	0,23	1
illum 11	0	0	0,77	0,23	1
illum 12	0	0	1	0	1
illum 13	0	0,77	0,23	0	1
illum 14	0	0,77	0,23	0	1
illum 15	0	1	0	0	1
illum 16	0	1	0	0	1
illum 17	0	1	0	0	1
illum 18	1	0	0	0	1
illum 19	0,1	0	0	0,9	1
illum 20	0	0	0,77	0,23	1
illum 21	0	0	1	0	1
illum 22	0	0,94	0,06	0	1
lights 00	0	0	0	1	1
lights 01	0	0	0	1	1
lights 02	1	0	0	0	1
lights 03	1	0	0	0	1
lights 04	0,71	0	0	0,29	1
lights 05	0	0	0	1	1
lights 06	0	0	0	1	1
lights 07	0	0	0	1	1
lights 08	0	0	0,26	0,74	1
lights 09	0	0	1	0	1
lights 10	0	0	0	1	1
lights 11	0	0	0,32	0,68	1
lights 12	0	0	1	0	1
lights 13	0	0	1	0	1
lights 14	0	0	1	0	1
lights 15	0	0,03	0,97	0	1
lights 16	0	0,9	0,1	0	1
lights 17	0	1	0	0	1
lights 18	0,23	0	0	0,77	1
lights 19	0	0	0	1	1
lights 20	0	0	0,26	0,74	1
lights 21	0	0	1	0	1
lights 22	0	0	1	0	1
lights 23	0	0	0	1	1

Tabelle A.12: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 4 Clustern erhalten aus Test 3 mit 10 Eigenvektoren

Test 3 / 10 EigVal	CI 0	CI 1	CI 2	CI 3	Sum
illum 02	0	1	0	0	1
illum 03	0	1	0	0	1
illum 04	0	1	0	0	1
illum 05	0,23	0,77	0	0	1
illum 06	1	0	0	0	1
illum 07	1	0	0	0	1
illum 08	0,23	0	0,77	0	1
illum 09	0	0	1	0	1
illum 10	0,26	0,74	0	0	1
illum 11	0,23	0	0,77	0	1
illum 12	0	0	1	0	1
illum 13	0	0	0,19	0,81	1
illum 14	0	0	0,16	0,84	1
illum 15	0	0	0	1	1
illum 16	0	0	0	1	1
illum 17	0	0	0	1	1
illum 18	0,03	0,97	0	0	1
illum 19	0,9	0,1	0	0	1
illum 20	0,23	0	0,77	0	1
illum 21	0	0	0,97	0,03	1
illum 22	0	0	0,06	0,94	1
lights 00	1	0	0	0	1
lights 01	1	0	0	0	1
lights 02	0	1	0	0	1
lights 03	0	1	0	0	1
lights 04	0,29	0,71	0	0	1
lights 05	1	0	0	0	1
lights 06	1	0	0	0	1
lights 07	1	0	0	0	1
lights 08	0,58	0	0,42	0	1
lights 09	0	0	1	0	1
lights 10	1	0	0	0	1
lights 11	0,61	0	0,39	0	1
lights 12	0	0	1	0	1
lights 13	0	0	1	0	1
lights 14	0	0	1	0	1
lights 15	0	0	0,97	0,03	1
lights 16	0	0	0,06	0,94	1
lights 17	0	0	0	1	1
lights 18	0,87	0,13	0	0	1
lights 19	1	0	0	0	1
lights 20	0,61	0	0,39	0	1
lights 21	0	0	1	0	1
lights 22	0	0	1	0	1
lights 23	1	0	0	0	1

Tabelle A.13: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 5 Clustern erhalten aus Test 1 mit 4 Eigenvektoren

Test 1 / 4 EigVal	CI 0	CI 1	CI 2	CI 3	CI 4	Sum
illum 02	1	0	0	0	0	1
illum 03	1	0	0	0	0	1
illum 04	1	0	0	0	0	1
illum 05	0,68	0,13	0,19	0	0	1
illum 06	0	0,29	0,71	0	0	1
illum 07	0	0,35	0,65	0	0	1
illum 08	0	0,29	0,19	0,52	0	1
illum 09	0	0	0	1	0	1
illum 10	0,68	0,13	0,19	0	0	1
illum 11	0	0,26	0,19	0,55	0	1
illum 12	0	0	0	1	0	1
illum 13	0	0	0	0,26	0,74	1
illum 14	0	0	0	0,23	0,77	1
illum 15	0	0	0	0	1	1
illum 16	0	0	0	0	1	1
illum 17	0	0	0	0	1	1
illum 18	1	0	0	0	0	1
illum 19	0,06	0,26	0,68	0	0	1
illum 20	0	0,26	0,23	0,52	0	1
illum 21	0	0	0	1	0	1
illum 22	0	0	0	0,13	0,87	1
lights 00	0	0,29	0,71	0	0	1
lights 01	0	0,29	0,71	0	0	1
lights 02	1	0	0	0	0	1
lights 03	1	0	0	0	0	1
lights 04	0,48	0,13	0,39	0	0	1
lights 05	0	0,23	0,77	0	0	1
lights 06	0	0,29	0,71	0	0	1
lights 07	0	0,29	0,71	0	0	1
lights 08	0	0,32	0,52	0,16	0	1
lights 09	0	0,1	0	0,9	0	1
lights 10	0	0,23	0,77	0	0	1
lights 11	0	0,32	0,48	0,19	0	1
lights 12	0	0,1	0	0,9	0	1
lights 13	0	0	0	1	0	1
lights 14	0	0	0	1	0	1
lights 15	0	0	0	0,97	0,03	1
lights 16	0	0	0	0,19	0,81	1
lights 17	0	0	0	0	1	1
lights 18	0,06	0,19	0,74	0	0	1
lights 19	0	0,26	0,74	0	0	1
lights 20	0	0,29	0,58	0,13	0	1
lights 21	0	0,1	0	0,9	0	1
lights 22	0	0	0	1	0	1
lights 23	0	0,29	0,71	0	0	1

Tabelle A.14: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 5 Clustern erhalten aus Test 2 mit 4 Eigenvektoren

Test 2 / 4 EigVal	CI 0	CI 1	CI 2	CI 3	CI 4	Sum
illum 02	0	0	0	0	1	1
illum 03	0	0	0	0	1	1
illum 04	0,03	0	0	0	0,97	1
illum 05	0,81	0	0	0	0,19	1
illum 06	0,9	0	0	0,1	0	1
illum 07	0,84	0	0	0,16	0	1
illum 08	0	0	0	1	0	1
illum 09	0	0	0,9	0,1	0	1
illum 10	0,81	0	0	0	0,19	1
illum 11	0	0	0	1	0	1
illum 12	0	0	0,9	0,1	0	1
illum 13	0	0,45	0,55	0	0	1
illum 14	0	0,48	0,52	0	0	1
illum 15	0	0,97	0,03	0	0	1
illum 16	0	1	0	0	0	1
illum 17	0	1	0	0	0	1
illum 18	0,29	0	0	0	0,71	1
illum 19	1	0	0	0	0	1
illum 20	0	0	0	1	0	1
illum 21	0	0	1	0	0	1
illum 22	0	0,84	0,16	0	0	1
lights 00	0	0	0	1	0	1
lights 01	0	0	0	1	0	1
lights 02	0	0	0	0	1	1
lights 03	0,19	0	0	0	0,81	1
lights 04	0,97	0	0	0	0,03	1
lights 05	1	0	0	0	0	1
lights 06	0,71	0	0	0,29	0	1
lights 07	0,58	0	0	0,42	0	1
lights 08	0	0	0	1	0	1
lights 09	0	0	0,61	0,39	0	1
lights 10	1	0	0	0	0	1
lights 11	0	0	0	1	0	1
lights 12	0	0	0,65	0,35	0	1
lights 13	0	0	0,97	0,03	0	1
lights 14	0	0	0,97	0,03	0	1
lights 15	0	0	1	0	0	1
lights 16	0	0,52	0,48	0	0	1
lights 17	0	0,77	0,23	0	0	1
lights 18	1	0	0	0	0	1
lights 19	0,84	0	0	0,16	0	1
lights 20	0	0	0	1	0	1
lights 21	0	0	0,84	0,16	0	1
lights 22	0	0	1	0	0	1
lights 23	0	0	0	1	0	1

Tabelle A.15: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 5 Clustern erhalten aus Test 3 mit 4 Eigenvektoren

Test 3 / 4 EigVal	CI 0	CI 1	CI 2	CI 3	CI 4	Sum
illum 02	0	1	0	0	0	1
illum 03	0	1	0	0	0	1
illum 04	0	1	0	0	0	1
illum 05	0,16	0,74	0,1	0	0	1
illum 06	0,35	0	0,65	0	0	1
illum 07	0,39	0	0,61	0	0	1
illum 08	0,29	0	0,32	0	0,39	1
illum 09	0	0	0	0	1	1
illum 10	0,16	0,74	0,1	0	0	1
illum 11	0,26	0	0,32	0	0,42	1
illum 12	0	0	0	0	1	1
illum 13	0	0	0	0,68	0,32	1
illum 14	0	0	0	0,68	0,32	1
illum 15	0	0	0	1	0	1
illum 16	0	0	0	1	0	1
illum 17	0	0	0	1	0	1
illum 18	0	1	0	0	0	1
illum 19	0,29	0,1	0,61	0	0	1
illum 20	0,26	0	0,42	0	0,32	1
illum 21	0	0	0	0	1	1
illum 22	0	0	0	0,87	0,13	1
lights 00	0,29	0	0,71	0	0	1
lights 01	0,29	0	0,71	0	0	1
lights 02	0	1	0	0	0	1
lights 03	0,03	0,97	0	0	0	1
lights 04	0,16	0,68	0,16	0	0	1
lights 05	0,26	0,03	0,71	0	0	1
lights 06	0,29	0	0,71	0	0	1
lights 07	0,29	0	0,71	0	0	1
lights 08	0,32	0	0,58	0	0,1	1
lights 09	0,1	0	0	0	0,9	1
lights 10	0,29	0	0,71	0	0	1
lights 11	0,26	0	0,65	0	0,1	1
lights 12	0,1	0	0	0	0,9	1
lights 13	0	0	0	0	1	1
lights 14	0	0	0	0	1	1
lights 15	0	0	0	0	1	1
lights 16	0	0	0	0,74	0,26	1
lights 17	0	0	0	0,97	0,03	1
lights 18	0,19	0,16	0,65	0	0	1
lights 19	0,29	0	0,71	0	0	1
lights 20	0,26	0	0,65	0	0,1	1
lights 21	0,06	0	0	0	0,94	1
lights 22	0	0	0	0	1	1
lights 23	0,29	0	0,71	0	0	1

Tabelle A.16: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 5 Clustern erhalten aus Test 1 mit 10 Eigenvektoren

Test 1 / 10 EigVal	CI 0	CI 1	CI 2	CI 3	CI 4	Sum
illum 02	1	0	0	0	0	1
illum 03	1	0	0	0	0	1
illum 04	1	0	0	0	0	1
illum 05	0,65	0,13	0,23	0	0	1
illum 06	0	0,29	0,71	0	0	1
illum 07	0	0,35	0,65	0	0	1
illum 08	0	0,29	0,19	0,52	0	1
illum 09	0	0	0	1	0	1
illum 10	0,68	0,13	0,19	0	0	1
illum 11	0	0,26	0,19	0,55	0	1
illum 12	0	0	0	1	0	1
illum 13	0	0	0	0,16	0,84	1
illum 14	0	0	0	0,19	0,81	1
illum 15	0	0	0	0	1	1
illum 16	0	0	0	0	1	1
illum 17	0	0	0	0	1	1
illum 18	1	0	0	0	0	1
illum 19	0,06	0,26	0,68	0	0	1
illum 20	0	0,26	0,19	0,55	0	1
illum 21	0	0	0	1	0	1
illum 22	0	0	0	0,06	0,94	1
lights 00	0	0,29	0,71	0	0	1
lights 01	0	0,29	0,71	0	0	1
lights 02	1	0	0	0	0	1
lights 03	0,97	0	0,03	0	0	1
lights 04	0,48	0,13	0,39	0	0	1
lights 05	0	0,23	0,77	0	0	1
lights 06	0	0,29	0,71	0	0	1
lights 07	0	0,29	0,71	0	0	1
lights 08	0	0,32	0,48	0,19	0	1
lights 09	0	0,1	0	0,9	0	1
lights 10	0	0,23	0,77	0	0	1
lights 11	0	0,32	0,48	0,19	0	1
lights 12	0	0,1	0	0,9	0	1
lights 13	0	0	0	1	0	1
lights 14	0	0	0	1	0	1
lights 15	0	0	0	0,94	0,06	1
lights 16	0	0	0	0,16	0,84	1
lights 17	0	0	0	0	1	1
lights 18	0,06	0,19	0,74	0	0	1
lights 19	0	0,26	0,74	0	0	1
lights 20	0	0,29	0,58	0,13	0	1
lights 21	0	0,1	0	0,9	0	1
lights 22	0	0	0	1	0	1
lights 23	0	0,29	0,71	0	0	1

Tabelle A.17: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 5 Clustern erhalten aus Test 2 mit 10 Eigenvektoren

Test 2 / 10 EigVal	CI 0	CI 1	CI 2	CI 3	CI 4	Sum
illum 02	0	0	0	0	1	1
illum 03	0	0	0	0	1	1
illum 04	0,03	0	0	0	0,97	1
illum 05	0,81	0	0	0	0,19	1
illum 06	0,9	0	0	0,1	0	1
illum 07	0,9	0	0	0,1	0	1
illum 08	0	0	0	1	0	1
illum 09	0	0	1	0	0	1
illum 10	0,81	0	0	0	0,19	1
illum 11	0	0	0	1	0	1
illum 12	0	0	0,97	0,03	0	1
illum 13	0	0,48	0,52	0	0	1
illum 14	0	0,55	0,45	0	0	1
illum 15	0	1	0	0	0	1
illum 16	0	1	0	0	0	1
illum 17	0	1	0	0	0	1
illum 18	0,26	0	0	0	0,74	1
illum 19	1	0	0	0	0	1
illum 20	0	0	0	1	0	1
illum 21	0	0	1	0	0	1
illum 22	0	0,84	0,16	0	0	1
lights 00	0	0	0	1	0	1
lights 01	0	0	0	1	0	1
lights 02	0	0	0	0	1	1
lights 03	0,16	0	0	0	0,84	1
lights 04	0,94	0	0	0	0,06	1
lights 05	1	0	0	0	0	1
lights 06	0,61	0	0	0,39	0	1
lights 07	0,55	0	0	0,45	0	1
lights 08	0	0	0	1	0	1
lights 09	0	0	0,61	0,39	0	1
lights 10	1	0	0	0	0	1
lights 11	0	0	0	1	0	1
lights 12	0	0	0,65	0,35	0	1
lights 13	0	0	0,97	0,03	0	1
lights 14	0	0	0,97	0,03	0	1
lights 15	0	0	1	0	0	1
lights 16	0	0,48	0,52	0	0	1
lights 17	0	0,77	0,23	0	0	1
lights 18	1	0	0	0	0	1
lights 19	0,84	0	0	0,16	0	1
lights 20	0	0	0	1	0	1
lights 21	0	0	0,87	0,13	0	1
lights 22	0	0	1	0	0	1
lights 23	0	0	0	1	0	1

Tabelle A.18: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 5 Clustern erhalten aus Test 3 mit 10 Eigenvektoren

Test 3 / 10 EigVal	CI 0	CI 1	CI 2	CI 3	CI 4	Sum
illum 02	0	1	0	0	0	1
illum 03	0	1	0	0	0	1
illum 04	0	1	0	0	0	1
illum 05	0,16	0,77	0,06	0	0	1
illum 06	0,35	0	0,65	0	0	1
illum 07	0,39	0	0,61	0	0	1
illum 08	0,29	0	0,32	0	0,39	1
illum 09	0	0	0	0	1	1
illum 10	0,16	0,81	0,03	0	0	1
illum 11	0,23	0	0,32	0	0,45	1
illum 12	0	0	0	0	1	1
illum 13	0	0	0	0,74	0,26	1
illum 14	0	0	0	0,71	0,29	1
illum 15	0	0	0	1	0	1
illum 16	0	0	0	1	0	1
illum 17	0	0	0	1	0	1
illum 18	0,06	0,94	0	0	0	1
illum 19	0,35	0,1	0,55	0	0	1
illum 20	0,26	0	0,42	0	0,32	1
illum 21	0	0	0	0	1	1
illum 22	0	0	0	0,87	0,13	1
lights 00	0,29	0	0,71	0	0	1
lights 01	0,29	0	0,71	0	0	1
lights 02	0	1	0	0	0	1
lights 03	0,03	0,97	0	0	0	1
lights 04	0,16	0,68	0,16	0	0	1
lights 05	0,26	0,03	0,71	0	0	1
lights 06	0,29	0	0,71	0	0	1
lights 07	0,29	0	0,71	0	0	1
lights 08	0,32	0	0,58	0	0,1	1
lights 09	0,06	0	0	0	0,94	1
lights 10	0,29	0	0,71	0	0	1
lights 11	0,26	0	0,65	0	0,1	1
lights 12	0,06	0	0	0	0,94	1
lights 13	0	0	0	0	1	1
lights 14	0	0	0	0	1	1
lights 15	0	0	0	0	1	1
lights 16	0	0	0	0,71	0,29	1
lights 17	0	0	0	0,97	0,03	1
lights 18	0,26	0,13	0,61	0	0	1
lights 19	0,29	0	0,71	0	0	1
lights 20	0,26	0	0,65	0	0,1	1
lights 21	0	0	0	0	1	1
lights 22	0	0	0	0	1	1
lights 23	0,29	0	0,71	0	0	1

Tabelle A.19: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 6 Clustern erhalten aus Test 1 mit 4 Eigenvektoren

Test 1 / 4 EigVal	CI 0	CI 1	CI 2	CI 3	CI 4	CI 5	Sum
illum 02	1	0	0	0	0	0	1
illum 03	1	0	0	0	0	0	1
illum 04	0,9	0	0,1	0	0	0	1
illum 05	0,1	0,1	0,81	0	0	0	1
illum 06	0	0,29	0,71	0	0	0	1
illum 07	0	0,35	0,65	0	0	0	1
illum 08	0	0,26	0	0,68	0	0,06	1
illum 09	0	0	0	0,03	0	0,97	1
illum 10	0,1	0,1	0,81	0	0	0	1
illum 11	0	0,26	0	0,68	0	0,06	1
illum 12	0	0	0	0,06	0	0,94	1
illum 13	0	0	0	0	0,48	0,52	1
illum 14	0	0	0	0	0,52	0,48	1
illum 15	0	0	0	0	0,97	0,03	1
illum 16	0	0	0	0	1	0	1
illum 17	0	0	0	0	1	0	1
illum 18	0,65	0	0,35	0	0	0	1
illum 19	0	0,13	0,87	0	0	0	1
illum 20	0	0,26	0	0,71	0	0,03	1
illum 21	0	0	0	0	0	1	1
illum 22	0	0	0	0	0,84	0,16	1
lights 00	0	0,26	0	0,74	0	0	1
lights 01	0	0,26	0	0,74	0	0	1
lights 02	0,97	0	0,03	0	0	0	1
lights 03	0,81	0,03	0,16	0	0	0	1
lights 04	0,03	0,1	0,87	0	0	0	1
lights 05	0	0,19	0,81	0	0	0	1
lights 06	0	0,26	0,42	0,32	0	0	1
lights 07	0	0,29	0,29	0,42	0	0	1
lights 08	0	0,29	0	0,71	0	0	1
lights 09	0	0,1	0	0,26	0	0,65	1
lights 10	0	0,19	0,81	0	0	0	1
lights 11	0	0,26	0	0,71	0	0,03	1
lights 12	0	0,1	0	0,29	0	0,61	1
lights 13	0	0	0	0	0	1	1
lights 14	0	0	0	0	0	1	1
lights 15	0	0	0	0	0	1	1
lights 16	0	0	0	0	0,52	0,48	1
lights 17	0	0	0	0	0,81	0,19	1
lights 18	0	0,13	0,87	0	0	0	1
lights 19	0	0,26	0,68	0,06	0	0	1
lights 20	0	0,26	0	0,71	0	0,03	1
lights 21	0	0,1	0	0,13	0	0,77	1
lights 22	0	0	0	0	0	1	1
lights 23	0	0,26	0	0,74	0	0	1

Tabelle A.20: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 6 Clustern erhalten aus Test 2 mit 4 Eigenvektoren

Test 2 / 4 EigVal	CI 0	CI 1	CI 2	CI 3	CI 4	CI 5	Sum
illum 02	0	0	0	0	0	1	1
illum 03	0	0	0	0	0	1	1
illum 04	0	0	0	0	0,03	0,97	1
illum 05	0	0	0	0	0,81	0,19	1
illum 06	0,03	0	0	0,06	0,9	0	1
illum 07	0,06	0	0	0,06	0,87	0	1
illum 08	0,06	0	0	0,94	0	0	1
illum 09	0	0	0,84	0,16	0	0	1
illum 10	0	0	0	0	0,81	0,19	1
illum 11	0,06	0	0	0,94	0	0	1
illum 12	0	0	0,84	0,16	0	0	1
illum 13	0	0,45	0,55	0	0	0	1
illum 14	0	0,52	0,48	0	0	0	1
illum 15	0	0,97	0,03	0	0	0	1
illum 16	0	1	0	0	0	0	1
illum 17	0	1	0	0	0	0	1
illum 18	0	0	0	0	0,32	0,68	1
illum 19	0	0	0	0	1	0	1
illum 20	0,06	0	0	0,94	0	0	1
illum 21	0	0	0,9	0,1	0	0	1
illum 22	0	0,84	0,16	0	0	0	1
lights 00	0,94	0	0	0,06	0	0	1
lights 01	0,94	0	0	0,06	0	0	1
lights 02	0	0	0	0	0	1	1
lights 03	0	0	0	0	0,19	0,81	1
lights 04	0,06	0	0	0	0,87	0,06	1
lights 05	0,1	0	0	0	0,9	0	1
lights 06	0,52	0	0	0,1	0,39	0	1
lights 07	0,58	0	0	0,13	0,29	0	1
lights 08	0,32	0	0	0,68	0	0	1
lights 09	0	0	0,52	0,48	0	0	1
lights 10	0,1	0	0	0	0,9	0	1
lights 11	0,26	0	0	0,74	0	0	1
lights 12	0	0	0,52	0,48	0	0	1
lights 13	0	0	0,97	0,03	0	0	1
lights 14	0	0	0,97	0,03	0	0	1
lights 15	0	0	1	0	0	0	1
lights 16	0	0,48	0,52	0	0	0	1
lights 17	0	0,74	0,26	0	0	0	1
lights 18	0,06	0	0	0	0,94	0	1
lights 19	0,23	0	0	0,03	0,74	0	1
lights 20	0,29	0	0	0,71	0	0	1
lights 21	0	0	0,71	0,29	0	0	1
lights 22	0	0	0,97	0,03	0	0	1
lights 23	0,94	0	0	0,06	0	0	1

Tabelle A.21: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 6 Clustern erhalten aus Test 3 mit 4 Eigenvektoren

Test 3 / 4 EigVal	CI 0	CI 1	CI 2	CI 3	CI 4	CI 5	Sum
illum 02	0	1	0	0	0	0	1
illum 03	0	1	0	0	0	0	1
illum 04	0	1	0	0	0	0	1
illum 05	0,16	0,74	0,1	0	0	0	1
illum 06	0,35	0	0,65	0	0	0	1
illum 07	0,39	0	0,61	0	0	0	1
illum 08	0,29	0	0,19	0	0,03	0,48	1
illum 09	0	0	0	0	0,42	0,58	1
illum 10	0,16	0,74	0,1	0	0	0	1
illum 11	0,23	0	0,19	0	0,06	0,52	1
illum 12	0	0	0	0	0,39	0,61	1
illum 13	0	0	0	0,48	0,39	0,13	1
illum 14	0	0	0	0,48	0,35	0,16	1
illum 15	0	0	0	0,97	0,03	0	1
illum 16	0	0	0	1	0	0	1
illum 17	0	0	0	1	0	0	1
illum 18	0,06	0,94	0	0	0	0	1
illum 19	0,35	0,1	0,55	0	0	0	1
illum 20	0,23	0	0,19	0	0,03	0,55	1
illum 21	0	0	0	0	0,42	0,58	1
illum 22	0	0	0	0,77	0,16	0,06	1
lights 00	0,29	0	0,71	0	0	0	1
lights 01	0,29	0	0,71	0	0	0	1
lights 02	0	1	0	0	0	0	1
lights 03	0,03	0,97	0	0	0	0	1
lights 04	0,16	0,55	0,29	0	0	0	1
lights 05	0,26	0,03	0,71	0	0	0	1
lights 06	0,29	0	0,71	0	0	0	1
lights 07	0,29	0	0,71	0	0	0	1
lights 08	0,32	0	0,42	0	0	0,26	1
lights 09	0,03	0	0	0	0,26	0,71	1
lights 10	0,29	0	0,71	0	0	0	1
lights 11	0,26	0	0,52	0	0	0,23	1
lights 12	0,03	0	0	0	0,26	0,71	1
lights 13	0	0	0	0	0,29	0,71	1
lights 14	0	0	0	0	0,29	0,71	1
lights 15	0	0	0	0	0,39	0,61	1
lights 16	0	0	0	0,61	0,26	0,13	1
lights 17	0	0	0	0,81	0,19	0	1
lights 18	0,19	0,16	0,65	0	0	0	1
lights 19	0,29	0	0,71	0	0	0	1
lights 20	0,26	0	0,52	0	0	0,23	1
lights 21	0,03	0	0	0	0,26	0,71	1
lights 22	0	0	0	0	0,29	0,71	1
lights 23	0,29	0	0,71	0	0	0	1

Tabelle A.22: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 6 Clustern erhalten aus Test 1 mit 10 Eigenvektoren

Test 1 / 10 EigVal	CI 0	CI 1	CI 2	CI 3	CI 4	CI 5	Sum
illum 02	1	0	0	0	0	0	1
illum 03	1	0	0	0	0	0	1
illum 04	0,9	0	0,1	0	0	0	1
illum 05	0,1	0,16	0,74	0	0	0	1
illum 06	0	0,32	0,65	0,03	0	0	1
illum 07	0	0,39	0,58	0,03	0	0	1
illum 08	0	0,1	0	0,81	0	0,1	1
illum 09	0	0	0	0	0	1	1
illum 10	0,1	0,16	0,74	0	0	0	1
illum 11	0	0,06	0	0,87	0	0,06	1
illum 12	0	0	0	0,03	0	0,97	1
illum 13	0	0	0	0	0,52	0,48	1
illum 14	0	0	0	0	0,58	0,42	1
illum 15	0	0	0	0	1	0	1
illum 16	0	0	0	0	1	0	1
illum 17	0	0	0	0	1	0	1
illum 18	0,61	0,1	0,29	0	0	0	1
illum 19	0	0,26	0,74	0	0	0	1
illum 20	0	0,06	0	0,87	0	0,06	1
illum 21	0	0	0	0	0	1	1
illum 22	0	0	0	0	0,84	0,16	1
lights 00	0	0,19	0	0,81	0	0	1
lights 01	0	0,19	0	0,81	0	0	1
lights 02	0,87	0,1	0,03	0	0	0	1
lights 03	0,71	0,1	0,19	0	0	0	1
lights 04	0	0,16	0,84	0	0	0	1
lights 05	0	0,23	0,77	0	0	0	1
lights 06	0	0,26	0,42	0,32	0	0	1
lights 07	0	0,26	0,32	0,42	0	0	1
lights 08	0	0,16	0	0,84	0	0	1
lights 09	0	0	0	0,29	0	0,71	1
lights 10	0	0,26	0,74	0	0	0	1
lights 11	0	0,16	0	0,84	0	0	1
lights 12	0	0	0	0,32	0	0,68	1
lights 13	0	0	0	0	0	1	1
lights 14	0	0	0	0	0	1	1
lights 15	0	0	0	0	0	1	1
lights 16	0	0	0	0	0,58	0,42	1
lights 17	0	0	0	0	0,84	0,16	1
lights 18	0	0,19	0,81	0	0	0	1
lights 19	0	0,23	0,68	0,1	0	0	1
lights 20	0	0,13	0	0,87	0	0	1
lights 21	0	0	0	0,16	0	0,84	1
lights 22	0	0	0	0	0	1	1
lights 23	0	0,19	0	0,81	0	0	1



Tabelle A.23: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 6 Clustern erhalten aus Test 2 mit 10 Eigenvektoren

Test 2 / 10 EigVal	CI 0	CI 1	CI 2	CI 3	CI 4	CI 5	Sum
illum 02	0	0	0	0	0	1	1
illum 03	0	0	0	0	0	1	1
illum 04	0	0	0	0	0,03	0,97	1
illum 05	0	0	0	0	0,81	0,19	1
illum 06	0	0	0	0,06	0,94	0	1
illum 07	0	0	0	0,06	0,94	0	1
illum 08	0,03	0	0	0,97	0	0	1
illum 09	0	0	0,84	0,16	0	0	1
illum 10	0	0	0	0	0,81	0,19	1
illum 11	0	0	0	1	0	0	1
illum 12	0	0	0,84	0,16	0	0	1
illum 13	0	0,42	0,58	0	0	0	1
illum 14	0	0,45	0,55	0	0	0	1
illum 15	0	0,97	0,03	0	0	0	1
illum 16	0	1	0	0	0	0	1
illum 17	0	1	0	0	0	0	1
illum 18	0	0	0	0	0,26	0,74	1
illum 19	0	0	0	0	1	0	1
illum 20	0	0	0	1	0	0	1
illum 21	0	0	0,9	0,1	0	0	1
illum 22	0	0,84	0,16	0	0	0	1
lights 00	0,97	0	0	0,03	0	0	1
lights 01	0,97	0	0	0,03	0	0	1
lights 02	0	0	0	0	0	1	1
lights 03	0	0	0	0	0,19	0,81	1
lights 04	0,03	0	0	0	0,9	0,06	1
lights 05	0,03	0	0	0	0,97	0	1
lights 06	0,26	0	0	0,1	0,65	0	1
lights 07	0,32	0	0	0,1	0,58	0	1
lights 08	0,26	0	0	0,74	0	0	1
lights 09	0	0	0,58	0,42	0	0	1
lights 10	0,06	0	0	0	0,94	0	1
lights 11	0,16	0	0	0,84	0	0	1
lights 12	0	0	0,52	0,48	0	0	1
lights 13	0	0	0,97	0,03	0	0	1
lights 14	0	0	0,97	0,03	0	0	1
lights 15	0	0	1	0	0	0	1
lights 16	0	0,32	0,68	0	0	0	1
lights 17	0	0,68	0,32	0	0	0	1
lights 18	0,03	0	0	0	0,97	0	1
lights 19	0,1	0	0	0,06	0,84	0	1
lights 20	0,13	0	0	0,87	0	0	1
lights 21	0	0	0,74	0,26	0	0	1
lights 22	0	0	1	0	0	0	1
lights 23	0,97	0	0	0,03	0	0	1

Tabelle A.24: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 6 Clustern erhalten aus Test 3 mit 10 Eigenvektoren

Test 3 / 10 EigVal	CI 0	CI 1	CI 2	CI 3	CI 4	CI 5	Sum
illum 02	0	1	0	0	0	0	1
illum 03	0	1	0	0	0	0	1
illum 04	0	1	0	0	0	0	1
illum 05	0,16	0,74	0,1	0	0	0	1
illum 06	0,39	0	0,61	0	0	0	1
illum 07	0,39	0	0,61	0	0	0	1
illum 08	0,29	0	0,19	0	0,03	0,48	1
illum 09	0	0	0	0	0,39	0,61	1
illum 10	0,16	0,71	0,13	0	0	0	1
illum 11	0,23	0	0,19	0	0,03	0,55	1
illum 12	0	0	0	0	0,39	0,61	1
illum 13	0	0	0	0,58	0,29	0,13	1
illum 14	0	0	0	0,58	0,26	0,16	1
illum 15	0	0	0	0,9	0,1	0	1
illum 16	0	0	0	1	0	0	1
illum 17	0	0	0	1	0	0	1
illum 18	0,1	0,9	0	0	0	0	1
illum 19	0,35	0,1	0,55	0	0	0	1
illum 20	0,26	0	0,19	0	0	0,55	1
illum 21	0	0	0	0	0,39	0,61	1
illum 22	0	0	0	0,84	0,13	0,03	1
lights 00	0,29	0	0,71	0	0	0	1
lights 01	0,29	0	0,71	0	0	0	1
lights 02	0	1	0	0	0	0	1
lights 03	0,1	0,9	0	0	0	0	1
lights 04	0,19	0,52	0,29	0	0	0	1
lights 05	0,29	0	0,71	0	0	0	1
lights 06	0,29	0	0,71	0	0	0	1
lights 07	0,29	0	0,71	0	0	0	1
lights 08	0,32	0	0,39	0	0	0,29	1
lights 09	0,03	0	0	0	0,26	0,71	1
lights 10	0,29	0	0,71	0	0	0	1
lights 11	0,26	0	0,48	0	0	0,26	1
lights 12	0,03	0	0	0	0,26	0,71	1
lights 13	0	0	0	0	0,29	0,71	1
lights 14	0	0	0	0	0,29	0,71	1
lights 15	0	0	0	0	0,32	0,68	1
lights 16	0	0	0	0,58	0,26	0,16	1
lights 17	0	0	0	0,77	0,23	0	1
lights 18	0,26	0,06	0,68	0	0	0	1
lights 19	0,29	0	0,71	0	0	0	1
lights 20	0,26	0	0,48	0	0	0,26	1
lights 21	0	0	0	0	0,29	0,71	1
lights 22	0	0	0	0	0,29	0,71	1
lights 23	0,29	0	0,71	0	0	0	1

Tabelle A.25: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 7 Clustern erhalten aus Test 1 mit 4 Eigenvektoren

Test 1 / 4 EigVal	CI 0	CI 1	CI 2	CI 3	CI 4	CI 5	CI 6	Sum
illum 02	1	0	0	0	0	0	0	1
illum 03	1	0	0	0	0	0	0	1
illum 04	0,84	0,06	0,1	0	0	0	0	1
illum 05	0,03	0,26	0,71	0	0	0	0	1
illum 06	0	0,35	0,39	0,26	0	0	0	1
illum 07	0	0,39	0,35	0,26	0	0	0	1
illum 08	0	0	0	0,61	0	0,39	0	1
illum 09	0	0	0	0	0,71	0,29	0	1
illum 10	0,03	0,26	0,71	0	0	0	0	1
illum 11	0	0	0	0,65	0	0,35	0	1
illum 12	0	0	0	0	0,74	0,26	0	1
illum 13	0	0	0	0	0,29	0,13	0,58	1
illum 14	0	0	0	0	0,32	0,1	0,58	1
illum 15	0	0	0	0	0	0	1	1
illum 16	0	0	0	0	0	0	1	1
illum 17	0	0	0	0	0	0	1	1
illum 18	0,42	0,13	0,45	0	0	0	0	1
illum 19	0	0,39	0,61	0	0	0	0	1
illum 20	0	0	0	0,74	0	0,26	0	1
illum 21	0	0	0	0	0,77	0,23	0	1
illum 22	0	0	0	0	0,13	0,03	0,84	1
lights 00	0	0,03	0	0,81	0	0,16	0	1
lights 01	0	0,03	0	0,81	0	0,16	0	1
lights 02	0,81	0,1	0,1	0	0	0	0	1
lights 03	0,19	0,13	0,68	0	0	0	0	1
lights 04	0	0,23	0,77	0	0	0	0	1
lights 05	0	0,29	0,68	0,03	0	0	0	1
lights 06	0	0,26	0,16	0,58	0	0	0	1
lights 07	0	0,26	0,1	0,65	0	0	0	1
lights 08	0	0	0	0,74	0	0,26	0	1
lights 09	0	0	0	0,13	0,52	0,35	0	1
lights 10	0	0,29	0,68	0,03	0	0	0	1
lights 11	0	0	0	0,74	0	0,26	0	1
lights 12	0	0	0	0,13	0,55	0,32	0	1
lights 13	0	0	0	0	0,74	0,26	0	1
lights 14	0	0	0	0	0,74	0,26	0	1
lights 15	0	0	0	0	0,77	0,23	0	1
lights 16	0	0	0	0	0,45	0,06	0,48	1
lights 17	0	0	0	0	0,19	0,06	0,74	1
lights 18	0	0,29	0,71	0	0	0	0	1
lights 19	0	0,26	0,42	0,32	0	0	0	1
lights 20	0	0	0	0,77	0	0,23	0	1
lights 21	0	0	0	0,06	0,68	0,26	0	1
lights 22	0	0	0	0	0,77	0,23	0	1
lights 23	0	0,03	0	0,81	0	0,16	0	1

Tabelle A.26: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 7 Clustern erhalten aus Test 2 mit 4 Eigenvektoren

Test 2 / 4 EigVal	CI 0	CI 1	CI 2	CI 3	CI 4	CI 5	CI 6	Sum
illum 02	0	0	0	0	0	1	0	1
illum 03	0	0	0	0	0	1	0	1
illum 04	0	0	0	0	0,06	0,94	0	1
illum 05	0	0	0	0	0,87	0,13	0	1
illum 06	0	0	0	0,13	0,87	0	0	1
illum 07	0	0	0	0,13	0,87	0	0	1
illum 08	0,58	0	0	0,42	0	0	0	1
illum 09	0	0	0,9	0,1	0	0	0	1
illum 10	0	0	0	0	0,9	0,1	0	1
illum 11	0,65	0	0	0,35	0	0	0	1
illum 12	0	0	0,9	0,1	0	0	0	1
illum 13	0	0,84	0,16	0	0	0	0	1
illum 14	0	0,84	0,16	0	0	0	0	1
illum 15	0	0,39	0	0	0	0	0,61	1
illum 16	0	0,06	0	0	0	0	0,94	1
illum 17	0	0	0	0	0	0	1	1
illum 18	0	0	0	0	0,32	0,68	0	1
illum 19	0	0	0	0,1	0,9	0	0	1
illum 20	0,65	0	0	0,35	0	0	0	1
illum 21	0	0,13	0,77	0,1	0	0	0	1
illum 22	0	0,97	0,03	0	0	0	0	1
lights 00	0,74	0	0	0,26	0	0	0	1
lights 01	0,74	0	0	0,26	0	0	0	1
lights 02	0	0	0	0	0	1	0	1
lights 03	0	0	0	0	0,19	0,81	0	1
lights 04	0	0	0	0	1	0	0	1
lights 05	0	0	0	0,1	0,9	0	0	1
lights 06	0,39	0	0	0,19	0,42	0	0	1
lights 07	0,42	0	0	0,26	0,32	0	0	1
lights 08	0,71	0	0	0,29	0	0	0	1
lights 09	0,13	0	0,65	0,23	0	0	0	1
lights 10	0	0	0	0,1	0,9	0	0	1
lights 11	0,71	0	0	0,29	0	0	0	1
lights 12	0,13	0	0,65	0,23	0	0	0	1
lights 13	0	0	0,9	0,1	0	0	0	1
lights 14	0	0	0,9	0,1	0	0	0	1
lights 15	0	0,32	0,61	0,06	0	0	0	1
lights 16	0	1	0	0	0	0	0	1
lights 17	0	1	0	0	0	0	0	1
lights 18	0	0	0	0,03	0,97	0	0	1
lights 19	0,1	0	0	0,16	0,74	0	0	1
lights 20	0,71	0	0	0,29	0	0	0	1
lights 21	0,1	0	0,71	0,19	0	0	0	1
lights 22	0	0,03	0,87	0,1	0	0	0	1
lights 23	0,74	0	0	0,26	0	0	0	1

Tabelle A.27: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 7 Clustern erhalten aus Test 3 mit 4 Eigenvektoren

Test 3 / 4 EigVal	CI 0	CI 1	CI 2	CI 3	CI 4	CI 5	CI 6	Sum
illum 02	0	1	0	0	0	0	0	1
illum 03	0	1	0	0	0	0	0	1
illum 04	0	0,94	0,06	0	0	0	0	1
illum 05	0,13	0,13	0,74	0	0	0	0	1
illum 06	0,35	0	0,65	0	0	0	0	1
illum 07	0,42	0	0,58	0	0	0	0	1
illum 08	0,19	0	0	0	0,06	0,74	0	1
illum 09	0	0	0	0,48	0,42	0,1	0	1
illum 10	0,13	0,13	0,74	0	0	0	0	1
illum 11	0,16	0	0	0	0,06	0,77	0	1
illum 12	0	0	0	0,52	0,39	0,1	0	1
illum 13	0	0	0	0,61	0,29	0	0,1	1
illum 14	0	0	0	0,65	0,26	0	0,1	1
illum 15	0	0	0	0,1	0,03	0	0,87	1
illum 16	0	0	0	0	0	0	1	1
illum 17	0	0	0	0	0	0	1	1
illum 18	0,1	0,65	0,26	0	0	0	0	1
illum 19	0,26	0	0,74	0	0	0	0	1
illum 20	0,16	0	0	0	0,06	0,77	0	1
illum 21	0	0	0	0,61	0,35	0,03	0	1
illum 22	0	0	0	0,29	0,13	0	0,58	1
lights 00	0,23	0	0	0	0	0,77	0	1
lights 01	0,23	0	0	0	0	0,77	0	1
lights 02	0,03	0,94	0,03	0	0	0	0	1
lights 03	0,1	0,77	0,13	0	0	0	0	1
lights 04	0,16	0,03	0,81	0	0	0	0	1
lights 05	0,23	0	0,77	0	0	0	0	1
lights 06	0,32	0	0,52	0	0	0,16	0	1
lights 07	0,32	0	0,48	0	0	0,19	0	1
lights 08	0,19	0	0	0	0	0,81	0	1
lights 09	0	0	0	0,23	0,26	0,52	0	1
lights 10	0,23	0	0,77	0	0	0	0	1
lights 11	0,19	0	0	0	0	0,81	0	1
lights 12	0	0	0	0,23	0,26	0,52	0	1
lights 13	0	0	0	0,68	0,29	0,03	0	1
lights 14	0	0	0	0,68	0,29	0,03	0	1
lights 15	0	0	0	0,68	0,32	0	0	1
lights 16	0	0	0	0,71	0,29	0	0	1
lights 17	0	0	0	0,58	0,23	0	0,19	1
lights 18	0,19	0	0,81	0	0	0	0	1
lights 19	0,26	0	0,68	0	0	0,06	0	1
lights 20	0,19	0	0	0	0	0,81	0	1
lights 21	0	0	0	0,42	0,26	0,32	0	1
lights 22	0	0	0	0,68	0,32	0	0	1
lights 23	0,23	0	0	0	0	0,77	0	1

Tabelle A.28: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 7 Clustern erhalten aus Test 1 mit 10 Eigenvektoren

Test 1 / 10 EigVal	CI 0	CI 1	CI 2	CI 3	CI 4	CI 5	CI 6	Sum
illum 02	1	0	0	0	0	0	0	1
illum 03	1	0	0	0	0	0	0	1
illum 04	0,81	0,13	0,06	0	0	0	0	1
illum 05	0,1	0,35	0,55	0	0	0	0	1
illum 06	0	0,29	0,58	0,13	0	0	0	1
illum 07	0	0,35	0,55	0,1	0	0	0	1
illum 08	0	0	0	0,68	0	0,32	0	1
illum 09	0	0	0	0	0,71	0,29	0	1
illum 10	0,1	0,35	0,55	0	0	0	0	1
illum 11	0	0	0	0,74	0	0,26	0	1
illum 12	0	0	0	0,03	0,71	0,26	0	1
illum 13	0	0	0	0	0,26	0,13	0,61	1
illum 14	0	0	0	0	0,29	0,13	0,58	1
illum 15	0	0	0	0	0	0	1	1
illum 16	0	0	0	0	0	0	1	1
illum 17	0	0	0	0	0	0	1	1
illum 18	0,58	0,23	0,19	0	0	0	0	1
illum 19	0	0,35	0,65	0	0	0	0	1
illum 20	0	0	0	0,74	0	0,26	0	1
illum 21	0	0	0	0	0,74	0,26	0	1
illum 22	0	0	0	0	0,13	0,03	0,84	1
lights 00	0	0	0	0,87	0	0,13	0	1
lights 01	0	0	0	0,87	0	0,13	0	1
lights 02	0,87	0,1	0,03	0	0	0	0	1
lights 03	0,61	0,19	0,19	0	0	0	0	1
lights 04	0	0,29	0,71	0	0	0	0	1
lights 05	0	0,29	0,71	0	0	0	0	1
lights 06	0	0,23	0,32	0,45	0	0	0	1
lights 07	0	0,23	0,32	0,45	0	0	0	1
lights 08	0	0	0	0,77	0	0,23	0	1
lights 09	0	0	0	0,23	0,42	0,35	0	1
lights 10	0	0,29	0,71	0	0	0	0	1
lights 11	0	0	0	0,77	0	0,23	0	1
lights 12	0	0	0	0,26	0,45	0,29	0	1
lights 13	0	0	0	0	0,74	0,26	0	1
lights 14	0	0	0	0	0,71	0,29	0	1
lights 15	0	0	0	0	0,77	0,23	0	1
lights 16	0	0	0	0	0,52	0,1	0,39	1
lights 17	0	0	0	0	0,23	0,06	0,71	1
lights 18	0	0,29	0,71	0	0	0	0	1
lights 19	0	0,26	0,61	0,13	0	0	0	1
lights 20	0	0	0	0,77	0	0,23	0	1
lights 21	0	0	0	0,06	0,65	0,29	0	1
lights 22	0	0	0	0	0,71	0,29	0	1
lights 23	0	0	0	0,87	0	0,13	0	1

Tabelle A.29: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 7 Clustern erhalten aus Test 2 mit 10 Eigenvektoren

Test 2 / 10 EigVal	CI 0	CI 1	CI 2	CI 3	CI 4	CI 5	CI 6	Sum
illum 02	0	0	0	0	0	1	0	1
illum 03	0	0	0	0	0	1	0	1
illum 04	0	0	0	0	0,03	0,97	0	1
illum 05	0	0	0	0	0,81	0,19	0	1
illum 06	0	0	0	0,06	0,94	0	0	1
illum 07	0	0	0	0,06	0,94	0	0	1
illum 08	0,03	0	0	0,97	0	0	0	1
illum 09	0	0	0,9	0,1	0	0	0	1
illum 10	0	0	0	0	0,81	0,19	0	1
illum 11	0	0	0	1	0	0	0	1
illum 12	0	0	0,87	0,13	0	0	0	1
illum 13	0	0,81	0,19	0	0	0	0	1
illum 14	0	0,84	0,16	0	0	0	0	1
illum 15	0	0,42	0	0	0	0	0,58	1
illum 16	0	0,03	0	0	0	0	0,97	1
illum 17	0	0	0	0	0	0	1	1
illum 18	0	0	0	0	0,26	0,74	0	1
illum 19	0	0	0	0	1	0	0	1
illum 20	0	0	0	1	0	0	0	1
illum 21	0	0,19	0,77	0,03	0	0	0	1
illum 22	0	0,94	0,06	0	0	0	0	1
lights 00	0,97	0	0	0,03	0	0	0	1
lights 01	0,97	0	0	0,03	0	0	0	1
lights 02	0	0	0	0	0	1	0	1
lights 03	0	0	0	0	0,19	0,81	0	1
lights 04	0,03	0	0	0	0,9	0,06	0	1
lights 05	0,03	0	0	0	0,97	0	0	1
lights 06	0,26	0	0	0,1	0,65	0	0	1
lights 07	0,32	0	0	0,1	0,58	0	0	1
lights 08	0,29	0	0	0,71	0	0	0	1
lights 09	0	0	0,77	0,23	0	0	0	1
lights 10	0,06	0	0	0	0,94	0	0	1
lights 11	0,19	0	0	0,81	0	0	0	1
lights 12	0	0	0,77	0,23	0	0	0	1
lights 13	0	0	1	0	0	0	0	1
lights 14	0	0	1	0	0	0	0	1
lights 15	0	0,29	0,71	0	0	0	0	1
lights 16	0	0,94	0,06	0	0	0	0	1
lights 17	0	1	0	0	0	0	0	1
lights 18	0,03	0	0	0	0,97	0	0	1
lights 19	0,1	0	0	0,06	0,84	0	0	1
lights 20	0,13	0	0	0,87	0	0	0	1
lights 21	0	0	0,77	0,23	0	0	0	1
lights 22	0	0	1	0	0	0	0	1
lights 23	0,97	0	0	0,03	0	0	0	1

Tabelle A.30: Relative Häufigkeit der vorgegebenen Beleuchtungsklassen in 7 Clustern erhalten aus Test 3 mit 10 Eigenvektoren

Test 3 / 10 EigVal	CI 0	CI 1	CI 2	CI 3	CI 4	CI 5	CI 6	Sum
illum 02	0	1	0	0	0	0	0	1
illum 03	0	1	0	0	0	0	0	1
illum 04	0	0,97	0,03	0	0	0	0	1
illum 05	0,13	0,13	0,74	0	0	0	0	1
illum 06	0,26	0	0,74	0	0	0	0	1
illum 07	0,32	0	0,68	0	0	0	0	1
illum 08	0,1	0	0	0	0	0,84	0,06	1
illum 09	0	0	0	0	0,52	0,1	0,39	1
illum 10	0,16	0,13	0,71	0	0	0	0	1
illum 11	0,06	0	0	0	0	0,87	0,06	1
illum 12	0	0	0	0	0,52	0,1	0,39	1
illum 13	0	0	0	0,29	0,39	0	0,32	1
illum 14	0	0	0	0,26	0,45	0	0,29	1
illum 15	0	0	0	0,87	0,06	0	0,06	1
illum 16	0	0	0	1	0	0	0	1
illum 17	0	0	0	1	0	0	0	1
illum 18	0,1	0,65	0,26	0	0	0	0	1
illum 19	0,16	0	0,84	0	0	0	0	1
illum 20	0,06	0	0	0	0	0,9	0,03	1
illum 21	0	0	0	0	0,61	0,03	0,35	1
illum 22	0	0	0	0,65	0,23	0	0,13	1
lights 00	0,19	0	0	0	0	0,81	0	1
lights 01	0,19	0	0	0	0	0,81	0	1
lights 02	0,1	0,87	0,03	0	0	0	0	1
lights 03	0,1	0,77	0,13	0	0	0	0	1
lights 04	0,16	0,03	0,81	0	0	0	0	1
lights 05	0,23	0	0,77	0	0	0	0	1
lights 06	0,23	0	0,52	0	0	0,26	0	1
lights 07	0,26	0	0,45	0	0	0,29	0	1
lights 08	0,16	0	0	0	0	0,84	0	1
lights 09	0	0	0	0	0,29	0,45	0,26	1
lights 10	0,23	0	0,77	0	0	0	0	1
lights 11	0,16	0	0	0	0	0,84	0	1
lights 12	0	0	0	0	0,29	0,45	0,26	1
lights 13	0	0	0	0	0,68	0,03	0,29	1
lights 14	0	0	0	0	0,68	0,03	0,29	1
lights 15	0	0	0	0	0,68	0	0,32	1
lights 16	0	0	0	0	0,68	0	0,32	1
lights 17	0	0	0	0,16	0,58	0	0,26	1
lights 18	0,19	0	0,81	0	0	0	0	1
lights 19	0,23	0	0,68	0	0	0,1	0	1
lights 20	0,13	0	0	0	0	0,87	0	1
lights 21	0	0	0	0	0,45	0,29	0,26	1
lights 22	0	0	0	0	0,68	0	0,32	1
lights 23	0,19	0	0	0	0	0,81	0	1



## Tabellen- und Abbildungsverzeichnis

Abb. 2.1:	Ein Beispiel für die Relation zwischen $V_{total}$ , $V_{intra-class}$ und $V_{inter-class}$ .....	2
Abb. 2.2:	Ein Beispiel für die Relation zwischen $V_{illumination}$ , $V_{identity}$ , $V_{intra-class}$ und $V_{inter-class}$ .....	3
Abb. 2.3:	Das Modell des Gesichtserkenners, basierend auf zwei Schritten (oben), mit Identifizierung in Klassen (Mitte), mit Vorbearbeitung (unten) .....	6
Abb. 3.1:	Modell des Half Face Recognizer .....	10
Abb. 3.2:	Modell des Eigen With Mirror.....	11
Abb. 3.3:	Effekt des Laplace- und Sobel-Operators auf das Bild des Gesichtes.....	12
Abb. 3.4:	Effekt der künstlichen Generierung von Beleuchtung.....	12
Tabelle 3.1:	Überblick über alle Arten von Algorithmen aus Kapitel 3.2 .....	13
Abb. 4.1:	Klassen mit ähnlichen (oben) und unähnlichen (unten) Bildern .....	15
Abb. 4.2:	Bilder einer Person in drei Cluster aufgeteilt.....	15
Abb. 4.3:	Bilder einer Person in vier Cluster aufgeteilt.....	16
Tabelle 4.1:	Gesamtklassifizierungsrate der Lichtklassifikationsalgorithmen .....	16
Tabelle 4.2:	Klassifikationsrate der Lichtklassifikationsalgorithmen unter der Bedingung der verschiedenen Parameter .....	16
Tabelle 4.3:	Ergebnisse der Gesichtserkennung einzeln für jede Beleuchtungsklasse	17
Tabelle 4.4:	Gesichtserkennungsergebnisse aller Algorithmen.....	19
Abb. 4.4:	Unbekleideter Roboter .....	20
Abb. 4.5:	Bekleideter Roboter .....	20
Tabelle 4.5:	Anteil der Bilder der Personen in den Clustern bei der Roboter Datenbank.....	21
Abb. 4.6:	Bilder von drei Clustern der Roboter Datenbank .....	21
Tabelle 4.6:	Ergebnisse der Gesichtserkennung auf der Roboter Datenbank.....	23
Abb. 4.7:	Bilder von 3 Clustern der ausgerichteten Roboter Datenbank.....	23
Tabelle 4.7:	Anteil der Bilder der Personen in den Clustern bei der Roboter Datenbank mit ausgerichteten Bildern .....	24
Tabelle 4.8:	Ergebnisse der Gesichtserkennung der Roboter Datenbank mit ausgerichteten Bildern.....	25

## Literaturverzeichnis

- [1] Y. Adini, Y. Moses and S. Ullman, "Face Recognition: The Problem of Compensating for Changes in Illumination Direction", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 19, No. 7, pp. 721-732, July 1997
- [2] S. F. Arnold, "The Theory of Linear Models and Multivariate Analysis", John Wiley & Sons, New York, 1981
- [3] J. Bacher, "Clusteranalyse: Anwendungsorientierte Einführung", R. Oldenbourg Verlag Wien München GmbH, 1994
- [4] K. Backhaus, B. Erichson, W. Plinke, R. Weiber, "Multivariate Analysemethoden: eine anwendungsorientierte Einführung", - 8. verb. Auflage - , Springer-Verlag, Berlin, Heidelberg, New York, 1996
- [5] P.N. Belhumeur, J.P. Hespanha and D.J. Kriegman, "Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection"; *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 19, No. 7, pp. 711-720, July 1997
- [6] V. Blanz, T. Vetter, "Face Recognition Based on Fitting a 3D Morphable Model", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 25, No. 9, September 2003
- [7] A. Bronstein, M. Bronstein, and R. Kimmel, "Expression Invariant 3D Face Recognition", *Proceedings, International Conference on Audio- and Video-Based Biometric Person Authentication*, 2003
- [8] R. Brunelli, and T. Poggio, "Face Recognition: Features versus Templates", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 15, No. 10, pp. 1042-1052, October 1993
- [9] H.K. Ekenel, B. Sankur, "Multiresolution Face Recognition", *Image and Vision Computing*, Vol. 23, No.5, pp. 469-477, May 2005
- [10] A.S. Georghiades, D.J. Kriegman, P.N. Belhumeur, "Illumination Cones for Recognition Under Variable Lighting: Faces", *Computer Vision and Pattern Recognition*, 1998. *Proceedings, 1998, IEEE Computer Society Conference on*
- [11] R.C. Gonzalez, R.E. Woods, "Digital image processing", Addison-Wesley Publishing Company, 1993
- [12] R. Gross, S. Baker, I. Matthews, T. Kanade, "Face Recognition Across Pose and Illumination", *Proceedings of the German Symposium on Pattern Recognition (DAGM)*, September, 2002

- [13] R. Gross, I. Matthews, S. Baker, "Eigen Light-Fields for Face Recognition Across Pose", Proceedings of the IEEE International Conference on Automatic Face and Gesture Recognition, May, 2002
- [14] R. Gross, J. Shi and J Cohn, "Quo Vadis Face Recognition?", Third Workshop on Empirical Evaluation Methods in Computer Vision 2001
- [15] J. Ho, K.-C. Lee, D. Kriegman, "On Reducing the Complexity of Illumination Cones for Face Recognition", 4th International Conference on Audio- and Video-Based Biometric Person Authentication, June, 2003
- [16] J. Huang, B. Heisele, and V. Blanz, "Component-Based Face Recognition with 3D Morphable Models", Proceedings, International Conference on Audio- and Video-Based Biometric Person Authentication, 2003
- [17] A.M. Martinez and A.C. Kak, "PCA versus LDA", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 23, No. 2, pp 228-233
- [18] A. Pentland, B. Moghaddam, T. Starner and M. Turk, "View Based and Modular Eigenspaces for Face Recognition", Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition, pp. 84-91, 1994
- [19] F. Perronnin, J.-L. Dugelay, "A Model of Illumination Variation for Robust Face Recognition", Workshop on Multimodal User Authentication (MMUA '03), Santa Barbara, December 2003
- [20] C. Sanderson, K.K. Paliwal, "Fast Features for Face Authentication Under Illumination Direction Changes", Pattern Recognition Letters 24 (2003) 2409 - 2419
- [21] E. Seemann, "Estimating Head Orientation with Stereo Vision", Diplomarbeit Universität Karlsruhe, 2003
- [22] T. Sim, S. Baker and M. Bsat, "The CMU Pose, Illumination and Expression (PIE) Database", Proceedings of IEEE International Conference on Automatic Face And Gesture Recognition, May 2002
- [23] T. Sim, T. Kanade, "Combining Models and Exemplars for Face Recognition", Proceedings of Workshop on Models versus Exemplars in Computer Vision, CVPR 2001
- [24] H. Wang, S.Z. Li, Y. Wang, W. Zhang, "Illumination Modeling and Normalization for Face Recognition", Proceedings of the IEEE International Workshop on Analysis and Modeling of Faces and Gesture, October 2003
- [25] W. Zhao, R. Chellappa, P.J. Phillips and A. Rosenfeld, "Face Recognition: A Literature Survey", ACM Computing Surveys, Vol. 35, No. 4, pp. 399-458, 2003

