

Farbkalibrierung und Farbkonstanz für die Objekterkennung

Masterarbeit

[September 2010]

Student:

Rettenbacher, Markus, BSc

retti@sbox.tugraz.at

Betreuer:

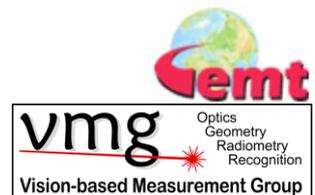
Pinz, Axel, Ao. Univ.-Prof. Dipl.-Ing. Dr.techn.

axel.pinz@tugraz.at



**Institut für Elektrische Messtechnik
und Messsignalverarbeitung
Technische Universität Graz**

Leiter: Univ.-Prof. Dipl.-Ing. Dr. techn. Georg Brasseur



Colour Calibration and Colour Constancy for Object Recognition

Master's Thesis

[September 2010]

Student:

Rettenbacher, Markus, BSc

retti@sbox.tugraz.at

Adviser:

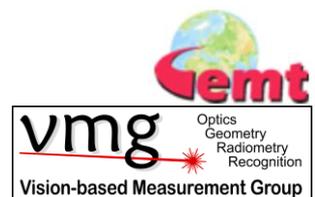
Pinz, Axel, Ao. Univ.-Prof. Dipl.-Ing. Dr.techn.

axel.pinz@tugraz.at



**Institute of Electrical Measurement
and Measurement Signal Processing
Technical University Graz**

Leader: Univ.-Prof. Dipl.-Ing. Dr. techn. Georg Brasseur



DANKSAGUNG

Diese Masterarbeit wurde in den Jahren 2009 bis 2010 in der Vision-based Measurement Group am Institut für Elektrische Messtechnik und Messsignalverarbeitung an der Technischen Universität Graz durchgeführt.

An dieser Stelle möchte ich mich bei meinem Betreuer und Begutachter Ao. Univ.-Prof. Dipl.-Ing. Dr.techn. Axel Pinz für die Unterstützung bei der Durchführung meiner Masterarbeit bedanken.

Weiters möchte ich mich bei allen Mitgliedern der Vision-based Measurement Group bedanken. Stets waren sie bereit mich bei der Durchführung zahlreicher Experimente zu unterstützen.

Mein besonderer Dank gilt meinem Vater und meinem Stiefvater, die mich bis 2009 begleitet und unterstützt haben.

Großer Dank gilt meiner Mutter, die mich während meines gesamten Studiums in jeder Hinsicht unterstützt hat. Weiters danke ich für die schöne Zeit im Theatercafé unter deiner Führung.

Ebenso bedanken möchte ich mich bei meinen beiden Geschwistern, meinen Großeltern, Tanten, Taufpaten, Studienkollegen und Freunden für deren Unterstützung.

Graz, September 2010

Markus Rettenbacher

EIDESSTÄTTLICHE ERKLÄRUNG

Ich erkläre an Eides statt, dass ich die vorliegende Arbeit selbstständig verfasst, andere als die angegebenen Quellen/Hilfsmittel nicht benutzt und die den benutzten Quellen wörtlich und inhaltlich entnommenen Stellen als solche kenntlich gemacht habe.

Graz, am

.....

(Unterschrift)

Englische Fassung:

STATUTORY DECLARATION

I declare that I have authored this thesis independently, that I have not used other than the declared sources / resources and that I have explicitly marked all material which has been quoted either literally or by content from the used sources.

.....

date

.....

(signature)

KURZFASSUNG

Diese Arbeit untersucht, wie man mit Hilfe der Farbinformationen von Objekten in einer Szene Farbkonstanz erreichen kann. Dafür wird unter anderem auch Hautfarbe in Betracht gezogen.

Nach einer kurzen Einführung wird ein Überblick über die bisherige Forschungsarbeit in den Bereichen Farbkalibrierung, Farbkonstanz, Farbkonstanz-Algorithmen, farbbasierte Objekterkennung und Farbkonstanz für die farbbasierte Objekterkennung gegeben.

Farbkalibrierungsalgorithmen werden in dieser Arbeit dazu verwendet, um Farbkonstanz zu erzielen. Dazu werden unterschiedliche Möglichkeiten vorgeschlagen und untersucht. Außerdem wird gezeigt, wie man Farbkalibrierungsalgorithmen auch bei ungleichförmiger Beleuchtung verwenden könnte. Weiters wird für einen ausgewählten Farbkalibrierungsalgorithmus [69] untersucht, ob man diesen durch einen nichtlinearen Optimierungsalgorithmus verbessern kann. Dabei wird mathematisch genau begründet, warum keine Verbesserung erzielt werden kann. Durch eine andere Methode, bei der die beiden Modelle, auf denen der Algorithmus [69] basiert, iterativ hintereinander bis zur Konvergenz ausgeführt werden, kann sogar eine Verbesserung erzielt werden.

Für die Experimente wurde ein farbbasierter Objektlokalisationsalgorithmus [19] implementiert, dessen Abhängigkeit von der Beleuchtung auch genauer untersucht wird. Danach wird überprüft, ob sich die Ergebnisse des Algorithmus durch vorgeschlagene Farbkonstanzmethoden, die die Farbinformationen von Objekten in einer Szene nutzen, verbessern. Jenes Objekt, dessen Farbinformationen bei der Farbkorrektur verwendet wurden, konnte dadurch danach, wie erwartet, tatsächlich jedes Mal mit einer höheren Wahrscheinlichkeit gefunden werden. Beim Grossteil der vorgeschlagenen Methoden konnten danach auch nahezu alle anderen Objekte, die sich in der Szene befanden, mit einer höheren Wahrscheinlichkeit gefunden werden. Am erfolgreichsten war man bei der Kalibrierung auf die Farben eines Targets.

Vor allem jene Methoden, welche die Farben von "natürlichen" Objekten verwenden, sind für zukünftige Anwendungen durchaus interessant. Dazu zählt auch jene Methode, wo die menschliche Hautfarbe verwendet wird.

ABSTRACT

This work examines, how to achieve Colour Constancy based on the colour information of objects in a scene. Besides coloured objects and colour targets, also skin colour is considered.

After a short introduction an overview about the previous work in the areas Colour Calibration, Colour Constancy, Colour Constancy algorithms, colour based Object Recognition and Colour Constancy for Object Recognition is given.

This work also shows, how to use Colour Calibration algorithms to achieve Colour Constancy. For this, different possibilities are suggested and examined. Furthermore, it is shown, how to use Colour Calibration algorithms under nonuniform illumination. For a selected Colour Calibration algorithm [69] it is examined, if it can be improved by nonlinear optimization. Fundamental reasons are explained why no improvement can be achieved. But a new method is described, which executes the two models from the algorithm [69] iteratively till convergence. With this method, better results than with the original algorithm [69], are achieved.

For the experiments, a colour based Object Localization algorithm [19] was implemented. Its dependency on illumination is analyzed in detail. It is examined, if the results of the algorithm can be improved with suggested Colour Constancy methods, which use the colour information of objects in a scene. As expected, the objects, whose colour information has been used for the colour correction, can always be detected with a higher probability. In most cases, detection rates increase as well for other objects that were not used for Colour Constancy. It is shown, that the best results can be achieved by calibrating with respect to a colour calibration target.

Those methods, which require the colour of “natural” objects will be very interesting for future applications. This also includes methods, where human skin colour is used.

INHALTSVERZEICHNIS

Danksagung	iii
Kurzfassung	v
Abstract	vi
1] Motivation und Problemdefinition	1
2] Einführung	3
2.1] Sichtbares Licht	3
2.2] Das Bildformations-Modell	3
2.3] Farbe und Farbprobleme	5
2.3.1] Metamers	6
2.4] Farbkalibrierung	6
2.5] Farbkonstanz	7
2.6] Farbkonstanz beim Menschen	8
3] Bisherige Forschungsarbeiten	11
3.1] Farbkalibrierung	11
3.2] Farbkonstanz und Farbkonstanz-Algorithmen	11
3.3] Farbbasierte Objekterkennung und -lokalisierung	15
3.4] Farbkonstanz für die farbbasierte Objekterkennung	18
4] Equipment	21
4.1] Farbkameras	21
4.1.1] Farbbildaufnahme	21
4.2] Lichtquellen	23
4.3] Farbtargets	24
4.4] Objekte	25
5] Farbkalibrierung	27
5.1] Nichtlineare Optimierung eines Farbkalibrierungsalgorithmus	29
5.2] Verbesserte Farbkalibrierung durch Iteration	34

5.3] Farbkonstanz durch Farbkalibrierung	35
5.3.1] Kalibrierung mit einem Farbtar­get	35
5.3.2] Schätzen der Beleuchtung	37
5.3.3] Kalibrierung auf Objekt X	38
5.4] Farbkalibrierung bei ungleichförmiger Beleuchtung	38
6] Ausgewählte farbbasierte Algorithmen	43
6.1] Objektlokalisierung mit Receptive Field Cooccurrence Histograms	43
6.1.1] Einfluss der Beleuchtung auf den RFCH-Algorithmus	47
6.2] Hautdetektion	48
6.2.1] Einfluss der Beleuchtung auf die Hautdetektion	51
7] Farbkonstanz durch Objektlokalisierung und Experimente	53
7.1] Kalibrierung mit einem Farbtar­get	55
7.2] Kalibrierung auf Objekt X	57
7.3] Verbessern von Farbkonstanzalgorithmen durch Zusatzinformation	63
7.4] Erfüllen der Bedingungen einzelner Farbkonstanzalgorithmen	64
7.5] Farbkonstanz durch Hautdetektion	66
8] Zusammenfassung	68
Literaturverzeichnis	71
Anhang	79

1] Motivation und Problemdefinition

Im Bereich der Computer Vision wird Farbe in vielen Anwendungen als ein charakteristisches Merkmal verwendet. Der Vorteil von Farbe gegenüber vielen anderen Merkmalen eines Objektes ist, dass sie invariant bezüglich Translation, Rotation und Skalierung ist. Ein Nachteil wiederum ist der Einfluss verschiedener Beleuchtungsbedingungen (siehe Kapitel 2.3).

Anwendungen im Vision Bereich sind zum Beispiel die farbbasierte Objekterkennung und –lokalisierung sowie das farbbasierte Tracking.

Bei dieser Arbeit wird untersucht, wie man mit Hilfe der Farbinformation von Objekten in einer Szene Farbkonstanz erreichen kann (siehe Abbildung 1.1).

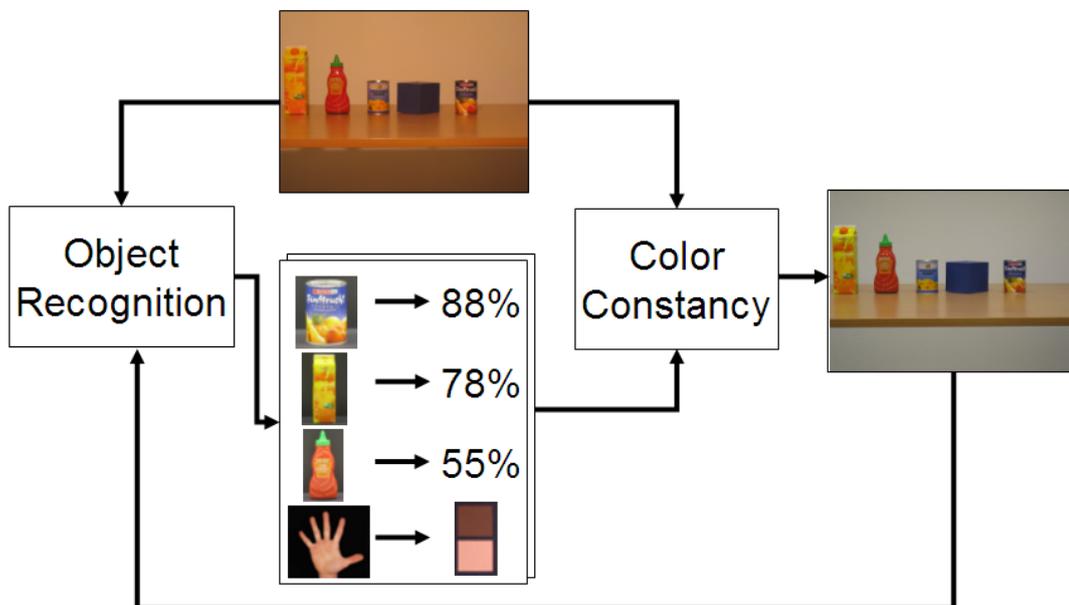


Abbildung 1.1: Objektlokalisationsalgorithmen liefern für jedes Objekt, das sie gesucht und gefunden haben, meist eine Boundingbox, die Auskunft über die Orte der Objekte im Bild gibt. Mit deren Farbinformation will man bei dieser Arbeit Farbkonstanz erreichen. Dafür wird unter anderem auch Hautfarbe herangezogen. Der verwendete farbbasierte Objektlokalisationsalgorithmus [19] sollte dadurch die Orte von Objekten im Bild mit einer höheren Wahrscheinlichkeit finden.

Es wird also nach bekannten Objekten in einer Szene gesucht, mit deren Farbinformation Farbkonstanz erzielt werden kann. Als Farbinformation sollte unter anderem auch Hautfarbe dienen.

Eine Möglichkeit wäre, auf die Farben von künstlichen Objekten (z.B. Farbtarget) als auch auf die von natürlichen Objekten zu kalibrieren. Die Referenzfarbwerte können zuvor unter einer vordefinierten Beleuchtung bestimmt werden. Die Kalibrierung selbst kann mit Farbkalibrierungsalgorithmen durchgeführt werden.

Eine andere Möglichkeit wäre, geeignete Farbkonstanzalgorithmen durch die Farbinformation von bestimmten Objekten in der Szene zu verbessern.

Die Objekte könnten eventuell auch einzelne Annahmen der Farbkonstanzalgorithmen erfüllen (z.B. hellster Fleck ist weiß).

Weiters wird untersucht wie die Resultate eines farbbasierten Objektlokalisationsalgorithmus [19] sowie von Skindetektionsalgorithmen durch die Beleuchtung beeinflusst werden und wie sich deren Resultate durch Farbkonstanz, die mit der Farbinformation von einem Objekt in der Szene erzielt wird, verbessern lassen.

Lediglich anwenden der für die gegebenen Bedingungen bestgeeigneten Algorithmen ist nicht Ziel dieser Arbeit.

Wurde durch die Farbinformation eines Objektes in der Szene Farbkonstanz erzielt, so sollte der Ort dieses Objektes im Bild mit einer höheren Wahrscheinlichkeit, durch den farbbasierten Objektlokalisationsalgorithmus [19], gefunden werden. Wünschenswerter Weise sollten auch andere Objekte in der Szene dadurch besser lokalisierbar sein.

Möglicherweise verbessern sich dadurch auch die Resultate einer Skindetektion.

2] Einführung

Im Folgenden wird eine Einführung rund um das Thema "Farbkalibrierung und Farbkonstanz für die Objekterkennung" gegeben. Dabei wird auf die Themen "Sichtbares Licht", "Das Bildformations-Modell", "Farbe und Farbprobleme", "Farbkalibrierung", "Farbkonstanz" sowie auf "Farbkonstanz beim Menschen" kurz eingegangen.

2.1] Sichtbares Licht

Das für den Menschen sichtbare Licht entspricht jenem Bereich der elektromagnetischen Strahlung, den unser Auge erfassen kann. Der Wellenlängenbereich reicht dabei von etwa 380 bis 780nm (siehe Abbildung 2.1).

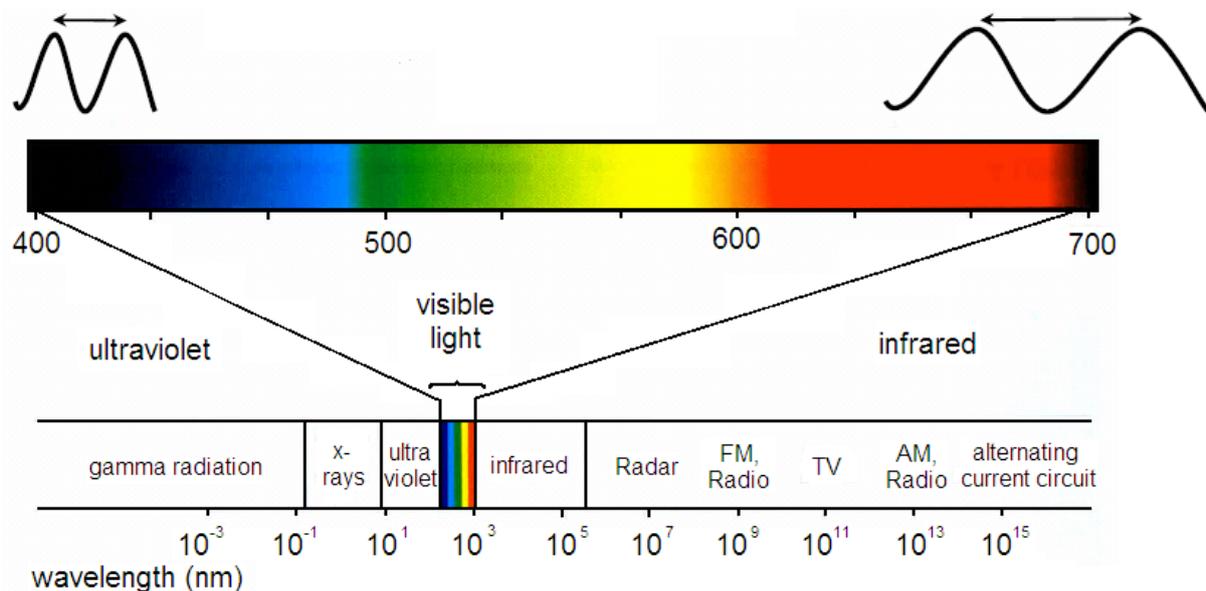


Abbildung 2.1: Nur ein kleiner Wellenlängenbereich des elektromagnetischen Spektrums ist für den Menschen sichtbar. Der Bereich reicht von etwa 380 bis 780nm. (angepasst von [36])

Sonnenlicht zum Beispiel (oder das Licht einer Glühlampe) erscheint uns weiß. Es ist eine Mischung aus unterschiedlichen Wellenlängen, die durch ein Prisma in einfärbige Anteile zerlegt werden kann.

2.2] Das Bildformations-Modell

Ein Pixel in einem Farbbild einer Kamera setzt sich zusammen aus dem Spektrum des Lichtes, welches die Szene beleuchtet, dem Reflexionskoeffizienten an der Stel-

le x und aus den Antwortfunktionen der drei Sensoren des Aufnahmesystems (siehe (2.1) und Abbildung 2.2) [41]:

$$s_k(x) = \int_0^\infty \rho(x, \lambda) E(\lambda) R_k(\lambda) d\lambda \quad (2.1)$$

- x : Punkt auf der Oberfläche eines Objektes
- λ : Wellenlänge
- k : Index des Sensorkanals, $k \in \{R, G, B\}$
- $s_k(x)$: Sensorantwort für Kanal k an der Stelle x
- $\rho(x, \lambda)$: spektraler Reflexionskoeffizient an der Stelle x
- $E(\lambda)$: spektrale Energieverteilung der Beleuchtung
- $R_k(\lambda)$: spektrale Sensitivitätsfunktion des k -ten Kanals des Sensors

Bei diesem Modell werden die Objekte als glatt, matt und gleichförmig beleuchtet angenommen.

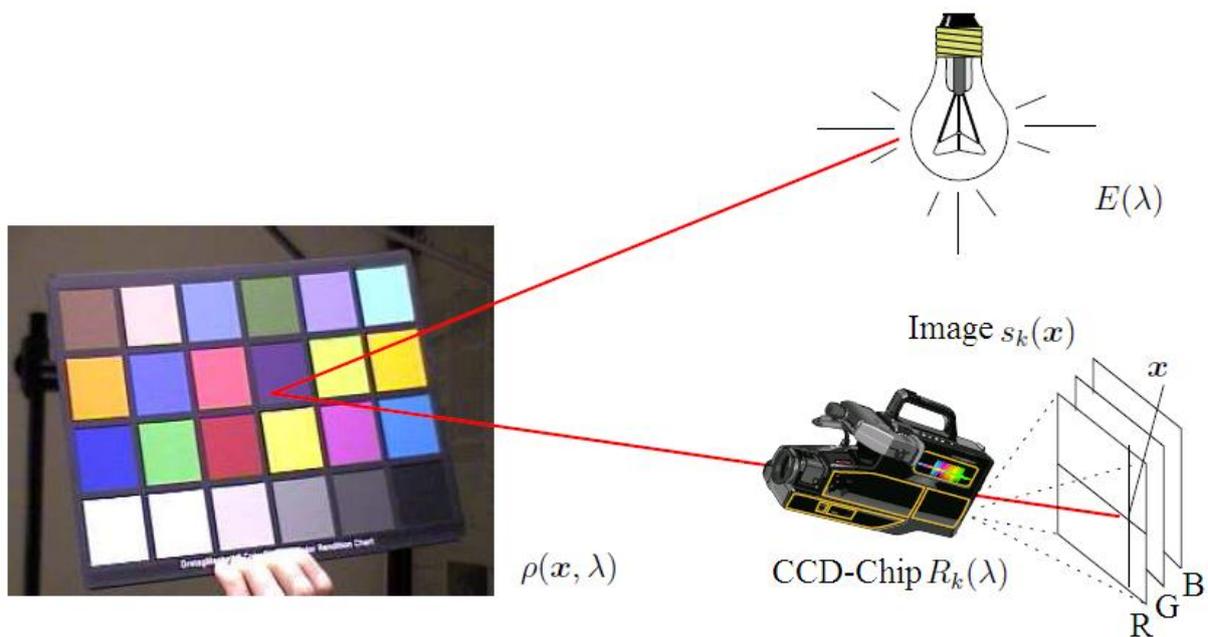


Abbildung 2.2: Ein Teil der von einer Lichtquelle ausgesendeten Bestrahlungsenergie $E(\lambda)$ trifft an der Stelle x auf. Der bestrahlte Punkt x reflektiert das Licht mit der spektralen Reflexivität $\rho(x, \lambda)$. $R_k(\lambda)$ entspricht der Sensorsensitivität des k -ten Kanals ($k \in \{R, G, B\}$). Die Sensorantwort für Kanal k an der Stelle x setzt sich aus den Komponenten $E(\lambda)$, $\rho(x, \lambda)$ und $R_k(\lambda)$ zusammen. (angepasst von [41])

2.3] Farbe und Farbprobleme [61]

Farbe ist keine direkt messbare physikalische Größe. Farbe wird wahrgenommen. Das Spektrum des Lichtes, welches in unsere Augen reflektiert wird, hängt nicht direkt mit der wahrgenommenen Farbe zusammen. Ein weißes Blatt Papier in unterschiedlichen Beleuchtungsszenarien zum Beispiel erscheint dem Menschen immer weiß – dem Photometer allerdings nicht.

Abbildung 2.3 zeigt, dass das Licht, das unsere Augen von einem Objekt erreicht, sich aus dem Produkt des Lichtspektrums, welches das Objekt beleuchtet, und der Objektoberflächen-Reflexion zusammensetzt. Mittels drei lichtempfindlichen Zellen wird das Licht vom menschlichen visuellen System über den Wellenlängenbereich von ca. 380 bis 780nm "abgetastet". Der Output des Auges ist ein diskretes Tripel von Farbwerten (X,Y,Z). Technische Geräte, wie zum Beispiel digitale Kameras, funktionieren ähnlich und liefern ebenfalls diskrete Zahlentripel (RGB-Werte).

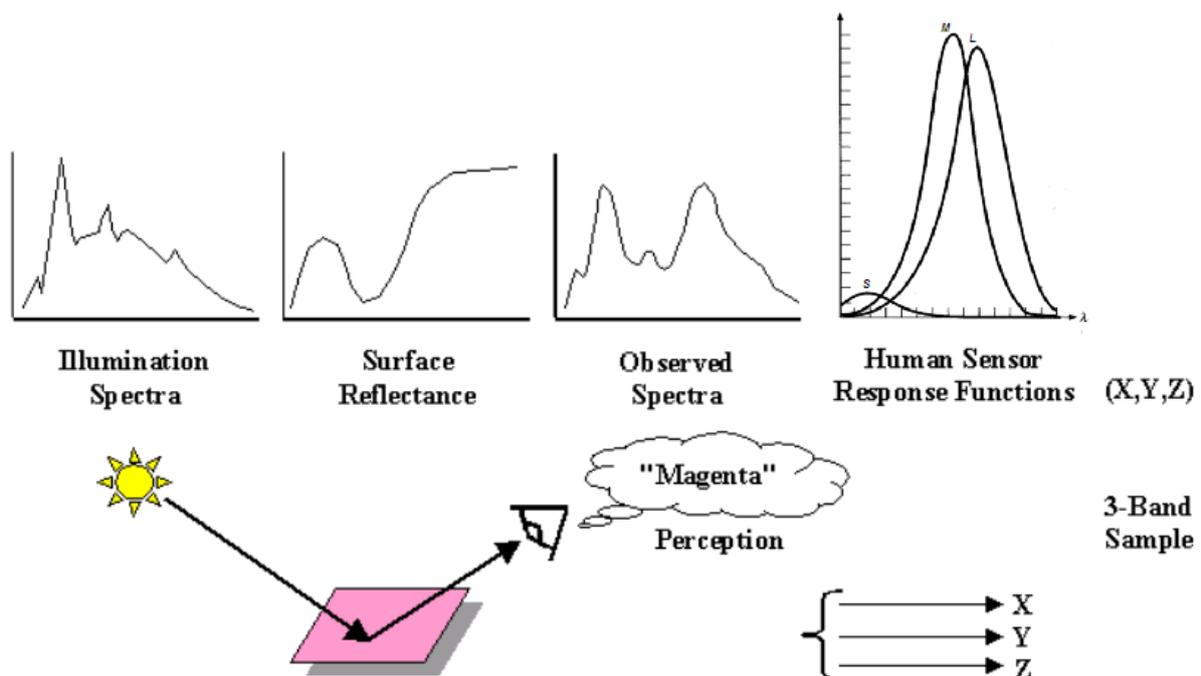


Abbildung 2.3: Das bei unseren Augen ankommende Licht setzt sich zusammen aus dem Produkt des Beleuchtungs- und Objektreflexionsspektrums. Das Licht wird vom Auge mittels drei lichtempfindlichen Zellen über den Wellenlängenbereich von ca. 380 bis 780 nm "abgetastet". Der Output ist ein diskretes Zahlentripel (X,Y,Z). (angepasst von [61])

Bei der "Abtastung" geht Information verloren. Das Originalspektrum kann somit nicht perfekt rekonstruiert werden. Es besteht keine Möglichkeit mehr, aus den diskreten

Werten die genauen Reflexionseigenschaften des Objektes zurück zu gewinnen. Weiters kann auch nicht das exakte Spektrum des Lichtes, welches die Szene beleuchtet, zurück gewonnen werden.

Das Hauptproblem aber ist, dass bei gleich bleibender Objektflächen-Reflexion eine Veränderung der Beleuchtung zu einer Veränderung der Sensor-Tripel-Antwort führt.

Um Objekte anhand ihrer Farbe identifizieren zu können, müssen also zusätzliche Informationen eingebracht werden.

2.3.1] Metamers

Rufen für eine gegebene Lichtart unterschiedliche Spektren den gleichen Farbeindruck hervor, spricht man von so genannten Metamers (siehe Abbildung 2.4). Metamers können nicht mehr durch Nachbearbeitung der vorhandenen Daten unterschieden werden. Farbkonstanz kann also nie perfekt sein.

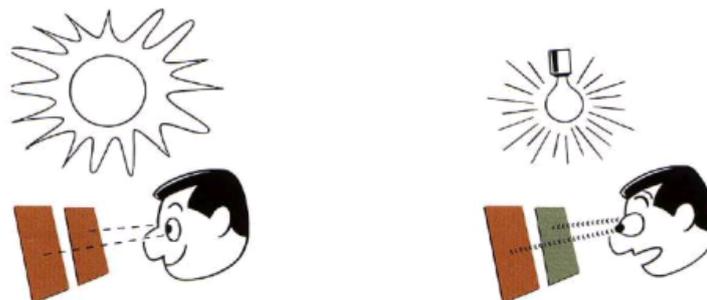


Abbildung 2.4: Erscheinen zwei Farben unterschiedlicher spektraler Zusammensetzung bei der einen Lichtsorte gleich und bei der anderen unterschiedlich, so werden sie im ersten Fall metamer genannt. (angepasst von [33])

2.4] Farbkalibrierung

Wird ein Bild einer Szene mit unterschiedlichen Kameras bei gleichen Bedingungen und Einstellungen aufgenommen, so werden die Farben meist nicht identisch dargestellt. Aufgrund von Produktionsschwankungen treten diese Farbfehler auch bei Kameramodellen desselben Herstellers und Exemplars auf.

Mittels Farbkalibrierung erhält man geräteunabhängige Farbbilder (siehe Abbildung 2.5). Dabei werden die unterschiedlichen Farbdarstellungen der verschiedenen Geräte standardisiert.

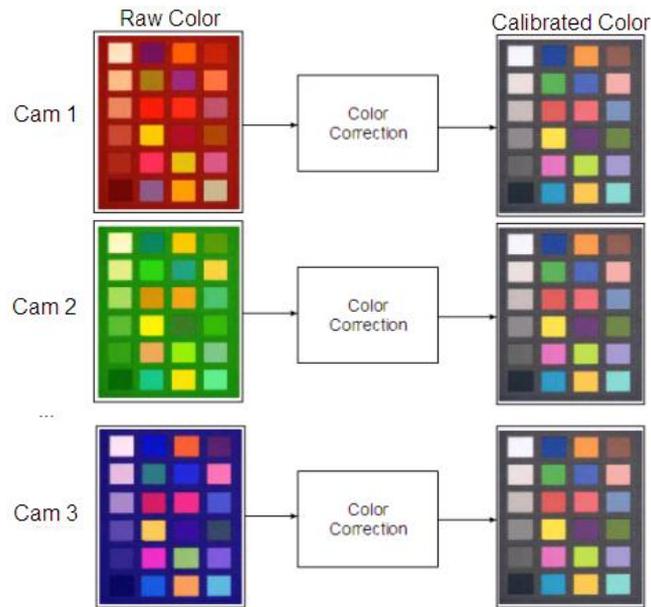


Abbildung 2.5: Werden Aufnahmen desselben Motivs mit unterschiedlichen Kameras gemacht, so sind Farbunterschiede festzustellen. Und das obwohl die Beleuchtung bei allen Kameras dieselbe ist. Bei der Farbkalibrierung werden die Farbwerte der unterschiedlichen Kameras so korrigiert, dass die Abweichungen untereinander minimal sind. (angepasst von [37])

Wenn man davon ausgeht, dass dasselbe Bild einer Szene unter gleichen Beleuchtungsbedingungen aufgenommen wird, liefern farbkalibrierte Kameras im Idealfall identische Bilder.

2.5] Farbkonstanz

Verschiedene Beleuchtungsbedingungen führen zu unterschiedlichen Farbdarstellungen (siehe Abbildung 2.6).



Abbildung 2.6: Obwohl für alle drei Aufnahmen dieselbe Kamera mit denselben Einstellungen verwendet wurde, werden die Farben, von der Beleuchtung abhängig, unterschiedlich dargestellt. (angepasst von [34])

Ziel der Farbkonstanz ist es, beleuchtungsunabhängig immer denselben Farbwert zu erhalten.

2.6] Farbkonstanz beim Menschen

Im Gegensatz zu technischen Bildaufnahmeegeräten ist der Mensch in der Lage, die Farbe von Objekten nahezu unabhängig vom Licht, welches die Objekte beleuchtet, zu erfassen (siehe Abbildung 2.7).

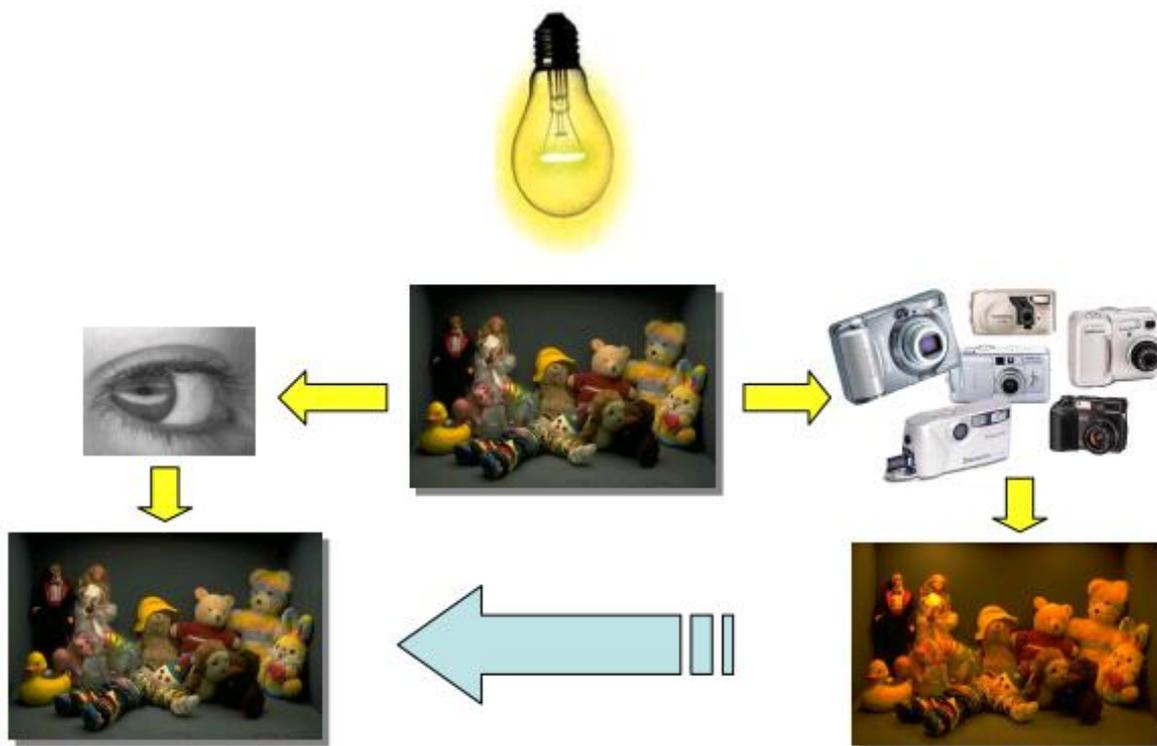


Abbildung 2.7: Das menschliche visuelle System ist in der Lage, nahezu unabhängig von der Lichtquelle, Farben konstant wahrzunehmen. Von technischen Bildaufnahmeegeräten erwartet man sich dasselbe. Deren Bilder wirken meist allerdings nicht so, wie sie der Mensch in Erinnerung hat, da deren Bildsensoren fixe spektrale Empfindlichkeiten besitzen. Eines der Ziele der rechnergestützten Farbkonstanz ist es, die Bilder so zurückzubringen, wie sie der Mensch gesehen und in Erinnerung hat. (aus [6])

Ohne Farbkonstanz können Objekte nicht zuversichtlich anhand ihrer Farbe identifiziert werden. Umgebende Farben, aber auch unser Gedächtnis, beeinflussen die Farbwirkung. Schnee beispielsweise erscheint uns immer weiß (siehe Abbildung 2.8).

Bis heute wissen wir noch nicht genau, wo und wie Farbkonstanz vom menschlichen visuellen System erreicht wird.

Die Farben, die der Mensch wahrnimmt, sind auch nicht perfekt konstant. Beispielsweise kann es passieren, dass ein im Geschäft (unter der umgebenden Wolfram-Beleuchtung) betrachteter Anzug dunkel braun erscheint und unter Tageslicht einen hässlichen Grünstich aufweist.



Abbildung 2.8: Der auf dem Foto bläulich erscheinende Schnee wird vom Menschen als weiß wahrgenommen. (aus [54])

Aus evolutionsbiologischer Sicht ist die Farbkonstanz sehr wichtig für uns. Dies lässt sich auch daran erkennen, dass von den einzelnen Sinnesorganen Sehen den größten Anteil an der Gehirnkapazität hat (83% Sehen; 11% Gehör; 3.5% Geruch) [31].

Viele alltägliche Aufgaben fallen uns durch das Farbsehen leichter (siehe Abbildung 2.9, 2.10 und 2.11).



Abbildung 2.9: Die Farbwahrnehmung erleichtert uns unter anderem das Auffinden von Beeren im Laub. (aus [29])



Abbildung 2.10: Farbe hat eine Signalfunktion. Sie ermöglicht es uns beispielsweise zwischen unreifem, reifem und überreifem Obst unterscheiden zu können. (aus [29])



Abbildung 2.11: Farbe vereinfacht und beschleunigt die Objekterkennung. (aus [29])

3] Bisherige Forschungsarbeiten

In diesem Kapitel wird ein Überblick über die bisherige Forschungsarbeit im Bereich Farbkalibrierung, Farbkonstanz und farbbasierte Objekterkennung/-lokalisierung gegeben.

3.1] Farbkalibrierung

Auf das Thema Farbkalibrierung, und im speziellen auf den Kalibrationsprozess, wird in Kapitel 5 näher eingegangen.

Algorithmen die zur Farbkalibrierung verwendet werden können, werden in [51] vorgestellt. Dabei sind auch jene Algorithmen [37, 52, 69] enthalten, die auch bei dieser Arbeit zur Farbkalibrierung verwendet werden.

3.2] Farbkonstanz und Farbkonstanz-Algorithmen

Durch Farbkonstanz ist es möglich die Farbe von Objekten unabhängig vom Beleuchtungsspektrum der Lichtquelle zu erfassen.

In diesem Forschungsgebiet werden mehrere Ziele verfolgt. Im Computer Vision Bereich versucht man den Reflexionskoeffizienten möglichst exakt abzuschätzen. Dieser Koeffizient erleichtert nämlich die Objekterkennung und -segmentierung.

Ein anderer Ansatz ist jene Farben zu ermitteln, wie sie unter einer vordefinierten Beleuchtung erscheinen würden.

Bei der Fotografie will man das menschliche visuelle System nachahmen. Schließlich möchte man jene Farben erhalten, die der Fotograf gesehen hat, als er das Bild aufnahm.

Das Problem der Farbkonstanz beschäftigt die Wissenschaftler bereits seit vielen Jahren. Es ist ein unterbestimmtes Problem, das nie perfekt gelöst werden kann. Aus drei Eingabewerten müssen sechs Unbekannte berechnet werden. Von den sechs Unbekannten beschreiben jeweils drei das Reflexionsspektrum und das Beleuchtungsspektrum. Das Problem ist ähnlich schwierig wie jenes bei der Segmentierung.

Einer der berühmtesten Forscher in diesem Gebiet ist Edwin H. Land (siehe Abbildung 3.1). Er formulierte die Retinex-Theorie und setzte sich damit in zahlreichen Experimenten auseinander.



Abbildung 3.1: Edwin H. Land war ein amerikanischer Forscher. Bekannt wurde er vor allem durch die von ihm verfasste Retinex-Theorie. Bei dieser Theorie wird davon ausgegangen, dass sowohl die Augen, als auch das Gehirn bei der Farbwahrnehmung involviert sind. (aus [5])

Land fand heraus, dass die vom Menschen wahrgenommene Farbe nicht von den absoluten Anteilen des reflektierten Lichtes abhängig ist, welches die Augen erreicht (siehe Abbildung 3.2).

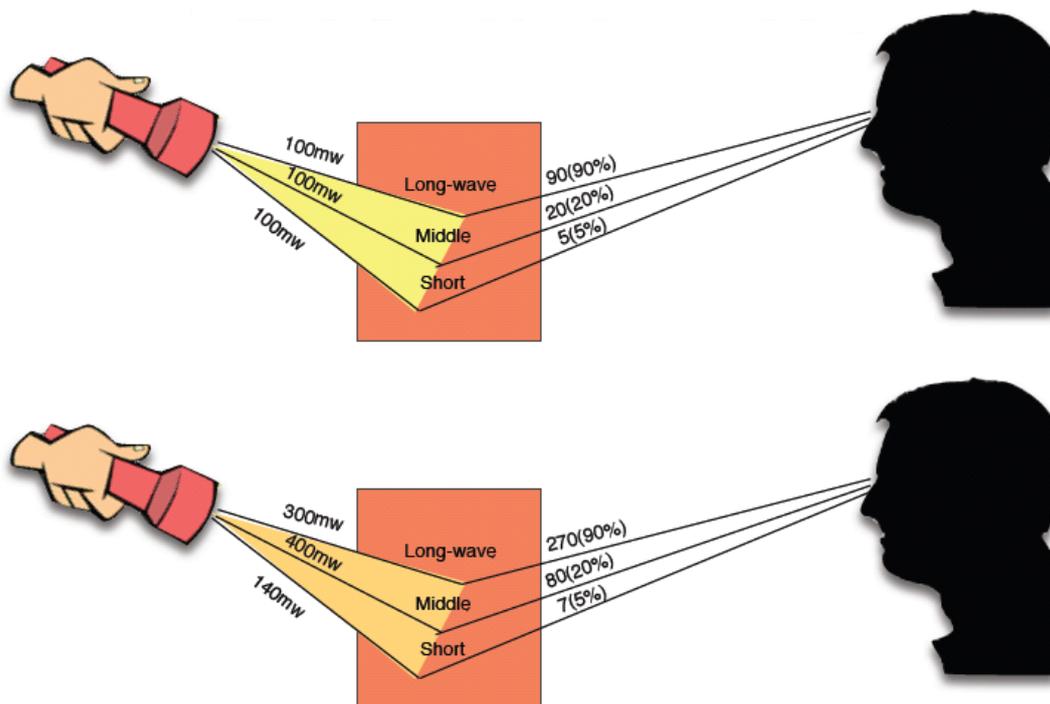


Abbildung 3.2: Die von einem Farbfleck reflektierten Lichtanteile haben keinen direkten Zusammenhang mit der vom Menschen wahrgenommenen Farbe. Beim unteren Bild wurden die Wellenlängen (long, middle, short) der Lichtquelle gegenüber dem oberen Bild verändert. Der Farbfleck erscheint dem Menschen jedoch noch immer in derselben Farbe wie im oberen Bild. (aus [5])

Den Effekt demonstrierte er mit so genannten “Mondrian-Bildern“ (siehe Abbildung 3.3). Diese bestehen aus mehreren zufällig angeordneten Farbflecken, und erinnern an die Bilder des Malers Mondrian (daher der Name).



Abbildung 3.3: Mit “Mondrian-Bildern“, wie hier oben dargestellt, entwickelte Edwin H. Land die Retinex-Theorie. Er benutzte dazu Farbpapierblätter, welche er zufällig anordnete. Diese wurden mit drei verschiedenen Projektoren, von denen jeder mit veränderbaren Filtern versehen war, beleuchtet. (aus [5])

Die Farbflecken beleuchtete er mit drei verschiedenen Lampen unterschiedlicher Wellenlängen (long, middle, short). Von einem Farbfleck, welcher für eine Testperson weiß erschien, wurden die reflektierten Intensitäten des roten, grünen und blauen Lichtanteils gemessen. Anschließend wurde die Testperson beauftragt, die Farbe eines Nachbarfarbfleckes zu identifizieren, welche beispielsweise grün erscheint. Als nun das vom grünen Fleck reflektierte Licht, durch variieren der Lichtquellen, so verändert wurde, dass es jenem vom zuvor gemessenen weißen Fleck entsprach, nahm die Testperson den Farbfleck immer noch als grün war. Auch der weiße Fleck erschien trotz Veränderung der einzelnen Lichtquellenintensitäten immer noch weiß.

Diese Form von Farbkonstanz wünscht man sich auch im technischen Bereich. Aufgrund der fixen spektralen Empfindlichkeiten eines digitalen Aufnahmesystems sind dessen Farbbilder jedoch von der Beleuchtung abhängig.

Um auch hier davon unabhängig zu sein, wurden zahlreiche Algorithmen unterschiedlicher Komplexität entwickelt (siehe Abbildung 3.4). Viele Fortschritte konnten bisher erzielt werden. Eine Auswahl der bekanntesten Farbkonstanzalgorithmen für

Bilder von gleichförmig (aber auch für ungleichförmig) beleuchtete Szenen wird in [17] vorgestellt. Vor- und Nachteile einzelner Algorithmen werden speziell in [1, 62] in tabellarischer Form gegenübergestellt.

Die meisten Arbeiten haben das Farbkonstanzproblem nur für künstliche Daten unter sehr einfachen physikalischen Bedingungen betrachtet. Wenige der Algorithmen wurden auch unter "realen" Bedingungen getestet. Die meisten von ihnen sind auch gar nicht für natürliche Bilder geeignet, da die spezifischen Bedingungen nicht erfüllt werden können.

Colour-by-Correlation Algorithmen [23] und Methoden die auf neuronalen Netzwerken [8] basieren, funktionieren beispielsweise für künstliche Bilder ziemlich gut [62]. Mit diesen Algorithmen können allerdings für reale Bilder keine ähnlich guten Ergebnisse erzielt werden [2].

Laut [3, 4] wurden mit dem Gamut Mapping Algorithmus [2] zum damaligen Zeitpunkt die besten Ergebnisse an realen Daten erzielt. Doch wie sich in Kapitel 3.4 noch zeigen wird, ist dieser Algorithmus für die Objekterkennung nicht gut genug.

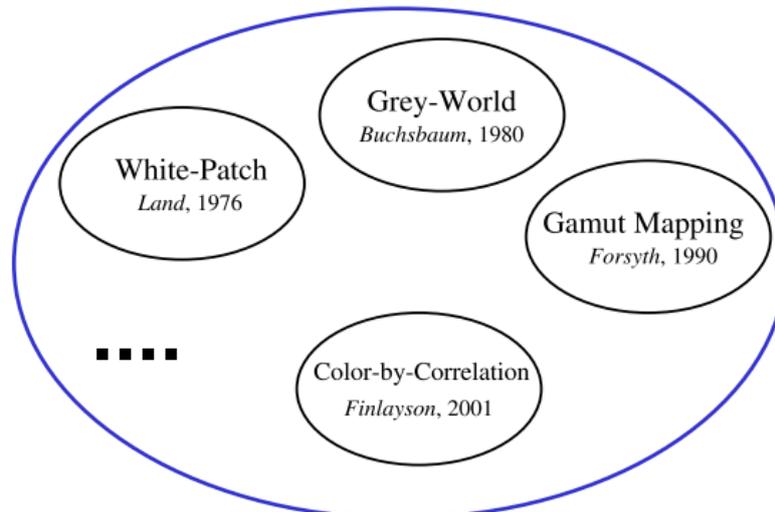


Abbildung 3.4: Im Laufe der Jahre wurden viele Farbkonstanzalgorithmen entwickelt. Jeder der Algorithmen funktioniert je nach Bedingungen unterschiedlich gut. (aus [68])

Aufgrund der vielen Annahmen die jeder Farbkonstanzalgorithmus mit sich bringt, kann keiner von ihnen universell eingesetzt werden.

Die Farbkonstanzforschung ist meist auf eine so genannte "Mondrian-Welt" begrenzt [25]. In dieser Welt gibt es fast immer nur eine einzige Lichtquelle, welche sich über

den Raum hinweg nicht verändert. Die Oberflächen werden meist als matt und frontal präsentiert angenommen. Es tritt auch kein Schatten auf. Alle Oberflächen sind Lambertian und jede Reflexion ist diffus. Die Oberflächenalbedo variiert nur mit der Wellenlänge. Diese Veränderung wird mit einer Oberflächenreflexionsfunktion beschrieben. Die Oberflächen fluoreszieren auch nicht.

Nicht immer ist es möglich Oberflächenreflexionen und Beleuchtungen so vorliegen zu haben, dass derzeitige Farbkonstanzalgorithmen überhaupt erfolgreich angewendet werden können. Die Anwendbarkeit der Algorithmen ist begrenzt. Werden die Annahmen der Algorithmen verletzt, funktionieren sie meist nicht mehr.

Viele der Algorithmen gehen davon aus, dass die Farbe der Welt im Durchschnitt grau ist. Diese Annahme kann vor allem dann zu Problemen führen, wenn nur sehr wenige Farben im Bild enthalten sind und wenn deren durchschnittliche Farbe nicht grau entspricht. Im Extremfall besteht ein Bild nur aus einer homogenen Fläche einer bestimmten Farbe (z.B. gelb). Bei diesem Bild ist es ohne zusätzlicher Information unmöglich festzustellen, ob diese Fläche tatsächlich gelb ist.

In der realen Welt hat man es nicht nur mit mehreren Lichtquellen zu tun, sondern auch damit, dass Oberflächen auch jenes Licht empfangen, welches von anderen Oberflächen reflektiert wird. Die Oberflächen der Objekte sind meistens auch nicht matt. Von Kleidung wird das Licht beispielsweise meist in eine bevorzugte Richtung reflektiert.

Man sieht, dass in Zukunft weitere Forschungsarbeit notwendig ist, damit alle Annahmen und Bedingungen der einzelnen Algorithmen ein wenig aufgelockert werden können.

3.3] Farbbasierte Objekterkennung und -lokalisierung

Ein Objekt kann durch verschiedene Eigenschaften beschrieben werden (siehe Abbildung 3.5).

Für die generische Objekterkennung ist die Form eines Objektes meist das wichtigste Merkmal. Wird nach einem spezifischen Objekt gesucht, so sind oft auch andere Eigenschaften sehr hilfreich, sofern man sie zuverlässig aus dem Bild berechnen kann.

In dieser Arbeit sind die Reflexionseigenschaften von Interesse. Diese bestimmen nämlich die Farben eines Objektes in einem Bild.

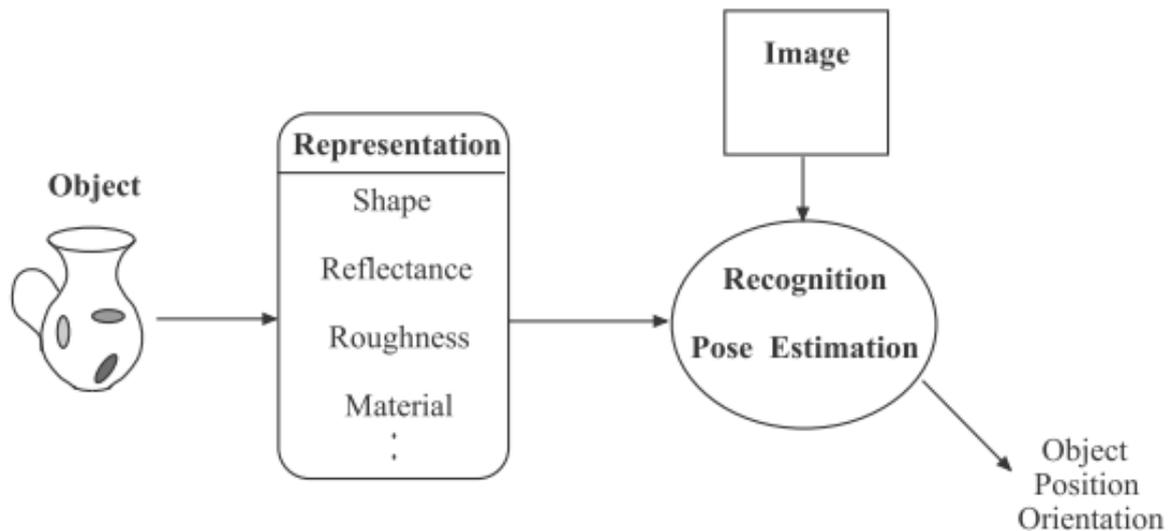


Abbildung 3.5: Ein Objekt wird durch mehrere Eigenschaften (Form, Reflexion, Rauheit, Material, ...) repräsentiert. Je nach Aufgabe werden unterschiedliche Eigenschaften für die Objekterkennung genutzt. (aus [45])

Wie in Kapitel 2.3 bereits ausführlich diskutiert wurde, werden die Objektfarben in einem Bild durch die Beleuchtung beeinflusst. Da es an guten Farbkonstanzalgorithmen mangelt, versuchten viele Forscher beleuchtungsunabhängige Farbinformation zu extrahieren die für die Objekterkennung genutzt werden kann [20, 30, 38, 42, 55]. Um gegenüber sich verändernde Lichtverhältnisse robuster zu sein, verwenden die meisten der farbbasierten Algorithmen relative (z.B. Verhältnisse von benachbarten Pixel [15, 22, 45]) anstatt absolute Farbdeskriptoren. Für Algorithmen die auf relativen Deskriptoren basieren, ist Farbkonstanz als Vorverarbeitungsschritt nicht unbedingt notwendig.

Um eine größere Menge von Objekten anhand der Farbe (unabhängig von der Beleuchtung) unterscheiden zu können, bräuchte man laut [59] nur die Anzahl der möglichen Farben im voraus auf ungefähr 200 zu beschränken um ohne Farbkonstanz auskommen zu können.

Für Farbkonstanzversuche scheinen Histogramm-Matching-Methoden [10, 18, 19, 59] am geeignetsten zu sein.

Prinzipiell unterscheidet man zwischen regular colour histograms, XY-colour histograms, colour cooccurrence histograms und receptive field cooccurrence histograms.

Das regular colour histogram enthält keine geometrische Informationen sondern nur eine Verteilung der Bildfarben [59]. Um dieses Histogramm erfolgreich zur Objekterkennung einsetzen zu können, darf kein Hintergrund um das Objekt sichtbar sein, wodurch es für dieses Projekt nicht geeignet ist.

XY-colour histograms enthalten zusätzlich geometrische Informationen, jedoch ist deren Anteil sehr gering. Sie eignen sich besonders gut für Objekte mit markanten Farben [18].

Mehr geometrische Informationen enthalten so genannte colour cooccurrence histograms [10, 18]. Bei diesen Histogrammen wird gezählt, wie oft Paare von Pixel (mit einer bestimmten Farbe) im Bild auftreten. Es werden dabei nur jene Pixelpaare betrachtet, die nicht weiter als eine maximale Distanz voneinander getrennt sind. Werden cooccurrence histograms zur Objektlokalisierung eingesetzt, so enthalten die die Objekte umgebenden Boundingboxen im Vergleich zu XY-histograms weniger Hintergrund. Dies geschieht jedoch auf Kosten der Vollständigkeit, wo in manchen Fällen nur 40% der Pixel eines Objektes enthalten sind [18]. Cooccurrence histograms sind sehr robust gegenüber Verdeckungen der Objekte. Selbst Objekte die bis zu 50% verdeckt sind, können mit diesen Histogrammen noch erfolgreich lokalisiert werden [18].

Receptive field cooccurrence histograms (RFCHs) erfassen noch mehr geometrische Informationen eines Objektes [19]. Sie repräsentieren wie oft Pixelpaare bestimmter Filterantworten und Farben nächst zu einander liegen. Auch mit RFCHs ist man in der Lage die Orte von teils verdeckten Objekten in Bildern erfolgreich zu lokalisieren. Für ein RFCH können unterschiedliche Deskriptoren herangezogen werden. Mit dem Anteil der zusätzlich zu den reinen Farbdeskriptoren verwendeten Deskriptoren, kann die enthaltene geometrische Information gewichtet werden.

Ein paar der Farbkonstanzversuche dieser Arbeit werden mit dem RFCH-Algorithmus durchgeführt. Dieser Algorithmus zeichnet sich vor allem dadurch aus, dass er für besonders viele verschiedene Objekte unter schwierigsten Bedingungen eingesetzt werden kann.

3.4] Farbkonstanz für die farbbasierte Objekterkennung

B. Funt, K. Barnard und L. Martin haben 1998 getestet, ob die von ihnen ausgewählten Farbkonstanzalgorithmen (greyworld, white-patch retinex, 2D/3D gamut-constraint und neural network) für die farbbasierte Objekterkennung gut genug sind [26]. Trotz der Tatsache, dass sie die für die damalige Zeit gut geltenden Algorithmen verwendet haben, war ihr Resultat negativ. Die Ergebnisse des Objekterkennungsalgorithmus verbesserten sich zwar, aber nicht signifikant.

Als Objekterkennungsstrategie wurde die "colour indexing"-Methode [59] von Swain und Ballard verwendet, welche auf dem Vergleich von Farbhistogrammen beruht. Wie die beiden Autoren bereits in ihrer Arbeit zeigten, verschlechtern sich die Testresultate dieser Methode bei sich verändernden Beleuchtungsbedingungen massiv. Mit Hilfe von Farbkonstanzalgorithmen, die als Vorverarbeitungsschritt eingesetzt werden, versuchte man, dieses Problem zu umgehen. Dabei wird für das Bild, welches bei einer unbekanntem Beleuchtung aufgenommen wurde, jenes Bild bestmöglich geschätzt, wie es unter einer vordefinierten Beleuchtung (Trainingsbeleuchtung) aussehen würde.

Die Farbkorrektur basiert auf einem Diagonalmodell, welches die Beleuchtungsänderung bestmöglich beschreibt. Mittels Skalierungsfaktoren können die R, G und B Kanäle dabei von einer Szenenbeleuchtung in die andere übergeführt werden. Die Skalierungsfaktoren werden als Elemente einer Diagonalmatrix dargestellt.

Die Experimente zeigten, dass die Farbkonstanzalgorithmen den Colour-Indexing Algorithmus in jenen Situationen verbesserten, in denen sich die Testbeleuchtung gegenüber der Trainingsbeleuchtung geändert hat.

Der Zusammenhang zwischen der colour indexing performance und dem colour constancy error ist in Abbildung 3.6 dargestellt.

Die Objekterkennungsperformance wurde hierbei durch gewichtete mittlere Einordnungsranklisten bestimmt. Beim Farbkonstanzerror wurde die Differenz des quadratischen Mittelwerts zwischen dem farbkorrigierten Bild und dem Referenzbild, welches unter einer vordefinierten Beleuchtung (Trainingsbeleuchtung) gemacht wurde, berechnet.

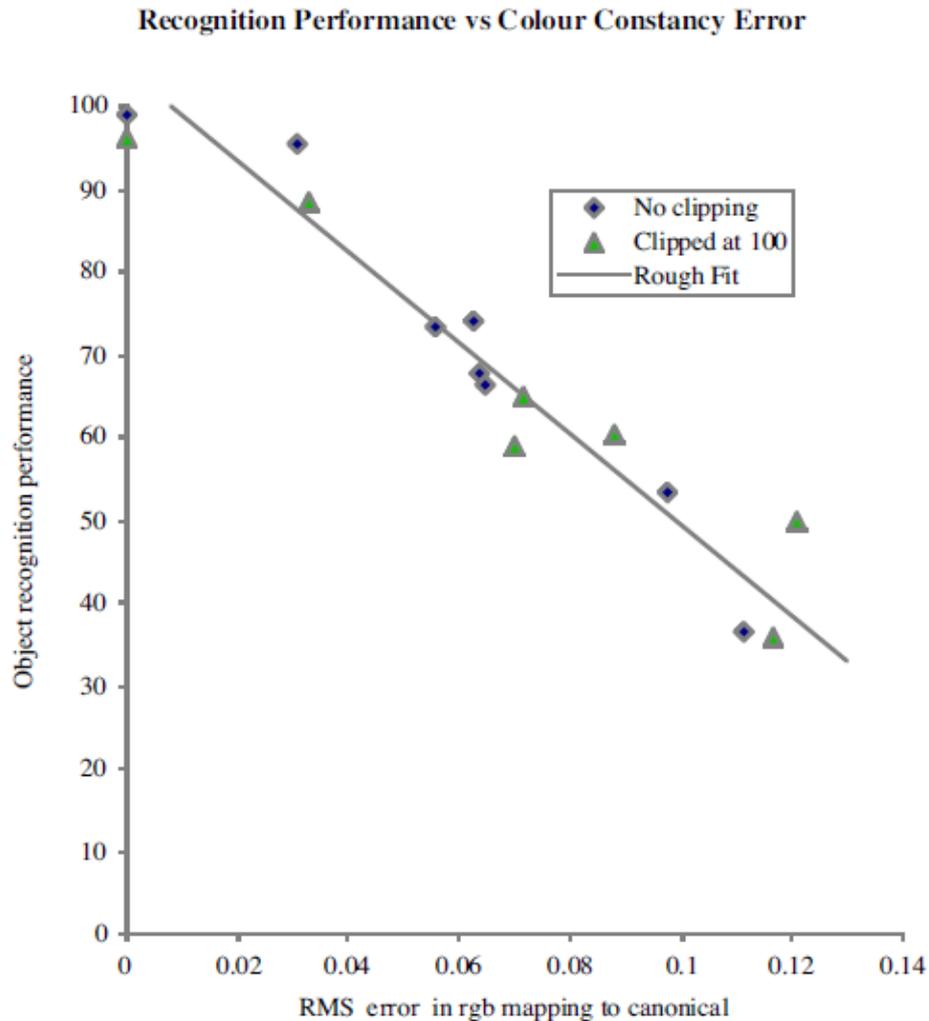


Abbildung 3.6: Die Grafik zeigt den Zusammenhang zwischen der Objekterkennungsperformance und dem RMS Farbkonstanzfehler. Eine Objekterkennungsperformance von über 80% ist bei einem Farbkonstanzfehler unter 0.04 gegeben. (aus [26])

Um absolute Farbdeskriptoren (im Gegensatz zu relativen, wie z.B. Farbverhältnisse) für einen Objekterkennungsalgorithmus verwenden zu können, sollte der RMS Farbkonstanzfehler zumindest unter 0.04 liegen. Damit erreicht man eine Objekterkennungsperformance von über 80%.

Tabelle 3.1 zeigt den erreichten RMS Farbkonstanzfehler aller getesteten Algorithmen. Bei "Actual" handelt es sich um keinen Farbkonstanzalgorithmus. Hier wurde das zuvor gemessene Spektrum der "unbekannten" Beleuchtung zur Farbkorrektur (basierend auf dem Diagonalmodell) herangezogen. Bei keinem der Algorithmen wurde ein RMS Farbkonstanzfehler unter 0.04 erreicht.

Algorithm	RMS Error
Nothing	0.1114
Actual	0.0306
White-Patch Retinex	0.0625
Greyworld	0.0975
2D Gamut-Constraint	0.0649
3D Gamut-Constraint	0.0555
Neural Net	0.0634

Tabelle 3.1: In der Tabelle ist der Farbkonstanzfehler aller getesteten Algorithmen aufgelistet. (aus [26])

Der White-Patch Retinex Algorithmus schnitt überraschend gut ab. Dies allerdings nur dann, wenn die getesteten Bildaufnahmen unterbelichtet waren, und somit kein Clipping auftrat.

Wie sich das Clipping-Level auf den RMS Farbkonstanzfehler der einzelnen Algorithmen auswirkt, wurde von den Forschern ebenfalls untersucht. Bei normalen Aufnahmen ist nämlich stets mit Clipping zu rechnen. Wie auch erwartet wurde, verschlechterte sich vor allem der White-Patch Retinex Algorithmus mit zunehmendem Clipping-Level sehr.

Bei anderen Arbeiten [13, 22] wurden verschiedene Farbnormalisierungsarten für eine verbesserte Objekterkennung und -lokalisierung angewendet.

Eine aktuellere Forschungsarbeit, die 2007 in Buchform erschienen ist, ist jene von Marc Ebner [17]. Im praktischen Teil seiner Arbeit experimentierte er mit 38 verschiedenen Farbkonstanzalgorithmen. Um Aussagen über die Qualität der Algorithmen machen zu können, testete er sie unter anderem auch anhand eines farbbasierenden Objekterkennungsalgorithmus [59]. Er unterteilte dabei die zu erkennenden Objekte, je nach Oberflächenbeschaffenheit (einfärbig, texturiert (komplex/ nicht komplex), gespiegelte Fläche, Leuchtfarben, transparent, gebürstetes Metall,...), in verschiedene Kategorien. Je nach Objektkategorie schnitten die Algorithmen unterschiedlich gut ab. Keiner der Algorithmen zeigte auf allen Bildkategorien gute Ergebnisse.

4] Equipment

In diesem Abschnitt wird das verwendete Equipment vorgestellt. Weiters wird auf die Farbbildaufnahme genauer eingegangen, da diese wesentlich ist, um akzeptable Ergebnisse bei den Farbkonstanzversuchen erzielen zu können.

4.1] Farbkameras

Am Institut stehen mehrere Farbkameras zur Verfügung (siehe Abbildung 4.1). Es handelt sich dabei um eine DFW-VL500 Sony Zoomkamera, eine IDS Stereokamera (2 uEye Kameras vom Typ UI-1220-C) und ein Magic Eye WLAN Kamerasystem, dessen Kamera an einem mobilen Fahrzeug montiert ist. Zusätzlich zu den industriellen Kameras kommen auch eine Canon IXUS 860 IS und einer Olympus E-510 zum Einsatz.



Abbildung 4.1: Für die Farbbildaufnahme stehen eine DFW-VL500 Sony Zoomkamera (mitte links), eine IDS Stereokamera (2 uEye Kameras vom Typ UI-1220-C) (oben rechts) und eine Magic Eye WLAN Kamera (mitte rechts) zur Verfügung. Zusätzlich werden auch eine Canon IXUS 860 IS und eine Olympus E-510 verwendet.

4.1.1] Farbbildaufnahme

Von den zur Verfügung stehenden industriellen Farbkameras (siehe Abbildung 4.1) lieferte die uEye Kamera vom Typ UI-1220-C die beste Farbbildqualität. Sie wurde

daher hauptsächlich für die einzelnen Versuche eingesetzt. Zusätzlich wurden auch Aufnahmen mit einer Canon IXUS 860 IS und einer Olympus E-510 gemacht.

Die Farbaufnahme für die uEye Kamera und die Olympus E-510 erfolgte im RAW-Format. Dieses Format enthält ein Abbild der Rohdaten des Bildsensors. Die so erhaltenen digitalen Daten sind von kamerainterner Bildbearbeitung, wie z.B. Weißabgleich oder Gammakorrektur, unversehen. Unbearbeitete Bilddaten werden bei den Farbkonstanzversuchen vorausgesetzt.

Bei der uEye Kamera musste die eigentliche Farbinformation erst rückgerechnet werden (Demosaicing). Der Sensor der Kamera ist mit einem Farbfilter (2x2 Bayer-Pattern) überzogen (siehe Abbildung 4.2).

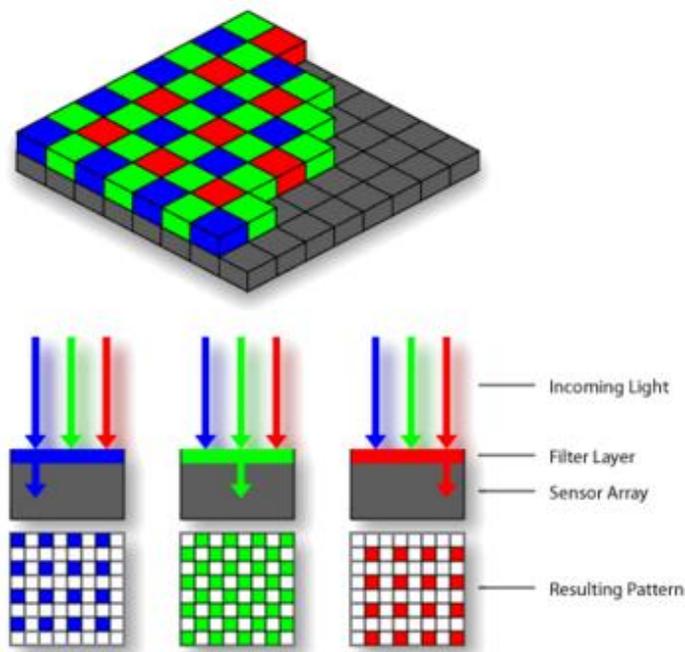


Abbildung 4.2: Hier ist der Aufbau des 2x2 Bayer-Patterns zu sehen. Das 2x2 Bayer-Pattern enthält doppelt so viele grün-empfindliche Pixel als rot- oder blau-empfindliche Pixel. Damit versucht man die Hellempfindlichkeitsfunktion des menschlichen Auges anzunähern, die für die Farbe Grün ein Maximum aufweist. [aus 67]

Beim Demosaicing wird das $N \times M \times 1$ RAW Bild des Sensors in ein $N \times M \times 3$ RGB Bild umgewandelt. Die Berechnung der fehlenden RGB-Werte erfolgt üblicherweise aus der lokalen Pixelinformation zuzüglich der Information des nahen Umfeldes. Dafür sind unterschiedliche Berechnungsmethoden möglich (vgl. z.B. [40] und die dort genannten Quellen).

Eine mögliche Methode, welche auch implementiert wurde, ist das Bilineare Demosaicing. Dabei wurden zunächst die fehlenden Werte jener Bildpunkte berechnet, wo die bekannten Werte die umliegenden Eckpunkte sind (die Werte wurden dabei einfach gemittelt). Dies war nur für den Rot- und Blau-Kanal notwendig, da diese Werte beim Grün-Kanal bereits bekannt sind. Darauf folgend wurden die restlichen fehlenden Farbwerte berechnet. Dies erfolgte für jeden Kanal jeweils mit den vier längs einer Kante bekannten Werten (auch diese wurden gemittelt).

Die Canon IXUS 860 IS wurde nur zweimal für die Farbkalibrierung in Kapitel 5 verwendet. Da bei dieser Kamera keine RAW-Bild Aufnahme möglich war, wurde stattdessen die kamerainterne Bildbearbeitung weitgehend deaktiviert (z.B. manueller statt automatischer Weißabgleich).

4.2] Lichtquellen

Die Versuche wurden größtenteils innerhalb des Bildmesslabors am Institut durchgeführt. Es wurde mit unterschiedlichen Lichtquellen (siehe Abbildung 4.3) experimentiert. Dabei wurde darauf geachtet, dass die Szene möglichst gleichmäßig beleuchtet war, da dies bei den meisten Versuchen vorausgesetzt wurde. Die Halogenbeleuchtung erfolgte daher beispielsweise indirekt (siehe Abbildung 4.4). Auch bei den anderen Beleuchtungsarten wurde versucht die Szene möglichst gleichmäßig zu beleuchten.

Die Aufnahmen bei wolkenlosem Tageslicht wurden zur Mittagszeit auf einer Dachterrasse gemacht.



Abbildung 4.3: Die Farbkonstanzversuche wurden mit den abgebildeten Lichtquellen (Halogen-, Tages- und Leuchtstoffröhrenlicht) durchgeführt.



Abbildung 4.4: Damit eine möglichst gleichförmige Beleuchtung sichergestellt werden konnte, erfolgte die Halogenbeleuchtung indirekt über eine weiße Leinwand.

Für den Halogenstrahler wurde eine Lampe vom Typ "Halogen Photo Optic Lamp von Osram 1000W" verwendet.

Für die Leuchtstoffröhrenbeleuchtung wurde eine "Philips Master TL5 HO 49W/840 (4000 K)"-Röhre verwendet, welche in einer Deckenlampe montiert war. Die Aufnahmen bei dieser Beleuchtung wurden unmittelbar darunter in einer Nische gemacht, wodurch eine nahezu gleichmäßige Beleuchtung erzielt werden konnte.

Um stabile Beleuchtungsverhältnisse bei der Leuchtstoffröhrenbeleuchtung zu garantieren, wurde nach dem Einschalten circa 5 Minuten gewartet, bevor Aufnahmen gemacht wurden.

4.3] Farbtargets

Als Farbtarjet standen zwei unterschiedliche Modelle zur Verfügung (siehe Abbildung 4.5).

Das linke Bild (Abbildung 4.5 a) entspricht dem "Munsell ColourChecker". Dieses Target besteht aus 18 Farbfeldern und einer 6 stufigen Grauskala. Die vorletzte Zeile enthält die Grundfarben Blau, Grün, Rot, Gelb, Magenta und Cyan. Die anderen

Farbfelder sind über das gesamte sichtbare Spektrum verteilt und enthalten unter anderem auch häufig vorkommende Farbtöne wie z.B. dunkle/helle Hautfarbe, blauer Himmel oder Laub. Bei den Experimenten wurde hauptsächlich mit diesem Target gearbeitet.

Das rechte Target (Abbildung 4.5 b) entspricht dem "IT-8 Standard". Es enthält ebenfalls eine Grauskala und 264 verschiedene Farbfelder. Genauer Details werden in [65] gegeben. Die Sollwerte der Farbfelder sind im zugehörigen Referenzfile gespeichert.



(a)

(b)

Abbildung 4.5: Für die Farbkalibrierung werden Targets verwendet, die spezielle Farbflecken enthalten, deren Farbwerte (unter einer standardisierten Beleuchtung) bekannt sind.

(a) "Munsell ColourChecker" (b) "IT-8 Standard"

4.4] Objekte

Bei dieser Arbeit wurde sowohl mit künstlichen Objekten (Farbtargets; mit farbigen Kartonpapier beklebten Objekten) als auch mit mehreren "natürlichen" Objekten gearbeitet (siehe Abbildung 4.6).

Die Einzel-Aufnahmen der in Abbildung 4.6 dargestellten Objekte befinden sich im Anhang (siehe Tabelle A.1 bis A.4). In den Tabellen wurden jedem Objekt ein Name (für die "natürlichen" Objekte war dies der Marken- und Produktname) und eine Nummer zugeordnet. Dadurch konnte später leichter auf die einzelnen Objekte referenziert werden. Die Objekte sind insbesondere für den in Kapitel 6 vorgestellten farbbasierten Objektlokalisationsalgorithmus [19] geeignet.

Jene Objekte, auf deren Farben kalibriert wurde, befinden sich in Tabelle A.1 (“natürliche“ Objekte) und Tabelle A.4 (künstliche Objekte). Ebenfalls als Objekt betrachtet wird menschliche Haut und das Farbtarget.



Abbildung 4.6: Die abgebildeten Objekte wurden für Objektlokalisations- und Farbkonstanz-Versuche in Kapitel 7 verwendet.

5] Farbkalibrierung

Für die Farbkalibrierung einer Kamera werden spezielle Kalibrierungstargets eingesetzt (siehe Abbildung 4.5). Die Targets bestehen aus unterschiedlichen Farbpatches. Die Farbwerte, die die Patches unter einer normierten Beleuchtung aufweisen, sind bekannt. Die Differenzen zu diesen "Sollwerten" (Ground Truth) werden bei der Kalibrierung mittels unterschiedlicher Algorithmen (siehe [51]) minimiert.

Nachfolgend wird der Farbkalibrierungsprozess anhand Abbildung 5.1 unabhängig von den verwendeten Algorithmen vorgestellt.

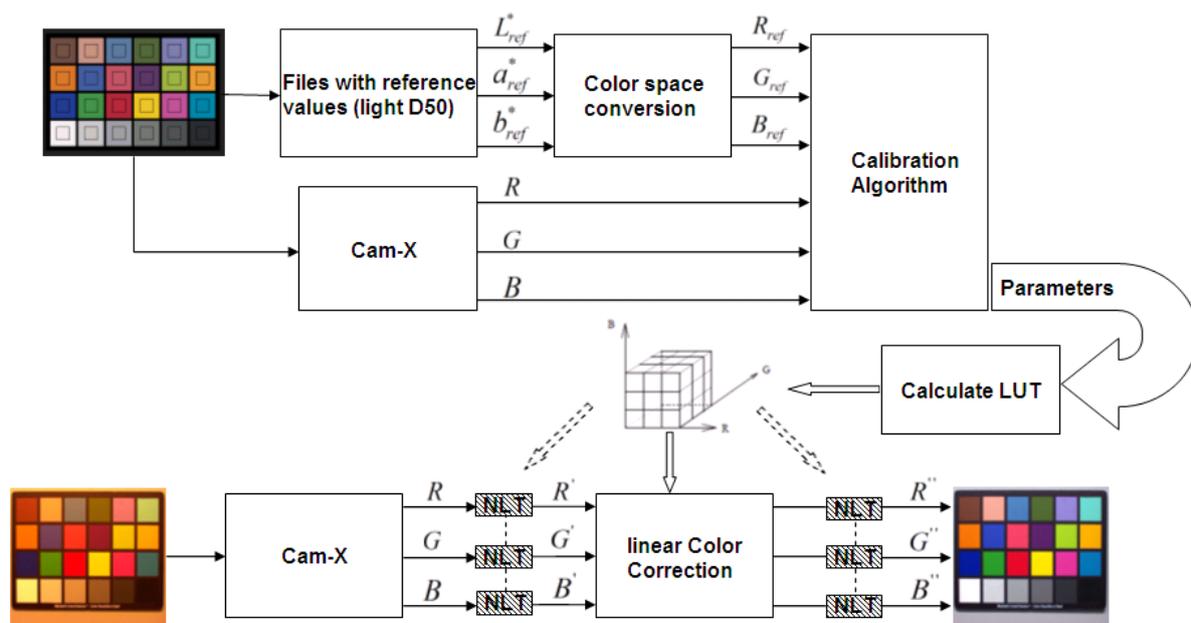


Abbildung 5.1: Von den Farbflecken eines Targets, das von der zu kalibrierenden Kamera aufgenommen wurde, werden die realen Farbwerte und die entsprechenden Sollwerte einem Farbkalibrierungsalgorithmus zugeführt. Mit den ermittelten Parametern kann eine Look-Up-Tabelle berechnet werden, mit der anschließend für andere Motive (bei selben Bedingungen) die Farbkorrektur durchgeführt werden kann.

Im Flussdiagramm befindet sich links oben das Target, das mit der zu kalibrierenden Kamera fotografiert werden muss. In [27, 65] wird speziell auf die korrekte Vorgehensweise bei der Aufnahme des Kalibrierungstargets eingegangen. Das aufgenommene Farbbild enthält zu jedem Farbfleck die zugehörigen RGB-Werte. Wie bereits zuvor erwähnt, gibt es zu jedem Target ein Referenzfile, das die entsprechenden Sollwerte unter einer standardisierten Beleuchtung enthält. Da diese Werte bei Targets nur im CIE-XYZ und CIE-LAB Farbraum vorliegen, müssen sie in die ent-

sprechenden RGB-Werte transformiert werden. Die Transformation ist nicht linear und erfolgt unter der Angabe eines beleuchtungsabhängigen Weißpunktes [70]. Da von den Referenzwerten die Beleuchtung bekannt ist, kann diese Umrechnung ohne Fehler durchgeführt werden.

Die IST- und SOLL-Werte werden schließlich dem Kalibrationsalgorithmus zugeführt. Dieser ermittelt Parameter mit denen das Bild, das unter unbekanntem Bedingungen aufgenommen wurde, in ein Bild mit Referenzbedingungen übergeführt werden kann.

Mit den vom Kalibrierungsalgorithmus erhaltenen Parametern kann eine Look-Up-Tabelle berechnet werden. Je nach Programmierumgebung kann dies die Farbkorrektur der Bilder beschleunigen. Die bei einem der Algorithmen gelieferten Parameter für eine nichtlineare Korrektur (NLT) fließen direkt in die Look-Up-Tabelle ein. Die NLT-Blöcke im Flussdiagramm sollten nur andeuten, dass diese Korrektur vor oder nach der linearen Korrektur durchgeführt werden kann, und dass die Reihenfolge der Korrekturen nicht unabhängig voneinander ist. Die nichtlineare Korrektur erfolgt anhand einer polynomialen Ausgleichskurve.

In Matlab erwies es sich am effizientesten alle Pixel eines Bildes mit nur einer einzigen Matrizenmultiplikation bezüglich der Farbe zu korrigieren (siehe Tabelle 5.1). Der Farbkalibrierungsalgorithmus der dabei eingesetzt wurde, ist jener von S. Wolf (inkl. polynomialer Ausgleichskurve) [69].

Art der Korrektur	Zeit
jedes Pixel einzeln korrigieren	35 s / Bild
alle Pixel auf einmal korrigieren	0.20 s / Bild
alle Pixel auf einmal korrigieren (exkl. polynomialer Ausgleichskurve)	0.11 s / Bild
vollständige LookUpTabelle berechnen	22 min 20 s
jedes Pixel mit LookUpTabelle korrigieren	4.84 s / Bild

Tabelle 5.1: Die angegebenen Zeiten wurden mit einem Intel Celeron 1.6 GHz Rechner und einem 752x564 Pixel großen Bild unter MATLAB R2007b gemessen. Wie man anhand der Werte erkennen kann, konnten mit Matlab die Farben des Bildes ohne LookUpTabelle am schnellsten korrigiert werden.

In [51] wurde anhand von unterschiedlichen Versuchen gezeigt, dass die Farbkalibrierung auf eine bestimmte Beleuchtungsbedingung und Kameraeinstellung optimiert ist. Um auch bei anderen Einstellungen und Beleuchtungen gute Resultate erzielen zu können, müsste der Kalibrierungsablauf für diese Bedingungen wiederholt wer-

den. Für spezielle Anwendungen könnten beispielsweise mehrere verschiedene Look-Up-Tabellen zur Korrektur ermittelt werden.

Da bei der Farbkalibrierung lediglich die Farbabweichungen zwischen verschiedenen Kameras minimiert werden, darf man sich nicht erwarten, dass man aus den Bildern einer billigen Kamera hochqualitative Farbaufnahmen erhält.

5.1] Nichtlineare Optimierung eines Farbkalibrierungsalgorithmus

Hier wurde untersucht, ob jener Farbkalibrierungsalgorithmus [69], der sowohl eine lineare als auch eine nichtlineare Korrektur vollzieht, durch einen numerischen Optimierungsalgorithmus verbessert werden kann.

Ähnlich wie Zhang [73] bei der Schätzung der Homographie (inkl. Linsenverzeichnung) zwischen der Ebene eines Kalibrierungstargets und dessen Bild wurde auch bei der Farbkalibrierung versucht die Euklidische Distanz zwischen den angepassten Werten und den Referenz-Werten durch eine nichtlineare Minimierung (5.1) zu verkleinern.

$$\min \sum_i d(v_i^{ref}, v_i^{est})^2 \quad (5.1)$$

In dem zu untersuchenden Fall entspricht v^{ref} einem Vektor der die Referenz-RGB-Werte eines Farbpatches enthält. v^{est} ist der Vektor mit den angepassten RGB-Werten.

Der Euklidische Abstand zwischen v^{ref} und v^{est} berechnet sich somit folgendermaßen (5.2):

$$d(v^{ref}, v^{est}) = \sqrt{(R^{ref} - R^{est})^2 + (G^{ref} - G^{est})^2 + (B^{ref} - B^{est})^2} \quad (5.2)$$

Zur Lösung des Minimierungsproblems (5.1) werden iterative Techniken verwendet. Hierzu zählen das Gauß-Newton-Verfahren und der Levenberg-Marquardt-Algorithmus. Die Algorithmen benötigen Anfangswerte um die Iteration durchführen zu können.

Für nachfolgende Betrachtungen ist es notwendig, den zu optimierenden Farbkalibrierungsalgorithmus genauer zu beschreiben:

S. Wolf [69] verwendet sowohl ein lineares Bildtransformationsmodell (5.3, 5.4) als auch eine polynomiale Ausgleichskurve 3ten Grades (5.5) für die Farbkalibration.

$$\begin{bmatrix} R_1^{ref} & G_1^{ref} & B_1^{ref} \\ R_2^{ref} & G_2^{ref} & B_2^{ref} \\ \dots & \dots & \dots \\ R_n^{ref} & G_n^{ref} & B_n^{ref} \end{bmatrix} = \begin{bmatrix} 1 & R_1^{ist} & G_1^{ist} & B_1^{ist} \\ 1 & R_2^{ist} & G_2^{ist} & B_2^{ist} \\ \dots & \dots & \dots & \dots \\ 1 & R_n^{ist} & G_n^{ist} & B_n^{ist} \end{bmatrix} \cdot \begin{bmatrix} \alpha_{11} & \alpha_{12} & \alpha_{13} \\ \alpha_{21} & \alpha_{22} & \alpha_{23} \\ \alpha_{31} & \alpha_{32} & \alpha_{33} \\ \alpha_{41} & \alpha_{42} & \alpha_{43} \end{bmatrix} \quad (5.3)$$

$$\text{oder:} \quad b_{n \times 3} = A_{n \times 4} \cdot x_{4 \times 3} \quad (5.4)$$

R_i^{ref} , G_i^{ref} und B_i^{ref} sind die Referenzfarbwerte und R_i^{ist} , G_i^{ist} und B_i^{ist} die realen Farbwerte. n entspricht der Anzahl der Farbpatches, die zur Berechnung der 4x3 Transformationsmatrix $[\alpha_{ij}]$ verwendet werden. Die Spalte mit 1er ermöglicht einen DC-Offset bezüglich der Helligkeit.

Durch Anwendung der Transformationsmatrix wird der Einfluss des Sensorsystems und der Beleuchtung minimiert. Die zur Lösung des Gleichungssystems benötigten realen Werte werden durch die Aufnahme eines Farbtargets (siehe Abbildung 4.5) ermittelt.

Mit dem vorgestellten Transformationsmodell (5.3, 5.4) werden die linearen Abweichungen korrigiert. Da in einem System jedoch auch Nichtlinearitäten (z.B. im CCD-Sensor) auftreten können, versuchte S. Wolf auch diese zu berücksichtigen. Er fand heraus, dass ein Polynom 3ten Grades (5.5) ausreichend viele Freiheitsgrade enthält, um die meist verbreiteten Nichtlinearitäten zu korrigieren.

$$y_i = b_{1j}x_j^3 + b_{2j}x_j^2 + b_{3j}x_j + b_{4j} \quad (5.5)$$

j steht für die drei Kanäle R, G und B. x_j entspricht dem Farbwert vor der Korrektur mit der polynomialen Ausgleichskurve und y_j entspricht dem Farbwert nach der Korrektur. Man erhält 12 weitere Parameter $[b_{ij}]$.

Nachfolgend wird die polynomiale Ausgleichskurve immer nach dem linearen Bildtransformationsmodell (5.3, 5.4) angewendet.

Die RGB-Werte $(R_i^{est1}, G_i^{est1}, B_i^{est1})$ vor der Korrektur mit der polynomialen Ausgleichskurve werden mit den ermittelten Parametern $\alpha_{11}, \alpha_{12}, \alpha_{13}, \dots, \alpha_{43}$ vom Gleichungssystem (5.3, 5.4) berechnet (5.6):

$$\begin{bmatrix} R_1^{est1} & G_1^{est1} & B_1^{est1} \\ R_2^{est1} & G_2^{est1} & B_2^{est1} \\ \dots & \dots & \dots \\ R_n^{est1} & G_n^{est1} & B_n^{est1} \end{bmatrix} = \begin{bmatrix} 1 & R_1^{ist} & G_1^{ist} & B_1^{ist} \\ 1 & R_2^{ist} & G_2^{ist} & B_2^{ist} \\ \dots & \dots & \dots & \dots \\ 1 & R_n^{ist} & G_n^{ist} & B_n^{ist} \end{bmatrix} \cdot \begin{bmatrix} \alpha_{11} & \alpha_{12} & \alpha_{13} \\ \alpha_{21} & \alpha_{22} & \alpha_{23} \\ \alpha_{31} & \alpha_{32} & \alpha_{33} \\ \alpha_{41} & \alpha_{42} & \alpha_{43} \end{bmatrix} \quad (5.6)$$

Werden R_i^{est1}, G_i^{est1} und B_i^{est1} in Gleichung (5.5) eingesetzt so ergeben sich drei weitere lineare Gleichungen (5.7, 5.8 und 5.9):

$$\begin{bmatrix} 1 & R_1^{est1} & R_1^{est1^2} & R_1^{est1^3} \\ 1 & R_2^{est1} & R_2^{est1^2} & R_2^{est1^3} \\ \dots & \dots & \dots & \dots \\ 1 & R_n^{est1} & R_n^{est1^2} & R_n^{est1^3} \end{bmatrix} \cdot \begin{bmatrix} b_{1R} \\ b_{2R} \\ b_{3R} \\ b_{4R} \end{bmatrix} = \begin{bmatrix} R_1^{ref} \\ R_2^{ref} \\ \dots \\ R_n^{ref} \end{bmatrix} \quad (5.7)$$

$$\begin{bmatrix} 1 & G_1^{est1} & G_1^{est1^2} & G_1^{est1^3} \\ 1 & G_2^{est1} & G_2^{est1^2} & G_2^{est1^3} \\ \dots & \dots & \dots & \dots \\ 1 & G_n^{est1} & G_n^{est1^2} & G_n^{est1^3} \end{bmatrix} \cdot \begin{bmatrix} b_{1G} \\ b_{2G} \\ b_{3G} \\ b_{4G} \end{bmatrix} = \begin{bmatrix} G_1^{ref} \\ G_2^{ref} \\ \dots \\ G_n^{ref} \end{bmatrix} \quad (5.8)$$

$$\begin{bmatrix} 1 & B_1^{est1} & B_1^{est1^2} & B_1^{est1^3} \\ 1 & B_2^{est1} & B_2^{est1^2} & B_2^{est1^3} \\ \dots & \dots & \dots & \dots \\ 1 & B_n^{est1} & B_n^{est1^2} & B_n^{est1^3} \end{bmatrix} \cdot \begin{bmatrix} b_{1B} \\ b_{2B} \\ b_{3B} \\ b_{4B} \end{bmatrix} = \begin{bmatrix} B_1^{ref} \\ B_2^{ref} \\ \dots \\ B_n^{ref} \end{bmatrix} \quad (5.9)$$

Durch das Lösen der drei Gleichungssysteme mit den Referenzwerten $(R_i^{ref}, G_i^{ref}, B_i^{ref})$ können die unbekannten Parameter b_{ij} berechnet werden. Mit denen wiederum kann man letztendlich die zuvor ermittelten RGB-Werte $(R_i^{est1}, G_i^{est1}, B_i^{est1})$ mit den polynomialen Ausgleichskurven (5.10, 5.11 und 5.12) nochmals anpassen und erhält als Endresultat R_i^{est2}, G_i^{est2} und B_i^{est2} :

$$\begin{bmatrix} R_1^{est2} \\ R_2^{est2} \\ \dots \\ R_n^{est2} \end{bmatrix} = \begin{bmatrix} 1 & R_1^{est1} & R_1^{est1^2} & R_1^{est1^3} \\ 1 & R_2^{est1} & R_2^{est1^2} & R_2^{est1^3} \\ \dots & \dots & \dots & \dots \\ 1 & R_n^{est1} & R_n^{est1^2} & R_n^{est1^3} \end{bmatrix} \cdot \begin{bmatrix} b_{1R} \\ b_{2R} \\ b_{3R} \\ b_{4R} \end{bmatrix} \quad (5.10)$$

$$\begin{bmatrix} G_1^{est2} \\ G_2^{est2} \\ \dots \\ G_n^{est2} \end{bmatrix} = \begin{bmatrix} 1 & G_1^{est1} & G_1^{est1^2} & G_1^{est1^3} \\ 1 & G_2^{est1} & G_2^{est1^2} & G_2^{est1^3} \\ \dots & \dots & \dots & \dots \\ 1 & G_n^{est1} & G_n^{est1^2} & G_n^{est1^3} \end{bmatrix} \cdot \begin{bmatrix} b_{1G} \\ b_{2G} \\ b_{3G} \\ b_{4G} \end{bmatrix} \quad (5.11)$$

$$\begin{bmatrix} B_1^{est2} \\ B_2^{est2} \\ \dots \\ B_n^{est2} \end{bmatrix} = \begin{bmatrix} 1 & B_1^{est1} & B_1^{est1^2} & B_1^{est1^3} \\ 1 & B_2^{est1} & B_2^{est1^2} & B_2^{est1^3} \\ \dots & \dots & \dots & \dots \\ 1 & B_n^{est1} & B_n^{est1^2} & B_n^{est1^3} \end{bmatrix} \cdot \begin{bmatrix} b_{1B} \\ b_{2B} \\ b_{3B} \\ b_{4B} \end{bmatrix} \quad (5.12)$$

Die zuvor genannten linearen Gleichungssysteme, welche die Form (5.13) aufweisen, liegen bei der Farbkalibrierung üblicherweise überbestimmt vor.

$$A \cdot x = b \quad (5.13)$$

Das bedeutet, dass die Anzahl der linear unabhängigen Gleichungen größer ist als die Anzahl der Unbekannten. Die Lösung kann daher nur angenähert werden. Dies geschieht durch Minimierung des quadratischen Fehlers (5.14).

$$\|Ax - b\|^2 \quad (5.14)$$

Die Lösung des Minimierungsproblems (5.14) kann mit der Methode der kleinsten Quadrate gefunden werden. Damit werden die 24 unbekannt Parameter (α_{ij} und b_{ij}) ermittelt, welche als Startwert für die iterative Optimierung mit Levenberg-Marquardt (oder Gauß-Newton) verwendet werden können.

Da jedoch aufgrund der vorliegenden Struktur der Gleichungssysteme bereits die Euklidische Distanz minimiert wird, kann keine Verbesserung mehr erzielt werden (5.15 bis 5.20):

$$A \cdot x = b \quad (5.15)$$

$$\underbrace{\begin{bmatrix} 1 & R_1^{ist} & G_1^{ist} & B_1^{ist} \\ 1 & R_2^{ist} & G_2^{ist} & B_2^{ist} \\ \dots & \dots & \dots & \dots \\ 1 & R_n^{ist} & G_n^{ist} & B_n^{ist} \end{bmatrix}}_{v_i^{est}} \cdot \begin{bmatrix} \alpha_{11} & \alpha_{12} & \alpha_{13} \\ \alpha_{21} & \alpha_{22} & \alpha_{23} \\ \alpha_{31} & \alpha_{32} & \alpha_{33} \\ \alpha_{41} & \alpha_{42} & \alpha_{43} \end{bmatrix} = \underbrace{\begin{bmatrix} R_1^{ref} & G_1^{ref} & B_1^{ref} \\ R_2^{ref} & G_2^{ref} & B_2^{ref} \\ \dots & \dots & \dots \\ R_n^{ref} & G_n^{ref} & B_n^{ref} \end{bmatrix}}_{v_i^{ref}} \quad (5.16)$$

minimiert wird

$$\|Ax - b\|^2 \quad (5.17)$$

und somit

$$\sum_i \|v_i^{est} - v_i^{ref}\|^2 \quad (5.18)$$

wodurch auch die quadratische Euklidische Distanz minimiert wird

$$\sum_i \left\| \begin{bmatrix} R_i^{est1} - R_i^{ref} \\ G_i^{est1} - G_i^{ref} \\ B_i^{est1} - B_i^{ref} \end{bmatrix} \right\|^2 \quad (5.19)$$

$$\sum_i \left((R_i^{est1} - R_i^{ref})^2 + (G_i^{est1} - G_i^{ref})^2 + (B_i^{est1} - B_i^{ref})^2 \right) \quad (5.20)$$

Ähnlich könnte man auch für die drei polynomialen Ausgleichskurven zeigen, dass ebenfalls bereits durch die Methode der kleinsten Quadrate die Euklidische Distanz minimiert wird.

Bei der Schätzung der Homographie zwischen der Ebene eines Kalibrierungstargets und dessen Bild sind die Punktpaare im Gleichungssystem in inhomogene Koordinaten enthalten (5.21). Dadurch wird bei der Lösung mittels der Methode der kleinsten Quadrate auch nicht die Euklidische Distanz minimiert, wodurch man mit dem Gauß-

Newton-Verfahren oder dem Levenberg-Marquardt-Algorithmus eine Verbesserung bezüglich des euklidischen Abstandes erzielen kann.

$$\begin{pmatrix} x_i^{ref} \\ y_i^{ref} \\ 1 \end{pmatrix} = \begin{pmatrix} \alpha_{11} & \alpha_{12} & \alpha_{13} \\ \alpha_{21} & \alpha_{22} & \alpha_{23} \\ \alpha_{31} & \alpha_{32} & \alpha_{33} \end{pmatrix} \cdot \begin{pmatrix} x_i^{ist} \\ y_i^{ist} \\ 1 \end{pmatrix} \quad (5.21)$$

5.2] Verbesserte Farbkalibrierung durch Iteration

Während untersucht wurde, ob der Farbkalibrierungsalgorithmus von S. Wolf [69] durch eine nichtlineare Optimierung verbessert werden kann (siehe Kapitel 5.1), ist eine andere Verbesserungsidee aufgekommen:

Durch iteratives Korrigieren der Farbwerte mit dem linearen Modell (5.3, 5.4) und den polynomialen Ausgleichskurven (5.5) konnten diesmal die Differenzen zu den Referenzwerten mehr minimiert werden, als ohne der Iteration.

Bei der uEye Kamera vom Typ UI-1220-C konvergierten die Differenzen nach 8 Iterationen (siehe Tabelle 5.2). Bei den beiden Digitalkameras "Canon IXUS 860 IS" und "Olympus E-510" konvergierten die Werte bereits nach 5 Iterationen (siehe Tabelle 5.3 und 5.4). Die dazu notwendigen Farbbildaufnahmen des Munsell-Targets wurden bei indirekter Halogenbeleuchtung (Standscheinwerfer mit einer Halogen Photo Optic Lamp von Osram 1000W) gemacht.

Bei jedem der Farbpatches die zur Kalibrierung verwendet wurden, wurden die Differenzen (|IST-SOLL|) der einzelnen Farbkanäle (RGB) berechnet und anschließend gemittelt (5.22).

$$\frac{|R_i^{ist} - R_i^{ref}| + |G_i^{ist} - G_i^{ref}| + |B_i^{ist} - B_i^{ref}|}{3} \quad (5.22)$$

Für die so erhaltenen Werte wurden für die Patches (Mu13 bis Mu24), welche auch für die Kalibrierung verwendet wurden, folgende statistischen Kennwerte ermittelt:

- Mittelwert
- 1stQ (0,25-Quartile)
- Median (0,5-Quartile)
- 3rdQ (0,75-Quartile)
- Maximalwert

DIFF-RGB (uEye)	ohne Kalib.	1.Iteration	8.Iteration
Mean (Mu13 bis Mu24)	39,58	8,63	4,25
1stQ (Mu13 bis Mu24)	30,12	7,21	1,70
Median (Mu13 bis Mu24)	37,57	7,95	4,29
3rdQ (Mu13 bis Mu24)	52,85	9,35	5,92
Max (Mu13 bis Mu24)	62,00	15,82	8,35

Tabelle 5.2: Iterative Farbkalibrierung mit der uEye Kamera vom Typ UI-1220C

DIFF-RGB (Olympus)	ohne Kalib.	1.Iteration	5.Iteration
Mean (Mu13 bis Mu24)	32,29	5,04	4,93
1stQ (Mu13 bis Mu24)	31,76	3,19	3,12
Median (Mu13 bis Mu24)	32,86	4,18	3,89
3rdQ (Mu13 bis Mu24)	34,07	6,50	6,33
Max (Mu13 bis Mu24)	38,40	12,06	11,80

Tabelle 5.3: Iterative Farbkalibrierung mit der Olympus E-510

DIFF-RGB (Canon)	ohne Kalib.	1.Iteration	5.Iteration
Mean (Mu13 bis Mu24)	10,43	5,88	5,18
1stQ (Mu13 bis Mu24)	6,99	3,66	3,47
Median (Mu13 bis Mu24)	10,11	6,02	4,48
3rdQ (Mu13 bis Mu24)	12,85	7,21	5,55
Max (Mu13 bis Mu24)	21,33	14,74	15,02

Tabelle 5.4: Iterative Farbkalibrierung mit der Canon IXUS 860 IS

5.3] Farbkonstanz durch Farbkalibrierung

Normalerweise wird Farbkalibrierung dazu verwendet, um die Farbdarstellungen einzelner Geräte zu standardisieren. In diesem Kapitel wurde der Frage nachgegangen, wie man durch Farbkalibrierung Farbkonstanz erreichen kann.

Folgende Möglichkeiten bieten sich grundsätzlich an:

- a) Kalibrierung mit einem Farbtarget
- b) Schätzen der Beleuchtung
- c) Kalibrierung auf Objekt X

Da bei der Farbkalibrierung nicht nur der Einfluss des Sensorsystems minimiert wird, sondern auch jener der Beleuchtung, kann damit Farbkonstanz erzielt werden.

5.3.1] Kalibrierung mit einem Farbtarget

Die Kalibrierung von technischen Geräten wird mit Farbtargets durchgeführt. Diesen Targets sind Referenzfarbwerte beigefügt, welche unter einer normierten Beleuchtung spektral vermessen worden sind. Wird Farbkalibrierung zur Farbkonstanz ge-

nutzt, ist es besser, wenn man die Referenzwerte mit jener Kamera neu bestimmt, mit welcher später auch gearbeitet wird. Dadurch muss bei der Kalibrierung nur noch der Einfluss der Beleuchtung korrigiert werden. Im Vergleich zur Kalibrierung mit den standardisierten Referenzwerten, können damit die Abweichungen zu den entsprechenden Sollwerten besser minimiert werden (vgl. Tabelle 5.2 mit Tabelle 5.5 und 5.6). Die Referenzwerte für die Ermittlung der Werte in den Tabellen 5.5 und 5.6 wurden bei Leuchtstoffröhrenlicht (Philips Master TL5 HO 49W/840) mit einer uEye Kamera vom Typ UI-1220C ermittelt (siehe Tabelle A.7 im Anhang). Der Algorithmus der verwendet wurde, ist derselbe wie zuvor in Kapitel 5.2 (inkl. Iteration).

DIFF-RGB (uEye)	ohne Kalib.	mit Kalib.
Mean (Mu13 bis Mu24)	11,25	1,74
1stQ (Mu13 bis Mu24)	6,17	0,58
Median (Mu13 bis Mu24)	11,00	1,43
3rdQ (Mu13 bis Mu24)	14,83	2,57
Max (Mu13 bis Mu24)	26,00	4,79

Tabelle 5.5: Kalibrierung mit den Referenzwerten, welche bei Leuchtstoffröhrenlicht ermittelt wurden, bei Tageslicht (wolkenlos/Mittagszeit).

DIFF-RGB (uEye)	ohne Kalib.	mit Kalib.
Mean (Mu13 bis Mu24)	8,06	1,15
1stQ (Mu13 bis Mu24)	2,33	0,50
Median (Mu13 bis Mu24)	5,00	1,01
3rdQ (Mu13 bis Mu24)	15,00	1,74
Max (Mu13 bis Mu24)	22,00	2,69

Tabelle 5.6: Kalibrierung mit den Referenzwerten, welche bei Leuchtstoffröhrenlicht ermittelt wurden, bei indirekter Halogenbeleuchtung (Standscheinwerfer mit einer Halogen Photo Optic Lamp von Osram 1000W).

Diese Art Farbkonstanz zu erreichen wird in Kapitel 7 ausgewählten Farbkonstanzalgorithmen gegenübergestellt. Die besten Ergebnisse werden dabei bei der Kalibrierung auf die Farben eines Targets erwartet. Bei den Farbkonstanzalgorithmen wird der Einfluss der Beleuchtung nämlich aus weniger zuverlässigen Informationen abgeleitet.

Die vorgestellte Methode erfordert, dass sich ein Target in der Szene, von der eine Aufnahme gemacht wird, befindet. Eine mögliche Anwendung im Bereich der Computer Vision wäre ein Roboter, der sich in Umgebungen unterschiedlicher Beleuchtung aufhält. Würden sich seine Algorithmen durch Farbkonstanz verbessern, könnte er dazu ein Farbtargt bei sich tragen.

5.3.2] Schätzen der Beleuchtung

Um von einem Target in der Szene unabhängig zu sein, könnte man ein Set von Beleuchtungsarten vordefinieren. In der Anwendung müsste man dann jene Beleuchtung ermitteln, welche der derzeitigen Beleuchtung am ähnlichsten ist (siehe Abbildung 5.2).

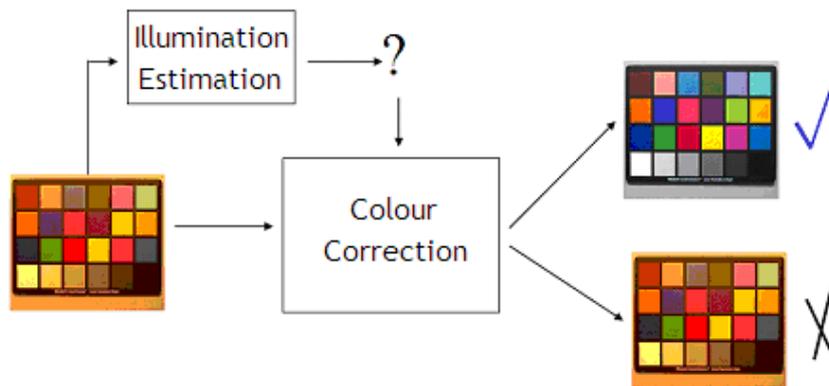


Abbildung 5.2: Um die Farben, welche durch die Beleuchtung beeinflusst werden, korrigieren zu können, wird die derzeitige Beleuchtung aus einem vordefinierten Set von Beleuchtungen geschätzt. Mittels Kalibrierung auf die Farben eines Targets, können zuvor jene Parameter ermittelt werden, mit denen die Testbilder zwischen den Beleuchtungsarten transformiert werden können. (angepasst von [58])

Die Parameter, welche für eine Farbkorrektur notwendig sind, können zuvor für die unterschiedlichen Beleuchtungen ermittelt werden. Dies kann wiederum mit einem Farbtarget gemacht werden.

Diese Methode ist vergleichbar mit dem Auswählen von vordefinierten Farbtemperaturen, was bei vielen Kameras möglich ist. Die unterschiedlichen Farbtemperaturen sind dort in der Regel durch Symbole gekennzeichnet (z.B. Sonne für Tageslicht). Durch die Auswahl der passenden Farbtemperatur kann ein Weißabgleich durchgeführt werden.

Eine Möglichkeit die Beleuchtung automatisiert zu schätzen, wäre mittels Receptive Field Cooccurrence Histograms [19]. Dabei könnte man die Histogramme von bekannten Objekten in der Szene mit jenen vergleichen, die die Objekte unter den vordefinierten Beleuchtungen haben. Die Ähnlichkeit zweier Histogramme kann mit Histogrammschnitt (6.5) berechnet werden.

5.3.3] Kalibrierung auf Objekt X

Bei der letzten Möglichkeit werden die Farben von bekannten Objekten in einer Szene verwendet. Anstatt auf die Farben eines Targets, wird nun auf die der Objekte kalibriert. Für die Korrektur mit einem Target, eignen sich die Grundfarben (Blau, Grün, Rot, Gelb, Magenta und Cyan) in Kombination mit einer 6 stufigen Grauskala am besten [51]. Da die Objekte, mit denen nun die Kalibrierung durchgeführt wird, in der Regel weniger geeignete und vor allem andere Farben enthalten, muss mit schlechteren Ergebnissen gerechnet werden.

Je nachdem mit wie vielen Farben von einem Objekt die Kalibrierung durchgeführt wird, können unterschiedliche Methoden verwendet werden.

Der Farbkalibrierungsalgorithmus von S. Wolf [69] benötigt mindestens 4 unterschiedliche Farben, um die unbekannt Parameter bestimmen zu können. So viele geeignete Farben sind allerdings auf einen Objekt selten enthalten. Bei den meisten Objekten eignen sich drei oder weniger Farben, auf die kalibriert werden kann.

Der Algorithmus von E. Roullot [52] erfordert zur Bestimmung der Parameter, die für die Farbkorrektur benötigt werden, mindestens drei unterschiedliche Farben. (Anm.: Das lineare Modell, das dabei verwendet wird, kann mit den polynomialen Ausgleichskurven von S. Wolf [69] kombiniert werden.)

Werden nur eine oder zwei Farben von einem Objekt verwendet, so kann die Korrektur der Farbwerte mit einem 3x3 Diagonalmodell durchgeführt werden.

Bei den Objekten werden größere homogen farbige Flächen vorausgesetzt, auf die kalibriert werden kann. Jene Objekte, auf deren Farben bei dieser Arbeit kalibriert wurde, befinden sich im Anhang in den Tabellen A.1 und A.4. Auf wie viele, und auf welche Farben der jeweiligen Objekte kalibriert wurde, wird bei den entsprechenden Versuchen in Kapitel 7 noch erwähnt.

5.4] Farbkalibrierung bei ungleichförmiger Beleuchtung

Wie bei den meisten Farbkonstanzalgorithmen [17] (z.B. White Patch Retinex, Gray World Assumption, Gamut-constraint Methods, Color in Perspective, Color Cluster Rotation, Color Constancy Using a Dichromatic Reflection Model, Comprehensive

Color Normalization,...), wird auch bei den in diesem Kapitel vorgestellten Möglichkeiten eine gleichförmige Beleuchtung angenommen.

Bei ungleichförmiger Beleuchtung kann es vermehrt passieren, dass durch die Farbkorrektur einzelne Farbwerte außerhalb ihres Wertebereiches kommen (siehe Abbildung 5.3). In diesem Fall spricht man von Clipping.



Abbildung 5.3: Die dargestellten Bilder zeigen eine Szene, die bei ungleichförmiger Beleuchtung fotografiert wurde. Das unbearbeitete Originalbild, welches mit einer Canon IXUS 860 IS aufgenommen wurde, befindet sich links. Rechts sieht man wie das Bild der Szene aussieht, wenn man auf die Farben des Targets kalibriert. Speziell an der Kontur der Türe, welche sich im Hintergrund befindet, kann man erkennen, dass einzelne Farbwerte in die Sättigung geraten sind.

Durch die Berechnung der normalisierten RGB-Werte (5.23, 5.24, 5.25) kann die Intensitätsinformation der Beleuchtung aus dem Bild entfernt werden.

$$r_{norm} = \frac{R}{R + G + B} \quad (5.23)$$

$$g_{norm} = \frac{G}{R + G + B} \quad (5.24)$$

$$b_{norm} = \frac{B}{R + G + B} \quad (5.25)$$

Da die Summe der drei normalisierten RGB-Werte 1 ergibt (5.26), kann eine der drei Komponenten aus den anderen beiden berechnet werden (5.27).

$$r_{norm} + g_{norm} + b_{norm} = 1 \quad (5.26)$$

$$b_{norm} = 1 - r_{norm} - g_{norm} \quad (5.27)$$

In Abbildung 5.4 sind die normalisierten Farben grafisch dargestellt:

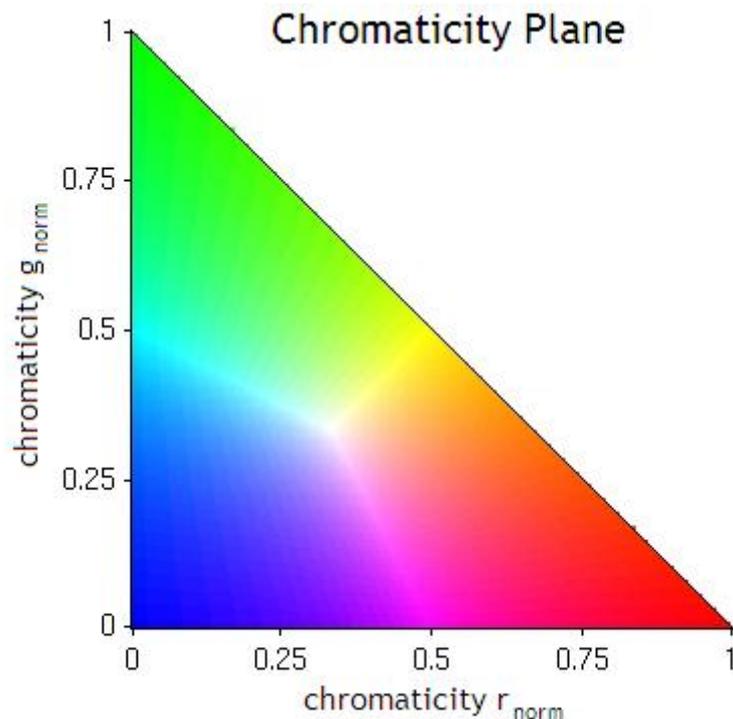


Abbildung 5.4: Um von der Beleuchtungsintensität unabhängig zu sein, können die normalisierten RGB-Werte berechnet werden. Diese enthalten für unterschiedliche Intensitäten denselben Farbwert. (angepasst von [58])

Damit auch bei einer ungleichförmigen Beleuchtung eine Farbkalibrierung durchgeführt werden kann, wurde der Farbkalibrierungsprozess angepasst (siehe Abbildung 5.5). Anstatt den RGB-Werten wurden diesmal die normalisierten Werte den Algorithmen zugeführt. Dies erforderte, dass auch die Referenzwerte normalisiert werden. Wegen (5.27) ergeben sich bei den Farbkalibrierungsalgorithmen pro Farbpatch nur noch zwei linear unabhängige Gleichungen (bisher waren es drei). Dadurch sind nun beim Algorithmus von E. Roullot [52] anstatt bisher 3 mindestens 5 Farbpatches notwendig, mit denen kalibriert wird. Da der Algorithmus von S. Wolf [69] in seinem Modell einen DC-Offset bezüglich der Helligkeit vollzieht, kann dort auch nicht mit den normalisierten Werten kalibriert werden.

Normalerweise wurde immer zusätzlich zu den Grundfarben (Blau, Grün, Rot, Gelb, Magenta und Cyan) mit der kompletten 6-stufigen Grauskala vom Munsell Target kalibriert. Da diese Grauwerte normalisiert im Idealfall denselben Wert haben, wurde diesmal nur einer dieser Farbpatches für die Kalibrierung verwendet.

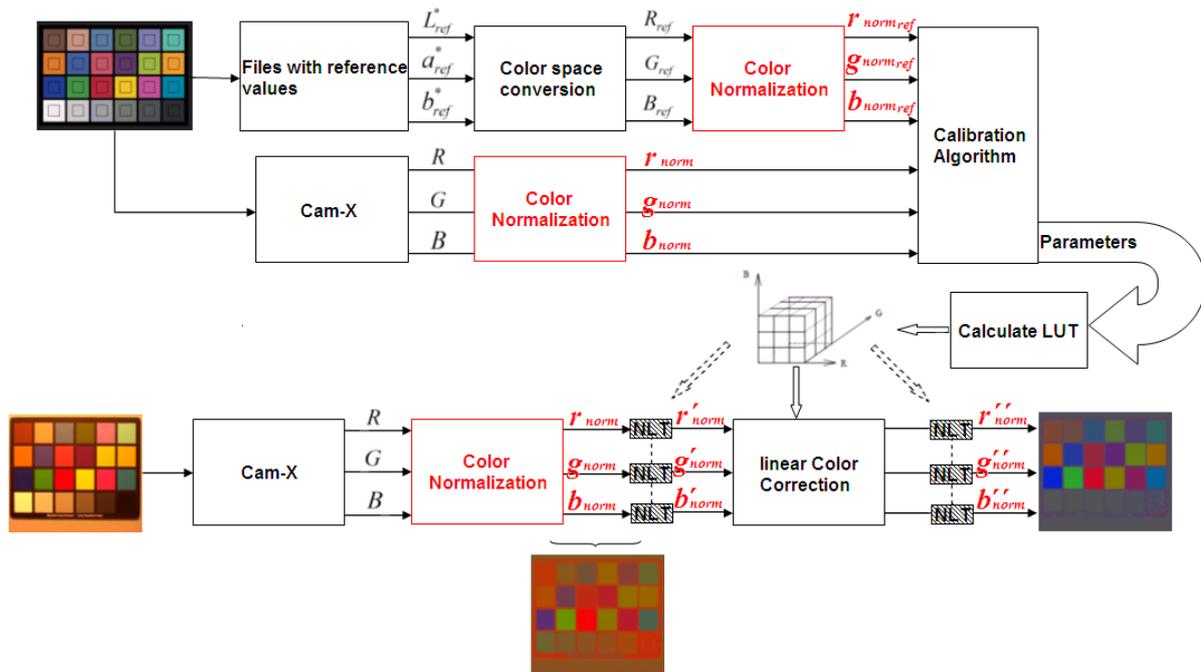


Abbildung 5.5: Der am Beginn von Kapitel 5 vorgestellte Farbkalibrierungsprozess (siehe Abbildung 5.1) wurde so angepasst, dass auch bei ungleichförmiger Beleuchtung für spezielle Anwendungen eine Farbkalibrierung durchgeführt werden kann. Dabei wurden die RGB-Werte vor der Farbkalibrierung normalisiert, wodurch die Intensitätsinformation aus den Farbwerten entfernt wurde. Angepasst werden diesmal die normalisierten RGB-Werte. Falls benötigt, könnte man die unveränderte Intensitätsinformation nach der Kalibrierung wieder dem Ergebnisbild hinzufügen, was in Abbildung 5.6 und 5.7 gemacht wurde.

Nachdem die Chromatizitätswerte durch die Farbkalibrierung korrigiert wurden, kann man die Intensitätsinformation wieder dem Bild hinzufügen. Im Vergleich zur ursprünglichen Methode kommt es diesmal zu keinem Clipping (vgl. Abbildung 5.3 mit 5.6).

Im Bereich der Fotografie würde es durchaus Sinn machen, wenn man bei der Minimierung der Abweichungen die Nebenbedingung fordert, dass die Differenz zum weißen Farbpatch null sein sollte. Hier gab es diese Bedingung nicht, da für Computer Vision Anwendungen alle Farben als gleichwertig angenommen wurden.

Diese Art der Kalibrierung kann bei ungleichförmiger Beleuchtung für den im nächsten Kapitel vorgestellten Objektlokalisationsalgorithmus [19], welcher auf normalisierten RGB-Werten basiert, nützlich sein.



Abbildung 5.6: Wie zuvor (siehe Abbildung 5.3) wurde auch hier auf die Farben des Targets bei ungleichförmiger Beleuchtung kalibriert. Diesmal wurde die Farbkalibrierung jedoch mit den normalisierten RGB-Werten durchgeführt, wodurch Clippingeffekte verhindert werden konnten (vgl. die Kontur der Türe im Hintergrund mit jener in Abbildung 5.3). Der leichte Blaustich der im rechten Bild erkennbar ist, erklärt sich dadurch, dass bei der Kalibrierung die Abweichungen zu allen sieben Patches (Blau, Grün, Rot, Gelb, Magenta, Cyan, Weiß) gleichermaßen minimiert wurden. Wenn man fordert, dass die Differenz zum weißen Patch null ist, und zu den anderen Patches so klein wie möglich, ist das Bild nach der Kalibrierung visuell gesehen "schöner" (siehe Abbildung 5.7).

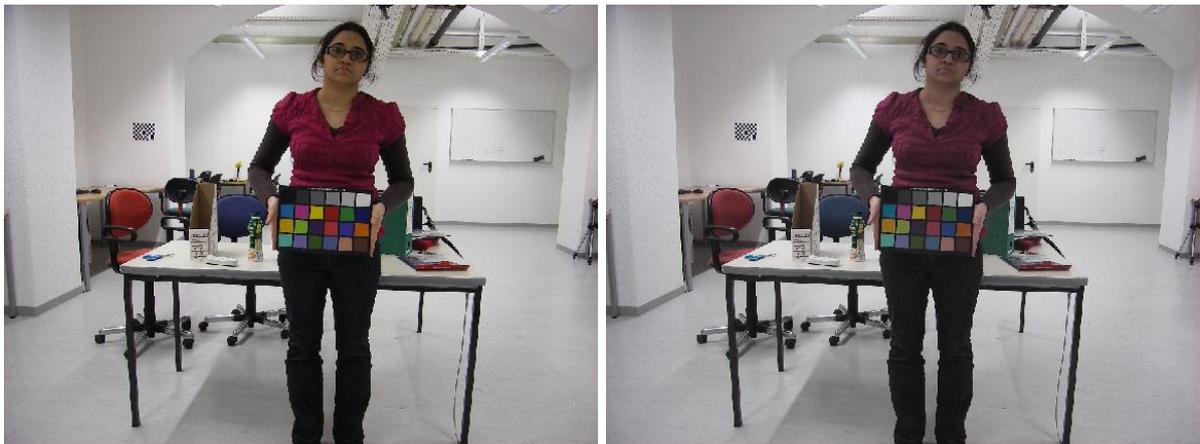


Abbildung 5.7: Hier wurde wieder auf die Farben des Targets bei ungleichförmiger Beleuchtung kalibriert (mit den normalisierten RGB-Werten). Im Gegensatz zu Abbildung 5.6 wurde diesmal gefordert, dass die Differenz zum weißen Patch null sein sollte, und zu den anderen Patches so klein wie möglich.

6] Ausgewählte farbbasierte Algorithmen

In diesem Kapitel wird ein farbbasierter Algorithmus vorgestellt, dessen Abhängigkeit von der Beleuchtung genauer untersucht wird. Einzelne Experimente in Kapitel 7 wurden mit diesem Algorithmus durchgeführt. Weiters wird auf das Thema Hautdetektion eingegangen, wobei hier ebenfalls der Einfluss der Beleuchtung untersucht wird.

6.1] Objektlokalisierung mit Receptive Field Cooccurrence Histograms [19]

Einer der farbbasierten Algorithmen der in dieser Arbeit für Farbkonstanzversuche herangezogen wurde, ist jener der auf Receptive Field Cooccurrence Histograms (RFCHs) basiert [19]. Mit diesem Algorithmus ist es möglich selbst unter schwierigen Bedingungen (komplexer Hintergrund, Verdeckung, verändernde Lichtverhältnisse) die Lage von Objekten in einem Bild festzustellen (siehe Abbildung 6.1).



Abbildung 6.1: Anhand drei ausgewählter Szenen [von 19] (linke Spalte) sieht man in der rechten Spalte typische Ergebnisse des RFCH-Algorithmus. Gesucht wurde der blau/gelbe LKW. Die Resultate in der rechten Spalte wurden mit der für diese Arbeit implementierten Version erzielt.

Bei diesem Algorithmus wird jedes Pixel im Bild durch eine Kombination seiner Farbe und der Antwort auf verschiedene Filter repräsentiert. Die Histogramme werden aus Paaren dieser Deskriptoren gebildet, wobei die Anzahl der Paare bezüglich ihrer relativen Distanz beschränkt werden kann (siehe Abbildung 6.2).

Die Distanz zwischen zwei Paaren wurde im RFCH nicht gespeichert. Schwarze Pixel (Grauwert 0) werden im Histogramm nicht berücksichtigt.

Ein RFCH gibt Auskunft darüber, wie oft Paare von bestimmten Filterantworten und Farben nahe einander in einem Bild vorkommen. Das Histogramm enthält somit auch geometrische Informationen, wodurch sich die Objekterkennung vereinfacht.

Als Deskriptoren wurden die normalisierten Farbintensitäten (6.1, 6.2), die Gradient Amplitude (6.3) und die Laplace-Antwort (6.4) verwendet. Diese Deskriptoren sind invariant gegenüber Rotation und Translation. Die Gradient Amplitude und die Laplace-Antwort wurden von den normalisierten Farbintensitäten (r_{norm} und g_{norm}) berechnet, welche zuvor noch mit einem Gauß-Kernel (mit $\sigma = 2$) geglättet wurden. (L_r und L_g stehen für die geglätteten normalisierten Farbintensitäten. Die Bezeichnung L_{rg} wurde verwendet, damit nicht dieselbe Formel für die beiden Farbintensitäten zweimal angeführt werden muss.)

$$r_{norm} = \frac{R}{R+G+B} \quad \text{und} \quad g_{norm} = \frac{G}{R+G+B} \quad (6.1, 6.2)$$

$$|\nabla L_{rg}| = |\text{grad } L_{rg}(x, y)| = \sqrt{\left(\frac{\partial L_{rg}}{\partial x}\right)^2 + \left(\frac{\partial L_{rg}}{\partial y}\right)^2} \quad (6.3)$$

$$\nabla^2 L_{rg} = \nabla^2 L_{rg}(x, y) = \frac{\partial^2 L_{rg}}{\partial x^2} + \frac{\partial^2 L_{rg}}{\partial y^2} \quad (6.4)$$

Damit die Histogramme dichter besetzt sind und damit die meisten Histogrammeinträge einen hohen Wert aufweisen, wurde mittels k-means Clustering [39] eine Dimensionsverminderung durchgeführt. Jedes Pixel, welches durch Farbwert und bestimmte Filterantworten repräsentiert wird, wurde dabei einem von 80 Clusterzentren zugewiesen.

Die Dimension des Merkmalraumes in dem gerechnet wird, hängt von der Anzahl der verwendeten Deskriptoren ab, und beträgt in dem für die Versuche umgesetzten Fall

6 (drei Deskriptoren für je zwei Farben). Zur Distanzmessung wurde beim Clustering die Euklidische Distanz verwendet. Dadurch hat jedes Cluster die Form einer Kugel. Die Clusterzentren wurden zufällig initialisiert, wobei ein Cluster ohne Mitglieder neu initialisiert wurde. Für die Neuinitialisierung wurde die Position jenes Clustermitgliedes genommen, welches die höchste Euklidische Distanz zu seinem zugehörigen Clusterzentrum hatte. Nach ein paar Iterationen konnte so sichergestellt werden, dass die Clusterzentren gut im Deskriptorraum verteilt sind, und dass jedes Cluster zumindest ein Mitglied besitzt.

Damit keiner der Deskriptoren beim Clustering bevorzugt wird, wurden diese zuvor alle auf das Intervall $[0,255]$ skaliert.

Für N Cluster ergeben sich $N_{bins} = \frac{N \cdot (N+1)}{2}$ mögliche einzigartige nichtgeordnete Paare.

Jedes Objekt wird durch seine Clusterzentren, die Skalierungsfaktoren der Deskriptoren und durch das RFCH repräsentiert.

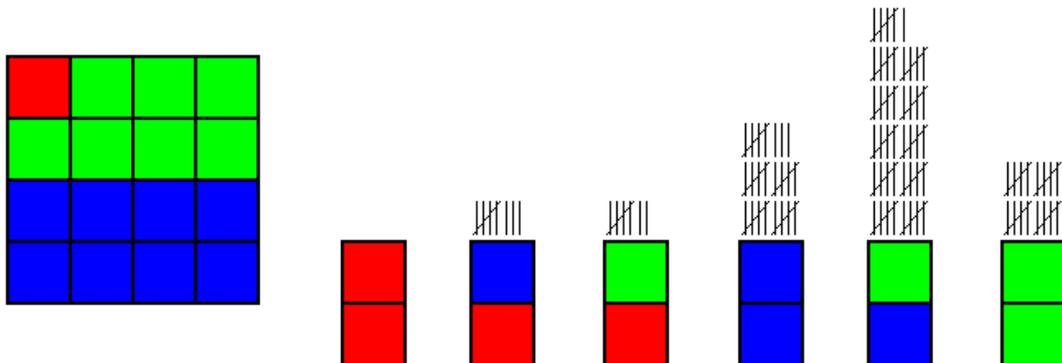


Abbildung 6.2: Das linke Quadrat entspricht einem 4x4 Pixel großen Bildausschnitt. Jedes Pixel ist Mitglied von genau einem Cluster. Im abgebildeten Beispiel wurden drei unterschiedliche Cluster verwendet, wobei die Zugehörigkeit zu diesen durch die Farben rot, grün und blau gekennzeichnet wurde. Auf der rechten Seite sieht man das zum Bildausschnitt dazugehörige Cooccurrence Histogramm. In diesem Beispiel wurden jene Pixel-Paare berücksichtigt, welche maximal 4 Pixel in X- und Y-Richtung voneinander entfernt sind. (Bei der für die Versuche implementierten Version werden jene Pixel-Paare berücksichtigt, welche maximal 10 Pixel in X- und Y-Richtung voneinander entfernt sind.)

Wird nach einem Objekt in einer Szene gesucht, so wird das Bild zuvor mit dessen Clusterzentren quantifiziert. Jene Pixel deren kürzeste Distanz zu einem der Clusterzentren größer ist als $\alpha \cdot d_{avg}$, werden als Hintergrund klassifiziert (siehe Abbildung 6.3 rechts oben) und beim Histogramm nicht berücksichtigt. d_{avg} entspricht dabei der

durchschnittlichen Entfernung der Trainingspixel zum jeweiligen Cluster. α ist ein freier Parameter für den der im Paper [19] empfohlene Wert 1.5 verwendet wurde. Die Ähnlichkeit zwischen zwei RFCH wird durch einen Histogrammschnitt (6.5) berechnet:

$$\mu(h_1, h_2) = \sum_{n=1}^{N_{bins}} \min(h_1[n], h_2[n]) \quad (6.5)$$

Vor dem Vergleich werden die Histogramme noch mit der jeweiligen Gesamtanzahl an Pixelpaaren normalisiert.

Bei der Objektlokalisierung wird das Bild mit einem Suchfenster abgescannt. Nachfolgende Suchfenster überlappen sich dabei zu 50%. Die Histogramme der einzelnen Bildausschnitte werden jeweils mit jenem vom Training verglichen. Nach dem Suchvorgang gibt eine Vote-Matrix (siehe Abbildung 6.3 links unten) eine Hypothese über die Lage des gesuchten Objektes.

Nicht jeder Objekterkennungsalgorithmus ist für diese Art der Suche geeignet.

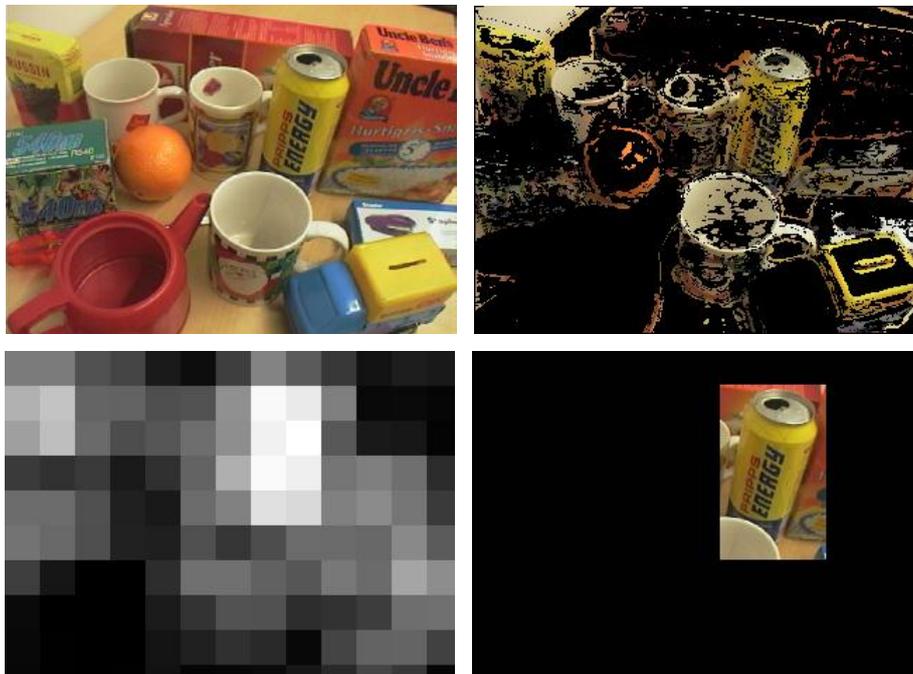


Abbildung 6.3: In der oben abgebildeten Szene [von 19] wurde nach der gelben Energydose gesucht, welche auch erfolgreich gefunden werden konnte. Rechts oben sieht man jenes Teilbild, bei dem alle Pixel die zu weit von ihrem nächsten Cluster entfernt lagen, als Hintergrund (Grauwert 0) markiert wurden. Links unten ist die für dieses Beispiel dazugehörige Vote-Matrix abgebildet. Helle Flächen geben eine hohe Wahrscheinlichkeit an, dass sich an dieser Stelle das gesuchte Objekt befindet. Die zwei Zwischenergebnisse (rechts oben und links unten) sowie das Resultatbild (rechts unten) wurden wiederum mit der für diese Arbeit implementierten Version erzielt.

6.1.1] Einfluss der Beleuchtung auf den RFCH-Algorithmus

Da für die Deskriptoren des Algorithmus die normalisierten Farbintensitäten verwendet werden, ist man gegenüber unterschiedlicher Lichtintensitäten unabhängig. Gegenüber sich ändernden Farbtemperaturen ist man allerdings noch immer anfällig. Eine weitere Invarianz gegenüber der Beleuchtung wird durch das Clustering erzielt.

In der Arbeit von S. Ekvall und D. Kragic [19] wurde bereits der Einfluss der Beleuchtung auf den RFCH-Algorithmus getestet. Dabei wurde die Detektionsrate für verschiedene Kombinationen von Deskriptoren bei zwei unterschiedlichen Beleuchtungen ermittelt (siehe Tabelle 6.1). Eine der beiden Beleuchtungen war dieselbe wie beim Training.

Lighting Condition:	Same	Changed
Descriptor Combination:		
2D: Color histogram	71,5	38,0
2D: $[r_{norm}, g_{norm}]$ (CCH)	77,5	38,0
4D: $[r_{norm}, g_{norm}, \nabla^2 L_{rg}, \sigma=2]$	88,5	61,5
5D: $[\nabla L , \sigma=1,2,4, \nabla L_{rg} , \sigma=2]$	57	51
5D: $[\nabla^2 L, \sigma=1,2,4, \nabla^2 L_{rg}, \sigma=2]$	77,5	62,0
6D: $[r_{norm}, g_{norm}, \nabla L_{rg} , \nabla^2 L_{rg}, \sigma=2]$	95,0	80,0
10D: $[r_{norm}, g_{norm}, \nabla L_{rg} , \nabla^2 L_{rg}, \sigma=2, 4]$	93,5	86,0

Tabelle 6.1: Detektionsrate für unterschiedliche Deskriptorkombinationen bei selber Beleuchtung wie beim Training und bei geänderter Beleuchtung. (angepasst von [19])

In der Tabelle 6.1 sind verschiedene Deskriptorkombinationen enthalten. Jene Kombination, bei der die Detektionsrate bei Trainingsbeleuchtung am höchsten war (95%), wurde auch bei dieser Arbeit gewählt. Die 10D-Kombination ist zwar bei Trainingsbeleuchtung etwas schlechter, jedoch ist man bei geänderter Beleuchtung besser. Diese Kombination erfordert allerdings 130 (statt 80) Clusterzentren beim k-means Clustering. Da alle Pixel beim Clustering berücksichtigt werden, war die Rechenzeit in Matlab dadurch noch höher als sie schon bei der 6D-Kombination war. Weiters werden in Kapitel 7 verschiedene Farbkonstanzmethoden anhand des

RFCH-Algorithmus evaluiert. Damit die Ergebnisse nicht all zu sehr von den ausgewählten Objekten und Beleuchtungen abhängen, wurde die 10D-Kombination nicht gewählt, da sie von der Beleuchtung zu wenig beeinflusst wird.

Lediglich bei der ersten Kombination von Tabelle 6.1 handelt es sich um ein normales Farbhistogramm. Für alle anderen Kombinationen wurden so genannte "cooccurrence histogram" bzw. "receptive field cooccurrence histogram" verwendet.

Die ersten beiden Kombinationen enthalten nur reine Farbdeskriptoren. Anhand der Detektionsrate kann man erkennen, dass diese besonders anfällig auf sich verändernde Beleuchtungsverhältnisse sind. Trotz der Tatsache, dass die Farben der Deskriptoren normalisiert wurden, verschlechterte sich das Ergebnis doch deutlich. Durch die Kombination mit anderen Deskriptoren lässt sich dieser Einfluss reduzieren, wodurch auch bei Beleuchtungsänderungen akzeptable Ergebnisse erzielt werden können.

Durch einen Farbkonstanzalgorithmus als Vorbereitungsschritt kann man sich den Resultaten bei Trainingsbeleuchtung annähern. Zwingend notwendig ist Farbkonstanz allerdings für diesen Algorithmus nicht.

6.2] Hautdetektion

Es wird nun eine kurze Einführung über "Hautdetektion im Computer Vision Bereich" gegeben. Anschließend wird der Einfluss der Beleuchtung auf die Detektionsergebnisse diskutiert. In Kapitel 7.5 wird untersucht, ob man durch Hautdetektion Farbkonstanz erzielen kann.

Unter Hautdetektion versteht man das Auffinden von Pixeln in einem Bild (oder einem Video) welche der menschlichen Hautfarbe entsprechen.

In den meisten Arbeiten wurde versucht, Haut anhand ihrer Farbe automatisiert zu erkennen. Sehr wenige Ansätze berücksichtigen auch Texturinformation (z.B. [46]).

Die Hautfarbe von verschiedenen Menschen ist generell unterschiedlich. Zusammengesetzt wird sie aus den Komponenten Blut (rot) und Melanin (braun, gelb) [28]. Je nach Hautfarbe variieren die Anteile dieser Zusammensetzung. Die menschliche Hautfarbe besitzt einen beschränkten Farbtonbereich und ist nicht sehr gesättigt [24].

Da Gesichter und Hände typischerweise unbekleidet sind, stellt Hautfarbe ein sehr leistungsfähiges Merkmal für diverse Applikationen dar. Angewendet werden kann Hautdetektion für:

- Personenerkennung/-tracking
- Gesichtserkennung/-tracking
- Handerkennung/-tracking
- Gestenerkennung
- Internet-Filter für Nacktbilder
- Information über Aktivitäten (z.B. Aufheben eines Gegenstands)
- Telekonferenz
- ...

Aufgrund der starken farblichen Variation ist der Hautfarbenbereich zu umfangreich um als eigenständiges Merkmal herangezogen werden zu können. Hautdetektion kann jedoch den Suchraum für weitere oft komplexere Algorithmen sehr einschränken, wodurch sich deren Berechnungszeit deutlich verkürzen lässt. Auch die Anzahl der Fehlentscheidungen kann damit vermindert werden. Weiters kann Hautdetektion als Realitätsüberprüfung dienen.

Experimente zeigten, dass die menschliche Haut eine charakteristische Farbe besitzt, welche der Mensch relativ einfach erkennen kann [49]. Trotz der Vielfalt unterschiedlicher Hautfarben gibt es große farbliche Ähnlichkeiten. Zahlreiche Studien zeigten, dass der Hauptunterschied im Wesentlichen auf unterschiedliche Intensität zurückzuführen ist [35, 72]. Der Farbwert selbst hingegen ändert sich für verschiedene Menschen relativ wenig. Vor allem in jenen Farbräumen, die die Helligkeitsinformation von der Farbinformation trennen, stellt Hautfarbe bei unterschiedlichen Beleuchtungsbedingungen einen schmalen gebündelten Bereich dar (siehe Abbildung 6.4). Für die Farbwerte verschiedener ethnischer Gruppen wurde dies für den HS-Farbraum in [48] begründet.

Zahlreiche Farbräume (RGB, normalisierter RGB, HSV, YCbCr, YUV, CIE Lab, CIE Luv, CIE XYZ, ...) wurden in der Literatur über Skindetektion erprobt [7, 9, 11, 12, 24, 44, 53, 56, 66, 71]. Favorisiert werden jene Farbräume, die die Farbintensität von den Farbinformationen komplett trennen. Wie bereits erwähnt, ergeben sich nämlich

in diesen Farbräumen für verschiedene Hautfarben schmale gebündelte Bereiche. Weiters ist man gegenüber Beleuchtungsänderungen robuster. Welcher der vielen unterschiedlichen Farbräume nun der geeignetste ist, lässt sich durch die Literaturrecherche nicht eindeutig sagen. Die Ergebnisse hängen auch von der Methode ab, mit der die Pixel klassifiziert werden.

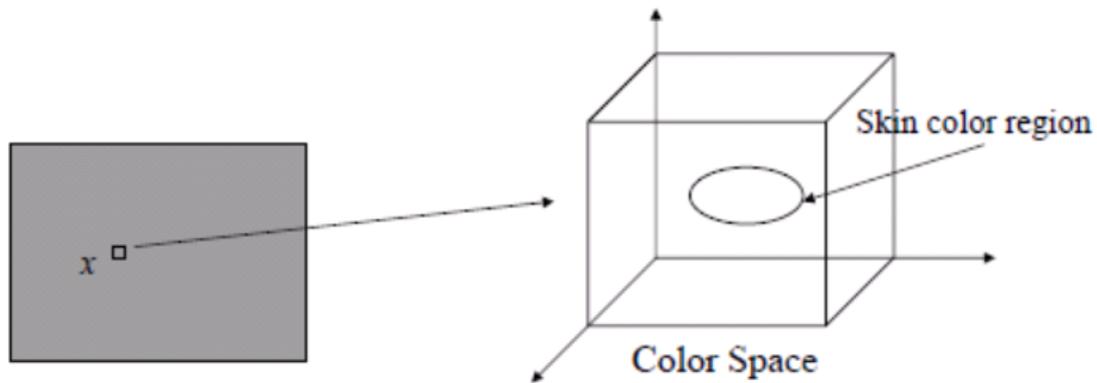


Abbildung 6.4: Hautfarbe stellt einen sehr kleinen gebündelten Bereich in vielen Farbräumen dar. (aus [20])

Bei der Hauterkennung werden also die Pixelwerte meist in einen bestimmten Farbraum transformiert, bevor sie klassifiziert werden. Viele Methoden benutzen Farbhistogramme zur Segmentation [7, 14, 32, 60]. Andere wiederum verwenden vordefinierte Schranken im jeweiligen Farbraum um die Pixel klassifizieren zu können [24, 43, 57]. Ein guter Überblick über gängige Modellierungsmethoden wird in [47, 63] gegeben.

Der Hautfarbenbereich wird meist mit Hilfe von größeren Bilddatenbanken ermittelt, bei denen die Hautpixel zuvor markiert wurden. Die Datenbanken enthalten Bilder von verschiedenen Menschen bei unterschiedlichen Beleuchtungsverhältnissen und Umgebungen. Die Datenbank von Giovanni Gomez Estrada [21] beispielsweise enthält über 2000 Personen unterschiedlicher Hauttypen. Die Bilder wurden bei verschiedenen Beleuchtungsbedingungen aufgenommen. Über 32 Millionen Hautpixel wurden sorgfältig markiert. Die Datenbank ist groß genug, um sowohl zum Trainieren als auch zum Testen verwendet werden zu können.

Um die Qualität eines Skin Detektors messen zu können, werden meist die TP (true positive) und FP (false positive) betrachtet. Ein guter Detektor besitzt einen hohen TP-Wert und einen niedrigen FP-Wert. Bei der Bestimmung der Modellierungspara-

meter muss ein Kompromiss zwischen korrekter Hautdetektion und Fehldetektion getroffen werden. Leider wird bei vielen Hautdetektionsmethoden über die Resultate, die bei der eigenen, meist nicht veröffentlichten, Bilddatenbank erzielt wurden, berichtet. Eine Auflistung der TP- und FP-Werte von häufig benutzten Methoden ist in [63] enthalten. Angegeben werden dort jene Werte, über die die Autoren in ihren Arbeiten berichtet haben.

False positive werden durch Objekte verursacht, welche hautähnliche Farben besitzen. Dazu zählen unter anderem Holz, Sand, hautfarbenähnliche Bekleidung und ein paar Sorten von Leder.

Ein typisches Resultat eines Skindetektors ist in Abbildung 6.5 dargestellt. Der ausgewählte Algorithmus [43] verwendet fixe Schwellwerte für die Chromatizitätswerte (Cr, Cb, Hue) von zwei verschiedenen Farbräumen (YCrCb und HSV).



Abbildung 6.5: Links sieht man das Bild, auf das ein Skindetektor [43] angewendet wurde. Rechts ist dessen Resultat abgebildet. Jene Pixel, die die Kriterien des Klassifikators erfüllen, sind weiß markiert. Die restlichen Pixel sind schwarz.

Oft werden die detektierten Regionen noch nachbearbeitet (z.B. mit Morphologischen Operationen) um räumliche Homogenität zu erhalten.

6.2.1] Einfluss der Beleuchtung auf die Hautdetektion

Wie jede Farbe wird auch die Hautfarbe von der Beleuchtung beeinflusst. Da die menschliche Hautfarbe unterschiedlicher Personen hauptsächlich in der Helligkeit variiert, ignorieren viele Hautdetektionsmethoden die Farbintensität. Dies geschieht durch Transformation des RGB-Bildes in einen Farbraum, wo Intensität und Chroma-

tizität voneinander getrennt sind. Die Farbraumtransformation erleichtert die Segmentierung und reduziert den Beleuchtungseinfluss. Manche Autoren sind sogar der Meinung, dass man durch das Ignorieren der Intensität eine Unabhängigkeit gegenüber der Beleuchtung erzielt [35].

Hautdetektionsmethoden sind dafür ausgelegt, dass sie für verschiedene Personen und Hauttypen bei unterschiedlichen Beleuchtungen gute Ergebnisse liefern. Auch bei den Trainingsbildern wird auf eine größere Auswahl unterschiedlicher Beleuchtungsbedingungen geachtet. Nur wenige Arbeiten erfordern kontrollierte Beleuchtungsverhältnisse. Im medizinischen Bereich gibt es beispielsweise zur Identifikation von Melanom (schwarzer Hautkrebs) spezielle Hautmodelle, die bei einer vordefinierten Beleuchtung erstellt wurden [50]. Im Allgemeinen hat man bei den meisten praktischen Anwendungen jedoch keine kontrollierten Beleuchtungsverhältnisse (z.B. Bilder im Internet).

7] Farbkonstanz durch Objektlokalisierung und Experimente

Die Aufnahmen für die einzelnen Experimente wurden bei drei verschiedenen Beleuchtungen mit einer uEye-Kamera vom Typ UI-1220C erstellt. Damit im folgenden Text nicht immer die genauen Beleuchtungsbeschreibungen erwähnt werden müssen, werden diese ab nun nur noch mit Leuchtstoffröhrenlicht, Tageslicht und Halogenbeleuchtung bezeichnet. Nähere Details zu den einzelnen Beleuchtungen wurden bereits in Kapitel 4.2 gegeben.

Bei jeder Szene, von der ein Bild gemacht wurde, war ein Farbtarget (Munsell ColourChecker) enthalten. Damit auf die einzelnen Farbpatches besser verwiesen werden kann, wurden diese in Abbildung 7.1 durchnummeriert.



Abbildung 7.1: Die Farbflächen des "Munsell ColourChecker" sind nummeriert dargestellt.

Kamera und Target/Objekt(e) waren bei jeder Beleuchtungsbedingung genau einen Meter voneinander entfernt.

Die Belichtungszeit wurde so gewählt, dass der weiße Farbpatch des Targets (Mu19) bei keinem der drei Farbkanäle des digitalen Bildes einen höheren Wert als 244 hatte.

Eingestellt wurden folgende Belichtungszeiten:

- 17.004 ms (bei Leuchtstoffröhrenlicht)
- 2.022 ms (bei Tageslicht)
- 20.035 ms (bei Halogenbeleuchtung)

Das Objektiv, das verwendet wurde, war ein "COSMICAR Television LENS 8.5mm 1:1.5 (Blende: 16 bis 1.5)".

Es wurden folgende Blendenzahlen und Fokuseinstellungen gewählt:

- Blende 2.0 und Fokus 0.50 m (bei Leuchtstoffröhren- und Halogenbeleuchtung)
- Blende 11 und Fokus 0.50 m (bei Tageslicht)

Als Qualitätsmaß der einzelnen Methoden werden bei vielen Versuchen die Differenzen zu den Grundfarben (Mu13 bis Mu18) und der Grauskala (Mu19 bis Mu24) betrachtet. Dabei wurde zu jedem dieser Farbpatches die Differenz (|IST-SOLL|) der einzelnen Farbkanäle (RGB) berechnet und anschließend gemittelt (7.1).

$$\frac{|R_i^{ist} - R_i^{ref}| + |G_i^{ist} - G_i^{ref}| + |B_i^{ist} - B_i^{ref}|}{3} \quad (7.1)$$

Für die so erhaltenen Werte wurden für die Patches (Mu13 bis Mu24) folgende statistischen Kennwerte ermittelt:

- Mittelwert
- 1stQ (0,25-Quartile)
- Median (0,5-Quartile)
- 3rdQ (0,75-Quartile)
- Maximalwert

In jenen Fällen wo die normalisierten Differenzen betrachtet werden, wurden zur Berechnung der statistischen Kennwerte nur die Patches Mu13 bis Mu19 verwendet (In den betreffenden Tabellen wurde dies vermerkt).

Damit auch festgestellt werden kann, ob sich die Ergebnisse des RFCH-Algorithmus [19] verbessern, wurden die Histogram-Intersection-Werte zwischen den Trainingsbildern und Testbildern vor und nach der Farbkorrektur berechnet. Verglichen wurden die Histogramme der einzelnen Objekte jeweils ohne Hintergrundinformation.

Genauso gut hätte man die Detektionsrate für mehrere Szenen, in denen verschiedene Objekte lokalisiert werden müssen, betrachten können. Die Ergebnisse wären jedoch nicht so aussagekräftig gewesen, da sie sehr von den jeweiligen Szenen und

den darin enthaltenen Objekten (und Objektanordnungen) abhängig gewesen wären. Beispielsweise hätte ein Objekt bei den verschiedenen Beleuchtungsbedingungen auch ohne Farbkorrektur jedes Mal gefunden werden können. Bei der Betrachtung des Histogram-Intersection-Werts kann jedoch festgestellt werden, ob es nach der Farbkorrektur mit einer höheren Wahrscheinlichkeit gefunden werden kann.

7.1] Kalibrierung mit einem Farbtarget

Es wird nun mit Hilfe eines Farbtargets (Munsell ColourChecker) versucht, den Beleuchtungseinfluss zu minimieren. In Kapitel 5.3.1 sind bereits die Abweichungen zu den Farbpatches (Mu13 bis Mu24) vor und nach einer Kalibrierung auf die Farben eines Targets für zwei unterschiedliche Beleuchtungen enthalten (siehe Tabelle 5.5 und 5.6).

Da als Vergleich später noch die Abweichungen zu den normalisierten RGB-Werten der Farbpatches benötigt werden, wurden auch diese mit der Farbkalibrierungsmethode von S.Wolf [69] berechnet (siehe Tabelle 7.1 und 7.2). Kalibriert wurde mit den Referenzwerten, welche bei Leuchtstoffröhrenlicht ermittelt wurden. Bei Tabelle 7.2 wurde mit den normalisierten RGB-Werten von den Patches (Mu13 bis Mu19) kalibriert. Der Vorteil dieser Kalibrierungsvariante macht sich hauptsächlich erst bei ungleichförmiger Beleuchtung bemerkbar.

DIFF-RGB (uEye)	Tageslicht		Halogen	
	ohne Kalib.	mit Kalib.	ohne Kalib.	mit Kalib.
Mean (Mu13 bis Mu19)	0,0347	0,0063	0,0262	0,0052
1stQ (Mu13 bis Mu19)	0,0308	0,0017	0,0187	0,0017
Median (Mu13 bis Mu19)	0,0340	0,0057	0,0269	0,0053
3rdQ (Mu13 bis Mu19)	0,0384	0,0114	0,0321	0,0077
Max (Mu13 bis Mu19)	0,0475	0,0127	0,0391	0,0132

Tabelle 7.1: Differenzen zu den normalisierten RGB-Werten bei Tageslicht und Halogenbeleuchtung.

DIFF-RGB (uEye)	Tageslicht		Halogen	
	ohne Kalib.	mit Kalib.	ohne Kalib.	mit Kalib.
Mean (Mu13 bis Mu19)	0,0347	0,0080	0,0262	0,0078
1stQ (Mu13 bis Mu19)	0,0308	0,0054	0,0187	0,0046
Median (Mu13 bis Mu19)	0,0340	0,0076	0,0269	0,0076
3rdQ (Mu13 bis Mu19)	0,0384	0,0099	0,0321	0,0111
Max (Mu13 bis Mu19)	0,0475	0,0145	0,0391	0,0121

Tabelle 7.2: Differenzen zu den normalisierten RGB-Werten bei Tageslicht und Halogenbeleuchtung. Kalibriert wurde diesmal mit den normalisierten RGB-Werten.

Abschließend wurden die Histogram-Intersection-Werte für 28 verschiedene Objekte (siehe Tabelle A1 bis A4) bei zwei unterschiedlichen Beleuchtungen (Tageslicht und Halogenbeleuchtung) ermittelt. Die Objekte wurden bei Leuchtstoffröhrenlicht trainiert.

Nach der Durchführung der Kalibrierung auf die Farben eines Targets wurden wiederum die Histogram-Intersection-Werte ermittelt (Die Referenzwerte der Farben am Target wurden bei der Trainingsbeleuchtung bestimmt). Wie erwartet, erhöhten sich die Werte bei allen Objekten (siehe Tabelle 7.3 und 7.4). In den Tabellen sind auch jene Werte enthalten, als mit den normalisierten RGB-Werten kalibriert wurde. Auch in diesem Fall erhöhten sich für alle Objekte die Werte nach der Kalibrierung.

Histogram-Intersection-Value (RFCH)	Objekt	Tageslicht		
		ohne Kalib.	mit Kalib.	mit Kalib. (normalisiert)
01	34,54	61,64	66,60	
02	22,51	62,23	46,42	
03	8,98	47,90	36,92	
04	10,49	64,51	48,82	
05	13,57	55,55	34,94	
06	14,45	31,76	27,11	
07	57,06	78,41	78,40	
08	47,52	76,55	71,59	
09	20,82	52,72	46,82	
10	42,32	65,51	64,98	
11	11,56	67,00	55,36	
12	25,22	68,43	71,82	
13	40,47	51,43	50,07	
14	38,00	62,95	66,58	
15	36,72	71,26	70,03	
16	27,67	64,52	57,28	
17	58,56	72,59	78,23	
18	46,48	68,20	66,73	
19	44,25	67,38	56,38	
20	43,85	73,57	78,93	
21	17,65	64,48	56,32	
22	30,13	70,98	68,38	
23	9,75	69,99	63,55	
24	57,78	81,50	64,79	
25	0,35	34,63	27,54	
26	0,00	46,11	5,63	
27	0,00	48,90	30,86	
28	1,47	52,57	58,46	

Tabelle 7.3: Histogram-Intersection-Werte für 28 verschiedene Objekte (mit/ohne Kalibrierung) bei Tageslicht.

Histogram- Intersection- Value (RFCH)	Objekt	Halogen		
		ohne Kalib.	mit Kalib.	mit Kalib. (normalisiert)
	01	47,89	65,01	75,46
	02	28,36	59,39	67,37
	03	31,88	45,97	71,63
	04	38,90	49,07	57,94
	05	24,28	37,53	26,91
	06	12,34	29,36	55,12
	07	57,72	76,62	77,44
	08	56,91	61,86	70,86
	09	25,09	40,21	59,52
	10	37,78	45,45	44,93
	11	10,27	49,90	63,97
	12	50,32	58,44	72,15
	13	35,88	52,08	49,99
	14	30,79	39,49	54,42
	15	52,92	63,62	68,47
	16	35,78	74,06	78,68
	17	55,88	70,66	84,17
	18	44,78	55,84	64,26
	19	40,41	47,09	56,38
	20	50,51	51,94	67,40
	21	27,99	71,42	83,61
	22	55,37	80,59	83,39
	23	43,97	63,62	75,40
	24	49,13	76,73	80,16
	25	0,05	40,87	9,88
	26	0,01	47,13	16,63
	27	0,00	25,18	50,46
	28	2,12	45,16	77,99

Tabelle 7.4: Histogram-Intersection-Werte für 28 verschiedene Objekte (mit/ohne Kalibrierung) bei Halogenbeleuchtung.

Die Ergebnisse des RFCH-Algorithmus [19] lassen sich also durch die Kalibrierung mit einem Farbtarget verbessern.

7.2] Kalibrierung auf Objekt X

Bei dieser Methode wurden die Objekte von Tabelle A.1 und A.4 verwendet. Diese Objekte enthalten eine oder mehrere homogen farbige Fläche(n) auf die kalibriert werden kann. Auf wie viele, und auf welche Farben von den Objekten kalibriert wurde, ist in Tabelle A.5 und A.6 ersichtlich. In den Tabellen sind auch die Referenzfarbwerte enthalten, welche bei Leuchtstoffröhrenlicht ermittelt wurden.

Abhängig davon, wie viele Farben von einem Objekt verwendet wurden, dienen unterschiedliche Methoden zur Farbkorrektur:

- eine oder zwei homogen farbige Flächen: 3x3 Diagonalmodell
- drei homogen farbige Flächen: Farbkalibrierungsmethode von E. Roullot [52]
- vier homogen farbige Flächen: Farbkalibrierungsmethode von S. Wolf [69] (exkl. polynomiale Ausgleichskurven)
- mehr als vier homogen farbige Flächen: Farbkalibrierungsmethode von S. Wolf [69] (inkl. polynomialer Ausgleichskurven und Iteration)

Zunächst wurden nach der Kalibrierung auf Objekt X wiederum die Differenzen zu den Grundfarben eines Farbtargets berechnet (siehe Tabelle 7.5 bis 7.18). Die Tabellen enthalten die Differenzen zu den normalisierten RGB-Werten der Farbpatches.

Objekt 01	Tageslicht		Halogen	
	ohne Kalib.	mit Kalib.	ohne Kalib.	mit Kalib.
DIFF-RGB (uEye)				
Mean (Mu13 bis Mu19)	0,0347	0,0257	0,0262	0,0142
1stQ (Mu13 bis Mu19)	0,0308	0,0094	0,0187	0,0077
Median (Mu13 bis Mu19)	0,0340	0,0284	0,0269	0,0136
3rdQ (Mu13 bis Mu19)	0,0384	0,0413	0,0321	0,0224
Max (Mu13 bis Mu19)	0,0475	0,0441	0,0391	0,0266

Tabelle 7.5: Differenzen zu den normalisierten RGB-Werten bei Tageslicht und bei Halogenbeleuchtung. Kalibriert wurde mit den Farben von Objekt 01.

Objekt 02	Tageslicht		Halogen	
	ohne Kalib.	mit Kalib.	ohne Kalib.	mit Kalib.
DIFF-RGB (uEye)				
Mean (Mu13 bis Mu19)	0,0347	0,0470	0,0262	0,0426
1stQ (Mu13 bis Mu19)	0,0308	0,0133	0,0187	0,0105
Median (Mu13 bis Mu19)	0,0340	0,0193	0,0269	0,0426
3rdQ (Mu13 bis Mu19)	0,0384	0,0882	0,0321	0,0626
Max (Mu13 bis Mu19)	0,0475	0,1063	0,0391	0,1066

Tabelle 7.6: Differenzen zu den normalisierten RGB-Werten bei Tageslicht und bei Halogenbeleuchtung. Kalibriert wurde mit den Farben von Objekt 02.

Objekt 03	Tageslicht		Halogen	
	ohne Kalib.	mit Kalib.	ohne Kalib.	mit Kalib.
DIFF-RGB (uEye)				
Mean (Mu13 bis Mu19)	0,0347	0,0297	0,0262	0,0185
1stQ (Mu13 bis Mu19)	0,0308	0,0084	0,0187	0,0115
Median (Mu13 bis Mu19)	0,0340	0,0110	0,0269	0,0198
3rdQ (Mu13 bis Mu19)	0,0384	0,0552	0,0321	0,0212
Max (Mu13 bis Mu19)	0,0475	0,0900	0,0391	0,0340

Tabelle 7.7: Differenzen zu den normalisierten RGB-Werten bei Tageslicht und bei Halogenbeleuchtung. Kalibriert wurde mit den Farben von Objekt 03.

Objekt 04	Tageslicht		Halogen	
	ohne Kalib.	mit Kalib.	ohne Kalib.	mit Kalib.
DIFF-RGB (uEye)				
Mean (Mu13 bis Mu19)	0,0347	0,0117	0,0262	0,0708
1stQ (Mu13 bis Mu19)	0,0308	0,0051	0,0187	0,0132
Median (Mu13 bis Mu19)	0,0340	0,0114	0,0269	0,0386
3rdQ (Mu13 bis Mu19)	0,0384	0,0147	0,0321	0,0532
Max (Mu13 bis Mu19)	0,0475	0,0283	0,0391	0,3108

Tabelle 7.8: Differenzen zu den normalisierten RGB-Werten bei Tageslicht und bei Halogenbeleuchtung. Kalibriert wurde mit den Farben von Objekt 04.

Objekt 05	Tageslicht		Halogen	
	ohne Kalib.	mit Kalib.	ohne Kalib.	mit Kalib.
DIFF-RGB (uEye)				
Mean (Mu13 bis Mu19)	0,0347	0,0237	0,0262	0,0258
1stQ (Mu13 bis Mu19)	0,0308	0,0108	0,0187	0,0188
Median (Mu13 bis Mu19)	0,0340	0,0260	0,0269	0,0244
3rdQ (Mu13 bis Mu19)	0,0384	0,0283	0,0321	0,0325
Max (Mu13 bis Mu19)	0,0475	0,0513	0,0391	0,0409

Tabelle 7.9: Differenzen zu den normalisierten RGB-Werten bei Tageslicht und bei Halogenbeleuchtung. Kalibriert wurde mit den Farben von Objekt 05.

Objekt 06	Tageslicht		Halogen	
	ohne Kalib.	mit Kalib.	ohne Kalib.	mit Kalib.
DIFF-RGB (uEye)				
Mean (Mu13 bis Mu19)	0,0347	0,0108	0,0262	0,0157
1stQ (Mu13 bis Mu19)	0,0308	0,0056	0,0187	0,0093
Median (Mu13 bis Mu19)	0,0340	0,0133	0,0269	0,0140
3rdQ (Mu13 bis Mu19)	0,0384	0,0137	0,0321	0,0242
Max (Mu13 bis Mu19)	0,0475	0,0199	0,0391	0,0283

Tabelle 7.10: Differenzen zu den normalisierten RGB-Werten bei Tageslicht und bei Halogenbeleuchtung. Kalibriert wurde mit den Farben von Objekt 06.

Objekt 07	Tageslicht		Halogen	
	ohne Kalib.	mit Kalib.	ohne Kalib.	mit Kalib.
DIFF-RGB (uEye)				
Mean (Mu13 bis Mu19)	0,0347	0,0091	0,0262	0,0106
1stQ (Mu13 bis Mu19)	0,0308	0,0064	0,0187	0,0063
Median (Mu13 bis Mu19)	0,0340	0,0107	0,0269	0,0095
3rdQ (Mu13 bis Mu19)	0,0384	0,0112	0,0321	0,0137
Max (Mu13 bis Mu19)	0,0475	0,0114	0,0391	0,0181

Tabelle 7.11: Differenzen zu den normalisierten RGB-Werten bei Tageslicht und bei Halogenbeleuchtung. Kalibriert wurde mit den Farben von Objekt 07.

Objekt 08	Tageslicht		Halogen	
	ohne Kalib.	mit Kalib.	ohne Kalib.	mit Kalib.
DIFF-RGB (uEye)				
Mean (Mu13 bis Mu19)	0,0347	0,0108	0,0262	0,0133
1stQ (Mu13 bis Mu19)	0,0308	0,0057	0,0187	0,0065
Median (Mu13 bis Mu19)	0,0340	0,0119	0,0269	0,0140
3rdQ (Mu13 bis Mu19)	0,0384	0,0156	0,0321	0,0166
Max (Mu13 bis Mu19)	0,0475	0,0176	0,0391	0,0260

Tabelle 7.12: Differenzen zu den normalisierten RGB-Werten bei Tageslicht und bei Halogenbeleuchtung. Kalibriert wurde mit den Farben von Objekt 08.

Objekt 09	Tageslicht		Halogen	
	ohne Kalib.	mit Kalib.	ohne Kalib.	mit Kalib.
DIFF-RGB (uEye)				
Mean (Mu13 bis Mu19)	0,0347	0,0197	0,0262	0,0394
1stQ (Mu13 bis Mu19)	0,0308	0,0085	0,0187	0,0089
Median (Mu13 bis Mu19)	0,0340	0,0184	0,0269	0,0326
3rdQ (Mu13 bis Mu19)	0,0384	0,0219	0,0321	0,0383
Max (Mu13 bis Mu19)	0,0475	0,0515	0,0391	0,1425

Tabelle 7.13: Differenzen zu den normalisierten RGB-Werten bei Tageslicht und bei Halogenbeleuchtung. Kalibriert wurde mit den Farben von Objekt 09.

Objekt 10	Tageslicht		Halogen	
	ohne Kalib.	mit Kalib.	ohne Kalib.	mit Kalib.
DIFF-RGB (uEye)				
Mean (Mu13 bis Mu19)	0,0347	0,1090	0,0262	0,1604
1stQ (Mu13 bis Mu19)	0,0308	0,0058	0,0187	0,0368
Median (Mu13 bis Mu19)	0,0340	0,0498	0,0269	0,0886
3rdQ (Mu13 bis Mu19)	0,0384	0,2005	0,0321	0,3216
Max (Mu13 bis Mu19)	0,0475	0,3849	0,0391	0,4190

Tabelle 7.14: Differenzen zu den normalisierten RGB-Werten bei Tageslicht und bei Halogenbeleuchtung. Kalibriert wurde mit den Farben von Objekt 10.

Objekt 25	Tageslicht		Halogen	
	ohne Kalib.	mit Kalib.	ohne Kalib.	mit Kalib.
DIFF-RGB (uEye)				
Mean (Mu13 bis Mu19)	0,0347	0,0203	0,0262	0,0130
1stQ (Mu13 bis Mu19)	0,0308	0,0164	0,0187	0,0086
Median (Mu13 bis Mu19)	0,0340	0,0195	0,0269	0,0122
3rdQ (Mu13 bis Mu19)	0,0384	0,0247	0,0321	0,0177
Max (Mu13 bis Mu19)	0,0475	0,0325	0,0391	0,0235

Tabelle 7.15: Differenzen zu den normalisierten RGB-Werten bei Tageslicht und bei Halogenbeleuchtung. Kalibriert wurde mit den Farben von Objekt 25.

Objekt 26	Tageslicht		Halogen	
	ohne Kalib.	mit Kalib.	ohne Kalib.	mit Kalib.
DIFF-RGB (uEye)				
Mean (Mu13 bis Mu19)	0,0347	0,0116	0,0262	0,0115
1stQ (Mu13 bis Mu19)	0,0308	0,0075	0,0187	0,0077
Median (Mu13 bis Mu19)	0,0340	0,0112	0,0269	0,0103
3rdQ (Mu13 bis Mu19)	0,0384	0,0159	0,0321	0,0154
Max (Mu13 bis Mu19)	0,0475	0,0221	0,0391	0,0203

Tabelle 7.16: Differenzen zu den normalisierten RGB-Werten bei Tageslicht und bei Halogenbeleuchtung. Kalibriert wurde mit den Farben von Objekt 26.

Objekt 27	Tageslicht		Halogen	
	ohne Kalib.	mit Kalib.	ohne Kalib.	mit Kalib.
DIFF-RGB (uEye)				
Mean (Mu13 bis Mu19)	0,0347	0,0114	0,0262	0,0130
1stQ (Mu13 bis Mu19)	0,0308	0,0062	0,0187	0,0097
Median (Mu13 bis Mu19)	0,0340	0,0120	0,0269	0,0118
3rdQ (Mu13 bis Mu19)	0,0384	0,0166	0,0321	0,0193
Max (Mu13 bis Mu19)	0,0475	0,0175	0,0391	0,0231

Tabelle 7.17: Differenzen zu den normalisierten RGB-Werten bei Tageslicht und bei Halogenbeleuchtung. Kalibriert wurde mit den Farben von Objekt 27.

Objekt 28 DIFF-RGB (uEye)	Tageslicht		Halogen	
	ohne Kalib.	mit Kalib.	ohne Kalib.	mit Kalib.
Mean (Mu13 bis Mu19)	0,0347	0,0085	0,0262	0,0135
1stQ (Mu13 bis Mu19)	0,0308	0,0032	0,0187	0,0089
Median (Mu13 bis Mu19)	0,0340	0,0104	0,0269	0,0095
3rdQ (Mu13 bis Mu19)	0,0384	0,0125	0,0321	0,0204
Max (Mu13 bis Mu19)	0,0475	0,0135	0,0391	0,0225

Tabelle 7.18: Differenzen zu den normalisierten RGB-Werten bei Tageslicht und bei Halogenbeleuchtung. Kalibriert wurde mit den Farben von Objekt 28.

Vergleicht man die einzelnen Ergebnisse mit jenen, wo mit dem Farbtarget kalibriert wurde (siehe Tabelle 7.1), so kann man erkennen, dass mit keinem Objekt die Farben so gut korrigiert werden konnten, wie mit dem Target. Dies war auch zu erwarten, da bei der Kalibrierung mit dem Farbtarget genau jene Abweichungen minimiert wurden, mit denen auch die statistischen Kenngrößen berechnet wurden. Die vom Target betrachteten Farben (Blau, Grün, Rot, Gelb, Magenta, Cyan und Grauskala bzw. weiß) wurden jedoch nicht willkürlich gewählt. Sie sollten repräsentativ für alle möglichen Farben am aussagekräftigsten sein.

Speziell bei jenen Objekten (06, 25, 26, 27, 28), wo nur auf eine oder zwei Farbe(n) kalibriert wurde, verbesserten sich alle ermittelten Kenngrößen. Auch bei den Objekten 07 und 08 verbesserten sich nach der Kalibrierung alle in den Tabellen enthaltenen Werte. Bei den Objekten 01 und 03 war dies großteils ebenfalls der Fall. Von Bedeutung ist dies für den RFCH-Algorithmus [19]. Wird nämlich auf die Farben dieser Objekte kalibriert, kann man davon ausgehen, dass auch andere Objekte, die sich in der Szene befinden, mit einer höheren Wahrscheinlichkeit gefunden werden können.

Bei allen anderen Objekten verschlechterten sich zum Teil die statistischen Kenngrößen. Für die Objektlokalisierung bedeutet das, dass nach der Kalibrierung auf die Farben dieser Objekte, andere Objekte in der Szene vielleicht mit einer geringeren Wahrscheinlichkeit gefunden werden können. Ob sich die Farbkorrektur für andere Objekte in der Szene verschlechtert, hängt jedoch davon ab, wie sehr sich deren Farben von jenen, auf die kalibriert wurde, unterscheiden.

Bei Objekt 10 vergrößerten sich die Differenzen zu den Farben am Target am meisten. Da die von diesem Objekt betrachtete Oberfläche nicht planar war sondern zylinderförmig, waren die Beleuchtungsbedingungen nicht optimal. Bei den an sich ho-

mogenen Farbflächen wurden dadurch einzelne Bereiche nicht mit der gleichen Intensität beleuchtet. Eine gleichförmige Beleuchtung wurde jedoch vorausgesetzt.

Ob der RFCH-Algorithmus [19] von der Kalibrierung auf Objekt X profitiert, wurde auch diesmal genauer untersucht (siehe Tabelle 7.19 und 7.20). (Für Tageslicht war es diesmal nicht sinnvoll eine Tabelle zu erstellen, da die Bildaufnahmen der einzelnen Objekte hintereinander gemacht wurden, wodurch die Beleuchtungsbedingungen bei Tageslicht nicht immer zu 100% dieselben waren.)

Histogram-Intersection-Value (RFCH)	Halogen (Teil 1)							
	ohne Kalib.	kalib. auf Objekt 01	kalib. auf Objekt 02	kalib. auf Objekt 03	kalib. auf Objekt 04	kalib. auf Objekt 05	kalib. auf Objekt 06	kalib. auf Objekt 07
Objekt 01	47,89	77,24	9,62	73,02	26,24	38,62	42,99	66,76
02	28,36	63,28	71,47	72,58	75,81	38,57	61,32	77,95
03	31,88	72,41	37,52	84,45	81,18	40,11	47,85	71,47
04	38,90	81,95	49,08	86,85	80,55	40,06	53,59	69,02
05	24,28	35,69	18,17	45,23	30,23	71,96	17,58	39,29
06	12,34	72,77	64,20	68,08	74,06	17,41	48,41	74,91
07	57,72	74,80	50,49	77,73	62,58	62,50	67,68	80,53
08	56,91	79,41	24,70	81,11	55,73	49,53	61,88	73,54
09	25,09	69,18	53,70	68,42	71,86	38,47	66,98	68,76
10	37,78	53,36	58,32	52,89	50,40	53,15	52,64	55,46
25	0,05	21,56	0,00	23,71	0,00	2,79	3,86	5,07
26	0,01	42,88	0,00	43,36	0,00	27,63	16,50	17,29
27	0,00	0,73	0,00	47,87	0,00	1,98	0,34	40,44
28	2,12	28,10	3,87	6,78	28,36	8,80	10,74	25,52

Tabelle 7.19: Histogram-Intersection-Werte für Objekt X (mit/ohne Kalibrierung auf Objekt X) sowie für alle anderen Objekte bei Halogenbeleuchtung.

Histogram-Intersection-Value (RFCH)	Halogen (Teil 2)							
	ohne Kalib.	kalib. auf Objekt 08	kalib. auf Objekt 09	kalib. auf Objekt 10	kalib. auf Objekt 25	kalib. auf Objekt 26	kalib. auf Objekt 27	kalib. auf Objekt 28
Objekt 01	47,89	80,84	66,02	18,16	56,98	49,39	59,89	38,35
02	28,36	87,28	82,58	19,06	51,67	66,11	48,04	51,72
03	31,88	85,52	86,78	7,16	53,30	71,58	51,62	33,40
04	38,90	86,39	82,53	15,63	37,59	51,36	34,96	44,90
05	24,28	35,80	38,51	5,38	30,66	21,47	40,30	14,28
06	12,34	83,24	83,26	22,57	31,07	78,20	26,44	35,76
07	57,72	85,10	68,75	36,34	70,41	69,16	71,79	63,07
08	56,91	88,05	72,29	36,28	60,68	62,57	65,29	51,77
09	25,09	71,32	82,85	19,39	40,07	54,97	38,13	52,74
10	37,78	55,22	51,58	46,57	40,75	49,34	41,78	46,70
25	0,05	18,67	6,18	0,00	53,43	9,10	22,45	4,45
26	0,01	15,03	24,95	0,00	39,76	41,45	22,88	10,33
27	0,00	11,17	16,22	0,00	38,21	5,18	62,01	4,02
28	2,12	18,70	25,27	0,14	32,86	11,15	45,04	21,95

Tabelle 7.20: Histogram-Intersection-Werte für Objekt X (mit/ohne Kalibrierung auf Objekt X) sowie für alle anderen Objekte bei Halogenbeleuchtung.

Für die Tabellen wurden wiederum die Histogram-Intersection-Werte, vor und nach der Farbkorrektur mit Objekt X, berechnet. Zusätzlich wurden diese Werte auch jedes Mal für alle anderen Objekte ermittelt. Damit konnte festgestellt werden, ob auch diese nach der Kalibrierung mit einer höheren Wahrscheinlichkeit gefunden werden können.

Bei jenen Objekten, auf deren Farben in der jeweiligen Spalte kalibriert wurde, besitzt der Histogram-Intersection-Wert einen dicken Rahmen. Wie zu erwarten war, haben sich diese Werte für alle Objekte erhöht.

Fett gedruckte Zahlen sollten hervorheben, dass sich das Ergebnis nach der Kalibrierung verschlechtert hat. Besonders oft war dies der Fall, als auf die Farben von Objekt 10 kalibriert wurde. Wenn man bedenkt, dass sich für dieses Objekt auch die Differenzen zu den Farben am Target ziemlich vergrößert hatten, konnte eigentlich auch nichts anderes erwartet werden. Ebenfalls ziemlich schlecht schnitten auch diesmal die Objekte 02 und 04 ab.

Bei der Kalibrierung auf die Objekte 01, 03, 07, 08 und 09 erhöhten sich auch für alle anderen Objekte die Histogram-Intersection-Werte.

Bei allen übrigen Objekten auf die kalibriert wurde verschlechterten sich die Werte für die anderen Objekte meist nur ein- bis zweimal.

Für Objekt 05 und speziell für Objekt 09 waren die Ergebnisse eher überraschend. Für eine größere Testmenge hätten sich jedoch bei diesen Objekten sicher mehr Werte verschlechtert.

7.3] Verbessern von Farbkonstanzalgorithmen durch Zusatzinformation

Eine andere Möglichkeit, Farbkonstanz durch Objektlokalisierung zu erzielen, würde sich ergeben, wenn sich geeignete Farbkonstanzalgorithmen, durch die Farbinformation von bestimmten Objekten in der Szene, verbessern ließen.

Da hierbei Zusatzinformationen über die Beleuchtung aus einem bestimmten Bereich im Bild abgeleitet werden, eignet sich diese Methode eher für Algorithmen, die für gleichförmige Beleuchtung entwickelt wurden. Außerdem sind jene Algorithmen, die auch bei ungleichförmiger Beleuchtung funktionieren, für reale Bedingungen meist

nicht geeignet. Deren Funktionsweise wurde größtenteils bei sehr künstlichen Bedingungen (z.B. mit Mondrian Bildern) demonstriert (siehe z.B. [17]).

Bei der Suche nach Algorithmen, welche von der Zusatzinformation profitieren könnten, bestand das Problem, dass man deren Grundprinzip abändern hätte müssen. Dadurch wäre auch ein neuer Algorithmus entstanden. Da es schon sehr viele Farbkonstanzalgorithmen gibt, war es nicht einfach, einen weiteren zu erfinden, welcher noch dazu unter realen Bedingungen möglichst gut funktionieren sollte.

Am ehesten wurde die Aufgabe in Kapitel 7.2 erfüllt, als auf die Farben von Objekt X kalibriert wurde. Diese Vorgehensweise ist vergleichbar mit dem White Patch Algorithmus [17], wo die Annahme getroffen wird, dass der hellste Fleck im Bild der Farbe weiß entspricht.

Für die Algorithmen kann die Farbinformation eines Objektes speziell dann nützlich sein, wenn dadurch einzelne Annahmen erfüllt werden können (z.B. hellster Fleck ist weiß). Genauere Untersuchungen dazu wurden im nächsten Kapitel durchgeführt.

7.4] Erfüllen der Bedingungen einzelner Farbkonstanzalgorithmen

Die Grundidee dieser Variante ist, dass nach Objekten in der Szene gesucht wird, die gute Constraints liefern, welche von ausgewählten Farbkonstanzalgorithmen benötigt werden.

Wiederum werden nur Farbkonstanzalgorithmen für gleichförmige Beleuchtung betrachtet. Für die Algorithmen (aus [17]) müssen oft nur sehr einfache Annahmen erfüllt werden:

- z.B. eine weiße Fläche: für den “white patch retinex, maximum value per channel“- Algorithmus oder den “white patch retinex, histogram“-Algorithmus.
- durchschnittliche Farbe grau: für alle Algorithmen die auf der Annahme passieren, dass die durchschnittliche Farbe grau ist.
- Hellste Fleck weiß und dunkelste schwarz: für eine Untervariante des Horn-Algorithmus.
- Möglichst viele verschiedene Farben: für die Gammut-Mapping-Methoden.
- ...

Für die weiteren Betrachtungen wurde der White Patch Algorithmus [17] ausgewählt. Der Grund dafür war, dass die Annahme von diesem Algorithmus von vielen Objekten erfüllt werden kann. Auch fast alle Objekte, die für die Versuche verwendet wurden, enthalten eine weiße homogene Fläche. Die Farbkorrektur erfolgt hierbei mit einem 3x3 Diagonalmatrixmodell. Die unbekannten Parameter werden mit der weißen Fläche von einem Objekt bestimmt.

Normalerweise, wenn der Algorithmus ohne diesem Zusatzwissen von einem Objekt auf ein Bild angewendet wird, wird der höchste Wert von jedem Farbkanal genommen, und als weiß angenommen. Die einzelnen Kanäle werden danach dementsprechend neu skaliert (7.2). Eine Verbesserung stellt der "white patch retinex, histogram"-Algorithmus [17] dar.

$$(R' \quad G' \quad B') = \begin{pmatrix} \frac{R_{white}}{R_{max}(I)} & 0 & 0 \\ 0 & \frac{G_{white}}{G_{max}(I)} & 0 \\ 0 & 0 & \frac{B_{white}}{B_{max}(I)} \end{pmatrix} \cdot \begin{pmatrix} R \\ G \\ B \end{pmatrix} \quad (7.2)$$

C_{white} : weiß bei der vordefinierten Beleuchtung

$C_{max}(I)$: Maximum von Kanal C von Bild I

Um feststellen zu können, ob man mit dieser Methode besser ist als mit der Kalibrierung auf die Farben eines Targets bzw. auf die von Objekt X, wurden auch diesmal die normalisierten Differenzen zu den Farben (Mu13 bis Mu19) des Munsell-Targets bei zwei unterschiedlichen Beleuchtungen ermittelt (siehe Tabelle 7.21).

DIFF-RGB (uEye)	Tageslicht		Halogen	
	ohne Kalib.	mit Kalib.	ohne Kalib.	mit Kalib.
Mean (Mu13 bis Mu19)	0,0347	0,0159	0,0262	0,0130
1stQ (Mu13 bis Mu19)	0,0308	0,0131	0,0187	0,0057
Median (Mu13 bis Mu19)	0,0340	0,0165	0,0269	0,0172
3rdQ (Mu13 bis Mu19)	0,0384	0,0188	0,0321	0,0191
Max (Mu13 bis Mu19)	0,0475	0,0275	0,0391	0,0194

Tabelle 7.21: Differenzen zu den normalisierten RGB-Werten bei Tageslicht und Halogenbeleuchtung. Die Kalibrierung erfolgte mit dem White Patch Algorithmus [17] (unter zu Hilfenahme einer weißen homogenen Fläche von Objekt 01).

Bei beiden Beleuchtungsbedingungen verkleinerten sich alle statistischen Kenngrößen. So gut wie mit dem Target (vgl. mit Tabelle 7.1) konnten jedoch auch diesmal die Farben nicht korrigiert werden. Im Vergleich zu den Objekten auf deren Farben in Kapitel 7.2 kalibriert wurde, verkleinerten sich hier die Werte fast überall mehr (Ausnahmen: Objekt 08, 27, 28 bei Tageslicht, Objekt 06 bei Halogenbeleuchtung und Objekt 07, 26 bei beiden Beleuchtungen).

Weiters wurden wieder die Histogram-Intersection-Werte mit dem RFCH-Algorithmus [19] für die einzelnen Objekte, vor und nach der Farbkorrektur, berechnet (siehe Tabelle 7.22).

Histogram-Intersection-Value (RFCH)	Halogen	
	ohne Kalib.	kalib. mit White Patch von Objekt 01
Objekt 01	47,89	61,28
02	28,36	52,41
03	31,88	66,29
04	38,90	46,92
05	24,28	37,50
06	12,34	42,82
07	57,72	71,98
08	56,91	66,22
09	25,09	44,64
10	37,78	47,15
25	0,05	16,68
26	0,01	43,09
27	0,00	13,10
28	2,12	13,15

Tabelle 7.22: Histogram-Intersection-Werte für Objekt X (mit/ohne White Patch Algorithmus [17] (unter zu Hilfenahme einer weißen homogenen Fläche von Objekt 01)) sowie für alle anderen Objekte bei Halogenbeleuchtung.

Bei allen Objekten konnte eine Verbesserung erzielt werden.

Aufgrund der Tatsache, dass viele natürliche Objekte eine weiße Fläche enthalten, ist diese Methode bei vielen Applikationen anwendbar.

7.5] Farbkonstanz durch Hautdetektion

Wie bereits in Kapitel 6.2 angekündigt, wird nun untersucht, ob (und wie) man durch Hautdetektion Farbkonstanz erzielen kann.

Die Hautfarbe von verschiedenen Personen/Bevölkerungsgruppen variiert sehr. Selbst bei ein und derselben Person gibt es teilweise große Unterschiede (Gesicht

vs. Hand; nach einer längeren Sonnenbestrahlung; ...) [16]. Die meisten Farbmodelle, die z.B. für Skindetektion erstellt wurden, berücksichtigten neben den unterschiedlichen Hauttypen zusätzlich noch den Einfluss verschiedener Beleuchtungen. Aufgrund der starken farblichen Variation, und auch weil der Beleuchtungseinfluss berücksichtigt wird, kann man mit diesen Modellen schwer Informationen über die aktuelle Beleuchtung erhalten.

Um an Hinweise über die Beleuchtung zu gelangen, müsste man mehrere Hautmodelle für vordefinierte Beleuchtungen erstellen. Falls man einen Farbraum finden würde, wo sich die gebündelten Bereiche dieser Modelle nicht all zu sehr überlappen, könnte man mit diesen Modellen die aktuelle Beleuchtung schätzen (Es wird davon ausgegangen, dass sich in der Szene, von der die Beleuchtung geschätzt werden sollte, Hautpixel befinden). Dazu müsste von den gebündelten Bereichen der einzelnen Modelle jeweils der Schwerpunkt berechnet werden. Von den Hautpixeln, welche beispielsweise ein Face-Detektor (in Kombination mit einem Hautdetektions-Algorithmus) liefert, könnte man dann den Abstand zu den einzelnen Clusterschwerpunkten berechnen. Aus jenem Modell, zu dessen Clusterschwerpunkt der kürzeste Abstand berechnet wurde, ergibt sich dann eine Schätzung für die aktuelle Beleuchtung. Dieser Ansatz wurde jedoch nicht weiter verfolgt.

Nachdem die Beleuchtung geschätzt wurde, kann die Farbkorrektur dann mit Hilfe von Farbkorrekturmatrizen erfolgen. Die Matrizen können mit einem Farbtarget vorberechnet werden (siehe Kapitel 5.3.2).

Möglicherweise ist es sogar notwendig, personenspezifische oder bevölkerungsspezifische Modelle zu erstellen. Personenspezifische Hautmodelle wurden bereits von Vilaplana [64] für die Skindetektion vorgeschlagen.

8] Zusammenfassung

Viele Anwendungen im Bereich der Computer Vision können durch das Einbeziehen der Farbinformation einer Objektoberfläche verbessert werden. Der Vorteil von Farbe ist, dass sie invariant bezüglich Translation, Rotation und Skalierung ist. Ein Nachteil wiederum ist der Einfluss verschiedener Beleuchtungsbedingungen. Im Gegensatz zu technischen Bildaufnahmegeräten ist der Mensch in der Lage, die Farbe von Objekten nahezu unabhängig vom Licht, welches die Objekte beleuchtet, zu erfassen.

Bei dieser Arbeit wurde untersucht, wie man mit Hilfe der Farbinformationen von Objekten in einer Szene Farbkonstanz erreichen kann. Dabei wurde unter anderem auch ein Konzept vorgestellt, wie man durch Hautdetektion Farbkonstanz erzielen könnte.

Derzeitige Farbkonstanzalgorithmen funktionieren meist nur bei sehr einfachen physikalischen Bedingungen. Die meisten Algorithmen fordern eine gleichförmige Beleuchtung, bei der keine spiegelnden Reflexionen auftreten. Die Objekte werden als glatt, matt und gleichförmig beleuchtet angenommen. Viele der Annahmen werden oft unter "realen" Bedingungen nicht erfüllt.

Da es an guten Farbkonstanzalgorithmen mangelt, verwenden viele farbbasierte Objekterkennungsalgorithmen beleuchtungsinvariante Farbinformationen (z.B. relative Farbdeskriptoren). Farbkonstanz ist meist nur dann notwendig, wenn die Farbinformation der Haupthinweis zur Objekterkennung ist. Für einen solchen Objekterkennungsalgorithmus sind die Farbkonstanzalgorithmen jedoch noch nicht gut genug [26]. Für alle anderen Algorithmen, die zwar von der Beleuchtung beeinflusst werden, aber auch ohne Farbkonstanz akzeptable Resultate liefern, sind Farbkonstanzalgorithmen nützlich, da die Objekterkennungseffizienz gesteigert werden kann.

Farbkalibrierung dient dazu, geräteunabhängige Farbbilder zu erhalten. Da bei der Farbkalibrierung nicht nur der Einfluss des Sensorsystems minimiert wird, sondern auch jener der Beleuchtung, kann damit auch Farbkonstanz erzielt werden. Drei verschiedene Möglichkeiten (Kalibrierung mit einem Farbtarget, Schätzen der Beleuchtung und Kalibrierung auf Objekt X) wurden vorgeschlagen. Für zwei dieser Möglichkeiten wurden auch Versuche durchgeführt. Bei der Kalibrierung mit einem Farbtarget, konnten, wie erwartet, die besten Ergebnisse erzielt werden. Da nicht genug ge-

eignete gleichförmige Beleuchtungsverhältnisse erzeugt werden konnten, gab es zur Schätzung der Beleuchtung keine Experimente.

Für einen der Farbkalibrierungsalgorithmen [69], der sowohl eine lineare als auch eine nichtlineare Korrektur vollzieht, wurde versucht, eine nichtlineare Optimierung durchzuführen. Dabei konnte jedoch keine Verbesserung erzielt werden, was mathematisch auch begründet wurde. Durch eine andere Methode, bei der die beiden Modelle, auf denen der Algorithmus [69] basiert, iterativ hintereinander bis zur Konvergenz ausgeführt werden, konnte hingegen eine Verbesserung erzielt werden.

Da Farbkalibrierungsalgorithmen eine gleichförmige Beleuchtung annehmen, wurde untersucht, wie man auch bei ungleichförmiger Beleuchtung eine Kalibrierung durchführen kann.

Für einen farbbasierten Objektlokalisationsalgorithmus [19], welcher auch implementiert wurde, wurde die Abhängigkeit von der Beleuchtung genauer untersucht. Die Detektionsrate des Algorithmus wird zwar von Beleuchtung beeinflusst, jedoch ist Farbkonstanz als Vorbearbeitungsschritt nicht unbedingt notwendig. Die Effizienz des Algorithmus kann durch Farbkonstanz allerdings gesteigert werden, was auch anhand einzelner Experimente bewiesen wurde.

Weiters wurde auf das Thema Hautdetektion eingegangen, wobei hier ebenfalls der Einfluss der Beleuchtung untersucht wurde. Da Hautdetektionsmethoden dafür ausgelegt wurden, dass sie für verschiedene Personen und Hauttypen bei unterschiedlichen Beleuchtungen gute Ergebnisse liefern, werden sie auch nicht von der Beleuchtung beeinflusst.

Zur Farbkonstanz durch Objektlokalisierung wurden mehrere Möglichkeiten (Kalibrierung mit einem Farbtarget, Kalibrierung auf Objekt X, Verbessern von Farbkonstanzalgorithmen durch Zusatzinformation, Erfüllen der Bedingungen einzelner Farbkonstanzalgorithmen, Farbkonstanz durch Hautdetektion) vorgestellt, welche auch größtenteils getestet wurden. Bei der Kalibrierung auf die Farben eines Targets war man am erfolgreichsten. Bei fast allen der vorgeschlagenen Methoden konnte sowohl jenes Objekt, dessen Farbinformationen bei der Farbkorrektur verwendet wurden, als auch nahezu alle anderen Objekte, die sich in der Szene befanden, mit einer höheren Wahrscheinlichkeit vom Objektlokalisationsalgorithmus [19] gefunden werden.

Vor allem jene Methoden, welche die Farben von “natürlichen“ Objekten verwenden, sind für zukünftige Anwendungen durchaus interessant. Dazu zählt auch jene Methode, wo die menschliche Hautfarbe verwendet wird.

LITERATURVERZEICHNIS

- [1] **V. Agarwal, B. R. Abidi, A. Koschan, M. A. Abidi**; "An Overview of Color Constancy Algorithms"; Journal of Pattern Recognition Res. 1(1), (pp. 42-54); 2006.
- [2] **K. Barnard**; "Practical Colour Constancy"; PhD thesis; Simon Fraser University; School of Computing; 1999.
- [3] **K. Barnard, L. Martin, A. Coath, B. Funt**; "A comparison of color constancy algorithms; Part Two. Experiments with Image Data," IEEE Transactions in Image Processing, Vol. 11. No. 9., (pp. 985-996); 2002.
- [4] **K. Barnard, L. Martin, B. Funt**; "Colour by correlation in a three dimensional colour space"; Proceedings of the 6th European Conference on Computer Vision, (pp. 275-289); 2000.
- [5] **B. Beston**; "Colour Constancy Processing in Visual Cortex"; McMaster University, Department of Psychology, San Diego;
http://psych.mcmaster.ca/3j03/Lecture_Notes_files/Colour%202008-3.pdf
(01.07.2009)
- [6] **S. Bianco, G. Ciocca, C. Cusano, R. Schettini**; "Classification-based Color Constancy"; Imaging & Vision Laboratory, DISCo University Milan;
<http://www.scribd.com/doc/13481991/ClassificationBased-Color-Constancy-CusanoVisual08> (01.07.2009)
- [7] **J. Cai, A. Goshtasby, C. Yu**; "Detecting human faces in color images"; Int. Workshop on Multi-Media Database Management Systems; (pp.124-131); 1998.
- [8] **V. Cardei**, "A Neural Network Approach to Colour Constancy"; Ph.D. thesis, Simon Fraser University, Burnaby; 2000.
- [9] **D. Chai, K. N. Ngan**; "Face Segmentation Using Skin-Color Map in Video-phone Applications"; IEEE Trans. Circuits and Systems for Video Technology; Vol. 9, Nr. 4, (pp. 551-564); 1999.

- [10] **P. Chang, J. Krumm**; "Object Recognition with Color Cooccurrence Histograms"; Proc. of IEEE Conf. on Computer Vision and Pattern Recognition; 1999.
- [11] **Q. Chen, H. Wu, M. Yachida**; "Face detection by fuzzy pattern matching"; IEEE 5th Int. Conf. Computer Vision; (pp. 591-596); 1995.
- [12] **M. Collobert, R. Feraud, G. Le Tourneur, D. Bernier, J. E. Vaiallet, Y. Mahieux, D. Collobert**; "Listen: A system for locating and tracking individual speakers"; Proc. of the second International Conference on Automatic Face and Gesture Recognition, Killinton, Vermont, (pp. 283-288); 1996.
- [13] **L. Csink, D. Paulus, U. Ahlrichs, B. Heigl**; "Color Normalization and Object Localization"; 4. Workshop Farbbildverarbeitung, (pp. 49-55); 1998.
- [14] **T. Darrell, G. Gordon, M. Harville, J. Woodfill**; "Integrated Person Tracking Using Stereo, Color, and Pattern Detection"; Proc. Conf. on Computer Vision and Pattern Recognition; Santa Barbara, California; 1998.
- [15] **A. Diplaros, T. Gevers, I. Patras**; "Color-Shape Context for Object Recognition"; IEEE Workshop on Color and Photometric Methods in Computer Vision (In conjunction with ICCV), October 2003.
- [16] **A. Diplaros, T. Gevers, N. Vlassis**; "Skin detection using the EM algorithm with spatial constraints"; IEEE International Conference on Systems, Man and Cybernetics; (pp.3071-3075); 2004.
- [17] **M. Ebner**; "Color Constancy"; Wiley; 2007.
- [18] **S. Ekvall, F. Hoffmann, D. Kragic**; "Object recognition and pose estimation for robotic manipulation using color cooccurrence histograms"; Proc. of the IEEE/RSJ International Conference on Intelligent Robots and Systems, IROS'03, (pp. 1284-1289); 2003.
- [19] **S. Ekvall, D. Kragic**; "Receptive field cooccurrence histograms for object detection"; Proc. of the IEEE/RSJ International Conference on Intelligent Robots and Systems, IROS'05, (pp. 84-89); 2005.

- [20] **A. Elgammal**; "Object Detection and Recognition"; Rutgers University, Dept. of Computer Science;
<http://www.cs.rutgers.edu/~elgammal/classes/cs534/lectures/ObjectRecognition.pdf> (01.07.2009)
- [21] **G. G. Estrada**; Skin Data Set; Institute of Bioinformatics and Systems Biology; HelmholtzZentrum München;
<http://acouchis.helmholtz-muenchen.de/staff/giovani/colour/> (20.09.2010)
- [22] **G. Finlayson, B. Funt, J. Barnard**; "Color constant color indexing"; IEEE Trans. on Pattern Analysis and Machine Intelligence, Vol. 17, (pp. 522-529); 1995.
- [23] **G. D. Finlayson, S. D. Hordley, P. M. Hubel**; "Color by correlation: a simple, unifying framework for color constancy"; IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 23, Nr. 11, (pp. 1209-1221); 2001.
- [24] **M. M. Fleck, D. A. Forsyth, C. Bregler**; "Finding naked people"; Proc. of the 4th European Conference on Computer Vision, Vol. II, (pp. 593-602), 1996.
- [25] **D. A. Forsyth**; "A Novel Algorithm for Color Constancy"; International Journal of Computer Vision; Vol. 5, Nr. 1, (pp. 5-36); 1990.
- [26] **B. Funt, K. Barnard, L. Martin**; "Is Machine Color Constancy Good Enough?"; Proc. of the 5th Eur. Conf. on Computer Vision, (pp. 445-459); 1998.
- [27] **R. Gardner**; "Adobe Photoshop ACR Camera Calibration Basic Adjustments"; Rags Int., Inc.;
<http://www.rags-int-inc.com/PhotoTechStuff/AcrCalibration/> (07.07.2010)
- [28] **B. Geisendrees**; "Methoden zur Erkennung von Hautfarbe in Farbbildern"; Diplomarbeit; Fachbereich 17 – Mathematik und Informatik, Arbeitsgruppe Wissensbasierte Systeme, Universität Paderborn; 2001.
- [29] **S. Gleixner, C. Sieber**; "Farbwahrnehmung"; Student presentation; University Regensburg; Institut for Psychology; Lecture: "General Psychology I";
<http://www.psychologie.uni->

- regens-burg.de/Greenlee/lehre/ws08/Grundstudium/Referat_Farbwahrnehmung_neu.pdf (24.08.2009)
- [30] **G. Healey, D. Slater**; “Using illumination invariant color histogram descriptors for recognition”; Proc. IEEE Conf. on Computer Vision and Pattern Recognition, IEEE Press, (pp. 355-360); 1994.
- [31] **M. Hilbert, M. Till**; “Farben, Farbtheorien, Farbwirkung”; University Bayreuth; <http://did.mat.uni-bayreuth.de/multimedia/ml/ss2002/ch09/fff.ppt> (01.07.2009)
- [32] **M. Hunke, A. Waibel**; “Face locating and tracking for human-computer interaction”; In Proc. of the 28th Asilomar Conf. on Signals, Systems and Computer; (pp. 1277-1281); 1994.
- [33] **Imaging & Media Lab**; Lecture Notes on Image Technology II; University Basel; http://www.abmt.unibas.ch/SKRIPTEN/bildtechnologiem/03_color2.pdf (01.07.2009)
- [34] **S. Jeschke**; “Algorithmen in der Robotik II – Neuronale Netze”; Lecture Notes on Robotic; IITS University Stuttgart; http://linguistix.iits.uni-stuttgart.de/mediawiki/images/e/ea/VI_10_neuronalenetze.pdf (01.07.2009)
- [35] **Y. Kondratyuk**; “Verfolgung und Segmentierung von Händen in Bildsequenzen zur Unterstützung der 3D-Analyse in einem Echtzeit-Videokonferenzsystem”; Diplom thesis; Technical University Berlin; 2003.
- [36] **W. Kunde**; “Wahrnehmung, Farben, Gestalten, Objekte”; Lecture Notes on General Psychology; University Hamburg; Department of Psychology; http://www.uni-hamburg.de/fachbereiche-einrichtungen/fb16/psych_1/Folien_26_April.ppt (24.08.2009)
- [37] **W. Li, M. Soto-Thompson, U. Gustafsson**; “A new image calibration system in digital colposcopy”; Optics Express, Vol. 14, No. 26, (pp. 12887-12901); 2006.

- [38] **B. Li, D. Xu, W. Xiong, S. Feng**; "Illumination-independent descriptors using color moment invariants"; *Optical Engineering*, Vol. 48, Issue 2, (pp. 027005-027005-11); 2009.
- [39] **J. B. MacQueen**; "Some Methods for classification and Analysis of Multivariate Observations"; In *Proc. of 5th Berkeley Symposium on Mathematical Statistics and Probability*, University of California Press, (pp. 1:281-297); 1967.
- [40] **H. S. Malvar, L.-W. He, R. Cutler**; "High-Quality Linear Interpolation for Demosaicing of Bayer-Patterned Color Images"; *Proc. of IEEE Int. Conf. on Acoustics, Speech and Signal Processing (ICASSP)*, Vol. 3., Montreal, Canada, (pp. 485-488); 2004.
- [41] **J. Michel**; "*Farbkalibrierung mittels linearer Transformation*"; Student research paper; University Koblenz-Landau; 2004.
- [42] **F. Mindru, T. Moons, L. Van Gool**; "Color-based moment Invariants for Viewpoint and Illumination independent Recognition of planar Color Patterns"; *International Conference on Advances in Pattern Recognition*, (pp. 113-122); 1998.
- [43] **Mustafa UCAK**; "Face & eye detection"; MATLAB Central / file exchange; <http://www.mathworks.com/matlabcentral/fileexchange/13716> (2007)
- [44] **T. A. Mysliwiec**; "Fingermouse: A Freehand computer pointing interface"; Technical report VISLab-94-01; University of Illinois at Chicago; 1994.
- [45] **S. K. Nayar, R. M. Bolle**; "Reflectance Based Object Recognition"; *Int'l J. Computer Vision*, Vol. 17, No. 3, (pp. 219-240); 1996.
- [46] **L. D. Nguyen**; "Hautfarbenadaption und Handverfolgung"; Diplomarbeit; Institut für Prozessrechentechnik, Automation und Robotik; Universität Karlsruhe; 2001.
- [47] **A. Panning**; "Extrahierung und Verfolgung von modellbasierten Gesichtsmerkmalen in Stereo-Farbbildsequenzen für medizinische Zwecke"; Diploma thesis, Otto-von-Guericke University of Magdeburg; 2006.

- [48] **Y. Raja, S. J. McKenna, S. Gong**; "Tracking and segmenting people in varying lighting conditions using colour"; IEEE International Conference on Face & Gesture Recognition; Japan; 1998.
- [49] **N. Rasiwasia**; "Color Space for Skin Detection – A Review"; Fondazione Graphitech, University of Trento, Italy;
<http://www.pptsearch.net/download.php?fid=465714> (20.09.2010)
- [50] **J. Rehg**; "Computational Perception"; CS 7636 Computational Perception Course (Lecture 1-5); Institute of Technology; Georgia; 2003.
- [51] **M. Rettenbacher**; "Radiometrische Kalibrierung"; Seminar/Project Image Analysis; Technical University Graz; 2009.
- [52] **E. Roullot**; "A Unifying Framework for Color Image Calibration"; Proc. of IWS-SIP, (pp. 97-100), Bratislava; 2008.
- [53] **D. Saxe, R. Foulds**; "Towards robust skin identification in video images"; Proc. of the second International Conference on Automatic Face and Gesture Recognition, Killinton, Vermont, (pp. 379-384); 1996.
- [54] **K. Simon**; "Farbe im Digitalen Publizieren: Konzepte der digitalen Farbwiedergabe für Office, Design und Software"; Springer-Verlag; 2007.
- [55] **D. Slater, G. Healey**; "Combining Color and Geometric Information for the Illumination Invariant Recognition of 3-D Objects"; Proc. of the Fifth International Conference on Computer Vision, (pp. 563-568); 1995.
- [56] **K. Sobottka, I. Pitas**; "Face localization and facial feature extraction based on shape and color information"; Proc. of the IEEE International Conference on Image Processing, Vol. 3, Lausanne, Switzerland, (pp. 236-241); 1996.
- [57] **K. Sobottka, I. Pitas**; "Segmentation and tracking of faces in color images"; Proc. of the second International Conference on Automatic Face and Gesture Recognition, Killinton, Vermont, (pp. 236-241); 1996.
- [58] **M. Störring**; "Colour"; Lecture notes on Introduction to Computer Vision; Aalborg University, Laboratory of Computer Vision and Media Technology;

- http://www.cvmt.dk/education/teaching/f05/ImageAnalysis/Colour/colour_vision.ppt (24.08.2009)
- [59] **M. J. Swain, D. H. Ballard**; “Color Indexing”; International Journal of Computer Vision; Vol. 7, Nr. 1, (pp. 11-32); 1991.
- [60] **J-C. Terrillon, M. David, S. Akamatsu**; “Automatic Detection of Human Faces in Natural Scene Images by Use of a Skin Color Model and of Invariant Moments”; Proc. 3rd Int. Conf. on Face and Gesture Recognition; Nara, Japan; 1998.
- [61] **The Centre for Systems Science**; Simon Fraser University; “*Computational Vision Lab Research*”; <http://www.cs.sfu.ca/~colour/> (01.07.2009)
- [62] **J. Vergés Lahí**; “Color Constancy and Image Segmentation Techniques for Applications to Mobile Robotics”; PhD thesis; University Politecnica de Catalunya; 2005.
- [63] **V. Vezhnevets, V. Sazonov, A. Andreeva**; “A survey on pixel-based skin color detection techniques”; GRAPHICON03, (pp. 85-92); 2003.
- [64] **V. Vilaplana, F. Marqués, P. Salembier, L. Garrido**; “Region-based segmentation and tracking of human faces”; Proc. of the Ninth European Signal Processing Conference EUSIPCO-98, Vol. 1, (pp. 311-315); 1998.
- [65] **P. Wagner**; “Farbmanagement”; Fa. ScanDig; <http://www.filmscanner.info/Farbmanagement.html> (07.07.2010)
- [66] **J. G. Wang, E. Sung**; “Frontal-view face detection and facial feature extraction using color and morphological operators”; Pattern recognition letters, Vol. 20, Nr. 10, (pp. 1053-1068); 1999.
- [67] **I. Weatherburn**; “DxO Optics Pro Elite 5.3.3 – A Review - 26.03.2009”; <http://ianweatherburn.blogspot.com/2009/03/dxo-optics-pro-elite-533-review.html> (07.07.2010)
- [68] **J.v.d. Weijer, C. Schmid**; “Using High-Level Visual Information for Color Constancy”; University Granada; <http://cyberpc.ugr.es/RT/ficheros/uab/FEB08-cvc2.pdf> (01.07.2009)

- [69] **S. Wolf**; “Color Correction Matrix for Digital Still and Video Imaging Systems”; NTIA Technical Memorandum TM-04-406; 2003.
- [70] **G. Wyszecki, W. S. Stiles**; “*Color Science: Concepts and Methods, Quantitative Data and Formulae*”; Wiley-Interscience; 2nd ed; 2000.
- [71] **M-H. Yang, N. Ahuja**; “Detecting human faces in color images“; Proc. of the International Conference on Image Processing, Vol. 1, Chicago, IL; (pp. 127-139); 1998.
- [72] **J. Yang, W. Lu, A. Waibel**; “Skin-Color Modeling and Adaption“; Technischer Bericht CMU-146, Carnegie Mellon University, Pittsburgh; 1997.
- [73] **Z. Zhang**; “A Flexible New Technique for Camera Calibration“; IEEE Trans. on Pattern Analysis and Machine Intelligence, Vol. 22, Nr. 11, (pp. 1330-1334); 2000.

ANHANG

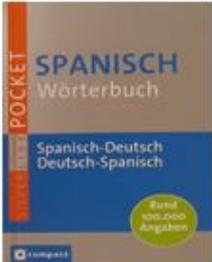
1	<p>Bensdorp KAKAO</p> 	2	<p>MAIZENA Reine Maisstärke</p> 
3	<p>Balea BATH Arzt Seife (SENSITIV)</p> 	4	<p>adria makrelen salat</p> 
5	<p>Compact Spanisch Wörterbuch</p> 	6	<p>BAD ISCHLER Kristallsalz mit Jod und Fluor</p> 
7	<p>Kelly MICROWAVE POPCORN</p> 	8	<p>Frank's MICROWAVE POPCORN</p> 
9	<p>SPAR PASTA Lasagne</p> 	10	<p>THORS LABS Lab Snacks</p> 

Tabelle A.1: "Natürliche" Objekte welche mehrere größere homogen farbige Flächen enthalten. Diese Objekte dienen sowohl zum Kalibrieren als auch für die Objektlokalisierung.

11	<p>Milka Pralines</p> 	12	<p>De Beukelaer Mikado Milkschokolade</p> 
13	<p>Harrest Basket Kartoffelpüree</p> 	14	<p>Pepino Trinkkakaomischung</p> 
15	<p>Dr. Oetker Flana Pudding Schokolade</p> 	16	<p>Bonduelle GOLDMAIS</p> 
17	<p>Rauch happy day Tomate</p> 	18	<p>vitafit Apfelsaft naturtrüb</p> 
19	<p>Nestlé After Eight (LIMITED EDITION)</p> 	20	<p>MILFORD Brombeere-Himbeere Tee</p> 

Tabelle A.2: "Natürliche" mehrfarbige Objekte die für die Objektllokalisierung verwendet wurden.

	GOLD DISH Fruchtcocktail		SPAR Fünfrucht COCKTAIL
21		22	
	Sweet Valley Orangensaft		RAUCH Ice Tea lemon
23		24	

Tabelle A.3: "Natürliche" mehrfarbige Objekte die für die Objektlokalisierung verwendet wurden.

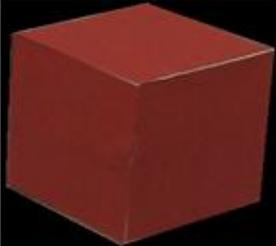
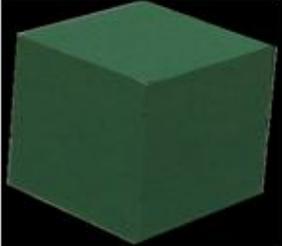
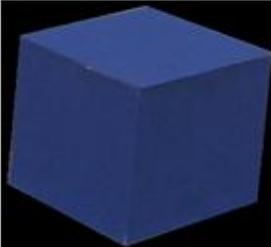
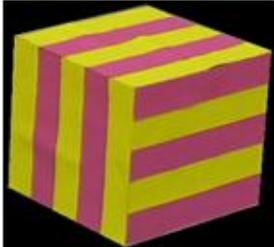
	roter Würfel		grüner Würfel
25		26	
	blauer Würfel		gelb/magenta Würfel
27		28	

Tabelle A.4: Künstliche ein- und zweifarbige Objekte die sowohl zum Kalibrieren als auch für die Objektlokalisierung verwendet wurden.

1)	Objekt 01	R	G	B
	dunkel blau	24	27	26
	weiß	129	154	94
	rot	109	55	32
2)	Objekt 02	R	G	B
	weiß	139	171	106
	gelb	134	148	49
	orange	104	64	33
	rot	96	49	31
3)	Objekt 03	R	G	B
	hell blau	66	98	75
	rot	77	45	30
	türkis	49	81	56
	weiß	129	156	95
4)	Objekt 04	R	G	B
	rot	83	40	27
	weiß	129	157	95
	gelb	122	135	47
	grün	46	58	40
5)	Objekt 05	R	G	B
	orange	112	72	36
	silber	66	77	49
	blau	29	47	51
	grün	70	96	37
6)	Objekt 06	R	G	B
	rot	86	45	30
	dunkel gelb	125	127	59
7)	Objekt 07	R	G	B
	rot	89	42	28
	gelb	127	122	44
	blau	23	27	35
	weiß	135	166	102
8)	Objekt 08	R	G	B
	blau	21	25	29
	rot	85	42	28
	weiß	123	155	93
	gelb	120	139	49
9)	Objekt 09	R	G	B
	dunkel grün	26	44	25
	dunkel gelb	110	105	40
	weiß	128	154	93
	rot	86	41	28
10)	Objekt 10	R	G	B
	rot	103	49	32
	gelb	164	176	62
	grün	46	78	36

Tabelle A.5: Referenzwerte der Objekte 1 bis 10 (Ermittelt mit der uEye Kamera vom Typ UI-1220C bei Leuchtstoffröhrenbeleuchtung (Philips Master TL5 HO 49W/840).

11)	Objekt 25	R	G	B
	rot	48	32	24
12)	Objekt 26	R	G	B
	grün	28	41	27
13)	Objekt 27	R	G	B
	blau	26	33	32
14)	Objekt 28	R	G	B
	magenta	76	48	39
	gelb	131	135	48

Tabelle A.6: Referenzwerte der Objekte 25 bis 28 (Ermittelt mit der uEye Kamera vom Typ UI-1220C bei Leuchtstoffröhrenbeleuchtung (Philips Master TL5 HO 49W/840).

	R	G	B
Mu01	44	44	29
Mu02	107	97	57
Mu03	46	67	56
Mu04	42	60	31
Mu05	64	80	70
Mu06	72	139	84
Mu07	118	85	39
Mu08	35	48	57
Mu09	103	62	42
Mu10	34	35	33
Mu11	92	141	53
Mu12	140	134	50
Mu13	24	32	41
Mu14	46	86	40
Mu15	82	45	30
Mu16	163	178	60
Mu17	96	66	59
Mu18	38	72	65
Mu19	186	243	149
Mu20	133	172	109
Mu21	90	116	75
Mu22	58	72	48
Mu23	37	45	32
Mu24	24	27	21

Tabelle A.7: Referenzwerte des Munselltargets (Ermittelt mit der uEye Kamera vom Typ UI-1220C bei Leuchtstoffröhrenbeleuchtung (Philips Master TL5 HO 49W/840)).