

VIS

Bachelorarbeit Nr. 54

# **Beleuchtungskompensation in Videobildpaaren und Videosequenzen**

Roberto Fontanarosa

<b>Studiengang:</b>	Informatik
<b>Prüfer/in:</b>	Prof. Dr. -Ing Andrés Bruhn
<b>Betreuer/in:</b>	Prof. Dr. -Ing Andrés Bruhn
<b>Beginn am:</b>	22. Mai 2013
<b>Beendet am:</b>	11. November 2013
<b>CR-Nummer:</b>	I.4.3, I.4.8, G.1.2



## **Kurzfassung**

In dieser Arbeit wird die Helligkeitskompensation von Bildern einer Bildfolge berechnet, um eine bessere Schätzung des Optischen Flusses zu ermöglichen. Die Suche nach dem Optischen Fluss ist eines der zentralen Themen des Maschinensehens und besonders wichtig, weil man damit Objekte in Bildern entdecken und verfolgen kann. Insgesamt werden drei verschiedene Methoden vorgestellt mit denen man die Helligkeitskompensation bei Bildpaaren aus einer Bildfolge durchführen kann. Die Verfahren werden mit Hilfe eines synthetischen Datensatzes (KITTI-Benchmark, Bildsequenzen aus dem Automotive Bereich [GLU12]) ausgewertet und verglichen.



# Inhaltsverzeichnis

<b>1</b>	<b>Einleitung</b>	<b>7</b>
1.1	Motivation . . . . .	7
1.2	Ziel der Arbeit . . . . .	7
1.3	Aufgabenstellung . . . . .	9
<b>2</b>	<b>Grundlagen</b>	<b>11</b>
2.1	Optischer Fluss . . . . .	11
2.2	Ausgangsdaten . . . . .	14
<b>3</b>	<b>Statistische Verfahren</b>	<b>19</b>
3.1	Varianz . . . . .	20
3.2	Ergebnis mit Varianz . . . . .	21
3.3	Totalvariation . . . . .	24
3.4	Ergebnis mit Totalvariation . . . . .	26
3.5	Totalvariation mit quadriertem Gradienten . . . . .	27
3.6	Ergebnis mit Totalvariation mit quadriertem Gradienten . . . . .	29
<b>4</b>	<b>Histogrammtransformation</b>	<b>31</b>
4.1	Histogramm . . . . .	31
4.2	Histogrammegalierung . . . . .	35
4.3	Ergebnisse zu Histogrammegalierung . . . . .	36
4.4	Histogrammspezifikation . . . . .	40
4.5	Ergebnisse zu Histogrammspezifikation . . . . .	41
<b>5</b>	<b>Histogrammbasierte Regression</b>	<b>43</b>
5.1	Rechenweg und Erklärung . . . . .	43
5.2	Ergebnisse der histogrammbasierten Egalisierung . . . . .	47
5.3	Vergleich der Verfahren . . . . .	54
<b>6</b>	<b>Zusammenfassung und Ausblick</b>	<b>55</b>
6.1	Zusammenfassung . . . . .	55
6.2	Ausblick . . . . .	56
	<b>Literaturverzeichnis</b>	<b>57</b>



# 1 Einleitung

Eines der zentralen Probleme des Maschinensehens ist das Bestimmen von Bewegungen zwischen zwei oder mehreren Bildern. Gesucht wird in diesem Zusammenhang der Optische Fluss. Dabei handelt es sich um ein Vektorfeld, das die Bewegung der einzelnen Pixel zwischen zwei Bildern einer Bildfolge angibt. Die ersten Ansätze zur Berechnung des Optischen Flusses stammen aus den 80er Jahren (Horn und Schunck 1981, Lucas und Kanade 1981 [BWS05]). Die Verfahren zur Bestimmung des Optischen Flusses, mit denen es möglich sein soll, einander zugehörige Pixel zwischen zwei Bildern zu identifizieren, basieren auf Konstanzannahmen.

## 1.1 Motivation

Eine typische Konstanzannahme ist, dass der Farb- bzw. Grauwert von zugehörigen Pixeln einer Bildfolge konstant bleibt oder sich kaum verändert. In der Praxis ist das allerdings nur selten der Fall. Aufgrund von Schatten, Blickwinkeländerungen, der Bewegung der Sonne und vielen weiteren Gründen, kommt es häufig zur Helligkeitsänderung in Bildfolgen. Eine schwierige Aufgabe ist es deshalb auch, Gesichter, die im Freien aufgenommen wurden, später wieder zu erkennen [HMB<sup>+</sup>08]. Das Hauptanwendungsgebiet dieser Arbeit ist jedoch nicht die Gesichtserkennung unter unkontrolliertem Licht [VWB<sup>+</sup>12], sondern vielmehr die Helligkeitskompensation bei Szenen, die im Freien aufgenommen wurden.

## 1.2 Ziel der Arbeit

Das Ziel dieser Arbeit ist, die Helligkeit von Grauwertbildern in Bildfolgen zu kompensieren, um eine bessere Berechnung des Optischen Flusses zu ermöglichen.

Selbst einfache Kameras, wie Webcams oder Kameras in Smartphones, korrigieren die Helligkeit nichtlinear nach, sodass zugehörige Objekte in aufeinander folgenden Bildern aufgrund des Grau- oder Farbwertes kaum noch zugeordnet werden können. Die so entstandenen Helligkeitsänderungen führen bei der Berechnung des Optischen Flusses zu inakkuraten Ergebnissen. Im Gegensatz zu den lokalen Korrekturverfahren in [PDKK04, RLB99], konzentrieren wir uns in dieser Arbeit ausschließlich auf Verfahren zur Kompensation globaler Helligkeitsänderungen. Dabei haben wir jedoch ebenfalls das Problem, dass wir ohne Kenntnis der Pixelkorrespondenzen (deren Schätzung wir gerade verbessern wollen) auf globale

ortsunabhängige Bildinformationen zurückgreifen müssen (mittlerer Grauwert, Varianz, Kontrast, Histogramm, etc.).

In dieser Arbeit werden drei verschiedene Verfahren zur Helligkeitskompensation vorgestellt. Eines dieser Verfahren arbeitet mit statistischen Größen, wie dem mittleren Grauwert, der Varianz und der Totalvariation. Dabei wird angenommen, dass diese statistischen Größen in zwei Bildern einer Bildfolge gleich bleiben. Ein weiteres Verfahren arbeitet mit Histogrammtransformationen, wie der Histogrammegalierung und der Histogrammspezifikation. Beim letzten der drei Verfahren handelt es sich um eine histogrammbasierte Regression.

Die Evaluation der Ergebnisse wird anhand von Experimenten mit synthetischen Datensätzen sowie mit Bildfolgen aus dem Automotive-Bereich erfolgen (KITTI-Benchmark [GLU12]). Dabei werden die verschiedenen, implementierten Verfahren ausgewertet und verglichen, indem die durchschnittliche Differenz der Grauwerte zwischen zwei Bildern einer Bildfolge ermittelt wird. In Abbildung 1.1 und 1.2 sind zwei Bilder eines Bildpaares aus dem KITTI-Benchmark abgebildet, die aus einem fahrenden Auto aufgenommen wurden. Links im Bild kann man den Unterschied zwischen den beiden Bildern erkennen.



**Abbildung 1.1:** Das erste Bild eines Bildpaares aus dem KITTI-Benchmark



**Abbildung 1.2:** Das zweite Bild eines Bildpaares aus dem KITTI-Benchmark. Zugehöriges Bild zu Abbildung 1.1.



## 1.3 Aufgabenstellung

Das Programm zur Berechnung der Helligkeitskompensation wurde in der Programmiersprache *C* geschrieben. Zur Berechnung und Anwendung verschiedener Methoden für die Helligkeitskompensation müssen zuerst die Grauwerte der Pixel, von den einzelnen Bildern, eingelesen werden. Zur Speicherung dieser Werte wird ein zweidimensionales Integer-Array verwendet.

Das Integer-Array, das die Grauwerte des ersten Bildes  $I_G$  enthält, wird im Verlauf dieser Arbeit  $G$  genannt. Das Array für das zweite Bild  $I_H$  wird mit  $H$  abgekürzt. Sowohl  $G$  als auch  $H$  haben die gleichen Dimensionen und bestehen aus  $n_x$  Zeilen und  $n_y$  Spalten.  $N$  sei dabei das Produkt aus Anzahl Zeilen und Spalten:  $N = n_x * n_y$

Das Ziel ist es, eine möglichst gute Abbildung  $f : G \rightarrow F$  zu finden, so dass die Grauwerte in  $F$  möglichst nah an denen von  $H$  sind. Da die Bilder im Normalfall aus verschiedenen Winkeln und Positionen gemacht wurden, lassen sich zwei Pixel,  $G_{i,j}$  und  $H_{i,j}$ , nicht direkt vergleichen. Erst nachdem die Pixel von  $F$  mittels Optischem Flusses zurücktransformiert werden, kann die Differenz zwischen allen Grauwerten  $H_{i,j}$  und  $F_{i,j}$ , wobei  $G_{i,j}$ , bzw.  $H_{i,j}$  oder  $F_{i,j}$  der Grauwert an der Stelle  $i, j$  sein soll, berechnet werden. Somit soll nach der Rücktransformation von  $F$

$$(1.1) \quad \sum_{i=1}^{n_x} \sum_{j=1}^{n_y} |H_{i,j} - F_{i,j}|$$

minimal sein.

## Gliederung

Wir beginnen in Kapitel 2 zunächst mit der Erklärung des Optischen Flusses. Die verwendeten Ausgangsdaten werden in diesem Kapitel ebenfalls vorgestellt und erklärt. Im nächsten Kapitel werden drei Verfahren vorgestellt, die mit statistischen Größen arbeiten. Alle drei Verfahren arbeiten mit dem mittleren Grauwert. Beim ersten Verfahren wird zusätzlich die Varianz, beim zweiten die Totalvariation und beim dritten die Totalvariation mit quadriertem Gradienten benutzt. Im Kapitel zu Histogrammtransformationen wird erklärt was ein Histogramm ist, und es werden zwei Histogrammtransformationen, die Histogrammegalierung und die Histogrammspezifikation, vorgestellt. In Kapitel 5 wird das letzte Verfahren, die histogrammbasierte Regression vorgestellt. Dabei wird genauer auf den Rechenweg eingegangen und erklärt wie sich das Verfahren auf beliebig viele Parameter erweitern lässt. Im letzten Kapitel wird die Arbeit zusammengefasst und die verschiedenen Ergebnisse miteinander verglichen. Am Ende werden mögliche Erweiterungen dieser Arbeit aufgezeigt.



## 2 Grundlagen

### 2.1 Optischer Fluss

Existiert Bewegung zwischen zwei Bildern einer Bildfolge, so ist man beim Maschinensehen nicht selten am Optischen Fluss interessiert. Vor allem bei Bildern von Szenen, in denen Bewegung stattfindet, die in einem kurzen zeitlichen Abstand gemacht werden, ist der Optische Fluss von Interesse, weil man damit Objekte in den Bildern erkennen kann. Da sich der Optische Fluss nicht eindeutig berechnen lässt, kann man ihn nur durch Schätzung erhalten.


Beim Optischen Fluss handelt es sich um ein Vektorfeld, das die Bewegung der einzelnen Pixel von einem Bild eines Bildpaares zum nächsten Bild des Bildpaares angibt. Ein Vektor dieses Vektorfeldes gibt sowohl die Richtung als auch die Länge, also wie stark sich etwas in eine Richtung bewegt, an [BSL<sup>+</sup>11].



**Abbildung 2.1:** Zwei Bilder einer Bildfolge, die zu aufeinander folgenden Zeitpunkten aufgenommen wurden. [GLU12]

In Abbildung 2.2 ist der Optische Fluss zu den Bildern aus Abbildung 2.1 farblich dargestellt. Der größte Teil des Bildes ist schwarz, weil dort keine Bewegung stattgefunden hat. An dieser Stelle ist der Hintergrund (Straße, Ampeln, Häuser etc.). Der Wagen im Vordergrund wird in Abbildung 2.2 grün-gelblich dargestellt, was eine Bewegung nach oben (gelb) links

(grün) signalisiert. Die weiteren Flussfelder in dieser Arbeit verwenden die selben Farben, um die Bewegungsrichtung anzugeben.



**Abbildung 2.2:** Der Optische Fluss zu Abbildung 2.1. [Bruo6]

Mit Hilfe dieser Informationen kann man so Bewegungen in einem Bild nachvollziehen. Zusätzlich kann man aber auch ein Bild mit Hilfe des Optischen Flusses rücktransformieren.

Bei der Rücktransformation werden die einzelnen Pixel an die Position vor der Bewegung zurück verschoben. Da es sein kann, dass sich ein Pixel vor der Bewegung zwischen zwei oder mehreren Pixeln befand, muss man die Position des Pixels interpolieren.

Abbildung 2.3 zeigt ein Bildpaar aus einem Datensatz aus dem Automotive Bereich, dem KITTI-Benchmark [GLU12].



**Abbildung 2.3:** Zwei Bilder einer Bildfolge aus dem KITTI-Benchmark

Das nächste Bild (Abbildung 2.4) ist nach der Rücktransformation des unteren Bildes aus Abbildung 2.3 mit Hilfe des Optischen Flusses entstanden. Wie man sehen kann, ist ein großer Teil des Bildes schwarz. An diesen Stellen ist der Optische Fluss nicht bekannt. Die Qualität der verschiedenen Helligkeitskompensationen lassen sich nur dort vergleichen, wo der Optische Fluss bekannt ist.



**Abbildung 2.4:** Das untere Bild aus Abbildung 2.3 nach der Rücktransformation.

## 2.2 Ausgangsdaten

### 2.2.1 KITTI

Bei KITTI-Benchmark [GLU<sub>12</sub>] handelt es sich um Datenbanken aus der realen Welt für verschiedene Bereiche aus der Computer Vision, die in Karlsruhe erstellt wurden. Der Name KITTI setzt sich aus den beiden Sponsoren KIT (Karlsruhe Institute of Technology) und TTI-C (Toyota Technological Institute at Chicago) zusammen. Die Bereiche, die abgedeckt werden, sind: Stereo, Optischer Fluss, visuelle Odometrie, 3D Objekt Erkennung und 3D Tracking. Um die Datenbanken für die verschiedenen Bereiche zu erstellen, wurde ein Kombinationskraftwagen mit zwei hochauflösenden Kameras (Farbe und Graustufen) sowie einem Velodyne Laserscanner und einem GPS Ortungssystem ausgestattet, die zur Bestimmung von Ground-Truth benötigt werden. Da der Velodyne Laserscanner für große Entfernungen nicht gut geeignet ist, um Ground-Truth Daten aufzunehmen, ist der Optische Fluss meistens nur in der unteren Bildhälfte bekannt (siehe 2.6).



**Abbildung 2.5:** Der Kombinationskraftwagen, der zur Aufnahme der Daten für KITTI-Benchmark benutzt wurde [GLU<sub>12</sub>].

Die Datensätze werden aufgenommen, während der mit Sensoren ausgestattete Kombinationskraftwagen durch städtische und ländliche Gebiete und auf der Autobahn in Karlsruhe fährt. Durchschnittlich sind 15 Autos und 30 Fußgänger auf jedem Bild zu sehen. Für diese Bachelorarbeit wurde die Datenbank aus dem Bereich Optischer Fluss verwendet, die aus 194 Trainingsbildpaaren und 195 Testbildpaaren im *.png* Format besteht. Zusätzlich ist der Optische Fluss zu den Bildpaaren im *.jpg* Format gegeben, der zur Berechnung der Rücktransformation allerdings ins *.flo* Format konvertiert werden muss. In Abbildung 2.6 ist der Optische Fluss zum Bildpaar aus Abbildung 2.7 zu sehen.




Abbildung 2.6: Visualisierung des Optischen Flusses.



Abbildung 2.7: Das Bildpaar zu dem der Optische Fluss aus Abbildung 2.6 gehört.

Konvertiert man den Optischen Fluss, der als *.jpg* Datei von der KITTI-Benchmark bereitgestellt wird, in eine *.flo* Datei, so lässt sich dieser leicht in ein C Programm einlesen. Zu jedem Pixel aus dem ersten Bild des Bildpaares ist seine Bewegung in x- und y-Richtung gegeben,

sofern der Optische Fluss für diesen Pixel vorhanden ist. Sie gibt an, wie weit sich der Pixel in die entsprechenden Richtungen bewegt. Mit dieser Information lassen sich die Pixel aus dem zweiten Bild des Bildpaares in die entsprechend andere Richtung zurücktransformieren. Es kann allerdings passieren, dass sich Pixel nach der Transformation zwischen zwei oder vier Pixeln befinden könnten. Dort muss man die neue Position des Pixels interpolieren.

### 2.2.2 PGM

Das Format der Bilder, die für diese Bachelorarbeit benutzt wurden, ist das Format *.pgm*. Die Abkürzung *pgm* steht für "portable graymap". Das Format *.pgm* gehört zusammen mit *.pbm* ("portable bitmap") und *.ppm* ("portable pixmap") zur PNM ("portable anymap") Familie. PGM-Dateien eignen sich zur Speicherung von Graubildern, weil sie sich einfach ein- und auslesen lassen.

Der Dateikopf von PNM Dateien ist immer gleich aufgebaut. Er besteht aus den folgenden sechs Komponenten:

1. **Magischer Wert** - Der magische Wert gibt an, um welches PNM Format es sich handelt.
2. **Leerraum** - Kann zum Kommentieren genutzt werden.
3. **Breite des Bildes** - Die Breite des Bildes, als Dezimal in ASCII kodiert.
4. **Leerraum** - Kann zum Kommentieren genutzt werden.
5. **Höhe des Bildes** - Die Höhe des Bildes, als Dezimal in ASCII kodiert.
6. **Leerraum** - Kann zum Kommentieren genutzt werden.

Bei Grau- und Farbbildern kommen noch zwei weitere Komponenten hinzu:

7. **Maximaler Grauwert** - Der Maximale Grauwert des Bildes, als Dezimal in ASCII kodiert. Zwischen 0 (schwarz) und 255 (weiß) bei Grauwertbildern.
8. **Leerraum**

Magische Nummer	Dateityp	Kodierung
P1	Portable Bitmap	ASCII
P2	Portable Graymap	ASCII
P3	Portable Pixmap	ASCII
P4	Portable Bitmap	Binär
P5	Portable Graymap	Binär
P6	Portable Bitmap	Binär

**Tabelle 2.1:** Die magische Nummer, der zugehörige Dateityp und ihre Kodierung



Im Rahmen dieser Bachelorarbeit wurden ausschließlich binärkodierte Grauwertbilder verwendet. Aus diesem Grund steht im Dateikopf jedes Bildes „P5“. Die Grauwerte der einzelnen Pixel bei *.pgm*-Dateien werden zeilenweise abgespeichert. Sie stehen nach dem Dateikopf und ihr Wertebereich liegt zwischen 0 und 255. Der Beginn eines Kommentars wird mit # eingeleitet.

Bei folgendem Beispiel handelt es sich um ein selbst erzeugtes Grauwertbild. Hier wurde das Format P2 zur besseren Lesbarkeit benutzt (Grauwerte werden als ASCII gespeichert):

```
P2
bild.pgm
24 7
7
00000000000000000000000000000000
077700007700040000077700
070070007700040000070070
077700007700040000070070
070070007700040000070070
077700007700044440077700
00000000000000000000000000000000
```

Es handelt sich also um ein Grauwertbild der Größe  $24 \times 7$  mit 8 Graustufen. Das Bild ist in Abbildung 2.8 zu sehen.



**Abbildung 2.8:** Das Bild, das durch obige Beschreibung entsteht.



### 3 Statistische Verfahren

Das Finden einer möglichst guten Funktion  $f$ , die Gleichung 1.1 optimiert, kann sich als schwierig erweisen. Es hat sich gezeigt, dass es ein guter Ansatz sein kann,  $f$  als lineare Funktion zu wählen. Sie hat somit die Form  $f(x) = ax + b, x \in G$ , womit mindestens zwei linear unabhängige Gleichungen benötigt werden, um die beiden Variablen  $a$  und  $b$  zu berechnen. Für die folgenden Verfahren wird eine der Informationen immer der Erwartungswert sein, was in unserem Fall nichts anderes als das arithmetische Mittel aller Grauwerte eines Bildes ist. Weiter nennen wir  $F$  das Integer-Array, das entsteht, wenn alle Grauwerte in  $G$  mit der Funktionen  $f$  abgebildet werden. Da  $G$  und  $H$  die Grauwerte zweier aufeinander folgender Bilder einer Bildsequenz beinhalten, können wir annehmen, dass der durchschnittliche Grauwert von  $H$  und  $F$  gleich ist.

Der durchschnittliche Grauwert für  $G$  und  $H$  lässt sich folgendermaßen berechnen:

$$(3.1) \quad \bar{G} = \frac{1}{N} \sum_{i=1}^{n_x} \sum_{j=1}^{n_y} G_{i,j}$$

$$(3.2) \quad \bar{H} = \frac{1}{N} \sum_{i=1}^{n_x} \sum_{j=1}^{n_y} H_{i,j}$$

$\bar{G}$  und  $\bar{H}$  seien der durchschnittliche Grauwert der Bilder von  $G$  und  $H$ . Da wir vorausgesetzt haben, dass der durchschnittliche Grauwert nach der Transformation von  $G$  mit  $f$  gleich ist wie der von  $H$  folgt:

$$\begin{aligned} \bar{F} &:= \frac{1}{N} \sum_{i=1}^{n_x} \sum_{j=1}^{n_y} (a * G_{i,j} + b) \stackrel{!}{=} \bar{H} \\ &\Leftrightarrow a * \underbrace{\frac{1}{N} \sum_{i=1}^{n_x} \sum_{j=1}^{n_y} G_{i,j}}_{=\bar{G}, \text{ siehe (3.1)}} + \frac{1}{N} \sum_{i=1}^{n_x} \sum_{j=1}^{n_y} b \stackrel{!}{=} \bar{H} \\ &\Leftrightarrow a * \bar{G} + \frac{N}{N} * b \stackrel{!}{=} \bar{H} \end{aligned}$$

$$(3.3) \quad \Rightarrow a * \bar{G} + b = \bar{H}$$

### 3.1 Varianz

Zur Bestimmung der Parameter  $a$  und  $b$  wird zusätzlich zu Gleichung 3.3 eine weitere Gleichung benötigt. Eine Möglichkeit diese zu bekommen, ist es, anzunehmen, dass nicht nur der durchschnittliche Grauwert in  $H$  und  $F$ , sondern auch noch die Varianz  $\sigma^2$  gleich ist. Sie gibt an, wie sehr Variablen vom Erwartungswert abweichen. In unserem Fall gibt die Varianz also an, wie groß die durchschnittliche Differenz eines Pixels zum durchschnittlichen Grauwert ist. Die Varianz von  $G$  lässt sich folgendermaßen berechnen.

$$(3.4) \quad \sigma_G^2 = \sum_{i=1}^{n_x} \sum_{j=1}^{n_y} (G_{i,j} - \bar{G})^2$$

Für die Varianz von  $H$  gilt dann äquivalent:

$$(3.5) \quad \sigma_H^2 = \sum_{i=1}^{n_x} \sum_{j=1}^{n_y} (H_{i,j} - \bar{H})^2$$

Setzt man nun die Varianz für  $F$  und  $H$  gleich, so erhält man für die Varianz  $\sigma_F^2$  in  $F$ :

$$\begin{aligned} \sigma_F^2 &:= \sum_{i=1}^{n_x} \sum_{j=1}^{n_y} (F_{i,j} - \bar{F})^2 \\ &= \sum_{i=1}^{n_x} \sum_{j=1}^{n_y} (a * G_{i,j} + b - (a * \bar{G} + b))^2 \\ &= \sum_{i=1}^{n_x} \sum_{j=1}^{n_y} (a * G_{i,j} - a * \bar{G} + b - b)^2 \\ &= a * \underbrace{\sum_{i=1}^{n_x} \sum_{j=1}^{n_y} (G_{i,j} - \bar{G})^2}_{=\sigma_G^2, \text{ siehe (3.4)}} \\ &= a * \sigma_G^2 \end{aligned}$$

Da  $\sigma_F^2 = \sigma_H^2$ , gilt:

$$(3.6) \quad a * \sigma_G^2 = \sigma_H^2$$

Wenn man die Gleichungen 3.3 und 3.6 nach  $a$  und  $b$  auflöst, erhält man:


$$(3.7) \quad a = \frac{\sigma_H^2}{\sigma_G^2}$$

$$b = \bar{H} - \frac{\sigma_H^2}{\sigma_G^2} * \bar{G}$$

### 3.2 Ergebnis mit Varianz

Wenn man zur Bestimmung von  $a$  und  $b$  die Ansätze nimmt, dass der durchschnittliche Grauwert und die Varianz bei  $H$  und  $F$  gleich sind, so folgen für  $a$  und  $b$  die Gleichungen 3.7.  $F$  lässt sich nun problemlos durch Anwenden der Funktion  $f$  auf  $G$  bestimmen.


Wenn man die durchschnittliche Differenz aller Pixel von zwei Bildern  $I_G$  und  $I_H$  einer Bildfolge berechnet, ohne vorher jegliche Helligkeitskompensationen auf  $G$  anzuwenden, so erhält man, nach Rücktransformation von  $H$  mittels Optischem Fluss folgenden Graphen (3.1). Auf der  $x$ -Achse sind die Bildpaare aufgelistet, während auf der  $y$ -Achse der durchschnittliche Fehler aufgetragen ist.



**Abbildung 3.1:** Fehler zwischen  $G$  und  $H$  nach Rücktransformation. Keine Helligkeitskompensation angewendet.

Die folgende Grafik zeigt den direkten Vergleich zwischen den Ergebnissen mit und ohne Helligkeitskompensation. Die roten Punkte signalisieren die durchschnittliche Differenz zweier Bilder ohne Anwendung jeglicher Helligkeitskompensationen. Die grünen Balken zeigen die Differenz nach Anwendung der oben definierten Funktionen  $f$ .


Rote Punkte, die mit einem „+“ dargestellt sind, zeigen, dass die Helligkeitskompensation bei diesem Bildpaar zu einer Verbesserung des durchschnittlichen Fehlers führen. Alle roten Punkte, die mit einem „-“ dargestellt sind, signalisieren eine Verschlechterung gegenüber keiner Helligkeitskompensation.



**Abbildung 3.2:** Vergleich vor und nach Helligkeitskompensation mittels Varianz und Erwartungswert

Wie man sehen kann, ist eine deutliche Verbesserung vor allem dort zu sehen, wo der Fehler vor der Kompensation hoch war. Bei kleinen Fehlern führt diese Helligkeitskompensation sogar zu Verschlechterungen. Grund dafür ist der Optische Fluss. Kennt man den Optischen Fluss an vielen Stellen, so lassen sich mehr Pixel miteinander vergleichen. Das führt dazu, dass der Fehler ohne Anwendung der Helligkeitskompensation größer wird. Nach Anwendung der Helligkeitskompensation, die das ganze Bild zur Berechnung beachtet, ist der Fehler geringer, bei denen sich mehr Pixel vergleichen lassen. Eine Auswertung ist bei solchen Bildern aussagekräftiger, als bei Bildern, bei denen der Optische Fluss nur an wenigen Stellen bekannt ist. Wirft man einen Blick auf Abbildung 2.4, so sieht man, dass zur Berechnung des Fehlers nur der untere Teil des Bildes eine Rolle spielt.

Um einen weiteren und eventuell besseren Eindruck zu bekommen wie gut ein Verfahren ist, wurde die Helligkeitskompensation auf ein selbst erzeugtes Bildpaar angewendet, das keinen Optischen Fluss benötigt, weil keine Bewegung vorhanden ist. Das zweite Bild ist dabei aus dem ersten entstanden, indem verschiedene Helligkeits- und Kontraständerungen vorgenommen wurden.



**Abbildung 3.3:** Selbst erzeugte Bilder, um einen weiteren Eindruck über die Qualität der verschiedenen Helligkeitskompensationen zu erhalten.

Der durchschnittliche Fehler, ohne Anwendung jeglicher Helligkeitskompensation, beträgt 35.063232 und ist somit deutlich größer als jeder Fehler in Abbildung 3.1. Wendet man die oben berechnete Helligkeitskompensation auf dieses Bildpaar an, so sinkt der Fehler auf 11.162521. Das Bild in der Mitte von Abbildung 3.4 ist auf diese Weise entstanden. Links und rechts davon sind die Bilder aus Abbildung 3.3 nochmal zum optischen Vergleich aufgeführt.



**Abbildung 3.4:** Links: Bild 1. Rechts: Bild 2. Mitte: Bild 1 nach der Helligkeitskompensation.

### 3.3 Totalvariation

Eine weitere Möglichkeit die lineare Funktion  $f$  mit Hilfe statistischer Größen zu bestimmen, ist es, anstatt dem Erwartungswert und der Varianz, den Erwartungswert und die sogenannte Totalvariation [AC33] zu benutzen.

Die Totalvariation kann vereinfacht als Gesamtsumme der Variation bezeichnet werden, wobei die Variation der Betrag der Ableitung ist. Man misst also genau die Änderungen zwischen Nachbarpixeln. Desto höher diese ausfällt, desto größer ist der Kontrast im Bild. In unserem Fall dient die Totalvariation als ein Maß für den Kontrast. Da die Ableitung der Betragsfunktion allerdings konstant ist, spielt es keine Rolle, ob der Kontrast langsam steigt oder sich abrupt verändert. Folgendes Beispiel mit den eindimensionalen Signalen  $S_1$  und  $S_2$  verdeutlicht das nochmal:

$$\begin{aligned} S_1 &= [1, 2, 3, 4, 5, 6, 7, 8], & \nabla(S_1) &= [1, 1, 1, 1, 1, 1, 1] \\ \Rightarrow TV(S_1) &= |1| + |1| + |1| + |1| + |1| + |1| + |1| = 7 \\ S_2 &= [0, 0, 0, 7, 7, 7, 7, 7], & \nabla(S_2) &= [0, 0, 7, 0, 0, 0, 0] \\ \Rightarrow TV(S_2) &= |0| + |0| + |7| + |0| + |0| + |0| + |0| = 7 \end{aligned}$$

Die Totalvariation  $TV$  einer mehrdimensionalen diskreten Funktion  $f$  ist definiert als:

$$TV(f) = \sum_{\Omega} \|\nabla(f)\|_2$$

Zur Bestimmung von  $\nabla(G)$  und  $\nabla(H)$  wird, da  $G$  und  $H$  diskret sind, die Vorwärtsdifferenz benutzt.  $TV(G)$  und  $TV(H)$  lassen sich deshalb folgendermaßen berechnen:

$$\begin{aligned} TV(G) &:= \sum_{i=1}^{n_x-1} \sum_{j=1}^{n_y-1} \|\nabla(G)\|_2 \\ &= \sum_{i=1}^{n_x-1} \sum_{j=1}^{n_y-1} \left\| \begin{bmatrix} G_{x_{i,j}} \\ G_{y_{i,j}} \end{bmatrix} \right\|_2 \\ &= \sum_{i=1}^{n_x-1} \sum_{j=1}^{n_y-1} \sqrt{G_{x_{i,j}}^2 + G_{y_{i,j}}^2} \end{aligned}$$

Da wir zur Bestimmung der Ableitung die Vorwärtsdifferenz gewählt haben, gilt für die Ableitung:

$$\begin{aligned} G_{x_{i,j}} &= \frac{1}{h} (G_{x_{i+1,j}} - G_{i,j}), & h &= 1 \\ G_{y_{i,j}} &= \frac{1}{h} (G_{x_{i,j+1}} - G_{i,j}), & h &= 1 \end{aligned}$$

Setzt man diese Definition ein, so erhält man für  $TV(G)$  und  $TV(H)$ :



$$(3.8) \quad TV(G) := \sum_{i=1}^{n_x-1} \sum_{j=1}^{n_y-1} \sqrt{(G_{i+1,j} - G_{i,j})^2 + (G_{i,j+1} - G_{i,j})^2}$$

$$(3.9) \quad TV(H) := \sum_{i=1}^{n_x-1} \sum_{j=1}^{n_y-1} \sqrt{(H_{i+1,j} - H_{i,j})^2 + (H_{i,j+1} - H_{i,j})^2}$$

Nimmt man an, dass, äquivalent zu Kapitel 3.1, der durchschnittliche Grauwert und die Totalvariation zweier aufeinander folgender Bilder  $I_G$  und  $I_H$  einer Bildfolge gleich ist, so gilt:

$$TV(f(G)) = TV(H)$$

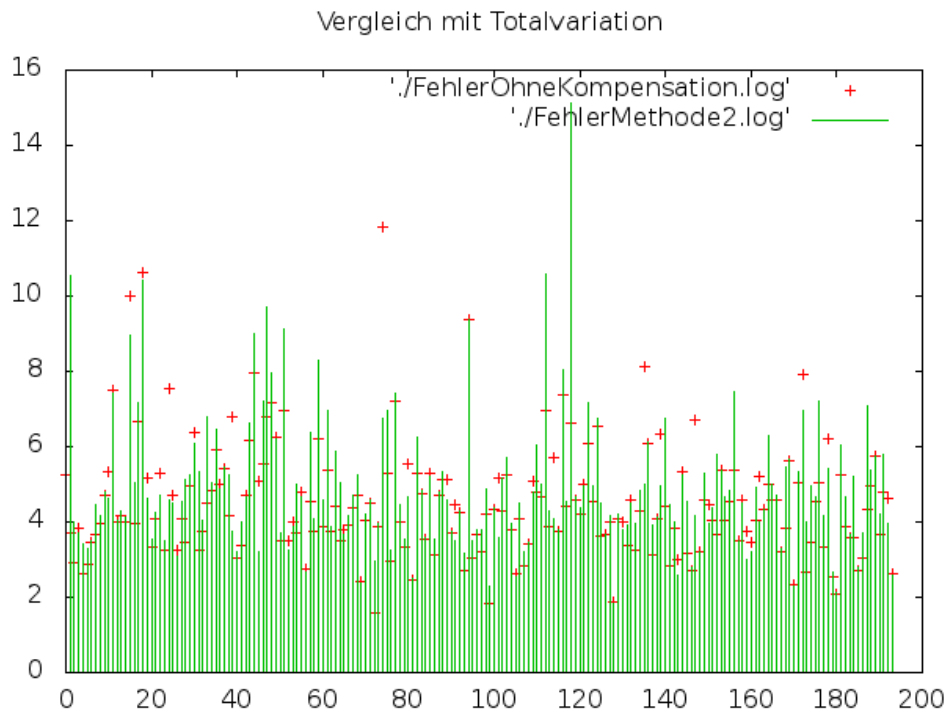
Für  $TV(f(G)) = TV(F)$  folgt dann:

$$\begin{aligned} TV(F) &:= \sum_{i=1}^{n_x-1} \sum_{j=1}^{n_y-1} \sqrt{(F_{i+1,j} - F_{i,j})^2 + (F_{i,j+1} - F_{i,j})^2} \\ &= \sum_{i=1}^{n_x-1} \sum_{j=1}^{n_y-1} \sqrt{(a * G_{i+1,j} + b - (a * G_{i,j} + b))^2 + (a * G_{i,j+1} + b - (a * G_{i,j} + b))^2} \\ &= \sum_{i=1}^{n_x-1} \sum_{j=1}^{n_y-1} \sqrt{(a * G_{i+1,j} - a * G_{i,j} + b - b)^2 + (a * G_{i,j+1} - a * G_{i,j} + b - b)^2} \\ &= \sum_{i=1}^{n_x-1} \sum_{j=1}^{n_y-1} \sqrt{a^2 (G_{i+1,j} - G_{i,j})^2 + a^2 (G_{i,j+1} - G_{i,j})^2} \\ &= \sum_{i=1}^{n_x-1} \sum_{j=1}^{n_y-1} \sqrt{a^2 * \sqrt{(G_{i+1,j} - G_{i,j})^2 + (G_{i,j+1} - G_{i,j})^2}} \\ &= a * \underbrace{\sum_{i=1}^{n_x-1} \sum_{j=1}^{n_y-1} \sqrt{(G_{i+1,j} - G_{i,j})^2 + (G_{i,j+1} - G_{i,j})^2}}_{=TV(G) \text{ siehe (3.8)}} \\ &= a * TV(G) \end{aligned}$$

$$(3.10) \quad \begin{aligned} \Rightarrow a &= \frac{TV(H)}{TV(G)} \\ b &= \bar{H} - \frac{TV(H)}{TV(G)} * \bar{G} \end{aligned}$$

### 3.4 Ergebnis mit Totalvariation


Wenn man zur Bestimmung von  $a$  und  $b$  die Ansätze nimmt, dass der durchschnittliche Grauwert und die Totalvariation bei  $H$  und  $F$  gleich sind, so folgen für  $a$  und  $b$  die Gleichungen 3.10.  $F$  lässt sich nun problemlos, wie in Kapitel 3.2, durch Anwenden der Funktion  $f$  auf  $G$  bestimmen. Zum Vergleich wurden wieder die Werte aus Abbildung 3.1, die den durchschnittlichen Fehler von Bildpaaren einer Bildfolge ohne Anwendung von Helligkeitskompensation zeigt, gewählt. In Abbildung 3.5 ist der durchschnittliche Fehler nach Anwendung von der Funktion  $f$ , deren Parameter mit Hilfe des durchschnittlichen Grauwerts und der Totalvariation berechnet wurden, mit grünen Balken dargestellt. Die roten Punkte signalisieren die Fehler ohne Anwendung von Helligkeitskompensation. Sind die roten Punkte mit einem „+“ dargestellt, so hat die Helligkeitskompensation in diesen Fällen zu einer Verbesserung beigetragen. Punkte, die mit einem „-“ dargestellt sind, signalisieren eine Verschlechterung gegenüber keiner Helligkeitskompensation.



**Abbildung 3.5:** Vergleich vor und nach Helligkeitskompensation mittels Erwartungswert und Totalvariation

Da, wie bereits in Kapitel 3.2, aufgrund von wenig Information über den Optischen Fluss in den oberen Hälften der Bilder aus dem KITTI-Benchmark bekannt ist, lohnt sich die Fehlerberechnung für die Bilder aus Abbildung 3.3. Der Fehler sinkt durch Anwendung der Helligkeitskompensation von 35.063232 auf 16.387390. Auf Grund des geringen Kontrasts in

den Bildern fällt die Helligkeitskompensation bei diesem Verfahren nicht so gut aus wie bei dem Verfahren aus Kapitel 3.1 und 3.2. Zum visuellen Vergleich ist das durch Anwenden dieser Helligkeitskompensation entstandene Bild zwischen den Originalbildern in Abbildung 3.6 abgebildet.



**Abbildung 3.6:** Das Bild in der Mitte ist durch Helligkeitskompensation (Totalvariation und Erwartungswert) des linken auf das rechte entstanden.

### 3.5 Totalvariation mit quadriertem Gradienten

Hier wird zur Bestimmung des zweiten Parameters, ähnlich wie in Kapitel 3.3, die Totalvariation, allerdings mit einem quadriertem Gradienten, gewählt. Wir kürzen es in diesem Paper mit  $GR$  ab. Für die Totalvariation von  $G$  und  $H$  mit quadriertem Gradienten folgt deshalb:

$$\begin{aligned}
 GR(G) &:= \sum_{i=1}^{n_x-1} \sum_{j=1}^{n_y-1} \|\nabla(G)\|_2^2 \\
 &= \sum_{i=1}^{n_x-1} \sum_{j=1}^{n_y-1} \sqrt{G_{x_{ij}}^2 + G_{y_{ij}}^2}^2 \\
 &= \sum_{i=1}^{n_x-1} \sum_{j=1}^{n_y-1} (G_{x_{ij}}^2 + G_{y_{ij}}^2)
 \end{aligned}$$

$$(3.11) \quad \Rightarrow GR(G) = \sum_{i=1}^{n_x-1} \sum_{j=1}^{n_y-1} (G_{i+1,j} - G_{i,j})^2 + (G_{i,j+1} - G_{i,j})^2$$

$$(3.12) \quad \Rightarrow GR(H) = \sum_{i=1}^{n_x-1} \sum_{j=1}^{n_y-1} (H_{i+1,j} - H_{i,j})^2 + (H_{i,j+1} - H_{i,j})^2$$

Da die Quadratsfunktion nicht mehr linear ist, tragen jetzt große Helligkeitssprünge im Bild überproportional zum Ergebnis bei. Ein Beispiel mit den selben Signalen  $S_1$  und  $S_2$  aus Kapitel 3.3 verdeutlicht das nochmal:

$$\begin{aligned} S_1 &= [1, 2, 3, 4, 5, 6, 7, 8], & \nabla(S_1) &= [1, 1, 1, 1, 1, 1, 1] \\ \Rightarrow GR(S_1) &= 1^2 + 1^2 + 1^2 + 1^2 + 1^2 + 1^2 + 1^2 = 7 \\ S_2 &= [0, 0, 0, 7, 7, 7, 7, 7], & \nabla(S_2) &= [0, 0, 7, 0, 0, 0, 0] \\ \Rightarrow GR(S_2) &= 0^2 + 0^2 + 7^2 + 0^2 + 0^2 + 0^2 + 0^2 = 49 \end{aligned}$$

Wie man sehen kann, ist die Totalvariation mit quadriertem Gradienten bei Signal  $S_2$  deutlich größer als bei Signal  $S_1$ , weil wenige große Sprünge im Bild mehr dazu beitragen als viele kleine.

Nimmt man an, dass, äquivalent zu Kapitel 3.1 und Kapitel 3.3, der durchschnittliche Grauwert und die Totalvariation mit quadriertem Gradienten zweier aufeinander folgender Bilder  $I_G$  und  $I_H$  einer Bildfolge gleich ist, so gilt für

$$GR(F) = GR(H)$$


$$\begin{aligned} GR(F) &:= \sum_{i=1}^{n_x-1} \sum_{j=1}^{n_y-1} (F_{i+1,j} - F_{i,j})^2 + (F_{i,j+1} - F_{i,j})^2 \\ &= \sum_{i=1}^{n_x-1} \sum_{j=1}^{n_y-1} (a * G_{i+1,j} + b - (a * G_{i,j} + b))^2 + (a * G_{i,j+1} + b - (a * G_{i,j} + b))^2 \\ &= \sum_{i=1}^{n_x-1} \sum_{j=1}^{n_y-1} (a * G_{i+1,j} - a * G_{i,j} + b - b)^2 + (a * G_{i,j+1} - a * G_{i,j} + b - b)^2 \\ &= \sum_{i=1}^{n_x-1} \sum_{j=1}^{n_y-1} a^2 (G_{i+1,j} - *G_{i,j})^2 + a^2 (G_{i,j+1} - G_{i,j})^2 \\ &= \sum_{i=1}^{n_x-1} \sum_{j=1}^{n_y-1} a^2 * (G_{i+1,j} - *G_{i,j})^2 + (G_{i,j+1} - G_{i,j})^2 \\ &= a^2 * \underbrace{\sum_{i=1}^{n_x-1} \sum_{j=1}^{n_y-1} (G_{i+1,j} - *G_{i,j})^2 + (G_{i,j+1} - G_{i,j})^2}_{=GR(G) \text{ siehe (3.11)}} \\ &= a^2 * TV(G) \end{aligned}$$

$$(3.13) \quad \begin{aligned} \Rightarrow a &= \sqrt{\frac{TV(H)}{TV(G)}} \\ b &= \bar{H} - \sqrt{\frac{TV(H)}{TV(G)}} * \bar{G} \end{aligned}$$


### 3.6 Ergebnis mit Totalvariation mit quadriertem Gradienten

Wenn man zur Bestimmung von  $a$  und  $b$  die Ansätze nimmt, dass der durchschnittliche Grauwert und die Totalvariation mit quadriertem Gradienten bei  $H$  und  $f(G)$  gleich sind, so folgen für  $a$  und  $b$  die Gleichungen (3.13).  $F$  lässt sich nun problemlos, wie in Kapitel 3.2 und 3.4, durch Anwenden der Funktion  $f$  auf  $G$  bestimmen. Zum Vergleich wurden wieder die Werte aus Abbildung 3.1, die den durchschnittlichen Fehler von Bildpaaren einer Bildfolge ohne Anwendung von Helligkeitskompensation zeigt, gewählt. In Abbildung 3.7 ist der durchschnittliche Fehler nach Anwendung von der Funktion  $f$ , deren Parameter mit Hilfe des durchschnittlichen Grauwerts und der Totalvariation mit quadriertem Gradienten berechnet wurden, mit grünen Balken dargestellt. Die roten Punkte signalisieren die Fehler ohne Anwendung von Helligkeitskompensation. Sind die roten Punkte mit einem „+“ dargestellt, so hat die Helligkeitskompensation in diesen Fällen zu einer Verbesserung beigetragen. Punkte, die mit einem „-“ dargestellt sind, signalisieren eine Verschlechterung gegenüber keiner Helligkeitskompensation.

Da, wie bereits in den Kapitel 3.2 und 3.4, aufgrund von wenig Information über den Optischen Fluss in den oberen Hälften der Bilder aus dem KITTI-Benchmark bekannt ist, lohnt sich die Fehlerberechnung für die Bilder aus Abbildung 3.3. Der Fehler sinkt durch Anwenden der Helligkeitskompensation von 35.063232 auf 19.517273, womit er etwas höher als bei dem Verfahren mit der Totalvariation ohne quadriertem Gradienten (16.387390) ist. Obwohl die Bilder hohe Kontrastsprünge aufweisen, womit dieses Verfahren, das stärkeren Einfluss auf hohe Kontraständerungen nimmt, besser geeignet sein sollte als das Verfahren aus Kapitel 3.3 und 3.4, verschlechtert sich das Ergebnis minimal. Grund dafür sind die Grenzen für die Grauwerte (0 bis 255), die eine exakte Transformation der Grauwerte, die danach außerhalb der Grenzen läge, verhindern. Zum visuellen Vergleich ist in Abbildung 3.8 wieder das durch Anwenden dieser Helligkeitskompensation entstandene Bild zwischen den Originalbildern abgebildet.



**Abbildung 3.7:** Vergleich vor und nach Helligkeitskompensation mittels Erwartungswert und Totalvariation mit quadrierter Gradienten



**Abbildung 3.8:** Das Bild in der Mitte ist durch Helligkeitskompensation (Totalvariation (quadrierter Gradient) und Erwartungswert) des linken auf das rechte entstanden.

# 4 Histogrammtransformation

## 4.1 Histogramm


Ein Histogramm ist eine graphische Darstellung der Häufigkeitsverteilung metrisch skalierten Merkmale [GW07]. In Bildverarbeitung und Computer Vision versteht man unter einem Histogramm eine graphische Darstellung der Häufigkeit einzelner Grauwerte. Auf der x-Achse sind dabei meistens die Grauwerte von 0 bis 255 abgetragen, während auf der y-Achse die Häufigkeit dieser, also wie oft ein Grauwert im Bild auftaucht, abgebildet ist.

Zählt man die einzelnen Grauwerte des Beispielbildes im PGM Format aus Kapitel 2.3

```
P2
bild.pgm
24 7
7
00000000000000000000000000000000
077700007700040000077700
070070007700040000070070
077700007700040000070070
070070007700040000070070
077700007700044440077700
00000000000000000000000000000000
```

so erhält man für folgende Zählung das Histogramm in Abbildung 4.1.

Grauwert	0	1	2	3	4	5	6	7
Anzahl	127	0	0	0	8	0	0	33



**Abbildung 4.1:** Das Histogramm zu obigem PGM.

Für komplexere Bilder, wie in Abbildung 4.3, wird das Histogramm benutzt, um Informationen wie den Kontrast oder den Dynamikbereich des Bildes zu erhalten. Bei einem optimalen Histogramm taucht jeder Grauwert gleich oft auf, da dann der komplette Wertebereich so gut wie möglich ausgeschöpft wird. In der Praxis ist das allerdings nur selten der Fall. Je nach Situation lassen sich mit geeigneten Histogrammtransformationen Informationen aus Bildern herauslesen, die man sonst nicht bekommen würde.






Abbildung 4.2: Das Histogramm zu Abbildung 4.3.





Abbildung 4.3: Ein Graustufenbild eines Pavians.

Wie man sehen kann, befinden sich fast alle Pixel in der linken Hälfte des Histogramms (Abbildung 4.2). Das liegt daran, dass das Bild mit dem Pavian hauptsächlich aus dunklen

Grauwerten besteht und somit einen geringen Dynamikbereich aufweist. Würde sich das Histogramm über die volle Breite erschöpfen, so würde das Bild einen hohen Dynamikbereich aufweisen, was Bilder realistischer wirken lässt.

In Abbildung 4.4 sieht man das Bild des Pavians aus Abbildung 4.3 nach Anwendung der Histogrammegalierung. Details, wie zum Beispiel die Haare, sind nach der Histogrammegalierung besser erkennbar.



**Abbildung 4.4:** Ein Graustufenbild eines Pavians nach der Histogrammegalierung.

Das egalisierte Histogramm dazu ist in Abbildung 4.5 zu sehen. Anders als beim Histogramm vor der Egalisierung tauchen im egalisierten Histogramm sowohl dunkle als auch helle Pixel auf. Pixel mit dem gleichen Grauwert tauchen nach der Egalisierung fast gleich oft auf, weshalb die Balken im egalisierten Histogramm ungefähr die gleiche Höhe haben. Die Lücken im Histogramm, die sich zwischen zwei oder mehreren Grauwerten befinden, sind Folge der Spreizung des Histogramms.



Abbildung 4.5: Das egalisierte Histogramm zu Abbildung 4.4.

## 4.2 Histogrammegalierung

Besteht ein Bild hauptsächlich nur aus dunklen oder aus hellen Pixeln, oder liegen die Pixel in einem gewissen Bereich, so kann es kontrastarm und unrealistisch wirken. Eine Methode, den Dynamikbereich des Bildes zu erhöhen und somit den verfügbaren Wertebereich auszunutzen, ist die Histogrammegalierung [Bru13].

Die Histogrammegalierung versucht, ein Histogramm so auszugleichen, dass jeder Balken, also die Anzahl Pixel mit einem Grauwert, gleich groß ist, indem aus der Grauwertverteilung eine Gleichverteilung berechnet wird. Optimalerweise taucht nach der Histogrammegalierung jeder Grauwert genau  $\frac{N}{256}$  mal auf.

### 4.2.1 Rechenweg und Erklärung

Sei  $p_i$  die Anzahl Pixel von  $I_G$  mit dem Grauwert  $v_i = (0, \dots, 255)$  und  $q_j$  die gewünschte Anzahl an Pixel mit dem Grauwert  $w_j = (0, \dots, 255)$ . Gesucht ist eine Transformation, die jedem Grauwert  $v_i$  einen Grauwert  $w_j$  zuweist. Wir nennen diese Transformation Mapping  $M$ .

Zur Bestimmung des Mappings müssen wir nun für  $r = 0, \dots, 255$  den größten Index  $k_r \leq 255$  finden für den  $\sum_{i=0}^{k_r} p_i \leq \sum_{j=0}^r q_j$  gilt, und dann alle Grauwerte  $v_{k_{r-1}+1}, \dots, v_{k_r}$  auf  $w_r$  abbilden.

Zur einfachen Bestimmung von  $M$  benötigen wir zu den Histogrammen, wobei  $H_G$  das Histogramm zu  $I_G$  und  $H_H$  das Histogramm zu  $I_H$  ist, die zugehörigen kumulativen Histogramme.

Ein kumulatives Histogramm enthält an der Stelle  $i$  die Summe aller Werte vom Histogramm  $\leq i$ , was bedeutet, dass ein kumulatives Histogramm an der Stelle 255 den Wert  $N$  hat. Die Berechnung der kumulativen Histogramme  $\overline{H}_G$  und  $\overline{H}_H$  erfolgt durch:

$$(4.1) \quad \begin{aligned} \overline{H}_G(i) &= \sum_{j=0}^i H_G(j), \text{ für } 0 \leq i \leq 255 \\ \overline{H}_H(i) &= \sum_{j=0}^i H_H(j), \text{ für } 0 \leq i \leq 255 \end{aligned}$$

Zusätzlich benötigen wir das kumulative Histogramm  $\overline{H}_O$  für das optimale Histogramm, das überall den Wert  $\frac{N}{256}$  hat. Falls es sich bei  $N$  um kein Vielfaches von 256 handelt, so müssen wir  $\frac{N}{256}$  aufrunden.

Zur Berechnung der Histogrammegalierung wurde folgender Algorithmus verwendet.

---

### Algorithmus 4.1 Algorithmus zur Histogrammegalierung

---

```
procedure HISTOGRAMMEGALIERUNG( $\overline{H}_G, \overline{H}_O$ )
j=0;
for (i = 0; i<256; i++)
{
    while ( $\overline{H}_G(i) > \overline{H}_O(j)$ )
    {
        j++;
    }
    mapGreyValue_i_to_j(i, j, mapping);
    return mapping;
}
end procedure
```


---

Ein weiteres Verfahren, das zur Bestimmung der Helligkeitskompensation benutzt wurde, nutzt genau diese Histogrammegalierung. Das Verfahren wendet die Histogrammegalierung auf Bild  $I_G$  und  $I_H$  an und vergleicht diese Bilder wieder nach Anwendung der Rücktransformation von  $I_H$  mittels Optischem Fluss.

## 4.3 Ergebnisse zu Histogrammegalierung

Anders als bei der Evaluation in Kapitel 2 reicht es bei der Histogrammegalierung nicht aus das helligkeitkompensierte Bild  $I_{f(G)}$  mit dem rücktransformierten Bild zu  $I_H$  zu vergleichen. Da bei einer Histogrammegalierung der Dynamikbereich des Bildes erhöht wird, ist der Kontrast im helligkeitkompensierten Bild höher als beim anderen Bild des Bildpaares. Deshalb müssen wir bei dem rücktransformierten Bild auch noch eine Histogrammegalierung durchführen. Zum Vergleich wurden wieder die Werte aus Abbildung 3.1, die

den durchschnittlichen Fehler von Bildpaaren einer Bildfolge ohne Anwendung von Helligkeitskompensation zeigt, gewählt. In Abbildung 4.4 ist der durchschnittliche Fehler nach Anwenden der Histogrammegalierung auf beide Bilder mit grünen Balken dargestellt. Die roten Punkte signalisieren die Fehler ohne Anwendung von Helligkeitskompensation. Sind die roten Punkte mit einem „+“ dargestellt, so hat die Helligkeitskompensation in diesen Fällen zu einer Verbesserung beigetragen. Punkte, die mit einem „-“ dargestellt sind, signalisieren eine Verschlechterung gegenüber keiner Helligkeitskompensation.



**Abbildung 4.6:** Vergleich vor und nach Helligkeitskompensation mittels Histogrammegalierung.

Wie man sehen kann, weist die Histogrammegalierung eine Verschlechterung bei fast allen Bildpaaren auf. Wirft man einen Blick auf die Bilder mit egalisierten Histogrammen, so sieht man allerdings visuell eine gute Anpassung der Helligkeit. Abbildung 4.5 zeigt das Bildpaar mit egalisierten Histogrammen, das einen der größten Fehler aufweist (Nr. 74). Visuell scheint die Helligkeit in beiden Bildern jedoch fast identisch zu sein.

Ein Grund für den großen Fehler sind die Lücken im egalisierten Histogramm, die durch die Egalisierung entstanden sind. Auf Grund grober Diskretisierung kann es passieren, dass Grauwerte im ersten egalisierten Histogramm im zweiten überhaupt nicht auftauchen (dort befindet sich eine Lücke). Ein Vergleich dieser Pixel erhöht den Fehler drastisch.

Ein weiterer Grund für den großen Fehler ist, dass sich die Pixel auf Grund der Lichtreflexionen nicht richtig vergleichen lassen. Obwohl sich der Hintergrund (Straße und Bäume) bewegt, verändert sich die Position der Lichtreflexionen auf Grund der Frontscheibe des Autos nicht. Das führt dazu, dass dunkle Pixel mit hellen Pixeln aus der Lichtreflexion verglichen werden. Da die Histogrammegalierung den Grauwert der Pixel stark verändert, fällt der Fehler größer aus als beim Vergleich ohne Helligkeitskompensation. Die Ungenauigkeit des Optischen Flusses führt in vielen Bildpaaren dazu, dass falsche Pixel, die sich in der Nähe der richtigen befinden, miteinander verglichen werden. Das wiederum spiegelt sich in der Fehlerauswertung wieder.



**Abbildung 4.7:** Vergleich des Bildpaares 74 nach der Histogrammegalierung. Das untere Bild muss noch rücktransformiert werden, um einen numerischen Vergleich durchzuführen.


Transformiert man das untere der beiden Bilder aus Abbildung 4.7 mit Hilfe des Optischen Flusses zurück und vergleicht es mit dem oberen Bild, so wird das angesprochene Problem, das Grund für den großen Fehler ist, noch deutlicher. In Abbildung 4.8 kann man beispielsweise sehen, dass der weiße Punkt auf der Straße links sich im oberen Bild nicht innerhalb des Lichtkreises befindet. Im unteren Bild kann man sehen, dass sich der weiße Punkt innerhalb eines der Lichtkreise befindet. Pixel in der Nähe des weißen Punktes zeigen deshalb große Helligkeitsunterschiede. Das gleiche Problem findet man bei den Bäumen am Rand der Straße. Die vielen Schatten und Lichtreflexionen führen dort ebenfalls dazu, dass dunkle Pixel (innerhalb eines Schattens) mit hellen Pixeln (innerhalb von Lichtreflexionen) miteinander verglichen werden. Eine solche numerische Auswertung ist bei derartigen Bildern deshalb nicht sinnvoll. Einen deutlich besseren Vergleich würde man bekommen, wenn keine Bewegung im Spiel wäre. Deshalb lohnt es sich umso mehr, einen Blick auf die Bilder

aus Abbildung 3.3 und die Bilder, die durch Anwenden der Histogrammegalierung auf diese entstehen, zu werfen. Abbildung 4.9 zeigt beide Bilder aus Abbildung 3.3 nach der Histogrammegalierung.



**Abbildung 4.8:** Vergleich des Bildpaares 74 nach der Histogrammegalierung und Rücktransformation.

Wie man sehen kann, sieht das Ergebnis, ähnlich wie bereits in Abbildung 4.4, sehr gut aus. Eine Verbesserung des Fehlers von 35.063232 auf 3.086868 bestätigt das auch.



**Abbildung 4.9:** Das Bild links ist durch Histogrammegalierung des linken Bildes aus Abbildung 3.3 und das rechts durch Histogrammegalierung des rechten Bildes aus Abbildung 3.3 entstanden.

## 4.4 Histogrammspezifikation

Eine weitere Möglichkeit Histogrammtransformationen auf  $I_G$  und  $I_H$  anzuwenden, ist die Histogrammspezifikation [Bru13]. Bei der Histogrammspezifikation wird, ähnlich wie bei der Histogrammegalierung, ein Mapping  $M_S$  gesucht, das jeden Grauwert auf einen neuen Grauwert abbildet. Anders als bei der Histogrammegalierung möchte man das Histogramm aber nicht egalieren, sondern an ein anderes Histogramm anpassen. Das Ziel hier ist es also, das Histogramm  $H_G$  so zu transformieren, dass es dem Histogramm  $H_H$  so ähnlich wie möglich ist.

---

**Algorithmus 4.2** Algorithmus zur Histogrammspezifikation

---

```
procedure HISTOGRAMMSPEZIFIKATION( $\overline{H}_G, \overline{H}_H$ )
  j=0;
  for (i = 0; i<256; i++)
  {
    while ( $\overline{H}_G(i) > \overline{H}_H(j)$ )
    {
      j++;
    }
    mapGreyValue_i_to_j(i, j, mapping);
    return mapping;
  }
end procedure
```


---

Der Vorteil gegenüber der Histogrammegalierung ist, dass nicht zwei Histogrammtransformationen durchgeführt werden müssen. Es wird lediglich das erste Histogramm an das zweite angepasst, womit nur eine Histogrammtransformation gemacht werden muss. Aufeinander folgende Bilder einer Bildsequenz haben viele zugehörige Pixel, die sich auf Grund der Helligkeitsunterschiede schwer zuordnen lassen. Eine Histogrammspezifikation ist bei solchen Bildpaaren besonders sinnvoll, weil Helligkeitsunterschiede dadurch angepasst werden.



## 4.5 Ergebnisse zu Histogrammspezifikation


Zur Evaluierung der Histogrammspezifikation wird das Bild  $I_G$ , bei dem eine Histogrammspezifikation zu Bild  $I_H$  durchgeführt wurde, einfach mit dem rücktransformierten Bild zu  $I_H$  verglichen. Eine Helligkeitstransformation bei  $I_H$  muss nicht durchgeführt werden. Wendet man die Histogrammspezifikation auf die Bildpaare aus dem KITTI-Benchmark für den Optischen Fluss an und vergleicht die Fehler mit den Fehlern aus Abbildung 3.1, so kann man sehen, dass die Histogrammspezifikation deutlich besser als die Histogrammegalierung ausfällt. In Abbildung 4.10 ist der durchschnittliche Fehler nach Anwenden der Histogrammspezifikation mit grünen Balken dargestellt. Die roten Punkte signalisieren die Fehler ohne Anwendung von Helligkeitskompensation. Sind die roten Punkte mit einem „+“ dargestellt, so hat die Helligkeitskompensation in diesen Fällen zu einer Verbesserung beigetragen. Punkte, die mit einem „-“ dargestellt sind, signalisieren eine Verschlechterung gegenüber keiner Helligkeitskompensation.



**Abbildung 4.10:** Vergleich vor und nach Helligkeitskompensation mittels Histogrammspezifikation.

Da die Histogrammspezifikation, anders als die Histogrammegalierung, keine großen Änderungen, an den Grauwerten vornimmt, fallen die Fehler nicht so hoch aus. Der Fehler hat sich vor allem bei den Bildern verbessert, bei denen der Fehler vorher groß war. War der

Fehler vorher klein, so ist er nach der Histogrammspezifikation aus den selben Gründen wie bei den statistischen Verfahren gestiegen. Einen besseren Eindruck wie gut dieses Verfahren ist, bekommt man, wenn die Histogrammspezifikation auf Bilder ohne Bewegung durchgeführt wird. Abbildung 4.11 zeigt den direkten Vergleich der Bilder aus Abbildung 3.3. In der Mitte ist das Bild, das durch Anwenden der Histogrammspezifikation vom linken auf das rechte Bild entstanden ist.



**Abbildung 4.11:** Das Bild in der Mitte ist durch Histogrammspezifikation des linken auf das rechte Bild entstanden.

Mit dem bloßen Auge lässt sich kaum ein Unterschied zwischen dem mittleren und dem rechten Bild erkennen. Das liegt daran, dass das menschliche Auge weniger als 40 verschiedene Grautöne unterscheiden kann. Der durchschnittliche Fehler in diesem Bild liegt bei 0.433304, womit eine deutliche Verbesserung gegenüber dem Fehler ohne Helligkeitsanpassung von 35.063232 vorliegt.

## 5 Histogrammbasierte Regression

Beim letzten Verfahren, das zur Berechnung der Helligkeitskompensation untersucht wurde, handelt es sich um eine histogrammbasierte Regression. Dazu wurde zu beiden kumulativen Histogrammen  $\bar{H}_G$  und  $\bar{H}_H$  eine Map der Größe  $N$  berechnet, die der Anzahl an Pixel einen Grauwert zuordnet. Dabei kann es passieren, dass der zugehörige Grauwert keine Ganzzahl ist, sondern sich zwischen zwei ganzzahligen Grauwerten befindet. Folgendes Beispiel soll das nochmals verdeutlichen:

Grauwert	0	1	2	3	4	5	6	7
Anzahl	0	3	4	9	10	14	15	16

**Tabelle 5.1:** Das kumulative Histogramm zu einem  $4 \times 4$  Bild.

Mappt man jetzt die Anzahl Pixel auf einen Grauwert, so erhält man folgendes Mapping:

Anzahl	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
Grauwert	0.33	0.66	1.00	2.00	2.20	2.40	2.60	2.80	3.00	4.00	4.25	4.50	4.75	5.00	6.00	7.00

**Tabelle 5.2:** Das zugehörige Mapping von Anzahl Pixel auf Grauwert.

Wir nennen  $x$  das Mapping zum Histogramm  $\bar{H}_G$  und  $y$  das zu  $\bar{H}_H$ , wobei  $x_i$  der Grauwert zu  $1 \leq i \leq N$  ist. Das Ziel ist es, eine Funktion  $f$  zu finden, die  $f(x_i)$  an  $y_i$  so gut wie möglich approximiert.

### 5.1 Rechenweg und Erklärung

Wir nehmen zuerst an, dass  $f$  eine lineare Funktion, also  $f(x_i) = ax_i + b$ , ist und nutzen die Methode der kleinsten Quadrate, um sie zu bestimmen (Regression). Die Aufgabe ist deshalb,

$$(5.1) \quad E(a, b) = \sum_{i=1}^N (y_i - f(x_i))^2 = \sum_{i=1}^N (y_i - (ax_i + b))^2$$

zu minimieren.

Um  $E$  zu minimieren, reicht es,  $E$  nach  $a$  und  $b$  abzuleiten und auf 0 zu setzen.

Leitet man  $E$  nach  $a$  ab, so erhält man:

$$\begin{aligned}\frac{\partial E(a,b)}{\partial a} &= 2 \sum_{i=1}^N (y_i - (ax_i + b)) * (-x_i) = 0 \\ &\Leftrightarrow \sum_{i=1}^N y_i * (-x_i) - a \sum_{i=1}^N x_i * (-x_i) - b \sum_{i=1}^N (-x_i) = 0 \\ &\Leftrightarrow a \sum_{i=1}^N x_i^2 + b \sum_{i=1}^N x_i = \sum_{i=1}^N y_i x_i\end{aligned}$$

Leitet man  $E$  nach  $b$  ab, so erhält man:

$$\begin{aligned}\frac{\partial E(a,b)}{\partial b} &= 2 \sum_{i=1}^N (y_i - (ax_i + b)) * (-1) = 0 \\ &\Leftrightarrow \sum_{i=1}^N y_i * (-1) - a \sum_{i=1}^N x_i * (-1) - b \sum_{i=1}^N (-1) = 0 \\ &\Leftrightarrow a \sum_{i=1}^N x_i + b \sum_{i=1}^N 1 = \sum_{i=1}^N y_i\end{aligned}$$

Das zu lösende Gleichungssystem sieht dann folgendermaßen aus:

$$(5.2) \quad \begin{pmatrix} \sum_{i=1}^N x_i^2 & \sum_{i=1}^N x_i \\ \sum_{i=1}^N x_i & \sum_{i=1}^N 1 \end{pmatrix} \begin{pmatrix} a \\ b \end{pmatrix} = \begin{pmatrix} \sum_{i=1}^N y_i x_i \\ \sum_{i=1}^N y_i \end{pmatrix}$$

Löst man dieses Gleichungssystem mit der Cramerschen Regel [Pap03], so erhält man:

$$(5.3) \quad \begin{aligned}a &= \frac{\sum_{i=1}^N y_i x_i * \sum_{i=1}^N 1 - \sum_{i=1}^N y_i * \sum_{i=1}^N x_i}{\sum_{i=1}^N x_i^2 * \sum_{i=1}^N 1 - \sum_{i=1}^N x_i * \sum_{i=1}^N x_i} \\ b &= \frac{\sum_{i=1}^N x_i^2 * \sum_{i=1}^N y_i - \sum_{i=1}^N x_i * \sum_{i=1}^N y_i x_i}{\sum_{i=1}^N x_i^2 * \sum_{i=1}^N 1 - \sum_{i=1}^N x_i * \sum_{i=1}^N x_i}\end{aligned}$$

Große Unterschiede in den Bildern  $I_G$  und  $I_H$  führen zu großen Fehlern bei  $(y_i - f(x_i))^2$ , da das Argument quadratisch auftaucht. Es empfiehlt sich deshalb, Gleichung (5.1) um eine Bestrafungsfunktion  $\psi$  zu erweitern, das große Fehler nicht so stark gewichtet, weil diese großen Einfluss auf die Berechnung von  $a$  und  $b$  haben [Hub81]. Ein solches Bestrafungsfunktion ist  $\psi(s^2) = \sqrt{s^2 + \epsilon^2}$ , wobei  $s^2 = (y_i - f(x_i))^2$ . Die Ableitung  $\frac{\partial \psi}{\partial s^2} = \frac{1}{2\sqrt{s^2 + \epsilon^2}}$  wird für große  $s$  klein und für kleine  $s$  groß. Das führt dazu, dass kleine Fehler stärker und große Fehler schwächer gewichtet werden, womit Ausreißer keinen großen Einfluss mehr auf die Berechnung von  $a$  und  $b$  haben. Um sicher zu gehen, dass der Nenner von  $\frac{\partial \psi}{\partial s^2}$  nie 0 werden kann, addieren wir unter der Wurzel  $\epsilon^2$  hinzu, womit  $\psi$  differenzierbar wird. Bei  $\epsilon$  handelt es sich um einen möglichst kleinen Wert (z.B.:  $\epsilon = 10^{-9}$ ).

Die neue Gleichung, die entsteht, wenn wir (5.1) um das Bestrafungsfunktion  $\psi(s^2)$  erweitern, sieht folgendermaßen aus:

$$(5.4) \quad E(\psi(a, b)) = \sum_{i=1}^N \psi((y_i - f(x_i))^2) = \sum_{i=1}^N \psi((y_i - (ax_i + b))^2)$$

Wie bereits bei (5.1) müssen wir auch diese Gleichung wieder nach  $a$  und  $b$  ableiten, um sie zu minimieren.

$$\begin{aligned} \frac{\partial E(\psi(a, b))}{\partial a} &= 2 \sum_{i=1}^N \psi'(s^2)(y_i - (ax_i + b)) * (-x_i) = 0 \\ &\Leftrightarrow \sum_{i=1}^N \psi'(s^2)y_i * (-x_i) - a \sum_{i=1}^N \psi'(s^2)x_i * (-x_i) - b \sum_{i=1}^N \psi'(s^2) * (-x_i) = 0 \\ &\Leftrightarrow a \sum_{i=1}^N \psi'(s^2)x_i^2 + b \sum_{i=1}^N \psi'(s^2)x_i = \sum_{i=1}^N \psi'(s^2)y_i x_i \end{aligned}$$

$$\begin{aligned} \frac{\partial E(\psi(a, b))}{\partial b} &= 2 \sum_{i=1}^N \psi'(s^2)(y_i - (a * x_i + b)) * (-1) = 0 \\ &\Leftrightarrow \sum_{i=1}^N \psi'(s^2)y_i * (-1) - a \sum_{i=1}^N \psi'(s^2)x_i * (-1) - b \sum_{i=1}^N \psi'(s^2) * (-1) = 0 \\ &\Leftrightarrow a \sum_{i=1}^N \psi'(s^2)x_i + b \sum_{i=1}^N \psi'(s^2) = \sum_{i=1}^N \psi'(s^2)y_i \end{aligned}$$

Das zu lösende nichtlineare Gleichungssystem (da  $\psi'(s^2) = \psi'(a, b) = \dots$ ) ist dann:

$$(5.5) \quad \begin{pmatrix} \sum_{i=1}^N \psi'(s^2)x_i^2 & \sum_{i=1}^N \psi'(s^2)x_i \\ \sum_{i=1}^N \psi'(s^2)x_i & \sum_{i=1}^N \psi'(s^2) \end{pmatrix} \begin{pmatrix} a \\ b \end{pmatrix} = \begin{pmatrix} \sum_{i=1}^N \psi'(s^2)y_i x_i \\ \sum_{i=1}^N \psi'(s^2)y_i \end{pmatrix}$$

Wählt man  $f$  nicht mehr als lineare Funktion, sondern als quadratische ( $f(x_i) = ax_i^2 + bx_i + c$ ), so muss man den Ausdruck  $E$  nach  $a$ ,  $b$  und  $c$  ableiten. Wenn wir  $E(\psi(a, b, c)) = \sum_{i=1}^N \psi((y_i - f(x_i))^2) = \sum_{i=1}^N \psi((y_i - (ax_i^2 + bx_i + c))^2)$  nach  $a$ ,  $b$  und  $c$  ableiten, erhalten wir:

$$\begin{aligned} \frac{\partial E(\psi(a, b, c))}{\partial a} &= 2 \sum_{i=1}^N \psi'(s^2)(y_i - (ax_i^2 + bx_i + c)) * (-x_i^2) = 0 \\ &\Leftrightarrow \sum_{i=1}^N \psi'(s^2)y_i * (-x_i^2) - a \sum_{i=1}^N \psi'(s^2)x_i^2 * (-x_i^2) \\ &\quad - b \sum_{i=1}^N \psi'(s^2)x_i * (-x_i^2) - c \sum_{i=1}^N \psi'(s^2) * (-x_i^2) = 0 \\ &\Leftrightarrow a \sum_{i=1}^N \psi'(s^2)x_i^4 + b \sum_{i=1}^N \psi'(s^2)x_i^3 + c \sum_{i=1}^N \psi'(s^2)x_i^2 = \sum_{i=1}^N \psi'(s^2)y_i x_i^2 \end{aligned}$$

$$\begin{aligned}
 \frac{\partial E(\psi(a, b, c))}{\partial b} &= 2 \sum_{i=1}^N \psi'(s^2)(y_i - (ax_i^2 + bx_i + c)) * (-x_i) = 0 \\
 &\Leftrightarrow \sum_{i=1}^N \psi'(s^2)y_i(-x_i) - a \sum_{i=1}^N \psi'(s^2)x_i^2(-x_i) \\
 &\quad - b \sum_{i=1}^N \psi'(s^2)x_i(-x_i) - c \sum_{i=1}^N \psi'(s^2)(-x_i) = 0 \\
 &\Leftrightarrow a \sum_{i=1}^N \psi'(s^2)x_i^3 + b \sum_{i=1}^N \psi'(s^2)x_i^2 + b \sum_{i=1}^N \psi'(s^2)x_i = \sum_{i=1}^N \psi'(s^2)y_i x_i
 \end{aligned}$$

$$\begin{aligned}
 \frac{\partial E(\psi(a, b, c))}{\partial c} &= 2 \sum_{i=1}^N \psi'(s^2)(y_i - (ax_i^2 + bx_i + c))(-1) = 0 \\
 &\Leftrightarrow \sum_{i=1}^N \psi'(s^2)y_i(-1) - a \sum_{i=1}^N \psi'(s^2)x_i^2(-1) \\
 &\quad - b \sum_{i=1}^N \psi'(s^2)x_i(-1) - c \sum_{i=1}^N \psi'(s^2)(-1) = 0 \\
 &\Leftrightarrow a \sum_{i=1}^N \psi'(s^2)x_i^2 + b \sum_{i=1}^N \psi'(s^2)x_i + b \sum_{i=1}^N \psi'(s^2) = \sum_{i=1}^N \psi'(s^2)y_i
 \end{aligned}$$

Das zu lösende Gleichungssystem sieht dann wie folgt aus:

$$(5.6) \quad \begin{pmatrix} \sum_{i=1}^N \psi'(s^2)x_i^4 & \sum_{i=1}^N \psi'(s^2)x_i^3 & \sum_{i=1}^N \psi'(s^2)x_i^2 \\ \sum_{i=1}^N \psi'(s^2)x_i^3 & \sum_{i=1}^N \psi'(s^2)x_i^2 & \sum_{i=1}^N \psi'(s^2)x_i \\ \sum_{i=1}^N \psi'(s^2)x_i^2 & \sum_{i=1}^N \psi'(s^2)x_i & \sum_{i=1}^N \psi'(s^2) \end{pmatrix} \begin{pmatrix} a \\ b \\ c \end{pmatrix} = \begin{pmatrix} \sum_{i=1}^N \psi'(s^2)y_i x_i^2 \\ \sum_{i=1}^N \psi'(s^2)y_i x_i \\ \sum_{i=1}^N \psi'(s^2)y_i \end{pmatrix}$$

Erweitert man die Funktion  $f$  auf ein beliebig großes Polynom vom Grad  $n$ , so lässt sich das zugehörige Gleichungssystem zur Berechnung der Parameter in  $f$  aufstellen, in dem Gleichung (5.5) bzw. (5.6) ebenfalls erweitert werden. Für ein beliebiges Polynom  $f$  vom Grad  $n$  mit  $f(x) = \sum_{k=0}^n a_k x^k$  ist das zu lösende Gleichungssystem:

$$(5.7) \quad \begin{pmatrix} \sum_{i=1}^N \psi'(s^2)x_i^{2n} & \sum_{i=1}^N \psi'(s^2)x_i^{2n-1} & \dots & \sum_{i=1}^N \psi'(s^2)x_i^n \\ \sum_{i=1}^N \psi'(s^2)x_i^{2n-1} & \sum_{i=1}^N \psi'(s^2)x_i^{2n-2} & \dots & \sum_{i=1}^N \psi'(s^2)x_i^{n-1} \\ \vdots & \vdots & \dots & \vdots \\ \sum_{i=1}^N \psi'(s^2)x_i^n & \sum_{i=1}^N \psi'(s^2)x_i^{n-1} & \dots & \sum_{i=1}^N \psi'(s^2)x_i^0 \end{pmatrix} \begin{pmatrix} a_n \\ a_{n-1} \\ \vdots \\ a_0 \end{pmatrix} = \begin{pmatrix} \sum_{i=1}^N \psi'(s^2)y_i x_i^n \\ \sum_{i=1}^N \psi'(s^2)y_i x_i^{n-1} \\ \vdots \\ \sum_{i=1}^N \psi'(s^2)y_i \end{pmatrix}$$

Dieses Gleichungssystem lässt sich mit Hilfe eines numerischen Löser, wie zum Beispiel dem Gauss-Seidel-Verfahren [Saa03] oder dem Jacobi-Verfahren [Saa03], lösen. Anders als das Gleichungssystem (5.2) sind die Matrix ( $M$ ) auf der linken Seite und der Vektor ( $\vec{y}$ )

auf der rechten Seite der Gleichung in (5.7) vom Ergebnisvektor abhängig, weil  $\psi'(s^2)$  dort berechnet wird. Deshalb muss man das Ergebnis Schritt für Schritt berechnen und das Ergebnis aus dem letzten Schritt für den nächsten einsetzen, solange sich der Ergebnisvektor nicht mehr verändert. Zu Beginn wird der Ergebnisvektor  $\vec{r}_{t=0}$  auf 0 initialisiert und damit  $M_{t=0}$  und  $\vec{y}_{t=0}$  berechnet. Mit Hilfe eines iterativen Löser lässt sich nun  $\vec{r}_{t+1}$  berechnen, welcher wiederum benutzt wird, um  $M_{t+1}$  und  $\vec{y}_{t+1}$  aufzustellen. Das Ganze wird solange wiederholt, bis das Residuum  $\vec{y}_t - M_t \vec{r}_t$  kleiner als eine bestimmte Grenze  $\epsilon_{Grenze}$  ist.  $\epsilon_{Grenze}$  wurde hier auf  $10^{-5}$  gesetzt. Als iterativer Löser wurde das Successive Over-Relaxation-Verfahren (Überrelaxationsverfahren) oder kurz SOR-Verfahren verwendet, wobei der Überrelaxationsparameter  $\omega$  auf 1.8 gesetzt wurde. Da es sich hier um eine Fixpunktiteration handelt, löst man das nichtlineare Gleichungssystem indem man es als Reihe linearer Gleichungssystem approximiert. Die nichtlinearen Gewichte  $\psi'()$  werden nach jeder Lösung des linearen Gleichungssystem aktualisiert.

Zum Lösen des Gleichungssystems (5.7) wurde deshalb folgender Algorithmus benutzt:

**Algorithmus 5.1** Algorithmus zur Bestimmung der Parameter mit Hilfe der histogrammbasierten Regression

---

```

procedure HISTOGRAMMBASIERTEREGRESSION( $\overline{H}_G, \overline{H}_H$ )
  map x = berechneMapZuHistogramm( $\overline{H}_G$ )
  map y = berechneMapZuHistogramm( $\overline{H}_G$ )

   $\vec{r} = 0$ ;
  while (Residuum(M,  $\vec{r}$ ,  $\vec{y}$ ) <  $\epsilon_{Grenze}$ )
  {
    M = BerechneMatrixM (x, y,  $\vec{r}$ );
     $\vec{y}$  = BerechneVektorY (x, y,  $\vec{r}$ );
    r = SOR (M,  $\vec{r}$ ,  $\vec{y}$ );
  }
  return r;
end procedure

```

---


Wird  $f$  als quadratische Funktionen gewählt, so kann der Ergebnisvektor mit Hilfe von (5.3) initialisiert werden, weil das eine bessere Schätzung als  $\vec{0}$  ist und deshalb schneller ans Ziel führen sollte.

## 5.2 Ergebnisse der histogrammbasierten Egalisierung

Anders als in Kapitel 3, wo  $f$  eine lineare Funktion ist, lässt sich  $f$  hier als beliebig großes Polynom vom Grad  $n$  wählen. Die  $N + 1$  Parameter, die zur Bestimmung von  $f$  benötigt werden, lassen sich leicht durch das Lösen des Gleichungssystems (5.7) bestimmen. Die so berechnete Funktion  $f$  lässt sich dann problemlos auf  $I_G$  anwenden, indem jeder Grauwert  $x_i$  auf  $f(x_i)$  abgebildet wird. Zum Vergleich wurden wieder die Werte aus Abbildung 3.1, die den durchschnittlichen Fehler von Bildpaaren einer Bildfolge ohne Anwendung von Helligkeitskompensation zeigt, gewählt.

### 5.2.1 $f$ als lineare Funktion $n = 1$

In Abbildung 5.1 ist der durchschnittliche Fehler nach Anwendung der linearen Funktion  $f$  auf  $I_G$ , deren Parameter mit Hilfe der histogrammbasierten Regression berechnet wurden, mit grünen Balken dargestellt. Die roten Punkte signalisieren die Fehler ohne Anwendung von Helligkeitskompensation. Sind die roten Punkte mit einem „+“ dargestellt, so hat die Helligkeitskompensation in diesen Fällen zu einer Verbesserung beigetragen. Punkte, die mit einem „-“ dargestellt sind, signalisieren eine Verschlechterung gegenüber keiner Helligkeitskompensation.




**Abbildung 5.1:** Vergleich vor und nach Helligkeitskompensation mittels histogrammbasierter Regression ( $n = 1$ ).

Insgesamt kann man viele Verbesserungen gegenüber den Fehlern ohne Anwendung jeglicher Helligkeitskompensation erkennen. Große Fehler insbesondere sind kleiner geworden, während kleine Fehler sich nicht allzu sehr (mit einer Ausnahme) vergrößert haben.


Auch hier lohnt es sich wieder einen Blick auf Bilder, in denen keine Bewegung stattfindet, zu werfen. Für die Bilder aus Abbildung 3.3 wurde deshalb wieder eine Helligkeitsanpassung vorgenommen. Abbildung 5.2 zeigt den direkten Vergleich der Bilder vor und nach der Helligkeitskompensation. In der Mitte von Abbildung 5.2 ist das Bild, das durch Abbildung des linken Bildes mit  $f$  entstanden ist.





**Abbildung 5.2:** Das Bild in der Mitte ist durch Anwenden von  $f$  mit  $n = 1$  auf das linke Bild entstanden.


Der durchschnittliche Fehler ist dabei von 35.063232 auf 8.813232 gesunken. Die so berechnete Funktion  $f$  für  $n = 1$  ist in Abbildung 5.3 zu sehen.



**Abbildung 5.3:** Funktion  $f$  für  $n = 1$ .

### 5.2.2 $f$ als quadratische Funktion $n = 2$

In Abbildung 5.4 ist der durchschnittliche Fehler nach Anwendung der quadratischen Funktion  $f$  auf  $I_G$ , deren Parameter mit Hilfe der histogrammbasierten Regression berechnet wurden, mit grünen Balken dargestellt.




**Abbildung 5.4:** Vergleich vor und nach Helligkeitskompensation mittels histogrammbasierter Regression ( $n = 2$ ).

Wieder signalisieren die roten Punkte die Fehler ohne Anwendung von Helligkeitskompensation. Sind die roten Punkte mit einem „+“ dargestellt, so hat die Helligkeitskompensation in diesen Fällen zu einer Verbesserung beigetragen. Punkte, die mit einem „-“ dargestellt sind, signalisieren eine Verschlechterung gegenüber keiner Helligkeitskompensation.


Insgesamt kann man sehen, dass der Fehler bei vielen Bildpaaren kleiner geworden ist. Wie bereits für  $n = 1$  sind große Fehler kleiner geworden, während kleine Fehler sich nicht allzu sehr vergrößert haben. Der große Fehler in Abbildung 5.1, der bei 15.1 lag, ist jetzt auf 12.1 gesunken. Auch sonst liegt eine Verbesserung gegenüber der Kompensation mit der linearen Funktion vor.

Vergleicht man die Bilder aus Abbildung 3.3 nach Anwendung der quadratischen Funktion  $f$ , kann man wieder eine Verbesserung feststellen. In Abbildung 5.5 sind diese angezeigt, wobei das Bild in der Mitte, das durch Anwenden von  $f$  ( $n = 2$ ) auf das linke entstanden ist, dargestellt ist.



**Abbildung 5.5:** Das Bild in der Mitte ist durch Anwenden von  $f$  mit  $n = 2$  auf das linke Bild entstanden.

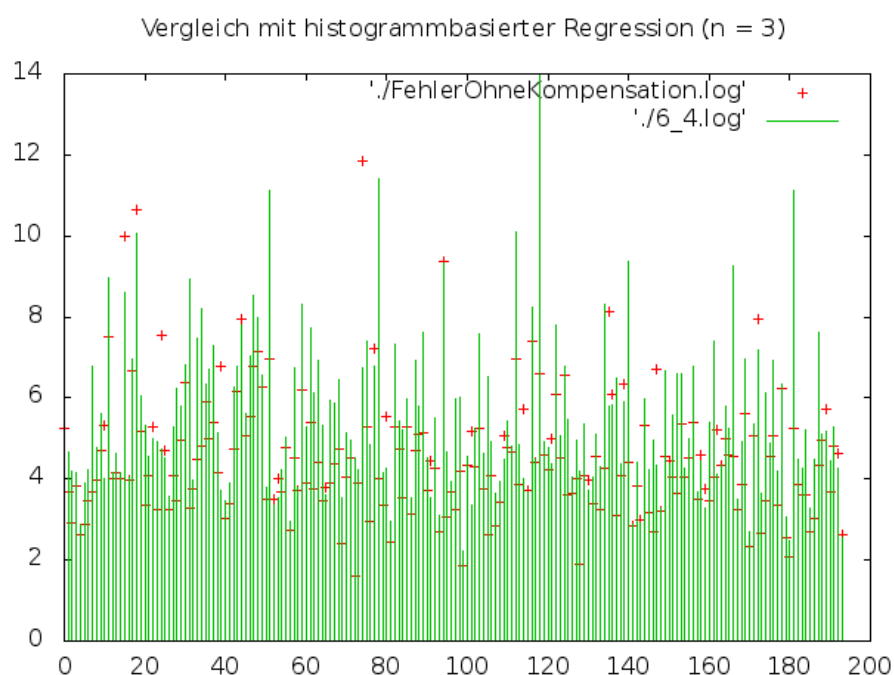
Der durchschnittliche Fehler hat sich noch einmal deutlich verringert und ist von 35.063232 auf 1.254166 gesunken. Die so berechnete Funktion  $f$  für  $n = 2$  ist in Abbildung 5.6 zu sehen.



**Abbildung 5.6:** Funktion  $f$  für  $n = 2$ .

### 5.2.3 $f$ als kubische Funktion $n = 3$


In Abbildung 5.7 ist der durchschnittliche Fehler nach Anwendung der Funktion  $f$  auf  $I_G$ , deren Parameter mit Hilfe der histogrammbasierten Regression berechnet wurden, mit grünen Balken dargestellt. Für diese Abbildung wurde  $f$  als kubische Funktion gewählt. Wie bereits in Kapitel 5.2.1 und 5.2.2 signalisieren rote Punkte die Fehler ohne Anwendung von Helligkeitskompensation. Sind die roten Punkte mit einem „+“ dargestellt, so hat die Helligkeitskompensation in diesen Fällen zu einer Verbesserung beigetragen. Punkte, die mit einem „-“ dargestellt sind, signalisieren eine Verschlechterung gegenüber keiner Helligkeitskompensation.



**Abbildung 5.7:** Vergleich vor und nach Helligkeitskompensation mittels histogrammbasierter Regression ( $n = 3$ ).


Wie man sehen kann, haben sich die Fehler gegenüber  $f$  mit  $n = 2$  verschlimmert. Grund dafür könnte die für  $n = 3$  zu frühe Endbedingung  $\epsilon_{Grenze} = 10^{-5}$  sein. Ein weiterer möglicher Grund ist, dass die Helligkeitsunterschiede in den getesteten Bildpaaren nicht so hoch sind und sich deshalb besser durch eine quadratische Funktion anpassen lassen. Der Koeffizient  $a_3$  für  $x^3$  befindet sich für die getesteten Bildpaare meistens im Bereich von  $10^{-5}$ . Oft nimmt  $a_3$  sogar den Wert 0 an. Eine Auswertung des Verfahrens mit diesen Bildern für  $n = 4$  ist, da  $a_4$  fast immer den Wert 0 annimmt, nicht sinnvoll.

Anders als die Bilder aus der KITTI-Benchmark Datenbank weisen die selbst erstellten Bilder aus Abbildung 3.3 große Helligkeitsunterschiede auf. Deshalb verbessert sich das Ergebnis für die selbst erzeugten Bilder nochmals gegenüber dem Ergebnis für die quadratische Funktion. Der Fehler sinkt von 35.063232 (ohne Kompensation) auf 0.487015 (1.254166 bei  $n = 2$ ). Der Unterschied ist jedoch für das menschliche Auge längst nicht mehr sichtbar (siehe Abbildung 5.7).



**Abbildung 5.8:** Das Bild in der Mitte ist durch Anwenden von  $f$  mit  $n = 3$  auf das linke Bild entstanden.

Die so berechnete Funktion  $f$  für  $n = 3$  ist in Abbildung 5.8 zu sehen.



**Abbildung 5.9:** Funktion  $f$  für  $n = 3$ .

### 5.3 Vergleich der Verfahren

Um einen Eindruck zu kriegen wie gut ein Verfahren ist, wurde jedes vorgestellte Verfahren mit Hilfe des synthetischen Datensatzes aus dem KITTI-Benchmark und dem selbst erzeugten Bildpaar getestet. In Tabelle 5.3 ist der durchschnittliche Fehler der selbst erzeugten Bilder unter Anwendung der verschiedenen Verfahren.

Art des Verfahrens	Informationen	ØFehler
Ohne Helligkeitskompensation	-	35.063232
Statistisches Verfahren	Erwartungswert (Erw.) und Varianz	11.162521
Statistisches Verfahren	Erwartungswert und Totalvariation	16.387390
Statistisches Verfahren	Erw. und Totalvariation (quadrierter Gr.)	19.517273
Histogrammtransformation	Histogrammegalierung	3.086868
Histogrammtransformation	Histogrammspezifikation	0.433304
Histogrammbasierte Regression	$n = 1$	8.813232
Histogrammbasierte Regression	$n = 2$	1.254166
Histogrammbasierte Regression	$n = 3$	0.487015
Histogrammbasierte Regression	$n = 4$	0.366714

**Tabelle 5.3:** Vergleich der verschiedenen Verfahren.

Eine numerische Auswertung der Fehler für die Bilder aus der KITTI-Benchmark Datenbank ist nicht sehr gut geeignet, weil der Optische Fluss, der zur Berechnung der Rücktransformation benötigt wird, meistens nur für die unteren Hälften der Bilder bekannt ist. Zudem ist fraglich, ob die Ground Truth Daten überhaupt pixelgenau vorhanden sind. Bei großen Helligkeitstransformationen, wie zum Beispiel bei der Histogrammegalierung, wird der Fehler wegen Vergleichen zwischen dunklen und hellen Pixeln sehr groß. Verfahren, die die Helligkeit von einem Bild auf ein anderes anpassen, sind dafür besser geeignet.

# 6 Zusammenfassung und Ausblick

## 6.1 Zusammenfassung

In dieser Arbeit wurden verschiedene Verfahren zur Berechnung der Helligkeitskompensation vorgestellt. Das Ziel war es, die Helligkeit von Bildern aus einer Bild- oder Videosequenz anzupassen, um eine bessere Berechnung des Optischen Flusses zu ermöglichen. Die verwendeten Bilder wurden zur einfachen Les- und Schreibbarkeit in das Format *.pgm* konvertiert. Zur Auswertung der verschiedenen Verfahren wurden Bilder aus der KITTI-Benchmark Datenbank [GLU12] und selbst erzeugte Bilder verwendet. Bei den Bilderpaaren aus dem KITTI-Benchmark handelt es sich um Bilder, die beim Fahren aufgenommen wurden und deshalb Bewegung enthalten. Zum Vergleichen wurde das zweite Bild des Bildpaares mit Hilfe des ebenfalls im KITTI-Benchmark vorhandenen Optischen Flusses zurücktransformiert. Bei den selbst erzeugten Bildern ist keine Bewegung vorhanden, weshalb zum Vergleich nicht der Optische Fluss zur Berechnung der Rücktransformation benötigt wurde.

Die ersten drei vorgestellten Verfahren beruhen auf statistischen Größen. Beim ersten Verfahren wurde angenommen, dass der Erwartungswert und die Varianz der Bilder eines Bildpaares gleich sind. So konnte eine lineare Funktion  $f$  aufgestellt werden, mit deren Hilfe das erste Bild des Bildpaares transformiert wurde. Für das zweite Verfahren wurde zusätzlich zum Erwartungswert angenommen, dass die Totalvariation gleich ist. Beim dritten Verfahren wurde anstatt der Totalvariation die Totalvariation mit quadriertem Gradienten, die größere Kontrastunterschiede im Bild stärker gewichtet, benutzt. Beim zweiten und dritten Verfahren konnte, ähnlich wie beim ersten, eine lineare Funktion  $f$  aufgestellt werden, deren Parameter mit Hilfe der genannten Konstanzannahmen berechnet wurden.

Bei den nächsten beiden vorgestellten Verfahren handelte es sich um Histogrammtransformationen. Das erste Verfahren, das mit Histogrammtransformationen gearbeitet hat, hat eine Histogrammegalierung an beiden Bildern der Bildpaare vorgenommen. Das zweite Verfahren hingegen hat eine Histogrammspezifikation, eine Anpassung des Histogramms des ersten Bildes an das des zweiten Bildes, durchgeführt.

Das letzte Verfahren, das vorgestellt wurde, arbeitet mit einer histogrammbasierten Regression, die die Wahl des Grades der zu berechnenden Funktion  $f$  ermöglicht. Das Verfahren wurde um ein Kostenfunktional  $\psi$  erweitert, die große Fehler nicht so stark in die Berechnung von  $f$  einfließen lässt. Zum Lösen des Gleichungssystems wurde das SOR-Verfahren verwendet.

Die Helligkeitskompensationen, die auf statistischen Größen beruhen, zeigen eine Verbesserung der Helligkeitsunterschiede in den Bildpaaren. Allerdings ist die Helligkeitskompensation nicht genau genug, weil nur lineare Transformationen angewandt werden können. Die Histogrammtransformationen (Histogrammegalierung und -spezifikation) führen hingegen zu einer deutlichen Verbesserung, wobei die Histogrammspezifikation noch etwas besser als die Histogrammegalierung ausfällt. Die histogrammbasierte Regression führt mit steigendem Grad der Funktion  $f$  zu einer Verminderung des Fehlers in den Bildpaaren und weist bereits für  $n = 3$  bessere Ergebnisse als die Histogrammspezifikation auf.

### 6.2 Ausblick

Ein großes Problem ist die numerische Auswertung des Fehlers. Die Berechnung des Fehlers mit Hilfe der Rücktransformation ist auf Grund von Ungenauigkeiten des Optischen Flusses nicht so gut geeignet.

Eine Möglichkeit, die Qualität der verschiedenen Verfahren zu bestimmen, wäre, dass man Bildpaare nimmt, die viele Helligkeitsunterschiede, aber keine Bewegung haben. Bilder aus der Natur und im Freien empfehlen sich dabei besonders. Leider ist es schwer, solche Bilder (vor allem in der Natur) zu machen, ohne dass Bewegung im Spiel ist, da zum Beispiel der Wind Blätter und Wasser bewegt. Lichtreflexionen wie in Abbildung 4.7 und 4.8 erschweren eine gute Berechnung des Fehlers. Wenn keine Bewegung in den Bildern vorhanden ist, wird das Problem allerdings deutlich vereinfacht.

Um eine bessere Auswertung zu erhalten, wie gut ein Verfahren ist, könnte man das Programm so erweitern, dass nach der Anwendung der Helligkeitskompensation versucht wird, den Optischen Fluss selbst zu schätzen. Je nachdem wie gut diese Schätzung ausfällt, könnte man sagen, wie geeignet ein Verfahren zur besseren Bestimmung des Optischen Flusses ist.

Eine weitere Möglichkeit wäre nicht nur die Helligkeitsänderung, sondern auch noch gleichzeitig den Optischen Fluss zu schätzen [KMK05]. Ferner könnte man das Programm auch noch so erweitern, dass nicht mehr globale Transformationen, sondern lokal variierende Transformationen berechnet werden [RLB99, PDKK04].



# Literaturverzeichnis

- [AC33] C. R. Adams, J. A. Clarkson. On definitions of bounded variation for functions of two variables. *Transactions of the American Mathematical Society*, 35:824–854, 1933. (Zitiert auf Seite 24)
- [Bru06] A. Bruhn. *Variational Optic Flow Computation: Accurate Modelling and Efficient Numerics*. dissertation, Saarland Universtiy, 2006. (Zitiert auf Seite 12)
- [Bru13] A. Bruhn. *Lecture Notes on Imaging Science*, 2013. (Zitiert auf den Seiten 35 und 40)
- [BSL<sup>+</sup>11] S. Baker, D. Scharstein, J. Lewis, S. Roth, M. J. Black, R. Szeliski. A database and evaluation methodology for optical flow. *International Journal of Computer Vision*, 92(1):1–31, 2011. (Zitiert auf Seite 11)
- [BWS05] A. Bruhn, J. Weickert, C. Schnörr. Lucas/Kanade meets Horn/Schunck: Combining local and global optic flow methods. *International Journal of Computer Vision*, 61(3):211–231, 2005. (Zitiert auf Seite 7)
- [GLU12] A. Geiger, P. Lenz, R. Urtasun. Are we ready for autonomous driving? The KITTI vision benchmark suite. In *Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference on*, S. 3354–3361. IEEE, 2012. (Zitiert auf den Seiten 3, 8, 11, 12, 14 und 55)
- [GW07] R. C. Gonzales, R. E. Woods. *Digital Image Processing*. Prentice Hall, 2007. (Zitiert auf Seite 31)
- [HMB<sup>+</sup>08] G. B. Huang, M. Mattar, T. Berg, E. Learned-Miller, et al. Labeled faces in the wild: A database for studying face recognition in unconstrained environments. In *Workshop on Faces in 'Real-Life' Images: Detection, Alignment, and Recognition*. 2008. (Zitiert auf Seite 7)
- [Hub81] P. J. Huber. *Robust Statistics*. Wiley, New York, 1981. (Zitiert auf Seite 44)
- [KMK05] Y.-H. Kim, A. M. Martínez, , A. C. Kak. Robust motion estimation under varying illumination. *Image and Vision Computing*, 23(1):365–375, 2005. (Zitiert auf Seite 56)
- [Pap03] L. Papula. *Mathematische Formelsammlung. Für Ingenieure und Naturwissenschaftler*, 7, 2003. (Zitiert auf Seite 44)

- [PDKK04] F. Pitie, R. Dahyot, F. Kelly, A. Kokaram. New robust technique for stabilizing brightness fluctuations in image sequences. In *Statistical Methods in Video Processing, ECCV 2004 Workshop on*, S. 153–164. Springer, 2004. (Zitiert auf den Seiten 7 und 56)
- [RLB99] P. M. B. van Roosmalen, R. L. Lagendijk, J. Biemond. Correction of intensity flicker in old film sequences. *Circuits and Systems for Video Technology, IEEE Transactions on*, 9(7):1013–1019, 1999. (Zitiert auf den Seiten 7 und 56)
- [Saa03] Y. Saad. *Iterative methods for sparse linear systems*. Siam, 2003. (Zitiert auf Seite 46)
- [VWB<sup>+</sup>12] L. Valgaerts, C. Wu, A. Bruhn, H.-P. Seidel, C. Theobalt. Lightweight binocular facial performance capture under uncontrolled lighting. *ACM Trans. Graph.*, 31(6):187, 2012. (Zitiert auf Seite 7)

## **Erklärung**

Ich versichere, diese Arbeit selbstständig verfasst zu haben. Ich habe keine anderen als die angegebenen Quellen benutzt und alle wörtlich oder sinngemäß aus anderen Werken übernommene Aussagen als solche gekennzeichnet. Weder diese Arbeit noch wesentliche Teile daraus waren bisher Gegenstand eines anderen Prüfungsverfahrens. Ich habe diese Arbeit bisher weder teilweise noch vollständig veröffentlicht. Das elektronische Exemplar stimmt mit allen eingereichten Exemplaren überein.

---

Ort, Datum, Unterschrift