

Erkennung von Szenenbeleuchtungen aus Bildern eines Fahrzeugkamarasystems zur Verbesserung der Objektdetektion

ALEXANDER HANEL¹, HORST KLÖDEN², LUDWIG HOEGNER¹ & UWE STILLA¹

Zusammenfassung: Zur Erfassung eines Fahrzeugumfeldes werden heutzutage häufig Kameras verwendet. Deren Bilder zeigen nicht nur Objekte der Szene, sondern erlauben auch Aussagen über die Beleuchtungssituation vorzunehmen. Diese Information kann beispielsweise zur Anpassung und Optimierung eines Objektdetektors genutzt werden. In diesem Beitrag wird ein Verfahren vorgestellt, das Aufschluss über die Beleuchtungssituation einer Szene gibt. Zur Unterscheidung verschiedener Beleuchtungssituationen werden mehrere Beleuchtungsklassen definiert. Dabei wird zwischen Beleuchtung unterschieden, die die gesamte Szene betrifft und solcher, die nur einen lokalen Szenenbereich beeinflusst. Aus dem Bild werden grauwertbasierte Merkmale abgeleitet, anhand derer ein Klassifikator das Bild einer Beleuchtungsklasse zuordnet. Dieses Verfahren wird für einen real aufgenommenen Datensatz mit Tag- und Nachtbildern getestet. Es hat sich gezeigt, dass die Beleuchtungsklasse für über 80% der Bilder korrekt bestimmt werden kann.

1 Einfluss von unterschiedlicher Szenenbeleuchtung

1.1 Beleuchtung und Objektklassifikation

Das Erkennen von Objekten im Umfeld eines Fahrzeugs ist heute wichtige Aufgabe für Fahrerassistenzsysteme. Von besonderem Interesse sind dabei Personen, die sich im vorausliegenden Fahrweg des Fahrzeugs befinden. Einen wesentlichen Beitrag zur Unfallvermeidung bildet dabei die Bestimmung ihrer Position, wobei eine hohe Zuverlässigkeit erwartet wird.

Zur Erfassung der Umfeldsituation sind moderne Fahrzeuge deshalb häufig mit Kamerasystemen ausgestattet. Mit Bildern dieser Kameras ist es mit Objektklassifikatoren möglich, Objekte vor dem Fahrzeug zu erkennen, wie beispielsweise Personen. Das Erscheinungsbild einer Person variiert mit der Beleuchtung der Szene (Abb. 1).

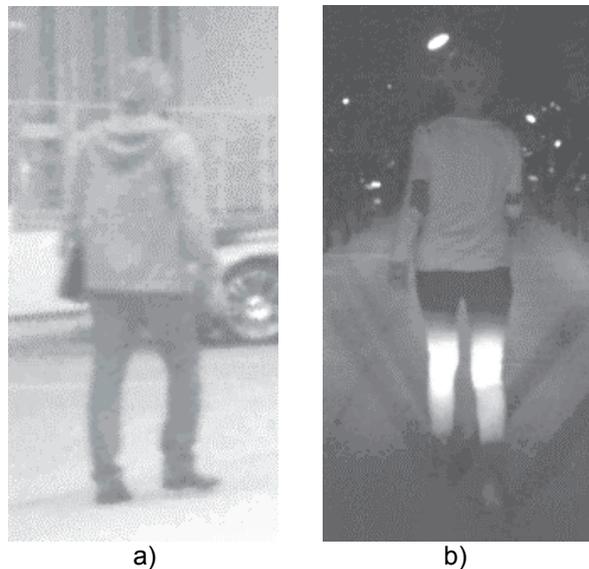


Abb. 1: Bild des Fahrzeugkamarasystems. Unterschiedliche Erscheinungsbilder von Personen: a) am Tag bei starker Bewölkung, b) in der Nacht.

¹ Technische Universität München, Photogrammetrie und Fernerkundung, Arcisstraße 21, 80333 München; E-Mail: [alexander.hanel, ludwig.hoegner, stilla]@tum.de

² BMW Forschung und Technik GmbH, Hanauer Straße 46, 80992 München; E-Mail: horst.kloeden@bmw.de

Bei sinkender Beleuchtung wird typischerweise der Kontrast geringer, was die Wahrnehmung von Texturinformationen erschwert oder verhindert. Mit dem Sinken des Signal-Rausch-Verhältnisses degradieren auch grauwert- und texturbasierte Merkmale für Klassifikatoren.

Objektklassifikatoren sind häufig für ein bestimmtes Erscheinungsbild einer Objektklasse angelemt. Für abweichende Erscheinungsbilder sinkt typischerweise auch die Detektionsgüte des Klassifikators. Es ist deswegen ratsam, für verschiedene Erscheinungsbilder Objektklassifikatoren separat anzulernen und spezifische Parametersätze zu bestimmen. In der Trainingsphase eines Objektklassifikators sollten unterschiedliche Szenen mit ähnlichem Erscheinungsbild (z.B. angestrahltes Objekt vor dunklem Hintergrund) als Stichproben verwendet werden. Um das Klassifikatormodell mit dem passenden Parametersatz nutzen zu können, ist es erforderlich, die entsprechende typische Beleuchtungssituation zu erkennen.

1.2 Definition „Beleuchtungssituation“

Mit dem Begriff *Beleuchtungssituation* wird in diesem Beitrag die Beleuchtung einer Szene bezeichnet, die sich durch Kombinationen mehrerer Beleuchtungsquellen mit unterschiedlicher Position, Richtung und Stärke ergibt (Beispielaufnahme siehe Abb. 2). Die Beleuchtung der Szene kann durch natürliche und künstliche Beleuchtungsquellen erfolgen. Natürliche Quellen wie Sonne und Mond beleuchten die Szene großflächig. Beeinflusst eine Quelle die Beleuchtung der gesamten Szene, so ist im Folgenden von der *globalen* Beleuchtungssituation die Rede. Diese lässt sich in Tag oder Nacht unterscheiden.



Abb. 2: Beispielaufnahme in Grautönen in einem Wohngebiet in der Nacht. Die Ausleuchtung der Umgebung im Bild wird hauptsächlich durch die Fahrzeugscheinwerfer gewährleistet. Das Bild ist zur besseren Darstellbarkeit durch eine Kennlinien-Transformation aufgehellt.

Künstliche Beleuchtungsquellen können beispielsweise Straßenlaternen oder Fahrzeugscheinwerfer darstellen und einen lokalen Bereich der Szene beleuchten. Die *lokale* Beleuchtungssituation ergibt sich aus der globalen und lokalen Beleuchtung.

Generell ist die Beleuchtung der in einem Bild erfassten Szene nicht einheitlich. Dies trifft vor allem auf Bilder von Nachtfahrten zu, die in einer Szene aufgenommen werden, deren Beleuchtung sich aus mehreren Quellen, z. B. Scheinwerferlicht und Straßenlaternen, zusammensetzt. Betrachtet man unterschiedliche lokale Bereiche im Bild, so zeigen diese je nach Blickrichtung und Position der Kamera sowie in Abhängigkeit der vorherrschenden Beleuchtungssituation unterschiedliche Belichtungen.

Die Bewegung eines Fahrzeugs mit hoher Geschwindigkeit erfordert zudem kurze Belichtungszeiten bei der Bildaufnahme, um Bewegungsunschärfe zu vermeiden. Dies führt insbesondere bei dunklen Szenen zu einer zusätzlichen Verschlechterung des Signal-Rausch-Verhältnisses im Bild.

Um bei unterschiedlicher Beleuchtung verschiedene Parametersätze eines Personendetektors anlernen zu können, wird die Vielzahl aller möglichen Beleuchtungssituationen in mehrere Beleuchtungsklassen eingeteilt. Beleuchtungssituation mit geringer Beleuchtung werden in die drei Klassen *Nacht-Stadtzentrum* (Ego-Fahrzeug-, Gegenverkehr- und Straßenbeleuchtung), *Nacht-Wohngebiet* (Ego-Fahrzeug- und Straßenbeleuchtung) und *Nacht-Landstraße* (nur Ego-Fahrzeugbeleuchtung) absteigend unterteilt. Beleuchtungssituationen mit heller Beleuchtung werden hier nur durch die Klasse *Tag* erfasst, die beispielsweise sonnige, schattige oder bewölkte Bereiche der Szene umfassen kann.

2 Arbeiten im Umfeld

In der Literatur sind Merkmale bekannt, die die Qualität von Bildern beschreiben, wie z. B. Unschärfe, Rauschen und Kompression (AVCIBAS et al. 2002). Hierbei ist es auch von Interesse, wie sich die Qualität von Bildern in Abhängigkeit dieser Parameter (z.B. Kompressionsverluste) ändert. Qualitätsmerkmale existieren zum Beispiel basierend auf low-level Bildmerkmalen wie dem sogenannten Minkowsky-Maß (DE RIDDER 1992), das sich aus der pixelweisen Differenz von Intensitätswerten ableiten lässt. Zudem finden wie beispielsweise bei NILL (1992) komplexere Verfahren basierend auf der Transformation der Bildinformationen in den Frequenzraum Anwendung. Ein weiterer Ansatz beschrieben durch SAGHRI et al. (1989) besteht in der Modellierung des menschlichen Sehsystems (HVS, engl. "human visual system model"), um daraus Qualitätsmerkmale abzuleiten. Im Zusammenhang mit der Variation der genannten Parameter liegt in den in diesem Beitrag durchgeführten Untersuchungen ein Augenmerk besonders auf den Variationen der Beleuchtungssituation mit ihrer Wirkung auf die Detektion von Objekten. Direkte Merkmale zur Bestimmung der Beleuchtung aus dem Bild in den Autoren nicht bekannt.

Wie bei den Qualitätsmerkmalen, gibt es auch eine Vielzahl an Standardverfahren zur Objektdetektion. Häufig wird zur dazu eine Kombination aus Deskriptor zur Beschreibung der Bildinformationen und Klassifikator zur Unterscheidung dieser Bildbeschreibungen in verschiedene Objektklassen angewandt.

Ein Deskriptor-Klassifikator-Verfahren zur Personendetektion beschreiben DALAL & TRIGGS (2005), wobei ein HOG-Deskriptor mit einem SVM-Klassifikator verknüpft wird, um eine Aussage über das Vorhandensein oder Nicht-Vorhandensein von Fußgängern zu gewinnen. Das Bild wird dazu rasterförmig mit einem Detektorfenster abgetastet. Es wird dazu in mehrere Blöcke aufgeteilt und für jeden Block eine gewichtete Darstellung über die Ausrichtung von dominierenden Objektkanten ermittelt. Die normalisierten Blöcke dienen als Merkmale. Durch Berücksichtigung der Topologie der Blöcke innerhalb des Detektorfensters können zusätzlich geometrische Informationen erfasst werden. Der SVM-Klassifikator mit einem linearen Kernel lässt es auch für eine hohe Zahl von Trainingsdaten in einer vertretbaren Zeit zu, die Hyperebene zur Trennung der beiden Klassen aufzuspannen.

2.1 Bildmerkmale

Histogrammbasierte Merkmale berechnen sich nach ROSS (2010) aus statistischen Kenngrößen des Grauwertistogramms eines Bildes. Damit ist es möglich, einerseits das Histogramm und dessen Form sowie andererseits das Bild selbst zu charakterisieren. Beispiele hierfür sind der Mittelwert oder die Standardabweichung, die sowohl für die Häufigkeitswerte des Histogramms selbst als auch für das Bild angegeben werden können. Weiterhin wird dadurch beispielsweise das durch ein Bild abgedeckte Grauwertintervall erfasst.

Die Kombination von Intensitätsinformationen mit ihrer geometrischen Verteilung im Bild ermöglichen nach BURGER & BURGE (2006) sowie nach ERHARDT (2008) die sogenannten zentralen Momente der Bildverarbeitung. Diese ermitteln beispielsweise den Schwerpunkt von Helligkeitsverteilungen von Bildpunkten in einem Bild und lassen somit Rückschlüsse auf die Stärke und Position von Beleuchtungsquellen zu.

2.2 Klassifikationsverfahren

Ein gängiges Klassifikationsverfahren ist der Bayes-Klassifikator, dessen Implementierung beispielsweise von FUKUNAGA (1990) beschrieben wird. Dieser Klassifikator gehört zur Gruppe der überwachten Klassifikationsverfahren. Er bestimmt für eine Stichprobe die Wahrscheinlichkeit, mit der sie zu jeder Klasse gehört. Sie wird schließlich derjenigen Klasse mit der höchsten Wahrscheinlichkeit zugeordnet.

Als Zuverlässigkeitsmaße zur Beurteilung von Klassifikationsergebnisse stehen nach SOKOLOVA & LAPALME (2009) und CONGALTON (1991) die Korrektklassifikationsrate (OA) sowie die User's (UA) und Producer's Accuracy (PA) zur Verfügung.

3 Bestimmen der Umgebungsbeleuchtung

In dem vorliegenden Beitrag wird eine Methode (Ablaufschema siehe Abb. 3) vorgestellt, mit der die Beleuchtungssituation aus den Bildern eines Fahrzeugkameranagements (Ab. 2) bestimmt werden kann. Betrachtet ein Mensch ein Bild, so kann er intuitiv eine Aussage über die Beleuchtung in dieser Aufnahme abgeben. Ein maschinelles System hingegen muss aus dem Bild erst eine Beschreibung ableiten, die die Informationen innerhalb des Bildes über die in der Szene vorherrschenden Beleuchtungsbedingungen extrahiert. Diese Beschreibung basiert auf

Bildmerkmalen. Anschließend kann anhand der Merkmale das Bild einer der genannten Beleuchtungsklassen zugewiesen werden.

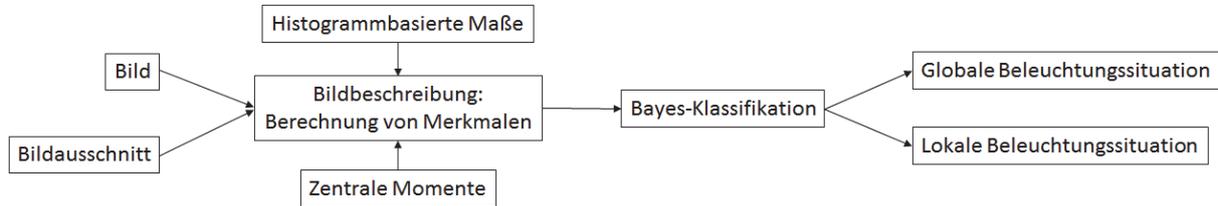


Abb. 3: Ablaufschema zur Bestimmung der Beleuchtungssituation. Ausgehend von einem Bild oder Bildausschnitt wird eine Bildbeschreibung abgeleitet. Eine Klassifikation anhand dieser Beschreibung ermittelt die Beleuchtungsklasse für die globale sowie lokale Beleuchtungssituation der im Bild dargestellten Szene.

3.1 Bildbeschreibung und Klassifikation

Als Bildbeschreibung werden die in 2.1 dargestellten Merkmale verwendet. Sowohl die histogrammbasierten Merkmale als auch die zentralen Momente der Bildverarbeitung umfassen eine Vielzahl von Einzelmerkmalen. Der Wert für jedes Einzelmerkmal kann für ein bestimmtes Bild oder einen Bildausschnitt berechnet werden. Die Zusammenfassung aller Werte für ein bestimmtes Bild oder beziehungsweise Bildbereich in einem Vektor bildet dessen Merkmalsvektor. Um die globale Beleuchtung ermitteln zu können, wird diese Berechnung für ein gesamtes Bild durchgeführt. Um die lokale Beleuchtung zu bestimmen, wird die Berechnung für einen Bildausschnitt durchgeführt. Der Bildausschnitt ergibt sich aus einem Fenster, das in einem Sliding-Window-Verfahren rasterförmig über das gesamte Bild geschoben wird. Dieses Fenster kann sich in Position, Form und Größe am Suchfenster eines Objektdetektors orientieren. Für einen Personendetektor eignet sich beispielsweise ein vertikal ausgerichtetes Rechteck.

Mit einem Klassifikationsalgorithmus wird der Merkmalsvektor ausgewertet. Ein solcher Algorithmus weist ein Bild oder einen Bildausschnitt einer Beleuchtungsklasse zu. Dazu wird der in 2.2 beschriebene Bayes-Klassifikator verwendet. Wird mit dem Klassifikator der Merkmalsvektor eines gesamten Bildes ausgewertet, so wird dadurch die Beleuchtungsklasse für die globale Beleuchtungssituation ermittelt. Wird hingegen nur ein lokaler Bildausschnitt ausgewertet, so wird dadurch die Beleuchtungsklasse für die lokale Beleuchtungssituation bestimmt.

Zuvor muss der Klassifikator mit einem Datensatz angelehrt werden, das heißt die Parameter des Klassifikatormodells werden bestimmt. Dieses Verfahren findet für gesamte Bilder und Bildausschnitte getrennt statt. Ein Datensatz besteht dabei aus einer Menge von Bildern oder Bildausschnitten aller Beleuchtungsklassen. Um diese als Trainingsdaten verwenden zu können, muss der Merkmalsvektor berechnet und die Klassenzugehörigkeit bekannt sein.

Anschließend ist es möglich, Bilder oder Bildausschnitte ohne vorab bekannte Klassenzugehörigkeit anhand des Klassifikatormodells einer bestimmten Beleuchtungsklasse zuzuordnen.

Durch Verknüpfen der globalen und lokalen Beleuchtungsaussage wird für einen bestimmten Bildausschnitt eine kombinierte Aussage über die Beleuchtung des Teils der Szene getroffen, der

im Ausschnitt abgebildet ist. Dadurch kann die globale Beleuchtung der Szene mit lokalen Variationen der Beleuchtung innerhalb der Szene in Verbindung gesetzt werden.

3.2 Anpassen des Objektdetektors an die Beleuchtungssituation

Ist die globale und lokale Beleuchtungssituation für einen Bildausschnitt bekannt, kann das passende Detektormodell eines Objektdetektors ausgewählt werden. Zur Verknüpfung von Beleuchtung und Detektormodell wird eine Look-Up-Tabelle verwendet. Diese speichert in einer 2D-Matrix für jede Kombination aus globaler und lokaler Beleuchtungssituation die Information, welcher Deskriptor und Klassifikator mit welchen Parametern am besten zur Detektion eines Objektes geeignet ist.

4 Anwendung und Ergebnisse

Die beschriebene Vorgehensweise wird im Folgenden auf einen Beispieldatensatz angewendet. Dieser besteht aus positiven sowie negativen Bildausschnitten mit der Größe 320x160 Pixel. Diese Bildausschnitte entstammen den Trainingsdaten eines Personendetektors. Positive Bildausschnitte (Abb. 4a) enthalten somit die Abbildung einer Person mit einem bestimmten Hintergrundanteil in jede Richtung um die Person herum. Negative Bildausschnitte (Abb. 4b) enthalten die Abbildung willkürlicher Objekte in der Szene, jedoch keine Personen.

Insgesamt werden in allen Beleuchtungsklassen zusammen etwa 18.000 positive sowie 60.000 negative Bildausschnitte verwendet. Ein solches Übergewicht an negativen Stichproben ist typisch für Objektklassifikationsverfahren, wie zum Beispiel DALAL & TRIGGS (2005) zeigen. Weiter stehen 32.000 Gesamtbilder zur Verfügung, aus denen die Bildausschnitte gewonnen wurden. Der Anteil an Bildern aus der Beleuchtungsklasse *Nacht-Wohngebiet* beträgt etwa 38%, aus *Nacht-Stadtzentrum* etwa 29%, aus *Nacht-Landstraße* etwa 19% sowie 14% für die *Tag*-Klasse. Die Ungleichverteilung kommt daher zustande, dass in städtischen Gebieten mit einer höheren Zahl an Fußgängern zu rechnen ist und diese Gebiete somit für die Fußgängerdetektion von besonderem Interesse sind. Für alle Daten ist bekannt, welcher Beleuchtungskategorie sie angehören.

Für die drei genannten Bildgruppen werden die Merkmale getrennt berechnet und somit die Merkmalsvektoren abgeleitet. Die Gesamtmenge der Daten wird anschließend nach dem

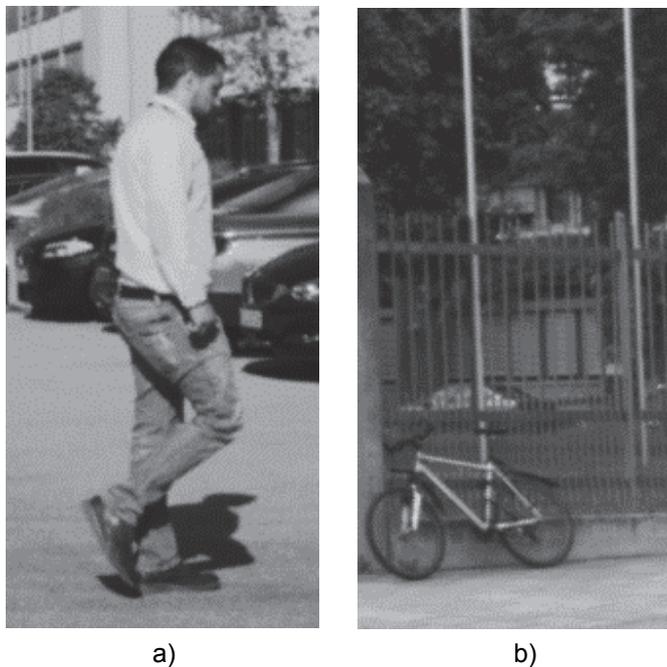


Abb. 4: Bildausschnitte zum Anlernen eines Personendetektors: a) positiver Bildausschnitt, b) negativer Bildausschnitt.

Zufallsprinzip aufgespaltet in einen 80%-Anteil, welcher zum Training verwendet wird und in einen 20%-Anteil, welcher der Validierung dient.

Mit den Trainingsdaten kann somit der beschriebene Bayes-Klassifikator angelehrt werden. Mit dessen Modell können schließlich die Merkmalsvektoren der Validierungsdaten einer Beleuchtungsklasse zugewiesen und durch Vergleich mit deren tatsächlicher Klassenzugehörigkeit (ground truth) die beschriebenen Zuverlässigkeitsmaße abgeleitet werden. Im Folgenden werden die Ergebnisse der Beleuchtungsklassifikation vorgestellt. Dabei werden die beschriebenen Zuverlässigkeitsmaße für die Bildgruppen der positiven Bildausschnitte (Tabelle 1), der negativen Bildausschnitte (Tabelle 2) sowie für Gesamtbilder (Tabelle 3) angegeben.

Tab. 1: Zuverlässigkeitsmaße für positive Bildausschnitte der unterschiedlichen Beleuchtungsklassen.

Klasse	UA	PA	OA
Wohngebiet	69,63%	86,21%	82,63%
Stadtzentrum	94,51%	67,47%	
Landstraße	66,81%	95,77%	
Tag	98,31%	96,13%	

Tab. 2: Zuverlässigkeitsmaße für negative Bildausschnitte der unterschiedlichen Beleuchtungsklassen.

Klasse	UA	PA	OA
Wohngebiet	77,68%	77,87%	86,12%
Stadtzentrum	83,44%	85,21%	
Landstraße	58,62%	48,30%	
Tag	97,34%	95,42%	

Tab. 3: Zuverlässigkeitsmaße für Gesamtbilder der unterschiedlichen Beleuchtungsklassen.

Klasse	UA	PA	OA
Wohngebiet	89,42%	99,33%	96,01%
Stadtzentrum	99,46%	88,45%	
Landstraße	98,19%	100%	
Tag	100%	99,78%	

Es lässt sich zeigen, dass mit dem beschriebenen Verfahren die Beleuchtungsklassifikation für Gesamtbilder nahezu fehlerfrei möglich ist. Die zugehörige Korrektklassifikationsrate liegt bei einem Wert von 96%, was bedeutet, dass nur etwa jedes 20. Bild einer falschen Klasse zugeordnet wird. Für Bildausschnitte, egal ob positiv oder negativ, können leicht niedrigere Werte für die Korrektklassifikationsrate erzielt werden. Im Vergleich untereinander erzielt die Beleuchtungsklassifikation der negativen Bildausschnitte einen etwas höheren Wert als die Klassifikation der positiven Bildausschnitte. Dieser Unterschied in der Zuverlässigkeit ist wahrscheinlich darauf zurückzuführen, dass sich bei den positiven Bildausschnitten Personen mit unterschiedlichem Erscheinungsbild im Bildvordergrund befinden. So können Personen beispielsweise sehr hell oder sehr dunkel gekleidet sein. Die hingegen beliebig aus dem Bild einer

Straßenszene entnommenen negativen Bildausschnitte enthalten häufiger Objekte aus dem Bildhintergrund, wie zum Beispiel geparkte Fahrzeuge oder Asphalt. Derartige Objekte unterliegen gerade bei Nachtaufnahmen einer geringeren Bandbreite an möglichen Erscheinungsformen.

Verwechslungen zwischen den Klassen treten hauptsächlich innerhalb der unterschiedlichen Nachtklassen auf, was an den niedrigeren Werten für die UA und PA im Vergleich zur Tagklasse festzumachen ist. Auffällig ist, dass bei den positiven Bildausschnitten die Klasse *Stadtzentrum* einen deutlich niedrigeren Wert für die PA aufweist, als alle anderen Klassen. Die beiden anderen Nachtklassen haben hingegen einen deutlich niedrigeren Wert für die UA. Das bedeutet, dass Stichproben der Klasse *Stadtzentrum* häufig einer der beiden anderen Nachtklassen zugewiesen werden. Wird beispielsweise eine Person in einem Bildausschnitt der tatsächlichen Klasse *Stadtzentrum* stark vom Scheinwerfer des Eigenfahrzeugs angestrahlt, aber kaum von der für diese Kategorie typischen Straßenbeleuchtung, so ordnet der Beleuchtungsklassifikator diesen Bildausschnitt mit hoher Wahrscheinlichkeit der Klasse *Landstraße* oder *Wohngebiet* zu, da bei diesen Klassen die Fußgänger häufig nur vom Scheinwerfer, nicht aber von anderweitigen Beleuchtungsquellen beleuchtet werden. Bei den negativen Bildausschnitten kehrt sich die Beobachtung um, das bedeutet, Bildausschnitte der tatsächlichen Klasse *Stadtzentrum* werden häufig korrekt zugeordnet, was sich an der im Vergleich hohen PA zeigt. Für die beiden anderen Nachtklassen ist der Wert dieser Größe hingegen deutlich gesunken. Für Gesamtbilder sind Falschzuordnungen bei keiner der drei Nachtklassen nennenswert vorhanden, was sich an den durchgängig sehr hohen Werten für UA und PA zeigt. Allen Arten von Bildern beziehungsweise Bildausschnitten haben gemeinsam, dass die *Tag*-Klasse mit einer noch höheren Zuverlässigkeit korrekt klassifiziert werden kann als die Nachtklassen.

Für einen Personendetektor auf Basis des HOG-SVM-Modells ergibt sich bei Verwendung eines einheitlichen Parametersatzes für alle Beleuchtungsklassen eine mittlere Precision von etwa 40%. Bei einem separat für jede Beleuchtungsklasse angelegten Parametersatz kann für die drei Nachtklassen eine mittlere Precision von 60% bis etwa 85% erreicht werden. Lediglich für die *Tag*-Klasse stagniert der Wert bei 40%. Die Zuverlässigkeit der Personendetektion lässt sich somit durch Berücksichtigen der Beleuchtungssituation bei Wahl der Parameter erhöhen. Eine ausführliche Darstellung der Ergebnisse der Personendetektion ist in einer vorausgegangenen Masterarbeit (HANEL, 2014) enthalten.

5 Fazit und Ausblick

Dieser Beitrag stellt ein Verfahren vor, mit dem die Beleuchtungssituation einer Szene aus Bildern bestimmt werden kann. Dazu werden low-level Merkmale definiert, die eine Beschreibung des Bildes erlauben. Auf deren Basis ist es möglich, einem Bild eine bestimmte Beleuchtungssituation zuzuweisen. Somit können je nach erkannter Beleuchtungssituation unterschiedliche Parameter für einen Objektdetektor verwendet werden.

Die Ergebnisse zeigen, dass zur Bestimmung der Beleuchtungssituation lediglich einfache, auf den Bildintensitäten zu berechnende Merkmale verwendet werden. Es sind keine rechenintensiven Transformationsverfahren oder Merkmale, die ein Referenzbild zum Vergleich verwenden, notwendig. Die Zuverlässigkeit des Verfahrens ist sowohl für gesamte Bilder als auch für

Bildausschnitte sehr hoch. Das Verfahren führt beim verwendeten Datensatz zu einer deutlichen Steigerung der Gesamtklassifikationsgüte und somit der Zuverlässigkeit der Objektdetektion gegenüber einer Verwendung ohne vorhergehende Erkennung der Beleuchtungssituation.

Es hat sich bei den Experimenten gezeigt, dass die höchsten Einbußen der Zuverlässigkeit bei Verwechslungen von Klassen auftreten. Es wäre zu untersuchen, welche Merkmale eine stabilere Klassifikation ermöglichen könnten. Zudem gilt es zu untersuchen, welche zusätzlichen Beleuchtungsklassen identifiziert und unterschieden werden müssen, um eine weitere Steigerung der Korrekturklassifikationsrate zu erzielen. In der vorliegenden Arbeit wurde für Tagsituationen nur eine Beleuchtungsklasse gewählt. Es ist anzunehmen, dass beispielsweise bei Gegenlicht (tiefstehende Sonne) oder Tunnelfahrten besondere Verhältnisse vorliegen könnten, die in zusätzliche Beleuchtungsklassen eingeteilt werden könnten. Auch scheinen es ratsam für verschiedene Witterungssituationen (z.B. Nebel, Regen, Schneefall), die spezielle Beleuchtungssituationen bedingen, weitere Einteilungen der Klassen vorzunehmen und durch Parameterstudien zu untersuchen.

6 Literaturverzeichnis

- AVCIBAS, I., SANKUR, B. & SAYOOD, K., 2002: Statistical evaluation of image quality measures. *Journal of Electronic Imaging* **11** (2), S. 206-223.
- BURGER, W. & BURGE, M., 2006: *Digitale Bildverarbeitung*. Springer, 529 S.
- CONGALTON, R. G., 1991: A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37 (1), S. 35-46.
- DALAL, N. & TRIGGS, B., 2005: Histograms of oriented gradients for human detection. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2005)* **1**, S. 886-893.
- DE RIDDER, H., 1992: Minkowsky Metrics as a Combination Rule for Digital Image Coding Impairments. *Human Vision, Visual Processing, and Digital Display III, Proc. SPIE* **1666**, S. 17-27.
- ERHARDT, A., 2008: *Einführung in die Digitale Bildverarbeitung: Grundlagen, Systeme und Anwendungen*. Vieweg und Teubner Verlag.
- HANEL, A., 2014: *Bestimmen der Beleuchtungsverhältnisse und Optimieren der Fußgängerdetektion aus Bildern eines Fahrzeugkameranagements*. Masterarbeit, Technische Universität München, Ingenieur fakultät Bau Geo Umwelt, Fachgebiet Photogrammetrie und Fernerkundung.
- FUKUNAGA, K., 1990: *Introduction to Statistical Pattern Recognition (2nd Ed.)*. Academic Press Professional, Inc.
- NILL, N. B., 1992: Objective image quality measure derived from digital image power spectra. *Optical engineering* **31** (4), S. 813-825.
- ROSS, S., 2010: *Introductory Statistics*. Elsevier Science.
- SAGHRI, J. A., CHEATHAM, P. S. & HABIBI A., 1989: Image quality measure based on a human visual system model. *Optical engineering* **28** (7), S. 813-818.
- SOKOLOVA, M. & LAPALME, G., 2009: A Systematic Analysis of Performance Measures for Classification Tasks. *Information Processing & Management* **45** (4), S. 427-437.