

Lehrstuhl für Mensch-Maschine-Kommunikation
Technische Universität München

Kamerabasierte Nebeldetektion und Sichtweitenschätzung im Fahrzeug

Mario Pavlić

Vollständiger Abdruck der von der Fakultät für Elektrotechnik und Informationstechnik
der Technischen Universität München zur Erlangung des akademischen Grades eines

Doktor-Ingenieurs (Dr.-Ing.)

genehmigten Dissertation.

Vorsitzender: Univ.-Prof. Dr.-Ing. Thomas Eibert
Prüfer der Dissertation: 1. Univ.-Prof. Dr.-Ing. habil. Gerhard Rigoll
2. Univ.-Prof. Dr.-Ing. habil. Walter Stechele

Die Dissertation wurde am 15.11.2013 bei der Technischen Universität München eingereicht
und durch die Fakultät für Elektrotechnik und Informationstechnik am 23.05.2014 angenom-
men.

Kurzzusammenfassung

Dichter Nebel wird immer wieder als Grund für folgenschwere Unfälle im Straßenverkehr genannt. Auch wenn statistisch betrachtet andere Unfallursachen bedeutsamer erscheinen, so resultieren diese meist in Massenkarambolagen mit einer Vielzahl verletzter Verkehrsteilnehmer. Die Lokale Gefahrenwarnung vor eingeschränkten Sichtverhältnissen versucht diesen durch frühzeitige Hinweise vorzubeugen. Da jedoch hierzu die Vorausschau der in heutigen Fahrzeugen verfügbarer Sensoren nicht ausreichend ist und die aus der Infrastruktur verfügbaren Daten eine zu geringe Abdeckung aufweisen, wird eine Car-to-Infrastructure Architektur verfolgt. Fahrzeuge dienen dabei als eine Art mobile Messstation und liefern Daten an ein zentrales Backend, in welchem diese mit lokalen Messdaten fusioniert werden. Dadurch soll eine zuverlässige, rechtzeitige und gezielte Warnung ermöglicht werden. Hierzu werden jedoch Fahrzeuge benötigt, welche in der Lage sind ein solches Ereignis zu erkennen. Da Kamerasysteme immer häufiger zur Ausstattung zählen und da sich Bilder mit dichtem Nebel von Bildern mit klaren Sichtverhältnissen deutlich unterscheiden, soll in dieser Arbeit ein Verfahren zur maschinellen Nebeldetektion entwickelt werden. Hierzu wird eine Klassifizierungsprozedur vorgestellt, welche anhand von spektralbasierten Merkmalen sowohl bei Tag als auch bei Nacht mit und ohne eingeschaltetem Fernlicht eine zuverlässige Unterscheidung ermöglicht. Das Leistungsspektrum wird dabei einer zweistufigen Merkmalsreduktion unterzogen, welche aus einer Abtastung im Frequenzbereich mittels einer neu vorgestellten Gabor Bandpass Filterbank sowie einer anschließenden Hauptkomponentenanalyse besteht. Dadurch erzielt bereits ein linearer Klassifikator ein hohes Trennvermögen. Die vorgestellte Klassifizierungsprozedur wird schließlich anhand einer ausgiebigen Evaluierung untersucht und mit bekannten Merkmalen aus der Bildverarbeitung verglichen.

Inhaltsverzeichnis

Abkürzungsverzeichnis	vii
Abbildungsverzeichnis	x
Tabellenverzeichnis	xi
1 Einleitung	1
2 Nebel und Sichtweite	7
2.1 Radiometrische Grundlagen	8
2.2 Photometrische Grundlagen	12
2.3 Grundlegende Eigenschaften der Streuung	13
2.4 Atmosphärische Streuung	15
2.4.1 Dämpfung	15
2.4.2 Airlight	16
2.4.3 Sichtbarkeit entfernter Objekte	18
2.5 Praktische Anwendung in der Meteorologie	19
2.5.1 Visuelle Sichtweitenschätzung	19
2.5.2 Instrumentelle Sichtweitenschätzung	21
2.5.2.1 Telephometer	21
2.5.2.2 Visuelle Extinktiometer	21
2.5.2.3 Transmissometer	22
2.5.2.4 Scatterometer	22
2.6 Meteorologische Sichtbereiche	25
3 Stand der Technik	27
3.1 Statische Nebeldetektion und Sichtweitenschätzung	27
3.2 Prozentuale Sichtbeeinträchtigung	28
3.3 Sichtweitenschätzung mittels Extinktionskoeffizient	30
3.4 Entfernung zum sichtbaren Horizont	34
3.5 Stereokamerabasierter Ansatz	34

3.6	Sichtweitenschätzung und Nebeldetektion bei Nacht	36
3.7	Nebeldetektion mittels Klassifizierungsprozedur	38
3.8	Diskussion	39
4	Bildbasierte Nebelerkennung	45
4.1	Spektralbasierter Ansatz	46
4.1.1	Vorverarbeitung	48
4.1.2	Merkmalsextraktion	49
4.1.3	Merkmalsreduktion	50
4.1.4	Klassifizierung	54
4.2	Weitere Bild-Deskriptoren	55
4.2.1	Histogramme	56
4.2.2	Haralick Merkmale	57
4.2.3	Wavelet-Koeffizienten	58
4.3	Segmentierung	62
5	Evaluierung	63
5.1	Datenquelle	64
5.2	Datengrundlage und Evaluierungsmethode	65
5.3	Evaluierung der Filterparameter	69
5.3.1	Gabor Filterbank	69
5.3.2	Bandpass Filterbanken	75
5.4	Evaluierung der Merkmale	79
5.5	Evaluierung der Segmentierung	84
5.6	Zusammenfassung der Evaluierungsergebnisse	86
6	Zusammenfassung und Ausblick	95
	Literatur	99

Abkürzungsverzeichnis

CBIR	Content Based Image Retrieval
CIE	Internationale Beleuchtungskommission
DFT	Diskrete Fouriertransformation
DWT	Diskrete Wavelet-Transformation
EOVAST	Electro-Optical Visualization and Simulation Tool
FAS	Fahrerassistenzsysteme
FB	Frequenzband
FLA	Fernlichtassistent
FWT	Fast Wavelet Transform
GLCM	Gray Level Co-Occurance Matrix
GPS	Global Positioning System
HAF	Hochautomatisiertes Fahren
HGM	Histogram of Gradient Magnitudes
HOG	Histogram of Oriented Gradients
IVC	International Visibility Code
LDA	Lineare Diskriminantenanalyse
LDW	Lane Departure Warning
LGW	Lokale Gefahrenwarnung
MAP	Maximum-a-Posteriori

Abkürzungsverzeichnis

MCC	Matthews Correlation Coefficient
MOR	Meteorological Optical Range
PCA	Principal Components Analysis
RALPH	Rapidly Adapting Lateral Position Handle
RMSC	Root Mean Square Contrast
RoI	Region of Interest
RSVP	Rapid Serial Visual Presentations
SI	Internationales Einheitensystem (franz. Système international d'unités)
SIFT	Scale-Invariant Feature Transform
SLI	Speed Limit Information
StVO	Straßenverkehrsordnung
SVM	Support Vector Machine
TEC	Traffic Event Compact
TMC	Traffic Message Channel
TPEG	Transport Protocol Experts Group
WDTACS	Weighted Distance Transform On Curved Space
WMO	World Meteorological Organization
xFCD	Extended Floating Car Data
ZNSSD	Zero Mean Normalized Sum of Squared Differences

Abbildungsverzeichnis

1.1	Car-to-Infrastructure Architektur der LGW	2
2.1	Lambert'sches Kosinusgesetz und effektive Fläche	9
2.2	Raumwinkel und inverses Abstandsgesetz	9
2.3	Lichtausbeute des menschlichen Auges	13
2.4	Streumuster an Partikel	14
2.5	Dämpfung des Lichts durch Streuung	16
2.6	Airlight	17
2.7	Transmissometer	23
2.8	Scatterometer	24
2.9	Anhalteweg, Sichtweite und Fahrzeuggeschwindigkeit	26
3.1	Stationärer Ansatz von Busch und Debers	28
3.2	Prozentualer Ansatz von Pomerleau	29
3.3	Intensitätsprofile aus zweilenweise verschobenem Areal Image	30
3.4	Intensitätsfunktion	32
3.5	Ansatz von Hautière <i>et al.</i>	33
3.6	Sichtweitemenschätzung mittels Stereoskopie	35
3.7	Ergebnisse Sichtweitemenschätzung mittels Stereoskopie	35
3.8	Sichtweitemenschätzung bei Nacht anhand der Fahrzeugscheinwerfer	37
3.9	Simulierte Referenzbilder unterschiedlicher Sichtweiten	37
3.10	Nebeldetektion bei Nacht anhand externer Lichtquellen	38
4.1	Cycles per Pixel	46
4.2	Übersicht bildbasierte Nebelerkennung	48
4.3	Einzelschritte der Vorverarbeitung	49
4.4	Beispiele zur Vorverarbeitung	49
4.5	Fahrscenen mit und ohne Nebel und korrespondierende Leistungsspektren	50
4.6	Gabor Filterbank	52
4.7	Ring-Filterbank	54
4.8	Fisher LDA	56

4.9	Aufbau HOG	57
4.10	Beispiel Gray Level Co-Occurrence Matrix	58
4.11	Wavelet Filterbank	61
4.12	Wavelet Pyramide	61
4.13	Segmentierung	62
5.1	Eingesetztes Kamerasystem	64
5.2	Rohbild der Kamera	65
5.3	Beispielfelder für die Nebel-Kategorien	67
5.4	Beispielfelder für unterschiedliche Autobahn-Typen	67
5.5	Exemplarische Nachtaufnahmen	68
5.6	Evaluierungsergebnisse Gabor Filterbanken bei Tag	70
5.7	Evaluierungsergebnisse Gabor Filterbanken bei Nacht mit Fernlicht	72
5.8	Evaluierungsergebnisse Gabor Filterbanken bei Nacht ohne Fernlicht	73
5.9	Evaluierete Gabor Filterbanken	74
5.10	Evaluierete Bandpass Filterbanken	75
5.11	Evaluierungsergebnisse Bandpass Filterbanken bei Tag	77
5.12	Evaluierungsergebnisse Bandpass Filterbanken bei Nacht mit Fernlicht	78
5.13	Evaluierungsergebnisse Bandpass Filterbanken bei Nacht ohne Fernlicht	79
5.14	Erkennungsraten HOG-Merkmale	81
5.15	Erkennungsraten HGM-Merkmale	81
5.16	Erkennungsraten GLCM-Merkmale	82
5.17	Erkennungsraten Wavelet-Merkmale	82
5.18	Beispiele für False Negatives bei Tag	88
5.19	Beispiele für True Positives bei Tag	88
5.20	Beispiele für False Positives bei Tag	89
5.21	Beispiele für True Negatives bei Tag	89
5.22	Beispiele für False Negatives bei Nacht mit Fernlicht	90
5.23	Beispiele für True Positives bei Nacht mit Fernlicht	90
5.24	Beispiele für False Positives bei Nacht mit Fernlicht	91
5.25	Beispiele für True Negatives bei Nacht mit Fernlicht	91
5.26	Beispiele für False Negatives bei Nacht ohne Fernlicht	92
5.27	Beispiele für True Positives bei Nacht ohne Fernlicht	93
5.28	Beispiele für False Positives bei Nacht ohne Fernlicht	93
5.29	Beispiele für True Negatives bei Nacht ohne Fernlicht	94

Tabellenverzeichnis

2.1	Radiometrische Größen	10
2.2	Photometrische Größen	12
2.3	Eigenschaften relevanter Teilchen bei der atmosphärischen Streuung . . .	14
2.4	Internationaler Sichtweiten Code	25
4.1	Haralick-Deskriptoren	59
5.1	Aufgenommene Messdaten bei Tag	66
5.2	Aufgenommene Messdaten bei Nacht	66
5.3	Filterbank Konfigurationen	69
5.4	Evaluierungsergebnisse Gabor Filterbank bei Tag	70
5.5	Evaluierungsergebnisse Gabor Filterbank bei Nacht mit Fernlicht	72
5.6	Evaluierungsergebnisse Gabor Filterbank bei Nacht ohne Fernlicht	73
5.7	Evaluierungsergebnisse Bandpass Filter bei Tag	77
5.8	Evaluierungsergebnisse Bandpass Filter bei Nacht mit Fernlicht	78
5.9	Evaluierungsergebnisse Bandpass Filter bei Nacht ohne Fernlicht	79
5.10	Evaluierungsergebnisse unterschiedlicher Merkmale	83
5.11	Evaluierungsergebnisse Segmentierung	85

Einleitung

Kamerabasierte Fahrerassistenzsysteme (FAS) sind eine Kerntechnologie intelligenter Fahrzeuge. Bekannte Funktionen sind der Spurhalteassistent (Lane Departure Warning, LDW) [9], welcher z.B. durch eine haptische Rückmeldung am Lenkrad vor einem unbeabsichtigtem Überqueren der Fahrspur warnt, die Schilderkennung (Speed Limit Information, SLI) [30], welche den Fahrer z.B. durch eine visuelle Anzeige im Kombi-Instrument auf eine geltende Geschwindigkeitsbegrenzung oder ein Überholverbot aufmerksam macht, oder der Fernlichtassistent (FLA) [3], welcher das Fernlicht einschaltet, wenn in einer unzureichend ausgeleuchteten Umgebung kein vorausfahrendes oder entgegenkommendes Fahrzeug vorhanden ist. All diese Systeme detektieren konkrete Objekte im Bild, wie z.B. Fahrspuren, Verkehrsschilder oder Lichtquellen vorausfahrender bzw. entgegenkommender Fahrzeuge. Dem Erkennen allgemeiner Bildeigenschaften, wie z.B. die aktuellen Wetterbedingungen, wurde bisher nur wenig Beachtung geschenkt. Eine solche Information kann jedoch sehr wertvoll sein, um einerseits bestehende Funktionen zu verbessern und andererseits neue Anwendungsgebiete im Bereich der Fahrerassistenz zu eröffnen.

Die vorliegende Arbeit befasst sich mit der Aufgabe, eine bestimmte Fahrsituation anhand von Kameradaten zu erfassen. Im Konkreten soll erkannt werden, ob sich das Fahrzeug in einer Situation mit dichtem Nebel befindet, in welcher der Fahrer aufgrund der stark eingeschränkten Sichtbedingungen infolge von Nebelbildung in seiner Fahraufgabe eingeschränkt ist. Motiviert wird die Arbeit durch die von Georg Obert vorgestellte *Lokale Gefahrenwarnung* (LGW) [91]. Ziel der LGW ist es, den Fahrer durch eine akustische und/oder visuelle Information rechtzeitig und räumlich präzise auf eine gefährliche Situation hinzuweisen, welche im direkten örtlichem Bezug zu seiner Fahrstrecke liegt. Eine Studie des Lehrstuhls für Verkehrstechnik der Technischen Universität München hat dabei gezeigt, dass der optimale Zeitpunkt zur Ausgabe einer solchen Information im Bereich von 1.000 bis 1.500 m vor der Gefahrenstelle liegt [7]. Um dies zu ermöglichen verfolgt die LGW eine Car-to-Infrastructure Architektur. Hierbei werden Fahrzeuge als eine Art mobile Messstationen eingesetzt und deren Informationen an ein zentrales Backend versendet. Im Backend werden die Fahrzeugdaten, die sogenannten Extended Floating Car Data (xFCD) [54], gesammelt und mit Infrastrukturdaten fusioniert. Dadurch soll neben der rechtzeitigen Warnung eine präzise Ortsreferenzierung und somit

1. Einleitung

eine hohe Qualität hinsichtlich der korrekten Einstellung, örtlichen Verschiebung sowie der rechtzeitigen Aufhebung einer Gefahr ermöglicht werden. Ein Fahrzeug, welches sich schließlich auf eine lokale Gefahr zubewegt, soll dann mit Hilfe der Informationen im Backend rechtzeitig informiert werden. Hierzu ist das international standardisierte Protokoll TPEG, der Nachfolger von TMC, vorgesehen, welches die Codierung und Übertragung solcher Informationen im sogenannten TEC Application Container bereits vorsieht [91, 124]. Insgesamt wurden sieben Gefahrentypen identifiziert, welche im Rahmen der LGW adressiert werden, dies sind *harte Stauenden*, eine *plötzliche Reduzierung der Sichtweite* z.B. aufgrund von Nebel, Starkregen oder einer tiefstehenden Sonne, die *plötzliche Änderung des Reibwerts* z.B. aufgrund von Glatteisbildung, Aquaplaning oder einer Ölspur, *Falschfahrer*, *Spursperrungen* z.B. durch befristete Straßenbauarbeiten, Wanderbaustellen oder Schwertransporter, *Hindernisse auf der Fahrbahn* wie z.B. Gegenstände, Tiere oder Personen sowie *ungesicherte Unfallstellen*. Während einige dieser Gefahrentypen rein durch Infrastrukturdaten abgedeckt werden können, wie z.B. die Spursperrung aufgrund von Straßenbauarbeiten, erhofft man sich bei den Gefahrentypen hartes Stauende, eingeschränkte Sichtverhältnisse und plötzlich Änderung des Reibwerts durch den Einsatz von xFCDs eine deutliche Verbesserung bei der Lokalisierung der Gefahrenstellen.

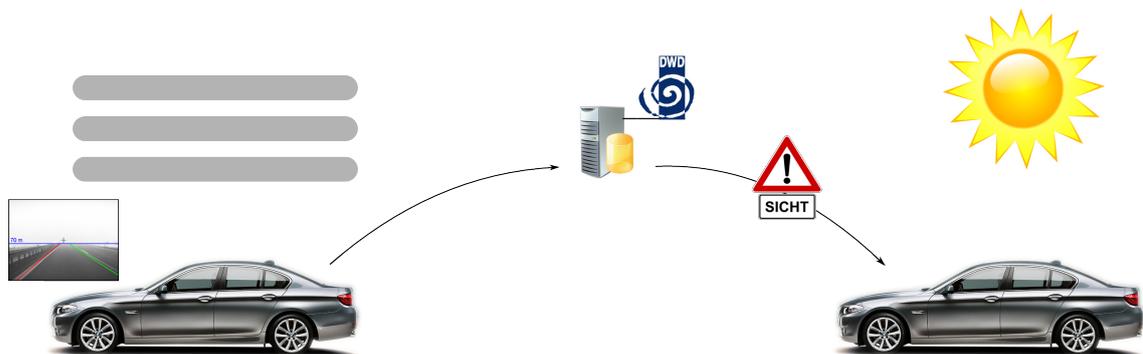


Abbildung 1.1: Bei der Lokalen Gefahrenwarnung (LGW) wird eine Car-to-Infrastructure Architektur verfolgt. Fahrzeuge senden Informationen über ein erkanntes Ereignis an ein zentrales Backend und dienen somit als eine Art mobile Messstationen. Im Backend werden diese sogenannten Extended Floating Car Data (xFCDs) gesammelt und mit Infrastrukturdaten, wie z.B. Wetterdaten eines Serviceproviders, fusioniert. Ein Fahrzeug, welches sich schließlich auf eine lokale Gefahr zubewegt, kann somit rechtzeitig, d.h. 1.000–1.500 m vor der Gefahrenstelle, mit Hilfe der Informationen aus dem Backend informiert werden.

Mit dieser Arbeit sollen die Grundlagen geschaffen werden, damit ein mit GPS-Sensor, Internetverbindung und einem Kamerasystem ausgestattetes Fahrzeug als Informationsquelle für Ereignisse dienen kann, in denen eine plötzliche Reduzierung der Sichtweite durch Nebel eintritt, und somit eine Lokale Gefahrenwarnung vor eingeschränkten Sichtverhältnissen eingestellt werden kann. Laut statistischem Bundesamt ereigneten sich im Jahr 2011 auf deutschen Straßen 711 Unfälle aufgrund von Sichtbehinderung durch Nebel. Bei insgesamt 38.229 erfassten Unfällen ist deren Anteil mit 1,86 % zwar relativ gering, jedoch zeichnen sich diese einerseits durch ihre besondere Schwere und andererseits durch eine hohe Anzahl involvierter Verkehrsteilnehmer aus. So finden sich in dem

Medien jedes Jahr Berichte über schwerwiegende Unfälle, welche sich aufgrund von Sichtbehinderungen durch Nebel ereigneten. Im Jahr 2012 waren z.B. auf der Autobahn A38, Halle-Göttingen, 42 Fahrzeuge, 8 Lastkraftwagen und insgesamt 70 Menschen in eine Massenkarambolage involviert, wobei 31 Menschen verletzt wurden. Diese Zahlen machen deutlich, wie wichtig ein rechtzeitiges Informieren von Verkehrsteilnehmer vor eingeschränkten Sichtverhältnissen durch Nebel ist. Neben diesem Anwendungsszenario finden sich jedoch eine Vielzahl weiterer Anwendungsgebiete, in denen eine kamera-basierte Nebelerkennung im Fahrzeug zum Einsatz kommen kann. Diese werden im Folgenden kurz beschrieben.

Strategieanpassung des Fernlichtassistenten

Der Fernlichtassistent (FLA) unterstützt den Fahrer beim Ein- und Ausschalten des Fernlichts. Befindet sich das Fahrzeug in einer unzureichend ausgeleuchteten Umgebung, d.h. außerhalb geschlossener Ortschaften bei Nacht, und ist kein vorausfahrendes oder entgegenkommendes Fahrzeug vorhanden, so wird das Fernlicht eingeschaltet. Bei Nebel wird der Fahrer in einer solchen Situation jedoch durch sein eigenes Licht geblendet. Durch das Erkennen von Nebel bei Nacht kann die Strategie des Fernlichtassistenten angepasst werden.

Hinweis auf implizite Geschwindigkeitsbegrenzung

Geschwindigkeitsbegrenzungen sind entweder explizit ausgeschildert oder implizit aufgrund von Regelungen des Straßenverkehrs gegeben. So gilt z.B. auf deutschen Bundesstraßen laut Straßenverkehrsordnung (StVO) eine implizite Geschwindigkeitsbegrenzung von 100 km/h. Liegt aufgrund der Witterungsbedingungen eine Sichtweite von weniger als 50 m vor, so darf laut StVO nicht schneller als 50 km/h gefahren werden. Vielen Verkehrsteilnehmern ist diese Regelung nicht immer bewusst. Zudem werden die Sichtverhältnisse bei Nebel häufig überschätzt, was zu überhöhten Geschwindigkeiten und somit zu einem erhöhten Unfallrisiko führt [15]. Durch das Erkennen solcher Situationen kann der Fahrer, z.B. durch eine visuelle Information der implizit geltenden Geschwindigkeitsbegrenzung im Kombi-Instrument, hierauf aufmerksam gemacht werden.

Nebellicht-/Nebelschlussleuchte Assistent

Laut deutscher Straßenverkehrsordnung (StVO) darf die Nebelschlussleuchte nur bei Sichtweiten unter 50 m eingeschaltet werden. Automobilclubs bemängeln jedoch, dass Verkehrsteilnehmer häufig vergessen, diese bei klaren Sichtverhältnissen wieder auszuschalten und somit der nachfolgende Verkehr geblendet wird. Durch eine Nebelerkennung können die Nebelschlussleuchte und die Nebelscheinwerfer automatisch ein- bzw. ausgeschaltet werden, so wie es heute bereits beim Abblendlicht üblich ist.

Intelligente Regelung der Heckleuchten

Für die Beleuchtung von Fahrzeugen werden heute Rücklichter konstanter Helligkeit eingesetzt, wobei die Sichtbarkeit bei schlechten Witterungsbedingungen durch Einschalten

der Nebelschlussleuchte verstärkt werden kann. Es gibt Überlegungen, für eine bessere Sichtbarkeit von Fahrzeugen, die Leuchtstärke der Heckleuchten stufenlos an die aktuell vorliegenden Umgebungsbedingungen anzupassen. So könnten diese z.B. im Tunnel gedimmt werden und bei starkem Regen oder Nebel heller leuchten. Zur Realisierung einer solchen Funktion muss das Fahrzeug jedoch die aktuellen Umgebungsbedingungen erkennen, wozu die Nebeldetektion einen Beitrag leisten kann.

Optimierung bildbasierter Algorithmen

Nebel verursacht eine Kontrastabnahme und Verunschärfung in der Wahrnehmung der Umgebung. Aktuelle kamerabasierte Fahrerassistenzsysteme basieren jedoch meist auf Untersuchungen des Intensitätsverlaufs und wurden in der Regel für klare Sichtverhältnisse konzipiert, wodurch es bei unscharfen Bildern zu deutlichen Einbrüchen bei der Detektionsgüte kommt. Dabei ist jedoch genau in solchen Situationen eine Unterstützung durch Assistenzsysteme wünschenswert. Die Nebelerkennung ermöglicht hierbei eine adaptive Parametrisierung bestehender Algorithmen oder eine Vorverarbeitung der Eingangsbilder durch bekannte Verfahren der Bildrestaurierung [89, 121].

Ausfallerkennung

Der Trend in der heutigen Fahrzeugentwicklung geht deutlich in Richtung hochautomatisiertes Fahren (HAF). Bereits heute sind Systeme verfügbar, welche den Fahrer beim Einparkvorgang unterstützen, indem sie ihm die Querführung des Fahrzeugs abnehmen. Der Fahrer bleibt hierbei in der Verantwortung, da er weiterhin durch Betätigung des Brems- und Gaspedals für die Fahrzeuglängsführung zuständig ist. Aus technischer Sicht ist ein vollautomatisiertes Einparken bereits heute realisierbar, jedoch gilt es an dieser Stelle noch haftungs- sowie zulassungstechnische Fragen zu klären, was in naher Zukunft jedoch absehbar erscheint. Der nächste Meilenstein beim HAF ist der Stauassistent. Dieser soll in wohl definierten Umgebungen bis zu einer maximal zulässigen Geschwindigkeit den Fahrer sowohl in der Längs- als auch in der Querführung von der Fahraufgabe befreien. Die Vision der Automobilindustrie geht dabei klar in Richtung eines Autopiloten, der in beliebigen Situationen in der Lage ist die Fahraufgabe zu übernehmen. Kamerasysteme spielen dabei neben weiteren Sensoren eine wichtige Rolle. Einerseits gelten Sie als kostengünstige Lösungen, andererseits erlauben Sie eine der menschlichen Wahrnehmung naheliegende Interpretation der Fahrzeugumgebung. Während ein Radar-System z.B. recht zuverlässig Objekte detektieren kann, ermöglicht ein Kamerasystem darüber hinaus eine Zuordnung des Objekts zu einer Fahrspur, wodurch z.B. ein unnötiger Bremsvorgang eines Abstandstempomaten vermieden werden kann. Eine große Herausforderung bei Kamerasystemen ist jedoch deren zuverlässiger Einsatz unter verschiedenen Umgebungsbedingungen. Dabei ist naheliegend, dass ein absolut fehlerfreier Einsatz nie gänzlich sichergestellt werden kann. Wichtig an dieser Stelle ist jedoch, dass ein Ausfall oder eine Fehlfunktion des Systems rechtzeitig erkannt wird um den Fahrer möglichst frühzeitig wieder zur Übernahme der Fahraufgabe zu veranlassen. Die kamerabasierte Nebelerkennung, vor allem in Kombination mit der Lokalen Gefahrenwarnung, kann hierzu einen wichtigen Beitrag leisten.

Die Ziele und der Beitrag dieser Arbeit lassen sich somit folgendermaßen zusammenfassen:

- Einführung in das Themengebiet Nebel und Sichtweite, dessen Entstehung, die Beschreibung der zugrundeliegenden Mechanismen und die Auswirkung auf die Wahrnehmung der Umgebung sowie die Vorstellung heute eingesetzter Methoden zur Nebelerkennung und Sichtweitenschätzung im Straßenverkehr.
- Zusammenfassung und Diskussion bekannter kamerabasierter Verfahren zur Nebeldetektion und Sichtweitenschätzung.
- Aufbau einer Datenbank mit Bildmaterial zu Fahrszenen bei Nebel.
- Entwicklung eines rein kamerabasierten Verfahrens zur Nebelerkennung im Fahrzeug. Dabei soll eine auf Grauwertbildern basierendes Monokamerasystem zum Einsatz kommen, wie es bereits heute in Serienfahrzeugen verwendet wird.
- Es sollen lediglich Autobahnfahrten untersucht werden, da hier das größte Gefährdungspotential für Verkehrsteilnehmer gesehen wird.
- Das Verfahren soll in unterschiedlichen Umgebungsbedingungen, d.h. sowohl bei Tag, als auch bei Nacht, einsetzbar und in Echtzeit ausführbar sein.
- Es ist wünschenswert, dass die Nebelerkennung bei Nacht ohne Einschalten des Fernlichts ermöglicht wird.
- Evaluierung der vorgestellten Methode im Vergleich zu anderen Ansätzen.

Die restliche Arbeit gliedert sich wie folgt: Im anschließenden Kapitel werden grundlegende Eigenschaften des Nebels sowie die Mechanismen, welche zu einer Einschränkung der Sichtverhältnisse führen, erklärt. In Kapitel 3 werden dann bekannte, kamerabasierte Verfahren zur Nebeldetektion und Sichtweitenschätzung vorgestellt, die unterschiedlichen Ansätze diskutiert und eine Abgrenzung zur hier vorliegenden Arbeit vorgenommen. In Kapitel 4 wird das in dieser Arbeit entwickelte Verfahren zur Nebeldetektion vorgestellt sowie weitere bekannte Merkmale, welche zur Klassifizierung von Nebelszenen in Betracht kommen, zusammengefasst. In Kapitel 5 wird das zugrundeliegende Kamerasystem, die erhobene Datengrundlage und die Evaluierungsmethodik vorgestellt. Desweiteren finden sich an dieser Stelle die Ergebnisse der Evaluierung bzgl. unterschiedlicher Parametrisierungen sowie ein Vergleich der verschiedenen Merkmale sowohl für Tag- als auch für Nacht-Szenen. Abschließend findet sich in Kapitel 6 eine Zusammenfassung der Ergebnisse sowie ein Ausblick.

Nebel und Sichtweite

In der Meteorologie beschreibt Nebel laut internationaler Definition eine Wolke, welche den Boden berührt und eine Sichtweite von weniger als 1.000 m verursacht. Ist die Sichtweite größer als 1.000 m, so spricht man von Dunst [4]. Nebel entsteht dabei, wenn die relative Luftfeuchtigkeit Sättigung erreicht und Luftpartikel, wie z.B. Staub, Eis oder Salz, durch Kondensation zu kleinen Wassertröpfchen anwachsen [109]. Der Anstieg der Luftfeuchtigkeit hat verschiedene Ursachen, wie z.B. Niederschlag, die Entstehung von Wasserdampf durch Sonneneinstrahlung auf nassen Flächen oder durch die Bewegung kalter oder trockener Luft über warme Gewässer [2]. Dabei gibt es verschiedene Nebelarten, wie z.B. Strahlungsnebel oder Advektionsnebel, welche sich in ihrem Entstehungsprozess unterscheiden. Ein wesentlicher Faktor zur Beschreibung des Nebels und zur Abgrenzung zu anderen Wetterbedingungen ist die *Sichtweite*. Laut Huschke [56] hat diese zwei ungleiche Bedeutungen: Bei Tag beschreibt die Sichtweite den größten Abstand, bei dem ein dunkles, herausragendes Objekt entgegen des Horizonts noch beobachtet werden kann und bei Nacht gilt entsprechendes für eine unfokussierte, mäßige Lichtquelle. Beide Bedeutungen beinhalten einen Beobachter und somit subjektive Faktoren, bei Tag ist dies die subjektive Bewertung der Kontrastabschwächung und bei Nacht die subjektiv wahrgenommene Dämpfung eines Lichtstrahls. In beiden Fällen ist die Streuung der wesentliche Faktor für die Sichtweitenreduzierung, welche wichtige Eigenschaften des Lichts, wie z.B. Intensität, Farbe oder Polarisation, abhängig von der Art, Größe und Konzentration der involvierten Partikel verändert [82]. Während bei klaren Wetterbedingungen die Streuung aufgrund der zur Wellenlänge des sichtbaren Lichts relativ geringen Größe der Luftmoleküle sehr gering ist, erzeugen größere Partikel eine Vielzahl unterschiedlicher Wetterbedingungen.

In diesem Kapitel werden im Folgenden Grundlagen zur Interpretation von bei Nebel aufgenommenen Bildern zusammengefasst. Nach einer kurzen Einführung in die Radiometrie und Photometrie werden aus der atmosphärischen Optik bekannte Modelle zur Beschreibung der atmosphärischen Streuung aufgegriffen und die in diesem Zusammenhang wesentlichen Mechanismen erläutert. Anschließend werden die Auswirkungen der Streuung auf die Sichtweite betrachtet sowie abschließend ein Überblick zu heute gebräuchlichen, instrumentellen Messmethoden der Sichtweite gegeben. Als Hintergrundmaterial dienen vor allem die Arbeiten von McCartney [82] und Middleton [84],

welche einen hervorragenden Überblick zu diesem Themengebiet geben, die Arbeit von Narasimhan und Nayar [90], welche wichtige Aspekte bezüglich des computergestützten Sehens zusammenfasst, sowie das *Handbuch Meteorologischer Instrumente und Methoden zur Observation* der Weltorganisation für Meteorologie (World Meteorological Organization, WMO) [132].

2.1 Radiometrische Grundlagen

Die Radiometrie befasst sich unter sorgfältig gewählten spektralen und geometrischen Rahmenbedingungen mit der Messung elektromagnetischer Strahlung. Die grundlegende Eigenschaft ist dabei die Rate, mit welcher elektromagnetische Energie, je angegebenen Spektralband, einen definierten Raumwinkel oder eine Fläche in eine bestimmte Richtung durchströmt.

Im freien Raum breiten sich elektromagnetische Wellen, ohne Berücksichtigung von Beugung aufgrund eines Gravitationsfelds, entlang einer geraden Linie aus. Wellenfronten bleiben dabei parallel zueinander und senkrecht zur Ausbreitungsrichtung. Bei Quellen elektromagnetischer Strahlung wird dabei zwischen *Punktquellen* und *ausgedehnten Strahlern* unterschieden. Während Punktquellen eine kugelförmige Welle ausstrahlen, emittiert bei einem ausgedehnten Strahler jedes Flächenelement eine kugelförmige Welle. Ist der Abstand zur Quelle 20-mal größer als die Abmessung der Projektion, so kann mit einem Fehler kleiner 1 % eine Quelle als Punktquelle betrachtet werden. In diesem Fall kann die Bestrahlungsstärke, d.h. die Menge an einfallenden Strahlungsfluss pro Flächeneinheit einer zur Ausbreitungsrichtung senkrechten Oberfläche, über das später beschriebene inverse Abstandsgesetz bestimmt werden. Ausgedehnte Strahler emittieren Strahlungsfluss hingegen in der Regel ungleichmäßig, für eine bestimmte Richtung θ kann dieser über das *Lambert'sche Kosinusetz*, wie in Abb. 2.1(a) dargestellt, bestimmt werden

$$d\Phi(\theta) = d\Phi_0 \cos \theta, \quad (2.1)$$

wobei $d\Phi_0$ den zum Flächenelement dA senkrechten Strahlenfluss beschreibt. Wichtig an dieser Stelle ist zudem, wie in Abb. 2.1(b) dargestellt, die Abhängigkeit der effektiven emittierenden bzw. reflektierenden Fläche vom Winkel θ .

Bei einer kugelförmigen Welle wächst, wie in Abb. 2.2 dargestellt, die Fläche der expandierenden Wellenfront quadratisch mit der zurückgelegten Strecke. Somit ändert sich die Bestrahlungsstärke E der betrachteten Oberfläche A bei einem festen Raumwinkel

$$\omega := \frac{A}{d^2} \quad (2.2)$$

umgekehrt proportional zur quadrierten Entfernung d

$$E = \frac{I}{d^2} \cos \theta. \quad (2.3)$$

Dabei beschreibt I die Strahlungsintensität der Quelle, d.h. den Strahlungsfluss pro Raumwinkel, und θ den Winkel zwischen Oberflächennormale und der Richtung der Quelle. Gl. (2.3) formuliert das *inverse Abstandsgesetz*, das für jedes Lichtbündel gilt. Ist

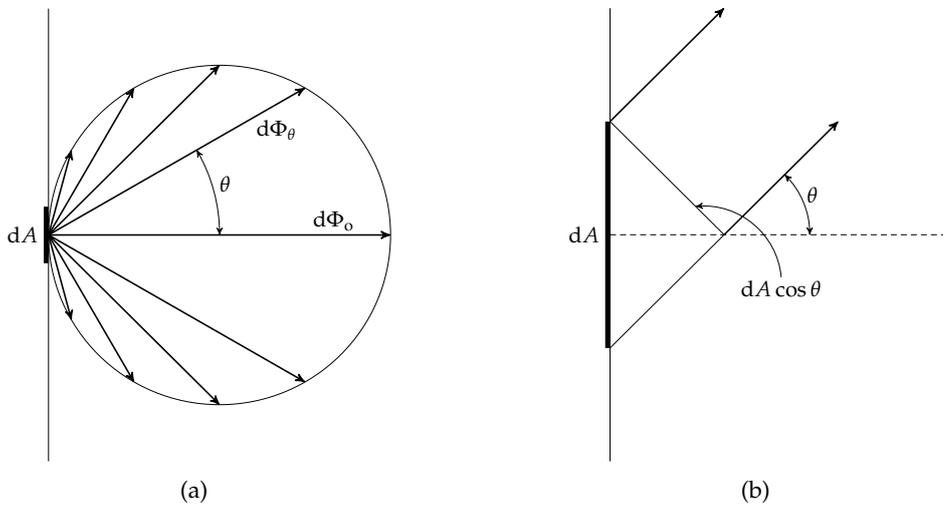


Abbildung 2.1: (a) Richtungsabhängigkeit des Strahlenflusses (Lambert'sches Kosinusetz). (b) Projizierte bzw. effektive Fläche einer Quelle über den Winkel zwischen Oberflächennormale und Beobachtungsrichtung. Jeweils übernommen aus [114].

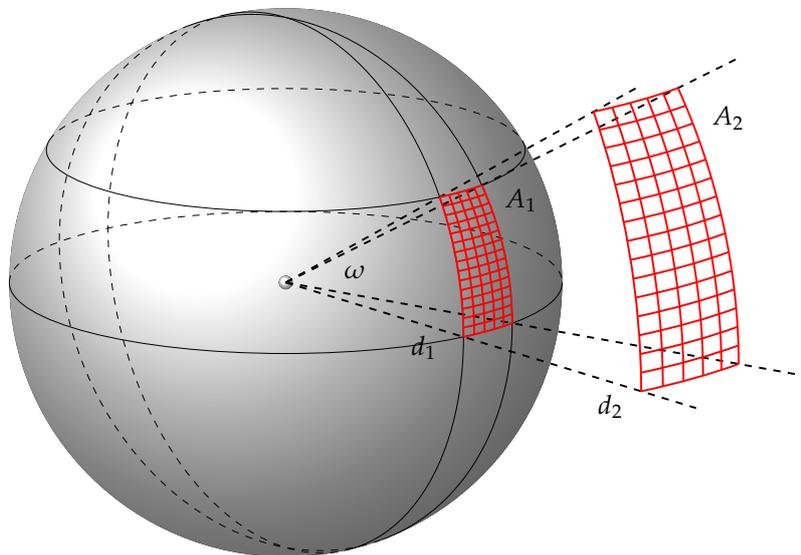


Abbildung 2.2: Raumwinkel und inverses Abstandsgesetz. Der Raumwinkel ω ist definiert als Quotient der Fläche A und dem quadratische Abstand d . Bei einem konstanten Raumwinkel wächst die Fläche quadratisch mit Verdopplung des Abstands.

2. Nebel und Sichtweite

die Quelle sehr weit entfernt oder wenn strahlenformende Elemente verwendet werden, können die begrenzenden Strahlen eines Lichtbündels einen sehr kleinen Divergenzwinkel aufweisen. Die entsprechende Anordnung kann dann erlauben, dass die Divergenz vernachlässigt wird und man spricht von einem *kollimierten* Strahlenbündel, welcher aus parallelen Strahlen besteht.

In Tabelle 2.1 sind die radiometrischen Größen zusammengefasst, wobei jede dieser auch auf ein spektrales Band begrenzt werden kann.

Symbol	Größe	Einheit
Q_e	Strahlungsenergie	Joule [J]
W_e	Strahlungsenergiedichte	Joule pro Kubikmeter $\left[\frac{\text{J}}{\text{m}^3}\right]$
Φ_e	Strahlungsfluss	Watt [W] bzw. Joule pro Sekunde $\left[\frac{\text{J}}{\text{s}}\right]$
M_e	Spezifische Ausstrahlung	Watt pro Quadratmeter $\left[\frac{\text{W}}{\text{m}^2}\right]$
E_e	Bestrahlungsstärke	Watt pro Quadratmeter $\left[\frac{\text{W}}{\text{m}^2}\right]$
I_e	Strahlungsintensität	Watt pro Steradian $\left[\frac{\text{W}}{\text{sr}}\right]$
L_e	Strahldichte	Watt pro Quadratmeter und pro Steradian $\left[\frac{\text{W}}{\text{m}^2\text{sr}}\right]$

Tabelle 2.1: Standard Symbole und Dimensionen radiometrischer Größen [5].

Spektrale radiometrische Größen können anstelle der üblichen SI-Einheiten Joule und Watt für Energie und Leistung auch in Bezug auf Photonen angegeben werden, zur Differenzierung wird dann das Subskript q verwendet. Da die Energie eines Photons von der Frequenz abhängig ist, handelt es sich hierbei um eine spektrale radiometrische Größe

$$Q_q = hf = \frac{hc}{\lambda}, \quad (2.4)$$

wobei h das Plank'sche Wirkungsquantum, f die Frequenz, λ die Wellenlänge und c die Lichtgeschwindigkeit beschreibt. Die Strahlungsenergie wird dann bei einer bestimmten Wellenlänge über die Anzahl der Photonen angegeben. Im Folgenden werden die radiometrischen Größen aus Tabelle 2.1 kurz erläutert.

Die *Strahlungsenergie* ist die Basis aller radiometrischen Größen und stark abhängig von der Wellenlänge und dem betrachteten spektralen Intervall. Sie ist definiert als

$$Q(\lambda) = \frac{dQ}{d\lambda}. \quad (2.5)$$

Dies bedeutet, dass sich die spektrale Energie über den Grenzwert bestimmt, der sich aus dem Verhältnis eines infinitesimalen spektralen Intervalls und dadurch infinitesimalen Energiemenge einstellt. Da ein unendlich schmales Intervall jedoch keine Energie enthält, benötigt eine endliche Energiemenge auch ein endliches Intervall. Die spektrale Strahlungsenergie ergibt sich daher durch Integration über einen spektralen Bereich

$$Q(\lambda_1, \lambda_2) = \int_{\lambda_1}^{\lambda_2} Q(\lambda) d\lambda. \quad (2.6)$$

Spektrale Einheiten müssen somit das zugrundeliegende Intervall angeben, wobei häufig eine Wellenlängeneinheit verwendet wird. Identische Überlegungen gelten für alle aus Tabelle 2.1 gebildeten spektralen Größen.

Die *Strahlungsenergie-dichte* ist der elektromagnetische Energieinhalt einer Volumeneinheit zu einem Zeitpunkt und definiert als

$$W = \frac{dQ}{dV}. \quad (2.7)$$

Der *Strahlungsfluss*, häufig auch *Strahlungsleistung* oder einfach *Strahlung* genannt, ist die zeitliche Rate, mit welcher Energie einen bestimmten Punkt passiert

$$\Phi = \frac{dQ}{dt}. \quad (2.8)$$

Sie ist die von den meisten Sensoren, einschließlich dem menschlichen Auge, detektierte und gemessene Größe. Bei integrierenden Sensoren, wie z.B. einer Kamera, ist jedoch auf einen multiplikativen Faktor, die Belichtungszeit, zu achten.

Die *spezifische Ausstrahlung* ist der an eine Oberfläche aufgrund von Emission oder Reflexion verlassende und die *Bestrahlungsstärke* der auf eine Oberfläche einfallende Strahlungsfluss. Sie sind definiert als

$$M \text{ oder } E = \frac{d\Phi}{dA}. \quad (2.9)$$

Die *Strahlungsintensität* ist der von einer Punktquelle in eine bestimmte Richtung ausgestrahlte Strahlungsfluss pro Einheitsraumwinkel,

$$I = \frac{d\Phi}{d\omega}. \quad (2.10)$$

Sie kann als Strahlungsfluss innerhalb eines um die gewählte Richtung zentrierten infinitesimalen Kegels interpretiert werden. Die Strahlungsintensität ist auch für ausgedehnte Quellen anwendbar, jedoch ist zu beachten, dass die Intensität, abhängig vom Winkel zwischen der Oberflächennormalen und der betrachteten Richtung, variiert. Handelt es sich um eine Lambert'sche Fläche, so ergibt sich durch Substitution von $d\Phi$ aus Gl. (2.10) mit $d\Phi(\theta)$ aus Gl. (2.1)

$$I(\theta) = \frac{d\Phi_o \cos \theta}{d\omega}. \quad (2.11)$$

Die *Strahldichte* bezieht sich auf emittierende oder reflektierende ausgedehnte Quellen und ist für jede Richtung θ definiert als Verhältnis des von einem Oberflächenelement stammenden Strahlungsflusses und dem Produkt aus Projektionsfläche und aufgespannten Raumwinkel

$$L(\theta) = \frac{d^2\Phi}{(dA \cos \theta) d\omega} = \frac{dI(\theta)}{dA \cos \theta}. \quad (2.12)$$

Der rechte Ausdruck, welcher sich über Gl. (2.10) ergibt, zeigt, dass die Strahldichte in jede Richtung gleich der Intensität derselben Richtung pro projizierter Einheitsfläche ist. Für eine Lambert'sche Oberfläche erhält man aus Gl. (2.12) über Gl. (2.11)

$$L(\theta) = \frac{dI_o \cos \theta}{dA \cos \theta} = \frac{dI_o}{dA}, \quad (2.13)$$

was bedeutet, dass die Strahldichte hier unabhängig von der Beobachtungsrichtung ist.

2.2 Photometrische Grundlagen

Die Photometrie ist ein Teilbereich der Radiometrie, welche die elektromagnetische Leistung nicht in absoluten Einheiten wie Joule oder Watt, sondern bezüglich ihrer Fähigkeit einen visuellen Sinneseindruck zu erwecken, auswertet. Das Ziel instrumenteller Messungen ist dabei eine möglichst gute Übereinstimmung mit der visuellen Wahrnehmung des menschlichen Auges im Bereich des sichtbaren Lichts zwischen $0,38$ und $0,76 \mu\text{m}$ zu erzielen. Zu jeder radiometrischen Größe existiert somit ein photometrisches Pendant, welche in Tabelle 2.2 zusammengefasst sind und im Folgenden kurz erläutert werden.

Symbol	Größe	Einheit
K	Lichtausbeute	Lumen pro Watt $\left[\frac{\text{lm}}{\text{W}}\right]$
V	Hellempfindlichkeit	Nummerischer Wert zwiscne 0 und 1
Q_v	Lichtmenge	Lumensekunde $[\text{lm s}]$
Φ_v	Lichtstrom	Lumen $[\text{lm}]$
M_v	Spezifische Lichtausstrahlung	Lumen pro Quadratmeter $\left[\frac{\text{lm}}{\text{m}^2}\right]$ bzw. Lux $[\text{lx}]$
E_v	Beleuchtungsstärke	Lux $[\text{lx}]$
I_v	Lichtstärke	Lumen pro Steradian $\left[\frac{\text{lm}}{\text{sr}}\right]$ bzw. Candela $[\text{cd}]$
L_v	Leuchtdichte	Candela pro Quadratmeter $\left[\frac{\text{cd}}{\text{m}^2}\right]$

Tabelle 2.2: Standard Symbole und Dimensionen photometrischer Größen [5].

Die *Lichtausbeute*, auch bekannt als *photometrisches Strahlungsäquivalent*, ist definiert als Verhältnis zwischen photometrischer und radiometrischer Leistung

$$K = \frac{d\Phi_v}{d\Phi_e} \quad (2.14)$$

und wird in Lumen pro Watt angegeben. Sie stellt somit einen Zusammenhang zwischen der physiologischen Größe Lichtstrom aus der Photometrie und der physikalischen Größe Strahlungsleistung aus der Radiometrie her. In Abb. 2.3 ist die experimentell ermittelte Lichtausbeute des menschlichen Auges für photoptisches Sehen, d.h. helladaptiert, mit einem Maximum bei $K_{\text{max}} = 683 \frac{\text{lm}}{\text{W}}$ und für skotoptisches Sehen, d.h. dunkeladaptiert, mit einem Maximum bei $K_{\text{max}} = 1.700 \frac{\text{lm}}{\text{W}}$ dargestellt [129]. Diese wurden von der internationalen Beleuchtungskommission in Form der relativen Hellempfindlichkeitskurven des CIE-Standard Beobachters übernommen [18]. Die Hellempfindlichkeit ist dabei definiert als

$$V(\lambda) = \frac{K(\lambda)}{K_{\text{max}}} \quad (2.15)$$

Die Einheit *Candela* ist so definiert, dass bei der Wellenlänge $\lambda = 555 \text{ nm}$

$$\begin{aligned} 1 \text{ W} &= 680 \text{ lm} \\ 1 \text{ lm} &= 1,47 \cdot 10^{-3} \text{ W} \end{aligned} \quad (2.16)$$

2.3. Grundlegende Eigenschaften der Streuung

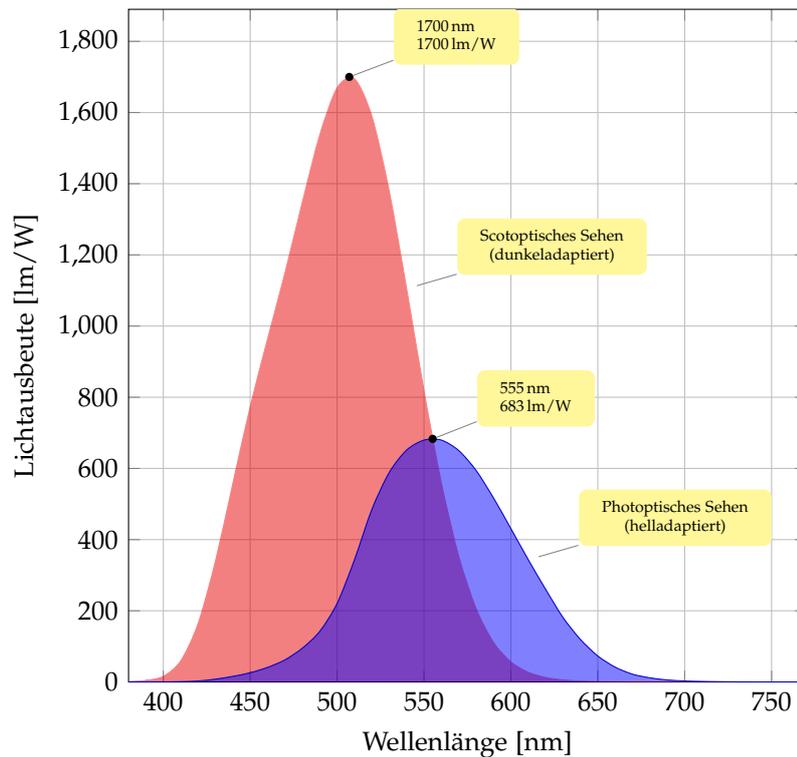


Abbildung 2.3: Lichtausbeute des menschlichen Auges.

gilt. Bei anderen Wellenlängen bestimmt sich der *Lichtstrom* über

$$\Phi_v(\lambda) = 680 V(\lambda) \Phi_e(\lambda). \quad (2.17)$$

Sind mehrere Wellenlängen involviert, bestimmt sich der Lichtstrom durch Integration

$$\Phi_v(\lambda) = 680 \int_{\lambda_1}^{\lambda_2} V(\lambda) \Phi_e(\lambda) d\lambda. \quad (2.18)$$

Die *Lichtmenge* ist die photometrisch gewichtete Strahlungsenergie und berechnet sich über das Integral

$$Q_v = \int_{380\mu\text{m}}^{760\mu\text{m}} K(\lambda) Q_e(\lambda) d\lambda \quad (2.19)$$

und wird in der Einheit Lumen während einer bestimmten Zeiteinheit angegeben. Die Photometrischen Größen *Lichtstrom*, *spezifische Lichtausstrahlung*, *Beleuchtungsstärke*, *Lichtstärke* und *Lichtausbeute* sind, basierend auf der Lichtmenge, analog zu den korrespondierenden radiometrischen Größen definiert.

2.3 Grundlegende Eigenschaften der Streuung

Streuung ist ein Prozess, bei dem von einer einfallenden elektromagnetischen Welle durch ein auf dem Ausbreitungspfad befindliches Teilchen kontinuierlich Energie entzogen und

2. Nebel und Sichtweite

diese, verteilt im gesamten Raumwinkel, zentriert um das Teilchen, wieder ausgestrahlt wird. Das Teilchen stellt dabei eine Punktquelle der gestreuten Energie dar. Die in der Atmosphäre für die Streuung des Lichts verantwortlichen Teilchen variieren dabei um ein Vielfaches in ihrer Größe, von Luftmolekülen mit einem Radius von $10^{-4} \mu\text{m}$ bis hin zu Wassertropfchen mit einem Radius von $10^4 \mu\text{m}$ [82], siehe Tabelle 2.3. Dabei entstehen, abhängig vom Verhältnis zwischen Teilchengröße und Wellenlänge, unterschiedliche dreidimensionale Streumuster [85]. Wie in Abb. 2.4 skizziert erzeugen kleine Teilchen ein symmetrisches Muster, mittelgroße Teilchen streuen verstärkt und große Teilchen nahezu gänzlich in Vorwärtsrichtung, wobei die Intensität des gestreuten Lichts mit wachsender Teilchengröße zunimmt. Die Form des Streumusters kann für kleine Teilchen über die *Rayleigh Streuung* und für größere Teilchen über die *Mie Streuung* theoretisch exakt beschrieben werden.

Typ	Radius (μm)	Konzentration (cm^{-3})
Luftmolekül	10^{-4}	10^{19}
Dunst Teilchen	10^{-2} –1	10^3 – 10
Nebeltröpfchen	1–10	100–10
Wolkentröpfchen	1–10	300–10
Regentropfen	10^2 – 10^4	10^{-2} – 10^{-5}

Tabelle 2.3: Eigenschaften relevanter Teilchen bei der atmosphärischen Streuung [82].

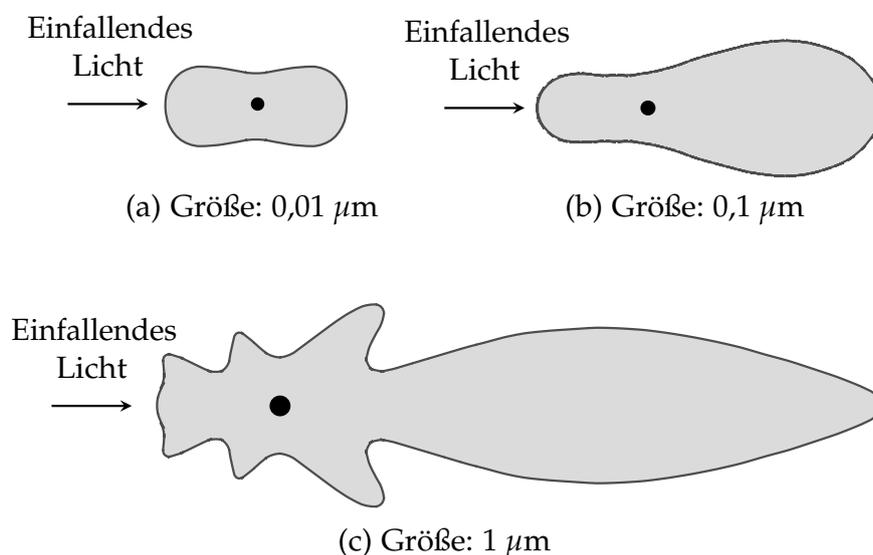


Abbildung 2.4: Streumuster an isotropischen Partikel unterschiedlicher Größe. (a) Kleines Teilchen, kleiner als $1/10$ der Wellenlänge des sichtbaren Lichts. (b) Mittelgroßes Teilchen, ca. $1/4$ der Wellenlänge des sichtbaren Lichts. (c) Großes Teilchen, d.h. größer als die Wellenlänge des sichtbaren Lichts. Übernommen aus [13].

Neben der Streuung kann einem einfallenden Lichtstrahl zudem durch *Absorption* Energie entzogen werden. Während die Streuung über die Wellentheorie des Lichts erklärt wird, benötigt die Absorption zur Beschreibung die Quantentheorie und bewirkt im Gegensatz zur Streuung eine Änderung der Energiestati der Moleküle, was eine Erwärmung der Atmosphäre zur Folge hat. Die Absorption wird in der Theorie der Streuung insofern mit einbezogen, als dass verschiedene Größen als ein Maß für die Absorption des Lichts entwickelt wurden. Dies erlaubt die gemeinsame Betrachtung der Streuung und Absorption in Form der *Extinktion*.

2.4 Atmosphärische Streuung

Während im vorherigem Abschnitt die Streuung an einem einzelnen Teilchen betrachtet wurde, ist man in praktischen Anwendungen an der Streuung innerhalb eines bestimmten Bereichs im Raum interessiert. Da in der Atmosphäre der mittlere Teilchenabstand um ein Mehrfaches größer als die Teilchengröße ist, beeinflussen sich die einzelnen Streumuster nicht und man spricht von *unabhängiger Streuung*, d.h. es treten keine Interferenzen auf. Dieses Abstandskriterium ist für alle in Tabelle 2.3 zutreffenden Wetterbedingungen erfüllt, nicht erfüllt ist es dagegen für Strukturen mit dicht gepackten Atomen und Molekülen, wie sie z.B. in Flüssigkeiten oder Feststoffen auftreten. Das einfallende Licht wird jedoch nicht nur an einem, sondern an mehreren Teilchen gestreut. Die sogenannte *Mehrfachstreuung* wirkt sich besonders auf das zusammengesetzte Streumuster des betrachteten Mediums aus, welches, unter Beibehaltung der grundsätzlichen Merkmale der einzelnen Streumuster, eine geringere Richtungsabhängigkeit des Lichts aufweist. Dies kann im Extremfall dazu führen, wie z.B. bei sehr dichtem Nebel, dass die Herkunft eines einfallenden Lichtstrahls nicht mehr zuordbar ist und als diffuse Lichtquelle wahrgenommen wird.

Die Wesentlichen, messbaren Erscheinungsformen der atmosphärischen Streuung, welche im Folgenden beschrieben werden, sind die Dämpfung von Lichtstrahlen, diffuses Licht aus der Hemisphäre, das sogenannte Airlight, und die Beeinflussung der Sichtbarkeit entfernter Objekte.

2.4.1 Dämpfung

Beim Durchqueren der Atmosphäre wird einem Lichtstrahl durch Streuung an Teilchen Energie entzogen. Betrachtet man einen kollimierten Strahl mit Einheitsquerschnitt, wie in Abb. 2.5 dargestellt, so reduziert sich die Beleuchtungsstärke nach Durchqueren der Strecke dx um den Bruchteil

$$\frac{dE(x, \lambda)}{E(x, \lambda)} = \beta(\lambda) dx. \quad (2.20)$$

Dabei beschreibt $E(x, \lambda)$ die spektrale Bestrahlungsstärke bei der Wellenlänge λ an der Stelle x und $\beta(\lambda)$ den Streukoeffizienten, einer zur gesamten, durch Streuung pro Einheitslänge entnommenen Energie proportionalen Größe.

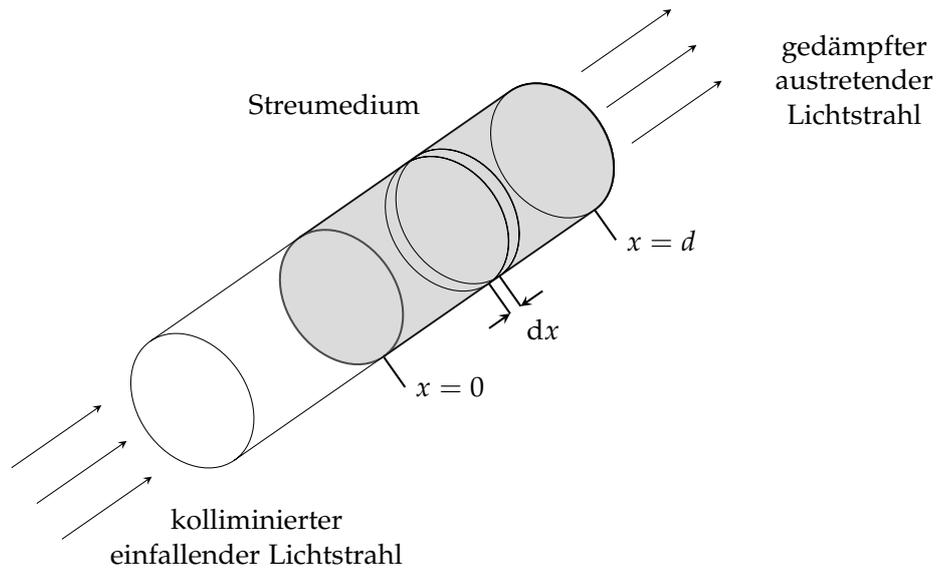


Abbildung 2.5: Dämpfung des Lichts durch Streuung. Teilchen des Mediums streuen einen Bruchteil des einfallenden Lichts in alle Richtungen, wodurch der austretende Lichtstrahl gedämpft wird.

Die Beleuchtungsstärke an der Stelle $x = d$ erhält man durch Integration beider Seiten

$$E(d, \lambda) = E_0(\lambda) e^{-\beta(\lambda)d}, \quad (2.21)$$

wobei $E_0(\lambda)$ die Beleuchtungsstärke an der Stelle $x = 0$ beschreibt. Gl. (2.21) ist das *Bourguier'sche Gesetz* der Dämpfung, welches später von Lambert aufgegriffen wurde und dadurch auch als *Bourguier-Lambert'sches Gesetz* bekannt ist. Dabei ist zu beachten, dass vorwärtsgerichtete Streuung nicht berücksichtigt wird und es strenggenommen nur für kollimierte Strahlen gilt. Gl. (2.21) kann über das Abstandsgesetz umformuliert werden und man erhält das *Allard'sche Gesetz* für die Dämpfung der Bestrahlungsstärke divergierender Punktquellen

$$E(d, \lambda) = \frac{I_0(\lambda) e^{-\beta(\lambda)d}}{d^2}. \quad (2.22)$$

2.4.2 Airlight

Durch Streuung der Umgebungsbeleuchtung an Luftpartikeln, wie z.B. direktes Sonnenlicht oder vom Boden reflektierte Strahlung, verhält sich die Atmosphäre wie eine diffuse Lichtquelle, wodurch Objekte im Bereich des Horizonts heller erscheinen als Objekte im Vordergrund. Dieses Phänomen wird *Airlight* genannt [67]. Während die im vorherigen Abschnitt beschriebene Dämpfung mit steigender Entfernung eine Abschwächung der Helligkeit bewirkt, erfolgt durch das Airlight eine Anhebung. Im Folgenden wird unter der Annahme, dass die Umgebungsbeleuchtung entlang der Beobachtungsrichtung konstant ist, das Airlight als Funktion der Entfernung über die in Abb. 2.6 dargestellte Anordnung hergeleitet [82].

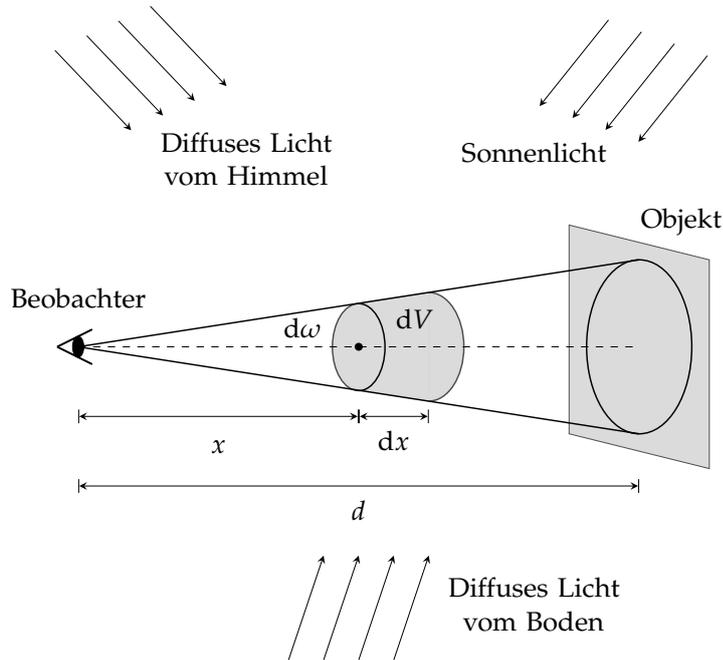


Abbildung 2.6: Airlight. Durch Streuung der Umgebungsbeleuchtung an Luftpartikeln verhält sich die Atmosphäre wie eine diffuse Lichtquelle. Dadurch wird die Helligkeit entfernter Objekte angehoben.

Hierzu wird ein gerader Kreiskegel des Raumwinkels $d\omega$ betrachtet, dessen Spitze sich bei einem Beobachter befindet und durch ein Objekt der Entfernung d begrenzt wird. Das infinitesimale Volumen dV an der Stelle x kann über das Produkt aus Schnittfläche $d\omega x^2$ und Dicke dx beschrieben werden

$$dV = d\omega x^2 dx. \quad (2.23)$$

Unabhängig von der exakten Zusammensetzung der Umgebungsbeleuchtung beträgt die Intensität des durch dV gestreuten Lichts

$$dI(x, \lambda) = dV k \beta(\lambda), \quad (2.24)$$

wobei k eine von der Umgebungsbeleuchtung und den Streueigenschaften des betrachteten Volumens abhängige Proportionalitätskonstante beschreibt. Wird dV als eine Beleuchtungsquelle der Intensität dI betrachtet, so beträgt die Beleuchtungsstärke beim Beobachter nach der atmosphärischen Dämpfung laut Gl. (2.22)

$$dE(x, \lambda) = \frac{dI(x, \lambda) e^{-\beta(\lambda)x}}{x^2}. \quad (2.25)$$

Aus der Beleuchtungsstärke kann die Helligkeit bestimmt werden

$$dL(x, \lambda) = \frac{dE(x, \lambda)}{d\omega} = \frac{dI(x, \lambda) e^{-\beta(\lambda)x}}{d\omega x^2} \quad (2.26)$$

und über (2.24) ergibt sich somit

$$dL(x, \lambda) = k\beta(\lambda) e^{-\beta(\lambda)x} dx. \quad (2.27)$$

Die Helligkeit durch Streuung entlang der gesamten Beobachtungsstrecke erhält man durch Integration über $x = 0$ und $x = d$

$$L_a(d, \lambda) = k \left(1 - e^{-\beta(\lambda)d} \right). \quad (2.28)$$

Ist das Objekt unendlich weit entfernt, d.h. am Horizont mit $d = \infty$, ist die Helligkeit aufgrund des Airlights maximal und beträgt

$$L_\infty(\lambda) = k. \quad (2.29)$$

Die Änderung der Helligkeit durch Airlight für eine beliebige Beobachtungsstrecke beträgt somit

$$L_a(d, \lambda) = L_\infty \left(1 - e^{-\beta(\lambda)d} \right). \quad (2.30)$$

Befindet sich ein Objekt direkt vor dem Beobachter, d.h. $d = 0$, erfolgt demnach keine Änderung der Helligkeit. Mit steigender Distanz erhöht sich der Einfluss des Airlights und entspricht im Unendlichen der Helligkeit am Horizont $L_\infty(\lambda)$, welche beobachtbar bzw. messbar ist. Über Gl.(2.21) ergibt sich somit die wahrgenommene Helligkeit eines Objekts mit der intrinsischen Helligkeit L_o der Entfernung d bei Betrachtung entgegen des Horizonts zu

$$L(d, \lambda) = L_o e^{-\beta(\lambda)d} + L_\infty \left(1 - e^{-\beta(\lambda)d} \right). \quad (2.31)$$

Gl. (2.31) wird *Airlight Formel* genannt und wurde erstmals von Koschmieder aufgestellt, wodurch sie auch als *Koschmieder'sches Gesetz* bekannt ist [67, 84]. Sie berücksichtigt sowohl die Dämpfung des Lichts aufgrund von Streuung als auch die Anhebung der Helligkeit aufgrund von Airlight.

2.4.3 Sichtbarkeit entfernter Objekte

Objekte unterscheiden sich vom Hintergrund durch Unterschiede im Farbton und in der Helligkeit und werden über den *Kontrast* ausgedrückt. Bei der Sichtbarkeit entfernter Objekte ist vor allem der Helligkeits-Kontrast von Bedeutung, welcher laut Weber definiert ist als

$$C = \frac{L - L_b}{L_b}. \quad (2.32)$$

Dabei beschreibt L die Helligkeit eines Objekts und L_b die uniforme Helligkeit des Hintergrunds oder einer angrenzenden Region. Für $L < L_b$ ist der Weber-Kontrast negativ und wird für ein ideal schwarzes Objekt zu -1 . Für $L > L_b$, wie z.B. bei der Betrachtung einer Lichtquelle in der Dunkelheit, erhält man hingegen einen positiven Wert. Über Gl. (2.31) und Gl. (2.32) lässt sich der wahrgenommene Kontrast eines Objekts der Entfernung d , mit intrinsischem Kontrast C_o und bei Betrachtung entgegen des Horizonts beschreiben als [29, 84]

$$C = C_o e^{-\beta d}. \quad (2.33)$$

2.5 Praktische Anwendung in der Meteorologie

Während bisher die Ursachen für die Sichtbeeinträchtigung bei Nebel sowie die daraus resultierenden Effekte betrachtet wurden, ist man in praktischen Anwendungen an einer Quantisierung der Sichtbeeinträchtigung interessiert. Hierzu wurde die Meteorologische Sichtweite definiert [19, 130, 131].

Definition Meteorologische Sichtweite bei Tag. *Die Meteorologische Sichtweite bei Tag ist die längste Distanz, in der ein schwarzes Objekt ausreichender Größe, welches sich in Bodennähe befindet, entgegen des Horizont beobachtet werden kann.*

Die Schätzung der Sichtweite erfolgt dabei durch einen Beobachter und Sichtmarker, d.h. feste, in bekannter Entfernung aufgestellte Sichtziele, welche einen deutlich erkennbaren schwarz-weiß Übergang aufweisen. Bei Nacht erfolgt die Sichtweitenschätzung hingegen anhand von Lichtquellen bekannter Stärke.

Definition Meteorologische Sichtweite bei Nacht. *Die Meteorologische Sichtweite bei Nacht ist die längste Distanz, in der eine Lichtquelle von 1.000 Candela vor einem unbeleuchtetem Hintergrund erkannt und beobachtet werden kann.*

Neben der subjektiven Schätzung der Sichtweite durch einen Beobachter existieren darüber hinaus auf unterschiedlichen Methoden basierende Sichtmesser zur instrumentellen Sichtweitenschätzung.

Im Folgenden wird die visuelle Sichtweitenschätzung anhand eines Beobachters sowie gängige Methoden der instrumentellen Sichtweitenmessung beschrieben. Darüber hinaus wird eine Kategorisierung des Begriffs Nebels anhand der Sichtweite für das hier betrachtete Anwendungsgebiet vorgestellt.

2.5.1 Visuelle Sichtweitenschätzung

Meteorologische Sichtweiten werden üblicherweise über die Sichtbarkeit spezieller, in unterschiedlicher Entfernung gegenüber dem Horizont aufgestellter Sichtziele geschätzt. Zwischen der Helligkeitswahrnehmung des menschlichen Auges und der Änderung eines Lichtreizes besteht jedoch, wie im Abschnitt 2.2 bereits erwähnt, ein stark nichtlinearer Zusammenhang. Laut dem Weber'schen Gesetz ist allgemein für eine gerade noch wahrnehmbare Änderung eines Sinnesindruck eine Reizerhöhung mit konstantem Verhältnis zum Absolutwert nötig [128]. Im vorliegenden Fall bedeutet dies, dass je heller der Leuchtwert L eines Objekts, desto größer muss der Helligkeitsunterschied ΔL zu einem benachbarten Objekt bzw. dem Hintergrund sein, um diese unterscheiden zu können

$$\epsilon = \frac{(L + \Delta L) - L}{L} = \frac{\Delta L}{L}. \quad (2.34)$$

Dieses konstante Verhältnis ϵ , welches für unterschiedliche Reize verschiedene Werte aufweist, wird bei der Betrachtung von Lichtreizen *visuelle Wahrnehmungsschwelle* oder auch *Kontrastschwelle* genannt. Bei Tag basiert die Sichtweitenschätzung auf der von Duntley formulierten Kontrastabnahme aus Gl. (2.33). Zur Bestimmung der Sichtweite

2. Nebel und Sichtweite

d_v muss das Sichtziel, mit einem intrinsischen Kontrast von $C_0 = 1$, einen zur Wahrnehmungsschwelle des Beobachters identischen Kontrast aufweisen

$$\epsilon = C_0 e^{-kd_v}, \quad (2.35)$$

wobei k den für die Sichtbedingungen charakteristischen Extinktionskoeffizienten beschreibt¹. Aufgrund der bekannten Anordnung der Sichtziele kann durch die Messung direkt die Sichtweite bestimmt werden und mit dieser zusätzlich der Extinktionskoeffizient

$$k = -\frac{\ln \epsilon}{d_v}. \quad (2.36)$$

Als Kontrastschwelle empfiehlt die WMO einen Wert von $\epsilon = 0,05$, welcher auch in der Luftfahrt anerkannt ist [19, 132]. In der Literatur finden sich hierzu jedoch unterschiedliche Empfehlungen, wie z.B. $\epsilon = 0,02$ von Koschmieder oder Helmholz. Middleton hat die hierzu durchgeführten Versuche, Daten und Ergebnisse zusammengefasst und diskutiert [83].

Zur visuellen Sichtweitenschätzung bei Nacht werden in bekannten Entfernungen aufgestellte Punktlichtquellen verwendet, bei denen die Lichtintensität in Richtung des Beobachters bekannt ist². Die Entfernung, in welcher eine Punktlichtquelle beobachtet werden kann, wird über das Allerd'sche Gesetz aus Gl. (2.22) beschrieben

$$E_t = \frac{I_0 e^{-kd_v}}{d_v^2}. \quad (2.37)$$

Dabei beschreibt I_0 die Intensität der Lichtquelle und E_t den von der Umgebungshelligkeit abhängigen *Beleuchtungsschwellwert*. Bei einer gerade noch sichtbaren Lichtquelle kann über die Entfernung und die experimentell ermittelten Beleuchtungsschwellen von $10^{-6,0}$, $10^{-6,7}$ bzw. $10^{-7,5}$ für Dämmerung, Mondschein bzw. absoluter Dunkelheit [132] der Extinktionskoeffizient bestimmt werden

$$k = \frac{\ln (I_0 / (E_t d_v^2))}{d_v}. \quad (2.38)$$

Sind der Extinktionskoeffizient, der Beleuchtungsschwellwert und die Intensität der Lichtquelle bekannt, so kann durch Logarithmierung von Gl. (2.37)

$$\ln I_0 - \ln E_t = 2 \ln d_v + k d_v \quad (2.39)$$

die Sichtweite tabellarisch bestimmt werden [75, 84].

¹Hier wird anstelle des Streukoeffizienten der Extinktionskoeffizient verwendet, da die visuelle Sichtweitenschätzung sowohl die Kontrastabschwächung durch Streuung als auch durch Absorption berücksichtigt. Das Vorhandensein von Eiskristallen, Staub oder Schadstoffen kann dazu führen, dass die Absorption einen signifikanten Beitrag zur Verminderung der Sicht beiträgt, bei Nebel ist der absorbierte Anteil hingegen vernachlässigbar gering [132].

²Eine 100 W Glühlampe liefert z.B. näherungsweise eine 100 cd Lichtquelle.

2.5.2 Instrumentelle Sichtweitschätzung

Eine instrumentelle Messung ist vor allem bei Nacht, wenn keine Referenzobjekte zur Verfügung stehen, oder wenn eine automatisierte Beobachtung gewünscht ist, von Vorteil. Hierzu wurde von der WMO eine Präzisierung der Meteorologischen Sichtweite in Form der *Meteorologischen Optischen Sichtweite* (Meteorological Optical Range, MOR) vorgenommen [132].

Definition Meteorologische Optische Sichtweite (MOR). *Die Meteorologische Optische Sichtweite ist die Länge des Pfades in der Atmosphäre, welche benötigt wird, um den Lichtstrom eines kollimierten Strahlenbündels einer Glühlampe mit einer Farbtemperatur von 2.700 K, auf 5 Prozent seines ursprünglichen Werts zu reduzieren, wobei der Lichtstrom durch die photometrische Leuchtkraft-Funktion der Internationalen Beleuchtungskommission ausgewertet wird.*

Laut Definition der MOR muss der Transmissionsfaktor

$$T = E/E_0 = e^{-kd} \quad (2.40)$$

nach durchqueren der Strecke $d = d_v$ den Wert $T = 0,05$ aufweisen. Somit kann durch Messung des Extinktionskoeffizienten über das Bourguer'sche Gesetz aus Gl. (2.21) die Sichtweite bestimmt werden

$$d_v = -\frac{\ln(0,05)}{k} \simeq \frac{3}{k}. \quad (2.41)$$

Zur instrumentellen Messung stehen unterschiedlich arbeitende Methoden zur Verfügung. Diese können zur Unterstützung visueller Sichtweitenmessungen herangezogen werden, wie z.B. Telephometer oder visuelle Extinktiometer, oder automatisiert die Sichtweite bestimmen, wie z.B. Transmissometer oder Scatterometer.

2.5.2.1 Telephometer

Telephometer führen eine visuelle Messung des Extinktionskoeffizienten bei Tag durch, wie z.B. das Lohle Telephometer [76], indem die beobachtete Helligkeit eines Objekts mit der des Hintergrunds, dem Himmel, verglichen wird. Sie werden in der Regel für Routine-Messungen nicht verwendet, da eine direkte visuelle Messung zu bevorzugen ist, können jedoch hilfreich sein um die MOR, welche sich jenseits des am weitesten entfernten Objekts befindet, hochzurechnen.

2.5.2.2 Visuelle Extinktiometer

Das visuelle Extinktiometer ist ein sehr einfaches Gerät zur Messung der Sichtweite bei Nacht. Über ein abgestuftes Neutralfilter kann das Licht entfernter Lichtquellen in einem bekannten Verhältnis gedämpft werden bis es gerade noch beobachtbar ist. Es liefert einen Wert über die Transparenz der Luft zwischen der Lichtquelle und dem Beobachter, womit der Extinktionskoeffizient bestimmt werden kann. Die Genauigkeit wird durch Schwankungen der Sensitivität des Auges und einer unterschiedlichen Strahlenintensität der Lichtquelle beeinflusst, wobei der Fehler proportional zur MOR wächst. Der Vorteil

visueller Extinktiometer ist, dass in einem Bereich von 100 m bis 5 km Sichtweiten mit brauchbarer Genauigkeit gemessen werden können und dabei lediglich drei korrekt angeordnete Lichtquellen benötigt werden. Ohne ein solches Gerät werden hingegen deutlich mehr und aufwändiger aufgestellte Lichtquellen benötigt.

2.5.2.3 Transmissometer

Die Verwendung von Transmissometern ist die weitverbreitetste Methode zur instrumentellen Messung der Sichtweite. Dabei wird mit Hilfe eines Lichtstrahls der Extinktionskoeffizient eines horizontalen, zylindrischen Bereichs der Luft zwischen einer Sende- und Empfangseinheit gemessen. Dazu sendet der Transmitter einen modulierten Lichtstrahl mit im Mittel konstanter Leistung, welcher beim Empfänger über eine Photodiode gemessen wird. Als Lichtquelle wird meist eine Halogenlampe oder eine pulsierende Xenon-Entladungsröhre verwendet, wobei durch Modulation dem Einfluss von Sonnenlicht entgegenwirkt wird. Durch die bekannte Sende- und die gemessene Empfangsleistung kann der Transmissionsfaktor ermittelt werden. Mit diesem und dem bekannten Abstand zwischen Sender und Empfänger d_o kann über Gl. (2.40) und Gl. (2.41) die Sichtweite

$$d_v = d_o \cdot \ln(0,05) / \ln(T) \quad (2.42)$$

bestimmt werden, welche sehr gut mit der Definition der MOR übereinstimmt. Dabei werden zwei Arten von Transmissometern unterschieden, doppelseitig und einseitig endende. Doppelseitig endende Transmissometer bestehen aus einer getrennten Sende- und Empfangseinheit, welche in einer bekannten Entfernung voneinander angeordnet sind (Abb. 2.7(a)). Bei einseitig endenden Transmissometern sind hingegen Sender und Empfänger in einer Einheit untergebracht, wobei das emittierte Licht über einen entfernten Spiegel bzw. Retroreflektor³ bekannter Entfernung zum Empfänger gelangt (Abb. 2.7(b)).

Der Abstand zwischen Transmitter und Empfänger bzw. Retroreflektor wird Baseline genannt und kann sich über wenige Meter bis hin zu 150 m oder sogar 300 m erstrecken. Über die Länge der Baseline kann der Messbereich der Sichtweite angepasst werden, welcher sich über das 1- bis 25-fache der Baseline erstreckt.

2.5.2.4 Scatterometer

Scatterometer messen den Streukoeffizienten

$$\beta = \frac{2\pi}{\Phi_V} \int_0^\pi I(\theta) \sin(\theta) d\theta \quad (2.43)$$

über den in das Volumen V eintretenden Lichtstrom Φ_V und die relativ zum Einfallstrahl in Richtung θ gestreute Lichtintensität $I(\theta)$. Unter der Annahme, dass Streuungs- und Extinktionskoeffizient nahezu identisch sind, wird somit in einem definierten Bereich der Luft über den Anteil des gestreuten Lichts einer bekannten Lichtquelle die Sichtweite

³Ein Retroreflektor reflektiert die einfallende Strahlung weitgehend unabhängig von seiner Ausrichtung zurück zur Strahlenquelle.

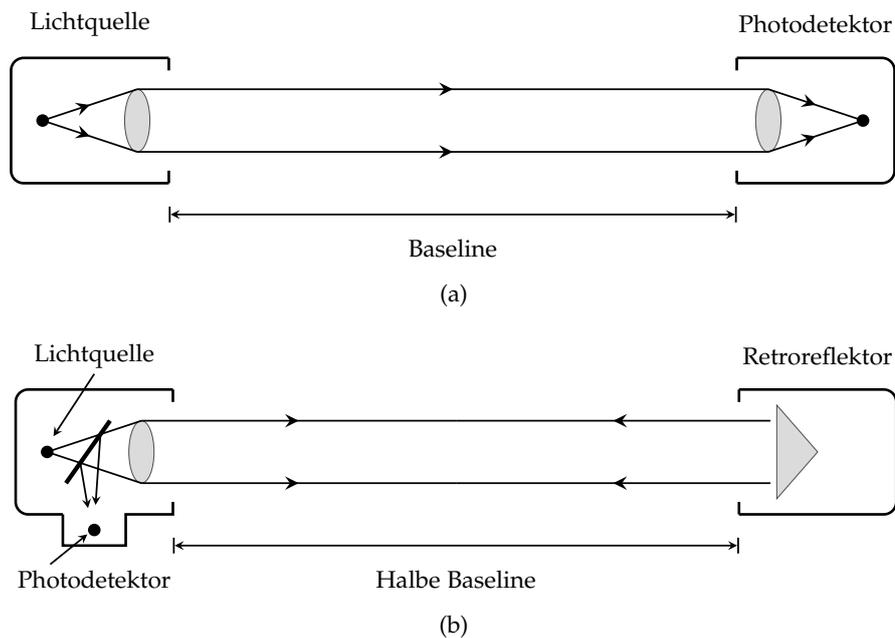


Abbildung 2.7: (a) Doppelseitig endende Transmissometer. Das emittierte Licht wird von einer entfernt aufgestellten Empfangseinheit gemessen. (b) Einseitig endende Transmissometer. Das emittierte Licht gelangt über einen Retroreflektor zum Empfänger, welcher sich im selben Gehäuse wie der Sender befindet. Übernommen aus [132].

bestimmt. Obwohl zur exakten Bestimmung des Streukoeffizienten das gestreute Licht entlang aller Richtungen bestimmt werden muss, wird in der Praxis nur ein bestimmter Bereich untersucht und eine hohe Korrelation zwischen dem gemessenen und dem tatsächlichen Wert angenommen. Der Lichtstrom stammt dabei von einer Sendeeinheit mit pulsierender Lichtquelle und das reflektierte Licht wird über Photodetektorzellen oder Photodioden gemessen. Durch Verwendung einer modulierten Lichtquelle oder durch Abschirmung der Messung von anderen Lichtquellen ist sowohl ein Einsatz bei Tag als auch bei Nacht möglich. Zur Bestimmung der Sichtweite bei Nebel kommen zwei Konstellationen zum Einsatz. Befinden sich Sende- und Empfangseinheit in einem Gehäuse, so wird der Rückstreukoeffizient gemessen. (Abb. 2.8(a)). Laut WMO sind sich die Experten jedoch einig, dass es zwischen diesem und dem Extinktionskoeffizienten keinen allgemeingültigen Zusammenhang gibt [31, 132]. Scatterometer mit getrennter Sende- und Empfangseinheit messen den vorwärtsgerichteten Streukoeffizienten. Sender und Empfänger sind dabei in einem Winkel von 20 bis 50° angeordnet. Alternativ kann auch eine horizontale Anordnung in Verbindung mit einer in der Mitte oder einer jeweils direkt vor Sender und Empfänger angebrachten Blende verwendet werden, wodurch sich zwei getrennte Messbereiche ergeben (Abb. 2.8(b)). Scatterometer kommen vermehrt zur Messung der Sichtweite bei Nebel am Straßenrand zu Einsatz, da sie wenig Platz benötigen (1-2 Meter), die MOR über einen weiten Bereich bestimmen können und relativ geringe Störanfälligkeit gegenüber Verschmutzungen im Vergleich zu Transmissometern aufweisen.

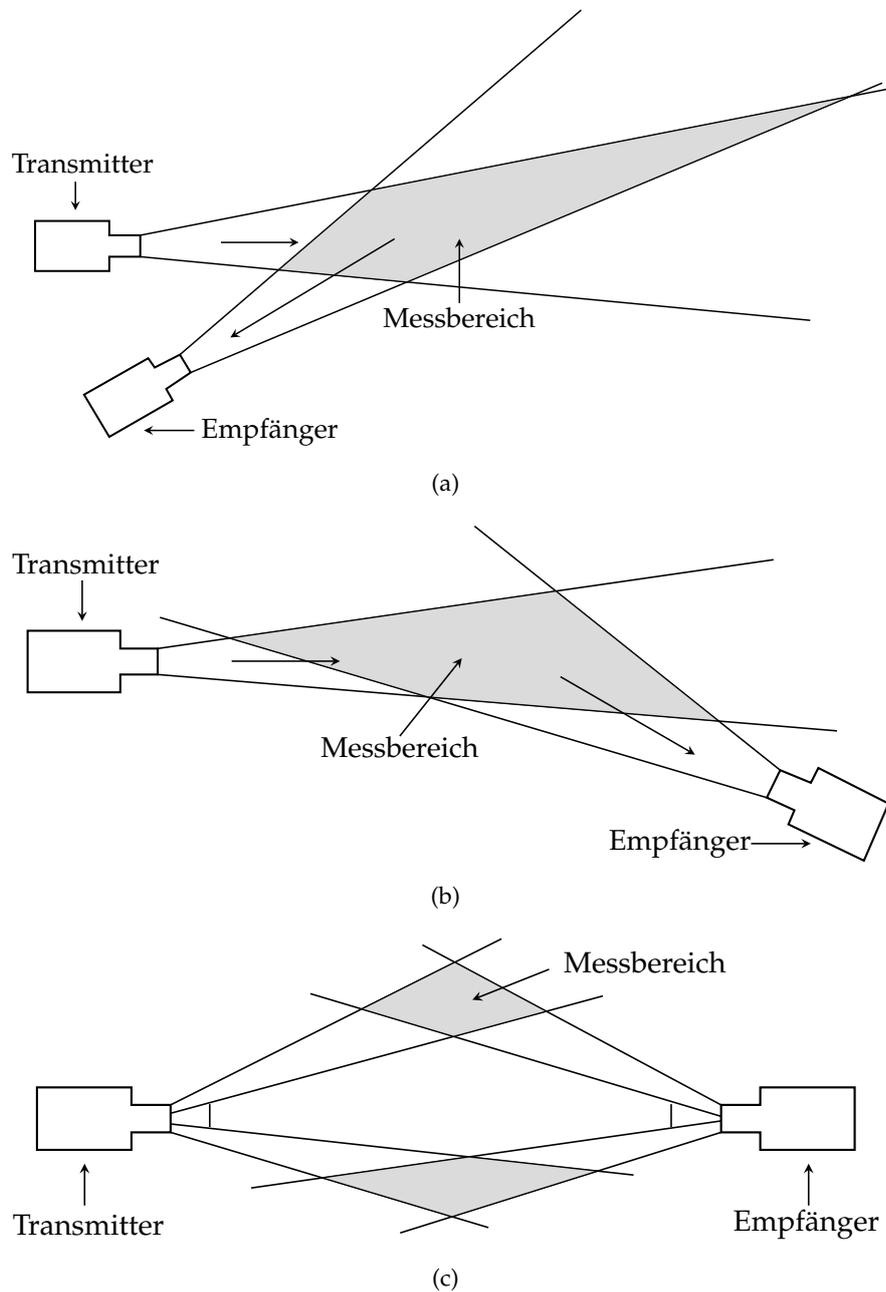


Abbildung 2.8: (a) Scatterometer, welche die Rückstreuung messen. (b) Scatterometer, welche die vorwärtsgerichtete Streuung messen. (c) Scatterometer, welche über mehrere Messbereiche die vorwärtsgerichtete Streuung messen. Übernommen aus [132].

2.6 Meteorologische Sichtbereiche

In Tabelle 2.4 ist der Internationale Sichtweitencode (International Visibility Code, IVC) dargestellt.

Code Nr.	Wetterbedingung	Meteorologischer Bereich	Streukoeffizient $[\text{km}^{-1}]$
0	Dense Fog	< 50 m	> 78,2
1	Thick Fog	50 m – 200 m	78,2 – 19,6
2	Moderate Fog	200 m – 500 m	19,6 – 7,82
3	Light Fog	500 m – 1.000 m	7,82 – 3,91
4	Thin Fog	1 km – 2 km	3,91 – 1,96
5	Haze	2 km – 4 km	1,96 – 0,954
6	Light Haze	4 km – 10 km	0,954 – 0,391
7	Clear	10 km – 20 km	0,391 – 0,196
8	Very Clear	20 km – 50 km	0,196 – 0,078
9	Exceptionally Clear	> 50 km	> 0,078

Tabelle 2.4: Internationaler Sichtweiten Code mit meteorologischen Bereichen der Sichtweite und des Streukoeffizienten [55].

Während diese Einteilung in Sichtbereiche für allgemeine Zwecke sinnvoll erscheint, ist es jedoch naheliegend, dass für konkrete Anwendungen unterschiedliche Kategorisierungen nötig sind [132]. In der zivilen Luftfahrt beträgt die obere Grenze des Messbereichs z.B. 10 km. Da für den Straßenverkehr keine allgemeingültige Eingrenzung bzw. Kategorisierung des Messbereichs vorliegt, wurde entsprechend der Empfehlung der WMO, für das konkrete Anwendungsgebiet diese zu definieren, die Überlegung zugrunde gelegt, dass ein Verkehrsteilnehmer sich sicher fortbewegt, wenn er innerhalb der ihm zur Verfügung stehende Sichtweite sein Fahrzeug zum Stillstand bringen kann. Der hierzu benötigte Anhalteweg d_A , welcher sich aus der zurückgelegten Strecke d_R während der Reaktionszeit t_R sowie dem Bremsweg d_B zusammensetzt, kann über ein vereinfachtes Modell in Abhängigkeit der Fahrzeuggeschwindigkeit v_{veh} und der Verzögerung a formuliert werden

$$d_A = d_B + d_R = \frac{v_{\text{veh}}^2}{2a} + v_{\text{veh}} \cdot t_R, \quad (2.44)$$

Diese Gleichung lässt sich umformulieren

$$v_{\text{veh}}(d_A) = \frac{-t_R + \sqrt{t_R^2 + 2d_A/a}}{1/a}, \quad (2.45)$$

sodass sich schnell, wie in Abb. 2.9 dargestellt, aus dem Anhalteweg die anfängliche Fahrzeuggeschwindigkeit ablesen lässt. Hierzu wurden für die Parameter Reaktionszeit und mittlere Verzögerung die Werte 0,8 s und 7,716 m/s² verwendet⁴.

⁴Die Werte für die Reaktionszeit und mittlere Verzögerung stammen aus einer Beispielrechnung der Bayerischen Polizei [100].

2. Nebel und Sichtweite

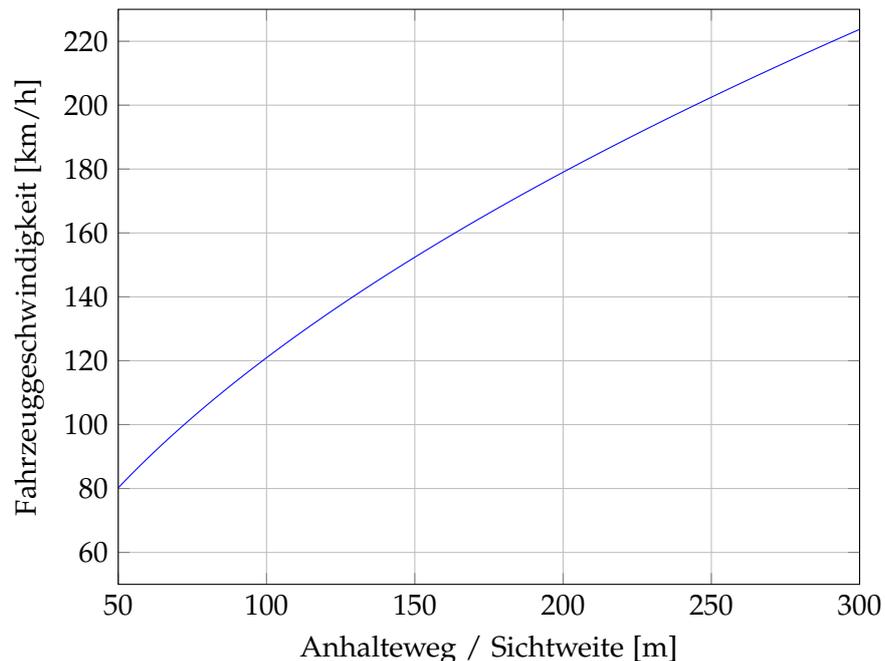


Abbildung 2.9: Anhalteweg bzw. Sichtweite relativ zur Fahrzeuggeschwindigkeit.

Wird der Anhalteweg durch die Sichtweite substituiert, so kann eine Abschätzung der unter diesen Bedingungen maximal vertretbaren Geschwindigkeit getroffen werden. Bei einer Sichtweite von 300 m sollte demnach nicht schneller als ca. 220 km/h gefahren werden. Dadurch wird ersichtlich, dass in dieser Situation keine allzu großen Beeinträchtigungen vorliegen. Bei Sichtweiten von ca. 100 m sollte jedoch nicht schneller als ca. 120 km/h gefahren werden, was darauf hindeutet, dass in diesem Fall, vor allem auf Autobahnen, durchaus eine Beeinträchtigung vorliegt. Anhand dieser Überlegung, welche auch die subjektiven Eindrücke bei den später näher erläuterten Messfahrten bestätigt, wurde folgende Kategorisierung des Begriffs Nebel für das Anwendungsgebiete des Straßenverkehrs vorgenommen:

- *Kein Nebel:* Sichtweite > 1.000 m
- *Leichter Nebel:* Sichtweite zwischen 300 und 1.000 m
- *Nebel:* Sichtweite zwischen 100 und 300 m
- *Dichter Nebel:* Sichtweite < 100 m

Je nach spezifischem Anwendungsgebiet ist nun zu entscheiden, wann von einer Nebel-Situation gesprochen wird. Im Falle der Lokale Gefahrenwarnung, bei welcher auf eine gefährlichen Situation hingewiesen werden soll, ist dies z.B. lediglich bei dichtem Nebel der Fall, weshalb hier vereinfacht von Nebel gesprochen wird, wenn Sichtbedingungen von unter 100 m vorliegen. Bei eingeschaltetem Fernlicht könnte hingegen bereits früher eine Blendung des Fahrers eintreten, weshalb für das Anwendungsgebiet des Fernlichtassistenten eine andere Unterscheidung denkbar ist.

In diesem Kapitel werden bekannte Verfahren zur Nebeldetektion zusammengefasst, welche als Eingangsquelle ausschließlich Kamerabilder verwenden. Verfahren, welche das Vorhandensein spezifischer Objekte voraussetzen, wie z.B. Sichtziele [69, 122] oder klar definierte Lichtquellen [37], werden hier nicht betrachtet, da sie für den Einsatz im Fahrzeug als nicht geeignet erscheinen. Zunächst wird ein für den stationären Einsatz konzipiertes Verfahren vorgestellt, welches einen interessanten ersten Ansatz liefert und grundsätzlich durch entsprechende Anpassungen auch im Fahrzeug anwendbar scheint. Die anschließend vorgestellten Arbeiten haben gemeinsam, dass sie eine im Fahrzeug montierte Kamera verwenden und unterscheiden sich in den gewählten Ausgangsgrößen, wie z.B. eine relative Sichtbeeinträchtigung, die Sichtweitschätzung als physikalische Größe oder die Kategorisierung in verschiedene Klassen, den Einsatz-Szenarien, wie z.B. bei Tag oder bei Nacht, sowie den zugrundeliegenden Modellannahmen der Umgebungsbedingungen. Abschließend werden die Ansätze diskutiert sowie eine Differenzierung zu dem in dieser Arbeit vorgestellten Verfahren vorgenommen.

3.1 Statische Nebeldetektion und Sichtweitschätzung

Busch und Debers stellten einen Ansatz zur kamerabasierten Sichtweitschätzung bei Nebel für den stationären Einsatz in Verkehrsleitsystemen vor [14]. Er beruht auf der internationalen Definition der Sichtweite und der von WMO und CIE empfohlenen Kontrastschwelle von 5 % [19, 132], wodurch die Sichtweite über das am weitesten entfernte Objekt, welches gegenüber seiner direkten Umgebung einen Kontrast größer 5 % aufweist, bestimmt wird.

Dazu wird im Kamerabild, wie in Abb. 3.1 dargestellt, der Bereich der Fahrbahn einer Fahrtrichtung manuell maskiert und in diesem die Intensitäts-Gradienten über B-Spline Wavelets approximiert. Diejenige Bildzeile, oberhalb derer keine Gradienten größer eines experimentell ermittelten Schwellwerts auftreten, liefert schließlich die Sichtweite im Kamerabild. Der dazu benötigte Schwellwert wird über den maximalen Gradienten eines Testbilds bestimmt, welches einen Kontrast von 5 % aufweist. Durch die bekannte Anordnung der Kamera und der Annahme einer flachen Welt, d.h. der Annahme, dass alle Objekte des untersuchten Bereichs in einer bekannten Ebene liegen, kann die Sichtweite

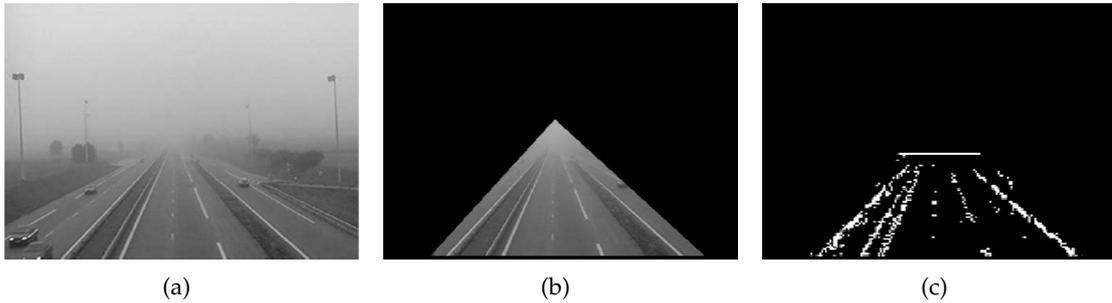


Abbildung 3.1: Stationärer Ansatz von Busch und Debers. (a) Ausgangsbild mit Nebel und einer Sichtweite von ca. 100 m. (b) Maskiertes Bild. (c) Intensitäts-Gradienten aus B-Spline Wavelets, welche einem Kontrast größer 5 % entsprechen und die daraus resultierende Sichtweitenschätzung.

in Weltkoordinaten transformiert und somit in der Einheit Meter ausgegeben werden. Bis 300 m wird die Sichtweite in 10 m Intervallen und zwischen 300 und 1.000 m in 50 m Intervallen ausgegeben. Beträgt die ermittelte Sichtweite mehr als 1.000 m liegt entsprechend der internationalen Definition kein Nebel vor.

3.2 Prozentuale Sichtbeeinträchtigung

Pomerleau stellte als erster einen Ansatz zur Schätzung der Sichtbedingung unter Verwendung einer im Fahrzeug montierten Kamera vor [102]. Das Verfahren liefert einen prozentualen Wert zur Sichtbeeinträchtigung und soll in beliebigen Situationen, wie z.B. Nebel, Regen, Schneefall oder Blendung, einsetzbar sein.

Hierzu wurde das zuvor entwickelte System RALPH (Rapidly Adapting Lateral Position Handle) [103] zur Bestimmung der Position und Krümmung der Fahrbahn um eine Untersuchung der Kontrastabnahme entlang gleichartiger Fahrbahnmerkmale erweitert. Als Fahrbahnmerkmale werden z.B. Fahrspurmarkierungen, das Bankett oder auch Ölspuren verwendet. Zur Merkmalsextraktion wird ein trapezförmiger Bereich, welcher Fahrbahninformationen im Bild enthält, definiert. Die Position und Ausdehnung dieses Bereichs variiert hierbei in Abhängigkeit der aktuellen Fahrzeuggeschwindigkeit und den aktuellen Sichtverhältnissen. Unter guten Sichtbedingungen erstreckt sich dieser von 50 bis 120 m vor dem Fahrzeug mit einer Breite von 7 m pro Bildzeile, was in etwa der doppelten Breite einer gewöhnlichen Fahrspur entspricht. Der trapezförmige Bildausschnitt wird anschließend unter der Annahme, dass die Fahrbahn in diesem Bereich planar ist, über eine geometrische Transformation in die Vogelperspektive überführt, dem sogenannten Areal Image. Dadurch gleicht eine gerade Straße einem Band paralleler Streifen aus Fahrbahnmarkierungen und anderen Fahrbahnmerkmalen (Abb. 3.2).

Durch einen zur Fahrbahn senkrechten Querschnitt aus dem unteren Bereich des Areal Image wird anschließend eine eindimensionale Darstellung der Fahrbahn erstellt, das sogenannte Fahrbahn Template. An Stellen, an denen Fahrbahnmerkmale im Bild enthalten sind, wie dies z.B. bei Fahrspuren der Fall ist, weist das Template markante

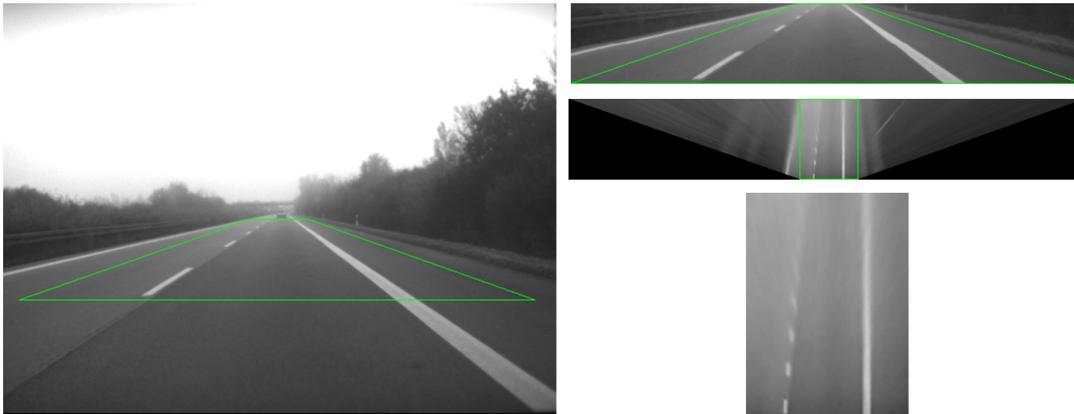


Abbildung 3.2: Prozentualer Ansatz von Pomerleau. Links: Bild einer mit in dieser Arbeit verwendeten Versuchsaufbau aufgenommene Fahrszene mit geradem Fahrspurverlauf und den zu untersuchenden Bereich. Aufgrund einer unterschiedlichen Positionierung der Kamera im Vergleich zu [102] erstreckt sich dieser von 10 bis 100 m vor dem Fahrzeug mit einer Breite von jeweils 7 m pro Bildzeile. Rechts oben: Bildausschnitt um den untersuchten Bereich. Rechts Mitte: Rektifizierter Bildausschnitt. Rechts unten: Vergrößerter Bereich mit Fahrbahnhinformatoren aus rektifiziertem Bild, das sogenannte Areal Image.

Intensitätssprünge auf. RALPH bestimmt anhand des Fahrbahn Templates und anhand weiterer Intensitätsprofile des Areal Image die Position und Krümmung der Fahrbahn. Dazu werden Hypothesen zum Fahrspurverlauf aufgestellt und entsprechend dieser einzelne Zeilen des Areal Image nach links bzw. rechts verschoben. Die Hypothesen geben dabei vor, wie stark und in welche Richtung einzelne Zeilen verschoben werden müssen, um die Krümmung der Fahrspur zu kompensieren und einen geraden Fahrspurverlauf zu erhalten. Diejenige Hypothese, deren Zeilenverschiebung zum besten Ergebnis führt, wird zur Beschreibung der Position und der Krümmung der Fahrbahn herangezogen. Das hieraus resultierende, zeilenweise verschobene Areal Image dient als Ausgangsbasis zur Schätzung der Sichtbeeinträchtigung.

Hierzu wird anhand mehrerer Querschnitte aus dem unteren und oberen Bereich jeweils die maximale Abweichung vom Median-Intensitätswert, welcher aus der Fahrbahnmittle entnommen wird, gemittelt. Die Differenz der zwei so gewonnenen Werte liefert schließlich die Kontrastabnahme, welche anschließend auf die durch den untersuchten Bereich abgedeckte Distanz normiert wird (Abb. 3.3). Da selbst bei idealen Sichtverhältnissen eine Abschwächung des Kontrasts aufgrund von Kameraeigenschaften auftritt, wird eine weitere Normierung vorgenommen, sodass das System letztendlich einen prozentualen Wert der Sichtbeeinträchtigung ausgibt, welcher bei uneingeschränkten Sichtverhältnissen den Wert Eins aufweist.

Zur Evaluierung des Verfahrens wurden für die Situationen klare Sichtbedingungen bei Tag, Nacht ohne externe Lichtquellen und Regen auf einer 24 km langen Teststrecke und für die Situationen Nacht mit externe Lichtquellen und Blendung auf einem 3 km langem Teilstück der Teststrecke Bilder aufgenommen. Dabei zeigte sich, dass bei klaren Sichtbedingungen der höchste Wert ausgegeben wird (ca. 0,8), gefolgt von Sichtbehinderungen durch Dunkelheit mit bzw. ohne externe Lichtquellen (ca. 0,5 bzw.

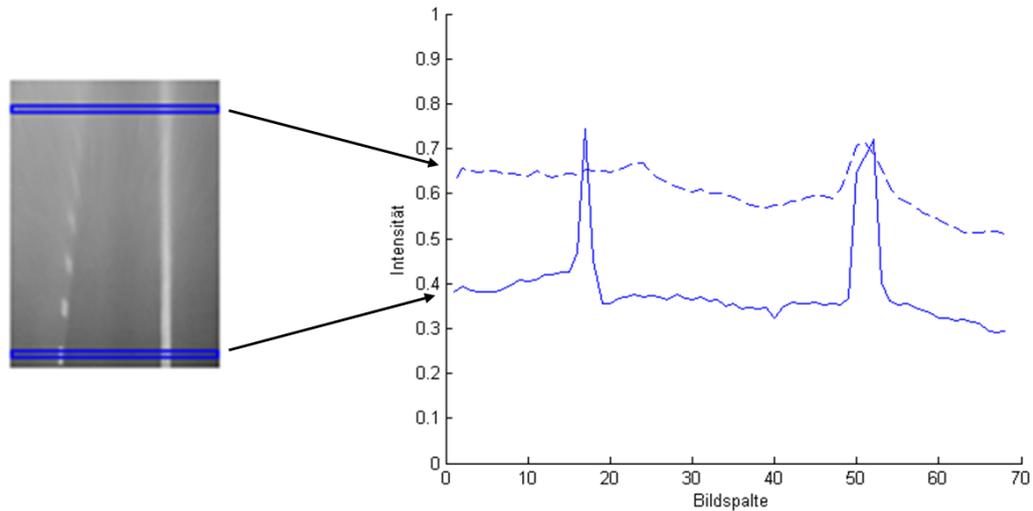


Abbildung 3.3: Intensitätsprofile aus zeilenweise verschobenem Areal Image. Die durchgezogene Linie zeigt das Intensitätsprofil eines Querschnitts aus dem unteren Bereich (das Fahrbahn Template), die gestrichelte Linie das Intensitätsprofil eines Querschnitts aus dem oberen Bereich des verschobenen Areal Image. Zur Bestimmung der Sichtbeeinträchtigung wird der Unterschied der Intensitätssprünge, jeweils aus mehreren Intensitätsprofilen des oberen und unteren Bereichs, verwendet.

ca. 0,4), Sichtbeeinträchtigungen durch Regen (ca. 0,2) und Sichtbehinderung durch Blendung (ca. 0,1). Zur Untersuchung des Systemverhaltens bei Nebel wurden mit Hilfe der EOFAST Software [104] anhand von 30 bei klaren Sichtbedingungen aufgenommenen Bildern Nebelbedingungen mit Sichtweiten von 700, 400, 300 und 100 m Sichtweite simuliert. Dabei konnte ein tendenziell abnehmender Wert der prozentualen Sichtbeeinträchtigung bei sinkenden Sichtweiten beobachtet werden, von ca. 0,65 bei klaren, 0,6 bei 700 m, 0,5 bei 400 sowie 300 und ca. 0,3 bei 100 m Sichtweite. Die Messungen unterlagen jedoch mit Standardabweichungen von ca. 0,2–0,3 sehr starken Schwankungen, sodass der Autor empfiehlt mindestens 30 aufeinanderfolgende Bilder für eine verlässliche Aussage zu verwenden.

3.3 Sichtweitenschätzung mittels Extinktionskoeffizient

Ein weiteres Verfahren zur Schätzung der Sichtweite über eine im Fahrzeug montierte Kamera wurde von Hautière *et al.* vorgestellt, welches jedoch explizit für den Einsatz bei Nebel entwickelt wurde und eine Sichtweitenschätzung in der Einheit Meter ausgibt [53]. Wie bereits in Kapitel 2 beschrieben kann die Kontrastabschwächung eines Objekts über

$$C = C_0 e^{-kd}, \quad (3.1)$$

modelliert werden, wobei C_0 den intrinsischen Kontrast eines Objekts, k den für die Umgebungsbedingungen charakteristischen Extinktionskoeffizienten und C den in der Entfernung d wahrgenommenen Kontrast beschreibt. Unter der Annahme, dass ein

schwarzes Objekt vor weißem Hintergrund untersucht wird, d.h. $C_0 = 1$, und unter Verwendung einer Kontrastschwelle von 5 %, d.h. $C = 0,05$, kann somit die Sichtweite in Abhängigkeit des Extinktionskoeffizienten angegeben werden

$$d_V = -\frac{1}{k} \ln(0,05). \quad (3.2)$$

Die Autoren schätzen nun anhand des Kamerabilds den Extinktionskoeffizienten um somit über Gl. (3.2) die Sichtweite zu bestimmen. Hierzu verwenden Sie die von Koschmieder fomulierte Airlight Formel

$$L = L_0 e^{-kd} - L_\infty (1 - e^{-kd}), \quad (3.3)$$

wobei L_∞ die Helligkeit des Hintergrunds, L die wahrgenommene und L_0 die intrinsische Helligkeit eines Objekts beschreiben. Unter der Annahme eines linearen Zusammenhangs zwischen der Helligkeit eines Objekts und korrespondierenden Pixelwerten im Kamerabild, d.h. $L \propto I$, und der Annahme, dass der im Kamerabild untersuchte Bereich in einer bekannten Ebene liegt, kann Gl. (3.3) als eine von der Bildzeile \tilde{v} abhängige Intensitätsfunktion formuliert werden

$$I(\tilde{v}) = I_0 e^{-k\tilde{v}} - I_\infty (1 - e^{-k\tilde{v}}), \quad (3.4)$$

mit

$$\tilde{v} = \frac{f_{px} h}{(v - v_h) \cos(\theta)}, \quad \forall v \in \{v | v > v_h\}, \quad (3.5)$$

wobei v die Bildzeile, v_h die zur Horizontallinie korrespondierende Bildzeile, f_{px} die Brennweite in der Einheit Pixel, h die Anbauhöhe und θ den Neigungswinkel der Kamera beschreiben. Über den Wendepunkt der Intensitätsfunktion

$$v_i: \frac{d^2 I}{d^2 v} = 0 \quad (3.6)$$

wird schließlich der Extinktionskoeffizient ermittelt

$$k = \frac{2 \cos(\theta)}{f_{px} h} (v_i - v_h). \quad (3.7)$$

und mit diesem über Gl. (3.2) und der Transformationsvorschrift aus Gl. (3.5) die Sichtweite bestimmt. In Abb. 3.4 sind hierzu modellhafte Intensitätsfunktionen und deren Ableitungen für unterschiedliche Extinktionskoeffizienten bei konstanten Werten für L_0 und L_∞ dargestellt.

Die zu untersuchende Intensitätsfunktion wird mit Hilfe eines modifizierten Region Growing Verfahrens aus den Bilddaten bestimmt. Dabei wird ein zusammenhängender Bereich (Region of Interest, RoI) extrahiert, welcher, ausgehend von einer Position direkt vor dem Fahrzeug, sich im Bild von unten nach oben erstreckt und sowohl Teile der Fahrbahn als auch Teile des Himmels enthält (Abb. 3.5(a)). Da die untersuchten Bereiche der Fahrbahn und des Himmels möglichst homogen sein sollen, wird innerhalb der RoI

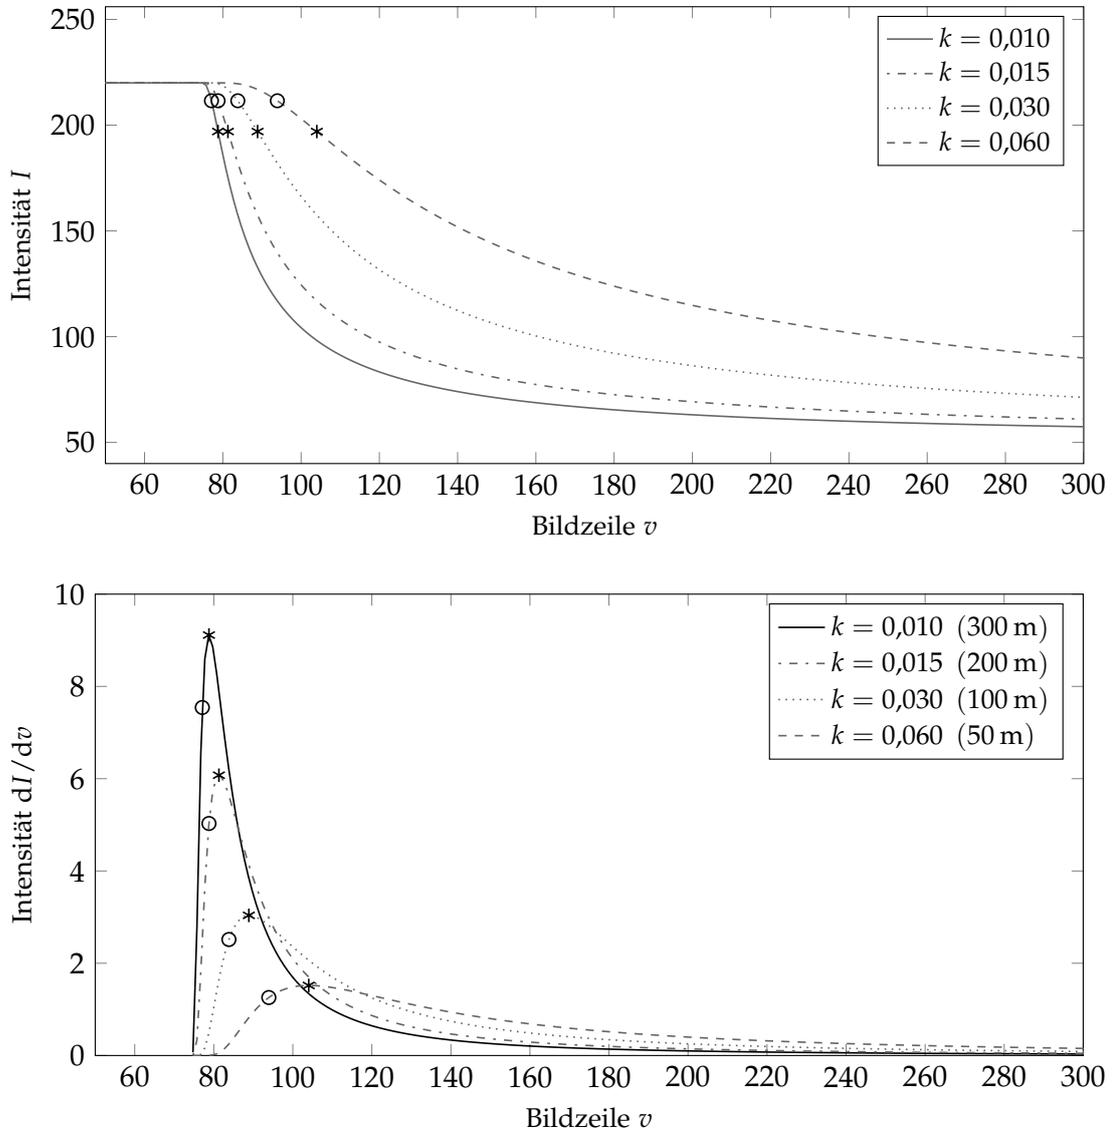


Abbildung 3.4: Oben: Wahrgenommene Intensität I in Abhängigkeit zur Entfernung bzw. Bildzeile v für unterschiedliche Extinktionskoeffizienten k , von 0,010 bis 0,060 bzw. Sichtweiten von 300 bis 50 m. Als intrinsische Intensität wurde $I_o = 50$ und als Hintergrund-Intensität $I_\infty = 220$ gewählt, die Parameter des von Hautière *et al.* verwendeten Versuchsaufbaus waren $f_{px} = 500$ px, $h = 2$ m, $\theta = \frac{8\pi}{180}$ und $v_h = 74$ px. Unten: Erste Ableitung der Intensitätsfunktion. Die Maxima der einzelnen Funktionen entsprechen den zur Sichtweitungsschätzung verwendeten Wendepunkten und sind mit (*) gekennzeichnet. Die hieraus resultierenden Sichtweiten in Bildkoordinaten wurden mit (o) veranschaulicht.

ein sogenannter Messbereich bestimmt, welcher möglichst geringe Gradientensprünge zwischen den Zeilen aufweist. Die Median-Intensitätswerte der einzelnen Zeilen des Messbereichs werden schließlich zur Beschreibung der Intensitätsfunktion herangezogen, welche anschließend noch geglättet wird um eine streng monoton fallende Funktion zu erhalten (Abb. 3.5(b)).

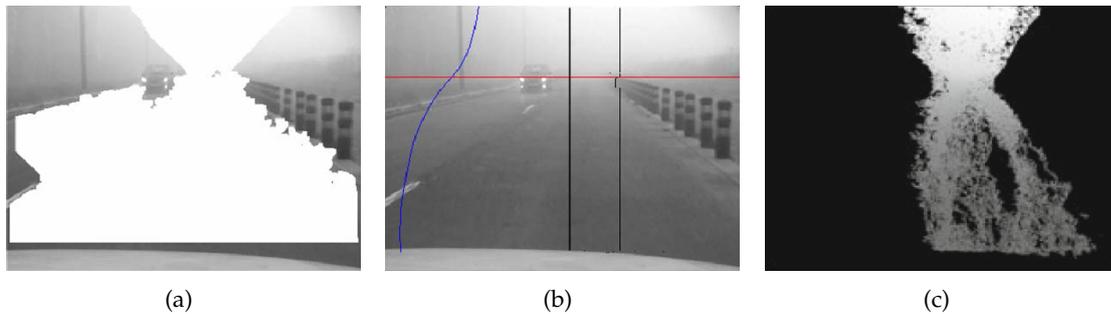


Abbildung 3.5: Ansatz von Hautière *et al.* (a) Zusammenhängender Bereich aus Fahrbahn und Himmel (RoI). (b) Die beiden vertikalen schwarzen Linien begrenzen den Messbereich innerhalb der RoI. Diese enthält homogene Bereiche der Fahrbahn und des Himmels und weist minimale Intensitätssprünge zwischen den Zeilen auf. Die blaue Kurve visualisiert die geglättete Intensitätsfunktion, welche sich aus den Median-Werten der einzelnen Zeilen des Messbereichs ergibt. Die horizontale rote Linie zeigt die aus der Intensitätsfunktion geschätzte Sichtweite. (c) Messbereich basierend auf dem kürzesten Pfad und der Abstandstransformation WDTOCS.

In [52] haben Hautière *et al.* eine Modifikation Ihres Verfahrens vorgestellt um zwei Einschränkungen Ihres ursprünglichen Verfahrens entgegenzuwirken. Zur Bestimmung der Intensitätsfunktion muss sowohl bei der Segmentierung mittels Region Growing als auch bei der Bestimmung des Messbereichs eine zusammenhängende Bildregion gefunden werden, beginnend von der untersten bis zur obersten Bildzeile. Dies gelingt jedoch nicht, wenn vorausfahrende Fahrzeuge, welche den Horizont verdecken, oder Brücken vorhanden sind, oder wenn die Fahrbahn eine starke Textur aufweist. Um dem entgegenzuwirken schlagen die Autoren einen alternativen Ansatz ohne Region Growing zur Bestimmung des Messbereichs vor. Dabei wird mit Hilfe der gewichteten Abstandstransformation WDTOCS (Weighted Distance Transform On Curved Space) [57] der kürzeste Pfad zwischen der Fahrbahn und dem Himmel berechnet und als Intensitätsfunktion verwendet (Abb. 3.5(c)). Dadurch werden lediglich die Annahmen getroffen, dass sich im unteren Bildbereich, d.h. direkt vor dem Fahrzeug, die Fahrbahn befindet und die Himmel-Region oberhalb der Horizontallinie liegt und aus den hellsten Intensitätswerten besteht. Desweiteren weisen die Autoren auf die Sensitivität des Verfahrens bzgl. der Verwendung einer exakten Horizontallinie hin. Im ursprünglichen Ansatz wird sie als konstant angenommen und in einer initialen Kalibrierung bestimmt. Vor allem bei Nickbewegungen der Karosserie sollen dadurch jedoch erhebliche Fehler auftreten, wodurch beim modifizierten Verfahren die Horizontallinie variabel gehalten wurde, indem sie über die Nullstellen der dritten Ableitung der Intensitätsfunktion für jedes Bild bestimmt wird.

3.4 Entfernung zum sichtbaren Horizont

Ein weiterer Ansatz zur Schätzung der Sichtweite bei Nebel über eine im Fahrzeug montierte Kamera wurde von Bronte *et al.* vorgestellt [12]. Das Verfahren schätzt anhand der Bilddaten die Sichtweite in der Einheit Meter und führt eine Kategorisierung der Fahrszene in die Klassen dichter Nebel (Sichtweite < 100 m), Nebel (Sichtweite zwischen 100 und 300 m) und kein Nebel (Sichtweite > 300 m) durch. Zur Schätzung der Sichtweite wird mittels Hough Transformation [27] der aktuelle Fluchtpunkt bestimmt und mit Hilfe eines Region Growing Verfahrens [1] eine Himmel- und eine Fahrbahnregion extrahiert. Befindet sich die untere Grenze der Himmel-Region oberhalb des Fluchtpunkts wird entschieden, dass keine Nebel Situation vorliegt. Andernfalls wird zusammen mit der oberen Grenze der Fahrbahn Region durch Mittelung die Position des sichtbaren Horizonts im Kamerabild bestimmt. Unter der Annahme einer flachen Welt kann mit dieser über die perspektivische Projektion die Sichtweite in der Einheit Meter bestimmt werden. Für eine effiziente Implementierung und um Fehldetektionen zu vermeiden wird dem Verfahren zudem ein einfacher schwellwertbasierter Nebel-Klassifikator vorgestellt. Dabei werden mittels Sobel Operator Gradientenbeträge der oberen Bildhälfte, welche einen bestimmten Wert überschreiten, aufsummiert. Unterschreitet die Summe der Gradientenbeträge einen Schwellwert, so wird anschließend die Sichtweite geschätzt, andernfalls wird die Fahrszene als nebelfrei klassifiziert und die Untersuchung des aktuellen Bildes abgebrochen. Da die Sichtweitenschätzung basierend auf ein einzelnes Bild sehr instabil ist, d.h. zeitlich betrachtet über mehrere aufeinanderfolgende Bilder starken Schwankungen unterworfen ist, wird eine Median-Bildung über eine feste Zeitperiode durchgeführt.

Das vorgestellte Verfahren ist laut Autoren bei einer Bildgröße von 320×240 Pixel und einer Bildwiederholfrequenz von 30 Hz echtzeitfähig und konnte basierend auf einer Untersuchung von insgesamt 36.028 Bildern eine Erkennungsrate von 87 % erzielen. Fehlklassifikationen treten vor allem bei Blendung und beim Vorhandensein mehrerer Fahrzeuge im Bereich des Horizonts auf. Im erstgenannten Fall entschied sich der Klassifikator fälschlicherweise für eine Nebel-, im zweitgenannten fälschlicherweise für eine nebelfreie Fahrszene.

3.5 Stereokamerabasierter Ansatz

In [48, 49, 51] haben Hautière *et al.* einen stereokamerabasierten Ansatz vorgestellt, welcher trotz der Einschränkung auf ein Monokamerasystem interessant erscheint, da bereits ab 2013 erste Serienfahrzeuge mit einem solchen Kamerasystem angeboten werden. Die Autoren nennen als wesentlichen Vorteil des Stereokamerasystems, dass hierdurch ein Einsatz sowohl bei Tag als auch bei Nacht ermöglicht wird. Desweiteren soll durch die vorliegenden Tiefeninformationen im Vergleich zu einem monokamerabasierten Ansatz, eine exaktere Quantifizierung der Sichtbeeinträchtigung ermöglicht werden.

Die Sichtweite wird dabei über das am weitesten entfernte, detektierbare Objekt auf der Fahrbahn, welches einen Kontrast größer 5 % aufweist, bestimmt. Dazu wird zunächst die Disparitätskarte des Stereokamerasystems mit Hilfe der sogenannten v-Disparity

Map um diejenigen Werte bereinigt, welche nicht zu Objekten der Fahrbahn gehören [70, 71]. Anschließend wird für die verbleibenden Disparitätswerte über die Methode von Kohler [66] der lokale, logarithmische Kontrast nach Jourlin und Pinoli [62] bestimmt. Dazu werden aus einem Kamerabild der Intensitätswert der betrachteten Position sowie dessen direkte Nachbarn herangezogen. Ist der ermittelte Kontrast kleiner 5 %, so wird der Disparitätswert verworfen. Der kleinste verbleibende, zum am weitesten entfernten Objekt zugehörige Disparitätswert liefert schließlich die aktuelle Sichtweite.



Abbildung 3.6: Sichtweiteschätzung mittels Stereoskopie. (a) Rechtes Kamerabild bei Nebel. (b) Disparitätskarte des Stereokamerasystems. (c) Disparitätskarte der Fahrbahn. (d) Bild mit Kontrasten größer 5 % (Nur zur Visualisierung, wird aus Effizienzgründen nicht für das gesamte Bild sondern nur für Disparitätswerte der Fahrbahn berechnet).

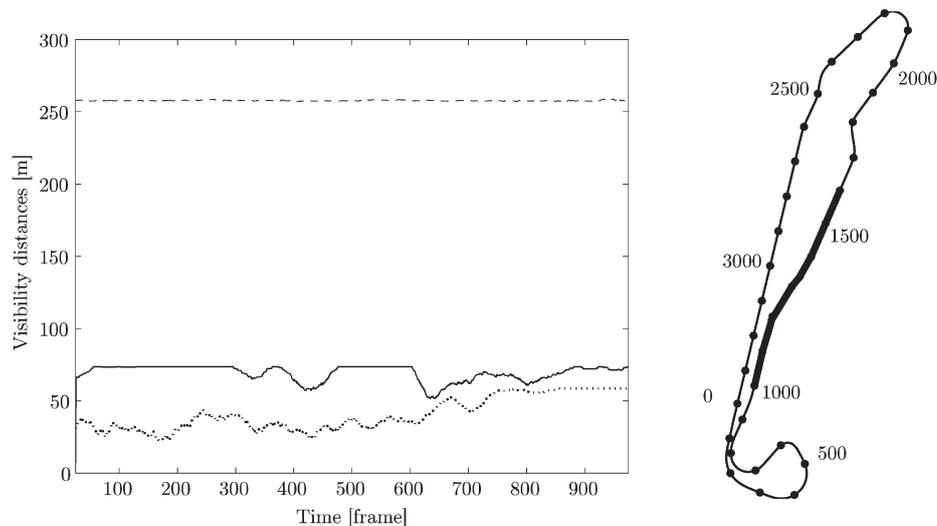


Abbildung 3.7: Ergebnisse Sichtweiteschätzung mittels Stereoskopie. Links: Sichtweiten bei klaren Wetterbedingungen (- -), Nebel bei Tag (-) und Nebel bei Dämmerung (· · ·). Rechts: Abschnitt der Teststrecke zur Aufnahme der Videosequenzen.

Das Verfahren wurde anhand von drei Videosequenzen untersucht, welche jeweils aus 1.000 Bildern bestehen und auf einem identischen Abschnitt einer Teststrecke aufgenommen wurden. Die erste Videosequenz beinhaltet klare, sonnige Wetterbedingungen mit einer in unterschiedlichen Entfernungen durchgeführten Folgefahrt. Die zweite Sequenz wurde unter Nebelbedingungen aufgenommen, wobei einem anderen Fahrzeug

mit zunehmend größer werdendem Abstand gefolgt wurde. Die dritte Sequenz enthält Aufnahmen bei Nebel und freier Strecke kurz vor der Dämmerung. Als Ergebnis wurden die für die jeweilige Sequenz ermittelten Sichtweiten ausgewertet. Bei klaren Sichtverhältnissen lieferte das Verfahren durchgehend die durch das Stereokamerasystem maximal mögliche Sichtweite von etwas über 250 m, bei der zweiten Sequenz ergaben sich Sichtweiten zwischen 50 und 75 m und bei der dritten Sichtweiten zwischen 30 und 50 m. Aus der Untersuchung gehen dabei zwei wesentliche Punkte hervor. Zum einen scheint die Verwendung einer festen Kontrastschwelle von 5 % unangemessen zu sein, besser wäre ein Schwellwert der sich der Umgebungshelligkeit anpasst. Des Weiteren ist die Verwendung der bereinigten Disparitätskarte vor allem bei kontrastarmen Bildern problematisch, da in diesen Fällen Tiefenwerte nur für sehr wenige Bildpunkte bestimmt werden können.

3.6 Sichtweiteschätzung und Nebeldetektion bei Nacht

Während alle bisher vorgestellten Verfahren im Wesentlichen auf Szenen bei Tag basieren, haben Gallen *et al.* ein Ansatz zur Nebeldetektion und Sichtweiteschätzung bei Nacht vorgestellt [36]. Das Problem wird dabei in zwei Szenarien unterteilt. Sind keine externen Lichtquellen, wie z.B. Straßenbeleuchtungen oder Scheinwerfer vorausfahrender oder entgegenkommender Fahrzeuge, vorhanden, so wird die Lichtausbreitung der eigenen Frontscheinwerfer im Kamerabild untersucht. Dazu werden mehrere aufeinanderfolgende Bilder gemittelt und mit Referenzbildern verglichen. Die Mittelung wird durchgeführt, um den Einfluss dynamische Bildinformationen, wie z.B. Fahrspuren, zu verringern. Als Referenzbilder wurden über eine Semi Monte Carlo Raytracing-Methode [28] simulierte Bilder mit unterschiedlichen Sichtweiten verwendet, wozu der Typ und die Position der Fahrzeugscheinwerfer sowie die intrinsischen und extrinsischen Kameraparameter bekannt sein müssen. Das gemittelte Bild der aktuellen Fahrszene wird dann mit den Referenzbildern über das Abstandsmaß Zero Mean Normalized Sum of Squared Differences (ZNSSD) [20] verglichen. Um den Einfluss dunkler Bildbereiche zu verringern, werden die Bilder zur Berechnung der ZNSSD maskiert. Das Referenzbild mit dem geringstem Abstand liefert schließlich den Wert für die aktuelle Sichtweite.

Sind in der aktuellen Fahrszene hingegen externe Lichtquellen vorhanden, so wird die Streuung deren Lichts über ein mehrstufiges Schwellwertverfahren untersucht. Der initiale Schwellwert wird dabei so gewählt, dass er eine Segmentierung von 3 % der Bildpunkte durchführt. Die so gewonnenen, zusammenhängenden Bildbereiche werden als Kandidaten für externe Lichtquellen herangezogen und untersucht. Dazu werden über eine Connected Components Analyse geometrische Parameter, wie z.B. Schwerpunkt, Ausdehnung und Kompaktheit für jeden Kandidaten bestimmt [46]. Stellt ein Kandidat aufgrund der geometrischen Parameter keine isolierte Quelle dar, wie es z.B. bei Fahrspuren der Fall ist, so wird er verworfen. Anschließend wird der Schwellwert schrittweise erhöht bis alle Kandidaten zu einem verschmelzen. Dabei werden in jedem Schritt für jeden Kandidaten geometrische Parameter bestimmt und ausgewertet, verschmelzen zwei Kandidaten, so werden deren Parameter fusioniert. Nach Abschluss der Schwellwerterhöhung werden weitere Kandidaten verworfen, wenn sie während

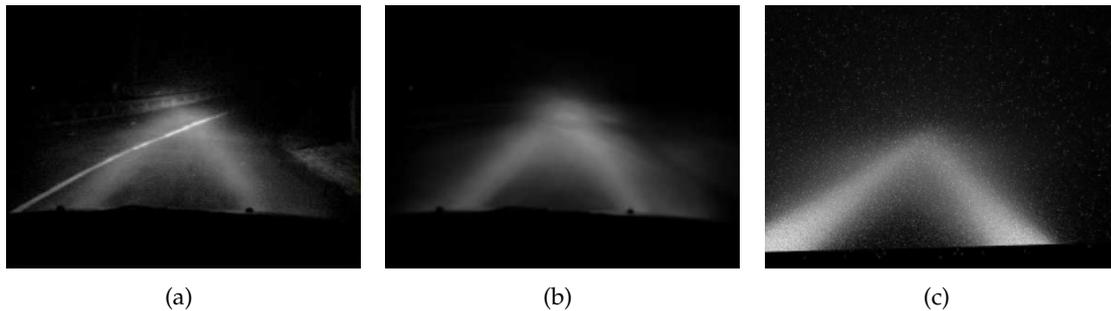


Abbildung 3.8: Sichtweitemenschätzung bei Nacht anhand der Fahrzeugscheinwerfer nach Gallen *et al.* (a) Einzelnes Bild einer Nebel-Fahrscene bei Nacht. (b) Gemitteltetes Bild zur Entfernung nicht statischer Merkmale wie z.B. Fahrspuren. (c) Über eine Semi Monte Carlo Raytracing-Methode simuliertes Referenzbild.

eines Verarbeitungsschritts besonders stark gewachsen sind oder eine sehr deutliche und ungerichtete Verschiebung des Schwerpunkts aufweisen. Für die verbleibenden Kandidaten wird anhand der in den Einzelschritten berechneten Schwerpunkte über eine lineare Regression die Richtung der Lichtausbreitung bestimmt und entlang dieser ein Intensitätsprofil erstellt. Die so gewonnenen Intensitätsprofile werden dann zu einem gemeinsamen Intensitätsverlauf zusammengefasst. Ein leichter Intensitätsabfall zwischen dem ersten und dem letzten Schwerpunkt im Intensitätsverlauf bedeutet schließlich, dass eine Nebelsituation vorliegt.

Das Verfahren zur Detektion von Nebel über externe Lichtquellen wurde anhand von 2.130 Bildern, zur Hälfte bestehend aus Nebel- und zur anderen Hälfte aus nebelfreien Szenen, evaluiert. Die untersuchten Bilder enthielten dabei im Mittel 10 Lichtquellen. Auf Einzelbildbasis konnte eine Erkennungsrate von 98,4 % und mit Hilfe eines Sliding Windows über 25 Bilder eine Erkennungsrate von 99,86 % erzielt werden.

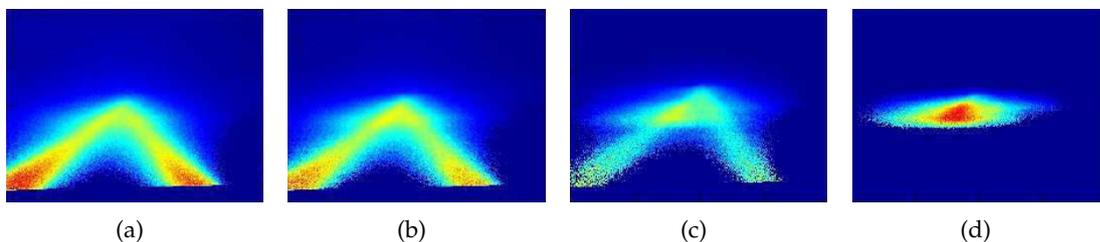


Abbildung 3.9: Simulierte Referenzbilder mit Sichtweiten von (a) 50, (b) 100, (c) 500 m und (d) ohne Sichtbeeinträchtigung. Die Farbskalierung reicht von Dunkelblau für geringe Lichtintensität bis Rot für hohe Lichtintensität.

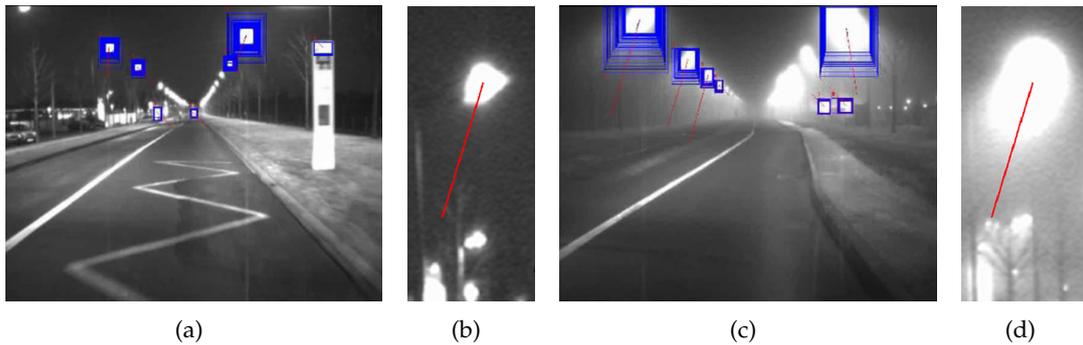


Abbildung 3.10: Nebeldetektion bei Nacht anhand externer Lichtquellen. (a) Nebelfreie Szene. (b) Detailansicht einer Lichtquelle aus der nebelfreien Szene. (c) Nebel Szene. (d) Detailansicht einer Lichtquelle aus der Nebel Szene. Die blauen Umrandungen zeigen die detektierten Lichtquellen und deren Ausbreitung bei Verwendung unterschiedlicher Schwellwerte. Die Roten Linien zeigen die Position und Richtung der Lichtausbreitung, mit welchen das Intensitätsprofil bestimmt wird.

3.7 Nebeldetektion mittels Klassifizierungsprozedur

Roser und Moosmann haben ein Klassifizierungserfahren vorgestellt, welches anhand einer im Fahrzeug montierten Farbkamera über Bild-Deskriptoren zwischen beliebigen Wetterbedingungen unterscheiden kann [112]. Der Bild-Deskriptor setzt sich aus Histogrammen des lokalen Kontrast, der Helligkeit, der Bildschärfe, des Farbtons und der Farbsättigung zusammen, wobei die Histogramme für das gesamte Bild (globale RoI) sowie für zwölf nicht überlappende Bildregionen (Sub-RoIs) bestimmt werden. Alle Merkmale liefern einen Wert zwischen Null und Eins und werden zur Darstellung als Histogramm auf zehn Bins diskretisiert. Als lokaler Kontrast wird die Definition nach Michelson verwendet. Die Bildschärfe wird, in Anlehnung an das modifizierte Tenengrad Kriterium [99] von Ferzli und Karam [32], über einen gewichteten Mittelwert der Gradientenbeiträge bestimmt

$$T = \frac{\sum_x \sum_y \delta(x, y) \rho(x, y) \sqrt{g_x^2(x, y) + g_y^2(x, y)}}{\sum_x \sum_y \delta(x, y)}, \quad (3.8)$$

wobei (x, y) die Bildkoordinaten in horizontaler bzw. vertikaler Richtung, (g_x, g_y) den Betrag des Gradienten und ρ einen zum Kontrast umgekehrt proportionalen Gewichtungsfaktor beschreibt. Desweiteren gilt $\delta(x, y) = 1$, wenn an dieser Stelle im Bild eine Kante vorliegt, andernfalls $\delta(x, y) = 0$. Die Merkmale Farbton und Sättigung werden aus dem HSV-Raum extrahiert, wobei Mittelwerte aus 10×10 Pixel Blöcken verwendet werden. Somit ergibt sich aus den 13 RoIs, jeweils bestehend aus fünf Histogrammen mit zehn Bins, ein 650-dimensionaler Merkmalsvektor, mit welchem schließlich über eine lineare Support Vector Machine (SVM) eine Klassifizierung der Fahrszene in eine Wettersituation durchgeführt wird.

Das Verfahren wurde am Beispiel der Unterscheidung von klaren Wetterbedingungen, leichten und starken Regen evaluiert. Hierzu wurde eine Datenbank bestehend aus

ca. 500.000 Bildern aufgebaut und aus dieser zufällig Bilder zum Trainieren und Testen entnommen. Dabei wurden drei Untermengen mit der gleichen Anzahl an Vorkommnissen für jede Klasse gebildet. Die erste Untermenge enthielt 1.080 Bilder, welche auf Autobahnen aufgenommen wurden. Die zweite bestand aus 900 auf Autobahnen und 900 auf Landstraßen aufgenommenen Bildern. Die dritte Untermenge entsprach der zweiten und wurde um zusätzlich 900 Bilder mit städtischer Umgebung ergänzt. Bei der Evaluierung wurde eine Hälfte der Bilder einer jeden Untermenge zum Trainieren und die andere Hälfte zum Testen verwendet. Dabei konnten Erkennungsraten von 97,96 %, 89,33 % und 85,16 % für die erste, zweite bzw. dritte Untermenge erzielt werden. Bei Betrachtung eines Zweiklassen-Problems, bei welchem Bilder mit klaren Wetterbedingungen und Bilder mit starker Regen unterschieden werden sollen, konnten sogar Erkennungsraten von 100 %, 99,5 % und 99,11 % erreicht werden. Die meisten Fehlklassifizierungen traten auf, wenn eine Definition der Klassenzugehörigkeit schwierig war, z.B. Bilder welche nicht eindeutig der Klasse leichter oder starker Regen zugeordnet werden konnten. Des Weiteren waren Probleme bei Vorhandensein von Objekten, wie z.B. Brücken, zu beobachten. Um die Leistungsfähigkeit der vorgestellten Bild-Deskriptoren zu untersuchen wurden zusätzlich Farb-Wavelets [88] und eine Kombination aus SIFT-Merkmalen [77] und Farbhistogrammen extrahiert. Dabei zeigte sich, dass der vorgestellte Merkmalsvektor deutlich höhere Erkennungsraten erzielen konnte.

3.8 Diskussion

Obwohl das von Busch und Debers vorgestellte Verfahren für den stationären Gebrauch konzipiert wurde liefert es einen interessanten ersten Ansatz. Er ist einfach und intuitiv und benötigt keine Parametrisierung. Wird die manuelle Definition des zu untersuchenden Bereichs durch ein dynamisches Verfahren ersetzt, z.B. mit Hilfe von bekannten Verfahren der Fahrbahn-Detektion [25, 35, 81], so ist auch ein Einsatz im Fahrzeug vorstellbar. Dabei liegt die Herausforderung darin, Fahrbahninformationen in ausreichend großer Entfernung robust zu extrahieren und eine Lösung für den Umgang mit dynamischen Objekten, wie z.B. anderen Verkehrsteilnehmern oder Brücken, sowie wechselnden Umgebungsbedingungen, z.B. Situationen mit Blendung, zu finden. Dennoch bleiben einige Fragen offen. Die Autoren begründen die Verwendung von B-Spline Wavelets zur Bestimmung des Gradienten damit, dass sie als Approximation des Gauß-Kernels wie dieser eine besonders gute Modellierung des menschlichen visuellen Systems darstellen, jedoch deutlich effizienter hinsichtlich der benötigten Rechenzeit implementiert werden können. Da jedoch keinerlei Angaben über die verwendete Bildgröße, die benötigte Bildwiederholfrequenz, die Umsetzung der Gradientenberechnung mittels Gauß-Kernel noch über die Programmlaufzeiten der beiden Realisierungen gemacht wurden, ist die Einschätzung der Echtzeitfähigkeit nicht nachvollziehbar. Zudem liefert ein Vergleich mit einer direkten Berechnung des lokalen Kontrast innerhalb eines 3×3 Fensters laut Autoren qualitativ kaum Unterschiede und scheint ebenfalls effizient hinsichtlich der Rechenzeit zu sein, wodurch die Verwendung von B-Spline Wavelets ausschließlich anhand theoretischer Überlegungen begründet ist. Des Weiteren wird nur das Ergebnis eines Einzelbildes mit einer geraden, planaren Fahrbahn ohne Verkehrsaufkommen im

untersuchten Bereich gezeigt. Anstelle einer rein qualitativen Beurteilung wäre jedoch eine quantitative Untersuchung unterschiedlicher Situationen, z.B. bzgl. Verkehrsaufkommen, Umgebungshelligkeit oder anderen Wetterbedingungen, wie z.B. Regen, interessant gewesen. Zudem wäre aufgrund des stationären Charakters ein Vergleich mit herkömmlichen Systemen zur Nebeldetektion und Sichtweitschätzung vorstellbar gewesen, z.B. mit einem wie in Kapitel 2 beschriebenen Transmissiometer oder Scatterometer.

Der von Pomerleau vorgestellte Ansatz unterscheidet sich insofern von den übrigen Verfahren, als dass er eine quantitative Schätzung der Sichtbeeinträchtigung unter beliebigen Situationen vorsieht. Ein besonderes Herausstellungsmerkmal ist die Schätzung über Intensitätssprünge gleichartiger Fahrbahnmerkmale an unterschiedlichen Positionen vor dem Fahrzeug, statt wie häufig üblich, das am weit entfernteste Fahrbahnmerkmal mit einem Kontrast größer eines vordefinierten Schwellwerts zu verwenden. Aufgrund der Normierung auf die untersuchte Distanz sowie einer weiteren Normierung zur Bereinigung von Kameraeigenschaften besteht jedoch die Gefahr, diesen Wert fälschlicherweise, wie z.B. in [49, 50], als Kontrastabschwächung pro Meter zu interpretieren. Aus dem in Kapitel 3 beschriebenen Bouguer-Lambert'schen Gesetz geht jedoch hervor, dass die Intensität exponentiell mit der Entfernung abnimmt und somit kein linearer Zusammenhang zwischen der Intensitätsabnahme und der Entfernung vorliegt. Dies wird auch bei einer theoretischen Betrachtung der in der Evaluierung erhaltenen Werte für die prozentuale Sichtbeeinträchtigung ersichtlich. Wird z.B. der aus der ersten Versuchsreihe ermittelte Durchschnittswert für uneingeschränkte Sichtverhältnisse von 0,8 herangezogen und dieser als Verhältnis zwischen wahrgenommener und intrinsische Intensität interpretiert, so kann über Gl. (2.21) der Extinktionskoeffizienten bestimmt werden, welcher schließlich über Gl. (2.41) eine Sichtweiten von 13,44 m liefert. Aus diesen Überlegungen wird ersichtlich, dass die Interpretation des ausgegebenen Werts schwierig ist und somit die Verwendbarkeit in unterschiedlichen Anwendungsgebieten problematisch sein kann. Zudem bleibt die Empfehlung der WMO für die Ausgabe eines Messgerätes zur Schätzung der Sichtbedingungen unberücksichtigt [132]. Darüber hinaus stellt sich die Frage, ob über die Untersuchung von nur wenigen Bildzeilen, welche anhand markanter Stellen des Intensitätsprofils bestimmt werden, beliebige Situationen mit Sichtbeeinträchtigungen zuverlässig erfasst werden können und insbesondere eine verlässliche Quantifizierung der Nebelausprägung möglich ist. Wird hierzu das Ergebnis der ersten Versuchsreihe betrachtet, so scheint eine Unterscheidung zwischen klaren Sichtbehinderungen, Nacht mit und Nacht ohne externe Lichtquellen, Regen und Blendung möglich. Es ist jedoch zu beachten, dass bei der Betrachtung eines Intervalls der doppelten Standardabweichung um den Mittelwert, welcher bei einer normalverteilten Zufallsvariablen 95,4 % der Realisierungen entspricht, in allen Fällen, in denen laut Autor eine Situation mit Sichtbeeinträchtigung vorliegt, deutliche Überlappungen zu beobachten sind. Bei Betrachtung der zweiten Versuchsreihe sind diese Beobachtungen bereits bei der Betrachtung des Intervalls mit einfacher Standardabweichung sehr deutlich zu erkennen, welche lediglich 68,3 % der Realisierungen entsprechen. Wird die doppelte Standardabweichung als Intervallgrenze herangezogen, erscheint die Ausgabe der prozentualen Sichtbehinderung zufällig und unkorreliert zur untersuchten Sichtweite.

Die umfangreichste Arbeit zum Thema kamerabasierte Nebeldetektion und Sichtweitschätzung stammt von Hautière *et al.* Sie beruht im Wesentlichen auf der aus der

Atmosphärischen Optik bekannten und von Koschmieder formulierten Airlight-Formel, welche die Sichtbarkeit entfernter Objekte unter Einbeziehung der atmosphärischen Streuung und Dämpfung berücksichtigt. Problematisch erscheint jedoch die Sensitivität des vorgestellten Ansatzes. Für die Ableitungen der modellierten Intensitätsfunktion aus Abb. 3.4 mit Sichtweiten von 300, 200, 100 und 50 m finden sich die Maxima an den Stellen 79, 81, 89 bzw. 104 px. D.h. die Schätzung der Sichtweite im Bereich von 50–300 m wird über eine möglichst exakte Bestimmung der Maxima, welche sich über 15 Pixel erstrecken, durchgeführt. Während die Intensitätsfunktionen aus Abb. 3.4 aus vorgegebenen Modellparametern stammen, müssen diese in der Praxis jedoch aus Bildinformationen bestimmt werden. Es ist davon auszugehen, dass dabei Ungenauigkeiten auftreten, vor allem da sich der Bereich, in welchem die Maxima aufzufinden sind, nahe der Horizontallinie befindet und somit in weiter Entfernung vor dem Fahrzeug. Kleine Fehler in der Bestimmung der Maxima wirken sich jedoch in Anbetracht von Abb. 3.4 deutlich auf die Sichtweiteschätzung aus. Darüber hinaus stellt sich die Frage, ob das gewählte Modell in dieser Form hier anwendbar ist. Die Airlight Formel wurde für bekannte Sichtziele, welche entgegen des Horizonts betrachtet werden, formuliert. Die Autoren wenden sie jedoch zur Beschreibung eines Intensitätsverlaufs im Kamerabild an, welcher von der Fahrbahn zum Himmel reicht. Dabei werden zwei wichtige Kriterien außer Acht gelassen. Während sich die Airlight Formel auf Sichtziele mit bekannter intrinsischer Intensität bezieht, wird hier ein beliebiger Bereich des Kamerabilds herangezogen, der nicht im Bezug zu einem konkreten Objekt steht. Um die Airlight Formel jedoch als Intensitätsverlauf über die Distanz darstellen zu können, d.h. die Veränderung der wahrgenommenen Helligkeit in Abhängigkeit von der Entfernung des Objekts, müsste zumindest die intrinsische Intensität der untersuchten Objekte im Bild konstant gehalten werden, indem z.B. ein Fahrspurverlauf herangezogen wird. Das zweite Kriterium, welches unbeachtet bleibt, ist eine Betrachtung der untersuchten Objekte entgegen des Horizonts. Die Airlight Formel modelliert, wie in Kapitel 2 beschrieben, neben der Dämpfung des Lichts auch die Anhebung der wahrgenommenen Helligkeit eines entfernten Objekts aufgrund von diffusem Licht aus der Hemisphäre. Diese Modellierung wird, z.B. bei Betrachtung der Fahrbahn im Bereich vor dem Fahrzeug, außer Acht gelassen.

Bronte *et al.* beschreiben einen auf recht einfachen Methoden aufbauenden Ansatz, der vor allem durch die Aufteilung des Problems in eine Klassifizierungsaufgabe und ein anschließende Quantifizierung der Sichtbeeinträchtigung bei Nebel-Bildern heraussticht. Zur Klassifizierung der Bilder in Nebel und nebefreie Fahrscenen wurde jedoch ein recht einfacher schwellwertbasierter Ansatz gewählt, welcher die Summe der Gradientenbeiträge auswertet. Hierzu wird die obere Bildhälfte verwendet, mit der Begründung, dass dort die Verunschärfung durch Nebel besonders stark ausgeprägt ist. Nebel wirkt sich jedoch am stärksten auf weit entfernte Objekte aus, welche mit höchster Wahrscheinlichkeit im Bereich des Horizonts vorzufinden sind. Zudem sind Bildinformationen der oberen Bildhälfte sehr unsicher, da hier beliebige Objekte in unterschiedlichen Entfernungen, wie z.B. Beschilderungen, Brücken oder während eines Überholvorgangs Teile von Lastwagen, vorkommen können. Die größte Schwachstelle scheint jedoch die mangelnde Robustheit des Verfahrens zu sein, was durch die Notwendigkeit einer Medianbildung der Sichtweiteschätzung über eine bestimmte Zeitperiode ersichtlich wird.

Der von Hautière *et al.* vorgestellte Ansatz, über Tiefeninformationen von Objekten, welche einen Kontrast größer 5 % aufweisen, die Sichtweite zu schätzen, beschreibt einen naheliegenden Ansatz bei Verwendung eines Stereokamerasystems. Obwohl die Autoren als wesentlichen Vorteil die Einsatzmöglichkeit sowohl bei Tag als auch bei Nacht angeben, werden bei der Evaluierung jedoch lediglich Fahrscenen bei Tag und bei Dämmerung betrachtet. Auch der zweitgenannte Vorteil einer exakteren Sichtweiteschätzung gegenüber monokamerabasierter Ansätze wurde im Rahmen der Evaluierung ebenfalls nicht untersucht, obwohl die Autoren einen solchen in vorangegangenen Arbeiten vorgestellt hatten. Zudem stellt sich die Frage, weshalb Tiefeninformationen von Objekten abseits der Fahrbahn nicht verwendet werden können und eine Segmentierung von Objekten der Fahrbahn über die v -Disparity Map nötig ist, vor allem da hierdurch laut Autoren bei kontrastarmen Bildern zu wenig Disparitätswerte zur Verfügung stehen. Aber auch der angegebene maximal erzielbare Tiefenwert von 250 m erscheint fragwürdig. Werden die Parameter des kommerziell erhältlichen Stereokamerasystems Bumblebee BBZ0852 der Firma PointGray herangezogen¹, mit einer Baseline von $d_o = 12$ cm, einer Brennweite von $f = 6$ mm und einer Pixelgröße von $d_{px} = 6 \mu\text{m}$, so ergibt sich für ein $Z = 250$ m entferntes Objekt ein Disparitätswert von $d = \frac{bf}{d_{px}Z} = 0,48$ px. Mit diesem System wäre somit ein Objekt dieser Entfernung nicht bestimmbar. Die Spezifikationen sowohl von mono- als auch stereokamerabasierten Systemen aus Serienfahrzeugen, welche zur Detektion von Objekten eine maximale Entfernung von 100 m angeben, bestätigen diesen Zweifel.

Gallen *et al.* haben als erste einen Ansatz zur Nebeldetektion und Sichtweiteschätzung bei Nacht vorgestellt. Da die Aufgabe in die Situationen mit und ohne externe Lichtquellen unterteilt wurde, stellt sich zunächst die Frage, mit welcher Genauigkeit diese unterschieden werden können. Sind keine externen Lichtquellen vorhanden, so wird ein Template Matching Ansatz verfolgt, bei welchem mehrere aufeinanderfolgende Bilder gemittelt werden und das Ergebnis mit einem simulierten Referenzbild verglichen wird. Andere Bereiche der maschinellen Bildverarbeitung, wie z.B. die Handschrifterkennung, haben jedoch bereits gezeigt, dass das Template Matching anderen Ansätzen, wie z.B. Neuronalen Netzen, unterlegen ist, weshalb hier an der Robustheit des Verfahrens, vor allem bei wechselnden Umgebungen, gezweifelt werden kann. Sind externe Lichtquellen vorhanden, wird anhand deren Lichtausbreitung eine Nebeldetektion vorgenommen. Eine Sichtweiteschätzung, wie in der Situation ohne externen Lichtquellen findet nicht statt, wodurch das Verfahren je nach Situation unterschiedliche Ausgangsparameter erzeugt. Bei einer Evaluierung anhand von 2.130 Bildern, welche im Mittel 10 externe Lichtquellen enthalten, konnte eine Erkennungsrate von 98,4 % erzielt werden. Offen bleibt jedoch wie mit fälschlicherweise detektierten externen Lichtquellen, wie z.B. überblendeten Verkehrsschildern, oder mit anderen Lichtquellen, wie z.B. Frontscheinwerfer entgegenkommender oder Heckleuchten vorausfahrender Fahrzeuge, umgegangen wird.

Die Arbeit von Roser und Moosmann verfolgt im Gegensatz zu den anderen hier vorgestellten Verfahren einen Klassifizierungsansatz, welcher mit Hilfe von Bild-Deskriptoren die Unterscheidung beliebiger Wettersituationen ermöglichen soll. Bei der Evaluierung konnten dabei hohe Erkennungsraten bei der Klassifizierung von Fahrscenen mit starkem Regen, leichtem Regen und kein Regen in unterschiedlichen Situationen,

¹Die Autoren haben keine Angaben über die verwendeten Systemparameter gemacht.

wie z.B. auf Autobahnen oder in städtischer Umgebung, erzielt werden. Dabei spielen Farbinformationen eine wichtige Rolle. Diese stehen jedoch aufgrund der einleitend genannten Einschränkungen in dieser Arbeit nicht zur Verfügung. Des Weiteren bleibt offen, welche Erkennungsraten mit den hier vorgestellten Bild-Deskriptoren bei der Unterscheidung von Nebel und nebelfreien Fahrscenen erzielt werden können.

Diese Arbeit verfolgt im Gegensatz zu den bereits bekannten Verfahren eine Klassifizierungsprozedur zur Unterscheidung von Nebel- und nebelfreien Fahrscenen. Anders als in der Arbeit von Roser und Moosmann werden dabei jedoch Grauwertbilder als Eingangsdaten verwendet und andere Merkmale als Bild-Deskriptoren herangezogen. Des Weiteren wird hier erstmals eine gemeinsame Betrachtung von Tag- als auch von Nacht-Szenen vorgenommen und eine geschlossene Lösung vorgeschlagen [97, 98]. Für Anwendungen, welche als Information lediglich die Unterschreitung einer Sichtweite benötigen, wie es z.B. bei der Lokalen Gefahrenwarnung oder dem Fernlichtassistenten der Fall ist, ist das Ergebnis dieses Ansatzes ausreichend. Wird neben der Nebeldetektion eine Quantifizierung der Sichtweite benötigt, so kann der hier vorgestellte Ansatz, ähnlich wie in der Arbeit von Bronte *et al.* beschrieben, um eine nachgeschaltete Sichtweitenschätzung erweitert werden. Eine konzeptionelle Betrachtung hierzu findet sich in Kapitel 6.

Bildbasierte Nebelerkennung

Zur visuellen Wahrnehmung der Umgebung führt das Auge *Sakkaden* und *Fixationen* durch [74]. Sakkaden sind schnelle Bewegungen, welche das Auge an eine neue Position führen. Sie erlauben effektiv keine Sinneswahrnehmung und dauern 20–40 ms [26, 111]. Fixationen sind Intervalle zwischen Sakkaden, in denen der Blick nahezu stationär gehalten wird und Informationen aufgenommen werden. Die durchschnittliche Fixationsdauer beträgt 200–250 ms [115].

Wegweisende Arbeiten aus dem Bereich des rechnergestützten Sehens folgen dieser Herangehensweise [8, 79]. Sie beschreiben die Szenenwahrnehmung als eine schrittweise Rekonstruktion des Eingangsbildes über lokale Messungen, wie z.B. einer Kantendetektion oder der Untersuchung von detektierten Objektoberflächen, welche sukzessive in Entscheidungsebenen steigender Komplexität integriert werden. Untersuchungen zur visuellen Wahrnehmung haben jedoch gezeigt, dass Menschen in der Lage sind, Bilder durch einen einzigen Blick zu erfassen [105, 107]. Bei sogenannten Rapid Serial Visual Presentations (RSVP), einer Abfolge jeweils kurz dargestellter Bilder, konnten Versuchspersonen eine gesuchte Szene lediglich durch eine grobe Beschreibung, wie z.B. „Geburts-tagsfeier“, zuverlässig erkennen. Da hierbei die Bilder für lediglich 100–300 ms dargestellt wurden, war maximal eine Fixation möglich und widerspricht dem sukzessiven Aufbau der Szenenwahrnehmung durch Betrachtung einzelner Objekte. Das Phänomen, die Gesamtheit eines Bildes, unabhängig von der Komplexität der Szene, durch einen einzigen Blick erfassen zu können, wurde in der Psychologie *Gist*¹ genannt [106]. Im Gegensatz zur herkömmlichen Herangehensweise empfehlen daher experimentelle Studien zur Wahrnehmung der Umgebung die Beschaffenheit der gesamten Bildinformationen in Form sogenannter *globaler Merkmale* zu verwenden [11, 106]. Globale Merkmale können z.B. Farbinformationen in Form eines Histogramms oder Texturinformationen wie die Gray Level Co-Occurance Matrix (GLCM) und das Leistungsspektrum sein. Die beiden Herangehensweisen sind jedoch nicht als konkurrierend zu betrachten. Während bei der Erstgenannten unter dem Begriff Wahrnehmung eine Rekonstruktion dreidimensionaler Szenen-Eigenschaften verstanden wird, um z.B. Bewegungsaufgaben durchzuführen, zielt die zweitgenannte auf eine semantische Beschreibung der Bildinformationen. So werden globale Merkmale vor allem im Bereich der Szenen-Klassifizierung, z.B. bei der Unter-

¹zu Deutsch das Wesentliche

scheidung von Indoor und Outdoor Szenen [41, 42, 120, 126, 127] oder allgemein zur Kategorisierung in semantische Klassen [93, 94, 123], sowie zur Gruppierung ähnlicher Bilder, dem sogenannten Content Based Image Retrieval (CBIR) [22] z.B. zur bildbasierten Suche, eingesetzt.

Im Folgenden wird anhand von spektralbasierten Merkmalen die zugrundeliegende Klassifizierungsprozedur vorgestellt, einige weitere, zur Unterscheidung von Nebel- und nebelfreien Szenen als vielversprechend erscheinende Merkmale beschrieben und abschließend auf eine einfache, in diesem Bereich häufig vorzufindende Segmentierung eingegangen.

4.1 Spektralbasierter Ansatz

Beim spektralbasierten Ansatz werden Bildmerkmale aus dem Frequenzbereich herangezogen. Hierzu wird die zweidimensionale diskrete Fouriertransformation (DFT) angewandt, welche definiert ist als

$$I(f_x, f_y) = \sum_{x=0}^{N_x-1} \sum_{y=0}^{N_y-1} i(x, y) e^{-j2\pi \left(\frac{x f_x}{N_x} + \frac{y f_y}{N_y} \right)}. \quad (4.1)$$

Dabei beschreiben $i(x, y)$ ein zweidimensionales Bild der Größe $N_x \times N_y$ und $I(f_x, f_y)$ die Fouriertransformierte mit den horizontalen bzw. vertikalen Frequenzen f_x und f_y . Die Frequenzen werden üblicherweise in der Einheit cycles/pixel angegeben, wobei der Übergang vom hellsten zum dunkelsten Wert einen Umlauf beschreibt. Hat ein Bild z.B. 64 horizontale Übergänge auf einer Bildbreite von 256 Pixel, so resultiert hieraus eine vertikale Frequenz von $f_y = \frac{64}{256} = 0,25 \text{ c/p}$, siehe Abb. 4.1 Die maximale Frequenz beträgt somit $0,5 \text{ c/p}$.

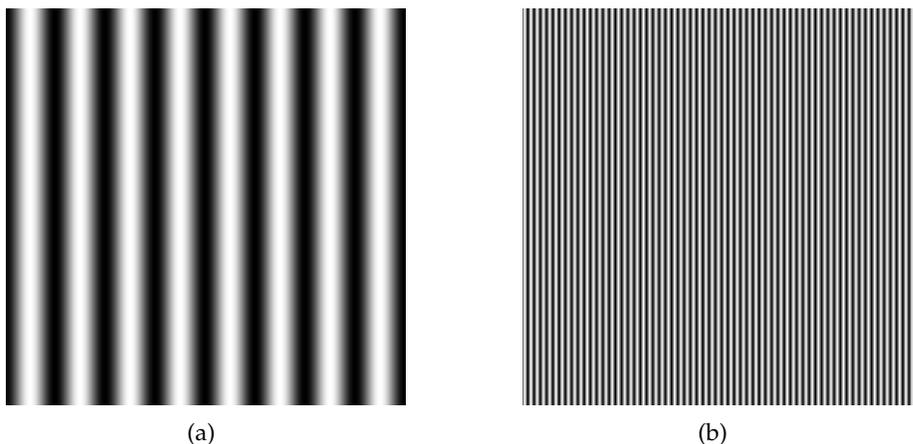


Abbildung 4.1: Sinusbild der Größe 256×256 mit (a) 8 bzw. (b) 64 horizontalen Umläufen, woraus eine vertikale Frequenz von $0,0313$ bzw. $0,25$ Cycles per Pixel resultiert.

Da die DFT im Allgemeinen komplex ist, kann sie auch in Polarform dargestellt werden

$$I(f_x, f_y) = |I(f_x, f_y)| e^{j\Phi(f_x, f_y)}. \quad (4.2)$$

Der Betrag

$$|I(f_x, f_y)| = \sqrt{\Re \{I(f_x, f_y)\}^2 + \Im \{I(f_x, f_y)\}^2} \quad (4.3)$$

wird *Frequenzspektrum* und

$$\Phi(f_x, f_y) = \arctan \left(\frac{\Im \{I(f_x, f_y)\}}{\Re \{I(f_x, f_y)\}} \right) \quad (4.4)$$

wird *Phase* genannt. Während das Frequenzspektrum Aufschluss darüber gibt, welche Frequenzen wie häufig im Bild auftreten, liefert die Phase Informationen darüber, an welcher Stelle im Bild diese auftreten. Durch Weglassen der Phaseninformationen erhält man somit Bildmerkmale, welche einen globalen Charakter aufweisen.

Für reelle Funktionen ist die Fouriertransformation konjugiert komplex, d.h.

$$I^*(f_x, f_y) = I(-f_x, -f_y), \quad (4.5)$$

wodurch das Spektrum gerade und die Phase ungerade Symmetrieeigenschaften aufweist,

$$|I(f_x, f_y)| = |I(-f_x, -f_y)|, \quad (4.6)$$

$$\Phi(f_x, f_y) = -\Phi(-f_x, -f_y). \quad (4.7)$$

Eine weitere wichtige Eigenschaft liefert die *Null-* bzw. *Gleichfrequenz*²

$$I(0,0) = \sum_{x=0}^{N_x-1} \sum_{y=0}^{N_y-1} i(x, y), \quad (4.8)$$

welche proportional zum mittleren Grauwert im Ortsbereich ist

$$I(0,0) = N_x N_y \mu, \quad (4.9)$$

mit

$$\mu = \frac{1}{N_x N_y} \sum_{x=0}^{N_x-1} \sum_{y=0}^{N_y-1} i(x, y). \quad (4.10)$$

Da die Proportionalitätskonstante $N_x N_y$ i.d.R. sehr groß ist, ist $I(0,0)$ typischerweise die größte Frequenzkomponente.

Die spektralbasierte Nebeldetektion basiert im Wesentlichen auf dem Leistungsspektrum. In Hinblick auf eine hohe Erkennungsrate besteht die Klassifizierungsprozedur zudem, wie in Abb. 4.2 dargestellt und im Folgenden näher beschrieben, aus einer Vorverarbeitung der Eingangsbilder sowie einer Merkmalsreduktion.

²In Anlehnung an die Bezeichnung von Gleichstrom wird die Nullfrequenz häufig auch als DC-Komponente bezeichnet.

4. Bildbasierte Nebelerkennung

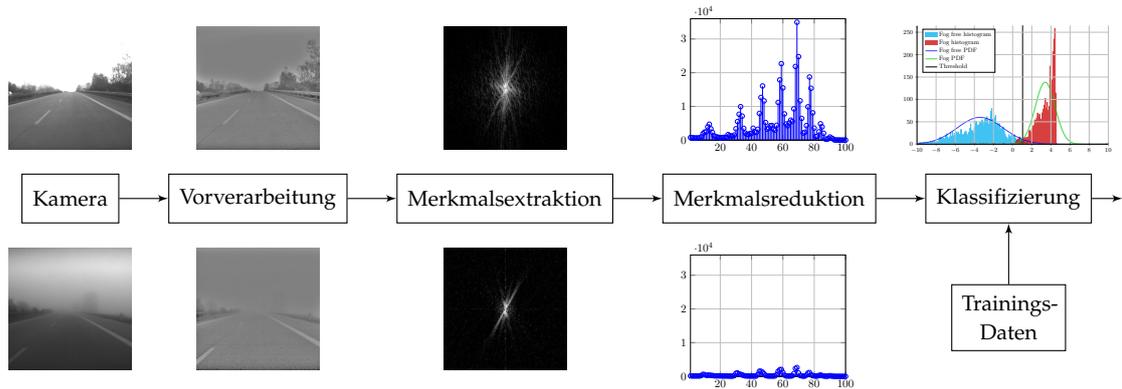


Abbildung 4.2: Übersicht zur bildbasierten Nebelerkennung am Beispiel spektralbasierter Merkmale mit einer Gegenüberstellung von Nebel- und nebelfreien Fahrscenen. Aus dem vorverarbeiteten Kamerabild wird das Leistungsspektrum berechnet und anschließend eine Merkmalsreduktion durchgeführt. Mit diesen wird ein Klassifikator zur Unterscheidung von Nebel- von nebelfreien Fahrscenen trainiert.

4.1.1 Vorverarbeitung

Ziel der Vorverarbeitung ist es, eine zur weiteren Verarbeitung günstige Darstellung der Bildinformationen zu erhalten sowie ähnliche Eingangsdaten für unterschiedliche Umgebungsbedingungen zu schaffen. Hierzu werden die Eingangsdaten in einem ersten Schritt logarithmisch transformiert

$$i_{\log}(x, y) = \log(i(x, y) + 1). \quad (4.11)$$

Die logarithmische Transformation findet häufig Einsatz bei der Modellierung natürlicher Szenen [39, 65] und wird durch das Weber-Fechner-Gesetz motiviert, welches besagt, dass sich die subjektiv empfundene Stärke eines Sinneseindrucks proportional zum Logarithmus der objektiven Intensität verhält [17].

Um zu vermeiden, dass einige Bildregionen das Spektrum dominieren und um den Einfluss unterschiedlicher Umgebungsbedingungen zu reduzieren wird das Bild anschließend mittelwertbefreit und auf eine Schätzung des lokalen Kontrasts normiert

$$i_p(x, y) = \frac{i_{\log}(x, y) * h(x, y)}{\varepsilon + \sqrt{[i_{\log}(x, y) * h(x, y)]^2 * g(x, y)}}. \quad (4.12)$$

Dabei beschreibt $g(x, y)$ einen isotropischen Tiefpass-Filter mit einer radialen Grenzfrequenz von 0.015 c/p und $h(x, y) = 1 - g(x, y)$. Der Zähler ist ein Hochpass-Filter, welcher das Bild mittelwertbefreit, der Nenner verhält sich wie ein lokaler Schätzer der Varianz des hochpassgefilterten Bilds. Die Konstante ε dient darüber hinaus zur Vermeidung von Rauschen in homogenen Bildregionen.

In Abb. 4.3 sind die Einzelschritte der Vorverarbeitung sowohl im Orts- als auch im Frequenzbereich dargestellt. Wie in Abb. 4.4 zu sehen, können dadurch deutlich stabilere Eingangsdaten für die weitere Verarbeitung geschaffen werden.

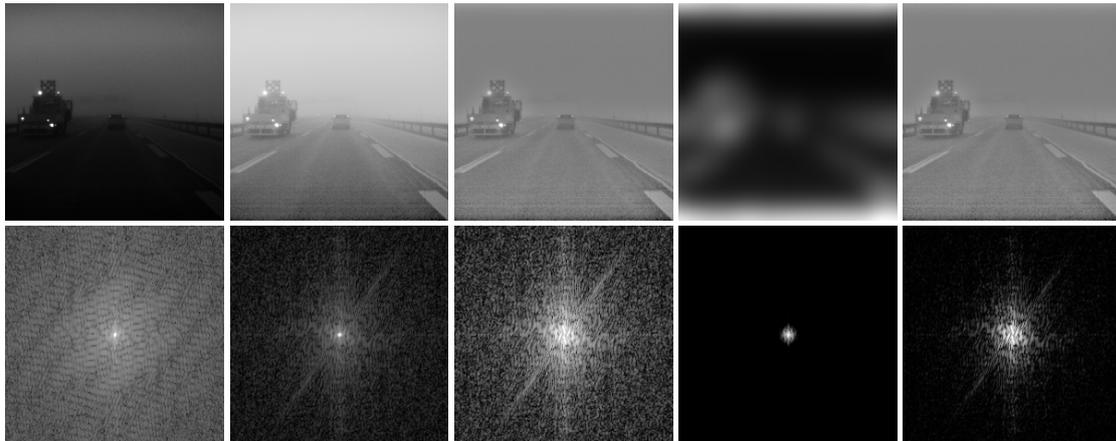


Abbildung 4.3: Einzelschritte der Vorverarbeitung im Orts- (oben) und Frequenzbereich (unten). Der Frequenzbereich zeigt das später beschriebene Leistungsspektrum, welches zur besseren Visualisierung logarithmiert wurde. Von links nach rechts: Eingangsbild, logarithmisch transformiertes Bild, mittelwertbefreites Bild, Schätzung der lokalen Varianz des mittelwertbefreiten Bildes, Ergebnis der Vorfilterung.

4.1.2 Merkmalsextraktion

Als Merkmal wird das Leistungsspektrum verwendet, welches als quadrierter Betrag der Fouriertransformierten definiert ist

$$\Gamma(f_x, f_y) = |I(f_x, f_y)|^2 = \Re \{I(f_x, f_y)\}^2 + \Im \{I(f_x, f_y)\}^2. \quad (4.13)$$

Um breitbandige Signalanteile entlang der Achsen zu vermeiden, welche bei der DFT aufgrund der impliziten Annahme eines periodisch fortgesetzten Signals entstehen, auch bekannt als *Leakage Effect*, wird vor der Transformation in den Frequenzbereich eine Fensterung durch ein zweidimensionales Hanning-Window durchgeführt.

In Abb. 4.5 sind typische Bilder von Fahrscenen mit bzw. ohne Nebel und die korrespondierenden Leistungsspektren dargestellt. Für die Leistungsspektren wurde zur



Abbildung 4.4: Vorverarbeitung am Beispiel jeweils zwei aufeinanderfolgender Bilder mit unterschiedlicher Beleuchtung aufgrund der automatischen Regelung der Kameraeinstellung. In der ersten Zeile sind die Kamerabilder dargestellt, in der zweiten Zeile das Ergebnis der Vorverarbeitung. In den vorverarbeiteten Bildern ist deutlich die Verminderung von Beleuchtungseffekten zu erkennen.

4. Bildbasierte Nebelerkennung

besseren Visualisierung eine logarithmische Darstellung gewählt, die Gleich- bzw. Nullfrequenz befindet sich in der Mitte, höhere Frequenzen sind nach außen hin angetragen. In den Bildern ist deutlich zu erkennen, dass das Spektrum bei vorhandenem Nebel um die Gleichfrequenz konzentriert ist, wohingegen bei nebelfreien Fahrszenen eine breite Streuung vorzufinden ist. Der Grund hierfür ist eine Verminderung des Kontrasts und eine Verunschärfung in Bildern mit Nebel. Während scharfe Kanten, welche in nebelfreien Fahrszenen deutlicher auftreten, viele hohe und niedrige Frequenzen zur Beschreibung im Frequenzraum benötigen, werden weiche Kantenübergänge, wie sie häufig in Nebel-Fahrszenen vorzufinden sind, durch niedrige Frequenzen dargestellt.



Abbildung 4.5: Bilder von Fahrszenen mit und ohne Nebel und die korrespondierenden Leistungsspektren. Fahrszenen mit Nebel weisen ein um die Gleichfrequenz konzentriertes Spektrum auf, während die Spektren nebelfreier Fahrszenen deutlich stärker gestreut sind und mehr hohe Frequenzen aufweisen. Dies ist auch in unterschiedlichen Situationen, wie z.B. ohne Verkehr, mit Verkehr, mit Verkehr und deutlichen Lichtquellen sowie bei Vorhandensein von baulichen Gegebenheiten wie z.B. Brücken beobachtbar.

4.1.3 Merkmalsreduktion

Hochdimensionale Daten sind im Bereich des maschinellen Lernens von Nachteil. Unter dem von Bellman eingeführten Begriff *curse of dimensionality* [10] ist bekannt, dass die Leistungsfähigkeit von Lernverfahren mit steigender Dimension der Eingangsdaten sinkt. Das Trainieren von Klassifikatoren ist ein Optimierungsproblem im mehrdimensionalen Raum, wobei eine Erhöhung der Dimension durch Verwendung mehrerer Merkmale die Aufgabe erschwert. Ein weiterer Grund die Dimensionalität gering zu halten ist, dass die Zuverlässigkeit eines Modells sich aus der Dichte der Trainings-Proben ergibt. In anderen Worten bedeutet dies, dass zur Erreichung eines bestimmten Generalisierungsfehlers die benötigte Anzahl an Trainingsdaten exponentiell mit der Dimensionalität der Daten steigt. Wenn z.B. 10 Proben pro Einheitslänge in einer Dimension ausreichend sind, werden im zweidimensionalen Fall 100 Punkte pro Einheitsfläche benötigt um die selbe Informationsdichte zu erhalten und im dreidimensionalen Fall bereits 1.000 Punkte pro Einheitsvolumen [24]. Dabei hat sich der Richtwert etabliert, pro Klasse mehr als zehnmals so viele Trainingsdaten wie die Anzahl der Merkmale zu wählen [34, 59, 110]. Wird jedes einzelne Pixel des Leistungsspektrums als Merkmal betrachtet, so ergibt sich nach der Merkmalsextraktion aufgrund der Symmetrie-Eigenschaften aus Gl. (4.6) ein $N_x N_y / 2$ dimensionaler Merkmalsvektor. Ein Eingangsbild der Größe $N_x = N_y = 256$ liefert somit

32.768 Merkmale wodurch laut Richtwert pro Klasse mehr als 327.680 Trainingsdaten benötigt werden.

Grundsätzlich sollten irrelevante Merkmale vermieden und korrelierte Merkmale kombiniert werden um möglichst wenige, leistungsfähige Merkmale zu erhalten. In dieser Arbeit wurde hierzu ein zweistufiges Verfahren zur Merkmalsreduktion, bestehend aus einer Abtastung im Spektralbereich und einer anschließenden Hauptkomponentenanalyse (Principal Components Analysis, PCA) gewählt. Zur Abtastung im Spektralbereich werden im Folgenden zwei Methoden, die Verwendung einer Gabor- und einer Bandpass Filterbank, vorgestellt.

Gabor Filterbank

Gabor Filter erlangten große Beachtung, da mit ihnen die Charakteristika einzelner Zellen des visuellen Cortex mancher Säugetiere approximiert werden konnten. Zusätzlich konnte gezeigt werden, dass sie sowohl im Orts- als auch im Frequenzbereich optimale Lokalisierungseigenschaften aufweisen [60, 61]. Ein Gabor Filter kann als eine sinusförmige ebene Welle einer bestimmten Frequenz und Orientierung, moduliert über eine elliptische Gauß'sche Hüllkurve, betrachtet werden

$$g(x, y) = \frac{f_0^2}{\pi \eta_x \eta_y} e^{-\left(\frac{f_0^2}{\eta_x^2} x'^2 + \frac{f_0^2}{\eta_y^2} y'^2\right)} e^{j2\pi f_0 x'} \quad (4.14)$$

$$x' = x \cos \theta + y \sin \theta$$

$$y' = -x \sin \theta + y \cos \theta$$

wobei f_0 die Mittenfrequenz, θ den Rotationswinkel bzw. die Orientierung und η_x und η_y die Ausbreitung der elliptischen Gauß-Kurve entlang der Haupt- und Nebendiagonalen beschreiben. Die Fouriertransformierte ist eine elliptische Gauß-Funktion an der Stelle f_0 , rotiert um den Winkel θ

$$G(f_x, f_y) = e^{-\pi^2 \left[\frac{(f_x - f_0)^2}{\sigma_x^2} + \frac{f_y^2}{\sigma_y^2} \right]} \quad (4.15)$$

$$f'_x = f_x \cos \theta + f_y \sin \theta$$

$$f'_y = -f_x \sin \theta + f_y \cos \theta$$

mit der Haupt- und Nebendiagonalen $\sigma_x = \frac{f_0}{\eta_x}$ und $\sigma_y = \frac{f_0}{\eta_y}$, siehe Abb. 4.6(a).

Zur Abtastung des Leistungsspektrums im Frequenzbereich wird eine *Gabor-Filterbank*, bestehend aus halbkreisförmig, in unterschiedlichen Frequenzbändern angeordneten Gabor-Filtern, verwendet [96] (Abb. 4.6(b)). Die Filter innerhalb eines Frequenzbands sind dabei äquidistant angeordnet

$$\theta_{l,s} = \frac{2\pi s}{N_{l,s}}, \quad (4.16)$$

$$l = \{0, \dots, N_l - 1\},$$

$$s = \{0, \dots, N_{l,s} - 1\},$$

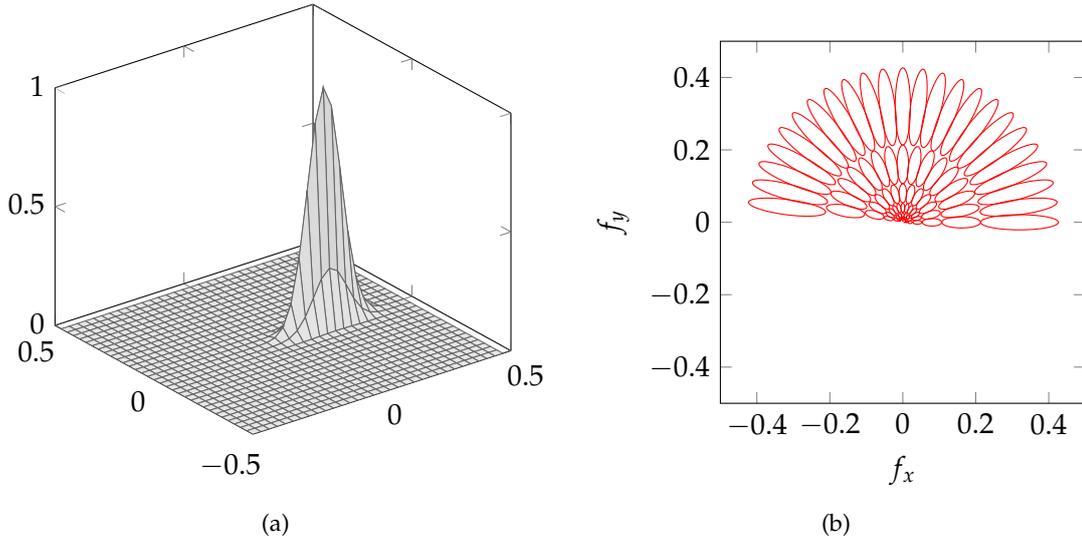


Abbildung 4.6: (a) Gabor Filter an der Stelle $f_o = 0,16$, rotiert um den Winkel $\theta = 0$. (b) Gabor Filterbank bestehend, von außen nach innen, aus 24, 16, 12, 12, 8, 8, 6 und 6 Filtern pro Frequenzband. Als äußerste Mittenfrequenz wurde $f_{\max} = 0,32$ gewählt, der Mittenfrequenzabstand beträgt eine Oktave und die Überlappung angrenzender Filter liegt bei 3 dB. Die Roten Konturen kennzeichnen die 3 dB Grenzfrequenz Isolinien der Gabor-Filter.

wobei l ein bestimmtes Frequenzband, s eine Orientierung, N_l die Anzahl der Frequenzbänder und $N_{l,s}$ die Anzahl der Filter eines Frequenzbands beschreibt. Die einzelnen Frequenzbänder sind über die Mittenfrequenzen an den Stellen

$$f_{o,l} = k^{-l} f_{\max} \quad (4.17)$$

angeordnet, wobei f_{\max} die äußerste Mittenfrequenz beschreibt und über den Parameter k der Abstand der Frequenzbänder eingestellt werden kann [63, 72]. Typische Werte für k sind 2 für einen Abstand von einer [101] oder $\sqrt{2}$ für einen Abstand von einer halben Oktave³ [68]. Sowohl die Filter innerhalb eines Frequenzbands als auch die Filter zwischen zwei Frequenzbändern berühren sich dabei an einem bestimmten Punkt p , wie z.B. der 3 dB Grenzfrequenz⁴ für $p = 1/\sqrt{2}$ oder der halben Filteramplitude für $p = 0,5$. Daraus lassen sich die Haupt- und Nebendiagonalen bestimmen [58]

$$\sigma_x = \frac{\pi f_{\max}}{\sqrt{-\ln(p)}} \frac{k-1}{k+1} \quad (4.18)$$

$$\sigma_y = \frac{\pi^2 f_{\max}}{2N_{l,s} \sqrt{-\ln(p)}} \quad (4.19)$$

³Eine Oktave steht, analog zur Bedeutung in der westlichen Musikskala, für die Verdopplung bzw. Halbierung der Frequenz.

⁴Die Grenzfrequenz eines Filters bezeichnet diejenige Frequenz, welche die Grenze zwischen Durchlass- und Sperrbereich bestimmt. Hierzu wird häufig diejenige Frequenz verwendet, unterhalb bzw. oberhalb derer die Leistung unter einen bestimmten Anteil des Durchlassbereichs gefallen ist. Meist wird hierzu die halbe Leistung des Durchlassbereichs verwendet, welche einer Dämpfung von 3 dB entspricht.

Die Abtastwerte des Leistungsspektrum, im Folgenden Gabor-Merkmale genannt, bestimmen sich schließlich aus dem Integral der Gabor-Filter über das Leistungsspektrum

$$g_i = \sum_{f_x} \sum_{f_y} \Gamma(f_x, f_y) G_i(f_x, f_y), \quad i = \{1, 2, \dots, K\} \quad (4.20)$$

wobei Γ das Leistungsspektrum und K die Anzahl verwendeter Gabor-Filter beschreibt. Diese werden im sogenannten Gabor-Merkmalvektor zusammengefasst

$$\mathbf{g} = \{g_i\}_{i=1}^K. \quad (4.21)$$

Bandpass Filterbank

Wie einleitend erwähnt, kann es von Vorteil sein Merkmale zu kombinieren. Bei nebelfreien Szenen sind im Vergleich zu Nebel-Szenen höhere Frequenzen zu erwarten, unabhängig von deren Orientierung, wodurch die Verwendung eines Bandpass-Filter anstelle mehrerer Gabor-Filter innerhalb eines Frequenzbands naheliegend ist. Durch Summierung bzw. Mittelung der Gabor-Filterantworten eines Frequenzbands kann mit der eben beschriebenen Filterbank ein Bandpass-Charakter nachgebildet werden. Auch denkbar ist die Zusammenfassung der Gabor-Filter eines Frequenzbands zu einem sogenannten *Gabor Bandpass-Filter*. Eine weitere Möglichkeit ist die Verwendung der von Ginsburg vorgestellten gaußförmigen Bandpass-Filter, auch bekannt als *Ring-Filter* [16, 40]

$$G_{Ring}(f_x, f_y) = e^{-\frac{1}{2\sigma^2} \ln^2\left(\frac{\sqrt{f_x^2 + f_y^2}}{f_{o,1}}\right)}, \quad (4.22)$$

wobei σ die Ausbreitung des Gauß-Filters beschreibt, siehe Abb. 4.7. Ginsburg empfiehlt einen Mittenfrequenzabstand von einer Oktave und für die Ausbreitung der Gauß-Filter einen festen Wert von $\sigma = 0,275$. In Anlehnung an [58] kann die Ausdehnung der Gauß-Filter jedoch über einen gewünschten Wert p des Schnittpunkts zweier angrenzender Filter parametrisiert werden. Hierzu kann Gl. (4.22) nach f_a , welche für die Position mit dem gewünschten Wert p steht, aufgelöst werden

$$\begin{aligned} G_{Ring}(f_a, 0) &= e^{-\frac{1}{2\sigma^2} \ln^2\left(\frac{f_a}{f_{o,1}}\right)} \stackrel{!}{=} p \\ \Rightarrow f_a &= f_{o,1} e^{\pm\sigma\sqrt{-2\ln(p)}} \end{aligned} \quad (4.23)$$

Die Mittenfrequenz angrenzender Filter beträgt $f_{o,1}$ und $f_{o,1}/k$, daher ist

$$f_{o,1} e^{-\sigma\sqrt{-2\ln(p)}} = \frac{f_{o,1}}{k} e^{\sigma\sqrt{-2\ln(p)}}. \quad (4.24)$$

Durch Auflösen nach σ lässt sich diese in Abhängigkeit vom gewünschten Filterwert p am Schnittpunkt angrenzender Filter bestimmen

$$\sigma = \frac{\ln(k)}{2\sqrt{-2\ln(p)}}. \quad (4.25)$$

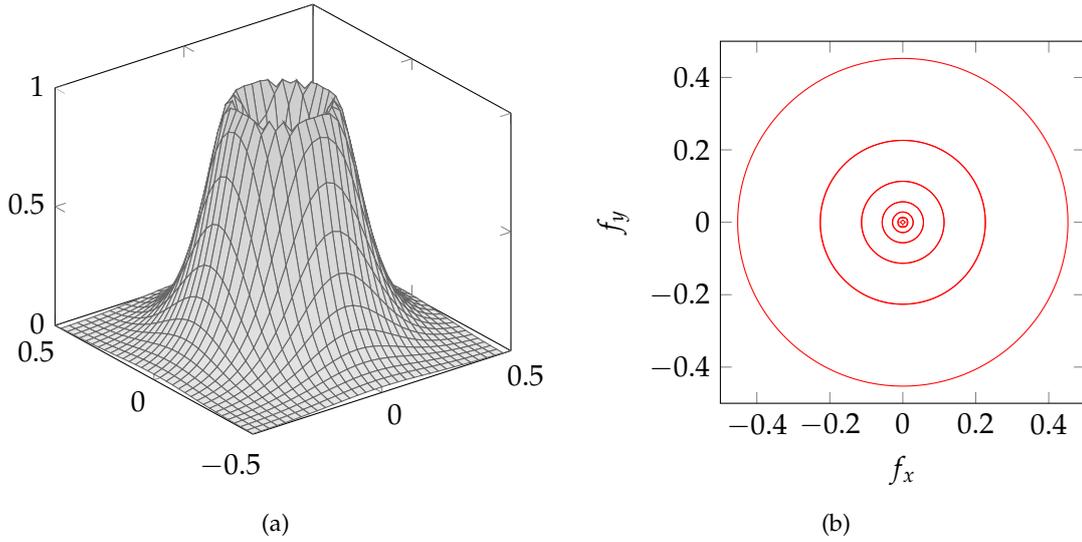


Abbildung 4.7: Ring-Filterbank. (a) Ring-Filter an der Stelle $f_o = 0,16$. (b) Ring-Filterbank mit 8 Frequenzbändern, $f_{\max} = 0,32$, einer Oktave Mittenfrequenzabstand und einer Überlappung angrenzender Filter bei 3 dB.

Hauptkomponenten Analyse

Im zweiten Schritt wird der abgetastete Merkmalsvektor einer Hauptachsentransformation unterzogen

$$\boldsymbol{\omega} = \mathbf{W}^T (\mathbf{g} - \bar{\mathbf{g}}). \quad (4.26)$$

Hierzu werden anhand von M Trainingsdaten der mittlere Merkmalsvektor

$$\bar{\mathbf{g}} = \frac{1}{M} \sum_{m=1}^M \mathbf{g}_m \quad (4.27)$$

und die Transformationsmatrix

$$\mathbf{W} = [\mathbf{w}_1 \ \mathbf{w}_2 \ \dots \ \mathbf{w}_N], \quad (4.28)$$

welche aus den ersten N , $N < K$ Eigenvektoren der Kovarianzmatrix

$$\mathbf{C} = \frac{1}{M} \sum_{m=1}^M (\mathbf{g}_m - \bar{\mathbf{g}}) (\mathbf{g}_m - \bar{\mathbf{g}})^T \quad (4.29)$$

besteht, berechnet.

4.1.4 Klassifizierung

Zur Klassifizierung wurde ein einfacher linearer Klassifikator, basierend auf der Linearen Diskriminantenanalyse (LDA) nach Fisher [33, 47], verwendet

$$u = \mathbf{d}^T \boldsymbol{\omega} = \sum_{n=1}^N d_n \omega_n \begin{cases} > b, & \text{Nebel} \\ < b, & \text{kein Nebel} \end{cases} \quad (4.30)$$

Dabei wird der Merkmalsvektor mit einem Gewichtsvektor \mathbf{d} multipliziert. Das daraus resultierende Skalar, die sogenannte Entscheidungsvariable u , dient zur Unterscheidung der beiden Klassen. Überschreitet der Wert der Entscheidungsvariablen den Schwellwert b , so wird das Merkmal der Klasse *Nebel* zugeordnet, andernfalls der Klasse *kein Nebel*. Der Gewichtsvektor und der Schwellwert werden in einer Trainingsphase gelernt. Die LDA nach Fisher findet einen Gewichtsvektor, welcher zu einer optimalen Unterscheidung der beiden Klassen führt. Der Grad des Trennvermögens wird über das Fisher'sche Diskriminantenverhältnis gemessen

$$f(\mathbf{d}, \bar{\mathbf{w}}_1, \bar{\mathbf{w}}_2, \mathbf{C}_1, \mathbf{C}_2) = \frac{\mathbf{d}^T (\bar{\mathbf{w}}_1 - \bar{\mathbf{w}}_2) (\bar{\mathbf{w}}_1 - \bar{\mathbf{w}}_2)^T \mathbf{d}}{\mathbf{d}^T (\mathbf{C}_1 + \mathbf{C}_2) \mathbf{d}} = \frac{(\mathbf{d}^T (\bar{\mathbf{w}}_1 - \bar{\mathbf{w}}_2))^2}{\mathbf{d}^T (\mathbf{C}_1 + \mathbf{C}_2) \mathbf{d}}, \quad (4.31)$$

wobei $\bar{\mathbf{w}}_1$ und $\bar{\mathbf{w}}_2$ den mittleren Merkmalsvektor und \mathbf{C}_1 und \mathbf{C}_2 die Kovarianzmatrizen der jeweiligen Klassen beschreiben. Der Gewichtsvektor, welcher das Fisher'sche Diskriminantenverhältnis maximiert lautet

$$\mathbf{d} = (\mathbf{C}_1 + \mathbf{C}_2)^{-1} (\bar{\mathbf{w}}_1 - \bar{\mathbf{w}}_2). \quad (4.32)$$

Mit dem Gewichtsvektor lassen sich die Entscheidungsvariablen der Trainingsdaten jeder Klasse berechnen. Unter der Annahme, dass diese innerhalb einer Klasse jeweils normalverteilt sind, kann der Schwellwert über dessen Schnittpunkt berechnet werden

$$b = \mathcal{N}_1(\bar{u}_1, \sigma_1) \cap \mathcal{N}_2(\bar{u}_2, \sigma_2), \quad (4.33)$$

wobei \bar{u}_1 und \bar{u}_2 die mittlere Entscheidungsvariable und σ_1 und σ_2 die Standardabweichung der jeweiligen Klasse bezeichnen und

$$\mathcal{N}(\bar{u}, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{u-\bar{u}}{\sigma}\right)^2}. \quad (4.34)$$

Dies entspricht einer Maximum-a-Posteriori (MAP) Schätzung. In Abb. 4.8 ist das Ergebnis einer exemplarischen Trainingsphase dargestellt. Die mittels Fisher LDA ermittelten Entscheidungsvariablen sind für die jeweiligen Klassen als Histogramme dargestellt. Die hieraus resultierenden Normalverteilungen wurden zur besseren Visualisierung mit einem identischen Faktor skaliert und sind als Kurven über den Histogrammen dargestellt. Daraus ergibt sich der als vertikale Linie eingezeichnete Schwellwert. Obwohl die Entscheidungsvariablen der Klasse *Nebel* nicht normalverteilt erscheinen, liefert dieser Ansatz sehr gute Ergebnisse. Aufwändigere Klassifizierungsverfahren, wie z.B. die weit verbreitete Support Vector Machine (SVM), lieferten kaum nennenswerte Verbesserungen. Um eine einfachere Analyse und Interpretation der Ergebnisse der Klassifizierungsprozedur zu ermöglichen, wurde daher auf deren Einsatz verzichtet.

4.2 Weitere Bild-Deskriptoren

Neben Merkmalen aus dem Frequenzbereich ist die Verwendung von Bild-Deskriptoren aus dem Ortsbereich naheliegend. Da in dieser Arbeit zur Unterscheidung der Klassen der Kontrast und die Bildschärfe ausschlaggebend sind, werden hierzu Texturmerkmale basierend auf Histogrammen, Haralick-Merkmale, sowie die Verwendung von Wavelets, welche sowohl eine Lokalität im Frequenz als auch im Ortsbereich besitzen, vorgestellt.

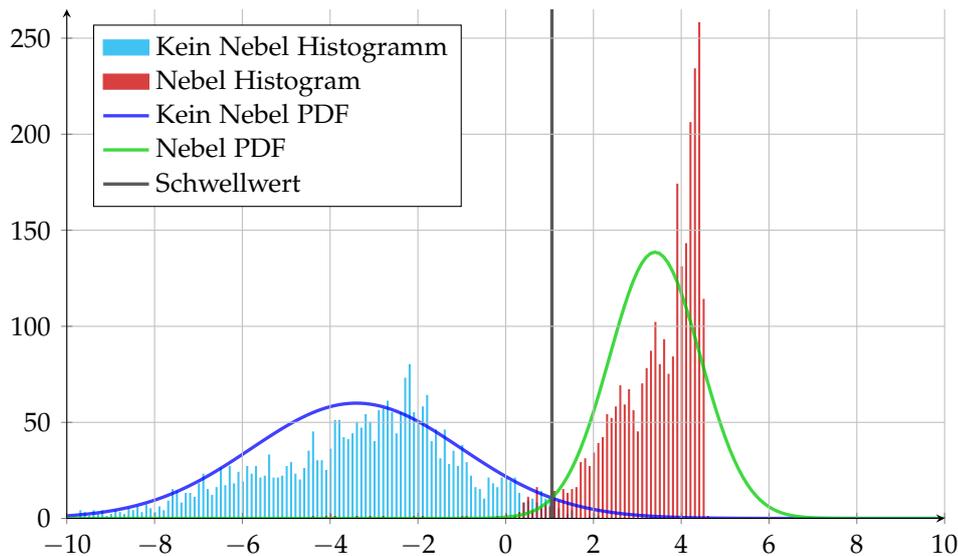


Abbildung 4.8: Ergebnisse einer exemplarischen Trainingsphase basierend auf der Fisher LDA. In Cyan ist das Histogramm der nicht Nebel- und in Rot das Histogramm der Nebel-Entscheidungsvariablen dargestellt. Die zu den Histogrammen korrespondierenden Normalverteilungen sind in Blau und Grün eingezeichnet. Diese wurden zur besseren Visualisierung mit einem identischen Faktor skaliert. Die vertikale schwarze Linie zeigt den aus dem Schnittpunkt der beiden Normalverteilungen resultierenden Schwellwert.

4.2.1 Histogramme

Histogramme werden häufig zur Beschreibung von Texturen verwendet [43, 64, 95]. Zur Berücksichtigung einer Kontrastabnahme und Verunschärfung kann als globales Merkmal ein einfaches Histogramm der Gradientenbeträge (Histogram of Gradient Magnitudes, HGM) verwendet werden, welches einen ähnlichen Charakter wie die Gabor Bandpass Filter aufweist, da es weder Orts- noch Richtungsinformationen enthält. Ein Äquivalent zur Gabor Filterbank im Frequenzbereich sind die von Dala und Triggs vorgestellten Histogram of Oriented Gradients (HOG), welche ursprünglich zur Personendetektion entwickelt wurden [21]. Dabei wird das Eingangsbild in kleine, nicht überlappende Bereiche unterteilt, sogenannte *Cells*, und jeweils ein Histogramm der Gradienten-Richtungen bestimmt, wobei die Bins um den zur Richtung korrespondierenden Betrag des Gradienten akkumuliert werden. Zum Ausgleich von Beleuchtungs- und Kontraständerungen werden sogenannte Block-Normierung durchgeführt. *Blocks* fassen mehrere angrenzende *Cells* zusammen und besitzen einen aus den einzelnen Histogrammen aneinandergereihten Merkmalsvektor. Dieser wird dann z.B. über die L2 Norm normiert. Blöcke weisen dabei eine Überlappung auf, wodurch die Histogramme einzelner Zellen in mehrere Block-Merkmalsvektoren einfließen. Die normierten Block-Vektoren werden letztendlich zu einem großen HOG-Deskriptor zusammengefasst. Zur Personendetektion in [21] wurden Bildausschnitte der Größe 64×128 Pixel verwendet und in *Cells* der Größe 4×4 Pixel unterteilt. Die Blöcke fassten 2×2 *Cells* zusammen und wurden horizontal und vertikal um eine Cell-Breite verschoben. Die Histogramme bestanden aus 9 Bins,

wodurch sich ein Merkmalsvektor der Größe $\frac{64}{16} \frac{128}{16} \cdot 4 \cdot 9 = 1.152$ ergab, welcher schließlich zur Klassifizierung mittels Support Vector Machine (SVM) herangezogen wurde.

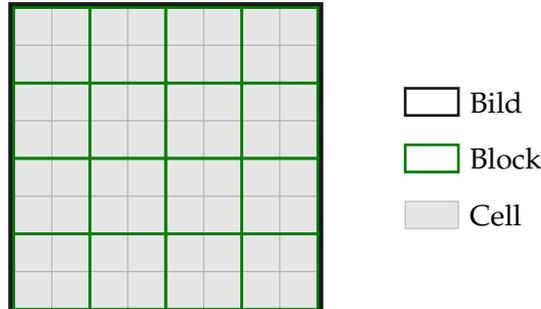


Abbildung 4.9: Aufbau HOG. Für jede Cell wird ein Histogramm berechnet. Ein Block fasst die Histogramme mehrerer Cells zusammen und führt eine Normierung durch. Zu beachten ist, dass hier zur besseren Visualisierung keine Überlappung der Blöcke dargestellt ist.

4.2.2 Haralick Merkmale

Ein häufig verwendeter und referenzierter Ansatz zur Beschreibung von Bildinformationen sind die von Haralick vorgestellten statistischen Merkmale [44, 45]. Sie basieren auf der Gray Level Co-Occurance Matrix (GLCM) \mathbf{G} , welche die Beziehung zwischen den Grauwerten benachbarter Pixel beschreibt. Hierzu werden die relative Häufigkeit von Pixelpaaren in bestimmten Abständen \mathbf{d} berechnet. Häufig verwendete Abstände bzw. Suchrichtungen sowie ein Beispiel zur Erzeugung der GLCM sind in Abb. 4.10 dargestellt. Dabei wurde ein Pixelpaar-Abstand von $\mathbf{d} = [1 \ 0]^T$ bzw. 0° und die zu untersuchenden Bildinformationen auf $L = 8$ Graustufen quantisiert. An der Stelle (1,1) hat \mathbf{G} den Wert 1, da in dem exemplarischen Bild nur einmal ein Pixel mit dem Wert 1 auftritt, welches als direkten rechten Nachbar ebenfalls den Wert 1 aufweist. Analog hierzu weist \mathbf{G} an der Stelle (6,2) den Wert 3 auf, da im Bild dreimal der Wert 6 mit einem direkten Nachbarn des Werts 2 vorkommt. Die Größe

$$p_{i,j} = G(i,j)/n, \quad (4.35)$$

wobei

$$n = \sum_{i=1}^L \sum_{j=1}^L G(i,j) \quad (4.36)$$

die Anzahl aller Pixelpaare beschreibt, ist eine Schätzung der Wahrscheinlichkeit, dass ein Paar mit dem Abstand \mathbf{d} die Werte (z_i, z_j) aufweist. Die Anzahl der Grauwertstufen L bestimmt dabei die Größe von \mathbf{G} . Ist L groß, so ist die Anzahl an Pixelpaaren, welche zu einem p_{ij} beitragen, gering und führt zu einer geringen statistischen Aussagekraft. Ist die Anzahl der Grauwertstufen hingegen gering, so können viele Bildinformationen verloren gehen. Haralick hat 14 Merkmale zur Charakterisierung von \mathbf{G} vorgestellt, häufig verwendete [45, 92, 119] sind in Tabelle 4.1 aufgelistet. Die Größen zur Beschreibung des

4. Bildbasierte Nebelerkennung

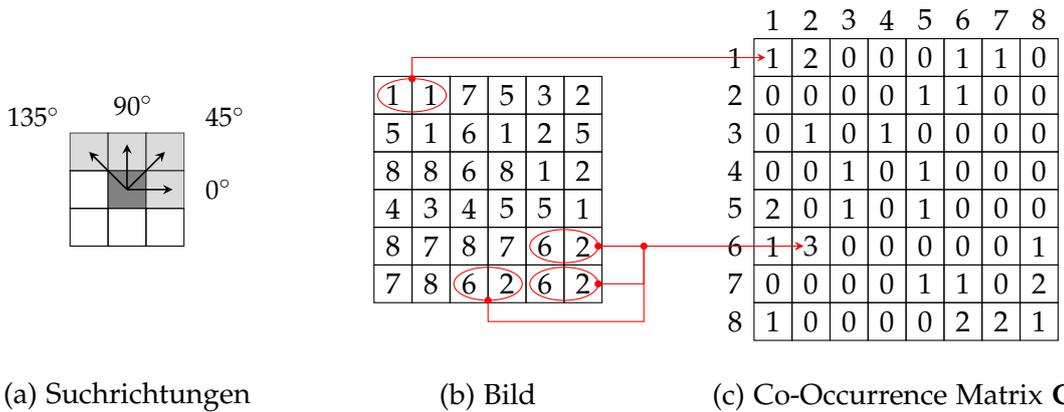


Abbildung 4.10: (a) Typische Suchrichtungen zur Erzeugung einer Gray Level Co-Occurrence Matrix. In diesem Beispiel wird der direkte Nachbar rechts vom betrachteten Pixel verwendet, welcher einer Suchrichtung von 0° entspricht. (b) Exemplarische Bildinformationen, welche auf $L = 8$ Grauwerte quantisiert wurden. (c) Resultierende GLCM.

Korrelations-Deskriptoren sind dabei folgendermaßen definiert:

$$m_r = \sum_{i=1}^L i \sum_{j=1}^L p_{ij} \quad (4.37)$$

$$m_c = \sum_{j=1}^L j \sum_{i=1}^L p_{ij}$$

und

$$\sigma_r^2 = \sum_{i=1}^L (i - m_r)^2 \sum_{j=1}^L p_{ij} \quad (4.38)$$

$$\sigma_c^2 = \sum_{j=1}^L (j - m_c)^2 \sum_{i=1}^L p_{ij}$$

4.2.3 Wavelet-Koeffizienten

Die diskrete Transformation eines Bildes $i(x, y)$ der Größe $N_x \times N_y$ kann allgemein dargestellt werden als

$$T(u, v, \dots) = \sum_{x, y} i(x, y) g_{u, v, \dots}(x, y), \quad (4.39)$$

wobei (x, y) die Variablen im Orts- und (u, v, \dots) die Variablen des Transformationsbereichs beschreiben. Analog hierzu lautet die allgemeine inverse diskrete Transformation

$$i(x, y) = \sum_{u, v, \dots} T(u, v, \dots) h_{u, v, \dots}(x, y). \quad (4.40)$$

Deskriptor	Beschreibung	Gleichung
Korrelation	Maß für die Korrelation eines Pixels zu seinen Nachbarn über das gesamte Bild mit dem Wertebereich $[1, -1]$.	$\sum_{i=1}^L \sum_{j=1}^L \frac{(i - m_r)(j - m_c) p_{ij}}{\sigma_r \sigma_c}$ $\sigma_r \neq 0, \sigma_c \neq 0$
Kontrast	Maß für den Kontrast zwischen einem Pixel und seinem Nachbarn über das gesamte Bild mit dem Wertebereich $[0, (L - 1)^2]$.	$\sum_{i=1}^L \sum_{j=1}^L (i - j)^2 p_{ij}$
Uniformität (Energie)	Maß für die Gleichmäßigkeit mit dem Wertebereich $[1, 0]$. Die Uniformität weist einen Wert von Eins für ein konstantes Bild und einen Wert von Null für zufällig verteilte Intensitätswerte auf.	$\sum_{i=1}^L \sum_{j=1}^L p_{ij}^2$
Homogenität	Maß für die Konzentration der Elemente von \mathbf{G} entlang der Hauptdiagonalen mit dem Wertebereich $[0, 1]$.	$\sum_{i=1}^L \sum_{j=1}^L \frac{p_{ij}}{1 + j - i }$
Entropie	Maß für die Zufälligkeit der Elemente von \mathbf{G} . Die Entropie beträgt Null, wenn alle p_{ij} Null sind und ist maximal, wenn alle p_{ij} gleich sind.	$-\sum_{i=1}^L \sum_{j=1}^L p_{ij} \log p_{ij}$

Tabelle 4.1: Einige Deskriptoren zur Charakterisierung der Co-Occurrence Matrix der Größe $L \times L$ nach Haralick [45].

$g_{u,v,\dots}$ und $h_{u,v,\dots}$ werden dabei *Vorwärts-* und *inverse Transformations-Kernel* genannt. Die *Transformations-Koeffizienten* $T(u, v, \dots)$ können als *Expansions-Koeffizienten* einer Reihenentwicklung von $i(x, y)$ bzgl. $\{h_{u,v,\dots}\}$ betrachtet werden. Im Falle der DFT aus Gl. (4.1) lauten diese

$$h_{x,y} = g_{u,v}^*(x, y) = \frac{1}{\sqrt{N_x N_y}} e^{j2\pi \left(\frac{ux}{N_x} + \frac{vy}{N_y} \right)}. \quad (4.41)$$

Die Variablen des Transformationsbereichs u und v beschreiben vertikale und horizontale Frequenzen. Die Kernel sind separierbar, da

$$h_{u,v}(x, y) = h_u(x) h_v(y) \quad (4.42)$$

für

$$h_u(x) = \frac{1}{\sqrt{N_x}} e^{j2\pi ux/N_x} \quad \text{und} \quad h_v(y) = \frac{1}{\sqrt{N_y}} e^{j2\pi vy/N_y} \quad (4.43)$$

und orthonormal.

Während die DFT vollständig über zwei Gleichungen beschrieben werden kann, bezieht sich die Diskrete Wavelet Transformation (DWT) auf eine Klasse von Transformationen, welche sich in den verwendeten Transformations-Kernel und somit auch den Expansionsfunktionen unterscheiden. Eine DWT wird daher durch ein Paar an Transformations-Kernel oder einen Satz an Parametern, welche diese definieren, charakterisiert. Alle Wavelet Transformationen haben dabei gemeinsam, dass ihre Expansionsfunktionen „kleine Wellen“ unterschiedlicher Frequenzen von begrenzter Dauer sind. Die Kernel können als drei separierbare 2D-Wavelets

$$\begin{aligned}\psi^H(x, y) &= \psi(x)\varphi(y) \\ \psi^V(x, y) &= \varphi(x)\psi(y) \\ \psi^D(x, y) &= \psi(x)\psi(y)\end{aligned}\tag{4.44}$$

wobei $\psi^H(x, y)$, $\psi^V(x, y)$ und $\psi^D(x, y)$ *horizontale*, *vertikale* und *diagonale Wavelets* genannt werden, und eine separierbare, zweidimensionale *Skalierungsfunktion*

$$\varphi(x, y) = \varphi(x)\varphi(y)\tag{4.45}$$

dargestellt werden. Jede dieser zweidimensionalen Funktionen ist das Produkt zweier eindimensionaler reeller, quadratisch integrierbarer Skalierungs- und Wavelet-Funktionen

$$\begin{aligned}\varphi_{j,k}(x) &= 2^{j/2}\varphi(2^jx - k) \\ \psi_{j,k}(x) &= 2^{j/2}\psi(2^jx - k)\end{aligned}\tag{4.46}$$

Die Translation k bestimmt die Position dieser 1D-Funktionen entlang der x -Achse, die Skalierung j deren Breite und $2^{j/2}$ die Höhe. Die einzelnen Expansionsfunktionen sind dabei binäre Skalierungen und ganzzahlige Translationen des *Mutter-Wavelets* $\psi(x) = \psi_{0,0}(x)$ und der Skalierungsfunktion $\varphi(x) = \varphi_{0,0}(x)$. Diese können über eine Reihenentwicklung als Linearkombinationen von sich selbst ausgedrückt werden

$$\begin{aligned}\varphi(x) &= \sum_n h_\varphi(n)\sqrt{2}\varphi(2x - n) \\ \psi(x) &= \sum_n h_\psi(n)\sqrt{2}\varphi(2x - n)\end{aligned}\tag{4.47}$$

wobei die Expansionskoeffizienten h_φ und h_ψ *Skalierungs-* und *Wavelet-Vektoren* genannt werden. Sie sind die Filterkoeffizienten der Fast Wavelet Transform (FWT), einer iterativen rechnerischen Annäherung an die DWT, siehe Abb. 4.11. Die in der Abbildung dargestellten Ausgänge $W_\varphi(j, m, n)$ und $W_\psi^i(j, m, n)$ für $i = \{H, V, D\}$ sind die DWT Koeffizienten der Skalierung j , die Wavelet-Vektoren $h_\varphi(-n)$ und $h_\psi(-m)$ Tiefpass und Hochpass *Dekompositions-Filter*. Die Reihe von Filter- und Downsampling-Operationen zur Berechnung von $W_\psi^H(i, j, m)$ lautet z.B.

$$W_\psi^H(i, j, m) = h_\psi(-m) * \left[h_\varphi(-n) * W_\varphi(j + 1, m, n) \Big|_{n=2k, k \geq 0} \right] \Big|_{m=2k, k \geq 0}.\tag{4.48}$$

Jeder Durchlauf durch die Filterbank zerlegt dabei das Eingangsbild in vier Komponenten niedrigerer Auflösung. Die W_φ Koeffizienten werden über zwei Tiefpässe erzeugt und

deshalb *Approximations-Koeffizienten* genannt. W_ψ^i für $i = \{H, V, D\}$ sind die *horizontalen*, *vertikalen* und *diagonalen Detail-Koeffizienten*. Die Wavelet Transformation hat drei Variablen im Transformationsbereich, j für die Skalierung sowie n und m für die horizontale und vertikale Translation.

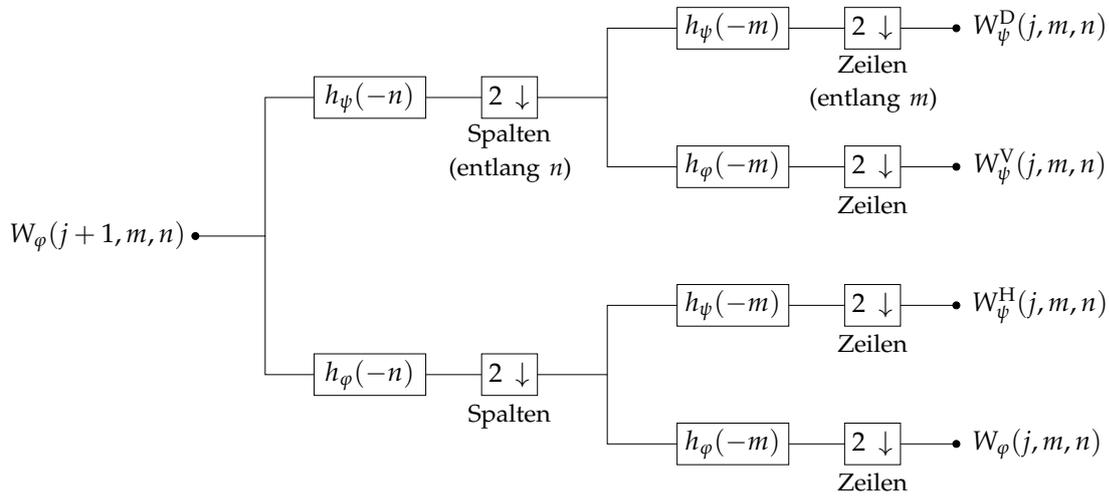


Abbildung 4.11: Filterbank der 2D Fast Wavelet Transformation. Jeder Durchlauf erzeugt eine DWT Skalierung.

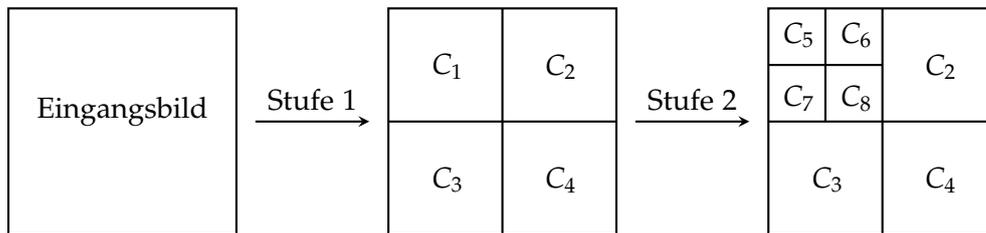


Abbildung 4.12: Zweistufige Wavelet Pyramide.

Die Wavelet Transformation wurde erstmals von Mallat zur Analyse von Texturen eingesetzt [78]. Ein wichtiger Punkt ist dabei die Wahl einer geeigneten Wavelet-Basis bzw. Filterbank. Mojsilovic *et al.* haben gezeigt, dass diese einen deutlichen Einfluss auf die Texturbeschreibung hat und zudem, dass biorthogonale Filter hierzu besser geeignet sind als orthogonale [87]. Bei der Texturanalyse werden häufig Daubechies Filterbanken [23] verwendet [38, 73, 113, 125]. Auch Serrano *et al.* verwendeten diese in Verbindung mit Farb-Merkmalen zur Klassifizierung von indoor und outdoor Szenen [116]. Hierzu wird das Bild in 4×4 Bereiche unterteilt und jeweils eine zweistufige Wavelet-Transformation durchgeführt. Als Texturmerkmale dienen die Energien der Approximations- und Detail-Koeffizienten $C_k(i, j)$

$$e_k = \frac{1}{N_x N_y} \sum_i \sum_j |C_k(i, j)|^2, \quad k = 2, 3, \dots, 4K \quad (4.49)$$

wobei N_x, N_y die Bildgröße, (i, j) die Variablen des Transformationsbereichs und K die Anzahl der Dekompositions-Stufen (Skalierungen) beschreibt, siehe auch Abb. 4.12.

4.3 Segmentierung

Viele Arbeiten im Bereich der Szenenklassifizierung berichten von einer besseren Diskriminierung durch Verwendung einer einfachen Segmentierung. Serrano *et al.* [116] sowie Vailaya *et al.* [126] unterteilen zur Unterscheidung von indoor und outdoor Szenen das Bild in vier bzw. 10 gleichgroße Bereiche, in denen jeweils Farb- und Texturmerkmale bestimmt werden und zur Klassifizierung in einen gemeinsamen Merkmalsvektor zusammengefasst werden. Eine ähnliche Herangehensweise beschreiben auch Oliva und Torralba [93], jedoch wurden hier 8×8 stark überlappende Bereiche gewählt.

Auch diese Arbeit verwendet eine einfache Segmentierung, jedoch werden hierzu nur im Bereich des Horizonts, d.h. in der Bildmitte, acht gleichgroße, stark überlappende Bildausschnitte verwendet (Abb. 4.13). Da sich Nebel nicht homogen auf die zugrundeliegenden Bildinformationen auswirkt, sondern einen stärkeren Einfluss auf entfernte Objekte hat und diese vor allem im Bereich des Horizonts vorzufinden sind, wird dadurch eine bessere Klassifizierung ermöglicht. Die unteren Bildbereiche, welche meist die Fahrbahn direkt vor dem Fahrzeug darstellen, weisen qualitativ sowohl bei Nebel als auch bei klaren Sichtverhältnisse ähnliche Eigenschaften auf. Die oberen Bildbereiche sind hingegen, unabhängig von den aktuellen Witterungsbedingungen stark schwankend. Sie können lediglich den Himmel enthalten, jedoch auch Brücken, Bäume oder auch Bereiche von anderen Fahrzeugen, welche mehr oder weniger weit entfernt sind.

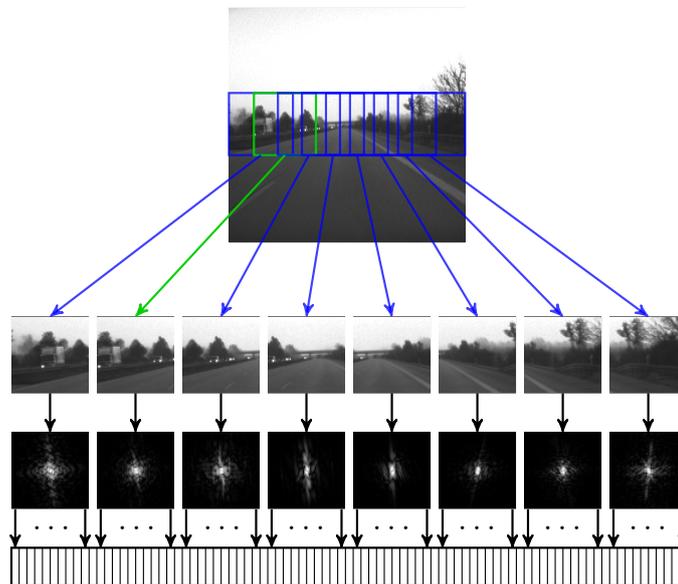


Abbildung 4.13: Einfache Segmentierung. Das Bild wird in einem Bereich um den Horizont in acht stark überlappende Bereiche unterteilt. Für jedes dieser so gewonnenen Segmente wird das Spektrum berechnet und die resultierenden Merkmale in einem großen Vektor zusammengefasst.

Dieses Kapitel untersucht den Einfluss der Parameter zur Generierung von Gabor- und Gabor Bandpass Filterbanken, vergleicht unterschiedliche Methoden zur Merkmalsextraktion und betrachtet die Auswirkung einer einfachen Segmentierung. Ein häufig vorzufindendes Maß zur Beurteilung einer Klassifizierungsprozedur ist dabei die *Erkennungsrate* (*Genauigkeit, Accuracy*)

$$acc = \frac{N_{tp} + N_{tn}}{N_{tp} + N_{tn} + N_{fp} + N_{fn}}, \quad (5.1)$$

wobei

- N_{tp} die Anzahl der True Positives, d.h. korrekt erkannter Nebel-Situationen,
- N_{tn} die Anzahl der True Negatives, d.h. korrekt erkannter nebelfreier Situationen,
- N_{fp} die Anzahl der False Positives, d.h. fälschlicherweise erkannter Nebel-Situationen und
- N_{fn} die Anzahl der False Negatives, d.h. fälschlicherweise erkannter nebelfreier Situationen

beschreiben. Da das Hauptaugenmerk dieser Arbeit auf der einleitend vorgestellten Lokalen Gefahrenwarnung liegt, ist das Ziel neben dem Erreichen einer möglichst hohen Genauigkeit auch ein möglichst ausgeglichenes Ergebnis hinsichtlich korrekt erkannter Nebel- sowie korrekt erkannter nebelfreier Fahrscenen. Als Maß für korrekt erkannte Nebel-Szenen dient die *True Positive Rate*, auch bekannt als *Sensitivität* oder *Recall*

$$tp = \frac{N_{tp}}{N_{tp} + N_{fn}}. \quad (5.2)$$

Die *True Negative Rate*, auch bekannt als *Spezifität*, liefert hingegen ein Maß für korrekt erkannte nebelfreie Fahrscenen

$$tn = \frac{N_{tn}}{N_{fp} + N_{tn}}. \quad (5.3)$$

Die Genauigkeit sowie eine Ausgewogenheit zwischen True Positiv- und True Negative-Rate kann über den in der maschinellen Bildverarbeitung weit verbreiteten *Matthews*

Korrelationskoeffizienten (MCC) zur Beurteilung binärer Klassifikatoren ausgedrückt werden [108]

$$\rho_{\text{MCC}} = \frac{N_{\text{tp}} \cdot N_{\text{tn}} - N_{\text{fp}} \cdot N_{\text{fn}}}{\sqrt{(N_{\text{tp}} + N_{\text{fp}}) (N_{\text{tp}} + N_{\text{fn}}) (N_{\text{tn}} + N_{\text{fp}}) (N_{\text{tn}} + N_{\text{fn}})}} \quad (5.4)$$

Er beschreibt die Korrelation zwischen Beobachtung und Prädiktion. Ein Wert von Eins besagt dabei eine perfekte Prädiktion, Null entspricht einer zufälligen Vorhersage und minus Eins weist auf eine vollkommene Unstimmigkeit zwischen Prädiktion und Beobachtung hin.

Vor einer genaueren Betrachtung der Klassifizierungsprozeduren erfolgt zunächst eine Vorstellung des eingesetzten Sensors, die zur Untersuchung verwendete Datengrundlage sowie die verwendete Evaluierungsmethode. Abschließend findet sich eine Zusammenfassung der erzielten Ergebnisse.

5.1 Datenquelle

Als Datenquelle wurde das Kamerasystem eines Serienfahrzeugs verwendet, welches im Fahrzeuginnenen hinter dem Rückspiegel montiert ist (Abb. 5.1). Es verwendet eine



Abbildung 5.1: Aus der Fahrzeugserie eingesetztes Kamerasystem.

5,7 mm Linse mit einer Blendenzahl von 1,7 [80] und den Grauwertsensor MT9V022 der Firma Aptina-Micron [6, 86, 117]. Die Bildpunkte haben eine quadratische Größe von $6 \mu\text{m}$ wodurch sich eine Brennweite von 950 Pixel ergibt. Dieser Sensor wurde speziell für den Einsatz in Fahrzeugen konzipiert: Neben einem Betriebsbereich von -40°C bis 85°C zeichnet ihn ein hoher Dynamikbereich von mehr als 100 dB aus. Dadurch können Bilder aufgenommen werden, welche sehr dunkle Bereiche enthalten (bis unter 0,1 Lux) und zugleich sehr helle, wie sie z.B. bei direkter Sonneneinstrahlung auftreten. Die Verwendung eines Grauwertsensors hat dabei den Vorteil, dass er gegenüber Farbsensoren sensitiver auf Lichteinstrahlung reagiert, wodurch Nacht- und Dämmerungs-Szenarien besser abgelichtet werden können. Um den Dynamikbereich nochmals zu erweitern ist direkt vor dem Sensor ein schachbrettförmiger Filter, ähnlich einer Bayer-Maske, montiert [117, 118]. Durch den Filter werden einfallende Lichtstrahlen gedämpft, wodurch diese, wie in Abb. 5.2 dargestellt, dunkler erscheinen. Bei Tag werden Bilder bestehend aus gefilterten Bildpunkten verwendet, um die Anzahl übersättigter Pixel zu verringern.

Bei Dämmerung und bei Nacht kommen hingegen die ungefilterten Bildpunkte zum Einsatz um möglichst viel Licht an den Sensor zu bekommen. Um die korrekten Bilder, d.h. gefiltert bzw. ungefiltert, verwenden zu können, besitzt die Kamera ein bildbasierte Unterscheidung von Tag- und Nacht- bzw. Dämmerungs-Szenen [117]. Das Kamerasystem lieferte dabei Grauwertbilder mit einer Auflösung von 320×240 Pixel bei einer effektiven Wiederholfrequenz von 15 Hz.

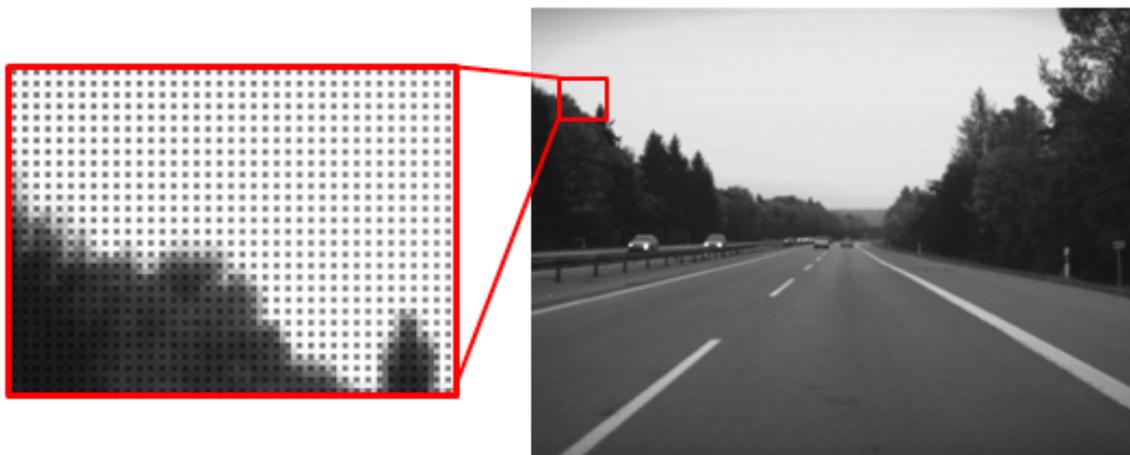


Abbildung 5.2: Rohbild der Kamera. Die dunklen Pixel stammen von einem schachbrettförmigen Filter, welcher direkt vor dem Sensor montiert ist.

5.2 Datengrundlage und Evaluierungsmethode

Zur Evaluierung wurden auf deutschen und österreichischen Autobahnen Fahrscenen mit und ohne Sichtbehinderung durch Nebel aufgenommen. Da das Kamerasystem unterschiedliche Betriebsmodi für Tag und Nacht anbietet, um z.B. für Funktionen wie die Fahrspur- oder Schilderkennung eine angepasste Parametrisierung zu ermöglichen, wurde im Rahmen der Evaluierung eine separate Betrachtung dieser beiden Situationen vorgenommen. Da es, wie einleitend erwähnt, wünschenswert ist, eine Unterscheidung von Nebel- und nebelfreien Fahrscenen zu ermöglichen, wenn lediglich das Abblendlicht eingeschaltet ist, wurde bei Nacht eine differenzierte Betrachtung von Situationen mit und ohne eingeschaltetem Fernlicht vorgenommen. Im Fahrzeug lässt sich dies ohne Weiteres durch das Auslesen der Scheinwerfer-Betriebsmodi realisieren.

Zur Evaluierung der Tag-Szenen wurden die entsprechenden Aufnahmen manuell den in Kapitel 2.6 definierten Kategorien *Excluded*¹, *kein Nebel*, *leichter Nebel*, *Nebel* und *dichter Nebel* zugeordnet. Hierzu wurden temporär zwei horizontale Linien in die Bilder eingezeichnet, welche unter der Annahme einer flachen Welt einer Entfernung von 100 bzw. 300 m entsprechen. Die Zuordnung erfolgte schließlich anhand der Sichtbarkeit der Fahrspurmarkierungen. Waren in einem Bild z.B. oberhalb der 100 m Linie aufgrund des

¹Bilder mit starker Überbelichtung oder Blendung wurden durch Zuweisung in die Kategorie *Excluded* von der Evaluierung ausgeschlossen.

5. Evaluierung

Name	Autobahn	Richtung	Frames	Excluded	Kein Nebel	Leichter Nebel	Nebel	Dichter Nebel
\mathcal{D}_1	A8	München - Salzburg	5.647	1.382	2.432	289	788	756
\mathcal{D}_2	A8	Salzburg - München	5.452	231	3.139	43	24	2.015
\mathcal{D}_3	A8	München - Salzburg	5.668	370	3.048	400	100	1.750
\mathcal{D}_4	A8	Salzburg - München	4.786	506	2.009	247	69	1.955
\mathcal{D}_5	A92	München - Deggendorf	37.375	5.329	9.561	7.934	5.166	9.385
\mathcal{D}_6	A92	München - Deggendorf	8.582	276	4.697	2.775	450	384
\mathcal{D}_7	A92	München - Deggendorf	9.334	400	0	614	3.205	5.115
\mathcal{D}_8	A92	München - Garmisch	17.043	1.757	0	6.954	7.183	1.149
Σ			93.887	10.251	24.886	19.256	16.985	22.509

Tabelle 5.1: Aufgenommene Messdaten bei Tag und Vorkommnisse der manuellen Annotationen.

Name	Autobahn	Richtung	Nebel (low beam)	Nebel (high beam)	Kein Nebel (low beam)	Kein Nebel (high beam)
\mathcal{D}_9	A92	München - Deggendorf	145	56	-	-
\mathcal{D}_{10}	A92	München - Deggendorf	124	16	-	-
\mathcal{D}_{11}	A92	Deggendorf - München	348	74	-	-
\mathcal{D}_{12}	A8, A92	München - Deggendorf	4.007	1.519	-	-
\mathcal{D}_{13}	A92	Deggendorf - München	2.847	1.404	-	-
\mathcal{D}_{14}	A9, A92	Deggendorf - München	2.212	393	-	-
\mathcal{D}_{15}	A92	München - Deggendorf	372	58	-	-
\mathcal{D}_{16}	A92	Deggendorf - München	435	227	-	-
\mathcal{D}_{17}	A92	München - Deggendorf	439	136	-	-
\mathcal{D}_{18}	A92	Deggendorf - München	959	175	-	-
\mathcal{D}_{19}	A92	München - Deggendorf	388	115	-	-
\mathcal{D}_{20}	A92	Deggendorf - München	924	131	-	-
\mathcal{D}_{21}	A92	Deggendorf - München	1.251	234	-	-
\mathcal{D}_{22}	A1 (A)	Salzburg - Wien	200	25	1.688	395
\mathcal{D}_{23}	A1 (A)	Wien - Salzburg	105	22	2.465	438
\mathcal{D}_{24}	A8	München - Salzburg	359	63	-	-
\mathcal{D}_{25}	A8	München - Salzburg	1.153	226	-	-
\mathcal{D}_{26}	A8	München - Salzburg	525	17	-	-
\mathcal{D}_{27}	A99, A8	München - Garmisch P.	489	54	-	-
\mathcal{D}_{28}	A8	München - Stuttgart	244	29	-	-
\mathcal{D}_{29}	A8	München - Salzburg	-	-	2.518	-
\mathcal{D}_{30}	A8	Salzburg - München	-	-	2.977	34
\mathcal{D}_{31}	A92	München - Deggendorf	-	-	1.767	445
\mathcal{D}_{32}	A92	München - Deggendorf	-	-	3.334	1.216
\mathcal{D}_{33}	A92	Deggendorf - München	-	-	3.508	851
\mathcal{D}_{34}	A92	Deggendorf - München	-	-	1.490	475
Σ			17.526	4.974	19.747	3.854

Tabelle 5.2: Aufgenommene Messdaten bei Nacht und Vorkommnisse der manuellen Annotationen.

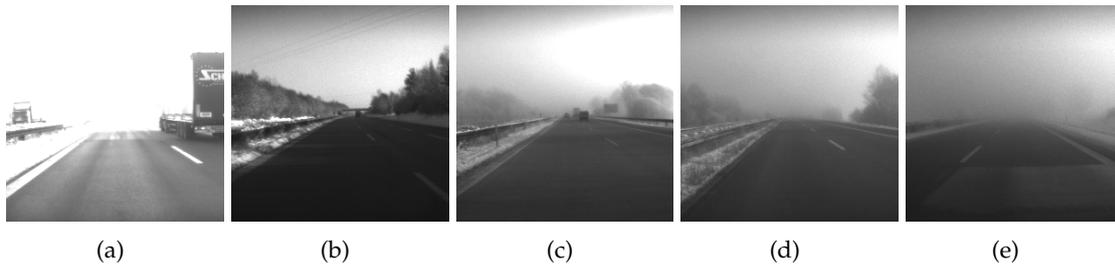


Abbildung 5.3: Beispielbilder für die Nebel-Kategorien. (a) Excluded, (b) kein Nebel, (c) leichter Nebel, (d) Nebel und (e) dichter Nebel.

Nebels keine Fahrschienen sichtbar, so wurde das Bild der Kategorie dichter Nebel zugeordnet. In Abb. 5.3 ist für jede Kategorie ein exemplarisches Bild dargestellt, Tabelle 5.1 gibt eine Übersicht der verwendeten Messdaten.

Als Evaluierungsmethode wurde eine 8-fache Kreuzvalidierung angewandt. Dazu wurden die vorliegenden Daten in acht gleichgroße Sample Sets aufgeteilt. Jedes Sample Set wird schließlich einmal zum Trainieren verwendet und anhand der restlichen sieben Sample Sets getestet. Der Mittelwert der daraus resultierenden $8 \cdot 7 = 56$ Testergebnisse liefert schließlich die Erkennungsrate des untersuchten Verfahrens. Die acht Sample Sets bestanden aus jeweils 5.500 Bildern, zur Hälfte bestehend aus Nebel und nebelfreien Fahrscenen. Die Nebel-Bilder stammen aus der Kategorie dichter Nebel und als nebelfreie Bilder wurden 500 als leichter Nebel und 2.250 als kein Nebel kategorisierte Bilder verwendet. Somit wurden insgesamt 44.000 Bilder zur Evaluierung der Tag-Szenen herangezogen. Bei der Zusammenstellung der Sample Sets wurde darauf geachtet, Bilder ähnlicher Autobahn-Typen zu gruppieren. Die Autobahn A8 zwischen München und Salzburg ist z.B. im Gegensatz zur A92 sehr hügelig und weist eine ausgeprägte Vegetation neben der Fahrbahn auf, wodurch sie bei klaren Witterungsverhältnissen Bilder mit



Abbildung 5.4: Beispielbilder für unterschiedliche Autobahn-Typen. (a) A8 mit einem Root Mean Square Contrast (RMSC) von 0,4048. (b) A92 mit einem RMSC von 0,1893.

deutlich höheren Kontrasten liefert. Dadurch kann gezeigt werden, wie sich ein zu untersuchendes Verfahren bei der Klassifizierung von z.B. grundsätzlich kontrastarmen Bildern verhält, wenn es mit grundsätzlich kontrastreichen Bildern trainiert wurde.

Zur Evaluierung der Verfahren bei Nacht wird eine differenzierte Betrachtung von Fahrscenen mit und ohne eingeschalteten Fernlicht vorgenommen. Während in Bildern mit eingeschaltetem Fernlicht die Sichtbedingungen in den Aufnahmen gut eingeschätzt werden konnten, ist dies bei Bildern, in denen lediglich mit Abblendlicht gefahren wurde, nicht immer ohne weiteres möglich. Daher wurde bei den Messungen darauf geachtet, das Fernlicht nach Möglichkeit periodisch einzuschalten. Somit konnten anhand der Bilder mit eingeschaltetem Fernlicht auch die Fahrscenen ohne Fernlicht zuverlässig der Kategorie Nebel bzw. kein Nebel zugeordnet werden. Aufgrund der begrenzten Anzahl an Messdaten erfolgte die Evaluierung der Nacht-Szenen mit eingeschaltetem Fernlicht mittels 4-facher Kreuzvalidierung, wobei jedes Sample Set aus jeweils 950 Bildern der Kategorie Nebel und 950 Bilder der Kategorie kein Nebel bestand. Somit wurden hierzu insgesamt 7.600 Bilder zur Evaluierung herangezogen. Zur Evaluierung von Nacht-Szenen ohne eingeschalteten Fernlicht wurde wiederum eine 8-fache Kreuzvalidierung angesetzt, wobei jedes Sample Set aus 2.125 Bilder der Kategorie Nebel und aus 2.125 Bilder der Kategorie kein Nebel bestand. Die Evaluierung der Nacht-Szenen ohne eingeschalteten Fernlicht bestand somit aus insgesamt 34.000 Bildern.

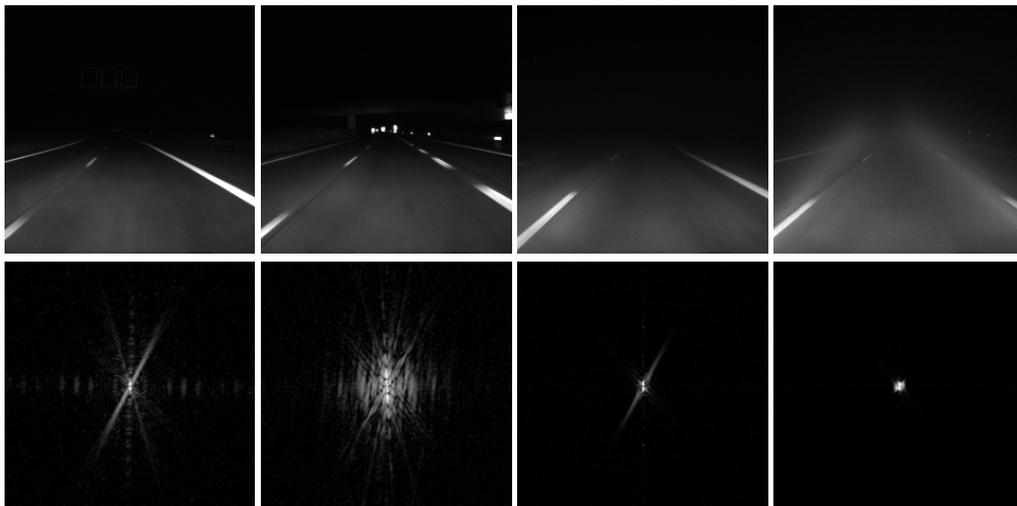


Abbildung 5.5: Exemplarische Nachtaufnahmen und korrespondierende Leistungsspektren. Von links nach rechts: Kein Nebel ohne Fernlicht, kein Nebel mit Fernlicht, Nebel ohne Fernlicht, Nebel mit Fernlicht.

Basierend auf einer jeweils einheitlichen Evaluierungsmethode für Fahrscenen bei Tag sowie Nacht mit und ohne eingeschaltetem Fernlicht wird in Abschnitt 5.3 der Einfluss unterschiedlicher Parameter bei Verwendung von Gabor- und Gabor Bandpass Filter untersucht. In Abschnitt 5.4 wird daraufhin das Klassifizierungsvermögen bei Verwendung von HOG, HGM (Histogram of Gradient Magnitudes), GLCM, Roser, Wavelet, Gabor- und Gabor Bandpass Merkmalen gegenübergestellt. Abschnitt 5.5 befasst sich

schließlich mit dem Einfluss einer einfachen Segmentierung bei Betrachtung von HGM, Roser, Wavelet, Gabor- und Gabor Bandpass Filtern.

5.3 Evaluierung der Filterparameter

5.3.1 Gabor Filterbank

Die in Abschnitt 4.1.3 beschriebene Gabor Filterbank wird durch die Anzahl der Frequenzbänder, die Anzahl der Orientierungen pro Frequenzband, die Mittenfrequenz des äußersten Frequenzbands, den Abstand der Frequenzbänder (FBs) und die Überlappung der Filter charakterisiert. Um den Einfluss dieser Parameter zu untersuchen, wurden die in Tabelle 5.3 zusammengefassten Filterbank-Konfigurationen² jeweils in Kombination mit einem Mittenfrequenz-Abstand von einer und einer halben Oktave sowie einer Überlappung der Filter bei 3 dB und bei halber Amplitude untersucht. Als maximale Mittenfrequenz wurde jeweils $f_{\max} = 0,32$ verwendet. Die hieraus resultierenden Filterbanken sind in Abb. 5.9 dargestellt.

Name	Anzahl Filter	Anzahl FBs	Orientierungen pro FB
G_{260}	260	16	32, 32, 28, 28, 24, 24, 16, 16, 12, 12, 8, 8, 6, 6, 4, 4
G_{100}	100	10	24, 16, 12, 12, 8, 8, 6, 6, 4, 4
G_{60}	60	5	12, 12, 12, 12, 12

Tabelle 5.3: Evaluerte Filterbank-Konfigurationen.

Tag-Szenen

In Abb. 5.6 sind die Ergebnisse für Tag-Szenen dargestellt. Bei separater Betrachtung der Filterbank-Konfigurationen, d.h. G_{260} , G_{100} und G_{60} , ist zu erkennen, dass mit einer Überlappung bei 3 dB durchweg bessere Ergebnisse erzielt werden konnten. In Tabelle 5.4 sind die Kombinationen aus Filterbank-Konfiguration und Parameter für die höchsten Erkennungsraten zusammengefasst. Das beste Ergebnis mit einer Erkennungsrate von $93,78 \pm 4,29$ % konnte die Filterbank-Konfiguration G_{260} mit einem Mittenfrequenzabstand von einer Oktave bei Verwendung von neun Frequenzbändern erzielen, bei einem Abstand von einer halben Oktave und allen 16 Frequenzbändern waren es $93,52 \pm 4,52$ %. Die Filterbank-Konfiguration G_{100} lieferte mit einem Mittenfrequenzabstand von einer Oktave und acht FBs eine nahezu identische Erkennungsrate von $93,74 \pm 4,54$ % und bei einem Abstand von einer halben Oktave mit 10 FBs $92,85 \pm 5,44$ %. Die Filterbank-Konfiguration G_{60} lieferte in der Spitze leicht schwächere Ergebnisse. Mit einem Mittenfrequenzabstand von einer bzw. einer halben Oktave und jeweils fünf FBs wurden Erkennungsraten von $92,71 \pm 5,08$ % bzw. $92,57 \pm 5,99$ % erreicht.

²Der Begriff Konfiguration beschreibt hier eine über die Anzahl der Orientierungen pro Frequenzband spezifizierte Filterbank.

5. Evaluierung

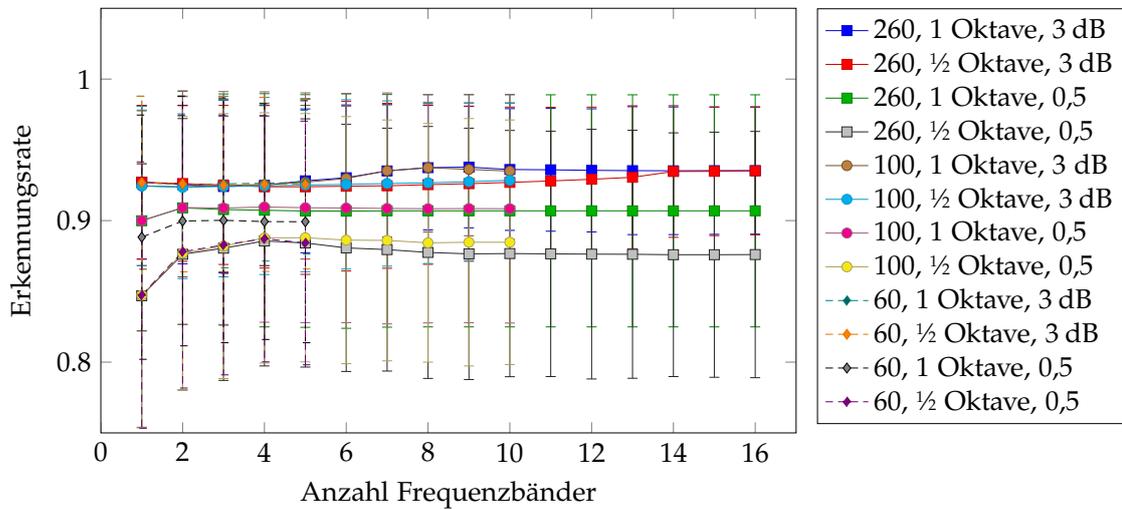


Abbildung 5.6: Evaluierungsergebnisse der Gabor Filterbanken unterschiedlicher Konfigurationen in Kombination mit verschiedenen Parametern für den Abstand der Frequenzbänder und für die Überlappung der Filter für Fahrscenen bei Tag mit sukzessiver Hinzunahme weiterer Frequenzbänder. Die Fehlerbalken kennzeichnen die Standardabweichung der einzelnen Ergebnisse der Kreuzvalidierung.

Name	Abstand	Überlappung	Anzahl FBs	Erkennungsrate
G_{260}	1 Oktave	3 dB	9	93,78 ± 4,29 %
G_{260}	1/2 Oktave	3 dB	16	93,52 ± 4,52 %
G_{260}	1 Oktave	0,5	2	90,90 ± 8,24 %
G_{260}	1/2 Oktave	0,5	4	88,56 ± 8,83 %
G_{100}	1 Oktave	3 dB	8	93,74 ± 4,54 %
G_{100}	1/2 Oktave	3 dB	10	92,85 ± 5,44 %
G_{100}	1 Oktave	0,5	4	90,96 ± 8,14 %
G_{100}	1/2 Oktave	0,5	5	88,79 ± 8,77 %
G_{60}	1 Oktave	3 dB	5	92,71 ± 5,08 %
G_{60}	1/2 Oktave	3 dB	5	92,57 ± 5,99 %
G_{60}	1 Oktave	0,5	3	90,02 ± 8,65 %
G_{60}	1/2 Oktave	0,5	4	88,72 ± 8,70 %

Tabelle 5.4: Evaluierungsergebnisse für die optimale Anzahl an Frequenzbänder für alle Kombinationen aus Filterbank-Konfiguration und Parameter bei Betrachtung von Tag-Szenen.

Nacht-Szenen mit Fernlicht

In Abb. 5.7 sind die Evaluierungsergebnisse bei Nacht mit eingeschaltetem Fernlicht dargestellt und Tabelle 5.5 gibt eine Zusammenfassung der höchsten Ergebnisse, die sich aus den Kombinationen der Filterbank-Konfigurationen und Parameter ergeben. Dabei ist zu erkennen, dass alle Filterbank-Konfigurationen in Kombination mit den untersuchten Parametern durchweg sehr hohe Erkennungsraten von ca. 99 % erzielen. Ab der Hinzunahme eines sechsten Frequenzbands ist ein leichter Einbruch bei den Filterbanken G_{100} mit Mittenfrequenz-Abstand von einer halben Oktave und halber Amplitude Überlappung sowie bei G_{100} und G_{260} jeweils mit einem FB-Abstand von einer Oktave und 3 dB Überlappung zu erkennen. Bei der Filterbank G_{260} mit halber Oktave FB-Abstand und 3 dB Überlappung tritt dieser Rückgang ab der Hinzunahme des elften Frequenzbands auf. Die höchste Erkennungsrate von $99,43 \pm 0,55$ % erzielt G_{100} mit einem FB-Abstand von einer halben Oktave und 3 dB Überlappung bei Verwendung von sieben FBs. Die Filterbank G_{60} mit halber Oktave FB-Abstand, halber Amplitude Überlappung und bei Verwendung von drei FBs erzielt in der Spitze die niedrigste Erkennungsrate. Mit $98,93 \pm 0,46$ % ist diese dennoch sehr hoch.

Nacht-Szenen ohne Fernlicht

In Abb. 5.8 sind die Evaluierungsergebnisse bei Nacht ohne eingeschaltetem Fernlicht dargestellt. Diese erreichen zwar nicht die Erkennungsraten bei eingeschaltetem Fernlicht, übertreffen jedoch die bei Tag-Szenen erzielten Ergebnisse. Bei den Filterbanken G_{260} ist bei Verwendung einer Überlappung von 3 dB und einem FB-Abstand von einer bzw. einer halben Oktave ein Rückgang der Erkennungsraten ab der Hinzunahme eines fünften bzw. achten FBs zu erkennen. Mit einer Überlappung bei halber Amplitude bleiben die Erkennungsraten relativ konstant bei ca. 98,8 % und 97,7 % für einen FB-Abstand von einer bzw. einer halben Oktave. Auch bei G_{100} mit einer Oktave Abstand und 3 dB Überlappung ist ein Rückgang ab Hinzunahme des fünften Frequenzbands zu erkennen. Das beste Ergebnis von $98,94 \pm 1,32$ % konnte mit der Filterbank-Konfiguration G_{100} mit einer Oktave Abstand, halber Amplitude Überlappung und zwei Frequenzbändern erzielt werden. Eine Zusammenfassung der höchsten Erkennungsraten für die jeweiligen Parameter und Filterbank-Konfigurationen findet sich in Tabelle 5.6.

Zusammenfassung

Zusammenfassend lässt sich sagen, dass die Anzahl der verwendeten Frequenzbänder und die Position der Überlappung angrenzender Filter den größten Einfluss auf die Erkennungsraten haben. Die verwendete Filterbankkonfiguration sowie der Mittenfrequenzabstand haben hingegen einen geringen Einfluss. Erfolgt lediglich eine Betrachtung der Ergebnisse mit einer Überlappung bei 3 dB, so liegen zwischen dem besten und schlechtesten Ergebnissen bei Tag, Nacht mit und ohne Fernlicht lediglich 1,21 %, 0,22 % und 0,26 %. Insgesamt sind die Ergebnisse mit Erkennungsraten von 93,78 %, 99,43 % und 98,94 % bei Tag, Nacht mit und ohne Fernlicht recht hoch.

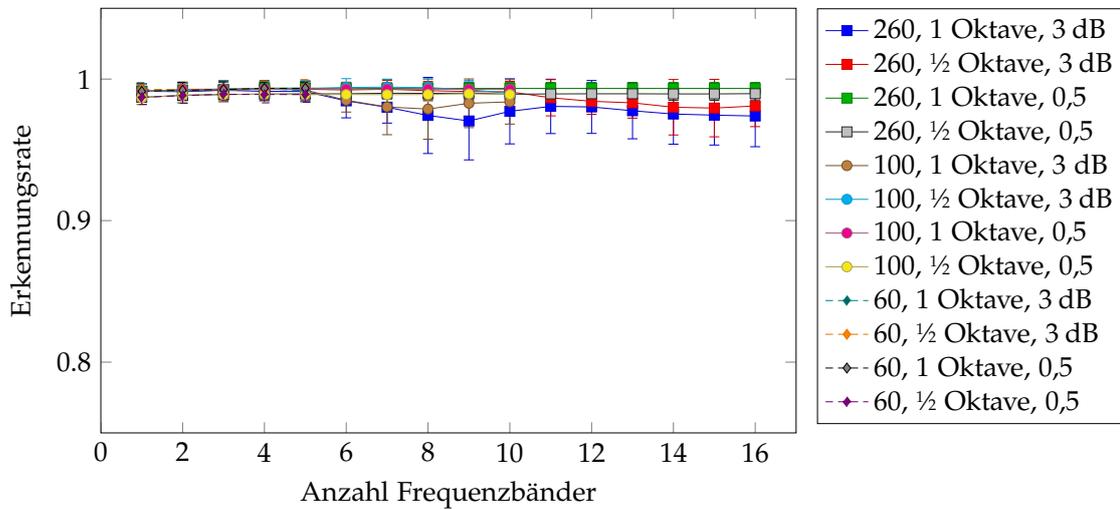


Abbildung 5.7: Evaluierungsergebnisse der Gabor Filterbanken unterschiedlicher Konfigurationen in Kombination mit verschiedenen Parametern für den Abstand der Frequenzbänder und für die Überlappung der Filter für Fahrscenen bei Nacht mit Fernlicht und sukzessiver Hinzunahme weiterer Frequenzbänder. Die Fehlerbalken kennzeichnen die Standardabweichung der einzelnen Ergebnisse der Kreuzvalidierung.

Name	Abstand	Überlappung	Anzahl FBs	Erkennungsrate
G_{260}	1 Oktave	3 dB	3	99,21 ± 0,61%
G_{260}	½ Oktave	3 dB	4	99,29 ± 0,52 %
G_{260}	1 Oktave	0,5	5	99,36 ± 0,35 %
G_{260}	½ Oktave	0,5	9	99,01 ± 0,43 %
G_{100}	1 Oktave	3 dB	4	99,31 ± 0,60 %
G_{100}	½Oktave	3 dB	7	99,43 ± 0,55 %
G_{100}	1 Oktave	0,5	4	99,32 ± 0,39 %
G_{100}	½ Oktave	0,5	9	98,96 ± 0,49 %
G_{60}	1 Oktave	3 dB	4	99,31 ± 0,56 %
G_{60}	½ Oktave	3 dB	5	99,37 ± 0,60 %
G_{60}	1 Oktave	0,5	5	99,35 ± 0,43 %
G_{60}	½ Oktave	0,5	3	98,93 ± 0,46 %

Tabelle 5.5: Evaluierungsergebnisse für die optimale Anzahl an Frequenzbänder für alle Kombinationen aus Filterbank-Konfiguration und Parameter bei Betrachtung von Nacht-Szenen mit eingeschaltetem Fernlicht.

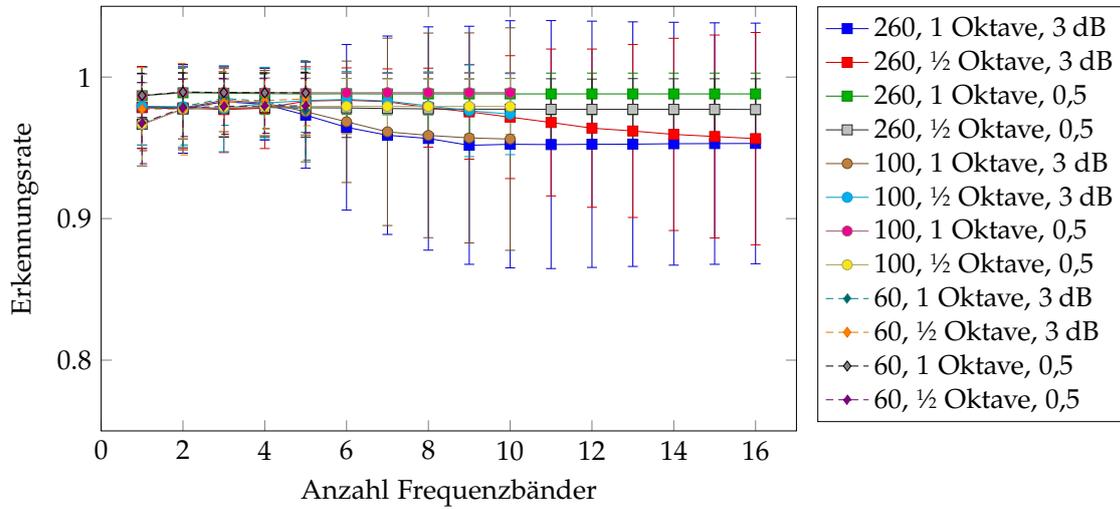


Abbildung 5.8: Evaluierungsergebnisse der Gabor Filterbanken unterschiedlicher Konfigurationen in Kombination mit verschiedenen Parametern für den Abstand der Frequenzbänder und für die Überlappung der Filter für Fahrscenen bei Nacht ohne Fernlicht und sukzessiver Hinzunahme weiterer Frequenzbänder. Die Fehlerbalken kennzeichnen die Standardabweichung der einzelnen Ergebnisse der Kreuzvalidierung.

Name	Abstand	Überlappung	Anzahl FBs	Erkennungsrate
G_{260}	1 Oktave	3 dB	3	$98,26 \pm 2,46$ %
G_{260}	$\frac{1}{2}$ Oktave	3 dB	6	$98,36 \pm 2,29$ %
G_{260}	1 Oktave	0,5	2	$98,89 \pm 1,40$ %
G_{260}	$\frac{1}{2}$ Oktave	0,5	4	$97,85 \pm 2,08$ %
G_{100}	1 Oktave	3 dB	3	$98,37 \pm 2,23$ %
G_{100}	$\frac{1}{2}$ Oktave	3 dB	6	$98,42 \pm 1,97$ %
G_{100}	1 Oktave	0,5	2	$98,94 \pm 1,34$ %
G_{100}	$\frac{1}{2}$ Oktave	0,5	6	$97,94 \pm 1,96$ %
G_{60}	1 Oktave	3 dB	3	$98,49 \pm 1,90$ %
G_{60}	$\frac{1}{2}$ Oktave	3 dB	5	$98,46 \pm 1,90$ %
G_{60}	1 Oktave	0,5	2	$98,94 \pm 1,36$ %
G_{60}	$\frac{1}{2}$ Oktave	0,5	5	$97,97 \pm 1,92$ %

Tabelle 5.6: Evaluierungsergebnisse für die optimale Anzahl an Frequenzbänder für alle Kombinationen aus Filterbank-Konfiguration und Parameter bei Betrachtung von Nacht-Szenen ohne eingeschaltetem Fernlicht.

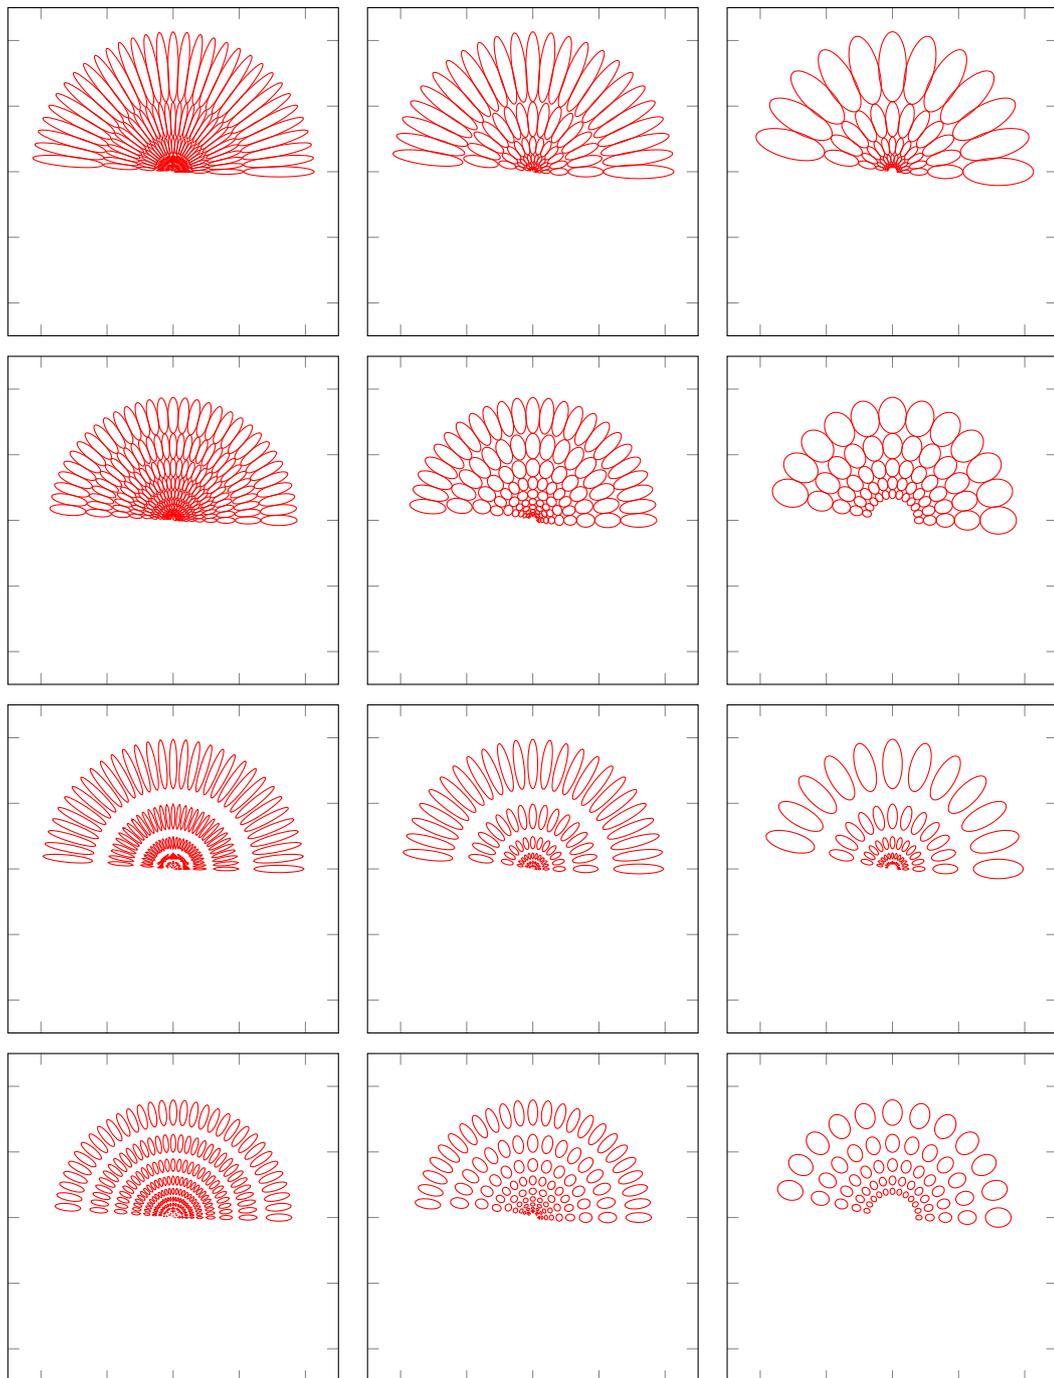


Abbildung 5.9: Evaluierte Gabor Filterbanken. Spaltenweise sind die Filterbank-Konfigurationen bestehend aus 260, 100 und 60 Gabor-Filter dargestellt. Zeilenweise sind abwechseln eine und eine halbe Oktave Mittenfrequenz-Abstand dargestellt sowie in den ersten beiden Zeilen Filter-Überlappungen bei 3 dB und in den letzten beiden Zeilen bei der halber Amplitude. Als äußerste Mittenfrequenz wurde jeweils 0,32 gewählt. Die roten Konturen zeigen die 3 dB Isolinien der einzelnen Gabor Filter.

5.3.2 Bandpass Filterbanken

Durch eine vorteilhafte Wahl bzw. Reduzierung der Merkmale kann wie in Abschnitt 4.1.3 beschrieben die Erkennungsrate eines Klassifikators erhöht werden. In diesem Abschnitt werden daher neben den Parametern unterschiedliche Ansätze zur Konstruktion von Bandpass Filtern untersucht, Gabor Bandpass und Ring Filterbanken. Die Gabor Bandpass

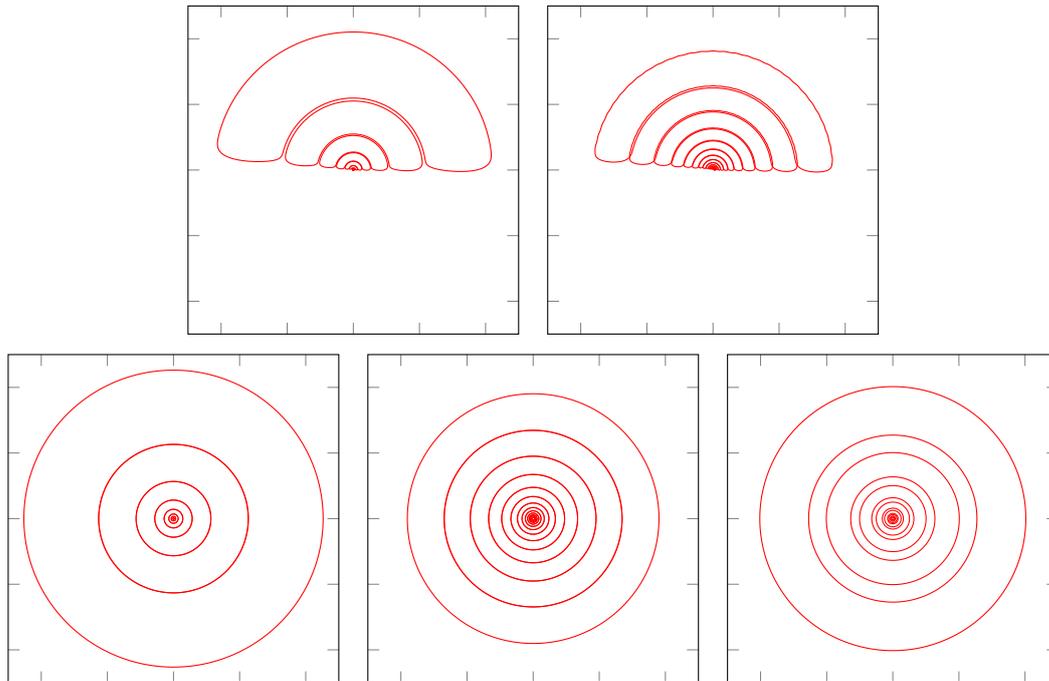


Abbildung 5.10: Evaluerte Bandpass Filterbanken. In der ersten Zeile sind die aus einzelnen Gabor-Filtern zusammengesetzten Bandpässe mit einer und einer halben Oktave abgebildet. In der zweiten Zeile sind die verwendeten Ring Filterbanken dargestellt. Die ersten beiden unterscheiden sich durch den Abstand von einer bzw. einer halben Oktave, die dritte entspricht der Designempfehlung aus [16]. Als äußerste Mittenfrequenz wurde jeweils $0,32 c/p$ gewählt. Die roten Konturen zeigen die 3 dB Isolinien der einzelnen Bandpass Filter.

Filterbanken wurden durch Aufsummieren der Gabor Filter eines Frequenzbands erstellt³. Die Filterbank Konfigurationen G_{100} und G_{60} stellen dadurch eine Untermenge von G_{260} dar. Um ein möglichst breites Frequenzspektrum zu untersuchen, wurde daher letztgenannte als Ausgangsbasis herangezogen. Des Weiteren wurden für die Gabor Bandpässe Mittenfrequenzabstände von einer halben und einer Oktave untersucht. Die Überlappung der Filter benachbarter Frequenzbänder bei halber Filteramplitude wurde nicht betrachtet, da bei der Evaluierung der Gabor Filter bei 3 dB bessere Ergebnisse erzielt werden konnten. Darüber hinaus wurden drei Ring Filterbanken untersucht,

³Die Mittelung bzw. das Aufsummieren der Filterantworten eines Frequenzbands liefert nahezu identische Ergebnisse, ist jedoch rechenaufwändiger, da der Vorteil weniger Abtastoperationen bei Verwendung von Bandpässen hier nicht ausgenutzt wird. Daher wird diese Art der Konstruktion von Bandpässen mittels Gabor-Filtern hier nicht weiter betrachtet.

eine mit den von Coggings vorgeschlagenen Parametern, und zwei mit zu den Gabor-Bandpässen korrespondierenden Parametern. In Abb. 5.10 findet sich eine graphische Darstellung der untersuchten Bandpass Filterbanken.

Tag-Szenen

In Abb. 5.11 sind die Ergebnisse bei Tag dargestellt und in Tabelle 5.7 findet sich eine Übersicht der besten Ergebnisse der untersuchten Bandpässe mit Angabe der verwendeten Anzahl an Frequenzbändern. Die beiden Gabor Bandpass Filterbanken erzielten nahezu identische Ergebnisse und weisen im Vergleich die höchsten Erkennungsraten von ca. $94,3 \pm 4,7$ % auf. Bei einem Frequenzabstand von einer Oktave werden hierzu acht FBs und bei einem Frequenzabstand von einer halben Oktave 15 FBs benötigt. Die Erkennungsraten sind bei Verwendung einer unterschiedlichen Anzahl an Frequenzbänder sehr stabil mit Erkennungsraten im Bereich von 93,36–94,31 %. Die Ring Filterbank mit einer Oktave Frequenzabstand kommt mit einer Erkennungsrate von $93,73 \pm 4,67$ % am nächsten an die Gabor Bandpässe heran, auch die von Coggings vorgeschlagene Parametrisierung liefert noch gute Werte und weist zudem über die Anzahl verwendeter Frequenzbänder hinweg die höchste Stabilität auf. Der Unterschied zwischen der höchsten und niedrigsten Erkennungsrate liegt bei 0,59 %. Lediglich die Ring Filterbank mit halber Oktave Frequenzabstand schneidet in diesem Vergleich deutlich schlechter ab.

Nacht-Szenen mit Fernlicht

Wie in Abbildung 5.12 und Tabelle 5.8 zu sehen ergibt sich bei der Evaluierung von Nacht-Szenen mit eingeschaltetem Fernlicht ein ähnliches Ergebnis wie bei der Untersuchung der Gabor Filter. Die Erkennungsraten sind in der Spitze leicht besser, liegen aber wiederum im Bereich von 99 %. Die Gabor Bandpässe konnten auch hier leicht besser abschneiden als die Ring Filterbanken. Auch die Verwendung einer bzw. einer halben Oktave Frequenzabstand wirkt sich kaum auf das Ergebnis aus, mit erstgenannter Parametrisierung werden jedoch wiederum weniger Frequenzbänder benötigt. Auffällig ist jedoch, dass die Erkennungsraten der Gabor Bandpass Filterbank mit einer Oktave FB-Abstand ab einer Verwendung von neun und mit einer halben Oktave Abstand bei Verwendung von 16 Filtern deutlich abfallen.

Nacht-Szenen ohne Fernlicht

Die Ergebnisse der Evaluierung bei Nacht ohne Fernlicht sind in Abbildung 5.13 und Tabelle 5.9 dargestellt. Wiederum liefern die Gabor Bandpässe die höchsten Erkennungsraten von $98,71 \pm 1,31$ % und $98,89 \pm 1,09$ % bei einer Oktave Frequenzabstand und vier FBs bzw. einer halben Oktave Frequenzabstand und sieben FBs. Mit diesen Werten erreichen sie ähnlich gute Ergebnisse wie z.B. die Ring Filter mit eingeschaltetem Fernlicht. Auffällig ist wiederum, dass die Ergebnisse der Gabor Filterbanken bei Verwendung einer halben Oktave Frequenzabstand ab fünf und bei Verwendung einer Oktave Frequenzabstand ab neun Frequenzbändern deutlich einbrechen. Bei den Ring Filterbanken wurde mit einer halben Oktave Frequenzabstand das beste Ergebnis erzielt. Das Ergebnis

von $96,53 \pm 3,99$ % bei einer Oktave Frequenzabstand weicht bereits deutlich von denen der Gabor Bandpässe ab.

Zusammenfassung

Die Gabor Bandpässe erzielen sowohl bei Tag als auch bei Nacht mit und ohne eingeschaltetem Fernlicht die höchsten Erkennungsraten. Dabei wirkt sich die Wahl des Frequenzabstands nicht merklich auf die erzielbare Erkennungsrate aus. Bei Verwendung eines Frequenzabstands von einer Oktave werden aber jeweils weniger Frequenzbänder benötigt. Da dadurch der Rechenaufwand verringert werden kann, ist diese Parametrisierung vorteilhaft. Im Vergleich zu den im vorherigen Abschnitt untersuchten Gabor Filterbanken werden zudem durch die Zusammenfassung der Filter eines Frequenzbands zu Bandpässen durchweg bessere Ergebnisse erzielt.

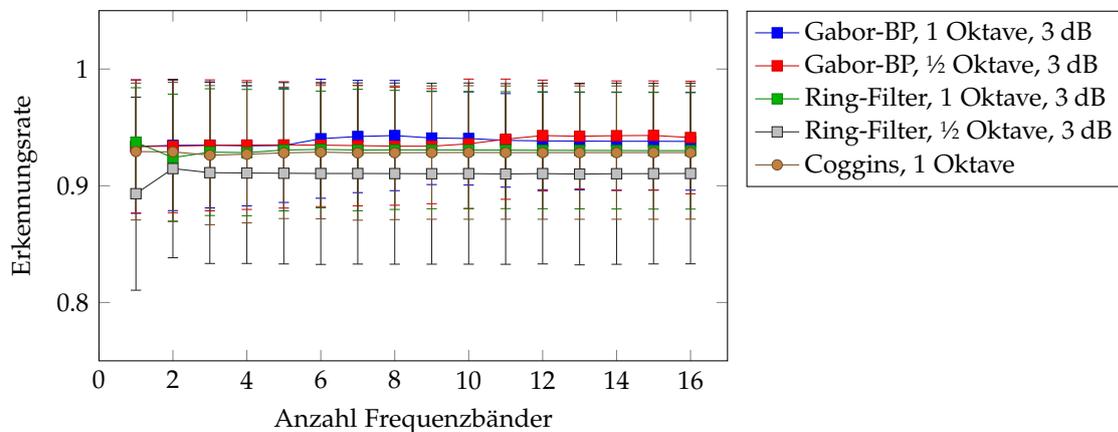


Abbildung 5.11: Evaluierungsergebnisse der Bandpass Filterbanken unterschiedlicher Konfigurationen in Kombination mit verschiedenen Parametern für den Abstand der Frequenzbänder für Fahrscenen bei Tag mit sukzessiver Hinzunahme weiterer Frequenzbänder. Die Fehlerbalken kennzeichnen die Standardabweichung der einzelnen Ergebnisse der Kreuzvalidierung.

Name	Abstand	Überlappung	Anzahl FBs	Erkennungsrate
$G_{260,BP}$	1 Oktave	3 dB	8	$94,30 \pm 4,72$ %
$G_{260,BP}$	½ Oktave	3 dB	15	$94,31 \pm 4,67$ %
G_{Ring}	1 Oktave	3 dB	1	$93,73 \pm 4,67$ %
G_{Ring}	½ Oktave	3 dB	2	$91,47 \pm 7,64$ %
$G_{Coggins}$	1 Oktave	-	1	$92,93 \pm 5,86$ %

Tabelle 5.7: Evaluierungsergebnisse der Bandpass Filter bei Tag.

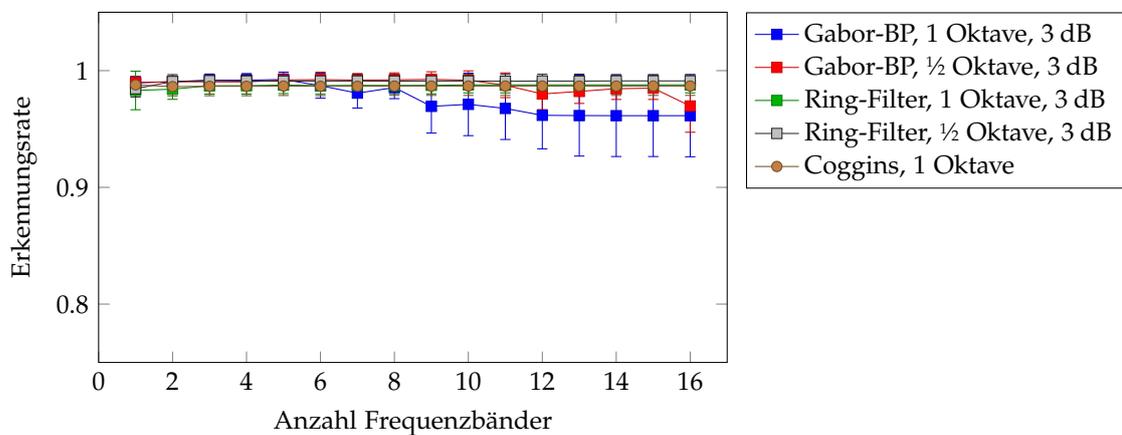


Abbildung 5.12: Evaluierungsergebnisse der Bandpass Filterbanken unterschiedlicher Konfigurationen in Kombination mit verschiedenen Parametern für den Abstand der Frequenzbänder für Fahrscenen bei Nacht mit Fernlicht und sukzessiver Hinzunahme weiterer Frequenzbänder. Die Fehlerbalken kennzeichnen die Standardabweichung der einzelnen Ergebnisse der Kreuzvalidierung.

Name	Abstand	Überlappung	Anzahl FBs	Erkennungsrate
$G_{260,BP}$	1 Oktave	3 dB	5	99,24 ± 0,63 %
$G_{260,BP}$	1/2 Oktave	3 dB	9	99,25 ± 0,65 %
G_{Ring}	1 Oktave	3 dB	10	98,78 ± 0,69 %
G_{Ring}	1/2 Oktave	3 dB	3	99,14 ± 0,51 %
$G_{Coggins}$	1 Oktave	-	1	98,78 ± 0,70 %

Tabelle 5.8: Evaluierungsergebnisse der Bandpass Filter bei Nacht mit Fernlicht.

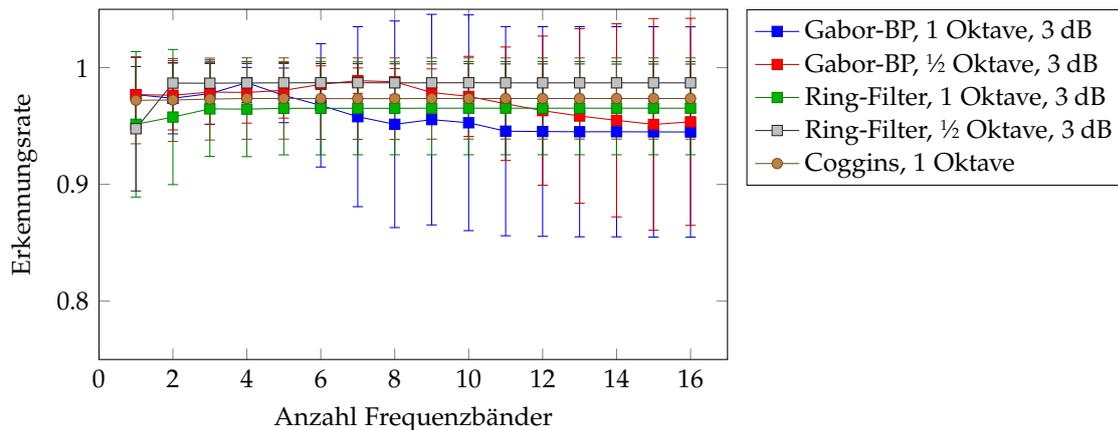


Abbildung 5.13: Evaluierungsergebnisse der Bandpass Filterbanken unterschiedlicher Konfigurationen in Kombination mit verschiedenen Parametern für den Abstand der Frequenzbänder für Fahrscenen bei Nacht ohne Fernlicht und sukzessiver Hinzunahme weiterer Frequenzbänder. Die Fehlerbalken kennzeichnen die Standardabweichung der einzelnen Ergebnisse der Kreuzvalidierung.

Name	Abstand	Überlappung	Anzahl FBs	Erkennungsrate
$G_{260,BP}$	1 Oktave	3 dB	4	$98,71 \pm 1,31$ %
$G_{260,BP}$	$\frac{1}{2}$ Oktave	3 dB	7	$98,89 \pm 1,09$ %
G_{Ring}	1 Oktave	3 dB	9	$96,53 \pm 3,99$ %
G_{Ring}	$\frac{1}{2}$ Oktave	3 dB	6	$98,71 \pm 1,64$ %
$G_{Coggins}$	1 Oktave	-	4	$97,36 \pm 3,49$ %

Tabelle 5.9: Evaluierungsergebnisse der Bandpass Filter bei Nacht ohne Fernlicht.

5.4 Evaluierung der Merkmale

Nach der Untersuchung der Konfiguration und Parametrisierung von Filterbanken zur Extraktion spektralbasierter Merkmale, erfolgt nun ein Vergleich zu anderen gängigen Merkmalen. Hierzu werden die Gabor- und Gabor Bandpass Filterbanken mit einer Oktave Frequenzabstand mit den in Abschnitt 4.2 beschriebenen HOG-, GLCM- und Wavelet-Merkmalen verglichen. Darüber hinaus wird auch die Verwendung eines Histogramms der Gradientenbeträge (Histogram of Gradient Magnitudes, HGM) sowie die in Abschnitt 3.7 beschriebenen Roser-Merkmale betrachtet. Die in Abschnitt 4.1.1 beschriebene Vorverarbeitung sowie die auf der Hauptkomponentenanalyse basierende Merkmalsreduktion hat sich bei Verwendung eines linearen Klassifikators basierend auf der Fischer-LDA bei allen hier betrachteten Merkmalen als vorteilhaft erwiesen und kommt somit durchgängig zum Einsatz.

Die HOG-Merkmale wurden basierend auf einer Cell, welche sich über das gesamte Bild erstreckt, bestimmt. Dabei galt es eine geeignete Anzahl an Bins zu bestimmen. Hierzu wurde, wie in Abb. 5.14 zu sehen, die Erkennungsrate in Abhängigkeit der verwendeten Bins untersucht. Für Tag-Szenarien wurde das beste Ergebnis von $90,89 \pm 7,05$ % mit fünf, bei Nacht mit Fernlicht $95,24 \pm 5,30$ % mit zehn und bei Nacht ohne Fernlicht $95,14 \pm 5,27$ % mit 15 Bins erzielt. Analog zur Verwendung von Bandpass Filtern im Spektralbereich liegt die Überlegung nahe, die Richtungsinformationen der HOG-Merkmale zu verwerfen und lediglich die Gradientenbeträge zu betrachten. Für die sogenannten HGM-Merkmale wurde ebenfalls die Erkennungsrate in Abhängigkeit der verwendeten Bins untersucht und ist in Abb. 5.15 dargestellt. Dabei ergaben sich für Tag- sowie Nacht-Szenen mit und ohne Fernlicht maximale Erkennungsraten von $92,67 \pm 3,28$ %, $98,80 \pm 0,86$ % und $96,23 \pm 9,72$ % bei Verwendung von 236, 32 bzw. 104 Bins.

Bei den GLCM-Merkmalen ergaben sich die höchsten Erkennungsraten durch Verwendung der ersten 14 Haralick-Deskriptoren aus [45], basierend auf der horizontalen, vertikalen und den beiden diagonalen GLCM-Matrizen. Die sich hieraus ergebenden $4 \cdot 14 = 56$ Merkmale wurden in einem großen Merkmalsvektor zusammengefasst. Die Mittelwertbildung sowie die Standardabweichung der Haralick-Deskriptoren über die GLCM-Matrizen hat sich als nicht vorteilhaft erwiesen. Eine Untersuchung der Quantisierungsstufen ergab schließlich, wie in Abb. 5.16 zu sehen, für Tag, Nacht mit und ohne Fernlicht optimale Ergebnisse bei 16, 16 bzw. 48 Stufen mit Erkennungsraten von $89,36 \pm 5,56$ %, $98,73 \pm 0,63$ % und $95,93 \pm 9,22$ %.

Die Roser-Merkmale wurden bei dieser Betrachtung ebenfalls über das gesamte Bild berechnet, d.h. die in [112] vorgestellte Unterteilung in Sub-RoIs wurde hier nicht angewandt. Darüber hinaus wurden lediglich die lokalen Kontrast-, Helligkeits- und Bildschärfe-Histogramme verwendet. Der Farbton und die Farbsättigung konnten wegen der fehlenden Farbinformationen im vorliegenden Datensatz nicht einbezogen werden. Für Tag, Nacht mit und ohne Fernlicht konnten somit Erkennungsraten von $91,52 \pm 5,77$ %, $97,64 \pm 1,78$ % und $96,14 \pm 3,01$ % erzielt werden.

Die Wavelet-Merkmale werden wie in [116] beschrieben über die Energien der Approximations- und Detail-Koeffizienten, basierend auf einer biorthogonalen Daubechies-Filterbank, für das gesamte Bild bestimmt. Darüber hinaus wurde, wie bei den spektralbasierten Merkmalen, vor der Dekomposition ein Hanning-Fenster auf das Bild im Ortsbereich angewandt, wodurch sich die Erkennungsrate bei Tag um mehr als 3 % steigern ließ. Insgesamt konnten dadurch für Tag, Nacht mit und ohne Fernlicht mit fünf, drei und einer Dekompositionsstufe Ergebnisse von $92,88 \pm 5,49$ %, $99,19 \pm 0,59$ % und $98,76 \pm 1,22$ % erzielt werden, siehe auch Abb. 5.17.

Tabelle 5.10 fasst die Evaluierungsergebnisse der untersuchten Merkmale zusammen. Dabei lässt sich erkennen, dass die spektralbasierten Merkmale bei Tag und bei Nacht sowohl mit als auch ohne Fernlicht die höchsten Erkennungsraten erzielen konnten. Der Gabor Bandpass Filter liefert hierbei mit $94,30 \pm 4,72$ %, $99,24 \pm 0,63$ % und $98,71 \pm 1,31$ % bei Tag, Nacht mit und ohne Fernlicht die höchsten Genauigkeiten und MCC's. Die Wavelet Merkmale liefern bei Nacht mit Fernlicht ebenso gute Ergebnisse wie die Gabor-Filter, bei Tag erzielen sie jedoch ein etwas schwächeres Ergebnis von $92,88 \pm 5,49$ %. Die Merkmale aus dem Ortsbereich können weder bei Tag, noch bei Nacht die Ergebnisse der spektralbasierten Merkmale oder der Wavelets erreichen. Am besten schnitten da-

bei die HGM-Merkmale mit Erkennungsraten von $92,67 \pm 3,28 \%$, $98,80 \pm 0,86 \%$ und $96,23 \pm 9,72 \%$ bei Tag, Nacht mit und ohne Fernlicht ab. Die HOG-Merkmale lieferten neben den niedrigsten Genauigkeiten von $90,89 \pm 7,05 \%$, $95,24 \pm 5,30 \%$ und $95,14 \pm 5,27 \%$ auch das am wenigsten ausgeglichene Ergebnis hinsichtlich der True Positiv und True Negative Rate, wie anhand des MCC zu erkennen ist.

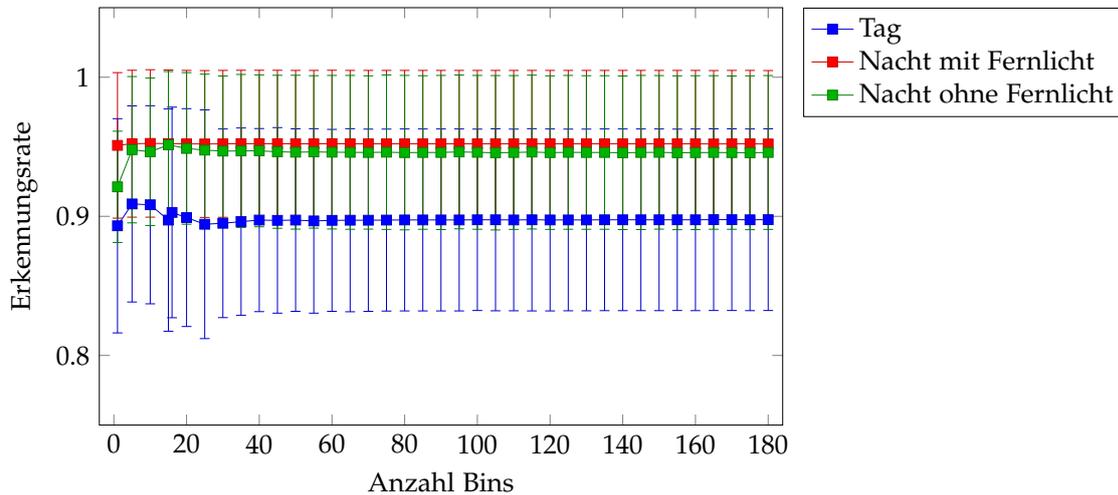


Abbildung 5.14: Erkennungsraten der HOG-Merkmale für Tag, Nacht mit und ohne Fernlicht abhängig von der Anzahl verwendeter Bins.

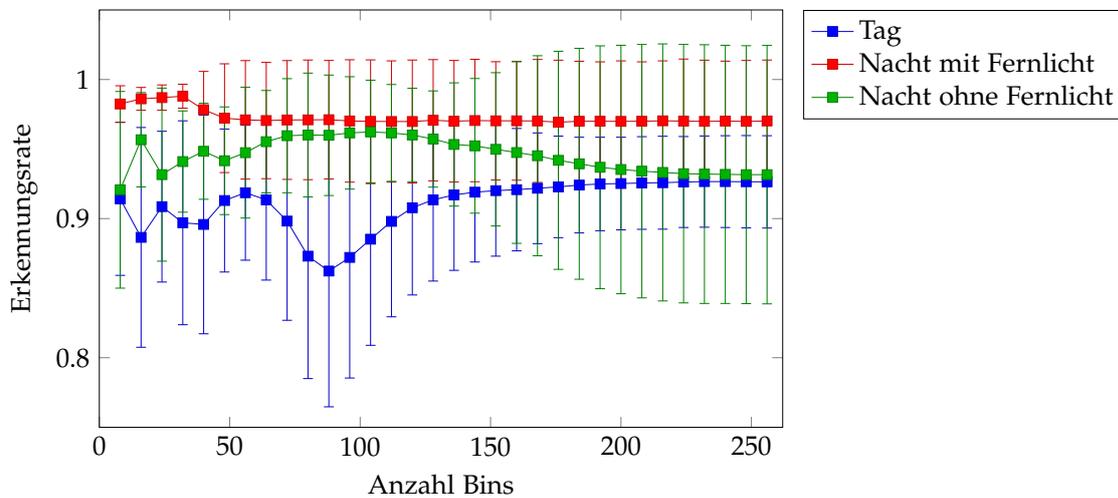


Abbildung 5.15: Erkennungsraten der HGM-Merkmale für Tag, Nacht mit und ohne Fernlicht abhängig von der Anzahl verwendeter Bins.

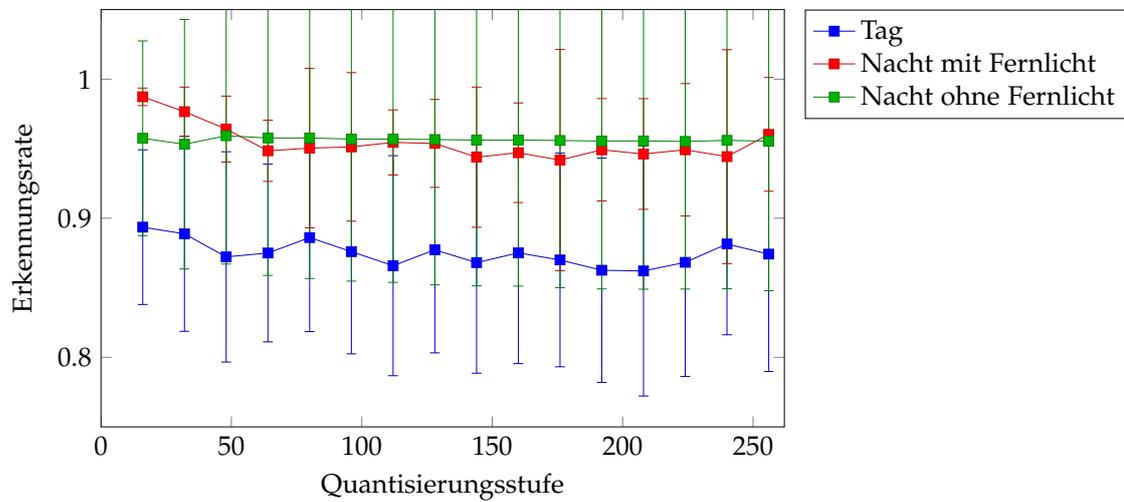


Abbildung 5.16: Erkennungsraten der GLCM-Merkmale für Tag, Nacht mit und ohne Fernlicht abhängig von der Quantisierungsstufe.

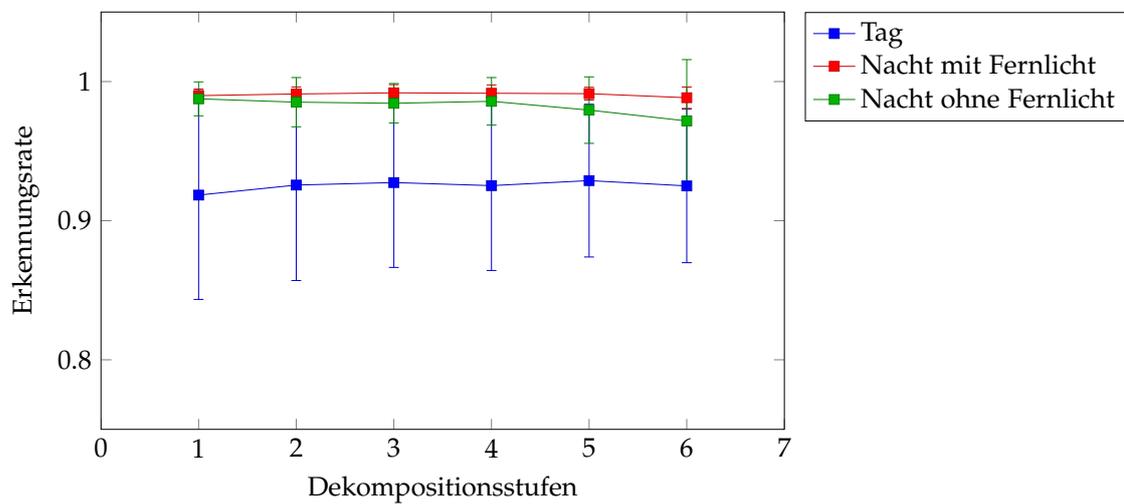


Abbildung 5.17: Erkennungsraten der Wavelet-Merkmale für Tag, Nacht mit und ohne Fernlicht abhängig von der Dekompositionsstufe.

		Tag	Nacht (mit Fernlicht)	Nacht (ohne Fernlicht)
HOG	Acc	90,89 ± 7,05	95,24 ± 5,30	95,14 ± 5,27
	Tp	93,58 ± 4,36	96,53 ± 3,40	96,73 ± 3,23
	Tn	88,20 ± 14,40	93,95 ± 9,80	93,54 ± 9,98
	Mcc	0,8190	0,9051	0,9032
HGM	Acc	92,67 ± 3,28	98,80 ± 0,86	96,23 ± 9,72
	Tp	93,79 ± 4,59	98,78 ± 1,09	97,09 ± 2,22
	Tn	91,55 ± 6,53	98,82 ± 1,81	95,61 ± 6,72
	Mcc	0,9275	0,9760	0,9271
GLCM	Acc	89,36 ± 5,56	98,73 ± 0,63	95,93 ± 9,22
	Tp	89,68 ± 10,96	99,01 ± 0,68	99,20 ± 1,08
	Tn	89,04 ± 10,17	98,46 ± 1,46	92,66 ± 18,57
	Mcc	0,7872	0,9747	0,9206
Roser	Acc	91,52 ± 5,77	97,64 ± 1,78	96,14 ± 3,01
	Tp	89,88 ± 11,63	97,57 ± 1,67	96,34 ± 2,83
	Tn	93,17 ± 7,04	97,72 ± 2,63	95,95 ± 5,39
	Mcc	0,8309	0,9529	0,9229
Wavelets	Acc	92,88 ± 5,49	99,19 ± 0,59	98,76 ± 1,22
	Tp	91,82 ± 10,73	98,43 ± 1,20	98,13 ± 1,43
	Tn	93,94 ± 7,64	99,96 ± 0,10	99,39 ± 2,22
	Mcc	0,8578	0,9840	0,9753
Gabor	Acc	93,78 ± 4,29	99,21 ± 0,61	98,26 ± 2,46
	Tp	93,14 ± 7,64	98,99 ± 0,99	98,39 ± 1,80
	Tn	94,41 ± 5,77	99,44 ± 1,21	98,12 ± 3,95
	Mcc	0,8756	0,9843	0,9651
Gabor BP	Acc	94,30 ± 4,72	99,24 ± 0,63	98,71 ± 1,31
	Tp	93,82 ± 8,47	98,48 ± 1,26	98,47 ± 1,85
	Tn	94,78 ± 6,22	100,00 ± 0,00	98,95 ± 2,02
	Mcc	0,8860	0,9849	0,9742

Tabelle 5.10: Prozentuale Evaluierungsergebnisse der untersuchten Merkmale bei Berechnung auf das gesamte Bild. Neben der Erkennungsrate (Acc), sind zudem die True Positiv Rate (Tp), die True Negative Rate (Tn) und der Matthews Korrelationskoeffizient (Mcc) aufgeführt.

5.5 Evaluierung der Segmentierung

Zur Untersuchung der in Abschnitt 4.3 vorgestellten Segmentierung erfolgt eine Unterteilung des Bildes in 8×8 Bereiche, jeweils bestehend aus 64×64 Pixel und einer Überlappung von 27 Pixel. Die Merkmale wurden aus acht horizontal angeordneten Segmenten im Bereich der Bildmitte extrahiert und zu einem Merkmalsvektor zusammengefasst, siehe auch Abb. 4.13. In Tabelle 5.11 sind die Erkennungsraten bei Verwendung von HOG, HGM, Wavelets, Gabor- und Gabor Bandpassfiltern zusammengefasst. Zudem findet sich dort auch das Evaluierungsergebnis bei Verwendung der Roser-Merkmalen, welche jedoch auf einer wie in der ursprünglichen Arbeit beschriebenen Segmentierung basieren, d.h. die Merkmale wurden anhand des gesamten Bildes sowie anhand 3×4 nicht überlappender Bereiche bestimmt.

Tag-Szenen

Bei Tag-Szenen führte die Segmentierung bei allen Merkmalen zu einer Verbesserung der Erkennungsraten sowie der MCC. Dabei konnten mit allen Merkmalen, außer den Roser-Features ($92,20 \pm 5,60\%$), Genauigkeiten im Bereich von ca. 95 % erzielt werden. Die Wavelets lieferten mit drei Dekompositionsstufen ein Ergebnis von $95,13 \pm 5,60\%$, die Gabor Filter bei Verwendung eines Frequenzbands und einer Überlappung bei 3 dB $94,79 \pm 2,29\%$. Die beste Erkennungsrate von $95,35 \pm 2,88\%$ erzielten die Gabor Bandpass Filter bei Verwendung von neun Frequenzbändern, einem Mittenfrequenzabstand von einer Oktave und einer Überlappung bei 3 dB, auch die MCC weist dabei den höchsten Wert von 0,9071 auf. Interessant ist auch, dass die Merkmale aus dem Ortsbereich durch die Verwendung der Segmentierung zu den Wavelets und den spektralbasierten Merkmalen aufschließen konnten. Die HGM-Merkmale erzielten mit 96 Bins eine Erkennungsrate von $94,59 \pm 2,67\%$ und die HOG-Merkmale bei Verwendung von 20 Bins sogar $95,21 \pm 2,89\%$. Die Roser-Features konnten sich durch die Segmentierung zwar verbessern, liefern jedoch mit der in [112] vorgestellten Segmentierung das schwächste Ergebnis von $92,59 \pm 5,60\%$ und einer MCC von 0,8918. Die Verwendung von Segmenten im Bereich des Horizonts scheint daher hier zu einer stärkeren Verbesserung zu führen.

Nacht-Szenen

Bei Nacht-Szenen mit eingeschaltetem Fernlicht zeigt sich ein differenzierteres Ergebnis. Bei den HOG-Merkmalen führt die Segmentierung zu einer deutlichen Verbesserung von $98,99 \pm 0,68\%$ bei Verwendung von 30 Bins, bei den Roser-Merkmalen zu einer leichten Verbesserung von $98,41 \pm 2,37\%$ und bei den HGM-Merkmalen zu einem ähnlichen Ergebnis von $98,24 \pm 1,95\%$ bei Verwendung von acht Bins. Bei den Wavelets (eine Dekompositionsstufe), den Gabor- (drei Frequenzbänder) und Gabor Bandpass Filter (acht Frequenzbänder) verschlechterte sich hingegen das Ergebnis auf $97,91 \pm 1,28\%$, $97,77 \pm 1,67\%$ bzw. $97,72 \pm 1,82\%$.

Bei Nacht ohne eingeschaltetem Fernlicht zeigt sich ein ähnliches Ergebnis. Die HOG-Merkmale konnten sich bei Verwendung von 10 Bins auf eine Erkennungsrate von $97,31 \pm 4,47\%$ und die Roser-Merkmale auf eine Erkennungsrate von $96,83 \pm 6,73\%$

steigern. Die HGM-Merkmale (32 Bins) und vor allem die Wavelets (eine Dekompositionsstufe), Gabor- (vier Frequenzbänder) und Gabor Bandpass Filter (drei Frequenzbänder) lieferten ein deutlich schwächeres Ergebnis von $94,41 \pm 8,74 \%$, $94,41 \pm 4,75 \%$, $94,29 \pm 7,55 \%$ und $94,41 \pm 8,93 \%$.

		Tag	Nacht (mit Fernlicht)	Nacht (ohne Fernlicht)
HOG	Acc	$95,21 \pm 2,89$	$98,99 \pm 0,68$	$97,31 \pm 4,47$
	Tp	$95,02 \pm 4,38$	$99,04 \pm 0,92$	$98,24 \pm 1,59$
	Tn	$95,40 \pm 3,75$	$98,93 \pm 1,64$	$96,37 \pm 8,46$
	Mcc	0,9042	0,9797	0,9463
HGM	Acc	$94,59 \pm 2,67$	$98,24 \pm 1,95$	$94,41 \pm 8,74$
	Tp	$94,90 \pm 2,59$	$98,14 \pm 1,21$	$95,44 \pm 6,75$
	Tn	$94,28 \pm 3,87$	$98,33 \pm 2,85$	$93,39 \pm 16,56$
	Mcc	0,8918	0,9647	0,8885
Roser	Acc	$92,20 \pm 5,60$	$98,41 \pm 2,37$	$96,83 \pm 6,73$
	Tp	$95,89 \pm 6,17$	$99,68 \pm 0,48$	$99,52 \pm 1,05$
	Tn	$88,52 \pm 11,58$	$97,14 \pm 4,83$	$94,14 \pm 13,28$
	Mcc	0,8464	0,9685	0,9380
Wavelets	Acc	$95,13 \pm 2,99$	$97,91 \pm 1,28$	$94,41 \pm 4,75$
	Tp	$95,09 \pm 5,13$	$97,30 \pm 1,37$	$94,46 \pm 6,54$
	Tn	$95,18 \pm 5,59$	$98,52 \pm 2,36$	$94,36 \pm 9,54$
	Mcc	0,9027	0,9583	0,8882
Gabor	Acc	$94,79 \pm 2,29$	$97,77 \pm 1,67$	$94,29 \pm 7,55$
	Tp	$94,60 \pm 4,47$	$97,29 \pm 1,21$	$95,70 \pm 4,18$
	Tn	$94,98 \pm 4,19$	$98,25 \pm 2,96$	$92,88 \pm 14,88$
	Mcc	0,8958	0,9554	0,8862
Gabor BP	Acc	$95,35 \pm 2,88$	$97,72 \pm 1,82$	$94,41 \pm 8,93$
	Tp	$94,87 \pm 4,58$	$97,39 \pm 1,15$	$95,75 \pm 3,33$
	Tn	$95,84 \pm 5,04$	$98,05 \pm 3,39$	$93,03 \pm 17,42$
	Mcc	0,9071	0,9544	0,8881

Tabelle 5.11: Prozentuale Evaluierungsergebnisse bei Verwendung einer einfachen Segmentierung. Neben der Erkennungsrate (Acc), sind zudem die True Positiv Rate (Tp), die True Negative Rate (Tn) und der Matthews Korrelationskoeffizient (Mcc) aufgeführt.

5.6 Zusammenfassung der Evaluierungsergebnisse

Gabor Filterbanken lassen sich über die Anzahl der Frequenzbänder, die Anzahl der Orientierungen pro Frequenzband, den Mittenfrequenzabstand der Frequenzbänder sowie über die gewünschte Amplitude bei der Überlappung angrenzender Filter parametrisieren. Bei der Evaluierung hat sich gezeigt, dass die Anzahl der Frequenzbänder sowie die Überlappung den größten Einfluss auf die Erkennungsraten haben, wobei die Verwendung der 3 dB Eckfrequenz zu besseren Ergebnissen führte. Die restlichen Parameter haben nur einen geringfügigen Einfluss. Das Zusammenfassen der Gabor Filter eines Frequenzbands zu einem Bandpass führt nochmals zu einer Verbesserung, wie z.B. bei der Filterbank-Konfiguration G_{260} mit einer Oktave Mittenfrequenzabstand und 3 dB Eckfrequenz von $93,78 \pm 4,25 \%$, $99,21 \pm 0,61 \%$ und $98,26 \pm 2,46 \%$ auf $94,30 \pm 4,72 \%$, $99,24 \pm 0,63 \%$ und $98,71 \pm 1,31 \%$ bei Tag, Nacht mit bzw. ohne Fernlicht. Die Gabor und Gabor Bandpass Filterbanken wurden anschließend mit den bekannten Methoden der Merkmalsextraktion HOG-, HGM-, GLCM-, Roser-Merkmale und Wavelet-Koeffizienten verglichen. Bei Berechnung der Merkmale auf das gesamte Bild, erzielte der Gabor Bandpass Filter die höchsten Erkennungsraten, wobei die Gabor Filterbank und die Wavelet-Koeffizienten jedoch ähnlich hohe Werte erzielen konnten. Die Merkmale aus dem Ortsbereich schnitten hierbei deutlich schwächer ab, lediglich die HGM-Merkmale konnten bei Tag annähernd gute Erkennungsraten erreichen. Die Verwendung einer einfachen Segmentierung, bei welcher die Merkmale aus acht am Horizont angeordnete, stark überlappende Bereiche extrahiert wurden, lieferte bei Tag Verbesserungen von 1,05 % bei Gabor Bandpass Filter und bis zu 4,32 % bei HOG-Merkmalen, wodurch die untersuchten Verfahren HOG, HGM, Wavelets, Gabor und Gabor Bandpassfilter alle Erkennungsraten von ca. 95 % erzielten. Das beste Ergebnis lieferte wiederum der Gabor Bandpass Filter, wobei der Unterschied zu dem zweithöchsten Ergebnis mittels HOG-Merkmalen jedoch lediglich 0,14 % betrug. Bei Nacht mit sowie ohne Fernlicht führte die Segmentierung nur bei den HOG-Merkmalen zu einer Verbesserung, bei den restlichen Verfahren ergab sich hingegen eine deutliche Reduzierung der Erkennungsraten. Die Verbesserung der HOG-Merkmale bei Nacht reichte jedoch nicht an die sehr hohen Erkennungsraten der Gabor- und Gabor Bandpass Filterbanken sowie der Wavelet-Koeffizienten bei der Berechnung auf das gesamte Bild heran. Darüber hinaus wurden die Roser-Merkmale basierend auf der ursprünglich vorgestellten Segmentierung, bei welcher die Merkmale anhand des gesamten Bildes sowie anhand 3×4 nicht überlappende Bereiche berechnet werden, untersucht. Dadurch konnte zwar ebenfalls eine Verbesserung erzielt werden, diese fiel jedoch im Vergleich zur vorgestellten Segmentierung deutlich geringer aus. Daraus wird ersichtlich, dass vor allem bei Tag die Verwendung von Bildbereichen, welche mit einer hohen Wahrscheinlichkeit weit entfernte Objekte enthalten, vorteilhaft für die Unterscheidung von Nebel und nebelfreien Szenen sind.

Insgesamt erzielten die Gabor Bandpass Filterbanken die besten Ergebnisse, bei Tag mit und bei Nacht ohne die Verwendung einer Segmentierung. Im Folgenden wird daher das Klassifizierungsvermögen der Gabor Bandpass Filter bei Tag, Nacht mit und ohne Fernlicht genauer betrachtet und gezeigt, in welchen Situationen Fehldetektionen auftraten und wann eine korrekte Zuordnung durchgeführt werden konnte.

Tag-Szenen

Fehldetektionen bei Nebel (False Negatives), d.h. Bilder mit Nebel-Situationen wurden als nebelfrei klassifiziert, traten hauptsächlich bei der Unterfahung von Brücken auf. Dabei wurden mehrere aufeinanderfolgende Bilder (10–30) falsch klassifiziert. Durch die Segmentierung konnte die Häufigkeit und Dauer der False Negatives verringert werden. Insgesamt gab es 37 Unterfahrungen von Brücken, bei Verwendung einer Merkmalsextraktion auf das gesamte Bild traten in 34 Fällen Fehlklassifikationen auf, bei Verwendung einer Segmentierung waren es lediglich 25. Darüber hinaus konnte beobachtet werden, dass durch die Segmentierung der Zeitpunkt der Fehldetektion nach vorne verschoben wurde, d.h. der Fehler trat auf, als die Brücke noch weiter entfernt war und während der eigentlichen Unterfahung wurde die Situation korrekt klassifiziert. Dies ist darauf zurückzuführen, dass die scharfen Kanten, welche durch die Brücke im Bild hervorgerufen werden, bei der eigentlichen Unterfahung durch die Segmentierung nicht mehr berücksichtigt werden, da sie außerhalb des untersuchten Bildbereichs liegen. Entfernte Brücken, welche sich im Bereich des Horizonts befinden, wirken sich dennoch negativ aus. Situationen, welche ebenfalls zu mehreren aufeinanderfolgenden Fehldetektionen führten, jedoch seltener falsch klassifiziert wurden, waren Überholvorgänge von Lastwägen, bei denen zumindest noch ein vorausfahendes, ebenfalls überholendes Fahrzeug vorhanden war oder weitere Elemente im Bild, wie z.B. Verkehrsschilder, mehrere entgegenkommende Fahrzeuge oder Bäume in der Nähe des Straßenrands hohe Kontraste im Bild erzeugten. Vereinzelt Fehldetektionen, welche in nur wenigen aufeinanderfolgenden Bildern auftraten (1–5), konnten bei Kombinationen aus einer Vielzahl entgegenkommende Fahrzeuge mit blendenden Fahrzeugscheinwerfern, ausgeprägter Vegetation am Straßenrand und dem Vorhandensein mehrerer großer Verkehrsschilder beobachtet werden. In Abb. 5.18 sind einige dieser Situationen dargestellt, in Abb. 5.19 finden sich zudem korrekt klassifizierte Nebelsituationen (True Positives). Wie dort zu sehen ist, gibt es zu jeder beschriebenen False Negative-Situation auch ein Beispiel, in der die korrespondierende Situation richtig klassifiziert wurde. Dies war vor allem dann möglich, wenn eine deutliche Ausprägung des Nebels mit geringeren Sichtweiten vorlag.

False Positives, d.h. Detektion von Nebel, wenn keiner vorhanden war, traten vor allem in Bildern mit leichtem Nebel auf. Dabei waren zwischen 1–59 aufeinanderfolgende Fehlklassifikationen zu beobachten. Vereinzelt führte auch Nebel neben der Fahrbahn zu Fehlklassifikationen. Bei klaren Sichtverhältnissen konnten False Positives nur in überbelichteten Bildern beobachtet werden, welche auf die adaptive, auf Bildinformationen basierenden Kamera-Einstellungen zurückzuführen sind. Diese traten sporadisch und für eine kurze Dauer von 1–6 aufeinanderfolgenden Bilder auf. In Abb. 5.20 sind einige Beispiele für False Positives und in Abb. 5.21 für True Negatives, d.h. korrekt erkannte nebelfreie Szenen, dargestellt. Dabei ist wiederum zu erkennen, dass die Klassifizierungsprozedur in unterschiedlichen Bedingungen, wie z.B. bei Vorhandensein von Schilderbrücken, Vegetation neben der Fahrbahn, großer Verkehrsschilder, Brücken, in kontrastarmen Bildern oder bei leichtem Nebel, eine korrekte Zuordnung vornimmt.

5. Evaluierung



Abbildung 5.18: Beispiele für False Negatives bei Tag. Diese traten vor allem bei der Unterföhrung von Brücken und bei Überholvorgängen von Lastkraftwägen auf.



Abbildung 5.19: Beispiele für True Positives bei Tag.

5.6. Zusammenfassung der Evaluierungsergebnisse



Abbildung 5.20: Beispiele für False Positives bei Tag. Diese traten vor allem bei leichtem Nebel und sporadisch bei überbelichteten Bildern auf.



Abbildung 5.21: Beispiele für True Negatives bei Tag

Nacht-Szenen mit Fernlicht

In Aufnahmen bei Nacht mit eingeschaltetem Fernlicht traten nur selten Fehldetektionen auf. False Negatives hatten eine Auftrittswahrscheinlichkeit von 1,52 % und konnten beobachtet werden, wenn laut Fahrzeugdaten das Fernlicht eingeschaltet war, im Bild dieses jedoch noch nicht oder nicht mehr als eingeschaltet erschien, wie z.B. in Abb. 5.22 zu sehen. Die Verfahren unterschieden sich dann darin, wie gut sie diese Situationen kompensieren konnten. In Abb. 5.23 sind einige True Positives dargestellt. Wie dort zu sehen ist, sind auch bei Nacht Variationen in den Aufnahmen vorhanden, wie z.B. Wechselverkehrszeichen, externe Lichtquellen sowie vereinzelte und mehrere kleine sowie größere Verkehrsschilder. Die hohen Erkennungsraten liegen jedoch vor allem daran, dass diese deutlich geringer als bei Tag ausfallen. So ist z.B. im Bild unten rechts eine Brücke vorhanden, welche bei Tag einen deutlich größeren Unterschied in Form von höheren Kontrastwerten hervorrufen würde. Das zweite Bild von rechts in der letzten Zeile zeigt zudem ein Beispiel, in welchem das Verfahren eine Situation, in welcher das Fernlicht sich noch nicht vollständig aufgebaut hat, korrekt klassifizieren konnte.



Abbildung 5.22: Beispiele für False Negatives bei Nacht mit Fernlicht.



Abbildung 5.23: Beispiele für True Positives bei Nacht mit Fernlicht.

Bei Verwendung einer Gabor Bandpass Filterbank traten keine False Positives auf, weshalb hier die fälschlicherweise als Nebel klassifizierten Fahrscenen bei Verwendung einer Gabor Filterbank betrachtet werden. Mit einer Auftrittswahrscheinlichkeit von 0,56 % traten diese Situationen ebenfalls sehr selten auf. Die ersten beiden Bilder von links in Abb. 5.24 zeigen die einzigen zwei aufgetretenen Fehldetektionen eines guten Trainings-Datensatzes⁴, welche sich über fünf bzw. acht aufeinanderfolgende Bilder erstreckten. Die drei weiteren Bilder konnten durch die Verwendung eines weniger gut geeigneten Trainings-Datensatzes gefunden werden. Bei den False Positives ist zu erkennen, dass leichter Nebel vorhanden war, und es scheinbar durch die Reflexion der Verkehrszeichen zu einer Verunschärfung kam, die den Klassifikator zu einer Fehlentscheidung führten. In Abb. 5.25 sind wiederum, analog zu Situationen mit Nebel, unterschiedliche Situationen mit korrekt als nebelfrei klassifizierten Bildern dargestellt (True Negatives).



Abbildung 5.24: Beispiele für False Positives bei Nacht mit Fernlicht.



Abbildung 5.25: Beispiele für True Negatives bei Nacht mit Fernlicht.

⁴Mit einem guten Trainings-Datensatz ist hier ein solcher gemeint, der bei den Testdaten zu wenig Fehlern führt.

Nacht-Szenen ohne Fernlicht

Aufnahmen bei Nacht ohne eingeschaltetem Fernlicht wurden mit einer Erkennungsrate von 98,71 % korrekt klassifiziert. Der häufigste Grund für fälschlicherweise als nebelfrei klassifizierte Fahrscenen (False Negatives, mit einer Auftrittswahrscheinlichkeit von 1,53 %) waren horizontale Artefakte in dunklen Bildbereichen. Diese werden erst bei Betrachtung des vorgefilterten Bilds ersichtlich. In Abb. 5.26 sind hierzu zwei Beispiele, jeweils mit dem direkt darauffolgenden Bild ohne Artefakte und den korrespondierenden vorgefilterten Bildern dargestellt. Diese Phänomene traten vereinzelt und für eine kurze Dauer auf, sodass sie z.B. durch eine zeitliche Filterung einfach kompensiert werden können. In Abb. 5.27 sind wiederum Fahr Situationen mit True Positives dargestellt. Wie dort zu sehen ist konnte die Klassifizierungsprozedur verschiedene Situationen, wie z.B. Verkehrsschilder, Wechselverkehrszeichen, vorausfahrende oder entgegenkommende Fahrzeuge mit und ohne Blendung, korrekt zuordnen.

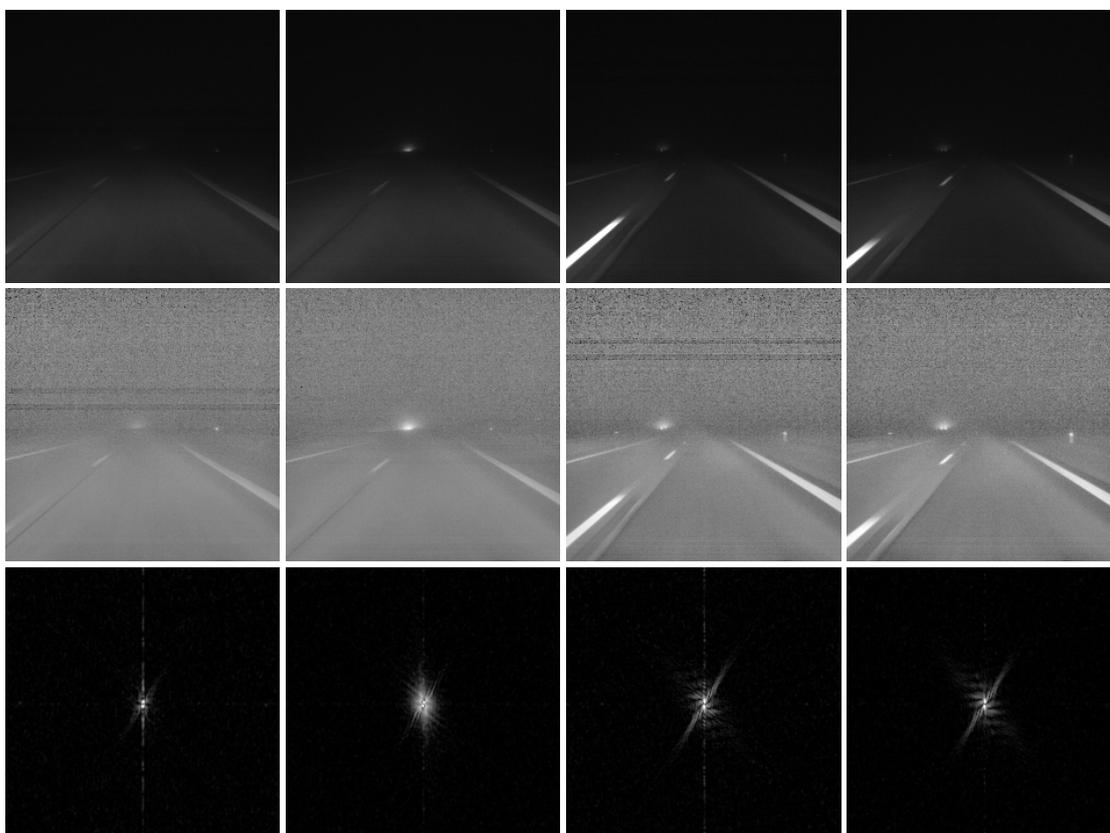


Abbildung 5.26: Beispiele für False Negatives bei Nacht ohne Fernlicht. Es sind jeweils zwei aufeinanderfolgende Bilder mit dem Originalbild in der ersten, dem Ergebnis der Vorfilterung in der zweiten und dem Spektrum in der dritten Zeile dargestellt, wobei das erste horizontale Artefakte aufweist welche zu einer Fehlklassifizierung führten.

Fälschlicherweise als Nebel klassifizierte Bilder (False Positives) waren mit einer Auftrittswahrscheinlichkeit von 1,05 % zu beobachten. Sie traten sporadisch und ver-



Abbildung 5.27: Beispiele für True Positives bei Nacht ohne Fernlicht.

einzelnt in maximal fünf aufeinanderfolgenden Bildern auf. Die häufigste Ursache für Fehldetektionen war leichter Nebel in Kombination mit sehr dunklen, kontrastarmen Fahrsituationen. Des Weiteren konnten Fehldetektionen ebenfalls bei leichtem Nebel sowie diffusem Licht durch Beleuchtungen entgegenkommender oder vorausfahrender Fahrzeuge beobachtet werden, siehe Abb. 5.28. In Abb. 5.29 sind wiederum Situationen dargestellt, in denen eine korrekte Klassifizierung erfolgte.



Abbildung 5.28: Beispiele für False Positives bei Nacht ohne Fernlicht. Diese traten bei leichtem Nebel und diffusen Lichtquellen oder ebenfalls bei leichtem Nebel und sehr kontrastarmen Bildern auf.

5. Evaluierung



Abbildung 5.29: Beispiele für True Negatives bei Nacht ohne Fernlicht.

Zusammenfassung und Ausblick

Einleitend wurde die Motivation dieser Arbeit, die Lokale Gefahrenwarnung, vorgestellt. Diese verfolgt den Ansatz, vorhandene Daten aus der Infrastruktur mit Daten aus dem Verkehrsnetz zu fusionieren, um Verkehrsteilnehmer gezielt auf Gefahrensituationen aufmerksam zu machen. Da zu einer sowohl räumlich als auch zeitlich präzisen Warnung vor eingeschränkten Sichtverhältnissen die Daten aus der Infrastruktur nicht ausreichend sind, wurde ein Verfahren entwickelt, welches Fahrzeuge befähigt als zusätzliche Informationsquelle zu fungieren. Ein wichtiges Kriterium war dabei, keine zusätzliche Sensorik zu benötigen. Daher wurde der Ansatz verfolgt das vorhandene Kamerasystem zu verwenden, um sowohl bei Tag als auch bei Nacht zwischen Nebel und nebfreien Situationen unterscheiden zu können. Darüber hinaus wurden weitere potentielle Einsatzgebiete einer kamerabasierten Nebeldetektion im Fahrzeug vorgestellt sowie die Ziele dieser Arbeit zusammengefasst.

Bei der Entwicklung eines bildbasierten Verfahrens zur Nebeldetektion drängt sich die Frage auf, wie das Phänomen Nebel in der Meteorologie definiert ist und welche Methoden und Verfahren zur Messung herangezogen werden. Dabei kommt der Sichtweite zur Quantifizierung der Nebelausprägung eine zentrale Rolle zu. Zum besseren Verständnis der optischen Effekte erfolgte daher, nach einer kurzen Einführung in die Radiometrie und Photometrie, eine Erläuterung der Entstehung von Sichtbeeinträchtigungen durch Nebel sowie deren Ursachen anhand der atmosphärischen Streuung. Von besonderer Bedeutung ist dabei die von Koschmieder formulierte Airlight Formel, welche sowohl die Dämpfung des Lichts aufgrund von Streuung, als auch dessen Anhebung durch eine diffuse Umgebungsbeleuchtung berücksichtigt. Ist der intrinsische Kontrast eines Objekts und dessen Entfernung bekannt, so lässt sich anhand des von einem Beobachter wahrgenommenen Kontrasts der Extinktionskoeffizient und damit die Sichtweite schätzen. Während auf diese Weise die in der Meteorologie weit verbreitete visuelle Schätzung ermöglicht wird, bestimmen instrumentelle Messgeräte wie das Transmissometer oder Scatterometer die Sichtweite über die Messung der Dämpfung entlang einer bestimmten Strecke bzw. der Streuung innerhalb eines Volumens. Darüber hinaus ist zu beachten, den Begriff Nebel entsprechend des vorliegenden Anwendungsfalles zu spezifizieren. In der Meteorologie wird Nebel über eine Sichtweite von weniger als 1.000 m definiert. Da im Straßenverkehr eine Gefährdung der Verkehrsteilnehmer erst bei deutlich geringeren Sichtweiten vorliegt, wurde für das Anwendungsgebiet Lokale Gefahrenwarnung

eine Abgrenzung zwischen klaren und eingeschränkten Sichtverhältnissen bei 100 m eingeführt.

Das anschließende Kapitel 3 stellte bekannte Verfahren zur bildbasierten Nebeldetektion bzw. Sichtweitenschätzung vor. Die meisten Verfahren sind für den Einsatz bei Tag vorgesehen und führen eine Sichtweitenschätzung anhand von Fahrbahnmerkmalen durch. Busch und Debers ermitteln hierzu die maximale Entfernung, in welcher Fahrbahnmerkmale eine bestimmte Kontrastschwelle überschreiten, Pomerlau untersucht die entfernungsabhängige Kontrastabschwächung, Bronte *et al.* bestimmen mittels Segmentierung die maximale Entfernung, in welcher die Fahrbahn sichtbar ist und Hautière *et al.* schätzen den Extinktionskoeffizienten anhand des Intensitätsverlaufs der Fahrbahn. Darüber hinaus wurde, ebenfalls von Hautière *et al.*, ein streokamerabasierter Ansatz vorgestellt, welcher Disparitätswerte von Fahrbahnmerkmalen, welche eine bestimmte Kontrastschwelle überschreiten, zur Sichtweitenschätzung heranzieht. Roser und Mosemann verwenden hingegen eine Klassifizierungsprozedur, um Bilder allgemeinen unterschiedlichen Wetter-Kategorien zuzuordnen und zeigten hohe Erkennungsraten bei der Unterscheidung von leichtem Regen, Regen und klaren Wetterbedingungen. Nebeldetektion bei Nacht wurde bisher nur von Gallen *et al.* betrachtet, wobei eine Unterteilung in zwei Szenarien durchgeführt wurde. Sind außer den eigenen Fahrzeugscheinwerfern keine anderen Lichtquellen im Kamerabild sichtbar, so wird anhand deren Lichtausbreitung mittels Template Matching die Sichtweite geschätzt. Bei Vorhandensein externer Lichtquellen, wie z.B. Straßenbeleuchtungen, wird hingegen die Lichtausbreitung entlang dieser zur Unterscheidung von Nebel und nebelfreien Situationen untersucht. Die hier vorgestellte Arbeit unterscheidet sich von den bisherigen insofern, als dass anstelle einer expliziten Sichtweitenschätzung eine Klassifizierungsprozedur zur Nebeldetektion verwendet wird. Im Gegensatz zur Arbeit von Roser und Mosemann, welche in Anspruch nimmt, beliebige Wetterbedingungen unterscheiden zu können, lag der Fokus dieser Arbeit darauf, explizit Nebel von nebelfreien Fahrsituationen sowohl bei Tag als auch bei Nacht unterscheiden zu können. Dadurch kamen andere Merkmale sowie ein verändertes Klassifizierungsverfahren zum Einsatz.

In Kapitel 4 wurde die entwickelte Klassifizierungsprozedur zur Unterscheidung von Nebel und nebelfreien Fahrszenen vorgestellt, welche sich im Wesentlichen aus einer Vorverarbeitung, einer Merkmalsextraktion, einer zweistufigen Merkmalsreduktion und einem Klassifikator zusammensetzt. Die Vorverarbeitung führt eine logarithmische Transformation, Mittelwertbefreiung und Kontrastnormierung der ursprünglichen Bilddaten durch und dient vor allem zum Ausgleich unterschiedlicher Beleuchtungsbedingungen. Als Merkmal dient das Leistungsspektrum, welches mittels Gabor- bzw. Gabor Bandpass Filterbanken abgetastet und anschließend einer Hauptkomponentenanalyse unterzogen wird. Zur Klassentrennung wird ein linearer Klassifikator verwendet, wobei der Gewichtsvektor mittels Fisher-LDA und der Schwellwert über den Schnittpunkt der Normalverteilungen der Entscheidungsvariablen bestimmt wird. Da sich Nebel nicht homogen auf den gesamten Bildbereich auswirkt, werden die Merkmale anhand acht stark überlappender Bereiche entlang des Horizonts berechnet und zu einem Merkmalsvektor zusammengefasst. Darüber hinaus wurden in diesem Kapitel die bekannten Bild Deskriptoren HOG, HGM, GLCM sowie die Wavelet-Koeffizienten vorgestellt, welche ebenfalls die Modellierung einer Verunschärfung und Kontrastabnahme ermöglichen.

Kapitel 5 stellt zunächst den verwendeten Sensor sowie die zur Evaluierung verwendete Datengrundlage und Methodik vor. Anschließend erfolgt eine Untersuchung zur Parametrisierung der Gabor Filterbanken. Dabei hat sich gezeigt, dass die Anzahl der Frequenzbänder sowie die Wahl der Position, an der sich angrenzende Filter überlappen, den größten Einfluss auf das Ergebnis haben. Die Anzahl der Filterbanken pro Frequenzband und der Mittenfrequenzabstand spielen dabei eine untergeordnete Rolle. Die hierauf folgende Untersuchung der Bandpass Filter hat gezeigt, dass mit Gabor Bandpass Filtern höhere Erkennungsraten als mit Ring Filterbanken erzielt werden. Schließlich wurde ein Vergleich der HOG-, HGM-, GLCM-, Wavelet-, Gabor- sowie Gabor Bandpass Deskriptoren vorgenommen. Dabei erzielten die Gabor Bandpass Filterbanken, dicht gefolgt von den Wavelet-Koeffizienten und Gabor Filterbanken, die höchsten Erkennungsraten. Abschließend wurde der Einfluss der Segmentierung untersucht. Während die Roser-Merkmale mit ihrer ursprünglichen Segmentierung eine leichte Verbesserung hinsichtlich der Erkennungsrate bei Tag aufwiesen, erzielten die HOG- und HGM-Merkmale, Wavelet-Koeffizienten sowie die Gabor- und Gabor Bandpass Filterbanken deutlichere Steigerungen. Die höchste Erkennungsrate bei Tag erzielten wiederum die Gabor Bandpass Filter, jedoch waren die Unterschiede zu den restlichen Merkmalen sehr gering. Auffällig war zudem, dass sich außer bei den HOG-Merkmalen die Ergebnisse bei Nacht durch die Segmentierung verschlechtert hatten. Eine detaillierte Betrachtung der Ergebnisse der Gabor Bandpass Filterbanken in Abschnitt 5.6 hat gezeigt, dass bei Tag vor allem Brücken und Überholvorgänge in Kombination mit einem vorausfahrenden Fahrzeug zu Fehldetektionen bei Nebel führen. Bei nebelfreien Szenen sind vor allem leichter Nebel und sporadisch überbelichtete Bilder Ursachen für ein falsches Klassifizierungsergebnis. Insgesamt gelang es jedoch, eine Vielzahl unterschiedlicher Fahrsituationen korrekt zuzuordnen. Bei Nacht wurden nochmals deutlich höhere Erkennungsraten erzielt, was vermutlich an der geringeren Variationen in den Bildern lag. Während z.B. eine Brücke bei Tag auch in einer Nebel-Situation deutlich höhere Frequenzen erzeugt, wirkt sich diese bei Nacht kaum auf das Spektrum aus. Bei Nebel und eingeschaltetem Fernlicht war als Ursache für Fehldetektionen zu beobachten, dass obwohl die Fahrzeugdaten ein eingeschaltetes Fernlicht signalisieren, dieses im Kamerabild noch nicht oder nicht mehr sichtbar war. Fehldetektionen bei nebelfreien Fahrszenen und eingeschaltetem Fernlicht traten hingegen nicht auf. War kein Fernlicht eingeschaltet, so waren sporadisch auftretende, horizontale Artefakte, welche wohl auf eine fehlerhafte Abbildung des Sensors zurückzuführen sind und diffuse Lichtquellen bei leichtem Nebel für Fehldetektionen bei Nebel bzw. nebelfreien Fahrszenen verantwortlich.

Zusammenfassend konnte somit gezeigt werden, dass durch Verwendung einer Gabor Bandpass Filterbank sowohl bei Tag als auch bei Nacht mit und ohne eingeschaltetem Fernlicht eine Unterscheidung von Nebel und nebelfreien Fahrsituationen mit hohen Erkennungsraten möglich ist, wobei lediglich eine bereits in Serienfahrzeugen verfügbare Grauwertkamera benötigt wird. Interessant zu untersuchen wäre an dieser Stelle noch, ob durch eine aufwändigere Segmentierung die Anzahl an Fehlklassifikationen, insbesondere bei Tag, verringert werden kann. Anstatt die Merkmale der einzelnen Blöcke zu einem großen Merkmalsvektor zusammenzufassen, könnte z.B. für jeden Block ein Klassifikator trainiert und die Ergebnisse durch einen einfachen Mehrheitsentscheid fusioniert werden. Da anhand der Trainingsdaten die Klassifizierungsgenauigkeit der

einzelnen Klassifikatoren bekannt ist, besteht zudem die Möglichkeit, Klassifikatoren mit höheren Erkennungsraten eine höhere Gewichtung zu verleihen. Hierzu ließe sich ein zur finalen Entscheidung verwendeter Wert um die jeweilige Klassifizierungsgenauigkeit, abhängig vom Klassifizierungsergebnis, inkrementieren bzw. dekrementieren. Das Vorzeichen des so gewonnenen Entscheidungswertes kann dann zur Klassentrennung herangezogen werden. Eine weitere Verfeinerung ermöglicht die intrinsische Sicherheit eines Klassifikators. Je weiter die von einem Klassifikator ermittelte Entscheidungsvariable von dessen Schwellwert entfernt ist, desto sicherer ist sich dieser über die getroffene Entscheidung. Somit ließe sich eine Art Naiver Bayes'scher Klassifikator konstruieren, welcher anhand der jeweiligen vorzeichenbehafteten Entfernung der Entscheidungsvariable vom Schwellwert sowie anhand der jeweiligen Klassifizierungsgenauigkeiten eine Fusionierung der einzelnen Entscheidungen durchführt.

Während diese Arbeit auf die Verwendung einer Grauwertkamera beschränkt ist, halten in heutigen Fahrzeugen immer mehr Farbkameras Einzug. Roser und Moosmann berichteten bereits in [112] von den Vorteilen beim Einsatz von Farbinformationen zur Klassifizierung von Regen-Situationen. Da bei Nebel im Vergleich zu nebelfreien Fahrsituationen eine deutlich geringere Farbvielfalt zu erwarten ist, scheint ein Einsatz auch hier vielversprechend. Hierzu könnten z.B. Farbinformationen in Form von Histogrammen mit in die Klassifizierungsprozedur aufgenommen werden, oder der vorgestellte Ansatz zur Merkmalsextraktion und Merkmalsreduktion auf einzelne Farbkanäle angewandt werden.

Die Verwendung einer Klassifizierungsprozedur ist dabei ausreichend für Funktionen wie die Lokale Gefahrenwarnung vor eingeschränkten Sichtverhältnissen oder zur Strategieanpassung des Fernlichtassistenten. Für Funktionen wie die adaptive Rückleuchtenregelung oder eine Kombination von Funktionen mit unterschiedlichen Entscheidungsschwellen, d.h. einer Spezifikation von Nebel-Situationen unter 200 und unter 100 m, wäre ausblickend betrachtet eine zusätzliche, nachgeschaltete Sichtweitenschätzung wünschenswert. Hierzu könnte z.B. der Kontrastverlauf entlang von Fahrbahnmarkierungen, welche heute bereits recht zuverlässig vor allem auf Autobahnen und Bundesstraßen detektiert werden können, untersucht werden. Ist die intrinsische, entfernungsabhängige Kontrastabschwächung des Kamerasystems aufgrund der Abbildungseigenschaften bekannt, so wäre es interessant zu untersuchen, ob bei Tag über einen bestimmten Bereich vor dem Fahrzeug mit Hilfe der Airlight Formel approximativ eine zuverlässige Sichtweitenschätzung möglich ist. Hierzu könnte die Kontrastabschwächung unterschiedlich weit entfernte Fahrbahn-Fahrspur-Übergänge bezüglich eines festen Referenzpunktes direkt vor dem Fahrzeug herangezogen werden, um z.B. wie in Kapitel 2 beschrieben, einen mittleren Extinktionskoeffizienten zu bestimmen und mit diesem die Sichtweite zu schätzen. Dabei ist jedoch zu beachten Objekte, welche nicht zur Fahrbahn gehören, wie z.B. andere Fahrzeuge, aus der Sichtweitenschätzung auszuschließen. Hierzu kann wiederum auf bekannte Verfahren bei der Fahrspurdetektion oder auf die Ergebnisse einer Fahrzeugdetektion zurückgegriffen werden.

Literatur

- [1] R. Adams und L. Bischof. „Seeded Region Growing“. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 16.6 (Juni 1994), S. 641–647.
- [2] C. D. Ahrens. *Meteorology Today: An Introduction to Weather, Climate, and the Environment*. 7. Aufl. Brooks Cole, 2002.
- [3] P. Alcantarilla, L. Bergasa, P. Jiménez, M. Sotelo, I. Parra, D. Fernández und S. S. Mayoral. „Night Time Vehicle Detection for Driving Assistance Lightbeam Controller“. In: *IEEE Intelligent Vehicles Symposium, 2008 IEEE*. 2008, S. 291–296.
- [4] American Meteorology Glossary. *Glossary of Meteorology*. Online available at <http://ams glossary.allenpress.com/glossary>. Besucht am 19.12.2012.
- [5] ANSI. *American National Standard: Nomenclature and Definitions for Illuminating Engineering, Z7.1-1967*. Illuminating Engineering Society. New York, 1967.
- [6] Aptina Imaging Corporation. *Products: Image Sensors*. http://www.aplina.com/products/image_sensors/mt9v022i77atm/. Juli 2013.
- [7] S. Assenmacher. *DIWA - Direkte Information und Warnung für Autofahrer*. Techn. Ber. Lehrstuhl für Verkehrstechnik, Technische Universität München, 2008.
- [8] H. G. Barrow und J. M. Tenenbaum. *Recovering Intrinsic Scene Characteristics from Images*. New York: Academic Press, 1978, S. 3–26.
- [9] P. Batavia. „Driver Adaptive Lane Departure Warning Systems“. Diss. Robotics Institute, Carnegie Mellon University, 1999.
- [10] R. E. Bellman. Princeton, New Jersey, U.S.A.: Princeton University Press, 1961.
- [11] I. Biederman. „Aspects and Extensions of a Theory of Human Image Understanding“. In: *Computational Processes in Human Vision: An Interdisciplinary Perspective*. Hrsg. von Z. Pylyshyn. Norwood, New Jersey: Albex Publishing Corporation, 1988, S. 370–428.
- [12] S. Bonte, M. Bergasa L. und P. F. Alcantarilla. „Fog Detection System Based on Computer Vision Techniques“. In: *IEEE Intelligent Transportation Systems* 12 (Okt. 2009), S. 1–6.

- [13] H. Brumberger, R. Stein und R. Powell. „Light Scattering“. In: *Science and Technology* (Nov. 1968), S. 34–60.
- [14] C. Busch und E. Debes. „Wavelet Transform for Analyzing Fog Visibility“. In: *IEEE Intelligent Systems* 13.6 (Nov. 1998), S. 66–71.
- [15] V. Cavallo, M. Colomb und J. Doré. „Distance Perception of Vehicle Rear Lights in Fog“. In: *Human Factors* 43.3 (Jan. 2001), S. 442–451.
- [16] J. M. Coggins und A. K. Jain. „A Spatial Filtering Approach to Texture Analysis“. In: *Pattern Recognition Letters* 3.3 (1985), S. 195–203.
- [17] A. Colman. *A Dictionary of Psychology*. 3. Aufl. Oxford University Press, 2009.
- [18] Commission of Illumination. *Commission internationale de l’Eclairage proceedings*. Cambridge, 1926.
- [19] Commission of Illumination. *International Lighting Vocabulary, CIE 17.4*. 1987.
- [20] B. Cyganek und J. P. Siebert. *An Introduction to 3D Computer Vision Techniques and Algorithms*. Wiley-Blackwell, 2009.
- [21] N. Dalal und B. Triggs. „Histograms of Oriented Gradients for Human Detection“. In: *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. Bd. 1. 2005, S. 886–893.
- [22] R. Datta, D. Joshi, J. Li und J. Z. Wang. „Image retrieval: Ideas, influences, and trends of the new age“. In: *ACM Computing Surveys* 40.2 (2008), S. 1–60.
- [23] I. Daubechies. *Ten Lectures on Wavelets*. CBMS-NSF Regional Conference Series in Applied Mathematics. Society for Industrial und Applied Mathematics, 1992.
- [24] P. Demartines und J. Héroult. „Curvilinear Component Analysis: A Self-Organizing Neural Network for Nonlinear Mapping of Data Sets“. In: *IEEE Transactions on Neural Networks* 8.1 (1997), S. 148–154.
- [25] E. Dickmanns und B. Mysliwetz. „Recursive 3-D Road and Relative Ego-State Recognition“. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 14.2 (Feb. 1992), S. 199–213.
- [26] R. Dodge. „Visual Perception During Eye Movement“. In: *Psychological Review* 7.5 (1900), S. 454–465.
- [27] R. O. Duda und P. E. Hart. „Use of the Hough Transformation to Detect Lines and Curves in Pictures“. In: *Communications of the ACM* 15.1 (Jan. 1972), S. 11–15.
- [28] E. Dumont. „Semi-Monte Carlo Light Tracing Applied to the Study of Road Visibility in Fog“. In: *Monte Carlo and quasi-Monte Carlo Methods*. Claremont Graduate Univ., Claremont, CA, Juni 1998.
- [29] S. Q. Duntley. „The Reduction of Apparent Contrast by the Atmosphere“. In: *Journal of the Optical Society of America* 38.2 (Feb. 1948), S. 179–187.
- [30] M. L. Eichner und T. P. Breckon. „Integrated Speed Limit Detection and Recognition from Real-Time Video“. In: *IEEE Intelligent Vehicles Symposium*. 2008, S. 626–631.

- [31] R. W. Fenn. „Correlation Between Atmospheric Backscattering and Meteorological Visual Range“. In: *Applied Optics* 5.2 (1966), S. 293–295.
- [32] R. Ferzli und L. Karam. „Human Visual System Based No-Reference Objective Image Sharpness Metric“. In: *IEEE International Conference on Image Processing*. Okt. 2006, S. 2949–2952.
- [33] R. A. Fisher. „The use of multiple measurements in taxonomic problems“. In: *Annals Eugen.* 7 (1936), S. 179–188.
- [34] D. Foley. „Considerations of Sample and Feature Size“. In: *IEEE Transactions on Information Theory* 18.5 (1972), S. 618–626.
- [35] U. Franke. „Real Time 3D-Road Modeling for Autonomous Vehicle Guidance“. In: *7th Scandinavian Conference on Image Analysis* (1991).
- [36] R. Gallen, A. Cord, N. Hautière und D. Aubert. „Towards Night Fog Detection through use of In-Vehicle Multipurpose Cameras“. In: *Intelligent Vehicles Symposium*. 2011, S. 399–404.
- [37] R. Gallen, N. Hautière und E. Dumont. „Static Estimation of the Meteorological Visibility Distance in Night Fog with Imagery“. In: *IEICE Transactions on Information and Systems* 93-D.7 (2010), S. 1780–1787.
- [38] W. Gaohong, Z. Yujin und L. Xinggang. „Wavelet Transform-Based Texture Classification with Feature Weighting“. In: *Proceedings of the International Conference on Image Processing*. Bd. 4. 1999, S. 435–439.
- [39] H. E. Gerhard, F. A. Wichmann und M. Bethge. „How Sensitive Is the Human Visual System to the Local Statistics of Natural Images?“ In: *Frontiers in Computational Neuroscience* 53 (2012).
- [40] A. P. Ginsburg. „Visual Information Processing Based on Spatial Filters Constrained by Biological Data“. Diss. University of Cambridge, Dez. 1978.
- [41] M. M. Gorkani und R. W. Picard. „Texture Orientation for Sorting Photos „at a Glance““. In: *Pattern Recognition, 1994. Vol. 1 - Conference A: Computer Vision Image Processing., Proceedings of the 12th IAPR International Conference on*. Bd. 1. Okt. 1994, S. 459–464.
- [42] A. Guérin-Dugué und A. Oliva. „Classification of scene photographs from local orientations features“. In: *Pattern Recognition Letters* 21.13-14 (Dez. 2000), S. 1135–1140.
- [43] X.-H. Han und Y.-W. Chen. „Biomedical Imaging Modality Classification Using Combined Visual Features and Textual Terms“. In: *Journal of Biomedical Imaging* 5 (Jan. 2011), S. 1–7.
- [44] R. M. Haralick. „Statistical and Structural Approaches to Texture“. In: *Proceedings of the IEEE* 67.5 (1979), S. 786–804.
- [45] R. M. Haralick, K. Shanmugam und I. Dinstein. „Textural Features for Image Classification“. In: *IEEE Transactions on Systems, Man and Cybernetics* SMC-3.6 (1973), S. 610–621.

- [46] R. M. Haralick und L. G. Shapiro. *Computer and Robot Vision*. Bd. 1. Addison-Wesley, 1991.
- [47] P. E. Hart, D. G. Stork und R. O. Duda. *Pattern Classification*. 2. Aufl. Wiley-Interscience, 2000.
- [48] N. Hautière, R. Labayrade und D. Aubert. „Estimation of the Visibility Distance by Stereovision: A Generic Approach“. In: *IEICE Transactions on Information and Systems* E89-D.7 (Juli 2006), S. 2084–2091.
- [49] N. Hautière, R. Labayrade und D. Aubert. „Real-Time Disparity Contrast Combination for Onboard Estimation of the Visibility Distance“. In: *IEEE Transactions on Intelligent Transportation Systems* 7.2 (Juni 2006), S. 201–212.
- [50] N. Hautière, R. Labayrade, C. Boussard, J.-P. Tarel und D. Aubert. „Perception through Scattering Media for Autonomous Vehicles“. In: *Autonomous Robots Research Advances*. Hrsg. von W. Yang. Hauppauge, NY: Nova Science Publishers, Inc., Apr. 2008. Kap. 8, S. 223–267.
- [51] N. Hautière, R. Labayrade, M. Perrollaz und D. Aubert. „Road Scene Analysis by Stereovision: a Robust and Quasi-Dense Approach“. In: *9th International Conference on Control, Automation, Robotics and Vision*. Dez. 2006, S. 1–6.
- [52] N. Hautière, J.-P. Tarel, H. Halmaoui, R. Brémond und D. Aubert. „Enhanced Fog Detection and Free-Space Segmentation for Car Navigation“. In: *Machine Vision and Applications* (2011), S. 1–13.
- [53] N. Hautière, J.-P. Tarel, J. Lavenant und D. Aubert. „Automatic Fog Detection and Estimation of Visibility Distance Through Use of an Onboard Camera“. In: *Machine Vision and Applications* 17.1 (Apr. 2006), S. 8–20.
- [54] W. Huber. „Fahrzeuggenerierte Daten zur Gewinnung von Verkehrsinformationen“. Diss. Lehrstuhl für Verkehrstechnik, Technische Universität München, 2001.
- [55] E. O. Hulburt. „Optics of Atmospheric Haze“. In: *Journal of the Optical Society of America* 31.7 (Juli 1941), S. 467–472.
- [56] R. E. Huschke. „Glossary of Meteorology“. In: *Quarterly Journal of the Royal Meteorological Society* 86.369 (1960), S. 431–431.
- [57] L. Ikonen und P. Toivanen. „Shortest Routes on Varying Height Surfaces Using Gray-Level Distance Transforms“. In: *Image and Vision Computing* 23.2 (2005), S. 133–141.
- [58] J. Ilonen, J.-K. Kämäräinen und H. K. Kälviäinen. *Efficient Computation of Gabor Features*. Techn. Ber. Lappeenranta University of Technology, Department of Information Technology, 2005.
- [59] A. Jain und B. Chandrasekaran. „Dimensionality and Sample Size Considerations“. In: *Pattern Recognition in Practice*. Hrsg. von P. Krishnaiah und L. Kanal. 1982, S. 835–855.
- [60] A. K. Jain und S. K. Bhattacharjee. „Address Block Location on Envelopes Using Gabor Filters“. In: *Pattern Recognition* 25.12 (1992), S. 1459–1477.

- [61] A. K. Jain, N. K. Ratha und S. Lakshmanan. „Object Detection Using Gabor Filters“. In: *Pattern Recognition* 30.2 (1997), S. 295–309.
- [62] M. Jourlin und J. Pinoli. „Logarithmic Image Processing: The Mathematical and Physical Framework for the Representation and Processing of Transmitted Images“. In: Hrsg. von P. W. Hawkes. Bd. 115. *Advances in Imaging and Electron Physics*. Elsevier, 2001, S. 129–196.
- [63] J.-K. Kämäräinen, V. Kyrki und H. H. Kälviäinen. „Invariance Properties of Gabor Filter-Based Features - Overview and Applications“. In: *IEEE Transactions on Image Processing* 15.5 (2006), S. 1088–1099.
- [64] D. Kim, M. Kim, B. Kim und K. Lee. „Histograms of Local Intensity Differences for Pedestrian Classification in Far-Infrared Images“. In: *Electronics Letters* 49.4 (2013), S. 258–260.
- [65] R. Kimmel, M. Elad, D. Shaked, R. Keshet und I. Sobel. „A Variational Framework for Retinex“. In: *International Journal of Computer Vision* 52.1 (2003), S. 7–23.
- [66] R. Kohler. „A Segmentation System Based on Thresholding“. In: *Computer Graphics and Image Processing* 15.4 (1981), S. 319–338.
- [67] H. Koschmieder. „Theorie der horizontalen Sichtweite“. In: *Beiträge zur Physik der freien Atmosphäre*. 2. Keim & Nemnich, 1925, S. 171–181.
- [68] P. Kruizinga und N. Petkov. „Nonlinear Operator for Oriented Texture“. In: *IEEE Transactions on Image Processing* 8.10 (Okt. 1999), S. 1395–1407.
- [69] T. M. Kwon. *Atmospheric Visibility Measurements Using Video Cameras: Relative Visibility*. Techn. Ber. Minnesota Department of Transportation, Juli 2004.
- [70] R. Labayrade und D. Aubert. „In-Vehicle Obstacles Detection and Characterization by Stereovision“. In: *Proceedings the 1st International Workshop on In-Vehicle Cognitive Computer Vision Systems*. Nov. 2003, S. 13–19.
- [71] R. Labayrade, D. Aubert und J.-P. Tarel. „Real Time Obstacle Detection in Stereovision on Non Flat Road Geometry through "v-Disparity"Representation“. In: *IEEE Intelligent Vehicle Symposium*. Bd. 2. Juni 2002, S. 646–651.
- [72] M. Lades, J. Vorbruggen, J. Buhmann, J. Lange, C. Von Der Malsburg, R. Wurtz und W. Konen. „Distortion Invariant Object Recognition in the Dynamic Link Architecture“. In: *IEEE Transactions on Computers* 42.3 (1993), S. 300–311.
- [73] A. Laine und J. Fan. „Texture Classification by Wavelet Packet Signatures“. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 15.11 (1993), S. 1186–1191.
- [74] M. Land, N. Mennie und J. Rusted. „The Roles of Vision and Eye Movements in the Control of Activities of Daily Living“. In: *Perception* 28 (11 1999), S. 1311–1328.
- [75] R. J. List. „Smithsonian Meteorological Tables“. In: *Quarterly Journal of the Royal Meteorological Society* 78.78 (Apr. 1952), S. 288.
- [76] F. Lohle. „Über ein Sichtphotometer zur Messung der Optischen Trübung der bodennahen Luftschicht“. In: *Zeitschrift für technische Physik* 16 (1935), S. 73–76.

- [77] D. Lowe. „Object Recognition from Local Scale-Invariant Features“. In: *The Proceedings of the Seventh IEEE International Conference on Computer Vision*. Bd. 2. 1999, S. 1150–1157.
- [78] S. G. Mallat. „A Theory for Multiresolution Signal Decomposition: The Wavelet Representation“. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 11.7 (1989), S. 674–693.
- [79] D. Marr, T. Poggio und S. Ullman. *Vision: A Computational Investigation Into the Human Representation and Processing of Visual Information*. MIT Press, 2010.
- [80] Marshall Electronics. *Lenses: High Resolution Miniature Glass Lenses*. http://www.mars-cam.com/optical/lenses/ccd_cmos/44.php. Juli 2013.
- [81] J. McCall und M. Trivedi. „Video-Based Lane Estimation and Tracking for Driver Assistance: Survey, System, and Evaluation“. In: *IEEE Transactions on Intelligent Transportation Systems* 7.1 (März 2006), S. 20–37.
- [82] E. J. McCartney. *Optics of the Atmosphere*. New York: John Wiley und Sons, 1976.
- [83] W. E. K. Middleton. *Vision through the Atmosphere*. Corrected Edition. University of Toronto Press, 1968.
- [84] W. E. K. Middleton. *Vision Through the Atmosphere*. University of Toronto Press, 1952.
- [85] M. Minnaert. *The Nature of Light and Colour in the Open Air*. 2. Aufl. Dover Publications, 1954.
- [86] Mobileye Inc. *Development & Evaluation Platforms: Cameras*. <http://www.mobileye.com/technology/development-evaluation-platforms/cameras/>. Juli 2013.
- [87] A. Mojsilovic, D. Rackov und M. Popovic. „On the Selection of an Optimal Wavelet Basis for Texture Characterization“. In: *International Conference on Image Processing*. Bd. 3. 1998, S. 678–682.
- [88] S. Murala, A. Gonde und R. Maheshwari. „Color and Texture Features for Image Indexing and Retrieval“. In: *IEEE International Advance Computing Conference*. 2009, S. 1411–1416.
- [89] S. G. Narasimhan und S. K. Nayar. „Contrast Restoration of Weather Degraded Images“. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 25.6 (Juni 2003), S. 713–724.
- [90] S. G. Narasimhan und S. K. Nayar. „Vision and the Atmosphere“. In: *International Journal of Computer Vision* 48.3 (Juli 2002), S. 233–254.
- [91] G. Obert. „Local Hazard Warning: A Cost Efficient Information Service for Digital Radio Receivers and Navigation Systems“. In: *Proceedings of the 13th ITS World Congress*. 2006.
- [92] P. P. Ohanian und R. C. Dubes. „Performance Evaluation for Four Classes of Textural Features“. In: *Pattern Recognition* 25.8 (1992), S. 819–833.

- [93] A. Oliva und A. Torralba. „Modeling the Shape of the Scene: A Holistic Representation of the Spatial Envelope“. In: *International Journal of Computer Vision* 42.3 (Mai 2001), S. 145–175.
- [94] A. Oliva, A. Torralba, A. Guérin-Dugué und J. Hérault. „Global Semantic Classification of Scenes using power spectrum templates“. In: *Proceedings of the Challenge of Image Retrieval, Newcastle*. Electronic Workshop Computer Series, Springer-Verlag, Okt. 1999, S. 1–12.
- [95] D. K. Park, Y. S. Jeon und C. S. Won. „Efficient Use of Local Edge Histogram Descriptor“. In: *Proceedings of the 2000 ACM workshops on Multimedia*. MULTIMEDIA. Los Angeles, California, USA: ACM, 2000, S. 51–54.
- [96] H. J. Park und H. S. Yang. „Invariant Object Detection Based on Evidence Accumulation“. In: *Pattern Recognition Letters* 22 (2001), S. 869–882.
- [97] M. Pavlić, H. Belzner, G. Rigoll und S. Ilić. „Image Based Fog Detection in Vehicles“. In: *IEEE Intelligent Vehicles Symposium*. 2012, S. 1132–1137.
- [98] M. Pavlić, G. Rigoll und S. Ilić. „Classification of Images in Fog and Fog-Free Scenes for Use in Vehicles“. In: *IEEE Intelligent Vehicles Symposium*. 2013, S. 481–486.
- [99] J. Pech-Pacheco, G. Cristobal, J. Chamorro-Martinez und J. Fernandez-Valdivia. „Diatom Autofocusing in Brightfield Microscopy: A Comparative Study“. In: *15th International Conference on Pattern Recognition*. Bd. 3. 2000, S. 314–317.
- [100] Polizei Bayern. <http://www.polizei.bayern.de/verkehr/studien/index.html/31494>. Besucht am 19.12.2012.
- [101] D. Pollen und S. Ronner. „Visual Cortical Neurons as Localized Spatial Frequency Filters“. In: *IEEE Transactions on Systems, Man and Cybernetics* SMC-13.5 (1983), S. 907–916.
- [102] D. Pomerleau. „Visibility Estimation from a Moving Vehicle Using the RALPH Vision System“. In: *IEEE Conference on Intelligent Transportation Systems*. Nov. 1997, S. 906–911.
- [103] D. Pomerleau und T. Jochem. „Rapidly Adapting Machine Vision for Automated Vehicle Steering“. In: *IEEE Expert: Intelligent Systems and Their Applications* 11.2 (Apr. 1996), S. 19–27.
- [104] D. Pomerleau, P. Kumar, J. Everson, L. Lazofson und E. Kopala. *Run-Off Road Collision Avoidance Using IVHS Countermeasures: Task 3 Report - Volume 1*. Techn. Ber. Washington, D.C.: U.S. Department of Transportation, Aug. 1995.
- [105] M. C. Potter. „Meaning in Visual Search“. In: *Science* 187.4180 (März 1975), S. 965–966.
- [106] M. C. Potter. „Short-Term Conceptual Memory for Pictures“. In: *Journal of Experimental Psychology: Humans Learning and Memory* 2.5 (Sep. 1976), S. 509–522.
- [107] M. C. Potter, A. Staub und D. H. O’Conner. „Pictorial and Conceptual Representation of Glimpsed Pictures“. In: *Journal of Experimental Psychology: Human Perception and Performance* 30.3 (Juni 2004), S. 478–489.

- [108] D. M. W. Powers. „Evaluation: From Precision, Recall and F-Factor to ROC, Informedness, Markedness & Correlation“. In: *Journal of Machine Learning Technologies* 2 (1 2011), S. 37–63.
- [109] H. R. Pruppacher und J. D. Klett. *Microphysics of Clouds and Precipitation*. 2nd. Springer, 1996.
- [110] S. Raudys und A. Jain. „Small Sample Size Effects in Statistical Pattern Recognition: Recommendations for Practitioners“. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 13.3 (1991), S. 252–264.
- [111] K. Rayner, B. R. Foorman, C. A. Perfetti, D. Pesetsky und M. S. Seidenberg. „How Psychological Science Informs the Teaching of Reading“. In: *Psychological Science in the Public Interest Monograph* 2.2 (2001), S. 31–74.
- [112] M. Roser und F. Moosmann. „Classification of Weather Situations on Single Color Images“. In: *IEEE Intelligent Vehicles Symposium*. Juni 2008, S. 798–803.
- [113] E. Salari und Z. Ling. „Texture Segmentation Using Hierarchical Wavelet Decomposition“. In: *Proceedings of the IEEE International Symposium on Industrial Electronics*. Bd. 1. 1995, S. 216–220.
- [114] F. W. Sears. *Optics*. 3. Aufl. Addison-Wesley, 1949.
- [115] S. C. Sereno¹ und K. Rayner. „Measuring Word Recognition in Reading: Eye Movements and Event-Related Potentials“. In: *Trends in Cognitive Sciences* 7.11 (2003), S. 489–493.
- [116] N. Serrano, A. Savakis und J. Luo. „A Computationally Efficient Approach to Indoor/Outdoor Scene Classification“. In: *Proceedings of the 16th International Conference on Pattern Recognition*. Bd. 4. 2002, S. 146–149.
- [117] G. Stein und O. Hadassi. „Bundling of Driver assistance systems“. Patent EP 2172873 A2. 7. Apr. 2010.
- [118] G. Stein und O. Hadassi. „Systematic Filter Patterns for Enhanced Performance of Single and Concurrent Driver Assistance Applications“. Patent EP 1887492 A1. 10. Feb. 2008.
- [119] J. Strand und T. Taxt. „Local Frequency Features for Texture Classification“. In: *Pattern Recognition* 27.10 (1994), S. 1397–1406.
- [120] M. Szummer und R. W. Picard. „Indoor-outdoor image classification“. In: *Content-Based Access of Image and Video Database, 1998. Proceedings., 1998 IEEE International Workshop on*. Jan. 1998, S. 42–51.
- [121] J.-P. Tarel und N. Hautière. „Fast Visibility Restoration from a Single Color or Gray Level Image“. In: *Proceedings of IEEE International Conference on Computer Vision (ICCV'09)*. Kyoto, Japan, 2009, S. 2201–2208.
- [122] J. R. Taylor und J. C. Moogan. „Determination of Visual Range During Fog and Mist Using Digital Camera Images“. In: *IOP Conference Series: Earth and Environmental Science*. Bd. 11. 2010.

-
- [123] A. B. Torralba und A. Oliva. „Semantic Organization of Scenes using Discriminant Structural Templates“. In: *Computer Vision, 1999. The Proceedings of the Seventh IEEE International Conference on*. Bd. 2. 1999, S. 1253–1258.
- [124] TPEG – *What is it all about? A guideline for understanding TPEG quickly!* Traveller Information Service Association. Apr. 2012.
- [125] M. Unser. „Texture Classification and Segmentation Using Wavelet Frames“. In: *IEEE Transactions on Image Processing* 4.11 (1995), S. 1549–1560.
- [126] A. Vailaya, A. Jain, M. Figueiredo und H. Zhang. „Content-Based Hierarchical Classification of Vacation Images“. In: *Proceedings of the IEEE International Conference on Multimedia Computing and Systems - Volume 2. ICMCS '99*. Washington, DC, USA: IEEE Computer Society, 1999, S. 518–523.
- [127] A. Vailaya, A. Jain und H. J. Zhang. „On Image Classification: City Images vs. Landscapes“. In: *Pattern Recognition* 31.12 (März 1998), S. 1921–1935.
- [128] E. H. Weber. „De Pulsu, Resorptione, Audita et Tactu“. In: *Annotationes Anatomicae et Physiologicae*. Leipzig: Koehler, 1834.
- [129] S. J. Williamson und H. Z. Cummins. *Light and Color in Nature and Art*. John Wiley & Sons, 1983.
- [130] World Meteorological Organization, 1992a. *International Meteorological Vocabulary*. WMO-No. 182. Geneva.
- [131] World Meteorological Organization, 2003. *Manual on the Global Observing System*. WMO-No. 544. Geneva.
- [132] World Meteorological Organization, 2008. *Guide to Meteorological Instruments and Methods of Observation*. WMO-No. 8. Geneva.