




TECHNISCHE UNIVERSITÄT  
MÜNCHEN

Lehrstuhl für Echtzeitsysteme und  
Robotik



# Fahrzeugeigenlokalisierung im Kontext hochautomatisierter Fahrfunktionen

Florian Benedikt Homm

Vollständiger Abdruck der von der Fakultät für Informatik der Technischen Universität München zur Erlangung des akademischen Grades eines

Doktors der Naturwissenschaften (Dr. rer. nat.)

genehmigten Dissertation.

Vorsitzender: Univ.-Prof. Dr. rer. nat. Daniel Cremers

Prüfer der Dissertation: 1. Univ.-Prof. Dr.-Ing. Darius Burschka  
2. Univ.-Prof. Dr.-Ing. Christoph Stiller  
Karlsruher Institut für Technologie

Die Dissertation wurde am 29.12.2011 bei der Technischen Universität München eingereicht und durch die Fakultät für Informatik am 21.09.2012 angenommen.



---

## Danksagung

---

Ich möchte mich zuerst recht herzlich bei Professor Dr.-Ing. Darius Burschka für die Betreuung dieser Arbeit seitens der TU München bedanken. Bedanken möchte ich mich auch bei Dr.-Ing. Christoph Stiller vom KIT für die Erstellung des Zweitgutachtens. Dank gilt auch Dr.-Ing. Dirk Wisselmann, Dr.-Ing. Helmut Spannheimer und Dr.-Ing. Klaus Gresser dafür, dass sie es mir ermöglicht haben, diese Arbeit bei der BMW Group Forschung und Technik schreiben zu können.

Mein besonderer Dank gilt Dr.-Ing. Nico Kämpchen für die mehrjährige Betreuung dieser Arbeit. Vor allem möchte ich mich bei ihm für die unzähligen fachlichen Diskussionen, seine hervorragende Unterstützung und intensive Förderung während meiner gesamten Doktorandenzeit bedanken. Großer Dank gilt auch Alexander Duda und Holger Ulrich für die nicht weniger interessanten Beiträge und Diskussionen während ihrer Zeit als Diplomanden bei der BMW Group Forschung und Technik.

Dank geht auch an Dr.-Ing. Frerk Fitzek, Dr.-Ing. Peter Waldmann, Michael Ardelt, Michael Aeberhard, Sebastian Rauch und Philipp Reinisch, die mich zu jeder Zeit unterstützt haben und immer ein offenes Ohr für mich hatten. Bei Mauro Gargano bedanke ich mich für seine umfassende Unterstützung in Sachen Framework. Weiterer Dank gilt Dr.-Ing. Daniel Schwarz, Dr.rer. nat. Rudolf Lindl, Dr.-Ing. Ralph Raßhofer, Dr.rer.nat. Reiner Wertheimer, Katrin Vogel, Dr.-Ing. Thomas Schaller, Martin Friedl, Frank Gensler, Thorsten Tronnier, Dr.-Ing. Marc Walessa und Dr.-Ing. Jan Löwenau.

Mein größter Dank gilt meiner Frau Julia und meiner Tochter Emma für den zugesprochenen Mut während dieser anstrengenden Zeit. Sie sind das größte Glück, welches mich Tag für Tag trägt. Dank gilt meiner Mutter und meinem Vater, ohne die diese Arbeit niemals möglich gewesen wäre.



Das Wissen über die Position und die Ausrichtung des Fahrzeugs innerhalb der Fahrbahn ist von grundlegender Bedeutung für eine Vielzahl von Fahrerassistenzsystemen. Insbesondere hochautomatisierte Fahrmanöver, wie beispielsweise die automatisierte Querführung oder der automatisierte Fahrstreifenwechsel, erfordern eine redundante und robuste Lokalisation innerhalb des eigenen Fahrstreifens sowie Informationen über die Position und die Anzahl weiterer Fahrstreifen.

In dieser Arbeit wird die Verwendung eines Lidar-Sensors zur Erhöhung der Robustheit in der Fahrzeugeigenlokalisierung untersucht. Der Schwerpunkt dieser Arbeit liegt dabei auf der lidarbasierten Fahrstreifenerkennung. Dies beinhaltet sowohl die genaue Betrachtung der Eigenschaften moderner Fahrbahnmarkierungen zur Abschätzung der allgemeinen Umsetzung einer lidarbasierten Fahrstreifenerkennung als auch die Entwicklung eines echtzeitfähigen Gesamtsystems zur Extraktion, Klassifikation und Verfolgung von Fahrbahnmarkierungen. Ein großer Teil dieser Arbeit widmet sich daher der Entwicklung und Evaluierung eines echtzeitfähigen Verfahrens zur Erkennung von Fahrbahnmarkierungen auf Basis einer Belegungskarte.

In einem darauf aufbauenden Schritt werden die durch das entwickelte Verfahren zur Verfügung gestellten Fahrstreifeninformationen mit einem kamerabasierten System zur Erkennung von Fahrbahnmarkierungen fusioniert. Ziel ist es, die Verfügbarkeit und die Robustheit eines allgemeinen Systems zur Fahrstreifenerkennung durch die Verwendung von Sensoren mit unterschiedlichen Messprinzipien zu steigern.



---

## Abstract

---

The knowledge about lanes and the exact position of the vehicle on the road is fundamental for many advanced driver assistance systems. In particular for highly automated driving tasks, an accurate and robust in-lane localization is required in order to derive the parameters required by a lateral vehicle controller. Additionally, the realization of complex driving strategies, such as lane change maneuvers, also require detailed information about the position and number of adjacent lanes.

In this thesis, the utilization of a Lidar-sensor to improve the robustness of a general lane-tracking system is investigated. This includes an evaluation of modern roadmarking materials in the context of a Lidar-based lane detection system, a preliminary analysis of sensor requirements and the development of a real-time capable occupancy grid-based lane marking classification and tracking system.

The extracted Lidar-based lane information is fused with a classical vision-based lane detection system. The aim is to compensate the errors of the single sensor system to gain a fail-safe positioning system in cases where a single sensor system might fail due to its sensor characteristics.



---

# Inhaltsverzeichnis

---

Notationen . . . . .	xiii
<b>1 Einleitung</b>	<b>1</b>
1.1 Motivation . . . . .	1
1.1.1 Verwandte Arbeiten . . . . .	2
1.1.2 Hochautomatisierte Fahrfunktionen . . . . .	5
1.1.3 Problemstellung . . . . .	7
1.2 Zielsetzung . . . . .	11
1.2.1 Schwerpunkte dieser Arbeit . . . . .	11
1.2.2 Randbedingungen dieser Arbeit . . . . .	12
1.3 Gliederung und Aufbau der Arbeit . . . . .	15
<b>2 Effiziente Berechnung von Belegungskarten auf der GPU</b>	<b>17</b>
2.1 Binärer Bayes Filter mit statischem Zustandsvektor . . . . .	19
2.2 Problemstellung und Motivation . . . . .	20
2.3 Grundlagen der Grafikkartenprogrammierung . . . . .	22
2.3.1 Hardwarearchitektur . . . . .	23
2.3.2 Compute Unified Device Architecture (CUDA) . . . . .	24
2.4 Parallelisierung . . . . .	25
2.4.1 Berechnung temporärer polarer Belegungskarten . . . . .	26
2.4.2 Abbildung auf eine temporäre kartesische Karte . . . . .	30
2.4.3 Stationäre Belegungskarte . . . . .	35
2.5 Exemplarische Umsetzung . . . . .	40
2.5.1 Laserscanner . . . . .	40
2.5.2 Bildgebendes Radar . . . . .	41
2.6 Zusammenfassung . . . . .	42

<b>3</b>	<b>Lidarbasierte Fahrstreifenerkennung</b>	<b>43</b>
3.1	Eigenschaften moderner Fahrbahnmarkierungen . . . . .	43
3.1.1	Anforderungen an Fahrbahnmarkierungssysteme . . . . .	44
3.1.2	Retroreflektive Eigenschaften von Fahrbahnmarkierungen . . . . .	46
3.1.3	Markierungssysteme und Markierungstypen . . . . .	49
3.1.4	Bedeutung für die lidarbasierte Fahrstreifenerkennung . . . . .	53
3.2	Messprinzip eines Lidar-Sensors . . . . .	53
3.2.1	Funktionsweise . . . . .	54
3.2.2	Signal-Rausch-Verhältnis zwischen Fahrbahnmarkierung und Fahr- bahnbelag . . . . .	55
3.2.3	Anforderungen an die Eigenschaften eines abstrakten Lidar-Sensors zur Detektion von Fahrbahnmarkierungen . . . . .	55
3.3	Parametrische Straßenmodelle . . . . .	62
3.4	Parameterextraktion und Fahrstreifenschätzung . . . . .	66
3.4.1	Stand der Technik . . . . .	67
3.4.2	Belegungskarte mit Bodenpunkten . . . . .	70
3.4.3	Histogrammbasierte iterative Parameteroptimierung des Kurswin- kels und der Krümmung . . . . .	74
3.4.4	Identifizierung potentieller Fahrbahnmarkierungen . . . . .	86
3.4.5	Erhöhung der Auflösung in der Ablage durch Interpolation . . . . .	87
3.4.6	Klassifikation von Fahrbahnmarkierungen . . . . .	88
3.4.7	Detektion gültiger Fahrstreifen . . . . .	91
3.5	Zusammenfassung . . . . .	93
<b>4</b>	<b>Fusion von lidar- und videobasierter Fahrstreifenerkennung</b>	<b>95</b>
4.1	Rekursive Zustandsschätzung mittels Kalman-Filter . . . . .	96
4.2	Lokalisation im eigenen Fahrstreifen . . . . .	98
4.2.1	Dynamikmodell . . . . .	99
4.2.2	System- und Messmodell . . . . .	100
4.3	Datenassoziation und Messfehlerkorrektur . . . . .	102
4.4	Erweiterung des Fahrbahnmodells zur Beschreibung weiterer Fahrstreifen .	103
4.5	Zusammenfassung . . . . .	104
<b>5</b>	<b>Modellbasierte Fahrbahnranderkennung</b>	<b>105</b>
5.1	Stand der Technik . . . . .	105
5.2	Erweiterung der histogrammbasierten Parameterextraktion . . . . .	106
5.3	Zusammenfassung . . . . .	109
<b>6</b>	<b>Evaluierung und Systembewertung</b>	<b>111</b>
6.1	Versuchsträger . . . . .	112
6.1.1	Koordinatensysteme . . . . .	112
6.1.2	Sensorik . . . . .	112
6.1.3	Aktuatorik . . . . .	115

6.1.4	Systemarchitektur und Framework . . . . .	116
6.2	Referenzdatengewinnung . . . . .	117
6.2.1	Globale Positionsbestimmung mit Differential-GPS . . . . .	117
6.2.2	Inertiales-Navigationssystem mit DGPS . . . . .	119
6.2.3	Hochgenaue digitale Karte . . . . .	120
6.3	Bewertung der lidarbasierten Fahrstreifenerkennung . . . . .	121
6.3.1	Abschätzung der Verfügbarkeit durch die Betrachtung von Fahr- bahnmarkierungsnormen . . . . .	121
6.3.2	Bewertung der Genauigkeit mit DGPS und einer hochgenauen digi- talen Karte . . . . .	129
6.3.3	Evaluierung der Verfügbarkeit . . . . .	134
6.3.4	Einfluss der Zellgröße einer Belegungskarte auf die histogrammba- sierte Fahrstreifenschätzung . . . . .	137
6.3.5	Zusammenfassung . . . . .	140
6.4	Bewertung des Fusionssystems . . . . .	141
6.4.1	Bestimmung des System- und des Messrauschens . . . . .	142
6.4.2	Bestimmung der Sensorlatenzzeiten . . . . .	144
6.4.3	Bewertung der Genauigkeit mit DGPS und einer hochgenauen digi- talen Karte . . . . .	145
6.4.4	Evaluierung der Verfügbarkeit . . . . .	149
6.4.5	Zusammenfassung . . . . .	150
6.5	Bewertung der Fahrbahnranderkennung mit DGPS und einer hochgenauen digitalen Karte . . . . .	151
6.6	Laufzeitanalyse der Berechnung stationärer Belegungskarten auf der GPU .	155
<b>7</b>	<b>Fazit</b>	<b>161</b>
7.1	Zusammenfassung . . . . .	161
7.2	Wissenschaftlicher Beitrag . . . . .	163
7.3	Ausblick . . . . .	164
<b>A</b>	<b>Koordinatentransformationen</b>	<b>165</b>
<b>B</b>	<b>Tabellen</b>	<b>167</b>
	<b>Abbildungsverzeichnis</b>	<b>171</b>
	<b>Tabellenverzeichnis</b>	<b>177</b>
	<b>Eigene Veröffentlichungen</b>	<b>179</b>
	<b>Betreute Arbeiten</b>	<b>181</b>
	<b>Literaturverzeichnis</b>	<b>183</b>



### Verwendete Abkürzungen

ABS	Antiblockiersystem
ACC	Adaptive Cruise Control
ADAS	Advanced Driver Assistance System
ASIC	Application Specific Integrated Circuit
BMW	Bayerische Motoren Werke
BAST	Bundesanstalt für Straßenwesen
CAN	Controller Area Network
CCD	Charge-coupled Device
CMOS	Complementary metal-oxide-semiconductor
CPU	Central Processing Unit
CUDA	Compute Unified Device Architecture
DARPA	Defense Advanced Research Projects Agency
D-GPS	Differential Global Positioning System
DIN	Deutsches Institut für Normung
DSP	Digital Signal-Processor
EKF	Extended Kalman-Filter
EN	Europäische Norm
EU	Europäische Union
FHWA	Federal Highway Administration
FLOPS	Floating Point Operations Per Second
FPGA	Field Programmable Gate Array
ESP	Elektronisches Stabilitätsprogramm
GLONASS	Globalnaja Nawigazionnaja Sputnikowaja Sistema
GPS	Global Positioning System
GPU	Graphics Processing Unit
GPGPU	General Purpose Computation on Graphics Processing Unit

IMU	Inertial Measurement Unit
INS	Inertiales Navigationssystem
JPDA	Joint Probabilistic Data Association
LIDAR	Light Detection and Ranging
LKW	Lastkraftwagen
MEMS	Micro Electro Mechanical System
MHT	Multi-Hypothesen-Tracker
NAVSTAR GPS	Navigational Satellite Timing and Ranging - Global Positioning System
PKW	Personenkraftwagen
RAA	Richtlinien für die Anlage von Autobahnen
RADAR	Radio Detection and Ranging
RAW	Read-After-Write
RANSAC	Random Sample Consensus
RAS	Richtlinien für die Anlage von Straßen
RMS	Root Mean Square
SDA	Strapdown-Algorithmus
SOC	System on Chip
SVM	Support-Vector-Machine
TOF	Time of flight
UKF	Unscented Kalman-Filter
WAW	Write-After-Write
WGS-84	World Geodetic System 1984

### Generelle Schreibweise

$a$	Skalar
$\mathbf{a}$	Vektor
$\mathbf{A}$	Matrix
$\mathbf{A}^T$	Transponierte der Matrix $\mathbf{A}$
$\mathbf{A}^{-1}$	Inverse der Matrix $\mathbf{A}$
$\mathbf{I}$	Einheitsmatrix

### Lateinische Buchstaben

$A$	Beliebige Fläche
$\mathbf{B}$	Eingangsmatrix des Kalman-Filters
$c$	Fahrbahnkrümmung mit $c = \frac{1}{R}$
$c_L$	Lichtgeschwindigkeit
$e$	Fehler (allgemein)
$e_{\max}$	Maximaler Schätzfehler einer Stichprobe
$E_f$	Beleuchtungsstärke einer beliebigen Empfängerfläche
$E_v$	Beleuchtungsstärke

---

<b>F</b>	Systemmatrix des Kalman-Filters
<b>H</b>	Messmatrix des Kalman-Filters
$I_v$	Lichtstärke
$k$	Aktueller Zeitschritt
<b>K</b>	Verstärkungsmatrix des Kalman-Filters
$L$	Leuchtdichte
$M$	Menge möglicher Fahrbahnmarkierungen
$p$	Wahrscheinlichkeit
<b>P</b>	Kovarianzmatrix des Systemzustands
<b>Q</b>	Kovarianzmatrix des Systemrauschens
$R$	Kurvenradius
<b>R</b>	Kovarianzmatrix des Messrauschens des Kalman-Filters
$R_L$	Leuchtdichtekoeffizient bei Retroreflexion
$s_i$	$i$ -ter Fahrstreifen
<b>S</b>	Kovarianzmatrix des Residuums des Kalman-Filters
<b>S<sub>0</sub></b>	Fahrzeugkoordinatensystem
<b>S<sub>x</sub></b>	Position und Orientierung relativ zum Fahrzeugkoordinatensystem
$t$	Zeitvariable
$T$	Zeitdifferenz
$\Delta T_S$	Signallaufzeit
<b>u</b>	Vektor mit Kontrolleingaben
$v$	Longitudinale Geschwindigkeit des Fahrzeugs
$V_e$	Entwurfsgeschwindigkeit
$b$	Fahrstreifenbreite
<b>x</b>	Wahrer Zustandsvektor
$\hat{\mathbf{x}}$	Geschätzter Zustandsvektor
$\tilde{\mathbf{x}}$	Schätzfehlervektor
$X_E$	X-Koordinate des GPS-Empfängers
$X_S$	X-Koordinate des GPS-Satelliten
$X_s$	X-Koordinate eines Sensors
$y$	Ablage zur Fahrstreifenmitte des eigenen Fahrstreifens
$y_i$	Ablage zur Mitte des $i$ -ten Fahrstreifens
$\tilde{\mathbf{y}}$	Residuum zwischen Messwert und Prädiktion
$Y_E$	Y-Koordinate des GPS-Empfängers
$Y_S$	Y-Koordinate des GPS-Satelliten
$Y_s$	Y-Koordinate eines Sensors
<b>z</b>	Messvektor
$Z_E$	Z-Koordinate des GPS-Empfängers
$Z_S$	Z-Koordinate des GPS-Satelliten
$Z_s$	Z-Koordinate eines Sensors

### Griechische Buchstaben

$\alpha$	Winkel (allgemein)
$\beta$	Winkel (allgemein)
$\alpha_v$	Anleuchtungswinkel
$\beta_v$	Beobachtungswinkel
$\alpha_s$	Horizontaler Öffnungswinkel eines Sensors
$\beta_s$	Vertikaler Öffnungswinkel eines Sensors
$\chi$	Allgemeine Strahldivergenz
$\chi_{\text{hor}}$	Horizontale Strahldivergenz
$\chi_{\text{ver}}$	Vertikale Strahldivergenz
$\delta_E$	Uhrenfehler des GPS-Empfängers
$\epsilon$	Abstand zur Beschränkung der maximalen Wahrscheinlichkeit
$\eta$	Einfallswinkel relativ zur Oberflächennormalen eines Objektes
$\gamma$	konstanter Verstärkungsfaktor
$\mu_{\bar{x}}$	Mittlerer Schätzfehler
$\Omega$	Raumwinkel
$\phi_s$	Rollwinkel eines Sensors
$\phi$	Rollwinkel des eigenen Fahrzeugs
$\Phi$	Lichtstrom
$\Phi_0$	Sendeleistung einer Laserdiode
$\psi$	Relativer Kurswinkel des eigenen Fahrzeugs
$\Psi$	Gierwinkel des eigenen Fahrzeugs
$\Psi_s$	Gierwinkel eines Sensors
$\dot{\Psi}$	Gierrate des Fahrzeugs
$\theta$	Nickwinkel des eigenen Fahrzeugs
$\theta_s$	Nickwinkel eines Sensors
$\sigma$	Standardabweichung
$\sigma_{\bar{x}}$	Standardabweichung des Schätzfehlers
$\sigma_{\text{br}}$	Konstante für die Reflektivität einer Oberfläche

### 1.1 Motivation

In den letzten Jahren wurde eine Vielzahl an aktiven Sicherheitssystemen für Fahrzeuge entwickelt, die einen Fahrer in kritischen Fahrsituationen unterstützen und ihm gegebenenfalls helfen, einen Unfall zu vermeiden. Fahrerassistenzsysteme wie das Anti-Blockiersystem (ABS) oder die Dynamische-Stabilitätskontrolle (DSC), die den Fahrer in fahrdynamischen Grenzsituationen durch aktives Eingreifen unterstützen, gehören längst zur segmentübergreifenden Serienausstattung. Der Begriff der *Fahrerassistenz* im Allgemeinen, hat in den vergangenen Jahren einen extremen Wandel erfahren. Systeme die noch Anfang des letzten Jahrzehnts undenkbar schienen, sind heute in vielen Bereichen zur Selbstverständlichkeit geworden. Das Auto wie wir es kennen, ist längst ein hoch vernetztes System mit beachtlicher Rechenleistung, welches in der Lage ist, Teile der menschlichen Fahraufgabe nachzubilden und diese, wenn nötig, vollständig zu übernehmen.

Nach Kompaß [Kom08] lassen sich heutige Fahrerassistenzsysteme in drei grundlegende Ebenen einteilen: die Stabilisierungsebene, die Führungsebene und die Planungsebene. Zur Stabilisierungsebene zählen Systeme, die den Fahrer in fahrdynamischen Grenzsituationen unterstützen. Die bekanntesten Vertreter dieser Klasse wurden bereits erwähnt, das ABS und DSC. Eine Besonderheit dieser Ebene ist, dass der menschliche Fahrer nicht in der Lage wäre, die Funktion dieser Systeme zu übernehmen, selbst wenn er eine geeignete Möglichkeit zur Steuerung der verwendeten Aktuatorik hätte. Dies unterscheidet die Stabilisierungsebene von der Planungsebene. Zur Planungsebene gehören zum Beispiel Systeme zur satellitengestützten Routenplanung, sogenannte Navigationssysteme. Es ist offensichtlich, dass der Mensch auch über die Fähigkeit der Navigation verfügt, jedoch ist er einem auf einer Kartenbasis aufbauenden System in der Regel unterlegen. Die Führungsebene unterscheidet sich grundlegend von den anderen beiden Ebenen.

Die Funktionen der Führungsebene sind heute dem größten technischen Wandel un-

terworfen. Zu ihnen zählen meist in der Oberklasse oder gehobenen Mittelklasse optional angebotene Systeme<sup>1</sup> wie die Park-Distance-Control (PDC), die automatische Abstandsregelung (ACC), die darauf aufbauende Anhaltewegverkürzung (AWV) und aktive Gefahrenbremsung (AGB), die Spurhalteassistentz, die Spurwechselwarnung und die automatische Verkehrszeichenerkennung. Um diese Funktionalitäten überhaupt erst zu ermöglichen, sind diese Systeme auf eine ganze Reihe von fahrumfelderfassenden Sensoren angewiesen. Dies unterscheidet die Führungsebene auch grundlegend von der Stabilisierungs- und Planungsebene, bei denen in der Regel keine Sensoren zur direkten Wahrnehmung des Fahrumfelds benötigt werden.

Wie bereits erwähnt, ist die Entwicklung der Fahrerassistenz zum heutigen Zeitpunkt einem extremen Wandel unterworfen. Dies bedeutet, dass die oben exemplarisch genannten Systeme nicht das Ende, sondern den Anfang einer neuen Ära der Fahrerassistenz einleiten. Kombiniert man einige der oben aufgeführten Basisfunktionalitäten miteinander, wie zum Beispiel die automatische Abstandsregelung mit der Spurhalteassistentz, bewegt man sich bereits in einem Funktionsbereich, der als hochautomatisiertes Fahren bezeichnet wird.

Für die Realisierung von hochautomatisierten Fahrfunktionen muss das Fahrumfeld zu jedem Zeitpunkt zuverlässig wahrgenommen werden. Hierzu zählen die Erkennung anderer Verkehrsteilnehmer, die Erkennung freier befahrbarer Bereiche sowie Informationen über die eigene Position und den Straßenverlauf. Insbesondere der genauen Fahrzeugeigenlokalisierung kommt eine enorme Bedeutung zu, um Fahrstrategien sicher ableiten zu können und eine robuste Längs- und Querführung des Fahrzeugs zu gewährleisten.

Das Themengebiet des hochautomatisierten Fahrens steht dabei in enger Verwandtschaft zu dem sogenannten „autonomen Fahren“, welches die Wissenschaft und Forschung seit nun mehr als zwei Jahrzehnten sowohl fasziniert als auch herausfordert. Das autonome Fahren blickt bereits heute auf eine sehr bewegte und spannende Vergangenheit zurück, welcher der folgende Teilabschnitt gewidmet ist.

### 1.1.1 Verwandte Arbeiten

Den ersten Meilenstein im Bereich des autonomen Fahrens erbrachte Prof. Ernst Dickmanns im Jahr 1986 mit seinem Forschungsteam der UniBw in München [Zap88]. Das Team um Prof. Dickmanns demonstrierte mit seinem Forschungsfahrzeug VaMoRs (Versuchsfahrzeug für autonome Mobilität und Rechnersehen) eine 20 km autonome Fahrt auf einer abgesperrten Autobahn von München nach Ingolstadt. Der umgebaute Mercedes-Benz Transporter (Abbildung 1.1) verfügte über die Möglichkeit, das Gas, die Bremse und die Lenkung mikroprozessorgesteuert auf Basis einer videobasierten Fahrstreifenenerkennung anzusprechen. Diese Fahrt kann somit als erste auf maschinellem Sehen basierte autonome Quer- und Längsführung eines Fahrzeugs betrachtet werden. Berücksichtigt man, mit welchen widrigen Bedingungen (eingeschränkte Rechenleistung und schlechte Sensorik) das Team von Prof. Dickmanns im Jahr 1986 konfrontiert war, stellt diese Fahrt eine beachtliche technische und wissenschaftliche Leistung dar.

---

<sup>1</sup>Mit Ausnahme der Park-Distance-Control, welche auch in Kleinwagen angeboten wird.



Abbildung 1.1: Forschungsfahrzeug VaMoRs der UniBW München aus dem Jahr 1986 [Wün10]. Abbildung (a) zeigt das Forschungsfahrzeug von außen und Abbildung (b) den Aufbau der Rechen- und Steuerungssysteme im hinteren Teil des Fahrzeugs.

Im Jahr 1987 startete, unter anderem motiviert durch die vorangegangenen Erfolge von Prof. Dickmanns, das durch die EU mit mehreren hundert Millionen geförderte Projekt PROMETHEUS (PROgraME for a European Traffic of Highest Efficiency and Unprecedented Safety). Das Ziel war es, die Machbarkeit des autonomen Fahrens unter realen Verkehrsbedingungen in autobahnähnlichen Szenarien mit einem PKW zu demonstrieren. Neben der reinen bildbasierten Fahrstreifenenerkennung, stand nun auch die Erkennung anderer Verkehrsteilnehmer im Fokus. Nach einiger Forschungs- und Entwicklungsarbeit demonstrierten Daimler-Benz und die UniBW im Jahr 1994 mit ihren Fahrzeugen VITA-2 [Rei96] und VaMP [DBD<sup>+</sup>94] die autonome Längs- und Querführung auf einer dreispurigen Autobahn nahe Paris. Demonstriert wurden unter anderem die kamerabasierte Längs- und Querführung bei Geschwindigkeiten bis 130 km/h und autonome Fahrstreifenwechsel bei Freigabe durch den Fahrer. Im Jahr 1995 erfolgte zusätzlich noch ein Langstreckentest über mehr als 1.600 km Autobahn, der zu 95% autonom zurückgelegt wurde.

Nach den Jahren 1994 bis 1995 und der erfolgreichen Demonstration der Machbarkeit autonomer Funktionen, wurde es etwas ruhiger im Bereich des autonomen Fahrens. Dies änderte sich abrupt als die DARPA (Defense Advanced Research Projects Agency) des US-amerikanischen Verteidigungsministeriums ankündigte, im Jahr 2004 einen mit einer Million Dollar Preisgeld dotierten Wettbewerb für autonome Fahrzeuge auszutragen, die DARPA Grand Challenge. Ziel des Wettbewerbs war es, einen 150 Meilen langen Wüstenkurs, der lediglich durch GPS Wegpunkte abgesteckt wurde, völlig autonom und ohne Eingriffe von außen (Fernsteuerung) zu bewältigen. Diese Herausforderung unterschied sich grundlegend von der im Projekt PROMETHEUS gezeigten Autonomie, die hauptsächlich aus der Längs- und Querführung innerhalb eines durch Fahrbahnmarkierungen abgegrenzten Fahrstreifens bestand. Die Beschaffenheit der Strecke variierte zwischen asphaltierten Wegen bis hin zu steinigen Passagen mit Hindernissen, die, wenn sie nicht umfahren wur-



Abbildung 1.2: Abbildung (a) zeigt das Siegerfahrzeug Stanley der DARPA Grand Challenge 2005 [Sta11]. Abbildung (b) zeigt das Fahrzeug BOSS von Tartan Racing [Urm07], welches die DARPA Urban Challenge im Jahr 2007 gewann. Im Vergleich der beiden Bilder ist deutlich zu erkennen, wie auf die gestiegene Anforderung, auch andere Verkehrsteilnehmer 360° um das eigene Fahrzeug herum zu erkennen, mit zusätzlichen seitlichen und hinteren Sensoren reagiert wurde.

den, ein Weiterkommen unmöglich machten. Die größte Herausforderung bestand somit auf Seite der Perzeption in Kombination mit der lokalen und globalen Bahnplanung, die in Echtzeit durchgeführt werden musste.

Zu der ersten Grand Challenge im Jahr 2004 traten mehr als 100 Teams aus Wissenschaft und Forschung an. Es gelang jedoch keinem Team, den Kurs erfolgreich zu absolvieren. Das erfolgreichste Fahrzeug schaffte lediglich 11.9 km der über 200 km langen Strecke.

Die zweite Grand Challenge wurde 2005 in der Mojave-Wüste im US-Bundesstaat Nevada ausgetragen. Von den 195 registrierten Teams gelang es 4 Fahrzeugen, die gesamten 212.76 km in weniger als den geforderten zehn Stunden zu bewältigen. Sieger des Rennens war das Team der Stanford University mit dem Fahrzeug „Stanley“ (Abbildung 1.2(a)), das die volle Strecke in 6 Stunden und 53 Minuten absolvierte [TMD<sup>+</sup>06].

Im Jahr 2007 fand auf einem ehemaligen US-Air Force Stützpunkt nahe Victorville (CA) der dritte und vorerst letzte Wettbewerb der DARPA statt, die Urban Challenge. Im Unterschied zu der vorher ausgetragenen Grand Challenge, war der Fokus nicht mehr alleine auf die autonome Navigation und Bahnplanung im unwegsamen Terrain ausgerichtet. Eine zusätzliche Herausforderung bestand in der Interaktion mit den auf dem Testgelände vorhandenen und durch die DARPA simulierten Verkehrsteilnehmern. Darüber hinaus mussten die für ein innerstädtisches Szenario gültigen Verkehrsregeln beachtet werden. Sieger war das Tartan Racing Team [UAB<sup>+</sup>08] der Carnegie Mellon University mit ihrem Fahrzeug „Boss“ (Abbildung 1.2(b)) gefolgt von „Junior“ von der Stanford University [MBB<sup>+</sup>08]. Die erfolgreichsten deutschen Teilnehmer, das Team Annieway [SKP<sup>+</sup>08] und das Team CarOLO [BR08], schafften es zwar unter die zehn besten Fahrzeuge ins Finale, schieden dort jedoch zum Teil auf unglückliche Weise aus.

Als weitere Meilensteine nach den DARPA Wettbewerben zu nennen sind die Aktivitäten der TU Braunschweig zur autonomen Umrundung des Braunschweiger Stadtrings [WSM10], sowie die im Jahr 2010 und 2011 in der Presse publizierte Aktivitäten über Googles autonomes Fahrzeug, welches in den USA mehrere tausend Meilen ohne Fahrereingriff zurücklegte [goo10].

Neben den eben vorgestellten Arbeiten, existieren noch eine ganze Reihe weiterer nicht weniger interessanter Forschungsaktivitäten aus dem Bereich des autonomen Fahrens. Der interessierte Leser ist auf die Zeittafel in [LB09] verwiesen, in der die wichtigsten Aktivitäten der letzten Jahre zusammengefasst sind.

### 1.1.2 Hochautomatisierte Fahrfunktionen

Der vorherige Abschnitt hat gezeigt, dass sich autonomes Fahren unter bestimmten Einschränkungen oder künstlichen Bedingungen (DARPA Wettbewerbe), mit dem extensiven Einsatz von Sensorik (Abbildung 1.2(b)), durchaus im Bereich des Möglichen befindet. Dies gibt jedoch zunächst keinen Aufschluss darüber, welchen Nutzen solche Systeme für einen Fahrer darstellen können und an welcher Stelle Autonomie in der Fahrerassistenz überhaupt sinnvoll eingesetzt werden kann.

Die Kernaufgaben der Fahrerassistenz liegen im Wesentlichen in der Unterstützung des Fahrers zur Steigerung des Komforts und der Sicherheit. Intuitiv werden die meisten Menschen der Behauptung zustimmen, dass ein hoher Grad von Autonomie im Fahrzeug, wenn nicht das Fahrerlebnis im Vordergrund steht, durchaus wünschenswert ist, um sich während der Fahrzeit anderen Aufgaben widmen zu können. Auch wenn sich die Technik in rasanten Schritten weiterentwickelt und man die rechtlichen Problemstellungen ignoriert [Kom08], so ist es äußerst unwahrscheinlich, dass automatisierte Systeme in absehbarer Zeit in der Lage sein werden, den Menschen in seiner Fahraufgabe zu ersetzen. Um die hohe Komplexität der im realen Straßenverkehr auftretenden Situationen in vollem Umfang zu beherrschen, setzt die vollständige Autonomie erhebliche sensorische und interpretative Fähigkeiten eines technischen Systems voraus, die nach dem heutigen Stand der Technik äußerst schwierig zu erfüllen sind.

Es lassen sich jedoch technisch machbare Teilaspekte ausgliedern, die im Sinne von Assistenzsystemen auch einen Nutzen für den Fahrer darstellen. Diese Systeme werden im Folgenden als hochautomatisierte Fahrfunktionen bezeichnet.

Nach Lienkamp [LB09] lassen sich der Bedarf nach Hilfe und die Leistungsfähigkeit eines Fahrers als gegenläufige Funktionen in Abhängigkeit zu dem Schwierigkeitsgrad einer Fahraufgabe darstellen (Abbildung 1.3). Im linken Teil der Grafik befinden sich Fahraufgaben, die durch den Fahrer zwar einfach zu bewerkstelligen sind, jedoch durch ihre *Monotonie* und die damit verbundene Ermüdung des Fahrers den Einsatz eines automatisierten Systems sinnvoll machen. Als Beispiel zu nennen hierfür sind die automatisierte Längs- und Querführung auf autobahnähnlichen Straßen. Neben dem reinen Sicherheitsaspekt, erfüllt ein solches System auch in hohem Maße den Komfortaspekt, da die Reisezeit zu einem großen Teil für andere Aufgaben zur Verfügung stehen würde. Dem rechten Teil der Grafik können Fahraufgaben zugeteilt werden, die durch ihre hohe Komplexität den Fah-




Abbildung 1.3: Bedarf nach Hilfe eines Fahrers in Abhängigkeit zu dem Schwierigkeitsgrad einer Fahraufgabe [LB09]. Der Bedarf nach Hilfe ist sowohl bei einer Unter- als auch bei einer Überforderung des Fahrers besonders groß.

rer überdurchschnittlich beanspruchen und manche Fahrer sogar überfordern können. Als Beispiel zu nennen ist das Durchfahren einer Baustelle, in der die Breite der Fahrstreifen stark reduziert wurde. Ein System, welches automatisiert eine Baustelle durchfahren könnte, würde einen sehr großen Sicherheits- und Komfortgewinn mit sich bringen. Betrachtet man jedoch zusätzlich die Anforderungen, die ein solches System an die Sensorik und die damit verbundene maschinelle Interpretation der Szenerie stellt, so wird schnell klar, dass Systeme der zweiten Kategorie den Schwierigkeitsgrad der ersten bei weitem übertreffen.

So ist es sinnvoll, sich zuerst den automatisierten Fahrfunktionen der ersten Kategorie zu widmen. Dies mag auf den ersten Blick zwar die „weniger anspruchsvolle“ Herausforderung darstellen, jedoch ist es keinesfalls so, dass mit Blick auf die Robustheit und die redundante Auslegung automatisierter Systeme, die für einen Serieneinsatz zwingend erforderlich sind, alle Problemstellungen bereits ausreichend gelöst worden sind (Abschnitt 1.1.3).

Neben den in der Literatur weitgehend bekannten Komfortfunktionen der ersten Kategorie, soll an dieser Stelle noch kurz auf eine besondere Anwendung automatisierter Fahrfunktionen eingegangen werden, die bis heute noch wenig Beachtung gefunden hat: Funktionen im Kontext der Fahruntfähigkeit eines Fahrers. Als Beispiel zu nennen hierfür ist der „Nothalteassistent“, der bei Fahruntfähigkeit des Fahrers die Kontrolle über das Fahrzeug übernimmt und es in einen sicheren Fahrzustand überführt [WKAH10, KHWA10]. Die Definition eines „sicheren Fahrzustands“ unterscheidet sich dabei je nach Szenario erheblich. So kann beispielsweise ein sicherer Zustand in einem innerstädtischen Szenario sich durchaus auf der Fahrbahn (sprichwörtlich „inmitten der Straße“) befinden, wohingegen auf einer Autobahn das Anhalten auf einem Fahrstreifen ein immenses Sicherheitsrisiko darstellt. Diese Sicherheitsfunktion unterscheidet sich daher in zwei Punkten grundlegend von Funktionen, bei denen neben dem Sicherheits- in erster Linie der Komfortaspekt im



Abbildung 1.4: Beispiel für einen Nothalt auf dem Standstreifen auf einer Autobahn mit drei Fahrstreifen. Um in einen sicheren Fahrzustand zu gelangen, müssen unter Berücksichtigung des Verkehrs, drei automatisierte Fahrstreifenwechsel durchgeführt werden.

Vordergrund steht. Zum einen sind die technischen Anforderungen invertiert. Bei einem Komfortsystem stellen die komplexen Situationen im innerstädtischen Bereich die größte Herausforderung dar, wohingegen ein Autobahnscenario als vergleichsweise einfach gilt. Bei einem Nothaltesystem ist dieses genau umgekehrt. In einem Autobahnscenario ist es gegebenenfalls notwendig, eine gewisse Strecke erst selbständig zu bewältigen und mehrere automatisierte Fahrstreifenwechsel durchzuführen (Abbildung 1.4), bevor ein sicherer Fahrzustand erreicht werden kann. Zum anderen kann davon ausgegangen werden, dass ein solch hoch automatisiertes System, selbst wenn es nicht unter allen Umständen den Fahrer nachbilden kann, besser ist, als ein komplett führerloses Fahrzeug.

Um hochautomatisierte Fahrfunktionen überhaupt realisieren zu können, müssen zuerst die Fähigkeiten eines Fahrers zum Führen des Fahrzeugs nachgebildet werden. Dies beinhaltet die Perzeption, das Treffen von Entscheidungen (Fahrstrategie) und das Ansteuern der Aktuatorik (Abbildung 1.5). Der folgende Abschnitt beschäftigt sich mit den Problemstellungen eines äußerst wichtigen Teilaspekts der Perzeption, der Fahrzeugeigenlokalisierung.

### 1.1.3 Problemstellung

Für die Realisierung von hochautomatisierten Fahrfunktionen, wie zum Beispiel den Nothalteassistenten [WKAH10, KHWA10], bildet die erfolgreiche Erkennung von sogenannten „Landmarken“ [TBF05] die allgemeine Basis für eine robuste und ausreichend genaue Positionsbestimmung.

Hierbei ist es zunächst unerheblich, ob die Lokalisation mit Bezug zu einem *lokalen* Referenzsystem (beispielsweise zur Fahrbahn) oder zu einem *globalen* Referenzsystem (georeferenzierte digitale Karte) erfolgt. Die globale Lokalisation bietet zwar den Vorteil, dass die Informationen einer globalen Wissensbasis in Kombination mit einem satellitengestütz-




Abbildung 1.5: Die Abbildung zeigt schematisiert die wichtigsten Systembausteine beim automatisierten Fahren. Ein wesentlicher Teilaspekt ist die Fahrzeugeigenlokalisierung.

ten System zur Positionsbestimmung verwendet werden können, diese jedoch in der Praxis aufgrund von Verdeckungen, Mehrwegeausbreitungen und atmosphärischen Störungen (siehe [Wen07]) nicht ohne die zusätzliche Unterstützung einer landmarkenbasierten Positionierung auskommt.

Die mit Abstand am häufigsten verwendeten Landmarken, um die Position eines Fahrzeugs auf der Straße und innerhalb eines Fahrstreifens zu bestimmen, sind Fahrbahnmarkierungen. Dabei ist bemerkenswert, dass Fahrbahnmarkierungen die einzigen Landmarken sind, die ohne eine a-priori Wissensbasis (digitale Karten) eine automatisierte Querführung innerhalb des Fahrstreifens ermöglichen. So verwundert es auch nicht, dass sich die Wissenschaft seit nun mehr als 25 Jahren intensiv mit der maschinellen Erkennung von Fahrbahnmarkierungen beschäftigt.

Die am häufigsten verwendete Methode ist die kamerabasierte Extraktion von Fahrbahnmarkierungen, bei der die Querablage und Ausrichtung des Fahrzeuges im Fahrstreifen sowie die Fahrbahnkrümmung anhand eines Videobildes geschätzt wird. Die ersten beiden der in Abschnitt 1.1.1 erwähnten Meilensteine des autonomen Fahrens, VaMoRs und VaMP, sind eng mit der kamerabasierten Fahrstreifenenerkennung verbunden. Im Gegensatz zu der DARPA Urban Challenge, bei der Fahrbahnmarkierungen nur eine untergeordnete Rolle spielten, erfolgte die autonome Querführung alleine auf Basis eines kamerabasierenden Systems [DM92, DBD<sup>+</sup>94]. Ab Anfang der 90er Jahre erfolgte eine ganz Reihe von Publikationen mit dem Themenschwerpunkt der bildbasierten Fahrstreifenschätzung. Zu erwähnen sind neben den bereits genannten Aktivitäten der UniBW um Prof. Dickmanns, die Systeme SCARF, YARF, und ALVINN im Rahmen des Navlab I. Projekts [THKS91] und RALPH [Pom95] von der Carnegie Mellon University. Zu nennen ist auch die Arbeit von Broggi und Bertozzi aus dem Jahr 1998 [BB98]. Ihr auf einer Stereokamera basierendes „generic obstacle and lane detection system“ (GOLD), war in der Lage, durch den Einsatz von parallelisierter Hardware, Objekte und Fahrstreifen zu detektieren. Eine der am meisten zitierten Veröffentlichung stammt von McCall und Trivedi [MT06]. Im Jahr 2006 veröffentlichten sie einen umfassenden Rückblick über bildbasierte Verfahren zur Fahr-

streifenenerkennung. Sie führten unter anderem einen detaillierten Vergleich über die bis zu diesem Zeitpunkt veröffentlichten Arbeiten zur Fahrstreifenschätzung durch. Nennenswerte Arbeiten nach dem Jahr 2006 sind [Kim08, LSB<sup>+</sup>08, DN09, MMSM<sup>+</sup>09, ZJX<sup>+</sup>10] und [ST10]. Neben den eben erwähnten Arbeiten, die sich ausschließlich alle mit dem Gesamtproblem der Fahrstreifenschätzung aus aufeinander folgenden Bilddaten befassen, widmen sich Veit *et al.* [VTNC08] der Bewertung eines äußerst wichtigen Teilaspekts bei der Fahrstreifenenerkennung, der Merkmalsextraktion.

Das einheitliche Ziel aller bisher in diesem Teilabschnitt vorgestellten Verfahren ist dabei, aus zeitlich aufeinander folgenden Bildern die Modellparameter eines sogenannten parametrischen Straßen- oder Fahrstreifenmodells (Abschnitt 3.3) zu schätzen, welches anschließend in den darauf aufbauenden Regelfunktionen oder in einem Fusionssystem zur Positionsbestimmung verwendet werden kann.

Zusammenfassend lässt sich konstatieren, dass sich kamerabasierte Systeme zum heutigen Zeitpunkt bereits auf einem hohen technischen Stand befinden, der unterstützt durch die rasante Entwicklung geeigneter Hardwarekomponenten, sogar den Einzug in die Serienproduktion<sup>2</sup> ermöglicht hat. Eine Problematik, die alle kamerabasierten Systeme unabhängig von dem eingesetzten Verfahren teilen, ist eng mit den *passiven* Eigenschaften kamerabasierter Systeme verknüpft. Für eine erfolgreiche bildbasierte Merkmalsextraktion, ist es zwingend erforderlich, dass zwischen Fahrbahnbelag und Fahrbahnmarkierung ein ausreichender Kontrast zur Bildung eines Gradienten oder zur Anwendung von Vergleichsoperatoren vorhanden ist. Fehlt dieser, weil er etwa durch Gegenlichtblendung (Abbildung 1.6(a)), Schattenwurf (Abbildung 1.6(b)) oder starke Spiegelung überlagert (Abbildung 1.6(b)) ist, kann eine erfolgreiche Merkmalsextraktion und damit Erkennung von Fahrbahnmarkierungen nahezu unmöglich sein. Neben der reinen „Verdeckung“ durch Schattenwurf, kann es unter bestimmten Umständen zusätzlich zur Erzeugung von Kontrastübergängen kommen, die in ihrer Anordnung und Form echten Fahrbahnmarkierungen äußerst ähnlich sind. Diese werden als „Geistermarkierungen“ bezeichnet (Abbildung 1.6(d)). Betrachtet man ein hoch automatisiertes Gesamtsystem, bei dem der Fahrer die Kontrolle zeitweise an das Fahrzeug übergeben hat, kann ein solcher Ausfall teils verheerende Folgen mit sich bringen.

Die Problemstellungen, die sich bezüglich der Fahrzeugeigenlokalisierung für hoch automatisierte Fahrfunktionen ergeben, beschäftigen sich daher in erster Linie mit der Frage, wie ein solches System möglichst redundant ausgelegt werden kann, um die Ausfälle einzelner Sensorsysteme tolerieren zu können. Ohne die Möglichkeit zu vernachlässigen, als zusätzlichen Sensor ein hoch-genaues satellitengestütztes System (DGPS) in Kombination mit einer hochgenauen digitalen Karte zu verwenden [Wal09], ist es wünschenswert, weitere Systeme zur landmarkenbasierten Lokalisation zur Verfügung zu haben, um die Redundanz signifikant zu steigern.

Eine vielversprechende Möglichkeit, um die Redundanz in der Positionsbestimmung zu verbessern, besteht in der Verwendung einer lidarbasierten Fahrstreifenenerkennung. Im Gegensatz zu einem kamerabasierten System, arbeitet ein Lidar nach dem *time-of-flight*

---

<sup>2</sup>Anwendung zur videobasierten Spurverlassenswarnung im BMW 5er ab dem Jahr 2007.




Abbildung 1.6: Beispiel für mögliche Fehlerquellen einer kamerabasierten Fahrstreifenerkennung. In (a), Gegenlichtblendung hervorgerufen durch schnellen Wechsel der Beleuchtungsverhältnisse bei Durchfahren einer Unterführung. In (b), Verdeckung der linken Markierung durch Schattenwurf. In (c), schlechte Sichtbarkeit aller Fahrbahnmarkierungen durch Spiegelung und Einsatz von Typ II Markierungen (Abschnitt 3.1.3). In (d), eine durch Schattenwurf erzeugte „Geistermarkierung“.

Messprinzip (siehe Abschnitt 3.2.1). Ein Lidar zählt zu der Klasse der *aktiven* Sensoren und ist somit unempfindlich gegenüber Störeinflüssen, die ihren Ursprung, wie zum Beispiel beim Schattenwurf, in dem Zusammenspiel der Szenerie mit der Umgebungsbeleuchtung haben. Darüber hinaus ermöglicht der Einsatz von Laserscannern mit ihrem großen horizontalen Sichtfeld, auch weiter entfernte Fahrstreifen zu erfassen. Dies ist dann von großem Nutzen, wenn neben der Position innerhalb eines Fahrstreifens, auch die relative Position auf der Fahrbahn (welcher Fahrstreifen) bestimmt werden soll.

In der Literatur finden sich vergleichsweise relativ wenige Arbeiten, die sich mit einer lidarbasierten Fahrstreifenschätzung befassen. Nennenswerte Arbeiten sind [DKF<sup>+</sup>05, Rey06, OT06, KP08, LRW<sup>+</sup>09] und [TL10]. So schreiben McCall und Trivedi in ihrer bekannten Veröffentlichung „Video-based lane estimation and tracking for driver assistance: survey, system, and evaluation“ [MT06] aus dem Jahr 2006:

*„LASER RADAR sensors are useful in rural areas for helping to resolve road boundaries. . .but fail on multilane roads without the aid of vision data.“* [MT06]

Obwohl sich bis zum heutigen Zeitpunkt weitere Arbeiten dieser Thematik gewidmet haben, hat sich relativ wenig an dem Inhalt der eben zitierten Aussage verändert und es bleibt eine ganze Reihe von Fragen unbeantwortet. So gilt es zum Beispiel zu klären, ob der Einsatz einer lidarbasierten Fahrstreifenerkennung eine „echte“ Alternative zu einem videobasierten System darstellt. Dies beinhaltet sowohl die Genauigkeit als auch die Verfügbarkeit eines solchen Systems. Darüber hinaus ist es im Kontext von hochautomatisierten Fahrfunktionen wichtig, ob eine Kombination der beiden heterogenen Systeme eine echte diversitäre Redundanz bietet. Es gilt daher zu klären, ob ein lidarbasiertes System in den Fällen zuverlässig funktioniert, in denen ein kamerabasiertes System versagt.

Diese Fragestellungen werden in dem folgenden Abschnitt aufgegriffen, um die genaue Zielsetzung dieser Arbeit zu definieren.

## 1.2 Zielsetzung

Das Ziel dieser Arbeit liegt in der Verbesserung der lateralen Positionsbestimmung für zukünftige hochautomatisierte Fahrfunktionen. Hauptziel ist dabei die Unterstützung einer der wichtigsten Teilaspekte automatisierter Fahrfunktionen, die automatisierte Querführung. Im Fokus der Arbeit steht dabei weniger die Verbesserung der Genauigkeit in der Positionsbestimmung, die durch verfügbare kamerabasierte Systeme in der notwendigen Güte bereits erbracht werden kann [Rei96], sondern vielmehr die Verbesserung der Robustheit durch die Schaffung von diversitärer Redundanz. Um dieses Ziel zu erreichen, ist der Fokus dieser Arbeit auf das vielversprechende „Light Detection and Ranging“ (Lidar) Messprinzip gerichtet.

### 1.2.1 Schwerpunkte dieser Arbeit

Ein Ansatz zur Unterstützung automatisierter Querführungsaufgaben, der in Abschnitt 1.1.3 bereits vorgestellt wurde, ist die Verwendung eines Lidar-Sensors zur Detektion von Fahrbahnmarkierungen. Es gilt zu prüfen, ob eine lidarbasierte Erkennung von Fahrbahnmarkierungen prinzipiell geeignet ist, eine Fahrzeugquerführung auf Autobahnen und autobahnähnlichen Straßen zu ermöglichen. Ferner gilt es zu untersuchen, ob ein solches System in sinnvoller Weise zur Unterstützung eines kamerabasierten Systems verwendet werden kann. In dieser Arbeit werden mit Blick auf hochautomatisierte Fahrfunktionen folgende Schwerpunkte und wissenschaftliche Fragestellungen bearbeitet:

- Genaue Betrachtung der Eigenschaften moderner Fahrbahnmarkierungen zur Abschätzung der allgemeinen Umsetzung einer lidarbasierten Fahrstreifenerkennung
- Entwicklung eines echtzeitfähigen und robusten Gesamtsystems zur Extraktion, Klassifikation und Verfolgung von Fahrbahnmarkierungen auf Basis von Messwerten eines Lidars
- Untersuchung der erzielbaren Genauigkeit und Verfügbarkeit eines Gesamtsystems zur lidarbasierten Fahrstreifenschätzung im Vergleich zu einem videobasierten System

- Betrachtung der allgemeinen Fragestellung, ob eine lidarbasierte Erkennung in Kombination mit einer videobasierten Erkennung von Fahrbahnmarkierungen, einen echten Mehrwert für ein Gesamtsystem zur Fahrstreifenschätzung bietet

Neben Fahrbahnmarkierungen wird in dieser Arbeit noch eine weitere Kategorie von Landmarken zur Unterstützung von Querführungsaufgaben untersucht: Kontinuierliche Fahrbahnbegrenzungen wie beispielsweise Leitplanken (Abbildung 1.6(c)), Betonabweiser (Abbildung 1.6(b)) und Tunnelwände. Im Gegensatz zu Fahrbahnmarkierungen können diese, ohne Vorwissen über die Position mit Bezug auf die einzelnen Fahrstreifen, nicht direkt für eine Querführungsunterstützung eingesetzt werden. Kann deren Position allerdings durch zeitliche Beobachtung oder durch eine digitale Kartenbasis in Bezug zu einem geeigneten Referenzkoordinatensystem gesetzt werden, so lassen sich auch Fahrbahnbegrenzungen zur Steigerung der Redundanz verwenden. Insbesondere in Szenarien, in denen eine satellitengestützte Positionsbestimmung durch Sichtverdeckung nicht möglich ist, ist die zusätzliche Verwendung von Fahrbahnbegrenzungen durchaus sinnvoll, um auf den Ausfall von Fahrbahnmarkierungen reagieren zu können.

Diese Arbeit konzentriert sich dabei auf die robuste Detektion von Fahrbahnbegrenzungen und wie bei der Erkennung von Fahrbahnmarkierungen (Abschnitt 1.1.3), auf das Ableiten eines parametrischen Modells, welches anschließend für die Unterstützung von Querführungsaufgaben verwendet werden kann. Ein Überblick und Vergleich der in der Literatur bestehenden Verfahren zur Erkennung von Fahrbahnbegrenzungen erfolgt in Abschnitt 5.

Neben der Positionierung, widmet sich das an die Einleitung anschließende Kapitel zunächst der Abstraktion des Fahrumfelds anhand von Belegungskarten, welche als Grundlage für die bereits erwähnten Positionierungsaufgaben dienen. Ziel ist es zunächst eine robuste, echtzeitfähige und von den Eingabedaten laufzeitunabhängige Basis für die in dieser Arbeit entwickelten Algorithmen der Lokalisation zu schaffen.

### 1.2.2 Randbedingungen dieser Arbeit

Für diese Arbeit werden zu Beginn einige Randbedingungen festgelegt, auf Basis derer in den folgenden Kapiteln die spezifischen Systemanforderungen abgeleitet werden können. Dies ist zum einen notwendig, um die genauen Systemanforderungen, die sich im realen Straßenverkehr je nach Szenario erheblich unterscheiden können, festzulegen, zum anderen ist dieses erforderlich, um etwaige Rahmenbedingungen wie zum Beispiel die Echtzeitfähigkeit des Gesamtsystems zu definieren.

Im Fokus dieser Arbeit steht die hochautomatisierte Querführung auf Autobahnen oder autobahnähnlichen Straßen ohne Querverkehr bei Geschwindigkeiten bis 130 km/h. Sondersituationen wie zum Beispiel Autobahnkreuze oder Ab- und Auffahrten werden nicht betrachtet. Widrige Witterungseinflüsse, die wie extrem starker Regen, Nebel oder Schnee in erster Linie negative Einflüsse auf die fahrumfelderfassende Sensorik haben, werden ebenfalls nicht berücksichtigt. Ebenso werden keine Ausfallwahrscheinlichkeiten technischer Bauteile „Failure In Time“ modelliert.



Abbildung 1.7: Die beiden Versuchsfahrzeuge „Caroline“ (a) und „Leonie“ (b) der TU Braunschweig [WSM10]. Das Fahrzeug „Caroline“ wurde für die DARPA Urban Challenge entworfen, wohingegen das Fahrzeug „Leonie“ für einen Einsatz im öffentlichen Straßenverkehr konzipiert wurde.

Um die Zulassungskriterien eines Fahrzeugs auf öffentlichen Straßen zu erfüllen und um die „Design-Konformität“ in einer möglichen Serienfertigung zu wahren, erhebt diese Arbeit den Anspruch, dass die verwendete Sensorik vollständig in das Fahrzeug integrierbar sein muss. Die betrifft sowohl das Interieur als auch das Exterieur des Fahrzeugs. Um den Leser für die sich daraus ergebenden Einschränkungen zu sensibilisieren, werden die Unterschiede zwischen den Fahrzeugen der DARPA Urban Challenge (Abbildungen 1.2(b) und 1.7(a)), dem von der TU Braunschweig zur autonomen Umrundung des Braunschweiger Stadtrings verwendeten Fahrzeug „Leonie“ (Abbildung 1.7(b)) und zwischen einem in dieser Arbeit verwendeten Versuchsfahrzeug (Abbildung 1.8) aufgezeigt. Betrachtet man zuerst die Fahrzeuge der DARPA Urban Challenge (Abbildungen 1.2(b) und 1.7(a)), so wird schnell ersichtlich, dass ein solch extensiver Einsatz von Sensorik im öffentlichen Straßenverkehr allein schon aus Gründen der Sicherheit anderer Verkehrsteilnehmer nicht möglich ist. Im Vergleich dazu das Fahrzeug „Leonie“ (Abbildung 1.7(b)), welches für die autonome Umrundung des Braunschweiger Stadtrings [WSM10] konzipiert wurde. Leistungsstärkster aber auch auffälligster Sensor ist ein 360° erfassender Laserscanner auf dem Dach des Versuchsfahrzeugs. Auch wenn dieses Fahrzeug im Vergleich zu denen bei der Urban Challenge eingesetzten Fahrzeugen die Zulassungskriterien für den Straßenverkehr erfüllt [WSM10], so ist es doch noch weit entfernt von einem Fahrzeug, welches den oben festgelegten Kriterien entspricht.

Im Gegensatz zu den eben vorgestellten Forschungsfahrzeugen, bei denen es möglich ist das Ziel der Automatisierung mit „beliebiger“ Sensorkonfiguration zu erreichen, ist dieses bei einem Serienfahrzeug nicht möglich. Abbildung 1.8 zeigt ein in dieser Arbeit verwendetes Versuchsfahrzeug. Die Anordnung der fahrumfelderfassenden Sensorik ist ohne Vorwissen äußerst schwer zu erkennen. Für einen Überblick über die verwendete Sensorik und deren Verbauort sei der interessierte Leser auf Kapitel 6.1.2 verwiesen. Aus den eben erwähnten Einschränkungen lassen sich durchaus auch wissenschaftliche Anforderungen ab-



Abbildung 1.8: BMW 5er der Baureihe F10 als Versuchsfahrzeug der BMW Group Forschung und Technik. Das Versuchsfahrzeug erfüllt sowohl die Zulassungsvoraussetzungen für den öffentlichen Straßenverkehr als auch die „Design-Konformität“ im Kontext einer Serienfertigung.

leiten, die in der Regel damit verknüpft sind, dass die zur Verfügung stehenden Sensoren in ihrer Leistungsfähigkeit und ihrem Verbauort stärkeren Einschränkungen unterworfen sind.

Der Begriff der Echtzeitfähigkeit wird wie folgt definiert: Die gesamte Datenverarbeitung sollte innerhalb von 40 ms abgeschlossen sein, um eine Sensor-Taktrate von 25 Hz verarbeiten zu können. Grundsätzlich gilt, dass die Verarbeitung, wenn möglich, weniger als die vorher angegebene maximale Zeit betragen sollte, um die Totzeiten in einem darauf aufbauendem Regel- oder Fusionssystem zu minimieren. Als Nebenbedingung wird zusätzlich festgelegt, dass die entwickelten Algorithmen zu einem möglichst hohen Grad parallelisierbar sein sollten, um eine Verwendung auf Automotive tauglichen Architekturen wie zum Beispiel System-On-Chip (SOC), FPGA und DSP basierten embedded Plattformen zu ermöglichen.

Abschließend wird noch die Genauigkeit der für eine automatisierte Fahrzeugquerführung benötigten Zustandsgrößen, Ablage  $y$ , relative Ausrichtung des Fahrzeugs  $\psi$  und der Krümmung  $c$  festgelegt. Mag die Definition an dieser Stelle für den Leser zunächst willkürlich erscheinen, so ist diese mit dem Vorwissen über den Einsatz auf autobahnähnlichen Straßen jedoch zweckmäßig und sinnvoll. Für eine detaillierte Diskussion sei der Leser auf Kapitel 3.3 verwiesen, in dem die Vor- und Nachteile unterschiedlicher Modelle zur Beschreibung des Straßenverlaufs ausführlich diskutiert werden.

In der Literatur finden sich relativ wenige bis gar keine Informationen über die Genauigkeit dieser Größen im Bezug auf einen automatisierte Querführung. Lediglich für die

Parameter	$\sigma_{\max}$
Ablage $y$ (m)	0.2
Ausrichtung $\psi$ ( $^\circ$ )	0.25
Krümmung $c$ ( $\text{m}^{-1}$ )	$0.3 \times 10^{-3}$

Tabelle 1.1: Geforderte Genauigkeit in der Ablage, Ausrichtung und Krümmung.

Ablage  $y$  findet sich in [SW07] ein Richtwert, welcher mit 0.25 m angegeben wird. Die für eine Querführung erforderliche Genauigkeit wird in Form der maximalen Standardabweichung  $\sigma_{\max}$  für diese Arbeit in Tabelle 1.1 festgelegt. Diese Anforderungen gelten dabei sowohl für die Fahrstreifenschätzung als auch für die Erkennung von Fahrbahnbegrenzungen.

## 1.3 Gliederung und Aufbau der Arbeit

Das folgende Kapitel widmet sich zunächst der effizienten Erstellung von Belegungskarten auf der GPU.

Das daran anschließende Kapitel, Kapitel 3, behandelt ausführlich die Fahrstreifen-erkennung auf Basis von Messwerten eines Lidar-Sensors. Dies beinhaltet sowohl den Vergleich bestehender Verfahren sowie die Entwicklung eines neuen Verfahrens zur Extraktion von Fahrbahnmarkierungen und die Betrachtung der für eine erfolgreiche Detektion zu beachtenden externen Gegebenheiten wie beispielsweise der Reflexionseigenschaften moderner Fahrbahnmarkierungen.

Aufbauend auf den Erkenntnissen der lidarbasierten Fahrstreifen-erkennung, folgt in Kapitel 4 die Fusion mit einem videobasierten System zur Fahrstreifen-erkennung.

Kapitel 5 widmet sich der modellbasierten Fahrbahn-erkennung.

Anschließend erfolgt in Kapitel 6 eine umfassende Evaluierung und Systembewertung. Im Fokus dieser Bewertung stehen dabei die Genauigkeit, die Verfügbarkeit und der Rechenzeitbedarf der zuvor vorgestellten Verfahren.

Kapitel 7 fasst die in dieser Arbeit behandelten Themenschwerpunkte und gewonnenen Erkenntnisse zusammen und gibt einen Ausblick für mögliche Folgearbeiten.



---

## Effiziente Berechnung von Belegungskarten auf der GPU

---

Eine der größten Herausforderungen für zukünftige Fahrerassistenzsysteme besteht in der Abstraktion des Fahrumfelds (Szenerie) durch geeignete Modelle. Mit einem zunehmenden Automatisierungsgrad müssen die eingesetzten Modelle in der Lage sein, die durch zeitlich aufeinander folgende Messdaten (meistens 2D oder 3D Punktwolken) gegebene Szenerie mit hoher Präzision abzubilden. Steht bei heutigen Assistenzsystemen die Erfassung anderer Verkehrsteilnehmer (dynamische Objekte) und damit auch deren Modellierung im Vordergrund, so müssen zukünftige automatisierte Systeme auch über detaillierte Information des statischen Umfeldes verfügen, um etwa den befahrbaren Korridor zu ermitteln oder die Genauigkeit und die Verfügbarkeit in der Positionsbestimmung zu erhöhen (landmarkenbasierte Lokalisation).

Können die zu modellierenden Objekte wie beispielsweise bei der Verfolgung dynamischer Objekte leicht durch einfache geometrische Primitive approximiert werden, ist die Verwendung einer *merkmalsbasierten* Repräsentation naheliegend [TBF05]. Die Modellierung und auch Verfolgung komplexer statischer Objekte mit unterschiedlicher Form und Ausdehnung auf Basis von geometrischen Primitiven, wie beispielsweise Rechtecken, ist jedoch bedeutend schwieriger. Abbildung 2.1 schematisiert diese Problematik für eine Punktwolke mit 2D Messwerten. Zuerst werden auf Basis eines beliebigen Gruppierungskriterium aus dem Messvektor  $\mathbf{z}_t$  drei Objekthypothesen erstellt (Abbildung 2.1(a)). Es ist zu erkennen, dass bei dem ersten Objekt durch Approximation mit einem Rechteck ein relativ großer Modellfehler entsteht<sup>1</sup>. Im nächsten Zyklus erfolgt eine weitere Messung (Abbildung 2.1(b)). Neben dem bereits bestehenden Modellfehler, ergibt sich nun zusätzlich das Problem der Zuordnung der verrauschten Messwerte zu den Objekthypothesen des vorherigen Zeitpunktes.

Um diese Limitierung zu umgehen, kann das Umfeld alternativ durch eine sogenannte

---

<sup>1</sup>Zur Veranschaulichung wurde das Rechteck als geometrisches Primitiv gewählt. Bei Verwendung anderer Primitive ließe sich der Fehler reduzieren.




Abbildung 2.1: Die Abbildungen (a) und (b) zeigen die Problematik bei der merkmalsbasierten Modellierung und Verfolgung komplexer statischer Objekte auf Basis eines Rechtecks als geometrisches Primitiv. Der aktuelle Messvektor zum Zeitpunkt  $t$  und  $t + 1$  wird als  $z_t$  beziehungsweise  $z_{t+1}$  bezeichnet.

Belegungskarte repräsentiert werden, welche zu den *ortsbezogenen* Kartenrepräsentationen zählt [TBF05]. Wurden diese bis in die 1990er Jahre vorwiegend im Bereich der Innenraum Robotik eingesetzt, bilden diese heute, bedingt durch die gestiegene Rechenleistung und die Möglichkeit Karten mit großer Abdeckung zu erstellen, ein „Standardvorgehen“ bei der Modellierung der statischen Szenerie. Die Anwendung von Belegungskarten ist nicht durch einen bestimmten Sensortyp limitiert und es existieren in der Literatur eine Vielzahl von Publikationen für unterschiedlichste Anwendungen. Als Beispiele zu nennen sind:

- Freiraum- und Straßenverlaufsschätzung mit Lidar [WSD07, HvW08, Eff09, SMDW10], Radar [MD09, DKL10] und Stereo [BFM07, PYL10, LDG<sup>+</sup>10].
- Lokalisierung und Kartenerstellung mit Lidar [BGFM07, GSB05, LMT07, LT10] und Stereo [ONDM09, LHK11].
- Erkennung und Verfolgung dynamischer Objekte mit Lidar [CTLM06, Wan04, VAA07] und Stereo [LHK11, VNO10].
- Datenfusion Lidar/Radar [GAVA08, PVB<sup>+</sup>09, BH10] und Lidar/Kamera [BA10].

Prinzipiell haben alle Belegungskarten gemein, dass die Fläche (2D) oder das zu modellier- te Volumen (3D) durch eine endliche Anzahl an Gitterzellen – meist in quadratischer Form – abgebildet wird. Repräsentiert der Zustand einer Zelle eine Belegungswahrscheinlichkeit, wird von einer probabilistischen Belegungskarte gesprochen [TBF05]. Das bekannteste Ver- fahren zur Erstellung von Karten aus mit Unsicherheit behafteten Messdaten ist das von

Elfes vorgestellte „Occupancy Grid Framework“ [Elf89], bei dem die Wahrscheinlichkeit für die Belegung jeder Zelle mit einem binären Bayes Filter geschätzt wird.

## 2.1 Binärer Bayes Filter mit statischem Zustandsvektor

Sei  $\mathbf{m}$  eine Belegungskarte und  $m_i$  eine Zelle mit Index  $i$ . In einer probabilistischen Belegungskarte korrespondiert jede Zelle  $m_i$  mit einem binären Wert der bestimmt, ob eine Zelle frei, oder belegt ist. Die Notation  $p(m_i = 1)$  oder  $p(m_i)$  steht für die Belegung der Zelle  $i$ .

Ziel des probabilistischen Frameworks ist es, die a-posteriori Wahrscheinlichkeitsverteilung der Belegungskarte  $\mathbf{m}$  unter Berücksichtigung aller bis zum Zeitpunkt  $t$  eingegangenen Messwerte  $\mathbf{z}_1 \dots \mathbf{z}_t$  und Positionen  $\mathbf{x}_1 \dots \mathbf{x}_t$  zu schätzen.

$$p(\mathbf{m} | \mathbf{z}_1 \dots \mathbf{z}_t, \mathbf{x}_1 \dots \mathbf{x}_t) \quad (2.1)$$

Die Schwierigkeit bei Lösung dieser Gleichung besteht in der hohen Dimensionalität aller möglicher Zustandskombinationen in  $\mathbf{m}$ . Für eine Karte mit  $N$  Zellen ergeben sich  $2^N$  mögliche Zustände, welche bei üblicherweise verwendeten Größen von Belegungskarten nicht in akzeptabler Zeit berechnet werden können. Um diese Problematik zu umgehen, werden in [Elf89] zwei Annahmen getroffen. Erstens, der Zustand jeder Zelle  $m_i$  ist unabhängig von den Zuständen aller anderen Zellen und wird einzeln bestimmt (*independence assumption*)<sup>2</sup>:

$$p(m_i | \mathbf{z}_1 \dots \mathbf{z}_t). \quad (2.2)$$

Gleichung 2.2 lässt sich nach Anwendung des Bayes'schen Gesetzes schreiben als:

$$p(m_i | \mathbf{z}_1 \dots \mathbf{z}_t) = \frac{p(\mathbf{z}_t | \mathbf{z}_1 \dots \mathbf{z}_{t-1}, m_i) p(m_i | \mathbf{z}_1 \dots \mathbf{z}_{t-1})}{p(\mathbf{z}_t | \mathbf{z}_1 \dots \mathbf{z}_{t-1})}. \quad (2.3)$$

Zusätzlich wird angenommen, dass der Zustand  $m_i$  vollständig ist und  $\mathbf{z}_1 \dots \mathbf{z}_{t-1}$  zum Zeitpunkt  $t$  keine zusätzliche Information über  $m_i$  beinhalten (bedingte Unabhängigkeit). Dies impliziert, dass in der Karte vorkommende dynamische Objekte als Rauschen betrachtet werden:

$$p(\mathbf{z}_t | \mathbf{z}_1 \dots \mathbf{z}_{t-1}, m_i) = p(\mathbf{z}_t | m_i). \quad (2.4)$$

Die Annahme aus Gleichung 2.4 erlaubt es Gleichung 2.3 zu formulieren als:

$$p(m_i | \mathbf{z}_1 \dots \mathbf{z}_t) = \frac{p(\mathbf{z}_t | m_i) p(m_i | \mathbf{z}_1 \dots \mathbf{z}_{t-1})}{p(\mathbf{z}_t | \mathbf{z}_1 \dots \mathbf{z}_{t-1})}. \quad (2.5)$$

<sup>2</sup>Die Positionen  $\mathbf{x}_1 \dots \mathbf{x}_t$  werden in den folgenden Gleichungen aus Gründen der Vereinfachung nicht mehr explizit aufgeführt.

Nach Anwendung des Bayes'schen Gesetzes auf den Term  $p(\mathbf{z}_t | m_i)$  folgt:

$$p(m_i | \mathbf{z}_1 \dots \mathbf{z}_t) = \frac{p(m_i | \mathbf{z}_t) p(\mathbf{z}_t) p(m_i | \mathbf{z}_1 \dots \mathbf{z}_{t-1})}{p(m_i) p(\mathbf{z}_t | \mathbf{z}_1 \dots \mathbf{z}_{t-1})}. \quad (2.6)$$

Nach der Annahme, dass für alle Zellen für die zum aktuellen Zeitpunkt  $t$  kein Messupdate vorliegt  $p(m_i) = 0.5$  gilt und weiteren Umformungen, ergibt sich die Belegungswahrscheinlichkeit einer Zelle  $m_i$  durch:

$$l_i^t = \frac{p(m_i | \mathbf{z}_1 \dots \mathbf{z}_t)}{1 - p(m_i | \mathbf{z}_1 \dots \mathbf{z}_t)} = \underbrace{\frac{p(m_i | \mathbf{z}_t)}{1 - p(m_i | \mathbf{z}_t)}}_{\text{Messupdate}} \underbrace{\frac{p(m_i | \mathbf{z}_1 \dots \mathbf{z}_{t-1})}{1 - p(m_i | \mathbf{z}_1 \dots \mathbf{z}_{t-1})}}_{\text{Vorheriger Zustand}} \quad (2.7)$$

$$p(m_i | \mathbf{z}_1 \dots \mathbf{z}_t) = \frac{l_i^t}{1 + l_i^t} \quad (2.8)$$

Für die vollständige Herleitung von Gleichung 2.8 sei der Leser auf [Thr03] oder [WSD07] verwiesen.

Gleichung 2.8 definiert einen einfachen rekursiven Filter, bei dem die Belegungswahrscheinlichkeit für jede Zelle  $m_i$  zum aktuellen Zeitpunkt  $t$  durch eine Multiplikation der durch  $\mathbf{z}_t$  ermittelten Belegungswahrscheinlichkeit (*Innovation*) und der alten Belegungswahrscheinlichkeit  $l_i^{t-1}$  geschätzt wird. Die eigentliche Schwierigkeit bei dem Messupdate besteht nun darin, welche Zellen  $m_i$  und wie diese in der Karte durch die aktuelle Messung  $\mathbf{z}_t$  beeinflusst werden. Anders ausgedrückt, welchen Wert hat  $p(m_i | \mathbf{z}_t)$  für jeden Index  $i$ ?

Diese Fragestellung ist von zentraler Bedeutung bei der Erstellung von Belegungskarten und wird im folgenden Abschnitt zu „Problemstellung und Motivation“ ausführlich diskutiert.

## 2.2 Problemstellung und Motivation

In dem vorangegangenen Abschnitt wurde die Integration der aktuellen Messung als eines der Kernprobleme bei der Erstellung von Belegungskarten definiert. Die Integration der Messwerte erfolgt häufig auf Basis eines sogenannten *inversen* Sensormodells [TBF05], welches die neue Belegungswahrscheinlichkeit jeder im Sichtbereich des Sensors liegenden Zellen unter Einbeziehung der eigentlichen Messungen (beispielsweise Winkel und Entfernung), der jeweiligen Messunsicherheit und weiteren intrinsischen Sensorcharakteristiken bestimmt. Um beispielsweise die durch eine einzelne Messung  $z_t^k$  (2.9) in einer kartesischen Belegungskarte  $\mathbf{m}$  affizierten Zellen zu bestimmen, wird in der Literatur häufig der Bresenham Algorithmus [Bre65] verwendet. Beispiele hierfür sind [TBF05, WSD07, VAA07, Eff09, LWGE10] und [VNO10].

$$\mathbf{z}_t = z_t^1, \dots, z_t^K \quad (2.9)$$




Abbildung 2.2: Moiré Effekt hervorgerufen durch ein auf dem Bresenham Algorithmus basierendem inversen Sensormodell. Die Belegungswahrscheinlichkeit der Zellen  $p(m_i)$  ist als Graustufenbild kodiert, wobei  $p(m_i) = 0$  als Weiß und  $p(m_i) = 1$  als Schwarz dargestellt ist.

Die Grundidee dieses Vorgehens ist, alle zwischen einem durch die Messung  $z_t^k$  und dem Sensor definierten „Sichtstrahl“ liegenden Zellen mit  $p(m_i) \leq 0.5$  (Freiraum) zu belegen. Zellen, denen eine Zieldetektion direkt zugewiesen wird, werden analog mit  $p(m_i) \geq 0.5$  (Hindernis) belegt. Für eine detaillierte Übersicht über die Umsetzung von auf „Ray-Casting“ basierten inversen Sensormodellen sei auf [Zit04] verwiesen. Abbildung 2.2 zeigt ein Beispiel für eine solche Belegungskarte. Es ist zu erkennen, dass durch die Modellierung mittels des Bresenham Algorithmus mit zunehmender Entfernung starke Rastereffekte auftreten – der sogenannte Moiré Effekt. Es entstehen große Lücken, die von einem Messupdate ausgeschlossen werden. Dies betrifft sowohl die entlang des Freiraums (weiß) angrenzenden Zellen, als auch die Zellen in der unmittelbaren Umgebung einer erfolgreichen Zieldetektion (schwarz). Der Moiré Effekt entsteht dabei durch die Annahme einer konstanten Strahbreite innerhalb des inversen Sensormodells, welche mit der Größe der Zellen korrespondiert. Diese Annahme widerspricht im Wesentlichen der physikalischen Ausbreitung von Wellen und damit dem Messprinzip aktiver als auch passiver Sensoren.

Ein zusätzlicher Effekt, der in Abbildung 2.2 nicht direkt sichtbar ist, ist die ebenfalls durch die Annahme einer festen Strahlaufweitung erzeugte wiederholte Aktualisierung von Zellen, die sich in der Nähe des Ursprungs eines Sensorkoordinatensystems befinden. Ein vereinfachtes Beispiel stellt die erste Zelle in einer Belegungskarte dar, die sich unmittelbar am Ursprung des Sensorkoordinatensystems befindet. Bei  $\mathbf{z}_t$  mit  $K$  Messungen (siehe Gleichung 2.9) wird diese durch  $K$  Messinnovation beeinflusst. Übertragen auf alle anderen Zellen bedeutet dies, dass die Belegungswahrscheinlichkeit jeder Zelle in direkter Abhängigkeit zu der räumlichen Position einer Zelle steht. In der Literatur existieren einige Ansätze, beispielsweise [And09, SMDW10, BH10], die zumindest darauf zielen, den

Moiré Effekt durch die Modellierung eines erweiterten Sensormodells zu reduzieren, jedoch nicht den zweiten beschriebenen Effekt, die ungewollte Überlagerung von Messinnovationen innerhalb der Belegungskarte, verhindern.

Eine weitere Schwierigkeit ist die Modellierung von Messunsicherheiten innerhalb des inversen Sensormodells. So ist es beispielsweise für eine Belegungskarte, die als Basis für die Kartenerstellung oder Fahrzeug-Eigenlokalisierung dient, nicht sinnvoll, die einzelnen Messungen lediglich den durch den Bresenham Algorithmus bestimmten Zellen zuzuordnen, sondern die Wahrscheinlichkeit und damit die Messunsicherheit auf mehrere Zellen zu verteilen. Die Unsicherheit um die Ziel-Messung wird häufig als zweidimensionale Normalverteilung modelliert, um dann die Belegungswahrscheinlichkeiten im korrespondierenden  $3\sigma$  Bereich der Verteilung dementsprechend anzupassen [TBF05, SMDW10, BH10]. Dies findet jedoch keine Anwendung bei den Zellen, die entlang des bis zu einem Ziel bestehenden Freiraums liegen.

Neben möglichen negativen theoretischen Einflüssen der auf dem Bresenham Algorithmus basierenden inversen Sensormodellen, ergeben sich mit Blick auf einen möglichen automotiven Serieneinsatz von Belegungskarten auch einige implementationsspezifische Problemstellungen. Die Berechnung einer Belegungskarte in Echtzeit stellt durch ihre große Anzahl an arithmetischen Operationen selbst für zukünftige im automotiven Bereich verfügbare Hardwarelösungen eine anspruchsvolle Aufgabe dar. Um diese Aufgabe zu bewältigen, ist eine möglichst effiziente Parallelisierung unabdingbar. Betrachtet man auf „Ray-Casting“ basierte Methoden wie beispielsweise den Bresenham Algorithmus, so erweist sich die Überlagerung von Messungen im Nahbereich für eine mögliche Parallelisierung als problematisch. Hierbei kommt es zwangsläufig durch mehrfachen Speicherzugriff auf die selbe Position zu Lese-nach-Schreibe-Konflikten (engl. „Read-After-Write“, RAW) und Schreib-nach-Schreibe-Konflikten (engl. „Write-After-Write“, WAW) die durch eine Serialisierung gelöst werden müssen [BU10]. Gleiches gilt für die Modellierung von Messunsicherheiten, die mehrere Zellen umfassen.

In den folgenden Abschnitten wird ein auf dem Grafikprozessor (engl. „Graphics Processing Unit“, GPU) basiertes Verfahren vorgestellt, welches eine extrem schnelle Berechnung von Belegungskarten ohne RAW und WAW Konflikte ermöglicht. Der Algorithmus bedient sich wesentlichen Elementen moderner Grafikprozessoren, um ein im kartesischen Raum durchgeführtes „Ray-Casting“ zu umgehen und um in geschickter Weise die bestehende Messunsicherheit der Ziel- als auch Freiraumbereiche zu modellieren.

## 2.3 Grundlagen der Grafikkartenprogrammierung

In diesem Abschnitt wird kurz auf die Aspekte der GPU-Programmierung eingegangen. Dies umfasst einen Vergleich zwischen dem Aufbau einer klassischen CPU und GPU sowie die wesentlichen Unterschiede, die bei der effizienten Umsetzung von Algorithmen auf einer GPU beachtet werden müssen. Im zweiten Teil wird das von der NVIDIA Corporation [NVI11b] eingeführte Konzept zur Programmierung von GPU's, das CUDA Framework, vorgestellt.



Abbildung 2.3: Vergleich der Architektur einer CPU mit einer GPU [NVI11b]. Der wesentlichste Unterschied zu einer CPU besteht in der um ein Vielfaches größeren Anzahl an arithmetisch-logischen Einheiten (ALU's).

### 2.3.1 Hardwarearchitektur

Angetrieben durch immer höhere Anforderungen realistischer 3D Computerspiele, hat sich die heutige GPU zu einem hoch-parallelen und extrem leistungsstarken Mehrkernrechner entwickelt, der die Rechenleistung (in FLOPS) moderner CPU's um ein Vielfaches übertrifft [NVI11b]. Während abseits der Anwendung für Computerspiele GPU's in der Vergangenheit überwiegend im wissenschaftlichen Bereich für rechenintensive Simulationsprozesse eingesetzt wurden, so finden diese heute bereits zur Darstellung von Multimedia und Navigationsinhalten ihren Weg ins Automobil [NVI]. Der Grund für diesen Leistungsunterschied liegt in der Architektur einer GPU. Während eine CPU auf die sequentielle Stapelverarbeitung und Berücksichtigung komplexer Kontrollflüsse spezialisiert ist, ist die GPU auf die Vektorverarbeitung von extrem datenintensiven und sich wiederholenden arithmetischen Operationen ausgelegt. Abbildung 2.3 schematisiert diesen Unterschied. Im Gegensatz zu einer CPU sind bei einer GPU mehrere ALU's einer gemeinsamen Kontrolleinheit zugeordnet. In diesem Unterschied besteht allerdings zugleich eine der wesentlichen Einschränkungen bei der effizienten Nutzung der GPU für reguläre Berechnungsaufgaben. Um einen größeren arithmetischen Durchsatz zu erzielen, ist die Architektur nach dem SIMD (engl. „Single Instruction Multiple Data“) Prinzip ausgelegt<sup>3</sup>. In der in Abbildung 2.3 schematisierten GPU, ist eine Kontrolleinheit (gelb) für jeweils 16 arithmetisch-logische Einheiten (grün) zuständig. Führen alle 16 denselben arithmetischen oder logischen Befehl, beispielsweise eine Addition, auf unterschiedlichen Daten aus, so wird die maximal mögliche Parallelität erreicht. Unterscheiden sich jedoch die arithmetischen oder logischen Anweisungen, beispielsweise hervorgerufen durch eine Fallunterscheidung im Programmkontrollfluss, müssen diese durch die Kontrolleinheit (gelb) serialisiert werden. Die Folge ist, dass der Durchsatz sinkt.

Eine der Hauptaufgaben bei der GPU-Programmierung besteht demzufolge darin, dass dieser Einschränkung durch auf der GPU ausgeführte Algorithmen Rechnung getragen

<sup>3</sup>Es existiert auch eine SIMD Erweiterung in einigen CPU's, wie beispielsweise der MMX Befehlssatz, jedoch ist die Anzahl an SIMD ALU's um ein Vielfaches geringer als bei einer GPU.




Abbildung 2.4: Logischer Aufbau der „Compute Unified Device Architecture“ (CUDA). Das CUDA Framework kapselt die physikalische GPU Speicher- und Multiprozessorarchitektur in den logischen Einheiten Block und Thread

wird. Neben dieser Einschränkung existieren weitere Prinzipien, wie zum Beispiel die Anordnung von Speicherzugriffen, die es zu beachten gilt. Für einen detaillierten Überblick ist der interessierte Leser auf [NV11a] verwiesen.

Allerdings, bieten GPU's im Vergleich zu Technologien wie beispielsweise FPGA's (engl. „Field Programmable Gate Array“) einige entscheidende Vorteile. Dies sind zum einen die durch sehr große Stückzahlen äußerst niedrigen Produktionskosten. Zum anderen die einfachere Skalierbarkeit und die stark vereinfachte Entwicklung und Portierung von Algorithmen durch eine einheitliche Programmierschnittstelle. Der folgende Abschnitt stellt eine der am häufigsten verwendeten Programmierschnittstellen vor, die „Compute Unified Device Architecture“ (CUDA).

### 2.3.2 Compute Unified Device Architecture (CUDA)

Bis zu dem Jahr 2006/2007 war die Rechenkapazität von Grafikprozessoren für die „generelle“ Programmierung nur äußerst aufwendig und mit großen Einschränkungen nutzbar [Pha05]. Um die Leistung von GPU's mit geringerem Aufwand abrufen zu können, stellte die NVIDIA Corporation im November 2006 das CUDA<sup>TM</sup> Framework als erste allgemeine Programmierschnittstelle für die Allzweck-Berechnung auf Grafikprozessoren (engl. „General Purpose Computation on Graphics Processing Unit“, GPGPU) vor. Seit seiner Einführung im Jahr 2006 hat das CUDA Framework im Allgemeinen und insbesondere im wissenschaftlichen Bereich eine enorme Aufmerksamkeit auf sich gezogen. Als Beispiele für Disziplinen im Bereich des maschinellen Sehens zu nennen sind: Segmentierung [MT07, VN08, LLWJ10], Objektklassifikation [SB07, CVG08], Objektverfolgung [MT07, BC11] und Szenenrekonstruktion [HN10, KM10, SW10].

Die „Compute Unified Device Architecture“ abstrahiert die Architektur einer GPU mit ihren  $n$  Multiprozessoren in den logischen Einheiten *Block* und *Thread* (Abbildung 2.4). Jedem Block steht zur internen performanten Thread-Kommunikation ein eigener geteilter Speicher (*Shared Memory*) zu. Ein Block wird zur Ausführung dediziert genau einem der

Multiprozessoren zugeteilt. Die ihm zugeordneten Threads werden anschließend in sogenannten *warps*, welche  $n$  Threads<sup>4</sup> umfassen, ausgeführt. Um die durch Speicherzugriffe entstehende Latenz zu verdecken, sollte ein Block aus mindestens 128, aus Performanzgründen jedoch nicht aus mehr als 512 Threads bestehen. Ein großer Vorteil des Frameworks besteht darin, dass die Anzahl der Multiprozessoren im Vorhinein nicht bekannt sein muss. Die Blöcke werden entweder vollständig parallel, falls ausreichend Multiprozessoren vorhanden, oder teilweise serialisiert abgearbeitet. Dies ermöglicht somit eine optimale Skalierung ohne ein vorheriges Wissen über die Zielarchitektur.

Die Kommunikation mit dem Arbeitsspeicher der CPU erfolgt über den globalen GPU Speicher<sup>5</sup> mit Hilfe eines synchronen oder asynchronen Blocktransfers. In dieser Kommunikation liegt zugleich eine der größten Limitierungen bei der Beschleunigung von Berechnungsaufgaben auf heutigen GPU's<sup>6</sup>. Diese wird auch als Flaschenhals (engl. „Bottleneck“) bei der GPGPU Entwicklung bezeichnet, weshalb sich lediglich sehr rechenintensive Anwendungen für eine Auslagerung auf die GPU eignen. Neben den bereits beschriebenen Einschränkungen durch die SIMD Architektur, gilt es daher, die Kommunikation zwischen CPU und GPU auf ein Minimum zu reduzieren.

## 2.4 Parallelisierung

In Abschnitt 2.2 wurde zunächst die Umsetzung des inversen Sensormodells als eines der Kernprobleme bei der Berechnung von Belegungskarten identifiziert. Anschließend erfolgte in Abschnitt 2.3 die Betrachtung der architekturellen Unterschiede zwischen einer auf Stapelverarbeitung (CPU) spezialisierten und auf Vektorverarbeitung (GPU) spezialisierten Hardwarearchitektur.

In diesem Abschnitt erfolgt die Formulierung eines gesamtheitlichen Frameworks zur Erstellung von Belegungskarten unter Berücksichtigung der in den vorherigen Abschnitten erarbeiteten Problemstellungen. Das im Folgenden vorgestellte Framework zur Erstellung einer Belegungskarte auf der GPU kann in drei aufeinander aufbauende Bereiche untergliedert werden (Abbildung 2.5).

Zuerst wird ausgehend von der aktuellen Messung  $\mathbf{z}_t$  eine temporäre Belegungskarte auf der GPU in einer Polardarstellung berechnet, um den in einem kartesischen Koordinatensystem auftretenden Moiré Effekt zu umgehen und eine bestmögliche Parallelisierung zu ermöglichen. Anschließend erfolgt die Transformation auf eine temporäre kartesische Belegungskarte auf Basis der anisotropen Filterung. Dieser Schritt bildet die Grundvoraussetzung, um in dem darauf folgenden Schritt die Translation und Rotation der Fahrzeugeigenbewegung zu kompensieren. Im letzten Schritt werden die temporären Belegungswahrscheinlichkeiten der kartesischen Abbildung mit der stationären Belegungskarte aus dem vorherigen Zeitschritt  $t - 1$  unter Berücksichtigung der bestehenden Einschränkungen

<sup>4</sup>Die Anzahl an parallel ausgeführten Threads steht in Abhängigkeit zu der SIMD Prozessorarchitektur.

<sup>5</sup>Es existieren noch weitere Speicher, wie beispielsweise der *Texturspeicher*, die zur Vereinfachung ausgelassen wurden.

<sup>6</sup>Es ist sehr wahrscheinlich, dass bei zukünftigen GPU Plattformen dieser Nachteil behoben wird.




Abbildung 2.5: Logischer Aufbau des vorgestellten Frameworks zur Erstellung einer Belegungskarte.

auf einer SIMD Architektur fusioniert.

Dieser Abschnitt bildet zudem mit der Definition einer temporären polaren Belegungskarte, der effizienten Berechnung einer temporären polaren Belegungskarte, der Anwendung der anisotropen Filterung und der Fusion zu einer stationären Belegungskarte den wesentlichen wissenschaftlichen Beitrag dieses Kapitels.

### 2.4.1 Berechnung temporärer polarer Belegungskarten

Für das weitere Vorgehen wird zunächst festgelegt, dass eine zweidimensionale Belegungskarte als orthogonale Projektion der Szenerie verwendet wird. Jeder binäre Zustand einer Zelle  $m_{x,y}$  bildet somit die Wahrscheinlichkeit für die Belegung eines durch die Größe einer Zelle definierten zweidimensionalen Bereichs ab. Zudem wird angenommen, dass die in  $\mathbf{z}_t$  enthaltenen Einzelmessungen  $z_t^k$  aus einer Azimut- ( $\phi$ ) und Entfernungsmessung ( $r$ ) bestehen:

$$z_t^k = [r \ \phi]^T . \quad (2.10)$$

Jeder Sensor, der nach dem Messprinzip der Laufzeitmessung von elektromagnetischen Wellen arbeitet, wie beispielsweise Lidar oder Radar, detektiert seine Ziele durch die physikalische Ausbreitung von Wellen in einem polaren Koordinatensystem. Um das Problem zu umgehen, dass die Position und Anzahl der durch ein inverses Sensormodell affektierten Zellen unmittelbar von der Entfernung und sensorintrinsicen Parametern abhängig ist, wird zunächst eine temporäre Belegungskarte in Polardarstellung berechnet. Die zum aktuellen Zeitschritt  $t$  zu einer Messung  $\mathbf{z}_t$  korrespondierende polare Karte wird im Folgenden als  $m'$  bezeichnet (Abbildung 2.6). Die Anzahl an Zellen in Azimut ( $\phi$ ) gleicht dabei der Anzahl an Messungen des Vektors  $\mathbf{z}_t$ . Dies setzt voraus, dass die Intrinsic eines Sensors und damit die maximale Anzahl an Winkelmessungen in einem Zeitschritt bekannt ist. Existiert zum aktuellen Zeitschritt für einen diskreten Winkel keine gültige Messung, wird die gemessene Entfernung als unendlich angenommen. Die Anzahl an Zellen in der Distanz  $r$  ergibt sich unmittelbar aus der maximalen Reichweite der Belegungskarte in Metern geteilt durch die Zellgröße. Weiter wird angenommen, dass alle Messungen  $z_t^1, \dots, z_t^K$  unabhängig voneinander sind. Jede Einzelmessung  $z_t^k$  korrespondiert mit genau einem eindimensionalen Vektor  $m'_k$  (Zeile) in  $m'$  (Abbildung 2.6).

#### Inverses Sensormodell

Die Aufgabe eines inversen Sensormodells ist es zu beschreiben, an welcher Stelle und wie eine Messung in der realen Welt erzeugt wurde und welche Zellen dadurch beeinflusst




Abbildung 2.6: Die Abbildung verdeutlicht die Zusammenhänge zwischen dem Messvektor  $\mathbf{z}_t$  und den korrespondierenden eindimensionalen Belegungskarten  $m'_k$  einer Karte  $m'$ . Zudem ist ein Beispiel für eine Messung in der Zeile  $m'_3$  mit den daraus abgeleiteten Belegungswahrscheinlichkeiten für Freiraum (weiß), Hindernis (schwarz) und Unbekannt (grau) visualisiert.

werden. Bei einer polaren Repräsentation mit der Annahme, dass  $z_t^1, \dots, z_t^K$  unabhängig voneinander sind, wird jede Messung  $z_t^k$  mit ihrer Distanzmessung  $r$  auf eine 1D Belegungskarte abgebildet. Der Fehler in der Distanz  $r$  jeder Messung wird durch eine 1D Normalverteilung mit dem Mittelwert  $r$  und der Standardabweichung  $\delta(z_t^k)$  modelliert. Dies folgt der Annahme, dass die wahre Position  $z_t^{k*}$  einem lokalen Rauschen unterliegt [Kon97, TBF05]. Die Funktion  $\delta(z_t^k)$  beschreibt dabei eine distanzabhängige Abweichung, die mit der Entfernung zum Ziel ansteigt. Weitere Fehler, wie beispielsweise zufälliges Rauschen (Geisterziele) [TBF05], werden nicht modelliert. Da es sich bei diesem Rauschen in der Regel um örtlich und zeitlich unkorrelierte Fehler handelt, ist deren Einfluss durch die anschließende zeitliche Filterung in Gleichung 2.8 zu vernachlässigen.

Die Wahrscheinlichkeit für die Belegung einer jeden Zelle  $m'_{k,i}$  ist dann gegeben durch:

$$p_{\text{occ}}(m'_{k,i}|z_t^k) = \frac{\alpha(z_t^k)}{\sqrt{2\pi\delta(z_t^k)}} e^{-\frac{(i-r)^2}{2\delta^2(z_t^k)}}. \quad (2.11)$$

Die Funktion  $\alpha(z_t^k)$  beschreibt, welches Vertrauen (Wahrscheinlichkeit für Belegung) in Abhängigkeit zu der Distanz einer Messung auf die Zellen übertragen wird. Zusätzlich zu denen durch Gleichung 2.11 definierten Belegungswahrscheinlichkeiten einer Zeile  $m'_{k,i}$  ist es für eine praktische Anwendung sinnvoll, eine zweite überlagernde Funktion zu definieren, welche explizit den bis zu einer Messung vorliegenden Freiraum modelliert. Der Nachteil bei der Modellierung des Freiraums mit einer Normalverteilung (2.11) ergibt sich dadurch, dass die Wahrscheinlichkeit außerhalb des durch die Standardabweichung  $\sigma$  definierten Bereichs sehr stark abfällt. Dies hat zur Folge, dass der rekursive Filter aus Gleichung 2.8 bereits nach wenigen Messungen gegen Null (sicherer Freiraum) konvergiert.

Die Definition des Freiraums wird daher zusätzlich um eine lineare Funktion erweitert, welche der Annahme folgt, dass die Wahrscheinlichkeit einer erfolgreichen Zieldetektion




Abbildung 2.7: Verteilung der Wahrscheinlichkeiten innerhalb einer 1D Belegungskarte mit  $r = 7$  und  $\sigma = 0.7$ . Zu Berechnung der endgültigen Belegung zum Zeitpunkt  $t$  einer Zelle  $m'_{k,i}$  werden die beiden Funktionen  $p_{\text{occ}}(m'_{k,i}|z_t^k)$  und  $p_{\text{free}}(m'_{k,i})$  mit dem Maximum-Operator zu  $p(m'_{k,i}|z_t^k)$  kombiniert.

mit der Entfernung linear abnimmt:

$$p_{\text{free}}(m'_{k,i}) = p_{\text{min}} + \frac{p_{\text{max}} - p_{\text{min}}}{r_{\text{max}}}i \quad \text{mit } p_{\text{min}} \leq p_{\text{max}}. \quad (2.12)$$

Es gilt  $p_{\text{max}} \leq 0.5$  und  $p_{\text{min}} \geq 0$ . Alle Zellen  $m'_{k,i}$  für die  $i > r$  gilt, werden mit  $p(m'_{k,i}) = 0.5$  belegt. Dies folgt unmittelbar der Annahme einer Sichtverdeckung von den Zellen, die sich hinter einem Ziel befinden. Die Wahrscheinlichkeit für die Belegung einer Zelle  $m'_{k,i}$  ergibt sich dann wie folgt:

$$p(m'_{k,i}|z_t^k) = \begin{cases} \max(p_{\text{free}}, p_{\text{occ}}) & i < r \\ \max(0.5, p_{\text{occ}}) & i > r. \end{cases} \quad (2.13)$$

Abbildung 2.7 verdeutlicht diesen Zusammenhang und zeigt  $p_{\text{occ}}(m'_{k,i}|z_t^k)$  und  $p_{\text{free}}(m'_{k,i})$  im Vergleich zu der Kombination aus beiden Funktionen,  $p(m'_{k,i}|z_t^k)$ .

## Effiziente Berechnung einer temporären polaren Belegungskarte auf der GPU

Für die Berechnung einer temporären Belegungskarte auf der GPU muss zunächst die Dimension von  $m'$  spezifiziert werden. Da sich diese direkt aus  $|\mathbf{z}|$  und  $r_{\text{max}}$  ableitet und sich diese Werte für gewöhnlich während der Laufzeit nicht verändern, kann dies in einer Initialisierungsphase erfolgen. Anschließend wird durch einen Blocktransfer in jedem Messzyklus der Vektor  $\mathbf{z}_t$  übertragen.

Für eine möglichst effiziente Ausführung auf der GPU wird jede eindimensionale Belegungskarte  $m'_k$  auf  $M$  Blöcke mit jeweils 256 Threads aufgeteilt (Abbildung 2.8). Die zweite Dimension  $N$  ergibt sich aus der Anzahl  $K$  aller 1D Belegungskarten. Jeder Thread innerhalb einer Zeile berechnet somit die Belegungswahrscheinlichkeit für die ihm zugewiesene Zelle auf Basis von Gleichung 2.13. Durch die Fallunterscheidung in (2.13) kommt es in-




Abbildung 2.8: Aufteilung jeder eindimensionalen Belegungskarte  $m'_k$  auf  $N \times M$  Blöcke mit jeweils 256 Threads. Eine einzelne Messung  $z_t^k$  bestimmt die Wahrscheinlichkeitsverteilung in genau einer Zeile  $k$ .



Abbildung 2.9: Mit simulierten Messwerten auf der GPU berechnete polare Belegungskarte mit  $256 \times 70$  Zellen.

nerhalb eines Blocks in jeder Zeile  $k$  zu einer Divergenz in dem Kontrollfluss, welcher serialisiert werden muss. Da es sich jedoch nur um eine einfache Zweiteilung innerhalb eines warps (siehe Abschnitt 2.3.2) handelt, kann dieser vernachlässigt werden.

In jeder Fallunterscheidung muss zudem der Maximumoperator für eine Fusion der Funktion  $p_{\text{occ}}(m'_{k,i}|z_t^k)$  mit  $p_{\text{free}}(m'_{k,i})$  oder  $p(0.5)$ , welcher sich für Werte größer Null (Wahrscheinlichkeiten) effizient ohne eine *Wenn-Dann* Verzweigung implementieren lässt (2.14), berechnet werden.

$$\max(a, b) = \frac{a + b + |a - b|}{2} \quad (2.14)$$

Abbildung 2.9 zeigt als Beispiel eine mit simulierten Messwerten auf der GPU berechnete polare Belegungskarte mit  $70 \times 256$  Zellen. Es ist deutlich zu erkennen, dass die Belegungswahrscheinlichkeit linear (weiß zu grau) ansteigt. Dieser Teil entspricht dem Einfluss der Funktion aus Gleichung 2.12. Alle Belegungswahrscheinlichkeiten mit  $p(m'_{k,i}) > 0.5$  (schwarz) entsprechen einer Normalverteilung um den jeweiligen Distanzwert  $r$  aus  $z_t^k$ .

Das eben vorgestellte Verfahren ist nicht auf eine polare temporäre Karte und dementsprechend einen Sensortyp mit nur einer vertikalen Messebene limitiert. Für jede weitere Messebene wird die polare Karte um einen Index  $i$  entsprechend jeder Messebene auf  $m'^i$  erweitert. Jeder Index definiert somit eine polare Karte, die mit genau einer vertikalen Ebene verknüpft ist. Die einzelnen Ebenen werden anschließend mit Hilfe des binären-Bayes Filters (2.8) in einer gemeinsamen Karte  $m'$  fusioniert.




Abbildung 2.10: Magnifikation und Minifikation [NH04]. Bei der Magnifikation entspricht ein Teil eines *Texels* (Bildpunkt einer Textur) einem Bildpunkt auf einem gerasterten Polygon. Bei der Minifikation korrespondieren mehrere Texel mit einem Bildpunkt eines Polygons.

### 2.4.2 Abbildung auf eine temporäre kartesische Karte

Um die berechnete temporäre polare Belegungskarte  $m'$  mit einer Karte  $\mathbf{m}_{t-1}$ , die alle Messwerte  $\mathbf{z}_1 \dots \mathbf{z}_{t-1}$  und Fahrzeugeigenpositionen  $\mathbf{x}_1 \dots \mathbf{x}_{t-1}$  bis zum Zeitschritt  $t - 1$  berücksichtigt, zu der endgültigen Belegungskarte  $\mathbf{m}$  fusionieren, muss diese zunächst unter Berücksichtigung der Sensorintrinsic in eine kartesische Repräsentation überführt werden (2.15). Die zu  $m'$  korrespondierende temporäre kartesische Belegungskarte zum Zeitpunkt  $t$  wird als  $m^t$  bezeichnet.

$$m' \mapsto m^t \quad (2.15)$$

Diese Abbildung ist keinesfalls trivial. In Regionen nahe des polaren Ursprungs korrespondiert die Wahrscheinlichkeit einer einzigen Zelle in  $m^t$  mit mehreren Zellen in  $m'$ . In Regionen weiter entfernt, korrespondiert eine Zelle in  $m'$  mit mehreren Zellen in  $m^t$  (Abbildung 2.11). In beiden Fällen ist es notwendig, dass die Wahrscheinlichkeiten in Abhängigkeit der Entfernung und der Intrinsic eines Sensors interpoliert werden. Fasst man  $m'$  nicht als Belegungskarte sondern als Bild mit den Dimensionen  $n_x$  und  $n_y$  auf, ist diese Problemstellung im Bereich der Computergrafik unter der *Minifikation* und *Magnifikation* im Bereich des sogenannten *Texture-Mappings*, welches die Abbildung einer Textur (Bild) auf ein Polygon beschreibt, bekannt [AMHH08]. Abbildung 2.10 verdeutlicht die Magni- und Minifikation anhand eines einfachen Beispiels.

Die ersten, die diesen Zusammenhang erkannten, waren Yguel, Aycard und Laugier [YAL08]. Sie betrachteten das Abbildungsproblem (2.15) als ein geometrisches Transformationsproblem, nämlich die Abbildung einer Textur  $T$  auf ein Polygon  $P$  (Abbildung 2.11). Zu Lösung dieses Transformationsproblems wurde der *exakte* Algorithmus, welcher eine Adaption des Guibas-Seidel Algorithmus entspricht, mit einem *Texture-Mapping* Ansatz verglichen. Die interessanteste Erkenntnis dieses Vergleichs war, dass der Texture-Mapping Ansatz im Vergleich zu der exakten Lösung einen vernachlässigbaren Fehler aufweist [YAL08]. Neben dem exakten Algorithmus, welcher keine Echtzeitfähigkeit aufwies, konnte bei der durch Yguel, Aycard und Laugier durchgeführten Simulation die Echtzeitfähigkeit eines auf Texture-Mapping basierten Vorgehens unter Beweis gestellt werden.

Vereinfacht beschreibt das Texture-Mapping das „Aufziehen“ eines als Textur aufgefass-




Abbildung 2.11: Als Textur  $T$  aufgefasste polare Belegungskarte  $m'$  mit dem korrespondierenden Polygon  $P$  im kartesischen Koordinatenraum. In der Nähe des polaren Ursprungs entspricht eine Zelle in  $m^t$  mehreren Zellen in  $m'$ . Weiter entfernt, ist dieses genau umgekehrt.

ten zweidimensionalen Bildes auf eine zwei- oder dreidimensionale Oberfläche (Polygon). Für eine ausführliche Einführung in diese Thematik wird auf [BB05] oder andere einführende Literatur der Computergrafik verwiesen. Sei  $I$  ein Bild mit  $n_x \times n_y$  Bildpunkten und  $T$  die korrespondierende Textur in einem zweidimensionalen orthogonalen Koordinatensystem mit den Texturkoordinaten  $(u, v) \in [0, 1]$ , dann existiert eine Funktion

$$f : P \mapsto T, (s, t) \mapsto (u, v) \quad (2.16)$$

die jedem Koordinatenpaar  $(s, t)$  eines Polygons, genau ein Paar  $(u, v)$  in einer Textur zuordnet<sup>7</sup>. Zu Verdeutlichung sind in Abbildung 2.11 die zu den jeweiligen *Vertices* eines Polygons  $P$  korrespondierenden Texturkoordinaten als blaue Punkte visualisiert. Da diese Abbildung im Wesentlichen durch die intrinsischen Parameter wie beispielsweise die Winkelschrittweite und die Strahldivergenz, welche sich für gewöhnlich während der Laufzeit nicht ändern, vorgegeben ist, kann die Abbildungsmatrix für eine möglichst effiziente Umsetzung bereits in einer Initialisierungsphase berechnet werden. Um nun den Intensitätswert des eigentlichen Rasters (im übertragenen Sinne die Wahrscheinlichkeiten der Belegungskarte  $m^t$ ) zu bestimmen, muss das Polygon mit der darauf projizierten Textur (polare Belegungskarte  $m'$ ) „gerendert“<sup>8</sup> werden. Das eben beschriebene theoretische Vorgehen wird auch als „Vorwärts-Mapping“ bezeichnet [Wat02].

Da jedoch jedes Polygon, egal ob 3D oder 2D, letztlich zur Visualisierung wieder durch eine perspektivische oder orthogonale Projektion auf eine zweidimensionale Rastergrafik

<sup>7</sup>Bei Texturen werden die Bildpunkte (*Texel*) nicht mit diskreten Koordinaten beschrieben, sondern als kontinuierliche Variablen in dem Parameterraum  $[0, 1]^2$  aufgefasst.

<sup>8</sup>„Rendern“ beschreibt in der Computergrafik die Abbildung der Szenerie auf ein diskretes Raster mit Farb- oder Intensitätswerten unter Berücksichtigung von Tiefeninformation, Beleuchtung und Textur.



Abbildung 2.12: Beispiel für die Erstellung einer *Mip-Map* von Stufe  $d = 0$  bis Stufe  $d = 2$ . In (a), das Ausgangsbild mit voller Auflösung. In (b) in halbiertem und in (c) in geviertelter Auflösung.

(Bildschirm) abgebildet werden muss, bedienen sich Grafikkarten bei der Bestimmung des eigentlichen Wertes eines Rasterpunktes (in Abbildung 2.11 als gelbe Zelle dargestellt) aus einer Textur eines „Tricks“, dem sogenannten „Rückwärts-Mapping“ [Wat02]. Ausgehend von dem zu rasternden Bildpunkt, muss das Urbild, auch als „Footprint“ bezeichnet, eines Bildpunktes in der Textur bestimmt werden. In den seltensten Fällen stimmt jedoch ein Rasterpunkt (Zelle in  $m^t$ ) mit einem Texel (Zelle in  $m'$ ) der Textur überein.

Bei der Problemstellung der Magnifikation (siehe Abbildung 2.10) wird deshalb durch eine *bilineare* Filterung der vier am nächsten liegenden Texel des zurück-projizierten Zentrums der Wert eines Rasterpunktes angenähert [BB05]. Abbildung 2.11 zeigt ein einfaches Beispiel für die Rückprojektion eines Punktes (rot) in  $m^t$  auf  $m'$ . Anhand der vier nächsten Texel (gelb) erfolgt eine gewichtete Interpolation um den Wert des Punktes (gelb) in  $m^t$  zu bestimmen.

Wesentlicher schwieriger ist die Minifikation. Wird wie bei der Magnifikation lediglich eine bilineare Filterung bei der Abtastung durchgeführt, kommt es durch Verletzung des Abtasttheorems (zu geringe Abtastfrequenz) zu starken Diskretisierungsfehlern, die auch als „Alias-Effekte“ bezeichnet werden. Ein ausführlicher Überblick über die Grundlagen der Signalverarbeitung und die Probleme bei der Minifikation kann in [BB05] gefunden werden. Um eine zu geringe Abtastung zu vermeiden, wird eine auf der bilinearen Filterung aufbauende Filtermethode eingesetzt, die *trilineare* Filterung. Basis für diese Filterung ist eine Textur  $T$ , die einer Zweierpotenz entspricht. Es gilt somit für  $n_x \times n_y = 2^i \times 2^j$  mit  $(i, j) \in \mathbb{N}_0^2$ . Auf der ersten Stufe ( $d = 0$ ), entspricht die Mip-Map der Textur  $T$ :

$$C_{\text{mip}}^0[i, j] = T[i, j]. \quad (2.17)$$

Die erste Stufe  $C_{\text{mip}}^0$  wird nun  $n$  Mal in ihrer Auflösung halbiert (2.18), welches als *Mip-Mapping* bezeichnet wird [Wat02].

$$C_{\text{mip}}^d[i, j] = \frac{C_{\text{mip}}^{d-1}[2i, 2j] + C_{\text{mip}}^{d-1}[2i + 1, 2j] + C_{\text{mip}}^{d-1}[2i, 2j + 1] + C_{\text{mip}}^{d-1}[2i + 1, 2j + 1]}{4} \quad (2.18)$$

Abbildung 2.12 zeigt ein Beispiel für eine Mip-Map mit drei Stufen. Sei  $w$  die maximal vorkommende Kantenlänge der Rück-Projektion des Bildpunktes im Texturraum, dann ist  $l = \log_2(w)$  die daraus resultierende kontinuierliche Mip-Map Stufe. Vor der eigentlichen




Abbildung 2.13: Auf der GPU berechnete kartesische Belegungskarte der in Abbildung 2.9 gezeigten polaren Karte. Jede der 70 Entfernungsmessungen wurde auf einen Winkelbereich mit  $1^\circ$  abgebildet.

Abtastung werden nun die beiden Stufen  $d = \lfloor l \rfloor$  und  $d + 1 = \lceil l \rceil$  ausgewählt, die in ihrer Auflösungsstufe der Größe des projizierten Urbildes am nächsten sind. Anschließend werden auf Basis einer Rückprojektion die Koordinaten  $(u, v)$  bestimmt und in beiden Mip-Map's bilinear interpoliert und abgetastet. Der endgültige Wert eines Rasterpunktes  $C_{\text{fil}}$  errechnet sich dann aus einer linearen Interpolation der beiden bilinear ermittelten Abtastwerte:

$$C_{\text{fil}}(u, v, l) = (l - \lfloor l \rfloor) \text{BiInt}(C_{\text{mip}}^{\lceil l \rceil}, u, v) + (\lceil l \rceil - l) \text{BiInt}(C_{\text{mip}}^{\lfloor l \rfloor}, u, v). \quad (2.19)$$

Die effiziente Umsetzung der bilinearen Filterung und die Erstellung von Mip-Map's gehört zu den wesentlichen Bestandteilen heutiger GPU's, wodurch eine Abbildung von  $m' \mapsto m^t$  äußerst schnell ausgeführt werden kann. Abbildung 2.13 zeigt als Beispiel eine auf der GPU mit Mip-Mapping berechnete kartesische Belegungskarte der in Abbildung 2.9 gezeigten polaren Karte. In diesem Beispiel lässt sich zudem einer der großen Vorteile einer bilinearen Filterung erkennen. Wurde zunächst durch Gleichung 2.11 nur die Messunsicherheit als 1D Normalverteilung in der Entfernung modelliert, wird diese bei der Abbildung auf  $m^t$  in eine entfernungsabhängige Fehlerellipse transformiert. Diese wiederum entspricht in erster Näherung einer zweidimensionalen Normalverteilung.

**Anisotropische-Filterung** In diesem Paragraphen soll noch eine Filtermethode vorgestellt werden, die bei der Abbildung von  $m'$  nach  $m^t$  in Bereichen der Minifikation, also nahe des polaren Ursprungs in  $m'$ , eine wesentlich bessere Approximation des eigentlichen Urbildes eines Rasterpunktes in einer Textur ermöglicht, als die von Yguel, Aycard und Laugier [YAL08] vorgeschlagene trilineare Filterung.

Wie bereits oben erwähnt, wurde durch Yguel, Aycard und Laugier [YAL08] untersucht, ob mit Hilfe von Texture-Mapping die Abbildung  $m' \mapsto m^t$  als geometrische Transformation beschrieben werden kann. Basis dieser Analyse war ein Vergleich der Abtastung des Guibas-Seidel Algorithmus mit auf trilinearer Filterung basierendem Texture-Mapping. Aus

Sicht des Abtasttheorems ermöglicht die trilineare Filterung zwar eine Unterabtastung zu umgehen, jedoch betrachtet dies nicht die eigentliche „Qualität“ der Abbildung. Durch die bei der Mip-Map Erstellung  $n$  fache Teilung der jeweiligen Auflösungsebenen mit einem Tiefpass-Filter, kommt es zu einer Eliminierung der hohen Frequenzanteile innerhalb der Mip-Maps. Die Folge ist ein starker Informationsverlust mit zunehmender Mip-Map Stufe. Abbildung 2.14(a) verdeutlicht diese Problematik anhand eines einfachen Beispiels. Ein simuliertes Ziel in gleicher Entfernung für alle  $z^k \in \mathbf{z}_t$  nahe des polaren Ursprungs in  $m'$  wurde auf Basis einer trilinearen Filterung auf eine kartesische Karte abgebildet. Durch die mehrfache Teilung mit anschließender Interpolation ist der ursprünglich in der Polardarstellung vorhandene hohe Gradient zwischen Hindernis und Freiraum zu einem ausgedehnten linearen Anstieg degeneriert. Dieser Effekt kann auch in der 3D Computergrafik bei Flächen beobachtet werden, die unter einem sehr „flachen Winkel“ betrachtet werden. Wird eine rechteckige Textur  $T$  auf ein eigentlich auch rechteckiges Polygon  $P$  übertragen, welches anschließend eine perspektivische Projektion  $M_{per}$  durchläuft, so steigt die benötigte Mip-Map Stufe mit Annäherung an den Fluchtpunkt (engl. vanishing-point)  $v$  bis zu der maximal möglichen Stufe  $n_{max}$  an. Um eine Unterabtastung in  $y$ -Richtung zu vermeiden, wird die Mip-Map Stufe ausgewählt, die in  $x$ -Richtung nach dem Abtasttheorem gar nicht benötigt werden würde. Zudem liegt die vereinfachte Annahme zugrunde, dass jeder Bildpunkt (Zelle in  $m^t$ ) einem durch ein Rechteck approximiertem Urbild in  $T$  entspricht. Der trilineare Filter arbeitet somit symmetrisch basierend auf der in  $x$ - oder  $y$ -Richtung kleinsten benötigten Mip-Map Stufe  $d$ .

Dieser negative Effekt kann durch eine erweiterte Filtermethode, der anisotropen (nicht in allen Richtungen gleich) Filterung, reduziert werden. Der Vorteil der anisotropen im Vergleich zur trilinearen Filterung setzt sich dabei aus zwei Grundprinzipien zusammen. Erstens, die Filtermethode basiert auf der *Mip-Mapping* Technik in Verbindung mit einem adaptiven asymmetrischen Filterkern, welcher in erster Näherung das eigentlich durch ein Parallelogramm definierte Urbild in  $T$  zu approximieren versucht. Zweitens, sei  $s$  die Raumrichtung anhand derer eine geringere und  $t$  die Richtung anhand derer eine größere Mip-Map Stufe benötigt wird. Die Grundidee der Anisotropen-Filterung ist, die Mip-Map Stufe auszuwählen, die in  $s$ -Richtung adäquat ist und gleichzeitig in  $t$ -Richtung Alias-Effekte vermeidet, indem eine größere Anzahl an Texel in  $t$ -Richtung zur Filterung herangezogen wird. In  $t$ -Richtung erfolgt somit analog eine Überabtastung, um das Abtasttheorem nicht zu verletzen. Für eine detaillierte Einführung in die anisotrope Filterung und dessen Anwendung in der Computergrafik wird auf [NH04] verwiesen.

Die Verwendung der anisotropen Filterung führt zu wesentlich besseren Ergebnissen als die einfache trilineare Filterung. In der Literatur bekannte Verfahren zur anisotropen Filterung sind beispielsweise das Texram-Footprint-Assembly [SKS96] oder das SPAF (Sub-Texel Precision Anisotropic Filtering) [SLK01] Verfahren. Die Abbildung 2.14 zeigt als Beispiel die Verwendung einer anisotropen Filterung im Vergleich zur einfachen trilinearen Filterung. Je nach Beispiel, werden im Vergleich zur bilinearen Filterung in  $t$ -Richtung zwischen vier, acht oder 16 mal so viele Pixel in die Abtastung mit einbezogen.




Abbildung 2.14: Vergleich der trilinearen mit der anisotropen Filtermethode. In (a) die einfache trilineare Filterung. In den Abbildungen (b) bis (d) die Filterung mit 4-facher, 8-facher und 16-facher anisotroper Filterung.

### 2.4.3 Stationäre Belegungskarte

Dieser Abschnitt beschäftigt sich mit der zeitlichen Fusion der in dem vorherigen Abschnitt 2.4.2 berechneten temporären kartesischen Karte  $m^t$  zu einer Belegungskarte  $\mathbf{m}$ . Per Definition (2.8) enthält die Karte  $\mathbf{m}$  die mit einem rekursiven Filter geschätzte Belegung unter Berücksichtigung aller Messungen  $\mathbf{z}_1 \dots \mathbf{z}_t$  und Positionen  $\mathbf{x}_1 \dots \mathbf{x}_t$ . Um folglich  $\mathbf{m}$  zu berechnen, muss die Karte  $m^t$ , welche die Belegung unter Berücksichtigung der aktuellen Messung  $\mathbf{z}_t$  enthält, mit  $\mathbf{m}$  aus  $t - 1$  fusioniert werden.

Bevor jedoch näher auf die Fusion mit einem binären Bayes-Filter eingegangen wird, müssen der Aufbau und das Koordinatensystem von  $\mathbf{m}$  definiert werden. Für diese Arbeit wird eine stationäre Belegungskarte verwendet, bei der die *Fahrzeug-Pose* innerhalb der Karte eindeutig durch einen Vektor (2.20) mit der Position  $(x_{\text{grid}}, y_{\text{grid}})$  und der Ausrichtung  $\psi_{\text{grid}}$  bestimmt ist.

$$\mathbf{s}_{\text{grid}}^t = \begin{bmatrix} x_{\text{grid}} \\ y_{\text{grid}} \\ \psi_{\text{grid}} \end{bmatrix} \in \mathbb{R}^3 \quad (2.20)$$

Vor der ersten Kontrolleingabe  $\mathbf{x}_1$  wird ein zweidimensionales kartesisches Koordinatensystem „verankert“ (Abbildung 2.15 links), welches zugleich den örtlichen Bezug zu der ersten Zelle  $m_{0,0}$  definiert. Um die vorher festgelegte Größe der Belegungskarte von  $n \times n$  Zellen bei einer durch  $\mathbf{x}_t$  induzierten translatorischen Bewegung konstant zu halten, wird der Koordinatenursprung nach einem Positionsupdate jeweils um  $\lfloor \Delta x \rfloor$  und  $\lfloor \Delta y \rfloor$  aus  $\mathbf{x}_t$  verschoben. Die verbleibende Differenz  $x_{\text{R}} = \Delta x - \lfloor \Delta x \rfloor$  und  $y_{\text{R}} = \Delta y - \lfloor \Delta y \rfloor$ , wird rekursiv zu einem Vektor  $\mathbf{s}_{\text{Rgrid}}^t$  addiert:

$$\mathbf{s}_{\text{Rgrid}}^t = \begin{bmatrix} x \\ y \end{bmatrix} \text{ mit } 0 \leq x, y < 1 \quad (2.21)$$

$$\mathbf{s}_{\text{Rgrid}}^t = \mathbf{s}_{\text{Rgrid}}^{t-1} + \begin{bmatrix} x_{\text{R}} \\ y_{\text{R}} \end{bmatrix} \text{ mit } 0 \leq x_{\text{R}}, y_{\text{R}} < 1. \quad (2.22)$$

Wird durch die durchgeführte Addition einer der Parameter in  $\mathbf{s}_{\text{Rgrid}}^t$  größer als 1, erfolgt eine weitere Verschiebung des Koordinatensystems auf der Koordinatenachse um 1 und der jeweilige Parameter in  $\mathbf{s}_{\text{Rgrid}}^t$  wird um eins dekrementiert.

Eine Besonderheit der in dieser Arbeit verwendeten stationären Karte ist, dass sich die in Fahrtrichtung vor dem Fahrzeug liegende Anzahl an Zellen von denen im hinteren Teil liegenden Zellen unterscheiden kann. Der Vorteil einer solchen Aufteilung ergibt sich daraus, dass bei gleichbleibender Anzahl an Zellen eine größere Anzahl an Zellen –und damit Sichtweite– in Richtung einer dominanten Bewegungsrichtung ermöglicht wird. Die Fahrzeugposition innerhalb der Karte befindet sich somit nicht zwangsläufig im Zentrum (Abbildung 2.15) einer Karte. Anders als bei einer symmetrischen Aufteilung, bewegt sich das Fahrzeug auf einer durch einen Radius  $R$  vorgegebenen Kreisbahn mit dem Zentrum  $\frac{n}{2}$  als Kreismittelpunkt. Diese Repräsentation stellt somit eine Erweiterung einer symmetrischen Karte dar, bei der stets  $R = 0$  gilt und sich das Fahrzeug zwangsläufig im Zentrum der Belegungskarte befindet. Da die translatorische Bewegung über eine Verschiebung des Koordinatensystems und über  $\mathbf{s}_{\text{Rgrid}}^t$  abgebildet wird, bestimmt lediglich die zum aktuellen Zeitpunkt gültige Ausrichtung  $\psi_{\text{grid}}$  über die Position  $(x_{\text{grid}}, y_{\text{grid}})$  des Fahrzeugs in der Karte:

$$\begin{aligned} x_{\text{grid}} &= \frac{n}{2} - R \cos \psi_{\text{grid}} \\ y_{\text{grid}} &= \frac{n}{2} + R \sin \psi_{\text{grid}}. \end{aligned} \tag{2.23}$$

Die Ausrichtung  $\psi_{\text{grid}}$  leitet sich dabei unmittelbar aus der Summation aller in  $\mathbf{x}_1 \dots \mathbf{x}_t$  enthaltenen Ausrichtungen ab. Abbildung 2.15 verdeutlicht die eben beschriebenen Zusammenhänge. Im linken Bild ist die Belegungskarte vor dem ersten Positionsupdate dargestellt. Der „vordere Teil“ ist durch  $\frac{n}{2} + R$  und der „hintere Teil“ durch  $\frac{n}{2} - R$  definiert. Das mittlere Bild zeigt die Verschiebung der Karte und des damit verbundenen Koordinatensystems durch eine translatorische Bewegung in  $x$ -Richtung. Die rot markierten Zellen werden entfernt und die weißen Zellen werden hinzugefügt. Das rechte Bild in Abbildung 2.15 zeigt die Karte zu einem Zeitpunkt  $t_i$  nach mehreren Rotationen und Translationen. In diesem Beispiel summieren sich alle Ausrichtungsänderungen zu  $45^\circ$ , so dass sich das Fahrzeug in der linken unteren Hälfte der Karte befindet. Um nun die endgültige Belegung der Karte  $\mathbf{m}$  zu berechnen, müssen die sich überlappenden Zellen (in Abbildung 2.15 als graue Zellen dargestellt) aus  $m^t$  mit denen der Karte aus dem vorherigen Zeitschritt fusioniert werden. Durch die Definition aus (2.2), alle Zellen sind unabhängig von ihren benachbarten Zellen, können alle Berechnungen parallel ausgeführt werden. Für eine Karte mit  $n \times n$  Zellen wird folglich eine Anzahl von  $n^2$  binären Bayes-Filtern benötigt, wobei jeder binäre Filter (siehe Gleichung 2.8) genau eine Zelle  $m_{x,y}$  fusioniert. Für die Umsetzung auf der GPU wird jeder Filter einem Thread zugewiesen und einem Block mit insgesamt 256 Threads hinzugefügt. Durch die vollständige Unabhängigkeit aller Filter kann die Gruppierung in einer beliebigen Reihenfolge erfolgen bei der lediglich die Speicherkohärenz beachtet werden muss. Eine Aufteilung in Blöcke von  $16 \times 16$  Threads erscheint daher sinnvoll.

An dieser Stelle soll nun abschließend noch auf die numerische Instabilität des binären




Abbildung 2.15: Schematischer Aufbau einer stationären Belegungskarte  $\mathbf{m}$ . Die Position und Ausrichtung des Fahrzeugs innerhalb der Karte ist eindeutig durch den Zustandsvektor  $\mathbf{s}_{\text{grid}}$  definiert. Abbildung (a) zeigt die Karte nach der Initialisierungsphase zum Zeitpunkt  $t_0$ . Abbildung (b) nach einer reinen Translation in  $x$ -Richtung und Abbildung (c) zu einem beliebigen Zeitpunkt  $t_i$  nach einer mit Rotation verbundenen Translation.

Bayes-Filters eingegangen werden. Für Belegungswahrscheinlichkeiten von  $p(m_{x,y}) \approx 1$  entsteht in der rekursiven Berechnungsvorschrift eine Division durch einen Wert nahe Null. Um dieses Problem zu umgehen, kann der rekursive Filter in eine logarithmusbasierte Darstellung überführt werden [TBF05]. Die Auswertung des Logarithmus und die Auswertung der Exponentialfunktion als dessen Umkehrfunktion sollte jedoch selbst auf heutigen GPU's aus Gründen des enormen Rechenaufwands vermieden werden. Zudem stellt dies keine ausreichende Lösung für eine praktische Anwendung des Filters dar, welches anhand eines einfachen Beispiels erläutert werden soll. Ein Lidar Sensor erhält über einen längeren Zeitraum in einem bestimmten Winkelschritt keine gültige Detektion eines vorhandenen Ziels, weil etwa die Oberflächenreflektivität zu klein oder der Einfallswinkel zu flach ist. Die Belegungswahrscheinlichkeit der betreffenden Zellen konvergiert nun rekursiv gegen Null (Freiraum). Ändert sich nun der Einfallswinkel oder die Distanz zum Ziel, wird die gleiche Anzahl an Messungen benötigt um eine Wahrscheinlichkeit von  $p(m_{x,y}) = 0.5$  zu erreichen, die zuvor für Freiraum votiert hat. In Weiss [WSD07] wird ein mit einer Wenn-Dann Verzweigung implementierter Epsilon-Test verwendet, um eine untere und obere Schranke für die Wahrscheinlichkeit einer Zelle  $m_{x,y}$  zu definieren. Zwar ermöglicht dieser, die beschriebene Problematik zu umgehen, jedoch ist die vorgestellte Form für eine Implementierung auf einer GPU Architektur ungeeignet. Gleichung 2.24 definiert zur Lösung dieses Problems einen Epsilon-Test, der ohne Verzweigungen auskommt und daher eine optimale Parallelisierung auf einer GPU ermöglicht.

$$\tilde{m}_{x,y} = \max(\epsilon, \min(1 - \epsilon, m_{x,y})) \quad (2.24)$$

Der Max- als auch der Minoperator kann für Werte größer Null wie in Gleichung 2.14 als geschachtelte Betragsfunktion formuliert werden.






Abbildung 2.16: Zusammenfassung der wesentlichen Schritte bei der Berechnung einer Belegungskarte auf der GPU.

Abbildung 2.16 fasst die wesentlichen Schritte bei der Erstellung einer stationären Belegungskarte auf der GPU zusammen. Zuerst werden mit Hilfe eines Blocktransfers nach jedem Messupdate die Messwerte in den globalen Speicher der GPU übertragen. Für jede vertikale Messebene wird eine temporäre polare Belegungskarte berechnet (Stufe 1). Existiert mehr als eine polare Karte, werden diese zunächst fusioniert (Stufe 2). Danach erfolgt die Abbildung auf eine temporäre kartesische Karte unter Berücksichtigung der Fahrzeuorientierung  $\psi_{\text{grid}}$  (Stufe 3). Die temporäre kartesische Karte wird anschließend zu der stationären Belegungskarte aus dem vorherigen Zeitschritt fusioniert (Stufe 4). Abschließend erfolgt die Übertragung der Belegungskarte  $\mathbf{m}$  zurück in den Speicher der CPU<sup>9</sup>. Abbildung 2.17 zeigt abschließend als Beispiel eine mit einem Laserscanner auf der GPU erstellte Belegungskarte.


<sup>9</sup>Der Speichertransfer zwischen CPU und GPU entfällt bei modernen „System-On-Chip“ (SOC) Architekturen [NVI], bei denen CPU und GPU einen physischen Speicherbereich teilen können.



(a)



(b)



(c)

Abbildung 2.17: Beispiel für eine auf der GPU mit Laserscannerdaten erstellte Belegungskarte in einem innerstädtischen Szenario. In (a), die Karte nach dem ersten und in (b) nach dem zweiten Messupdate. Abbildung (c) zeigt die Karte nach 30 Messupdates bei einer konstanten Geschwindigkeit von 12 m/s.

## 2.5 Exemplarische Umsetzung

In diesem Abschnitt erfolgt exemplarisch die Anwendung des zuvor vorgestellten Verfahrens auf einen mehrzeiligen automotiven Laserscanner und ein bildgebendes Radar. Die genaue Spezifikation der verwendeten Sensoren ist in Kapitel 6.1.2 zu finden.

### 2.5.1 Laserscanner

Die Anwendung des Verfahrens auf einen mehrzeiligen Laserscanner entspricht im Wesentlichen dem bereits vorgestellten Vorgehen (Stufen 1 bis 4 aus Abbildung 2.16). In diesem speziellen Fall handelt es sich um einen Laserscanner (siehe Kapitel 6.1.2 Laserscanner 1) mit vier parallelen vertikalen Messebenen. Für jede dieser Ebenen wird zuerst eine temporäre polare Belegungskarte berechnet. Die Fusion der einzelnen Messebenen erfolgt mittels des binären Bayes-Filters (Gleichung 2.8) unter Beachtung der numerischen Stabilität (2.24).

Die Abbildungen 2.18(a) und 2.18(b) zeigen jeweils ein Beispiel für eine mit Laserscanner 1 aus Kapitel 6.1.2 erstellte Belegungskarte in einem Landstraßen- und in einem Autobahnszenario. Die Größe der Belegungskarte beträgt in beiden Beispielen  $512 \times 512$  Zellen bei einer Zellgröße von 0.2m. In Abbildung 2.18(b) sind zudem die Fehler zu erkennen, die durch die Annahme, die Welt ist „statisch“, entstehen. Der auf dem mittleren Fahrstreifen vorausfahrende LKW erzeugt durch wiederholte Messungen in unterschiedlichen stationären Zellen starke Artefakte, die zu keinem zum aktuellen Zeitpunkt gültigen Ziel gehören. Das Entfernen solcher „Geisterobjekte“ ist nicht Bestandteil dieser Arbeit und der Leser wird auf [Wan04] oder [VAA07] verwiesen.




Abbildung 2.18: Beispiel für eine mit einem mehrzeiligen Laserscanner erstellte Belegungskarte in einem Landstraßen- und in einem Autobahnszenario.

## 2.5.2 Bildgebendes Radar

Wie ein Laserscanner, misst ein Radar die Entfernung  $r$  und den Winkel  $\psi$  zu einem Ziel. Radarsensoren haben üblicherweise einen kleineren horizontalen Öffnungswinkel und eine geringere Winkelauflösung als ein Laserscanner, jedoch sind sie durch den Dopplereffekt in der Lage, zusätzlich direkt die radiale Geschwindigkeit eines Ziels zu bestimmen. Dies ist insbesondere von Vorteil, um dynamische Objekte bereits zu Beginn aus einer stationären Belegungskarte zu entfernen. Der zusätzliche Aufwand einer nachträglichen Filterung entfällt.

Das für die exemplarische Umsetzung verwendete scannende Radar ist in Kapitel 6.1.2 genauer spezifiziert. Das Radar liefert Informationen über die radiale Entfernung und relative Geschwindigkeit in Form von zwei polaren Bildern (Abbildung 2.19). Das erste Bild,




Abbildung 2.19: Beispiel für ein Amplitudenbild (a) und ein Frequenzbild (b). Beide Bilder haben eine Auflösung von  $200 \times 18$  Pixeln.

das Amplitudenbild (Abbildung 2.19(a)), enthält Informationen über die Existenz von Objekten. Je heller ein Bildpunkt desto wahrscheinlicher ist es, dass dieser zu einem existierenden Objekt gehört. Das zweite Bild, das Frequenzbild (Abbildung 2.19(b)), enthält Informationen über die relative Geschwindigkeit eines jeden Bildpunktes. Alle Messungen in einem Amplitudenbild, die im Frequenzbild nicht mit der Fahrzeugeigengeschwindigkeit korrespondieren, werden in dem Amplitudenbild als dynamisch markiert und entfernt. Fasst man das so entstandene Amplitudenbild als Karte auf, entspricht dies grundlegend der Definition einer polaren Belegungskarte (vergleiche Abbildung 2.9). Der einzige Unterschied besteht in der Repräsentation des Zustands der Belegung, welcher zunächst nicht probabilistisch ist. Um die zuvor festgelegte Notation einer probabilistischen Belegungskarte zu erfüllen und die zeitlich aufeinander folgenden Amplitudenbilder zu einer stationären Belegungskarte zu fusionieren, muss die Belegung in Form der Amplitude auf eine Wahrscheinlichkeit abgebildet werden. Sei  $y_i$  der Amplitudenwert einer Zelle und  $\hat{y}_{\text{GSNR}}$  das globale maximale Rauschniveau, dann ergibt sich die Belegungswahrscheinlichkeit als

$$p(m_i) = \left( \frac{y_i}{\hat{y}_{\text{GSNR}}} \right)^{p_f} \quad (2.25)$$

mit  $p_f$  als Verstärkungsfaktor. Der Faktor  $p_f$  wird empirisch so festgelegt, dass alle Ziele oberhalb des Rauschniveaus einen Wert  $p(m_i) < 0.5$  zugewiesen bekommen. Diese Umrechnung ersetzt somit Stufe 1 in Abbildung 2.16. Alle weiteren Schritte folgen den bereits vorgestellten Stufen. Abbildung 2.20 zeigt ein Beispiel für eine aus zeitlich aufeinander folgenden Amplitudenbildern berechnete Belegungskarte. Es ist zu erkennen, dass die mit



Abbildung 2.20: Beispiel für eine aus Amplitudenbildern erzeugte stationäre Belegungskarte in einem Autobahnszenario. Es ist deutlich zu erkennen, dass die mit der Entfernung zunehmende laterale Messunsicherheit auf die stationäre kartesische Karte abgebildet wurde.

ansteigender Entfernung zunehmende laterale Messunsicherheit durch die geometrische Transformation in Stufe 3 berücksichtigt wurde.

## 2.6 Zusammenfassung

In diesem Kapitel wurde ein Framework zur parallelen Berechnung probabilistischer Belegungskarten auf SIMD Architekturen (GPU's) vorgestellt. Die Zielsetzung zu Beginn dieses Kapitels war es, eine möglichst effiziente Parallelisierung ohne Lese-nach-Schreibe-Konflikten und Schreibe-nach-Schreibe-Konflikten zu erreichen und zudem die bei auf „Ray-Casting“ basierenden inversen Sensormodellen existierenden Probleme, wie beispielsweise der Moiré Effekt und die unzureichende Modellierung der Messunsicherheit, zu vermeiden.

Um diese Problemstellungen zu lösen, wurde das in diesem Kapitel entwickelte Verfahren in drei wesentliche Teilaspekte gegliedert. Die Berechnung und Fusion polarer Belegungskarten auf SIMD Basis, die Transformation der polaren Karte auf eine temporäre kartesische Karte und die Erstellung einer stationären Belegungskarte.

Als wissenschaftlicher Beitrag dieses Kapitels zu werten ist dabei die Analyse der optimalen Parallelisierung auf der GPU, die Erstellung polarer Belegungskarten auf der GPU und die Betrachtung von Sensoren mit mehreren vertikalen Messebenen, die Anwendung der anisotropen Filterung zur Verbesserung der Transformation der Polardarstellung auf eine kartesische Darstellung sowie die effiziente Fusion zu einer stationären Belegungskarte mit optimierten Speicherbedarf durch Einführung der variablen „Historie“. In dem experimentellen Teil dieses Kapitels erfolgte zudem der erste in der Literatur bekannte Nachweis einer ganzheitlichen Berechnung von Belegungskarten auf der GPU auf Basis von reellen Sensordaten (Laserscanner und Radar).

---

## Lidarbasierte Fahrstreifenerkennung

---

Bei der Erkennung von Fahrbahnmarkierungen mittels eines Lidar-Sensors ergeben sich vielschichtige wissenschaftliche Fragestellungen. Dieser Teil der Arbeit befasst sich im Detail mit den wesentlichen Aspekten eines Gesamtsystems zur Detektion von Fahrbahnmarkierungen mit einem in Fahrtrichtung ausgerichteten Lidar-Sensor.

Im Gegensatz zu einem kamerabasierten System, ist es einem Lidar nicht möglich, den im sichtbaren Spektrum vorliegenden Kontrast zwischen Fahrbahnmarkierungen und dem Fahrbahnbelag zu detektieren. Vielmehr ist es eine besondere Eigenschaft von Fahrbahnmarkierungen, die Retroreflektivität, die eine Detektion ermöglicht. Im ersten Teil dieses Kapitels werden einführend die komplexen Eigenschaften moderner Fahrbahnmarkierungen und der Begriff der Retroreflexion erläutert. Anschließend wird auf das Messprinzip eines Lidar-Sensors bei der Detektion von Fahrbahnmarkierungen eingegangen, um die in der Literatur ausstehenden Fragestellungen bezüglich der zu erfüllenden Sensorcharakteristika zu beantworten.

Eine der größten Herausforderungen besteht anschließend darin, aus den wenigen gültigen und mit Rauschen überlagerten Messwerten ein konsistentes Fahrbahnmodell zu schätzen. Hierfür wird ein neues und echtzeitfähiges Verfahren (Abschnitt 1.2.2) zur iterativen histogrammbasierten Schätzung der Fahrbahnausrichtung und des Fahrbahnverlaufs vorgestellt.

### 3.1 Eigenschaften moderner Fahrbahnmarkierungen

Die Eigenschaften moderner Fahrbahnmarkierungen bei aktiver Beleuchtung sind grundlegend für ein weiteres Verständnis der Funktionsweise einer lidarbasierten Erkennung von Fahrbahnmarkierungen. Wie bereits einleitend erwähnt, basiert die Erkennung von Fahrbahnmarkierungen auf einer Eigenschaft, die als Retroreflexion bezeichnet wird. Eine Erklärung, was sich hinter dem Begriff der Retroreflexion verbirgt, wie diese bei Fahr-

bahnmarkierungen erreicht wird und zudem quantitativ gemessen werden kann, erfolgt in diesem Abschnitt.

In 3.1.1 werden einleitend die allgemeinen Anforderungen an Fahrbahnmarkierungsmaterialien erörtert. Anschließend erfolgt in 3.1.2 die Einführung einer der wichtigsten Eigenschaften von Fahrbahnmarkierungen, die der Retroreflexion. In Unterabschnitt 3.1.3 wird abschließend kurz auf die am häufigsten verwendeten Systeme zum Aufbringen von Fahrbahnmarkierungen eingegangen.

#### 3.1.1 Anforderungen an Fahrbahnmarkierungssysteme

Gut sichtbare und funktionsfähige Fahrbahnmarkierungen sind für eine sichere und flüssige Verkehrsführung von großer Bedeutung. Gerade bei Dunkelheit und widrigen Witterungsverhältnissen ist die Verkehrsführungsfunktion von Fahrbahnmarkierungen überdurchschnittlich groß. Weltweit gehören sie zu dem am häufigsten eingesetzten Instrument um eine kontinuierliche visuelle Führung der Kraftfahrer sicherzustellen und diese zu entlasten [Die07].

##### Geschichtlicher Hintergrund

Bereits im 19. Jahrhundert wurde über Fahrbahnmarkierungen zur Aufteilung des Straßenquerschnittes und zur Führung des Verkehrs diskutiert. Verwirklicht wurde dies erst zu Beginn des 20. Jahrhunderts. Etwa um 1916 wurden in Europa erste Markierungen in England appliziert.

Auf der Reichsautobahn wurde erstmals die Straßenmitte 1932 mit einer durchgehenden Linie markiert. Diese Markierungen waren in schwarzer Farbe aufgetragen, um einen guten Kontrast zur hellen Betondecke zu gewährleisten. Die heutige verkehrsrechtliche Bedeutung von Fahrbahnmarkierungen hatten sie jedoch nicht. Ihre Aufgabe bestand lediglich darin, die Aufteilung eines Straßenquerschnittes zu verdeutlichen, also eine Abgrenzung zwischen dem rechten und linken Fahrstreifen darzustellen.

Ab 1935 wurden Markierungen auf den deutschen Autobahnen zum festen Bestandteil des neuen Straßensystems. In 1936 wurde die „Richtlinie über die vorläufige Ausrüstung der Reichsautobahnen“ und 1938 die „Vorläufigen Anweisungen für die Durchführung der Bauarbeiten an den Reichsautobahnen“, herausgegeben in denen geregelt wurde, wie Autobahnen zu markieren waren [Die07].

##### Heutiger Stand

Mit dem Ausbau des Straßennetzes und dem starken Anstieg der Verkehrsdichte in der zweiten Hälfte des 20. Jahrhunderts, hat die Bedeutung von Fahrbahnmarkierungen und insbesondere die der eingesetzten Materialien einen kontinuierlichen Wandel erfahren. Von einem reinen „weißen Farbstrich“ Anfang des 20. Jahrhunderts bis hin zu qualitativ hochwertigen und langlebigen Markierungssystemen.

An heutige Materialien für Fahrbahnmarkierungen werden eine ganze Reihe von Anforderungen gestellt. Als wichtigste Anforderungen zu nennen sind:




Abbildung 3.1: In (a), eine der ersten selbstfahrenden Markiermaschinen in Deutschland der Firma Baumbach aus Kassel [Die07]. Noch bis in die 70er Jahre des 20. Jahrhunderts waren Fahrbahnmarkierungen auf bestimmten Autobahnabschnitten äußerst schwer zu erkennen (b).

- Tagsichtbarkeit
- Nachtsichtbarkeit
- Griffigkeit
- Verschleißfestigkeit
- Überrollbarkeit

Mit Blick auf die Bundesrepublik Deutschland, sind diese Anforderungen in den nationalen Verwaltungsvorschriften ZTV M 02 „Zusätzliche Technische Vertragsbedingungen und Richtlinien für Markierungen auf Straßen“ und TL M 06 „Technische Lieferbedingungen für Markierungsmaterialien“ festgelegt [Die07]. Diese erfassen neben dem Herstellungsprozess auch den Liefer- und Applikationsprozess von Fahrbahnmarkierungen.

Die wichtigste Eigenschaft von Fahrbahnmarkierungen mit Bezug auf eine lidarbasierte Fahrstreifenenerkennung, stellt die Anforderung bezüglich einer ausreichenden Sichtbarkeit bei Dunkelheit mit aktiver Beleuchtung durch Scheinwerferlicht dar. Damit Fahrbahnmarkierungen bei Nacht und aktiver Beleuchtung besser wahrgenommen werden können, müssen diese retroreflektiv ausgeführt werden [Die07, U.S07, ZS98, U.S94]. Vereinfacht beschreibt Retroreflexion die Eigenschaft von Materialien, den überwiegenden Teil der Energie des einfallenden Lichtes in die Richtung der Quelle zu reflektieren.

Eine detaillierte Einführung zu den retroreflektiven Eigenschaften von Fahrbahnmarkierungen und wie das Phänomen der Retroreflexion quantitativ gemessen und bewertet werden kann, erfolgt in dem nächsten Abschnitt.

### 3.1.2 Retroreflektive Eigenschaften von Fahrbahnmarkierungen

Grundsätzlich kann zwischen drei Reflexionsarten unterschieden werden:

- Spiegelung
- Diffuse Reflexion
- Retroreflexion

Bei der Spiegelung wird der Großteil des einfallenden Lichtes an dem Normalenvektor der auftreffenden Oberfläche *gespiegelt* (Abbildung 3.2(a)). Nur ein Teil der Energie wird gestreut. Legt man eine gleichmäßige und nicht spiegelnde Oberfläche zu Grunde, wird das einfallende Licht zum größten Teil diffus reflektiert, welches als *diffuse* Reflexion bezeichnet wird (Abbildung 3.2(b)). Da eine solche Oberfläche allenfalls unter idealisierten Bedingungen existiert, ist diese Betrachtungsweise nicht vollständig, jedoch zur Veranschaulichung durchaus geeignet. Ein umfassender Überblick über die Modellierung von Reflexionseigenschaften „realer“ Oberflächen anhand der „Bidirektionalen Reflektanzverteilungsfunktion“ (BRDF)<sup>1</sup> kann in [RL10] gefunden werden. Die dritte Art der Reflexion ist die Retroreflexion. Bei einer „perfekten“ Retroreflexion würde die gesamte einfallende Lichtmenge entlang der Achse zwischen Lichtquelle und auftreffender Oberfläche reflektiert werden. Unabhängig davon, ob sich ein solch idealisierter Retroreflektor in der Realität anfertigen lässt, wäre ein solches Verhalten äußerst ungeeignet, um die Nachtsichtbarkeit von Fahrbahnmarkierungen zu verbessern. Dies liegt darin begründet, dass der Winkel des einfallenden Lichtes der aktiven Beleuchtung durch die Scheinwerfer nicht mit dem Beobachtungswinkel des Fahrers übereinstimmt. Vielmehr ist Retroreflexion so zu verstehen, dass der überwiegende Teil des einfallenden Lichtes, gestreut entlang des Einfallswinkels, zurückreflektiert wird (Abbildung 3.2(c)). Zum tieferen Verständnis, wie Retroreflexion quantitativ erfasst werden kann, ist zuerst die Einführung von Grundlagen der Photometrie notwendig.

#### Grundlagen der Photometrie

Grundlegende geometrische Größe ist der Raumwinkel  $\Omega$ . Er ist definiert als Teilfläche  $S$  einer Kugel, dividiert durch das Quadrat des Radius  $r$  einer Kugel:

$$\Omega = \frac{S}{r^2}. \quad (3.1)$$

Raumwinkel werden in der Einheit *Steradian* (sr) angegeben. Ein Raumwinkel von 1 sr umschließt somit auf einer Einheitskugel mit dem Radius 1 m eine Fläche von 1 m<sup>2</sup>. Der Raumwinkel ist so definiert, dass 4 $\pi$  der Fläche der Einheitskugel entsprechen. Analog zum zweidimensionalen Fall, bei dem 2 $\pi$  den Umfang des Einheitskreises entsprechen. Auf Basis des Raumwinkels, kann der Begriff des Lichtstroms und die damit verbundene SI-Basiseinheit [Phy07] für die Lichtstärke  $I_v$ , die *Candela* (cd), definiert werden. Die Candela bezeichnet ein genormtes Maß für die ausgesendete Lichtstärke einer isotropen <sup>2</sup> Lichtquelle

---

<sup>1</sup>engl. Bidirectional reflectance distribution function

<sup>2</sup>Energie die in alle Raumrichtungen gleichmäßig abgestrahlt wird




Abbildung 3.2: In (a), die Spiegelung. Der Teil des Lichts  $I_v$ , der nicht absorbiert worden ist, wird als  $M_v$  reflektiert. In (b), die diffuse Reflexion.  $C$  beschreibt zur Veranschaulichung die sogenannte *Indikator*, welche als eine Hülle um die reflektierte Energie definiert ist. In (c), die Retroreflexion. Bei der Retroreflexion wird der größte Teil des einfallenden Lichtes in Richtung der Quelle reflektiert.

pro Raumwinkeleinheit sr. Die Definition der Candela hat sich historisch bereits mehrfach geändert und ist zurzeit definiert als [Phy07]:

*Die Candela ist die Lichtstärke in einer bestimmten Richtung einer Strahlungsquelle, die monochromatische Strahlung der Frequenz  $540 \times 10^{12}$  Hertz aussendet und deren Strahlstärke in dieser Richtung  $\frac{1}{683}$  Watt durch Steradian beträgt.*

Mit der Candela als photometrische Basiseinheit, kann die Einheit des Lichtstroms  $\Phi$ , die *Lumen*, definiert werden. Ein Lumen (lm) entspricht dabei der Menge an Energie, die bei einer isotropen Lichtquelle von 1 Candela in einem Raumwinkel ausgestrahlt wird. Es gilt also  $\text{cd} = \text{lm}/\text{sr}$ . Die Lichtstärke  $I_v$  ist dann definiert als:

$$I_v = \frac{\Phi}{\Omega}. \quad (3.2)$$

Als Beispiel ergibt sich so für die Einheitskugel mit einer isotropen Lichtquelle von 1 cd eine Strahlleistung von  $4\pi \times 1 \text{ lm} \approx 12.57 \text{ lm}$ . Eine weitere Größe, die insbesondere dann von Bedeutung ist, wenn  $r \neq 1$  gilt, ist die Beleuchtungsstärke  $E_v$ . Sie ist definiert als der Quotient von Lichtstrom  $\Phi$  und beleuchteter Fläche  $A$ :

$$E_v = \frac{\Phi}{A}. \quad (3.3)$$

Die Einheit der Beleuchtungsstärke ist Lux (lx) und es gilt  $\text{lx} = \text{lm}/\text{m}^2$ . Der Unterschied zwischen Lichtstärke und Beleuchtungsstärke, soll durch folgendes Beispiel veranschaulicht werden. Eine isotrope Lichtquelle von 1 cd emittiert bei einem Raumwinkel von 0.25 sr einen Lichtstrom von 0.25 lm. Somit ergibt sich bei einem Radius von  $r = 1 \text{ m}$  in Abbildung 3.3(a)

für die Fläche  $A$  eine Beleuchtungsstärke von 1 lx. Die Lichtquelle in Abbildung 3.3(b) emittiert ebenfalls bei 0.25 sr einen Lichtstrom von 0.25 lm auf die Fläche  $A'$ , jedoch ergibt sich bei  $r = 1.25$  m für  $A'$  nur eine Beleuchtungsstärke von 0.64 lx. Folglich, nimmt die Beleuchtungsstärke einer Fläche mit dem Quadrat der Entfernung  $r$  ab und es gilt:

$$E_v = \frac{\Phi}{A} = \frac{I_v \Omega}{A} = \frac{I_v}{r^2}. \quad (3.4)$$

Dieser Zusammenhang ist von großer Bedeutung und findet Anwendung in der nachfolgenden Bewertung der optimalen Sensorausrichtung zur Detektion von Fahrbahnmarkierungen mit einem Lidar.




Abbildung 3.3: Beispiel für den Unterschied zwischen Lichtstrom und Beleuchtungsstärke. Die isotrope Lichtquelle im Zentrum beider Kugeln emittiert bei gleichem Raumwinkel auf beide Flächen,  $A$  und  $A'$ , den gleichen Lichtstrom. Durch die unterschiedliche Entfernung zu der Lichtquelle, entsteht jedoch eine unterschiedliche Beleuchtungsstärke von  $A$  und  $A'$ .

Die letzte zu definierende Größe ist die Leuchtdichte  $L$ , welche durch den Quotienten zwischen der Lichtstärke  $I_v$  und der Fläche  $A$

$$L = \frac{I_v}{A} \quad (3.5)$$

definiert ist. Die Leuchtdichte besitzt keine eigene Maßeinheit und wird in  $\text{cd}/\text{m}^2$  angegeben.

### Leuchtdichtekoeffizient bei Retroreflexion

Die am häufigsten verwendete Beschreibung, um die Retroreflexion zu erfassen, ist der „Leuchtdichtekoeffizient bei Retroreflexion“,  $R_L$ . Er ist definiert als der Quotient zwischen

der Leuchtdichte  $L$  und der Normalen der Beleuchtungsstärke  $E_{\perp}$  [Die07, U.S07]:

$$R_L = \frac{L}{E_{\perp}}. \quad (3.6)$$

Die Einheit für den Leuchtdichtekoeffizient bei Retroreflexion ist  $\text{mcd}/\text{m}^2/\text{lx}$  (Millicandela je  $\text{m}^2$  und Lux).

Da die Lichtstärke der Quotient von Lichtstrom und Raumwinkel ist (3.2), ist die Leuchtdichte  $L$  die reflektierte Lichtstärke pro Flächeneinheit einer Fahrbahnmarkierung. Die Normale der Beleuchtungsstärke  $E_{\perp}$  ist die Beleuchtungsstärke  $E_v$  pro Flächeneinheit, gemessen auf einer Ebene orthogonal zu der Achse der Beleuchtungsquelle. Abbildung 3.4 verdeutlicht diesen Zusammenhang und zeigt zusätzlich zwei wichtige Größen bei der Messung von Retroreflexion, den Anleuchtungswinkel  $\alpha_v$  und den Beobachtungswinkel  $\beta_v$ . Der




Abbildung 3.4: Standardgeometrie zur Messung des Leuchtdichtekoeffizienten bei Retroreflexion,  $R_L$ . Der Anleuchtungswinkel  $\alpha_v$  beträgt bei einer Distanz von 30 m und einer Scheinwerferhöhe von 0.64 m  $1.24^\circ$ . Der Beobachtungswinkel von  $\beta_v = 2.29^\circ$  ergibt sich unmittelbar aus der genormten Beobachtungshöhe von 1.2 m.

Anleuchtungswinkel  $\alpha_v$  definiert den Winkel zwischen der Lichtquelle und der zu messenden Fläche (Markierung). Der Beobachtungswinkel  $\beta_v$  beschreibt den Winkel, bei dem die reflektierte Lichtstärke im Verhältnis zu der Beleuchtungsstärke einer genormten Fläche gemessen wird. Die Größe der Fläche  $A$  mit  $1\text{ m}^2$  (Abbildung 3.4) ergibt sich dabei unmittelbar aus der Definition für die Beleuchtungsstärke, die in  $\text{lx} = \text{lm}/\text{m}^2$  angegeben wird. Die Entfernung, der Anleuchtungs- und Beobachtungswinkel (Abbildung 3.4) sind für einen Messaufbau durch die *Standardgeometrie* [Die07, U.S07] vorgegeben und leiten sich direkt aus der genormten Scheinwerfer- und Beobachtungshöhe von 0.64 m und 1.2 m ab. In der Praxis wird der Leuchtdichtekoeffizient bei Retroreflexion mit dafür ausgelegten photometrischen Messsystemen überprüft, welche die Standardgeometrie in kleinerem Maßstab nachbilden.

### 3.1.3 Markierungssysteme und Markierungstypen

In dem vorherigen Teilabschnitt 3.1.2 wurde die Größe zur Messung von Retroreflexion, der Leuchtdichtekoeffizient bei Retroreflexion ( $R_L$ ), eingeführt. Dieser Abschnitt beschäftigt sich damit, wie Retroreflexion bei Fahrbahnmarkierungen erreicht werden kann. Darüber hinaus, werden einige Materialien mit unterschiedlichen Eigenschaften zum Erstellen

von Fahrbahnmarkierungen vorgestellt. Zusätzlich wird eine Einteilung von Markierungstypen in zwei Klassen vorgenommen, Standardmarkierungen (Typ I) und Markierungen mit erhöhter Retroreflexion bei Nässe (Typ II).

In den letzten Jahrzehnten wurden verschiedene Materialien zum *Applizieren*<sup>3</sup> von dauerhaften oder temporären Fahrbahnmarkierungen entwickelt, die sich unter den Aspekten der Haltbarkeit und Wirtschaftlichkeit besonders gut eignen. Als Beispiel zu nennen sind hierfür Kaltspritzplastiken, für dauerhafte Markierungen und Folien, für temporäre Markierungen. Ein umfassender Überblick über gängige Verfahren kann in [Die07] gefunden werden. Um eine ausreichende Retroreflexion von Fahrbahnmarkierungen zu erreichen, werden in die für Markierungen verwendeten Grundmaterialien, auch Binder genannt, mehrere tausende Glasperlen (Reflexperlen) pro m<sup>2</sup> beigemischt.

Abbildung 3.5(a) zeigt eine mikroskopische Aufnahme von Markierungsmaterial mit eingebetteten Reflexperlen. Bei korrekter Applizierung wirken diese wie ein Prisma, welches das Licht bündelt und an der in dem Binder eingebetteten Rückseite reflektiert (Abbildung 3.5(b)). Reflexperlen besitzen zwei entscheidende Eigenschaften, die sie zur Erhöhung der Retroreflektivität einzigartig machen. Zum einen ist dies der wirtschaftlich geringe Preis, zum anderen ihre Eigenschaft eine ausreichende Retroreflektivität bei äußerst geringem Anleuchtungswinkel ( $\alpha_v = 1.24^\circ$ ) zu gewährleisten. Reflexperlen besitzen




Abbildung 3.5: Abbildung (a) zeigt die in der Farbe der Markierung eingebetteten Reflexperlen bei starker Vergrößerung. Abbildung (a) zeigt die Funktionsweise der Reflexperlen bei einfallendem Licht  $I_v$ . Ein Großteil des Lichtes wird als  $M_v$  entlang der Beleuchtungsachse reflektiert.

üblicherweise einen Durchmesser von 60  $\mu\text{m}$  bis 850  $\mu\text{m}$  und erreichen ihren besten Wirkungsgrad bei einer Einbettung von 50% - 60%. Zusätzlich kann eine Einteilung nach dem Brechungsindex ( $RI$ ) der Reflexperlen vorgenommen werden. Grundsätzlich gilt, je größer der Brechungsindex, desto mehr Licht wird reflektiert. Er gilt somit als Gütemaß für die Qualität, wobei ein Brechungsindex von 1.5 als ein guter Kompromiss zwischen Wirtschaftlichkeit und Leistungsfähigkeit gilt [U.S94].

Wie bereits erwähnt, kann prinzipiell zwischen zwei verschiedenen Typen von Markierungen unterschieden werden: Standardmarkierungen (Typ I), und Markierungen mit erhöhter Retroreflexion bei Nässe (Typ II). Bis Mitte der 1980er Jahre waren lediglich Typ

<sup>3</sup>Aufbringen auf den Fahrbahnbelag

I Fahrbahnmarkierungen bekannt. Die Problematik aller Typ I Markierungen ist, dass sich bei nasser Fahrbohnoberflache ein Wasserfilm auf der Markierungsoberflache bildet und dadurch die Retroreflexion extrem herabgesetzt wird (Abbildung 3.6). Je nach Starke des uberdeckenden Wasserfilms, fuhrt dies im ungunstigsten Fall zu einer totalen Spiegelung. Dieser Nachteil und die damit verbundenen Gefahren fur die Verkehrsteilnehmer fuhrten letztendlich zu einer Entwicklung von Markierungssystemen mit verbesserter Retroreflexion bei Nasse.




Abbildung 3.6: Beeintrachtung der Funktionsweise von Typ I Markierungen bei Nasse. Ein Groteil des einfallenden Lichtes wird an dem uberdeckenden Wasserfilm gespiegelt bevor es uberhaupt in die Reflexperle eintreten kann. Die Folge ist eine stark verminderte Retroreflexion.

Alle Typ II Markierungen verbindet die Grundidee, dass Teile der Markierung so ausgebildet werden, dass sie aus der flachen Oberflache –und somit aus dem Wasserfilm– herausragen. Dies erfolgt entweder durch das Nachstreuen von groen Reflexperlen bei *Dunnschichtsystemen* oder durch Applizieren von profilierten *Dickschichtsystemen*, bei denen groe Teile der Markierung so ausgebildet sind, dass sie aus dem Wasserfilm herausragen. Abbildung 3.7 zeigt als Beispiel zwei Agglomerat-Markierungen die zu der Klasse der Dickschichtsysteme zahlen. Es ist deutlich zu erkennen, dass beide Markierungen eine profilierte Oberflache aufweisen, die das Abflieen von Wasser begunstigt. Zusatzlich wird an Teilen der Markierung der Winkel, in dem das einfallende Licht auf die Oberflache auftrifft, durch die nicht mehr orthogonale Oberflachennormale erheblich verbessert.

Es ist zu erwahnen, dass Typ II Markierungen bei Trockenheit nicht zwingend einen besseren Leuchtdichtekoeffizienten bei Retroreflexion aufweisen mussen. Es existiert sogar ein entscheidender Nachteil: die Tagsichtbarkeit bei Gegenlicht (Abbildung 3.8). Da die Tagsichtbarkeit von Markierungen fur ein aktives System keine Bedeutung hat, entsteht somit kein Nachteil aus Sicht einer lidarbasierten Fahrstreifenenerkennung. Jedoch kann diese Eigenschaft zu erheblichen Beeintrachtigungen bei videobasierten Systemen fuhren, die auf das Umgebungslicht angewiesen sind. Unter bestimmten Umstanden, sind diese Markierungen daher fur passive Sensorsysteme auerst schwierig zu detektieren, da kein ausreichender Kontrast zwischen Fahrbohnbelag und Markierung gegeben ist.

Eine letzte zu klarende Frage ist, welchen Leuchtdichtekoeffizienten bei Retroreflexion heutige Fahrbohnmarkierungen aufweisen mussen. Aus Grunden der nicht vorhandenen allgemeinen Gultigkeit, kann an dieser Stelle nicht direkt auf eine Groenordnung fur den




Abbildung 3.7: Beispiel für zwei Agglomerat-Markierungen mit erhöhter Retroreflexion bei Nässe. Es ist deutlich zu erkennen, dass beide Markierungen eine profilierte Oberfläche aufweisen, die das Abfließen von Wasser begünstigt.



Abbildung 3.8: Aufnahme einer Typ II Agglomerat-Markierung bei Gegenlicht [Die07]. Ein großer Nachteil von Typ II Markierungen ist ihre schlechte Tagsichtbarkeit bei Gegenlicht, die eine Erkennung mit einem videobasierten System erheblich erschwert.

Leuchtdichtekoeffizienten bei Retroreflexion eingegangen werden, da sich dieser in verschiedenen Normen teils erheblich unterscheidet. Jedoch kann ein Wert von  $\approx 100 \text{ mcd/m}^2/\text{lx}$  als realistisches Beispiel für  $R_L$  angenommen werden. Der interessierte Leser ist auf das Kapitel 6.3.1 verwiesen, in dem detailliert auf die Normung und die Klasseneinteilung von Retroreflexion eingegangen wird.

### 3.1.4 Bedeutung für die lidarbasierte Fahrstreifenerkennung

Die eben vorgestellten Prinzipien können fast vollständig auf das Messprinzip eines Lidar-Sensors übertragen werden. Sie unterscheiden sich lediglich bezüglich folgender Aspekte:

- Anleuchtungs- und Beobachtungswinkel
- Wellenlänge des ausgesendeten Lichtes

#### Anleuchtungs- und Beobachtungswinkel

Entgegen der Auslegung der Standardgeometrie, bei der sich der Anleuchtungswinkel von  $\alpha_v = 1.24^\circ$  vom Beobachtungswinkel von  $\beta_v = 2.29^\circ$  unterscheidet, sind der Anleuchtungs- und Beobachtungswinkel bei einem automotiv-tauglichen Lidar identisch. Die Sende- und Empfangsdioden sind üblicherweise im selben Gehäuse untergebracht und es gilt  $\alpha_v \approx \beta_v$ . Diese Tatsache kann jedoch vernachlässigt werden, denn wie aus Abschnitt 3.1.2 bekannt ist, wird bei der Retroreflexion der größte Teil des Lichtes entlang der Achse der Beleuchtungsquelle gestreut. Aus der Theorie ergibt sich für den Fall von  $\alpha_v = \beta_v$  sogar ein Vorteil, jedoch ist dieser bei einer Winkeldifferenz von  $1.05^\circ$  ebenfalls zu vernachlässigen.

#### Wellenlänge des ausgesendeten Lichtes

Ähnlich wie ein Scheinwerfer, sendet ein Lidar einen Lichtimpuls aus, welcher von der Rückseite der Reflexperlen gebündelt reflektiert wird. Ein Unterschied besteht jedoch in der Wellenlänge des ausgesendeten Lichtimpulses. Während ein Scheinwerfer überwiegend Licht im sichtbaren Spektralbereich von 380 nm - 780 nm emittiert, arbeitet die Sendediode eines Lidar-Sensors bei einer Wellenlänge von etwa 900 nm. Diese Wellenlänge zählt zu dem sogenannten Nah-Infrarotspektrum, welches im Gegensatz zu dem Fern-Infrarotspektrum, in seinen Eigenschaften dem sichtbaren Spektrum sehr ähnlich ist. Insbesondere bei einem Spektralbereich von 900 nm bis 1000 nm, der unmittelbar an das sichtbare Spektrum angrenzt, ist eine Beeinträchtigung der retroreflektiven Eigenschaften von Fahrbahnmarkierungen nicht zu erwarten. Dieser Aspekt kann daher ebenfalls vernachlässigt werden.

## 3.2 Messprinzip eines Lidar-Sensors

Für die erfolgreiche Detektion von Fahrbahnmarkierungen mit einem Lidar sind neben den reinen Materialeigenschaften von Fahrbahnmarkierungen, eine ganze Reihe weiterer Faktoren maßgebend. In diesem Abschnitt werden zuerst die notwendigen theoretischen Grundlagen zur Funktionsweise eines Lidars vorgestellt. Zusätzlich werden Anforderungen an die Eigenschaften eines abstrakten Lidar-Sensors definiert, die für die Detektion von Fahrbahnmarkierungen mit Lidar-Sensorik notwendig sind oder zumindest empfohlen werden. In Unterabschnitt 3.2.2, wird zudem eine entscheidende Größe bei der Erkennung von Fahrbahnmarkierungen eingeführt, das Signal-Rausch-Verhältnis (SNR) zwischen Fahrbahnmarkierungen und Fahrbahnbelag.

### 3.2.1 Funktionsweise

Der Vollständigkeit halber wird an dieser Stelle kurz auf das wesentliche Messprinzip eines Lidars, das der Lichtlaufzeitmessung, eingegangen.

Betrachtet man das Messprinzip des Pulslaufzeitverfahren, wird zur Bestimmung der Distanz eines Objekts direkt die Laufzeit eines sehr kurzen Laserpulses gemessen. Mit der Konstante  $c_L$  für die Geschwindigkeit des Lichtes, kann die Distanz zum Ziel  $r$ , wie folgt bestimmt werden:

$$r = \frac{c_L \Delta t}{2}. \quad (3.7)$$

Der von einem Ziel reflektierte und auf der Empfängerfläche detektierte Puls wird im Folgenden als *Echopuls* bezeichnet. Je nach Einfallswinkel und Oberflächeneigenschaft des Objektes, wird der einfallende Laserpuls zu unterschiedlichen Anteilen absorbiert, reflektiert und diffus gestreut. Für die gemessene Beleuchtungsstärke  $E_f$ , die ein Echopuls an der Empfängerfläche eines Lidars erzeugt, gilt die Laser-Radar Gleichung [Für04], die wie folgt definiert ist:

$$E = \sigma_{\text{br}} \frac{\Phi_0}{\pi^2 \sin^2 \chi r^4} A \cos \eta \cos \gamma \quad (3.8)$$

mit

- $\sigma_{\text{br}}$  : Oberflächenreflektivität,
- $\Phi_0$  : Sendeleistung des Lidars,
- $\chi$  : Strahldivergenz des Laserpulses,
- $\gamma$  : Einfallswinkel auf den Empfänger,
- $\eta$  : Einfallswinkel auf das Objekt,
- $r$  : Distanz zum Objekt,
- $A = \pi \sin^2 \chi r^2$  : Querschnittsfläche des Laserpulses.

Der Einfallswinkel  $\eta$  ist so definiert, dass er den Winkel zwischen der Hauptachse des Laserlichtes und der Oberflächennormalen beschreibt. Es gilt  $\alpha_v = 90^\circ - \eta$ . Unter der Annahme, dass der gesamte Lichtstrom das Ziel erfasst und der Echopuls bei einem Lidar immer senkrecht auf die Empfängerfläche einfällt, gilt für die auf der Empfängerfläche auftreffende Beleuchtungsstärke  $E_f$ :

$$E_f(\sigma_{\text{br}}, r, \eta) = \sigma_{\text{br}} \frac{\Phi_0}{\pi r^2} \cos \eta. \quad (3.9)$$

Es gilt zu beachten, dass Gleichung 3.9 nur bedingt Gültigkeit besitzt, wenn der Lichtstrom  $\Phi_0$  das Objekt nicht vollständig erfasst. Nach Fürstenberg et al. [Für04], kann Gleichung 3.9 noch weiter vereinfacht werden, wenn die Oberfläche des Objektes über retroreflektive Eigenschaften verfügt. Es gilt:

$$E_{\text{Refl}}(\bar{\sigma}_{\text{br}}, r) = \bar{\sigma}_{\text{br}} \frac{\Phi_0}{\pi r^2} \quad (3.10)$$

mit  $\bar{\sigma}_{\text{br}}$  als Konstante für die Oberflächenreflektivität der retroreflektiven Fläche. Durch die retroreflektiven Eigenschaften wird davon ausgegangen, dass die Beleuchtungsstärke auf der Empfängerfläche unabhängig von dem Einfallswinkel  $\eta$  ist. Es ist offensichtlich, dass diese Vereinfachung nur bedingte Gültigkeit besitzen kann. Diese Annahme impliziert einen *perfekten* Retroreflektor, der selbst bei  $\eta = 90^\circ$  retroreflektive Eigenschaften aufweist. Unabhängig der Einschränkung dieser vereinfachten Annahme, ist diese Definition äußerst hilfreich für das spätere Verständnis bei der Wahl der optimalen Position eines Lidars zur Fahrstreifendetektion.

### 3.2.2 Signal-Rausch-Verhältnis zwischen Fahrbahnmarkierung und Fahrbahnbelag

Ähnlich zu der videobasierten Fahrstreifenenerkennung, bei der eine erfolgreiche Detektion von dem Kontrast zwischen Fahrbahnmarkierungen und dem Fahrbahnbelag im visuellen Spektrum abhängt, gilt dieses in abgeänderter Form auch für eine lidarbasierte Erkennung von Fahrbahnmarkierungen. Grundsätzlich existieren mehrere Möglichkeiten, um ein Signal-Rausch-Verhältnis (SNR<sup>4</sup>) zwischen Fahrbahnmarkierungen (Nutzleistung) und dem Fahrbahnbelag (Rauschleistung) zu definieren. Zu beachten ist, dass das SNR als Empfängergröße definiert wird, da es die Abhängigkeit zwischen den unterschiedlichen Reflexionseigenschaften der Objektoberflächen berücksichtigen muss.

Eine Möglichkeit ist, das SNR als Quotient zwischen der Leuchtdichte (3.5) von Fahrbahnmarkierung und Fahrbahnbelag zu definieren. Aus (3.5) ergibt sich bei Annahme der gleichen Größe für  $A$ , der Quotient zwischen der emittierten Lichtstärke  $I_v$  von Fahrbahnmarkierung und Fahrbahnbelag. Geeigneter ist eine Definition, die zusätzlich noch die Auswirkung unterschiedlicher Einfallswinkel berücksichtigt. Das SNR wird daher als der Quotient zwischen der Beleuchtungsstärke  $E_{\text{Refl}}$  von retroreflektierenden Oberflächen, die ein Echopuls an der Empfängerfläche eines Lidars erzeugt und der Beleuchtungsstärke  $E_f$ , für diffus-spiegelnd reflektierende Oberflächen definiert:

$$\text{SNR}_{\text{M,dB}} = 20 \lg \left( \frac{E_{\text{Refl}}}{E_f} \right) = 20 \lg \left( \frac{\bar{\sigma}_{\text{br}}}{\sigma_{\text{br}} \cos \eta} \right). \quad (3.11)$$

### 3.2.3 Anforderungen an die Eigenschaften eines abstrakten Lidar-Sensors zur Detektion von Fahrbahnmarkierungen

Für eine genauere Betrachtung ist es erforderlich, Anforderungen an die Eigenschaften eines Lidars bezüglich der Sensorcharakteristik und der Anbauposition zu definieren. Auf der einen Seite ist es für eine allgemeine Gültigkeit der Erkenntnisse wünschenswert, möglichst wenige zu erfüllende Sensorcharakteristiken festzulegen, auf der anderen Seite ist dies in einigen Fällen zwingend notwendig, um die praktische Umsetzbarkeit nach dem Stand der heutigen Technik zu ermöglichen.

---

<sup>4</sup>engl. signal-to-noise-ratio

Es werden daher Anforderungen an einen abstrakten Lidar-Sensor bezüglich folgender Eigenschaften gestellt:

- Position des Sensors
- Mehrzielfähigkeit
- Horizontale und vertikale Winkelauflösung
- Horizontaler und vertikaler Öffnungswinkel

In der Literatur existieren betreffend der oben genannten Anforderungen nur wenige bis keine Erkenntnisse. Es ist daher erforderlich, die einzelnen Sachverhalte ausführlich zu diskutieren um mögliche Anforderungen zu definieren.

#### Position des Sensors

Für die Detektion von Fahrbahnmarkierungen ist es fundamental, dass diese von dem Laserstrahl erfasst werden. Betrachtet man zur Vereinfachung die intrinsischen Parameter des Sensors nicht und vernachlässigt zusätzlich mögliche Einflüsse durch Nick- und Rollbewegungen des Fahrzeugs und der Fahrbahnneigung, entscheidet lediglich die relative Position des Sensors  $\mathbf{S}_x$  im Bezug zu dem Fahrzeugkoordinatensystem  $\mathbf{S}_0$ , ob ein Lidar die Fahrbahnoberfläche erfasst oder nicht. Es sei angemerkt, dass dieses nicht mit einer erfolgreichen Zieldetektion zu verwechseln ist, sondern lediglich die Richtung des ausgesendeten Impulses beschreibt. Die theoretische Betrachtung bezieht sich dabei aus Gründen der Veranschaulichung zuerst auf einen Lidar mit nur einem Laserstrahl.

Für die folgende Betrachtung sind insbesondere der in  $\mathbf{S}_x$  definierte Nickwinkel  $\theta_s$  und die Höhe des Sensors  $Y_s$  von Bedeutung. Der Winkel  $\theta_s$  definiert den Anleuchtungs- und Beobachtungswinkel (3.1.2). Zusätzlich bestimmt die Anbauhöhe des Sensors  $Y_s$  in Kombination mit  $\theta_s$  über die Entfernung, in der der Laserstrahl die Fahrbahnoberfläche erfasst. Die daraus resultierende Fragestellung beschäftigt sich somit mit der Optimierung des Anleuchtungswinkels in Kombination mit der optimalen Entfernung, in der der Laserstrahl auf den Boden trifft.

An dieser Stelle soll kurz auf die in [Rey06] vorgestellten theoretischen Betrachtungen und experimentellen Ergebnisse bezüglich der „optimalen“ Sensorposition eingegangen werden. Für die Abschätzung der maximalen Detektionsreichweite und Verfügbarkeit einer lidarbasierten Markierungsdetektion, wurde in [Rey06] eine Variation der Entfernung und des Winkels, in der ein Laserstrahl auf das Ziel trifft, durchgeführt. Anschließend wurde die im Sensor empfangene Rückstrahlintensität  $I_S$  in Abhängigkeit zu der Entfernung und dem Winkel zu zwei Zielen in einem experimentellen Aufbau betrachtet. Das erste der beiden Ziele entsprach in seinen Reflexionseigenschaften dem des Fahrbahnbelages. Das zweite Ziel war mit einer temporären Fahrbahnmarkierung mit Reflexperlen beklebt, welches somit über die Eigenschaft verfügte, Licht bei niedrigem Anleuchtungswinkel zur Quelle zu reflektieren.

Es wurden folgende Thesen aufgestellt, die es zu verifizieren galt. Erstens, mit zunehmender Distanz  $d$  zum Ziel, sinkt die Rückstrahlintensität  $I_S$ . Zweitens, es besteht eine

Abhängigkeit zwischen der Stärke von  $I_S$  und dem Einfallswinkel des Laserstrahls auf dem Ziel. Es wurde vermutet, dass der Betrag der Rückstrahlintensität mit wachsendem Einfallswinkel  $\eta_i$  zwischen Strahl und Oberflächennormalen der Markierung sinkt. Die in [Rey06] gewählten Winkelschritte für den Einfallswinkel  $\eta_i$  entsprechen dabei dem Winkel zwischen der Normalen des Ziels und der Sensorachse. Es gilt  $\alpha_v = 90^\circ - \eta$ . Drittens, die Beschaffenheit der Oberfläche hat direkten Einfluss auf die Rückstrahlintensität  $I_S$ .

In dem anschließenden Versuchsaufbau wurden die Parameter Entfernung und Winkel variiert und der jeweilige Wert für  $I_S$  bestimmt. Nach [Rey06] war eine quantitative Bewertung der Ergebnisse nicht möglich, jedoch konnten die Einflüsse von Winkel  $\eta$ , Distanz  $d$  und Retroreflexion nachgewiesen werden. Diese Erkenntnisse decken sich mit der Definition für die theoretisch empfangene Lichtstärke an der Empfängerfläche des Lidars (3.9).

Auf Basis der Ergebnisse, dass die Rückstrahlintensität mit zunehmendem Einfallswinkel und zunehmender Distanz abnimmt, wurde vorgeschlagen, den Sensor in  $Y_s$  möglichst weit über der Fahrbahnoberfläche zu installieren, um einen möglichst kleinen Einfallswinkel zu erreichen. Wie in Gleichung 3.9 ersichtlich, hat ein zunehmender Einfallswinkel  $\eta$  direkten Einfluss auf die Lichtstärke, die an der Empfängerfläche eintrifft.

Diese Annahmen betrachten jedoch nicht den Zusammenhang zwischen dem Reflexionsverhalten der Fahrbahnoberfläche (Asphalt oder Beton) und den darauf applizierten Fahrbahnmarkierungen. Bei einem Einfallswinkel  $\eta$ , der nahezu Null ist, haben Fahrbahnmarkierungen ein ähnliches Reflexionsverhalten wie beliebig diffus-spiegelnd reflektierende Oberflächen. Ihr Leuchtdichtekoeffizient bei Retroreflexion muss nicht zwangsläufig über dem von Oberflächen mit ähnlicher Farbe liegen. Erst mit zunehmendem Winkel  $\eta$ , zeigt sich der entscheidende Unterschied. Während bei beliebigen Oberflächen mit zunehmendem Einfallswinkel die empfangene Lichtstärke überproportional abnimmt, bleibt diese bei Materialien, die über Reflexperlen verfügen, nahezu konstant. Der Verlust der empfangenen Lichtstärke an der Empfängerfläche, der durch den zunehmenden Einfallswinkel entsteht, wird durch den Brechungsindex der Reflexperlen und der daraus resultierende Retroreflexion wieder ausgeglichen.

Da diese Eigenschaft nicht für den Fahrbahnbelag gilt, steigt das Signal-Rausch-Verhältnis (3.11) zwischen dem Fahrbahnbelag und den Fahrbahnmarkierungen mit zunehmendem Einfallswinkel. Analog gilt, dass mit abnehmendem Einfallswinkel das SNR sinkt.

Ein besseres Signal-Rausch-Verhältnis ist einem größeren absoluten Betrag der Rückstrahlintensität aus folgenden Gründen zu bevorzugen. Erstens, bei Fahrbahnbelägen die aufgrund ihrer Materialeigenschaften gute Reflexionseigenschaften besitzen, ist bei kleineren Einfallswinkeln eine messbare Differenz in der Rückstrahlintensität nicht zwangsläufig gegeben. Zweitens, bauartbedingt verfügen nicht alle Lidar-Sensoren über die Fähigkeit die Rückstrahlintensität ohne Mehrdeutigkeiten zu bestimmen, da dieses der Bestimmung der Amplitude des empfangenen Signals entspricht und folglich ein Abtasten des Signals erforderlich macht. Aus Gleichung 3.11 ist außerdem ein weiterer Vorteil eines möglichst großen Einfallswinkels ersichtlich. Unabhängig von der Konstante für die Oberflächenreflektivität  $\sigma_{br}$  des Fahrbahnbelages, steigt das SNR mit zunehmendem Einfallswinkel an. Dies bedeu-

tet, dass ein Wissen über die Farbe und damit über die Reflektivität des Fahrbahnbelages nicht zwangsläufig erforderlich ist.

Das Signal-Rausch-Verhältnis wird daher im Weiteren als die entscheidende Größe betrachtet, dessen Betrag durch die Wahl der Anbauposition des Sensors optimiert werden sollte. Wie bereits erwähnt, steigt das SNR (3.11) mit zunehmendem Einfallswinkel (abnehmendem Anleuchtungswinkel). Dies impliziert, dass die Höhe des Sensors  $Y_s$  möglichst klein gewählt werden sollte, um einen möglichst großen Einfallswinkel zu erreichen. Ein großer Einfallswinkel besitzt zusätzlich noch einen weiteren Vorteil, der im Zusammenhang der dadurch entstehenden Strahldivergenz und der im nachfolgenden Unterabschnitt diskutierten Eigenschaft der „Mehrzielfähigkeit“ an Bedeutung gewinnt.

Es sollte erwähnt werden, dass selbstverständlich der gleiche Winkel bei einer erhöhten Anbauposition erreicht werden kann, indem die Distanz in der der Laserstrahl den Boden erfasst, vergrößert wird. Diese Option kann jedoch nicht als wirkliche Alternative betrachtet werden, da eine Verdeckung der Markierungen durch andere Fahrzeuge in größeren Distanzen sehr wahrscheinlich ist. Darüber hinaus fällt die Lichtstärke, die an der Empfängerfläche des Sensors eintrifft, mit der zweiten Potenz der reziproken Entfernung ab (3.9) und die Wahrscheinlichkeit sinkt, selbst bei gut retroreflektierenden Fahrbahnmarkierungen ein Signal oberhalb des Rauschniveaus eines Sensors zu erhalten.

Abschließend lässt sich zusammenfassen, dass die Anbauposition des Sensors möglichst nah an der Fahrbahnoberfläche zu wählen ist. Als Orientierung für die Anbauhöhe und den optimalen Anleuchtungswinkel  $\alpha_v$  kann die in Abschnitt 3.1.2 definierte Standardgeometrie herangezogen werden. Der Sensor sollte möglichst unterhalb der Normhöhe von 0.64 m (Abbildung 3.4) angebracht werden und in einer Entfernung von weniger als 30 m den Boden erfassen.

#### Mehrzielfähigkeit

Eine bedeutende Fähigkeit heutiger automotiver tauglicher Lidar-Sensoren ist die sogenannte Mehrzielfähigkeit. Vereinfacht beschreibt diese die Fähigkeit, aus einem reflektierten Signal,  $n$  Ziele mit unterschiedlicher Laufzeit  $\Delta t_n$  detektieren zu können. Folglich, da  $\Delta t$  in direktem Zusammenhang zu der Distanz  $r_i$  eines Ziels steht und wenn zusätzlich  $n$  größer 1 gilt, kann von einer Mehrzielfähigkeit gesprochen werden. Diese Eigenschaft findet in der Praxis bei Lidar-Sensoren dann Anwendung, wenn mögliche Sekundärziele, die das Primärziel nicht vollständig verdecken, nicht als einziges Ziel detektiert werden sollen. Als Beispiel hierfür zu nennen ist die Detektion von Zielen bei Regen. Das Primärziel sollte auch noch dann sicher detektiert werden können, wenn eine unerwünschte Reflexion an einem Regentropfen (Sekundärziel) zwischen Empfängerfläche und dem Primärziel erfolgt ist. Durch die mit steigender Entfernung zunehmende Strahlaufweitung des Laserpulses, ist es einem Lidar prinzipiell möglich, mehrere Ziele zu erfassen, obwohl diese für Laserlicht nicht transmissiv sind. Analog zu der Entfernung, steigt die Fläche eines Pulses auf dem Ziel mit zunehmendem Einfallswinkel  $\eta$ . Primäre Bedeutung im Zusammenhang mit der Mehrzielmessung auf Fahrbahnmarkierungen, hat die vertikale Strahldivergenz  $\chi$  eines Laserstrahls im Zusammenspiel mit dem Einfallswinkel  $\eta$  und der Entfernung  $r$ . Ab-




Abbildung 3.9: Darstellung der bedeutenden Größen zur Abtastung der Fahrbahnoberfläche mit einem Laserstrahl. Die Höhe  $Y_s$  und der Einfallswinkel  $\eta$  bestimmen die Distanz  $r$ , in der das Zentrum des Laserstrahls den Boden erfasst. Die Strahldivergenz  $\chi$  definiert das Abtastintervall  $\Delta d$ , in dem mögliche Reflexionen und damit Distanzmessungen  $r_i$  zu erwarten sind.

Abbildung 3.9 verdeutlicht diesen Zusammenhang. Die Distanz  $r$ , in der das Zentrum des Laserstrahls den Boden erfasst, ist bestimmt durch die Höhe  $Y_s$  und den Einfallswinkel  $\eta$ . Die Strahldivergenz  $\chi$  bestimmt in welchem Abtastintervall  $\Delta d$  mögliche Reflexionen und damit Distanzmessungen  $r_i$  zu erwarten sind. Die Strahldivergenz in Verbindung mit der Fähigkeit in einem Echopuls mehr als nur ein Ziel zu detektieren, stellt sowohl theoretisch als auch praktisch einen entscheidenden Vorteil dar. Zum einen erhöhen mehrere Messungen auf einer Markierung das gesamte Signal-Rausch-Verhältnis, zum anderen erzeugen mehrere Messungen eine Redundanz. Sollte zum Beispiel die Retroreflexion bei einem Teil der Markierung durch Verschmutzung stark gemindert sein, besteht durch die Strahldivergenz immer noch die Möglichkeit, eine ausreichend starke Reflexion von einem anderen Teil der Markierung zu erhalten.

### Horizontale und vertikale Winkelschrittweite

In dem vorangegangenen Teilabschnitt zur Mehrzielfähigkeit, wurde bereits der Einfluss der vertikalen Strahlgeometrie auf mögliche Bodenreflexionen für einen einzelnen Laserstrahl betrachtet. In diesem Teilabschnitt werden die Einflüsse der horizontalen und vertikalen Winkelschrittweite, bezeichnet als  $\vartheta_{\text{hor}}$  und  $\vartheta_{\text{ver}}$  in direktem Zusammenhang zu der Strahldivergenz  $\chi$  diskutiert.

Für diese Betrachtung ist es notwendig, die Definition der Strahldivergenz auf eine horizontale und vertikale Divergenz zu erweitern. Die horizontale Divergenz wird im Folgenden als  $\chi_{\text{hor}}$  und die vertikale Divergenz als  $\chi_{\text{ver}}$  bezeichnet. Zur Vereinfachung wird angenommen, dass die Strahldivergenz über den gesamten horizontalen und vertikalen Sichtbereich eines Sensors konstant ist. Zudem wird angenommen, dass die Winkelauflösung durch  $\vartheta = 2\chi$  definiert ist. Dies impliziert bildlich überlappungsfreie und direkt aneinander angrenzende Laserstrahlen über den gesamten Sichtbereich des Sensors. Auch wenn diese vereinfachte Annahme nicht für alle Lidar-Sensoren Gültigkeit besitzt, ist sie jedoch sehr nützlich, um die Auswirkungen unterschiedlicher Winkelschrittweiten und Strahldivergenzen zu veranschaulichen.

Abbildung 3.10 zeigt die oben erläuterten Zusammenhänge für den horizontalen Öffnungsbereich und der Winkelschrittweite  $\vartheta_{\text{hor}}$ . Die  $i$ -te Winkelmessung  $\theta_i = 2i\chi_{\text{hor}}$ , die bei

einer Entfernungsmessung für ein Ziel ermittelt wird, ist im Zentrum jedes farbig markierten Laserstrahls als gestrichelte Linie dargestellt. Abbildung 3.10 verdeutlicht zudem ein bedeutendes Problem im Bezug auf die Genauigkeit einer Winkelmessung unter der Abhängigkeit von  $\chi_{\text{hor}}$ . Da ein Lidar über die Laufzeit des Lichtes lediglich die Entfernung  $r$  direkt messen kann, muss die Messung für den Winkel aus den intrinsischen des Sensors abgeleitet werden. Es wird daher vereinfacht angenommen, dass sich die Reflexion direkt im Zentrum, dargestellt durch die gestrichelten Linien in Abbildung 3.10, des Laserstrahls befindet. Betrachtet man lediglich den lateralen Abstand zu einer Fahrbahnmarkierung, ergibt sich im ungünstigsten Fall somit ein entfernungsabhängiger Fehler in der Ablage von  $y_{\text{err}} \approx r \tan \chi$ .

Daraus lässt sich schlussfolgern, dass die horizontale Winkelschrittweite möglichst klein sein sollte. Dies liegt darin begründet, dass eine kleinere Winkelschrittweite die Anzahl der zur Verfügung stehenden Messwerte erhöht und damit direkt zu einem besserem Signal-Rausch-Verhältnis zwischen Fahrbahnmarkierung und Fahrbahnbelag führt. Eine obere Schranke als direkte Mindestanforderung an die horizontale Winkelschrittweite eines Sensors kann an dieser Stelle nicht gegeben werden, da diese direkt von weiteren unbekanntem Größen wie der Abtastrate des Sensors, der Fahrzeugeigengeschwindigkeit und der Markierungslänge abhängig ist.

Ein Richtwert für die horizontale Winkelauflösung mit Blick auf heutige zur Verfügung stehende automotiv geeignete Lidar-Sensoren ist  $\vartheta_{\text{hor}} \leq 0.5^\circ$ . Für die horizontale Strahldivergenz kann eine obere Schranke, unter der Annahme einer maximalen Detektionsreichweite von  $\approx 30$  m und den Anforderungen an die Genauigkeit aus Abschnitt 1.2, mit  $\chi_{\text{hor}} \leq 0.1^\circ$  angegeben werden.

In Abbildung 3.11 werden die eben erläuterten Zusammenhänge für die vertikale Winkelauflösung  $\vartheta_{\text{ver}}$  verdeutlicht. Für die vertikale Winkelauflösung und Strahldivergenz gelten prinzipiell die gleichen Schlussfolgerungen, wie für die horizontalen Vergleichsgrößen. Eine bessere Winkelauflösung bei gleich bleibendem Sichtbereich ist stets zu bevorzugen. Jedoch gibt es einen entscheidenden Unterschied, der die vereinfachte Annahme, die Reflexion hat ihren Ursprung in dem Zentrum des Laserstrahls, nivelliert und eine andere Betrachtung zulässt.

Es soll an dieser Stelle jedoch zuerst kurz auf die in [Rey06] getroffenen Schlussfolgerungen bezüglich der theoretischen Betrachtung der Messgenauigkeit eingegangen werden. In [Rey06] wird beschrieben, dass die vertikale Unsicherheit impliziert durch die Annahme, die Winkelmessung ist stets im Zentrum des Strahls, von untergeordnetem Interesse ist, da sich diese kaum auf die errechnete Position einer Fahrbahnmarkierung auswirkt.

Legt man als Beispiel eine gängige vertikale Strahldivergenz heutiger Lidar-Sensoren von  $\chi_{\text{ver}} = 0.5^\circ$ , eine Distanz zum Ziel von 20 m und eine Sensorhöhe von  $Y_s = 0.5$  m zu Grunde, ergibt sich eine Länge von etwa 7 m für die Schnittgerade mit der Fahrbahnoberfläche  $\Delta d$  (Abbildung 3.9). Betrachtet man zusätzlich den Fall, dass der Kurswinkel  $\psi$  des Fahrzeugs bezüglich der Fahrbahnmarkierungen ungleich Null ist, ist der durch die Abweichung von der Strahlmitte entstehende Fehler keines Falls zu vernachlässigen. Diese Betrachtungsweise besitzt somit keine allgemeine Gültigkeit.




Abbildung 3.10: Beispiel für einen horizontalen Öffnungswinkel  $\alpha_s$  von  $100^\circ$  bei einer Winkelauflösung von  $\vartheta_{\text{hor}} = 4^\circ$  und einer Strahldivergenz  $\chi_{\text{hor}} = 2^\circ$ .

Viel entscheidender ist die Tatsache, dass eine Betrachtung der Strahlmitte für den Fall einer vertikalen Strahlaufweitung auf der Fahrbahnoberfläche nicht zwangsläufig benötigt wird. Der entscheidende Unterschied ist, dass es sich um eine Strahlaufweitung entlang der Dimension handelt, die bei einem Lidar über die Lichtlaufzeit aufgelöst wird. Diese ist gleichbedeutend mit der Entfernung  $r_i$ . Ein Lidar kann somit ganz genau eine durch die Schnittgerade erzeugte Mehrdeutigkeit auflösen und die Entfernung  $r_i$  bestimmen, in der die Reflexion innerhalb von  $\Delta d$  stattgefunden hat.

Auf Basis dieser Tatsache kann der Einfluss der Strahldivergenz auf die Messgenauigkeit von Punkten auf der Fahrbahnoberfläche vernachlässigt werden. Eine Strahldivergenz, die der halben Winkelauflösung gleicht, ist durchaus von Vorteil, um sicherzustellen, dass eine Markierung von einem Laserstrahl mit hoher Wahrscheinlichkeit erfasst wird. Bei einer zu großen Strahldivergenz jedoch sinkt die auf der Empfängerfläche des Lidar-Sensors eintreffende Lichtstärke überproportional stark ab, da der überwiegende Teil des Laserlichtes die Fahrbahnmarkierung verfehlt und somit für eine Retroreflexion nicht mehr zur Verfügung steht. Eine Strahldivergenz von  $\chi_{\text{ver}} > 0.5^\circ$  scheint somit weniger sinnvoll, da  $\Delta d$  die Länge möglicher Fahrbahnmarkierungen, welche bis zu 6 m betragen kann [Die07], in einer Entfernung von 30 m um ein Vielfaches überschreitet.




Abbildung 3.11: Darstellung der bedeutenden Größen für den vertikalen Erfassungsbereich. Vertikaler Öffnungswinkel  $\beta_s$ , Winkelauflösung  $\vartheta_{\text{ver}}$ , Strahldivergenz  $\chi_{\text{ver}}$  und Höhe des Sensors über Grund  $Y_s$ .

### Horizontaler und vertikaler Öffnungswinkel

Im Gegensatz zu der vorher diskutierten Anforderung an die Winkelauflösung eines Lidar-Sensors für die Detektion von Fahrbahnmarkierungen, hat der Sichtbereich des Sensors zwar keinen direkten Einfluss auf die Messgenauigkeit, jedoch bestimmt dieser, welche Fahrbahnmarkierungen von einem Sensor überhaupt erfasst werden können.

Für den horizontalen Öffnungswinkel  $\alpha_s$  gilt trivialerweise, je größer  $\alpha_s$ , desto größer der Bereich, in dem potentielle Markierungen detektiert werden können. Welcher minimale Öffnungswinkel erforderlich ist, ist von der erwartenden Breite der Fahrstreifen, der Fahrbahnkrümmung und der Entfernung, in der eine erste mögliche Reflexion erfolgen soll, abhängig. Die direkte Anforderung unterscheidet sich somit je nach Applikation. Es wird an dieser Stelle daher davon abgesehen, einen minimalen Öffnungswinkel zu definieren. Abbildung 3.10 zeigt als Beispiel einen horizontalen Sichtbereich  $\alpha_s$  von  $100^\circ$ .

Bedeutender als der horizontale Öffnungswinkel, ist der vertikale Sichtbereich  $\beta_s$  in Kombination mit der Strahlauflösung  $\chi_{\text{ver}}$ . Legt man weiterhin eine maximale Detektionsreichweite von ungefähr 30 m zu Grunde und berücksichtigt, dass  $\chi_{\text{ver}} \leq 0.5^\circ$  gilt, sollte der vertikale Öffnungswinkel von  $\beta_s > 0.5^\circ$  betragen, um bei gleich bleibender Reichweite Sichtverdeckungen durch andere Verkehrsteilnehmer kompensieren zu können. Diese Art von Lidar-Sensoren werden häufig als „Mehr-Ebenen Sensoren“ bezeichnet, da sie über mehrere vertikale Messebenen verfügen. Darüber hinaus, erhöht ein Sensor mit mehreren vertikalen Ebenen das Signal-Rausch-Verhältnis durch zeitlich aufeinander folgende Redundanzmessungen und hilft mögliche Störeinflüsse, entstehend durch vertikale Fahrbahnneigungen und Nickbewegungen des Fahrzeuges, zu kompensieren.

## 3.3 Parametrische Straßenmodelle

Dieser Abschnitt beschäftigt sich mit der parametrischen Modellierung des Straßenverlaufs und bildet die Basis für die folgende Parameterextraktion in Abschnitt 3.4.

Die Wahl eines geeigneten Straßenmodells ist direkt abhängig von dem erwarteten Einsatzbereich einer Fahrstreifenerkennung und kann je nach Systemausprägung erheblich variieren [MT06]. In der Literatur existiert eine Vielzahl von funktionalen Ansätzen zur

Beschreibung des Straßenverlaufs, die nach der Anzahl der zu modellierenden Freiheitsgrade in folgende Klassen eingeteilt werden können:

- Lineare Funktionen : [LK01, MT04, VSD07, KAKC10].
- Parabel oder Kreisfunktionen : [OT06, MMSM<sup>+</sup>09, ST10, Rey06, ZJX<sup>+</sup>10].
- B- oder kubische Splines : [WST00, WTS04, Kim08, NC10]

Zusätzlich existiert eine Reihe von Ansätzen, bei denen die durch vereinfachte Modellannahmen entstehenden Fehler durch Bildung von Gültigkeitsintervallen reduziert werden. Als Beispiel zu nennen hierfür sind sogenannte „Poly-Line“ Modelle [LSB<sup>+</sup>08, FZ10]. Während die eben genannten Verfahren das Umfeld als Ebene modellieren, existieren auch funktionale Modelle, die den Straßenverlauf mit zusätzlicher Höheninformation (3D) abbilden [DN09]. Eine umfassende Übersicht über parametrische Straßenmodelle und deren Verwendung kann in [MT06] oder [Cra05] gefunden werden. Die Anzahl an Modellparametern  $a_i$ , die benötigt wird, um den Straßenverlauf eindeutig zu beschreiben, wird im Folgenden als Dimension des Zustandsvektors  $\mathbf{f}$  bezeichnet.

$$\mathbf{f} = \begin{bmatrix} a_1 \\ \vdots \\ a_n \end{bmatrix} \quad (3.12)$$

In der Regel gilt, je mehr Parameter aus den vorliegenden Messwerten geschätzt werden müssen, desto schwieriger wird es, diese in einer für die laterale Querführung ausreichenden Güte zu bestimmen. Bei der Wahl eines geeigneten Straßenmodells ist es daher wichtig, dieses an die in der Realität vorkommenden Gegebenheiten anzupassen. Zur Verdeutlichung kann als Beispiel ein innerstädtisches Szenario im Vergleich zu einem Autobahnszenario herangezogen werden. Sollen im innerstädtischen Bereich alle möglichen Gegebenheiten wie zum Beispiel wechselnde Richtungsänderungen in S-Kurven, sich teilende Fahrstreifen und Mehrfachmarkierungen unterschiedlicher Fahrtrichtungen im Kreuzungsbereich, in einer definierten Distanz zum Eigenfahrzeug berücksichtigt werden, so sollte das gewählte Modell diese auch mit einem maximal zu tolerierenden Fehler funktional beschreiben können. In einem Autobahnszenario mit großen Kurvenradien ist, je nach gewünschtem Gültigkeitsbereich des Modells, ein Parabel- oder Kreismodell mit 3 zu bestimmenden Parametern meist ausreichend.

Für die Wahl des geeigneten Modells ist daher eine Betrachtung des Einsatzbereiches und des Gültigkeitsbereiches zwingend erforderlich. In Abschnitt 1.2 wurde bereits eine Einschränkung für Autobahnen und autobahnähnliche Straßenabschnitte vorgenommen. Die Suche eines geeigneten Straßenmodells beschränkt sich daher in dieser Arbeit auf Modelle, die geeignet sind, autobahnähnliche Straßen innerhalb des erwarteten Erfassungsbereiches eines Lidar-Sensors zu repräsentieren.

Der Entwurf dieser Straßentypen unterliegt baulichen Richtlinien, um die Sicherheit unter der vorgegebenen Höchstgeschwindigkeit zu gewährleisten [For08]. Damit Kurven mit möglichst konstantem Lenkradeinschlag durchfahren werden können, sind diese möglichst

als Kreisbögen auszuführen [For08]. Da der Übergang zwischen geraden Abschnitten und Kurven allerdings ohne eine abrupte Lenkwinkeländerung nicht zu befahren wäre, werden Klothoiden als Übergangsegment zwischen Geraden und Kreisbögen eingefügt. Eine Klothoide, auch Cornusche Spirale genannt, ist eine Kurve, deren Krümmung  $c$  proportional mit der Bogenlänge  $l$  zu- oder abnimmt<sup>5</sup>:

$$c(l) = c_0 + c_1 l. \quad (3.13)$$

Dabei ist  $c_0$  der Anfangswert für die Krümmung und  $c_1$  die Krümmungsänderung. Soll ein Klothoidenmodell zur funktionalen Beschreibung des Straßenverlaufs verwendet werden, ist eine Überführung in ein kartesisches Koordinatensystem mit einer Reihenentwicklung notwendig [Cra05, GHT<sup>+</sup>10].

Zusätzlich zu der festgelegten Segmentfolge der einzelnen Abschnitte, existieren Richtlinien für die maximale Krümmung und Krümmungsänderung in Abhängigkeit zu der vorgeschriebenen Geschwindigkeit. In diesem Zusammenhang wird in der Literatur [Cra05, Rey06] oft von der sogenannten *Entwurfsgeschwindigkeit* ( $V_e$ ) eines Straßenabschnitts gesprochen. Der Begriff der Entwurfsgeschwindigkeit ist dabei zurückzuführen auf den Teilbereich „Linienführung“ (-L) der „Richtlinien für die Anlage von Straßen“ (RAS) [For95]. Der durch die Entwurfsgeschwindigkeit definierte minimale Kurvenradius, leitet sich dabei direkt aus mehreren Größen wie zum Beispiel Querneigung der Straße, Querbesehleunigung und Reibwert ab [KHS<sup>+</sup>08]. Es muss an dieser Stelle erwähnt werden, dass mit der Einführung der „Richtlinien für die Anlage von Autobahnen“ (RAA) im Jahr 2008 [For08], die (RAS-L) bei der Anlage neuer Straßenabschnitte keine Anwendung mehr findet. In diesem Regelwerk, findet unter anderem der Begriff der Entwurfsgeschwindigkeit  $V_e$  und die Durchschnittsgeschwindigkeit  $V_{85}$ <sup>6</sup> keine Verwendung mehr. Unabhängig davon, eignet sich die Entwurfsgeschwindigkeit und die darin festgehaltenen Beschränkungen jedoch weiterhin sehr gut für eine Betrachtung der Modellfehler in Abhängigkeit der Krümmung und der Krümmungsänderung eines Streckenabschnitts. Der Begriff der Entwurfsgeschwindigkeit findet daher in dieser Arbeit nach wie vor Anwendung.

In diesem Zusammenhang ist insbesondere die Arbeit von Cramer [Cra05] hervorzuheben, die sich ausführlich dieser Thematik widmet. Bei einer Entwurfsgeschwindigkeit von 120 km/h werden die durch funktionale Näherung induzierten Fehler in der Ablage  $y$  für Geraden-, Kreis- und Klothoidensegmente betrachtet. Bei einem Gültigkeitsbereich von 50 m, 100 m und 200 m erfolgt eine Abschätzung des mittleren  $\mu_{\bar{x}}$  und maximalen  $e_{\max}$  Fehlers bei Verwendung eines Geraden-, Parabel-, Kreis und kubischen Parabelmodells. Aus Abschnitt 3.2.3 ist bekannt, dass die Fahrbahnoberfläche in einer Entfernung von weniger als 30 m erfasst werden sollte. Die Betrachtungen von Cramer eignen sich daher sehr gut für eine Fehlerabschätzung im Bezug auf eine lidarbasierte Fahrstreifenerkennung.

Zuerst wird zur Veranschaulichung der Fehler bei einem Gültigkeitsbereich von bis zu 200 m betrachtet. Betrachtet wird der maximale Fehler  $e_{\max}$ . Wie nicht anders zu erwarten, sind alle vier Modelle in der Lage, Segmente, die als Geraden ausgeführt sind, fehlerfrei zu

---

<sup>5</sup>vgl. Cramer [Cra05].

<sup>6</sup>Geschwindigkeit von 85% der Autofahrer bei trockener Fahrbahn.

beschreiben. Bei einem Kreissegment hingegen, entsteht bei Approximation durch eine Gerade ein Fehler von  $e_{\max} = 4.452$  m und bei einer Parabelfunktion von  $e_{\max} = 0.052$  m. Der Fehler bei einer kubischen Parabel ist mit  $e_{\max} = 0.006$  m zu vernachlässigen. Bei einem Klothoidensegment, entsteht bei Approximation durch eine Gerade ein Fehler von  $e_{\max} = 2.597$  m, bei einer Parabelfunktion von  $e_{\max} = 0.403$  m und bei einer Kreisfunktion von  $e_{\max} = 0.397$  m. Der Fehler bei einer kubischen Parabel ist mit  $e_{\max} = 0.003$  m wieder zu vernachlässigen.

Der von Cramer untersuchte Gültigkeitsbereich von bis zu 100 m wird in dieser Arbeit nicht berücksichtigt. Bedeutender ist für eine Abwägung die Fehlerbetrachtung in einer Distanz von bis zu 50 m, da diese für einen Vergleich mit einem Gültigkeitsbereich von bis zu 30 m am interessantesten ist. Für einen Gültigkeitsbereich bis zu 50 m werden durch Cramer nur noch das Kreis- und kubische Parabelmodell betrachtet. Ein Parabelmodell bietet nach Cramer durch den größeren maximalen Fehler bei Kreissegmenten bei gleicher Anzahl zu schätzenden Parametern keinen Vorteil gegenüber dem Kreismodell. In einer Distanz von bis zu 50 m sind sowohl das kubische Parabelmodell als auch das Kreismodell bei Approximation von Geraden- und Kreissegmenten fehlerfrei<sup>7</sup>. Bei dem Klothoidensegment, weist das Kreismodell lediglich einen Fehler von  $e_{\max} = 0.015$  m auf, welcher vernachlässigbar klein ist. Für das Kreismodell ergibt sich der Zustandsvektor wie folgt:

$$\mathbf{f}_K = \begin{bmatrix} c \\ \psi \\ y \end{bmatrix} = \begin{bmatrix} \text{Krümmung} \\ \text{Relativer Kurswinkel des Fahrzeugs} \\ \text{Relativer Offset des Fahrzeugs} \end{bmatrix}. \quad (3.14)$$

Im Gegensatz zum Kreismodell, ist bei der kubischen Parabel zusätzlich der kubische Funktionsparameter  $a_3$  zu schätzen:

$$\mathbf{f}_P = \begin{bmatrix} a_3 \\ a_2 \\ a_1 \\ a_0 \end{bmatrix} = \begin{bmatrix} \text{Kubischer Parameter} \\ \text{Quadratischer Parameter} \\ \text{Anstiegsparameter der Parabel} \\ \text{Relativer Offset des Fahrzeugs} \end{bmatrix}. \quad (3.15)$$

Betrachtet man die Anzahl zu schätzender Parameter und die damit reduzierten Freiheitsgrade, ist das Kreismodell dem kubischen Parabelmodell zu bevorzugen. Dies gilt insbesondere im Bezug auf eine lidarbasierte Fahrstreifenerkennung, bei der im Gegensatz zu einer videobasierten Fahrstreifenerkennung vergleichsweise nur relativ wenige Messwerte zur Schätzung der im Zustandsvektor modellierten Größen zur Verfügung stehen. Betrachtet man wie in [Rey06] allerdings zusätzlich eine Entwurfsgeschwindigkeit von 70 km/h, die eine größere maximale Krümmung und Krümmungsänderung zulässt, steigt der maximale Fehler  $e_{\max}$  auf 0.11 m in einer Distanz von 25 m. Im Wesentlichen gilt es daher abzuwägen, ob der bei Klothoidensegmenten entstehende Modellierungsfehler vernachlässigt werden kann, weil er sich etwa wie in [Rey06] unterhalb des Messrauschens befindet.

<sup>7</sup>Der Fehler eines kubischen Parabelmodells ist bei Approximation des Kreis- und Klothoidensegments so klein, dass  $e_{\max} \equiv 0$  gilt




Abbildung 3.12: Verwendetes Modell zur Beschreibung des Fahrstreifenverlaufs mit der Krümmung  $c$ , dem relativen Kurswinkel zur Fahrstreifenmitte  $\psi$ , der Ablage zur Fahrstreifenmitte  $y$  und der Breite des Fahrstreifens  $b$ .

Das in dieser Arbeit verwendete Modell basiert auf dem Kreismodell. Ein weniger komplexes Modell mit einer reduzierten Anzahl an Freiheitsgraden wird aus Gründen der Robustheit dem kubischen Parabelmodell bevorzugt. Darüber hinaus ist die Wahl des Kreismodells mit dem in 3.4 vorgestellten histogrammbasierten Verfahren zur Parameterextraktion verbunden. Ein Modell mit zusätzlichen zu schätzenden Größen, hätte für diesen Ansatz einen enormen Anstieg der Komplexität und damit der Rechenzeit zur Folge.

Abbildung 3.12 zeigt das verwendete Kreismodell mit den zu bestimmenden Größen: Krümmung  $c$ , Kurswinkel  $\psi$ , Ablage  $y$  und Breite  $b$ . Die zusätzlich eingeführte Breite eines Fahrstreifens  $b$ , leitet sich dabei direkt aus der linken und rechten Fahrbahnmarkierung ab. Die einzelnen modellierten Fahrstreifen (3.16) einer Straße bilden anschließend zusammen das Straßenmodell  $S$  (3.17).

$$\mathbf{f}_i = [c_i \ \psi_i \ y_i \ b_i]^T \quad (3.16)$$

$$S = \{\mathbf{f}_1, \dots, \mathbf{f}_n\} \quad (3.17)$$

### 3.4 Parameterextraktion und Fahrstreifenschätzung

In dem vergangenen Abschnitt wurde diskutiert, welches parametrische Modell geeignet ist, den Straßenverlauf autobahnähnlicher Straßen funktional zu beschreiben. Als zu bestimmende Größen wurden die Krümmung, der Kurswinkel, die Ablage und die Breite jedes einzelnen Fahrstreifens festgelegt. Ziel der Parameterextraktion ist es, diese Modellparameter auf Basis der Messwerte eines Lidar-Sensors zu schätzen. Hierzu werden zuerst die in der Literatur bestehenden Verfahren auf ihre Eigenschaften bezüglich der Echtzeitfähigkeit und Robustheit hin untersucht. Anschließend erfolgt die Einführung einer Belegungskarte

als Basis für das in Abschnitt 3.4.3 vorgestellte histogrammbasierte iterative Verfahren zur Bestimmung der Fahrbahnkrümmung und der Fahrzeugausrichtung. Abschließend erfolgt die Detektion und Klassifikation der eigentlichen Fahrstreifen mit Hilfe eines kombinatorischen Ansatzes.

### 3.4.1 Stand der Technik

In diesem Abschnitt erfolgt ein Überblick über die in der Literatur existierenden Verfahren zur lidarbasierten Fahrstreifenerkennung. Es werden verschiedene Ansätze diskutiert und in einem tabellarischen Vergleich die wesentlichen Eigenschaften der bedeutendsten Verfahren gegenübergestellt. Der Vergleich beinhaltet die Wahl des funktionalen Modells zur Beschreibung der Fahrstreifen, die Eingangsdaten und das eigentliche Verfahren zur Parameterextraktion und rekursiven Schätzung der Modellparameter.

Dietmayer et al. [DKF<sup>+</sup>05] und Kibbel et al. [KJF05] verwenden einen histogrammbasierten Ansatz, um aus den Messwerten Hypothesen von Fahrbahnmarkierungen abzuleiten. Dieser Ansatz ermöglicht zwar die robuste Parameterschätzung der Ablagen  $y_i$  der einzelnen Markierungen, allerdings kann weder die relative Fahrzeugausrichtung  $\psi_i$ , noch die Krümmung  $c_i$  geschätzt werden. Eine zeitliche Filterung der Schätzung findet nicht statt. Reyher [Rey06] verwendet ein erweitertes Kalman-Filter, um die Zustände eines Kreismodells zu schätzen. Ogawa und Takagi [OT06] verwenden eine Hough-Transformation mit einem nachgestellten Kalman-Filter, um die Zustandsgrößen eines Parabelmodells zu schätzen. Kammel und Pitzer [KP08] nutzen eine auf einer Belegungskarte angewendete Radon-Transformation, um die Ablage und den Kurswinkel des Fahrzeugs  $\psi_i$  zu bestimmen. Eine Schätzung der Krümmung  $c_i$  erfolgt nicht. Linder et al. [LRW<sup>+</sup>09] verwenden ein auf einer adaptiven Schwellwertfilterung aufbauendes *unscented* Kalman-Filter um den eigenen Fahrstreifen zu schätzen. Thuy et al. [TL10] verwenden ebenfalls ein erweitertes Kalman-Filter, um die Zustände eines Parabelmodells zu bestimmen.

Tabelle 3.1, fasst noch einmal die wesentlichen Aspekte der einzelnen Verfahren zusammen. In keinem der vorgestellten Verfahren wird sowohl die Krümmung als auch die Anzahl der Fahrstreifen simultan erfasst. Dies bedeutet nicht, dass dies prinzipiell nicht möglich ist, jedoch müssen die einzelnen Verfahren auf ihre Tauglichkeit hin näher betrachtet werden.

Nicht weiter betrachtet werden zuerst Ansätze, die auf einem Kalman-Filter (EKF und UKF) [BS87, TBF05] aufbauen. Dieser bildet in der Literatur eine Art „Standardvorgehen“ bei der rekursiven Zustandsschätzung aus verrauschten Messwerten [BS87]. Ein großer Nachteil ist jedoch seine Anfälligkeit gegenüber „Multi-Modal“ verteiltem Messrauschen. Ein Kernpunkt bei der praktischen Anwendung des Kalman-Filters beschäftigt sich daher mit der Messdatenzuordnung (Data-Association) und der Plausibilisierung der Eingabedaten, auch „Gating“ genannt [BS87, Cra05]. Für eine lidarbasierte Fahrstreifenerkennung, mit ihrem äußerst schlechten Signal-Rausch-Verhältnis, ist die Anwendung zur robusten Schätzung der in 3.3 definierten Zustandsgrößen daher äußerst fragwürdig. In Reyher [Rey06], wird in diesem Zusammenhang explizit auf diese Problematik aufmerksam gemacht. Vielversprechender sind, insbesondere im Bezug auf die Detektion weiterer

	[KJF05]	[KP08]	[OT06]	[Rey06]	[LRW <sup>+</sup> 09]
<b>Eingangsdaten</b>	aktuelle Messwerte	Belegungskarte	aktuelle und vergangene Messwerte	aktuelle Messwerte	aktuelle Messwerte
<b>Verfahren</b>	Histogramm	Radon-Transformation	Hough-Transformation / Kalman Filter	Erweiterter Kalman Filter	Unscented Kalman Filter
<b>Modell</b>	Polynom 0. Grades	Polynom 1. Grades	Polynom 2. Grades	Kreisbogen	unbekannt
<b>Krümmung</b>	Nein	Nein	Ja	Ja	Ja
<b>Mehrere Fahrstreifen</b>	Ja	Ja	Nein	Nein	Nein
<b>Fahrstreifenklassifikation</b>	Nein	Nein	Nein	Nein	Nein

Tabelle 3.1: Vergleich der in der Literatur existierenden Verfahren zur lidarbasierten Fahrstreifenerkennung.

benachbarter Fahrstreifen, Ansätze, die auf einer Histogrammbildung [KJF05], Hough-Transformation [OT06] oder Radon-Transformation [KP08] basieren. Zwar ist es mit diesen Verfahren wie bei Kalman-Filter basierten Ansätzen nicht direkt möglich, die Unsicherheit in der Schätzung zu bestimmen, jedoch bieten diese durch ihre *globale* Betrachtungsweise eine hohe Robustheit gegenüber jeglicher Art von Messrauschen. Im Nachfolgenden werden diese Verfahren daher genauer auf ihre Eigenschaften hin untersucht.

### Histogramm

In [KJF05] wurde ein einfaches nicht rekursives Verfahren zur Detektion von Fahrbahnmarkierungen aus Laserscannerdaten vorgestellt. Unter der Annahme, dass die Mehrheit der von der Fahrbahnoberfläche stammenden Reflexionen den Fahrbahnmarkierungen zugeordnet werden kann, wurde ein in Fahrtrichtung orientiertes Histogramm erstellt, um die Messwerte nach ihrem lateralen Abstand geordnet zusammenzufassen. In dem Histogramm wurden anschließend alle einen festen Schwellwert überschreitenden Klassen<sup>8</sup> als potentielle Markierungen betrachtet. Dieser einfache Ansatz ist allerdings nicht in der Lage, den Kurswinkel  $\psi$  und die Krümmung der Fahrstreifen  $c$  zu bestimmen. Selbst bei einer theoretisch sehr unwahrscheinlichen Fahrzeugausrichtung von  $\psi = 0$  ist eine robuste Bestimmung des lateralen Abstandes  $y$  nicht in allen Fällen möglich, da bei einer Krümmung  $c \neq 0$ , die Messwerte der einzelnen Fahrbahnmarkierungen nicht mehr nur einer einzigen Klasse des Histogramms zugeordnet werden.

<sup>8</sup>engl. bins

## Hough Transformation

Die Hough Transformation findet häufig in der Bildverarbeitung zur Detektion von parametrisierbaren geometrischen Modellen in Bildern Anwendung [Jäh05]. Betrachtet wird zuerst der einfache Fall zur Detektion von Geraden.

Bei der Suche nach Geraden werden dazu alle Bildpunkte jeweils als Überlagerung einer Kosinus- und Sinus-Welle im Hough-Raum mit den Achsen  $\theta$  dargestellt, wodurch die Bildpunkte jeder möglichen Geraden in Parameterdarstellung zugeordnet werden (3.18). Die Stellen im Hough-Raum, an denen eine starke Überlagerung aller Wellen stattfindet, geben dabei die Parameter der in dem Bild gefundenen Geraden an.

$$\rho(\theta) = x \cdot \cos(\theta) + y \cdot \sin(\theta) \quad (3.18)$$

---

### Algorithmus 3.1 : HOUGH TRANSFORMATION.

---

$d_{\max} = \text{sqrt}((0.5 \cdot \text{ImageHeight})^2 + (0.5 \cdot \text{ImageWidth})^2);$

$d_{\min} = -1 \cdot d_{\max};$

Hough[0... $\pi$ ][ $d_{\min}$ ... $d_{\max}$ ] = 0;

**für alle Pixel in Image tue**

**für  $\alpha = 0$  bis  $\pi$  tue**

$d = \text{Pixel}.x \cdot \cos(\alpha) + \text{Pixel}.y \cdot \sin(\alpha);$

        Hough[ $\alpha$ ][ $d$ ]++;

**Ende**

**Ende**

---

Um statt der Geraden auch Kreisbögen abbilden zu können, wird Gleichung 3.18 durch Gleichung 3.19 ersetzt, wobei  $x_m$  und  $y_m$  den Kreismittelpunkt und  $r$  den Kreisradius angibt. Man spricht bei Kreisen daher auch von einem dreidimensionalen Hough-Raum.

$$r^2 = (x_m - x)^2 + (y_m - y)^2 \quad (3.19)$$

Für die Schätzung der Krümmung  $c$ , müsste für jeden möglichen Radius ein Hough-Raum mit den Achsen  $x_m$  bzw.  $y_m$  berechnet werden. Dieses erhöht die Komplexität und den damit verbundenen Rechenaufwand soweit, dass die unter Abschnitt 1.2 geforderte Echtzeitfähigkeit nicht mehr erfüllt werden kann. Die Hough Transformation kann daher für die Schätzung der Krümmungen von Fahrstreifen nicht verwendet werden.

## Radon Transformation

Die Radon Transformation [BL02] besitzt eine große Ähnlichkeit zur Hough Transformation, sie verwendet jedoch eine modifizierte Raumdarstellung. Für die Detektion von Geraden wird zunächst jeder Bildpunkt als eine quadratische Zelle aufgefasst und in vier gleich große quadratische Bereiche unterteilt, um bei der anschließenden Berechnung eine höhere Auflösung zu erreichen. Nach dieser Unterteilung werden orthogonal zu einer Geradenschar  $g(x, \alpha)$  (3.20) mit dem Ursprung  $x_0, y_0$  die Geraden  $r(x, \alpha, b)$  (3.21) berechnet

und alle Bildpunkte  $f(x, y)$  aufsummiert, die auf jeweils einer Geraden  $r(x, \alpha, b)$  liegen (3.22). Anschließend wird die Summe  $s(\alpha, b)$  entsprechend ihrer Parameter in den Radon-Raum eingetragen. Die Komplexität dieses Verfahrens ist geringer als bei einer Hough Transformation.

Die Radon Transformation fand zum Beispiel Anwendung bei der Fahrstreifenerkennung während der Urban Challenge 2007 [KP08]. Jedoch wurden dort ausschließlich Geraden detektiert, da bei der Detektion von Kreisen für jeden möglichen Radius eine Radon Transformation durchgeführt werden müsste. Der Rechenaufwand steigt dadurch soweit an, dass die Krümmung der Fahrstreifen nicht unter Berücksichtigung der unter Abschnitt 1.2 geforderten Echtzeitbedingung berechnet werden kann. Die Radon Transformation kann daher genauso wie die Hough Transformation nicht für die Parameterextraktion von der Krümmung  $c$  verwendet werden.

$$g(x, \alpha) = \tan(\alpha) \cdot (x - x_0) + y_0 \quad (3.20)$$

$$r(x, \alpha, b) = \sin(\alpha) \cdot b + \tan\left(\alpha + \frac{\pi}{2}\right) \cdot (x - x_0 - \cos(\alpha) \cdot b) + y_0 \quad (3.21)$$

$$s(\alpha, b) = \int_{-d}^{+d} f(x, r(x, \alpha, b)) dx \quad (3.22)$$

für  $\alpha = ] - \frac{\pi}{2}, \frac{\pi}{2} [$

## Zusammenfassung und Diskussion

Abschließend lässt sich zusammenfassen, dass keines der untersuchten Verfahren alle festgelegten Anforderungen erfüllt.

Auf dem Kalman-Filter aufbauende Verfahren wurden bereits zu Anfang aus Gründen der Robustheit ausgeschlossen. Die Hough- und Radon Transformation bieten zwar eine ausreichende Robustheit gegenüber Störungen, erfüllen jedoch nicht die unter Abschnitt 1.2 geforderten Echtzeitbedingungen, wenn zusätzlich auch die Krümmung geschätzt werden soll. Das histogrammbasierte Verfahren in seiner vorgestellten Form eignet sich ebenso wenig, um die benötigten Parameter zu bestimmen.

In Abschnitt 3.4.3 wird deshalb ein neues iteratives Verfahren vorgestellt, welches auf Basis einer Histogrammdarstellung die Krümmungen, Kurswinkel und Ablage der Fahrstreifen aus einer vorher erstellten Belegungskarte berechnet.

Die Grundlage für diese histogrammbasierte Parameterextraktion bildet eine Belegungskarte vorklassifizierten Bodenpunkten, welche in Abschnitt 3.4.2 eingeführt wird.

### 3.4.2 Belegungskarte mit Bodenpunkten

In Abschnitt 3.4.1 wurden unterschiedliche Verfahren zur Parameterextraktion und Fahrstreifenschätzung diskutiert. Mit Ausnahme des histogrammbasierten Verfahrens, handelt es sich um auf dem Bayes Filter [TBF05] aufbauende rekursive Schätzverfahren, die den aktuellen Zustand  $\mathbf{x}_t$  unter Berücksichtigung aller bisherigen Messwerte  $\mathbf{z}_{1:t}$  und Kontrol-

leingaben  $\mathbf{u}_{1:t}$  schätzen:

$$p(\mathbf{x}_t \mid \mathbf{z}_{1:t}, \mathbf{u}_{1:t}). \quad (3.23)$$

Wird zum Beispiel der Straßenverlauf anhand eines Kalman-Filters geschätzt, erfolgt die Integration der Fahrzeugeigenbewegung mit Hilfe eines *dynamischen* Modells innerhalb des Prädiktionsschritts und die Integration des Messvektors  $\mathbf{z}_t$  in dem folgenden Fusionschritt des Kalman-Filters [Cra05]. Wird allerdings eine Hough-Transformation oder eine Histogrammbildung angewendet, so gilt es zuerst zu klären, auf welchen Daten eine solche Transformation überhaupt stattfinden soll. Intuitiv ist es nicht sinnvoll, nur die aktuelle Messung  $\mathbf{z}_t$  zu betrachten. Darüber hinaus handelt es sich wie in Abschnitt 3.3 bereits angedeutet bei dem Straßenmodell um eine Momentaufnahme mit Bezug auf das Fahrzeugkoordinatensystem  $S_0$ . Da sich das Fahrzeug zwischen  $z_{t-1}$  und  $z_t$  relativ bewegt, ist eine Berücksichtigung der Fahrzeugeigenbewegung zwingend erforderlich.

Eine Möglichkeit ist, eine auf Belegungskarten (siehe Kapitel 2) basierte Parameterextraktion durchzuführen. Bei Belegungskarten, die zu der Klasse der *ortsbezogenen* Umfeldmodelle gehören, sind die zeitlich aufeinander folgenden Messungen  $\mathbf{z}_{1:t}$  unter Berücksichtigung der Eingabe  $\mathbf{u}_{1:t}$  in Form eines ortsbezogenen Belegungswertes gespeichert. Bezieht sich die Belegungskarte zudem noch wie in Abschnitt 2.4.3 auf ein ortsfestes Koordinatensystem, kann die relative Position jeder Grid-Zelle zum Zeitpunkt  $t$  aus dem in Abschnitt 2.4.3 definierten Vektor  $\mathbf{s}_{\text{grid}}$  abgeleitet werden:

$$\mathbf{s}_{\text{grid}} = \begin{bmatrix} x_{\text{grid}} \\ y_{\text{grid}} \\ \psi_{\text{grid}} \end{bmatrix} \in \mathbb{R}^3. \quad (3.24)$$

Da es sich bei den zu potentiellen Fahrbahnmarkierungen gehörenden Messwerten zweifelsfrei um ortsfeste Ziele handelt, besteht zudem keine Verletzung der mit der Belegungskarte verankerten *static world assumption*. Weiterhin begünstigt die Aufteilung in  $n \times m$  Gitterzellen Algorithmen, die wie zum Beispiel die Hough-Transformation, ihren Ursprung in der Bildverarbeitung haben. Ebenso begünstigt es die Anwendung von Verfahren, die wie das Histogramm für die Klassenzuordnung auf eine Intervallbildung angewiesen sind.

Für das in Abschnitt 3.4.3 vorgestellte histogrammbasierte Verfahren zur iterativen Parameterschätzung, wird daher als Eingabe eine zweidimensionale Belegungskarte vorausgesetzt.

Es ist darüber hinaus sinnvoll, eine Vorauswahl an Messwerten  $z_t^k$  zu treffen, die in das Messupdate (siehe Gleichung 2.8) der probabilistischen Belegungskarte einbezogen werden sollen. Eine Besonderheit des in dieser Arbeit verwendeten für automotive Applikationen entwickelten mehrzeiligen Laserscanners ist die Fähigkeit, in einem Vorverarbeitungsschritt eine Klassifikation zwischen sogenannten *Objekt-* und *Bodenpunkten* durchzuführen. Jeder einzelne Messwert  $z_t^k$  des Messvektors  $\mathbf{z}_t = \{z_t^1 \dots z_t^K\}$  kann einer dieser beiden Klassen zugeordnet werden, wobei die Objektklasse  $\mathbf{z}_{\text{Objekt},t}$  mit großer Wahrscheinlichkeit Punkte von nicht überfahrbaren Objekten und die Bodenklasse  $\mathbf{z}_{\text{Boden},t}$  Punkte von Objekten enthält, die direkt zu der geschätzten Bodenebene zu zählen sind oder dieser sehr nahe sind.

Als Beispiel für die Bodenebene zu nennen sind: Reflexionen von Fahrbahnbelag und Fahrbahnmarkierungen. Eine Sonderstellung nehmen Fahrbahnabgrenzungen wie zum Beispiel Bordsteine ein, die aufgrund ihrer erhabenen Ausprägung auch der Klasse Objekt zugeordnet werden könnten, jedoch durch ihre Bodennähe in einem Klassifikationsschritt eher der Bodenebene zugeordnet sind.

Da es sich bei dieser durchgeführten Klassifikation um einen Vorverarbeitungsschritt handelt, der direkt im Sensor durchgeführt wird, existieren leider keine Informationen über die angewendete Algorithmik zur Differenzierung zwischen Objekt- und Bodenpunkten. Dies stellt jedoch keine generelle Limitierung auf diesen Sensortyp dar. So ist es zum Beispiel möglich, wie in [LRW<sup>+</sup>09], die Rückstrahlintensität  $I_S$  der einzelnen Messungen zu einer Hypothesengenerierung zu verwenden. Ist die Rückstrahlintensität nicht verfügbar, ist es denkbar, aus der in einer Messung  $z_t$  enthaltenen Distanzinformation mit Hilfe der Strahlcharakteristik die Höhen der einzelnen Messwerte abzuleiten. Diese kann dann anschließend für eine Clusterbildung und Schätzung einer Bodenebene verwendet werden. In [MMH08] wird als Beispiel ein 4D (räumlich und zeitlicher) Ansatz auf Basis des RANSAC-Algorithmus zur Schätzung einer Bodenebene in TOF-Kameradaten vorgestellt. In [MNBI10] ist ein Verfahren zum Schätzen der Bodenebene aus Lidar-Daten in Waldgebieten beschrieben. Ein Überblick und ein Verfahren zur Schätzung der Bodenebene aus 3D-Lidar Daten im Rahmen der DARPA Urban- und Grand-Challenge kann in [MPS09] gefunden werden.

Im Folgenden wird eine Trennung der beiden Objektklassen vorgenommen. Die Belegungskarte, die Messwerte aus der Bodenklasse  $\mathbf{z}_{\text{Boden},1:t}$  enthält, wird im weiteren Verlauf als  $mG$  bezeichnet. Die Abbildung 3.13 bis 3.16 zeigen zur Verdeutlichung vier Belegungskarten mit vorklassifizierten Bodenpunkten. Abbildung 3.13 zeigt den *idealen* Fall aus Sicht einer anschließenden Parameterextraktion. Begünstigt durch einen sehr dunklen Fahrbahnbelag mit äußerst schlechter Oberflächenreflektivität  $\sigma_{\text{br}}$ , stammen alle bis zum aktuellen Zeitschritt  $t$  akkumulierten Bodenreflexionen von den eigentlichen Fahrbahnmarkierungen. Greift man die Definition für das Signal-Rausch-Verhältnis aus Abschnitt 3.2.2 auf, kann in diesem Szenario von einem *idealen* SNR gesprochen werden. Betrachtet man hingegen die Abbildungen 3.14 bis 3.16, so wird deutlich, dass dies nicht immer zutrifft. Abbildung 3.14 zeigt eine Belegungskarte mit additivem Rauschen, hervorgerufen durch Reflexionen des Fahrbahnbelages. Wie bekannt ist, kann ein Lidar nicht direkt zwischen Messwerten von Fahrbahnmarkierungen und Fahrbahnbelag differenzieren. Anders ausgedrückt, übersteigt ein vom Fahrbahnbelag empfangener Echopuls die Detektionsschwelle des Lidar-Sensors, ist dieser von einem Messwert auf einer Fahrbahnmarkierung nicht zu unterscheiden. Die Ursachen für eine ausreichende Reflexion des Fahrbahnbelages, trotz des in Abschnitt 3.2.3 definierten großen Einfallswinkels  $\eta$ , sind vielschichtig. Zum einen, weisen einige Fahrbahnbeläge wie zum Beispiel Beton durch ihre helle Farbe eine gute Oberflächenreflektivität auf, die ausreicht, um eine Reflexion zu erzeugen, die oberhalb des Rauschniveaus des Sensors liegt. Zum anderen, kann durch Fahrbahnunebenheiten und Fahrzeugnickenbewegungen der Einfallswinkel auf der Fahrbahnoberfläche verkleinert werden, wodurch die gemessene Beleuchtungsstärke an der Empfangsdiode (Abschnitt 3.2.1) ansteigt. Zudem ist



Abbildung 3.13: Erstes Beispiel für eine Belegungskarte mit Bodenpunkten. Idealer Fall aus Sicht einer anschließenden Parameterextraktion. Begünstigt durch einen sehr dunklen Fahrbahnbelag mit äußerst schlechter Oberflächenreflektivität  $\sigma_{br}$ , stammen alle bis zum aktuellen Zeitschritt  $t$  akkumulierten Bodenreflexionen von den eigentlichen Fahrbahnmarkierungen.




Abbildung 3.14: Zweites Beispiel für eine Belegungskarte mit Bodenpunkten und additiven Rauschen, hervorgerufen durch Reflexionen des Fahrbahnbelages.

eine Kombination aus beiden Ursachen möglich, die eine Detektion ebenfalls begünstigen. Abbildung 3.15 zeigt eine weitere mögliche Ursache für additives Rauschen, hervorgerufen durch *falsch-positive* Zuweisungen innerhalb des Vorverarbeitungsschritts der Bodenerkennung. In diesem gezeigten Beispiel wurden Messwerte, die der Bodenebene sehr nah sind, jedoch von einem LKW stammen, der der Objektklasse  $\mathbf{z}_{\text{Boden}}$  zugeordnet. Durch zeitlich aufeinander folgende Messungen entstehen wie in Abbildung 2.18 gezeigt ausgedehnte Artefakte durch die Verletzung der *static-world-assumption*. Abbildung 3.16 zeigt abschließend die Überlagerung aller eben erläuterten additiven Störgrößen in einer einzigen Belegungskarte und verdeutlicht ein wesentliches Problem bei der lidarbasierten Fahrstreifenerkennung. Betrachtet man alle Messwerte, die bis zum Zeitpunkt  $t$  in einer Belegungskarte  $mG$  akkumuliert wurden, so kann die Anzahl der Rausch-Messwerte in unmittelbarer Nachbarschaft zu den Fahrbahnmarkierungen die Anzahl der Messungen auf den Fahrbahnmarkierungen sogar übersteigen. Zwar unterscheiden sich in der Regel die Zustände jedes binären Bayes Filters  $p(mG_{x,y})$  von Fahrbahnmarkierungen durch iterative Mehrfachmessungen von den




Abbildung 3.15: Drittes Beispiel für eine Belegungskarte mit Bodenpunkten und additiven Rauschen hervorgerufen durch *falsch-positive* Zuweisungen innerhalb des Vorverarbeitungsschritts der Bodenerkennung.




Abbildung 3.16: Das vierte Beispiel zeigt abschließend die Überlagerung aller eben erläuterten additiven Störgrößen in einer einzigen Belegungskarte.

Zuständen der Nachbarzellen, jedoch kann davon nicht in allen Fällen ausgegangen werden. Es ist daher umso wichtiger, dass ein anschließendes Verfahren zur Parameterextraktion diese Gegebenheiten berücksichtigt und eine möglichst hohe Resistenz gegenüber additiven Störgrößen besitzt.

#### 3.4.3 Histogrammbasierte iterative Parameteroptimierung des Kurswinkels und der Krümmung

Ziel der Parameterextraktion ist es, alle in einer Belegungskarte  $mG$  enthaltenen Fahrstreifen  $f_i$  (3.25) zu bestimmen und eine konsistente Instanz des Straßenmodells  $S_j$  (3.26) zu erzeugen. In diesem Abschnitt wird als Teillösung dieses Problems zuerst ein Verfahren zur iterativen Parameteroptimierung des Kurswinkels  $\psi_i$  und der Krümmung  $c_i$  der in einer

Belegungskarte enthaltenen Fahrstreifen (3.26) vorgestellt.

$$\mathbf{f}_i = [c_i \ \psi_i \ y_i \ b_i]^T \quad (3.25)$$

$$S_j = \{\mathbf{f}_1, \dots, \mathbf{f}_n\} \quad (3.26)$$

Sei

$$\mathbb{P}_S = \{\mathbf{f}_0, \dots, \mathbf{f}_i, \dots, \mathbf{f}_n\} \quad (3.27)$$

die Menge aller theoretisch möglicher Kombinationen von Fahrstreifen, dann existiert eine Teilmenge  $S_j \subset \mathbb{P}_S$ , die alle in einer Belegungskarte  $mG$  vorhandenen Fahrstreifen enthält. Das Bestimmen der Teilmenge  $S_j$  ist keinesfalls trivial und um den Suchraum einzugrenzen, wird zuerst die Annahme getroffen, dass die Krümmung und Ausrichtung aller in  $mG$  enthaltener Fahrstreifen identisch ist:

$$c_i = c_k = \dots = \bar{c}, \quad (3.28)$$

$$\psi_i = \psi_k = \dots = \bar{\psi}. \quad (3.29)$$

Diese Annahme setzt implizit parallele überlappungsfreie Fahrstreifen voraus und entspricht einer autobahnähnlichen Straße ohne die Berücksichtigung von Abzweigungen (Abbildung 3.12). Die für  $S$  und jeden Fahrstreifen  $\mathbf{f}_i$  zu bestimmenden Parameter aus Abschnitt 3.3 reduzieren sich somit auf die allgemeine Krümmung der Straße  $\bar{c}$ , den relativen Kurswinkel  $\bar{\psi}$ , die Ablage  $y_i$  und die Breite  $b_i$  für jeden Fahrstreifen (Gleichung 3.30 und 3.31).

$$\bar{\mathbf{f}}_i = [\bar{c} \ \bar{\psi} \ y_i \ b_i]^T \quad (3.30)$$

$$S_j = \{\bar{\mathbf{f}}_1, \dots, \bar{\mathbf{f}}_n\} \quad (3.31)$$

Es ist offensichtlich, dass die Annahme über parallele Fahrstreifen mit einer einzigen Krümmung keine Gültigkeit besitzen kann, da benachbarte Fahrstreifen immer einen unterschiedlichen Kurvenradius aufweisen müssen, um sich nicht zu schneiden. Geht man davon aus, dass die Fahrstreifenbreite konstant bleiben muss, entsteht ein Modellierungsfehler in der proportional mit dem lateralen Abstand eines Fahrstreifens zum Entwicklungspunkt des Modells zunimmt. Dieser Fehler soll im Folgenden exemplarisch für eine Straße mit drei Fahrstreifen bei unterschiedlichen Entwurfsgeschwindigkeiten betrachtet werden.

### Fehlerabschätzung für ein Modell mit einheitlicher Krümmung

Tabelle 3.2 zeigt den relativen Fehler in der Krümmung für die jeweils zwei benachbarten Fahrstreifen bei einer Entwurfsgeschwindigkeit von 70 km/h bis 120 km/h. Für die Betrachtung wurde eine mittlere Fahrstreifenbreite von 3.5 m angesetzt und es wurde zudem angenommen, dass sich das Fahrzeug in der Mitte des dritten Fahrstreifens befindet. Die Nummerierung erfolgt dabei ausgehend von dem Fahrstreifen mit dem kleinsten Radius  $R$ . Der maximale Fehler bei  $V_e = 70$  km/h mit einem Kurvenradius von 180 m liegt bei einem Abstand von 7 m zum Entwicklungspunkt bei ungefähr 4%. Bei der am häufigsten vorkom-

$V_e$ (m)	$R_{\min}$ (m)	$L_{\min}$ (m)	Relativer Krümmungsfehler des i-ten Fahrstreifens (%)	
			1	2
70	180	40	4.05	1.98
80	250	45	2.88	1.42
90	340	50	2.10	1.04
100	450	55	1.58	0.78
120	720	60	0.98	0.49

Tabelle 3.2: Betrachtung des relativen Krümmungsfehlers des i-ten Fahrstreifens bei variierender Entwurfsgeschwindigkeit  $V_e$  nach RAS-L [For95] mit minimalem Kurvenradius  $R_{\min}$  bei minimaler Länge eines Kurvensegments  $L$ .

menden Entwurfsgeschwindigkeit von  $V_e = 120$  km/h mit einem minimalen Kurvenradius von 120 m, liegt dieser unterhalb von einem Prozent.

Um die Auswirkung des Fehlers in der Krümmung besser quantifizieren zu können, zeigt Abbildung 3.17 den Einfluss auf die Ablage  $y_i$  für den ersten und zweiten Fahrstreifen in einer Distanz von bis zu 30 m. Wie erwartet, nimmt der Fehler in der Ablage  $e_y$  mit abnehmendem Kurvenradius und steigender Distanz zu. Betrachtet man den ungünstigsten Fall für den ersten Fahrstreifen bei  $V_e = 70$  km/h, so liegt der maximale Fehler bei 0.1 m. Dieser Fehler ist mit Blick auf die in Abschnitt 1.2 festgelegten Anforderungen an die Genauigkeit durchaus zu tolerieren.

### Histogrammbildung

Grundidee des vorgestellten Verfahrens zur Parameterschätzung ist es,  $S$  in eine Histogrammdarstellung zu überführen, bei der jede mögliche Variation von  $c_k$  und  $\psi_l$  genau ein einzelnes Histogramm  $H_i$  definiert. Jeder Klasse  $k_i$  (3.32) eines Histogramms  $H_i$ , sind dabei alle Wahrscheinlichkeiten  $p(mG_{x,y})$  bi-linear zugeordnet, die sich auf einem Kreisbogen  $K_r$  mit der Krümmung  $c_k$  befinden, der eine Gerade  $g(\alpha, x, x_{\text{grid}}, y_{\text{grid}})$  orthogonal<sup>9</sup> in einem diskreten Abstand  $y$  schneidet (Abbildung 3.18). Die Gerade  $g$  beschreibt dabei eine Gerade in  $mG$  unter Berücksichtigung der Eigenfahrzeugposition  $\mathbf{s}_{\text{grid}}$  mit der Steigung  $\alpha_l = \psi_{\text{grid}} + \psi_l + \frac{\pi}{2}$ .

$$f(k_i) = \sum_{x=-j}^j f(y, x, c_k, \alpha_l) \tag{3.32}$$

Gilt beispielsweise  $c_k = \psi_l = 0$ , entspricht die Histogrammbildung einer einfachen zeilen- oder spaltenweisen Summation mit der Nebenbedingung  $\psi_{\text{grid}} = 0$ . Abbildung 3.18 zeigt im Detail die ebenen erläuterten Zusammenhänge. Zudem verdeutlicht Abbildung 3.18 die

<sup>9</sup>Die Gerade  $g$  verläuft durch den Kreismittelpunkt von  $K_r$ .




Abbildung 3.17: Fehler in der Ablage  $e_y$  bei einer Distanz von bis zu 30 m. In (a) für den ersten und in (b) für den zweiten Fahrstreifen in Abhängigkeit der Entwurfsgeschwindigkeit  $V_e$ .

Notwendigkeit, bei der Summation entlang des Kreisbogens  $K_r$  eine Interpolation durchzuführen. Im Gegensatz zu  $y$ , welches per Definition nur diskrete Abstandswerte annehmen kann, sollten  $c$  und  $\psi$  beliebige kontinuierliche Werte annehmen können, um den negativen Einfluss der Diskretisierung einer Belegungskarte auf die Güte der Parameterschätzung zu reduzieren. Der theoretisch maximale Funktionswert einer Klasse  $f(k_i)$  ist dabei abhängig von der maximal möglichen Pfadlänge  $n$  eines Kreisbogens in  $mG$ . Um diese Abhängigkeit




Abbildung 3.18: Die Abbildung zeigt die wichtigsten Zusammenhänge bei der Berechnung eines beliebigen Histogramms  $H_i$ . Einer Klasse  $k_i$  sind alle Wahrscheinlichkeiten aus der Belegungskarte bi-linear entlang des Kreisbogens  $K_r$  zugeordnet, der eine Gerade  $g$  in einem Abstand  $y$  schneidet. Zusätzlich ist die Interpolation zwischen benachbarten Zellen zur Bestimmung der Wahrscheinlichkeit eines beliebigen Punktes  $\mathbf{x}$  auf dem Kreisbogen  $K_r$  schematisiert.

für die nachfolgenden Schritte aufzulösen, werden die akkumulierten Wahrscheinlichkeiten durch Gleichung 3.33 auf Eins normiert.

$$\bar{k}_i = \frac{f(k_i)}{n} \quad \forall k_i \in H_i \quad (3.33)$$

Ein Histogramm  $H_i$  wird als *optimales* Histogramm  $H_{\text{opt}}$  bezeichnet, wenn keine weitere Parametervariation von  $c_k$  und  $\psi_l$  existiert, die die in  $mG$  vorliegende Krümmung und Ausrichtung der Straße besser approximiert. Abbildung 3.19(a) zeigt als Beispiel das zur Belegungskarte aus Abbildung 3.14 korrespondierende Histogramm  $H_{\text{opt}}$ . In diesem Beispiel ist  $\bar{c}$  und  $\bar{\psi}$  als bekannt vorausgesetzt. Da jedoch genaue diese Parameter geschätzt werden sollen, ist eine direkte Bestimmung von  $H_{\text{opt}}$  unmöglich.

Werden die Parameter des optimalen Histogramms nun variiert, degeneriert das Histogramm mit zunehmender Abweichung hin zu einer Gleichverteilung. Abbildung 3.19(b) und 3.19(c) zeigen als Beispiel die Auswirkung auf  $H_{\text{opt}}$  bei einer Abweichung von der optimalen Krümmung. Analog gilt dieses für eine Abweichung in der Ausrichtung  $\bar{\psi}$  (Abbildung 3.20(b) bis 3.20(c)). Der Grund für diese Degeneration ist, dass bei einer Straße alle Fahrbahnmarkierungen in Richtung der Fahrbahn ausgerichtet sind und mit zunehmendem Fehler in der geschätzten Krümmung oder Ausrichtung die Wahrscheinlichkeiten  $p(mG_{x,y})$  auf mehrere Klassen verteilt werden. Bei einem optimalen Histogramm  $H_{\text{opt}}$  sind daher definitionsgemäß die Messwerte der Fahrbahnmarkierungen und die damit verknüpften Belegungswahrscheinlichkeiten möglichst wenigen Klassen zugeordnet.




Abbildung 3.19: Auswirkungen eines additiven Fehlers in der Krümmung auf das optimale Histogramm. In (a), das optimale Histogramm  $H_{\text{opt}}$ . In (b), ein additiver Fehler in der Krümmung von  $0.0004 \text{ m}^{-1}$ . In (c),  $0.004 \text{ m}^{-1}$ .

Die Degeneration der Histogramme bei einer Abweichung von der optimalen Krümmung und Ausrichtung kann ausgenutzt werden um ein Gütefunktional  $q(H_i)$  zu definieren, das jedes Histogramm  $H_i$  ausgehend von der Verteilung bewertet. Es sollte gelten, dass die Funktion bei  $q(H_{\text{opt}})$  maximal oder minimal wird, um eine Korrelation zu der *optimalen* Parameterkombination von  $c_k$  und  $\psi_l$  zu erhalten.

Eine häufig in der Bildverarbeitung angewendete Methode zur Bestimmung der Informationsdichte in einem Bild ist die Berechnung der *Entropie*. Sie geht zurück auf Claude E. Shannon's Veröffentlichung „A mathematical theory of communication“ aus dem Jahr 1948 [Sha48]. Per Definition ist die Entropie groß, wenn eine Informationsquelle eine eher zufällige Verteilung aufweist. Die Entropie einer Informationsquelle wird demnach maximal, wenn die Verteilung einer Gleichverteilung entspricht. Sei  $p(k_i)$  die Wahrscheinlichkeit für die relative Häufigkeit einer Klasse  $k_i$ , dann ist die Entropie  $\dot{H}$  für ein Histogramm definiert als

$$\dot{H}(H_i) = - \sum_{i=1}^N p(k_i) \log_2 p(k_i) \quad (3.34)$$

mit  $N$  als Anzahl der Klassen in  $H_i$ . Bei einer Gleichverteilung gilt demnach für alle Klassen  $k_i$ :

$$p(k_i) = \frac{1}{N} \quad \forall k_i \in H_i. \quad (3.35)$$

Dieses ist per Definition genau dann der Fall, wenn ein Histogramm  $H_i$  vollständig degeneriert ist. Ist im Gegensatz dazu die gesamte Information auf lediglich eine Klasse verteilt  $p(k_i) = 1$ , ist die Entropie  $\dot{H}(H_i)$  minimal. Die Entropie erfüllt somit alle Anforderungen an ein Gütefunktional und ist daher prinzipiell zur Bewertung eines Histogramms geeignet. Zusätzlich zur Entropie, soll noch ein weiteres Gütefunktional untersucht werden, die quadratische Summe aller Klassen  $k_i$  (3.36). Diese kann direkt aus ihrer Verwendung als




Abbildung 3.20: Auswirkungen eines additiven Fehlers in der Ausrichtung auf das optimale Histogramm. In (a), das optimale Histogramm  $H_{\text{opt}}$ . In (b), ein additiver Fehler in der Ausrichtung von  $1^\circ$ . In (c),  $4^\circ$ .

Strafterm bei der Methode der kleinsten Quadrate motiviert werden.

$$Q(H_i) = \sum_{i=1}^N \bar{k}_i^2 \quad (3.36)$$

Abbildung 3.21 zeigt die Entropie im Vergleich zur quadratischen Summe eines Histogramms. Ausgehend von einer Entropie von Null  $p(k_0) = 1$ , wurde iterativ eine Degeneration zu einer Gleichverteilung (3.35) für  $N = 5$  Zufallsvariablen durchgeführt. Für einen besseren Vergleich, wurde die Entropie  $\dot{H}(H_i)$  mit der maximalen Entropie  $\dot{H}_{\text{max}}$  (3.37) normiert.

$$\dot{H}_{\text{max}} = - \sum_{i=1}^N \frac{1}{N} \log_2 \frac{1}{N} = \log_2 N \quad (3.37)$$

$$\bar{H}(H_i) = \frac{\dot{H}(H_i)}{\dot{H}_{\text{max}}} \quad (3.38)$$

Es ist zu erkennen, dass neben der Entropie, auch die Summe der Quadrate als einfache nicht-lineare Funktion die Anforderungen an ein Gütefunktional erfüllt. Unterschiede ergeben sich lediglich bei dem Anstiegsverhalten und dem Minimum beider Funktionen<sup>10</sup>. Anders als bei der Entropie, gilt für die quadratische Funktion  $Q(H_i)$  eine untere Schranke von  $\frac{1}{N}$ . Diese ist jedoch, genau wie die Steigung der Funktionen, für einen Vergleich der einzelnen Histogramme miteinander nicht entscheidend. Beide Funktionen sind strengmonoton steigend und somit für einen Vergleich geeignet. Zusammenfassend lässt sich sagen, dass beide Funktionen gleichermaßen geeignet sind um die Güte der Histogramme  $H_i$  funktional zu beschreiben. Für diese Arbeit wurde als Gütefunktion  $q(H_i)$  die Sum-

<sup>10</sup>Als Vergleichsfunktion wurde  $1 - \bar{H}(H_i)$  gewählt.




Abbildung 3.21: Die quadratische Summe im Vergleich zur Entropie.

me der Quadrate gewählt, da im Gegensatz zur Entropie, keine Berechnung der relativen Häufigkeit erforderlich ist.

Durch die Gütefunktion  $q(H_i)$  ist es möglich, die einzelnen Histogramme relativ zueinander zu bewerten. Dabei besitzt das optimale Histogramm  $H_{\text{opt}}$  das größte Gütemaß  $q_{\text{max}}$  und alle anderen entsprechend ihrer Parameter geringere Werte. Abbildung 3.22 zeigt als Beispiel die Auswertung des Gütefunktional für die Belegungskarte aus Abbildung 3.14 in einem vorgegebenen Intervall für  $c$  und  $\psi$ . Es ist intuitiv, dass die Berechnung aller Histogramme in einer angemessenen Diskretisierung die Anforderungen an die Echtzeitfähigkeit des Verfahrens nicht erfüllen würde. Ziel ist es folglich,  $q(H_{\text{opt}})$  zu bestimmen, ohne alle Histogramme im Abstand einer vorgegebenen Diskretisierung berechnen zu müssen. Das Problem, das optimale Histogramm zu bestimmen, kann daher als nicht-lineares Optimierungsproblem einer Funktion  $f(\mathbf{x})$

$$\min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x}) \text{ für } f : \mathbb{R}^n \rightarrow \mathbb{R} \quad (3.39)$$

$$\mathbf{x} = [c \ \alpha]^T \quad (3.40)$$

aufgefasst werden. Es wird zudem angenommen, dass das in Abbildung 3.22 dargestellte lokale Maximum des Gütefunktional  $H_{\text{opt}}$ , auch das globale Maximum repräsentiert.

### Nicht-lineare Optimierung

In der Literatur existieren mehrere Verfahren zur lokalen Optimierung nicht-linearer Funktionen [Alt02, KLT03]. Diese können prinzipiell in ableitungsfreie- und nicht ableitungsfreie Verfahren unterteilt werden. Verfahren, die auf der ersten oder zweiten Ableitung basieren,




Abbildung 3.22: Auswertung des Gütefunktionals  $q(H_i)$  für  $\psi = -4 \dots -4^\circ$  und  $c = -0.01 \dots 0.01 \text{ m}^{-1}$ .

weisen in der Regel ein schnelleres Konvergenzverhalten als ableitungsfreie Methoden auf, jedoch ist für ihre Anwendung mindestens die Berechnung der ersten Ableitung erforderlich.

Für die Suche nach dem Maximum der Funktion  $f(\mathbf{x})$  wird in dieser Arbeit das Down-Hill-Simplex Verfahren verwendet, welches wie der Hook-Jeeves Algorithmus [HJ61] zu der Klasse der *Direct-Search* Methoden zählt. Alle diese Methoden haben gemein, dass sie zur Suche des Minimums mit einer Heuristik arbeiten und auf die Berechnung des Gradienten oder der Hesse-Matrix nicht angewiesen sind. Ein äußerst umfassender Überblick über unterschiedliche Methoden zur *direkten Suche* kann in [KLT03] gefunden werden.

Das Down-Hill-Simplex Verfahren benutzt für einen  $n$  dimensionalen Parameterraum ein Simplex mit  $n + 1$  Ecken, um über geschickte Transformationen von diesem Simplex das Maximum zu finden. Es gehört zu den ableitungsfreien Methoden zur Optimierung nichtlinearer Funktionen mit mehreren Parametern und eignet sich deshalb und wegen seiner Robustheit gegenüber kleinen lokalen Maxima, die Funktion  $f(\mathbf{x})$  zu maximieren. Dabei ist es von großem Vorteil, dass die erste Ableitung, die nur sehr aufwendig über den Differentialquotienten berechnet werden kann, nicht benötigt wird. In der Literatur existieren zahlreiche Varianten des Down-Hill-Simplex Verfahrens, die je nach zu lösendem Problem unterschiedliche Ausprägungen der einzelnen Berechnungsschritte aufweisen. Im Folgenden sind die Berechnungsvorschriften eines auf die Problemstellung angepassten Verfahrens aufgeführt, das auf dem Nelder-Mead Algorithmus basiert [NM65].

Bei der Suche nach dem optimalen Histogramm besteht der Parameterraum aus den zwei Parametern  $c$  und  $\alpha$  (3.40) und es gilt  $n = 2$ . Das Simplex beschreibt somit ein Dreieck, dessen Eckpunkte jeweils für ein berechnetes Histogramm mit seinem Gütemaß

stehen. Die Parameter zur Berechnung eines Histogramms  $c$  und  $\alpha$ , werden dabei durch die Koordinaten eines Punktes  $\mathbf{x}_i$  im Parameterraum des Simplex vorgegeben. Anstelle des Minimums, soll hier das Maximum der Funktion  $f(\mathbf{x})$  bestimmt werden. Dieses wird erreicht, indem das Gütefunktional  $q(H_i)$  negiert wird.

Im Folgenden sind die wesentlichen Berechnungsschritte des Nelder-Mead Algorithmus für einen Parameterraum mit zwei zu bestimmenden Parametern aufgeführt.

Vor der Berechnung der ersten Iteration wird zunächst ein Eckpunkt  $\mathbf{x}_1$  des Simplex auf Basis einer Schätzung des Winkels  $\alpha$  und der Krümmung  $c$  gewählt. Anschließend werden die anderen beiden Eckpunkte  $\mathbf{x}_2$  und  $\mathbf{x}_3$  über Addition von definierten Abständen  $\mathbf{d}_1$  und  $\mathbf{d}_2$  zu dem geschätzten Eckpunkt  $\mathbf{x}_1$  bestimmt. Die Abstände  $\mathbf{d}$  müssen dabei so gewählt werden, dass die durch die Eckpunkte aufgespannten Kanten des Dreiecks linear unabhängig sind.

In jedem Iterationsschritt werden anschließend die Eckpunkte aufsteigend nach ihrem Funktionswert sortiert

$$f(\mathbf{x}_1) \leq f(\mathbf{x}_2) \leq f(\mathbf{x}_3) \quad (3.41)$$

und der mit  $n+1$  markierte Eckpunkt am Schwerpunkt  $\mathbf{x}_0$  (3.42) mit dem Skalierungsfaktor  $\gamma_1 \geq 1$  gespiegelt (3.43).

$$\mathbf{x}_0 = \frac{\mathbf{x}_1 + \mathbf{x}_2}{2} \quad (3.42)$$

$$\mathbf{x}_r = \mathbf{x}_0 + \gamma_1(\mathbf{x}_0 + \mathbf{x}_3) \quad (3.43)$$

Je nach Funktionswert des neuen Eckpunktes  $\mathbf{x}_r$  werden dabei drei Fälle unterschieden:

1.  $f(\mathbf{x}_1) \leq f(\mathbf{x}_r) \leq f(\mathbf{x}_2)$ . Besitzt der neue Eckpunkt  $\mathbf{x}_r$  einen Funktionswert  $f(\mathbf{x}_r)$ , der zwischen dem Funktionswert von Eckpunkt  $f(\mathbf{x}_2)$  und  $f(\mathbf{x}_1)$  liegt, wird  $\mathbf{x}_3$  durch  $\mathbf{x}_r$  ersetzt (Abbildung 3.23(a)).
2.  $f(\mathbf{x}_r) < f(\mathbf{x}_1)$ . Besitzt der neue Eckpunkt  $\mathbf{x}_r$  sogar einen Funktionswert  $f(\mathbf{x}_r)$  der kleiner ist als das Minimum  $f(\mathbf{x}_1)$ , wird die Spiegelung von  $\mathbf{x}_r$  nochmals am Schwerpunkt  $\mathbf{x}_0$  mit dem Skalierungsfaktor  $\gamma_2$  durchgeführt. Der Eckpunkt  $f(\mathbf{x}_3)$  wird anschließend durch den Punkt ersetzt, der den kleineren Funktionswert aufweist (3.44).

$$\mathbf{x}_3 = \begin{cases} \mathbf{x}_r, & \text{für } f(\mathbf{x}_r) \leq f(\mathbf{x}_{rr}), \\ \mathbf{x}_{rr}, & \text{sonst.} \end{cases} \quad (3.44)$$

3.  $f(\mathbf{x}_r) \geq f(\mathbf{x}_2)$ . Ist der Funktionswert  $f(\mathbf{x}_r)$  größer als der Funktionswert  $f(\mathbf{x}_2)$ , wurde das Minimum wahrscheinlich übersprungen und das Simplex wird durch eine Reflexion von  $f(\mathbf{x}_3)$  am Schwerpunkt  $f(\mathbf{x}_0)$  mit dem Skalierungsfaktor  $\rho_1 < 1$  kontrahiert (Abbildung 3.23(b) und 3.23(c)). Der sich ergebende Punkt wird als  $f(\mathbf{x}_c)$  bezeichnet. Ist der Funktionswert des neu berechneten Punktes  $f(\mathbf{x}_c)$  kleiner ist als der von  $f(\mathbf{x}_3)$ , wird  $f(\mathbf{x}_3)$  durch  $f(\mathbf{x}_c)$  ersetzt. Andernfalls erfolgt die sogenannte *Reduktion*:

$$\mathbf{x}_i = \mathbf{x}_1 + \rho_2(\mathbf{x}_i - \mathbf{x}_1) \quad \forall i \in \{2 \dots n + 1\}. \quad (3.45)$$

Der Reduktionsschritt sorgt allgemein dafür, dass sich das Simplex schneller zusammenzieht und leistet somit einen wichtigen Beitrag zur Konvergenzbeschleunigung in der Nähe des Minimums. Durch jede Iteration, die durchgeführt wird, nähert sich das Simplex weiter dem Minimum. Ist dieses erreicht, zieht sich das Simplex zusammen, wodurch die Lage des Minimums mit einer hohen Genauigkeit bestimmt werden kann. Die Größe des Simplex außerhalb des globalen Minimums ermöglicht dabei eine große Robustheit gegenüber lokalen Minima, die von ihrer Ausdehnung kleiner als das Simplex sind und somit übersprungen werden. Ein Konvergieren in ein lokales Minimum kann dadurch verhindert werden. Im Folgenden werden noch einige wichtige praktische Überlegungen diskutiert, die für die Anwendung des Nelder-Mead Verfahrens notwendig sind.

**Skalierungsfaktoren  $\gamma_1, \gamma_2$  und  $\rho_1, \rho_2$ :** Da die Skalierungsfaktoren direkten Einfluss auf Konvergenz des Simplex besitzen, ist ihre Wahl von entscheidender Bedeutung für das Konvergenzverhalten des Iterationsverfahrens. In der Regel werden sie mit den Standardwerten  $\gamma_1 = 1, \gamma_2 = 2$  und  $\rho_1 = \rho_2 = \frac{1}{2}$  belegt. Diese Werte haben sich in der Literatur [LRWW98] als guter Kompromiss zwischen Kontraktion und Aufweitung des Simplex erwiesen. Sie können jedoch prinzipiell an die speziellen Gegebenheiten einer Zielfunktion angepasst werden.

**Degenerierung:** Das Simplex kann sich durch eine Reflexion seiner  $n + 1$  Eckpunkte am Mittelpunkt seiner Kanten in alle  $n$  Raumrichtungen bewegen. Diese Bewegungsfreiheit wird stark eingeschränkt, wenn ein Eckpunkt auf einen anderen oder die Verbindungslinie zwischen zwei andere Eckpunkte fällt. Dadurch wird die Bewegungsfreiheit des Simplex um eine Raumrichtung eingeschränkt und das Minimum kann in aller Regel nicht mehr erreicht werden. So ist in der Literatur auch allgemein bekannt, dass der Nelder-Mead Algorithmus durch eine iterative Degeneration nicht immer in der Lage ist, auch das Minimum zu erreichen [KLT03]. Dieses kann jedoch verhindert werden, wenn nur bestimmte Transformationen verwendet werden, die eine Degeneration prinzipiell unterbinden. Bei einem Simplex mit drei Ecken wird dieses dadurch erreicht, dass bei einer Transformation immer nur ein Eckpunkt in Richtung des Mittelpunktes  $\mathbf{x}_0$  der Verbindungslinie zwischen den beiden anderen Punkten verschoben wird. So können sich die Eckpunkte zwar beliebig nahe annähern, jedoch nie aufeinander fallen.

**Konditionierung der Größe des Simplex:** Bei der Verwendung des Down-Hill Simplex Verfahrens ist es im Allgemeinen erwünscht, dass sich das Simplex im Minimum zusammenzieht, um eine ausreichende Genauigkeit zu erreichen. Eine Besonderheit dieses Optimierungsproblems ist jedoch, dass sich die Lage des Maximums in der Zielfunktion  $f(\mathbf{x})$  kontinuierlich über der Zeit verändert. Dieses liegt daran, dass die Lage des Maximums durch den Winkel  $\alpha$  und die Krümmung  $c$  der Straße vorgegeben wird, auf der die Belegungskarte berechnet wird. Da sich diese beiden Parameter in der Regel bei einer autobahnähnlichen Straße kontinuierlich über den Weg und damit auch die Zeit verändern,




Abbildung 3.23: Die Abbildung (a) bis (d) zeigen vier Iterationen des Nelder-Mead-Simplex Verfahrens. Das Minimum der Funktion ist als schwarzer Punkt markiert. In Abbildung (a), gilt  $f(\mathbf{x}_1) \leq f(\mathbf{x}_r) \leq f(\mathbf{x}_2)$  und der Eckpunkt  $\mathbf{x}_3$  wird durch den neu berechneten Punkt  $\mathbf{x}_r$  ersetzt. In Abbildung (b), gilt  $f(\mathbf{x}_r) \geq f(\mathbf{x}_2)$  und das Simplex zieht sich durch eine Reflexion mit  $\rho_1 < 1$  zusammen. Eckpunkt  $\mathbf{x}_3$  wird durch  $\mathbf{x}_c$  ersetzt. In Abbildung (c) erfolgt eine weitere Kontraktion und in Abbildung (d) eine weitere Reflexion mit der sich das Simplex immer weiter dem Minimum nähert.

ist die Positionsveränderung des Minimums in der Zielfunktion auch kontinuierlich. Zieht sich das Simplex daher in einem temporär gültigen Minimum zu stark zusammen, ist es anschließend nicht mehr in der Lage ausreichend schnell der zeitlichen Veränderung der Zielfunktion zu folgen. Aus diesem Grund wird nach jedem Messzyklus überprüft, wie stark

sich das Simplex zusammengezogen hat, um es gegebenenfalls aufzuweiten. Dabei werden die Proportionen des Simplex erhalten, um zu verhindern, dass es zu einer versehentlichen Degeneration des Simplex kommt.

### 3.4.4 Identifizierung potentieller Fahrbahnmarkierungen

Aus dem optimalen Histogramm  $H_{\text{opt}}$ , dessen Parameter  $c$  und  $\alpha$  mit Hilfe des Nelder-Mead Verfahrens bestimmt wurden, ist es möglich, diejenigen Klassen  $k_i$  zu identifizieren, deren lokale Maxima potentielle Fahrbahnmarkierungen repräsentieren. Eine Auswertung über einen festen Schwellwert einer Klasse ist hierbei aufgrund des additiven Rauschens in der Belegungskarte nicht sinnvoll. Darüber hinaus steht der Funktionswert  $\bar{k}_i$  in direkter Abhängigkeit zu dem Typ einer Fahrbahnmarkierung. *Gestrichelte* Fahrbahnmarkierungen weisen im Vergleich zu *durchgezogenen* Fahrbahnmarkierungen ein deutlich geringeres Maximum auf. Da zu diesem Zeitpunkt keine Information über den Typ einer Fahrbahnmarkierung vorliegt, ist die Verwendung eines Schwellwertes praktisch unmöglich.

Eine Möglichkeit besteht in der Verwendung des Signal-Rausch-Verhältnisses, um jede Klasse  $k_i$  unter Betrachtung der lokalen Nachbarschaft in  $H_{\text{opt}}$  zu bewerten. Für die Berechnung des SNR wird sowohl die Nutz- als auch die Rauschleistung benötigt, welche als Quotient zwischen dem Funktionswert  $\bar{k}_i$  der  $i$ -ten Klasse, für die das SNR bestimmt werden soll, und dem minimalen Wert aller Klassen in einer Umgebung  $u$  um  $k_i$  definiert werden kann (3.46).

$$\begin{aligned} v_l &= \min(\bar{k}_{-u}, \dots, \bar{k}_{i-1}) \\ v_r &= \min(\bar{k}_{i+1}, \dots, \bar{k}_u) \\ \text{SNR}_{\text{K,dB}}(k_i) &= 20 \lg \left( \frac{\bar{k}_i}{\min(v_l, v_r)} \right) \end{aligned} \quad (3.46)$$

Die Umgebung  $u$  wird dabei so gewählt, dass sie die maximale zu erwartende Breite möglicher Fahrbahnmarkierungen um den Faktor zwei übersteigt. Dadurch wird sichergestellt, dass alle Messungen zu denen eine Hypothese  $i$  gehören kann auch in der Umgebung  $u$  enthalten sind. Jede Klasse  $k_i$ , dessen Signal-Rausch-Verhältnis  $\text{SNR}_{\text{K,dB}}(k_i)$  einen Schwellwert  $T^s$  übersteigt und die unter Betrachtung der Funktionswerte ihrer direkten Nachbarn  $\bar{k}_{i-1}$  und  $\bar{k}_{i+1}$  ein lokales Maximum repräsentiert, wird anschließend als mögliche Position einer Fahrbahnmarkierung betrachtet und der Menge potentieller Markierungen  $M$  (3.47) zugeordnet.

$$M = \{k_i \mid k_i \in H_{\text{opt}} \wedge \text{SNR}_{\text{K,dB}}(k_i) > T^s \wedge (\bar{k}_i > \bar{k}_{i-1} \wedge \bar{k}_i > \bar{k}_{i+1})\} \quad (3.47)$$

In Abbildung 3.24 sind exemplarisch die Positionen der Fahrbahnmarkierungshypothesen für das zu Abbildung 3.14 korrespondierende Histogramm dargestellt.




Abbildung 3.24: Die Abbildung zeigt exemplarisch die Positionen (gelb) in dem zu Abbildung 3.14 korrespondierenden Histogramms, die anhand ihres SNR's als Hypothesen für potentielle Markierungen in Betracht kommen.

### 3.4.5 Erhöhung der Auflösung in der Ablage durch Interpolation

Die einzelnen Klassen  $k_i$  aus  $H_{\text{opt}}$  die einen in Abschnitt 3.4.4 festgelegten Schwellwert überschreiten, geben Aufschluss darüber, an welchen Stellen im Histogramm sich die am stärksten ausgeprägten Kreisbögen und damit auch mögliche Fahrbahnmarkierungen befinden können. Liegt eine Markierung bedingt durch die Diskretisierung der Belegungskarte zwischen zwei Klassen  $k_i$  und  $k_{i+1}$ , verteilen sich die zugehörigen Wahrscheinlichkeiten auf die Funktionswerte der beiden Klassen linear gemäß der Lage zwischen den beiden Klassen. Dieses gilt analog für  $k_i$  und  $k_{i-1}$ . Für die Krümmung  $c$  und die Ausrichtung  $\psi$  wurde dieser Sachverhalt bereits bei der Histogrammbildung durch eine bi-lineare Interpolation berücksichtigt. Die Ablage  $y_i$  eines beliebigen Fahrstreifens  $\mathbf{f}_i$ , welche sich direkt aus den diskreten Indizes der dazugehörigen Klassen ableiten lässt, ist in ihrem Auflösungsvermögen jedoch zuerst an die Diskretisierung des Histogramms und damit an die Zellgröße der Belegungskarte gekoppelt. Um diese Abhängigkeit zu verringern, wird im Weiteren angenommen, dass sich die um eine Klasse  $k_i$  vorliegende lokale Gaußverteilung in erster Näherung durch ein Polynom zweiten Grades beschreiben lässt. Der Offset  $c_i^P$  für die Korrektur einer beliebigen Klasse  $k_i$  ist dann gegeben durch:

$$c_i^P = \frac{\frac{1}{2}(\bar{k}_{i-1} - \bar{k}_{i+1})}{2\bar{k}_i - \bar{k}_{i-1} - \bar{k}_{i+1}}. \quad (3.48)$$

### 3.4.6 Klassifikation von Fahrbahnmarkierungen

Bevor aus der in Abschnitt 3.4.4 definierten Menge potentieller Fahrbahnmarkierungen  $M$  ein konsistentes Straßenmodell  $S_j$  erstellt wird, soll zunächst auf die Klassifikation der einzelnen Markierungen eingegangen werden. Eine Klassifikation von Fahrbahnmarkierungen stellt nicht nur aus funktionaler Sicht einen entscheidenden Vorteil gegenüber einer einfachen Detektion von Fahrbahnmarkierungen dar. Die Anordnung von durchgezogenen Markierungen zur Abgrenzung der Fahrbahn kann ausgenutzt werden, um falsch-positive Fahrbahnmarkierungen und daraus abgeleitete falsch-positive Fahrstreifen  $f_i$  aus  $S$  zu entfernen. Jedem Element aus  $M$  wird zusätzlich eines der beiden Merkmale durchgezogen oder gestrichelt zugeordnet:

$$M_{\text{class}} = \{(k_i, x_i) \dots (k_n, x_n) \mid k_i \in M, x_i \in \{\text{durchgezogen, gestrichelt}\}\}. \quad (3.49)$$

Sonderformen wie zum Beispiel *durchgezogen-gestrichelt* oder *durchgezogen-durchgezogen* werden nicht berücksichtigt. Eine zusätzliche Klassifikation dieser Sonderformen in dem Histogramm  $H_{\text{opt}}$  ist zwar denkbar, jedoch erfordert diese eine erweiterte Suche nach Nebenmaxima, die dem lokalen Hauptmaximum zugeordnet werden müssen. Anschließend könnte die Entscheidung getroffen werden, ob es sich um eine „Doppelmarkierung“ handelt.

Um eine Klassifikation der in  $M$  enthaltenen Hypothesen vorzunehmen, werden zuerst alle Wahrscheinlichkeiten  $p(mG_{x,y})$ , die einer Klasse  $k_i$  zugeordnet wurden, als Funktion über ihre Position entlang des Kreisbogens  $K_i$  interpretiert. Diese Funktion entspricht einem diskreten, krümmungsfreien und winkelneutralen 1D Signal für jede Hypothese aus  $M$ . Das so erhaltene Signal  $S_i$  stimmt im idealen Fall mit dem einer Rechteckfunktion überein, wobei die Periode bei einer gestrichelten Fahrbahnmarkierung in etwa der doppelten Markierungslänge entspricht und bei einer durchgezogenen Fahrbahnmarkierung den Wert unendlich annimmt. Durch eine Autokorrelation des Signals  $S_i$  mit sich selbst, kann zuerst die Periode berechnet werden. Die Berechnung der Autokorrelationsfunktion ist jedoch aufwendiger als die Berechnung des Autoleistungsspektrums, das einer Fourier-Transformation der zeitlichen Autokorrelationsfunktion entspricht. Aus diesem Grund wird anstelle der Autokorrelationsfunktion das Autoleistungsspektrum verwendet.

Für die Berechnung des Autoleistungsspektrums wird das diskrete Signal  $S_i$ , bestehend aus  $N$  Wahrscheinlichkeiten  $p(mG_{x,y})$ , zunächst mit der Hilfe der diskreten Fourier-Transformation in den Frequenzraum transformiert (3.50). Das Autoleistungsspektrum berechnet sich anschließend aus dem Quadrat des Betrages der Fourierspektren (3.51). Abbildung 3.25 zeigt exemplarisch die Berechnung des Autoleistungsspektrums für zwei synthetische Rechteckfunktionen  $S_1$  und  $S_2$ .

$$F(\omega_n) = \sum_{k=1}^N e^{-i\omega_n t_k} f(t_k) \quad (3.50)$$

$$S_{xx}(\omega_n) = |F(\omega_n)|^2 \quad (3.51)$$




Abbildung 3.25: Autoleistungsspektrum von synthetischen Rechteckfunktionen mit überlagertem gaußschen Rauschen. Abbildung (a) Rechtecksignal  $S_1$ , das dem einer gestrichelten Fahrbahnmarkierung entspricht. Abbildung (b) Autoleistungsspektrum des Signals  $S_1$ . Abbildung (c) Rechtecksignal  $S_2$ , das dem einer durchgezogenen Fahrbahnmarkierung entspricht. Abbildung (d) Autoleistungsspektrum des Signals  $S_2$ .

Das berechnete Autoleistungsspektrum wird zur Klassifizierung der Fahrbahnmarkierung anschließend in drei Intervalle  $I_1, I_2$  und  $I_3$  eingeteilt. Die Größe der einzelnen Intervalle kann direkt aus der minimal und maximal erwarteten Länge gestrichelter Fahrbahnmarkierungen abgeleitet werden.

Das erste Intervall (Frequenzbereich)  $I_1$  beinhaltet Leistungsdichten von Frequenzanteilen, die zu Impulsfunktionen oder Funktionen mit einer großen Periodendauer gehören. Aus diesem Grund liefern Signale mit einer kleinen Periodendauer zu diesen Leistungsdichten keinen Beitrag. Daher darf der Mittelwert der Summe  $\bar{S}_{xx1}$  (3.52) der Leistungsdichten in diesem Bereich einen vorher definierten Schwellwert  $T_1^s$  nicht übersteigen, wenn das Signal

$S_i$  zu einer gestrichelten Fahrbahnmarkierung gehört.

$$\bar{S}_{xx1} = \frac{1}{a_1} \sum_{n=1}^{a_1} S_{xx}(\omega_n) \quad (3.52)$$

Das zweite Intervall  $I_2$  erstreckt sich vom Frequenzanteil  $a_1 + 1$  bis  $a_2$ . Liegt das Signal einer gestrichelten Fahrbahnmarkierung vor, tritt in diesem Bereich eine maximale Leistungsdichte  $\hat{S}_{xx2}$  (3.53) auf, dessen Position je nach Qualität des Signals und der jeweiligen Markierungslänge variiert. Damit das Signal als gestrichelte Fahrbahnmarkierung erkannt wird, muss  $\hat{S}_{xx2}$  einen vorher festgelegten Schwellwert  $T_2^s$  überschreiten.

$$\hat{S}_{xx2} = \max_{n=a_1+1}^{a_2} S_{xx}(\omega_n) \quad (3.53)$$

Der dritte Frequenzbereich  $I_3$  erstreckt sich vom Frequenzanteil  $a_3$  bis zur höchsten berechneten Frequenz. Kommt in diesem Bereich eine Leistungsdichte  $\hat{S}_{xx3}$  (3.54) vor, die ein bestimmtes Verhältnis zu  $\hat{S}_{xx2}$  übersteigt, ist die Wiederholfrequenz für eine gestrichelte Fahrbahnmarkierung zu hoch und es wird von einer durchgezogenen Fahrbahnmarkierung ausgegangen, die zahlreiche Fehlstellen aufweist.

$$\hat{S}_{xx3} = \max_{n=a_3}^N S_{xx}(\omega_n) \quad (3.54)$$

Diese Bedingung ist direkt motiviert durch eine *defensive* Auslegung des Klassifikators. Bei einem starken Rauschen, welches die Periode fast vollständig überlagert, sollte eine Markierung eher als durchgezogen klassifiziert werden, um einen möglichen Fahrstreifenwechsel zu unterbinden.

Ein Klassifikator  $K$ , der unter Berücksichtigung der oben erläuterten Zusammenhänge eine Markierung in eine der beiden Klassen gestrichelt oder durchgezogen einteilt, ist demnach wie folgt gegeben:

$$K(k_i, x_i) = \begin{cases} x_i = \text{gestrichelt}, & \text{wenn } (\bar{S}_{xx1} < T_1^s) \wedge (\hat{S}_{xx2} > T_2^s) \wedge \left(\frac{\hat{S}_{xx2}}{\hat{S}_{xx3}} < T_3^s\right), \\ x_i = \text{durchgezogen}, & \text{sonst.} \end{cases} \quad (3.55)$$

Gleichung 3.55 entspricht einem regelbasierten Schwellwertklassifikator, bei dem die Parameter  $T_1^s$ ,  $T_2^s$  und  $T_3^s$  zuvor empirisch oder durch Parametervariation bestimmt werden müssen. Neben einem regelbasierten Ansatz, wäre darüber hinaus auch die Klassifikation mit einem lernendem Verfahren, welches auf einer zuvor bestimmten Trainingsmenge  $\{(k_i, x_i) \dots (k_n, x_n) \mid x_i \in \text{gestrichelt}\}$  und  $\{(k_i, x_i) \dots (k_n, x_n) \mid x_i \in \text{durchgezogen}\}$  aufbaut, denkbar. Ein Überblick über lernende Klassifikationsverfahren kann in [Bis07] gefunden werden.

### 3.4.7 Detektion gültiger Fahrstreifen

In den vorangegangenen Abschnitten 3.4.3 bis 3.4.6 wurden die globalen Straßenparameter  $c$  und  $\psi$  geschätzt, die Klassen  $k_1 \dots k_n$  potentieller Fahrbahnmarkierungen aus dem optimalen Histogramm  $H_{\text{opt}}$  extrahiert und anschließend klassifiziert. In diesem Abschnitt erfolgt nun die Erstellung eines konsistenten Straßenmodells  $S_j$  auf Basis eines regelbasierten und kombinatorischen Ansatzes.

Der vorgestellte Ansatz kann dabei in drei grundlegende Schritte unterteilt werden: die Detektion des Ego-Fahrstreifens, die Detektion benachbarter Fahrstreifen und die Wahl des besten Straßenmodells durch Bewertung des Signal-Rausch-Verhältnis aller möglicher Fahrstreifenkombinationen.

#### Detektion des Ego-Fahrstreifens

Im ersten Schritt werden aus der Menge potentieller Fahrbahnmarkierungen  $M_{\text{class}}$  alle möglichen Kombinationen von Fahrstreifen erzeugt, auf denen sich das Fahrzeug zum aktuellen Zeitpunkt befinden kann. Diese Fahrstreifen werden im Folgenden als *Ego-Fahrstreifen* bezeichnet.

Sei  $u$  der Index, der die Eigenfahrzeugposition in  $H_{\text{opt}}$  beschreibt,  $j$  und  $l$  die Indizes von zwei beliebigen Elementen aus  $M_{\text{class}}$ , dann errechnet sich die Ablage  $y_i$  und die Breite  $b_i$  eines möglichen Fahrstreifens  $\mathbf{f}_i$  wie folgt:

$$y_i = \frac{l - c_l^P + j - c_j^P}{2} - u \quad (3.56)$$

$$b_i = |l - c_l^P - j - c_j^P| \quad (3.57)$$

wobei  $c_j^P$  und  $c_l^P$  die beiden Offsets zur Korrektur der Ablage aus Abschnitt 3.4.5 repräsentieren.

Anschließend werden alle kombinatorisch möglichen Fahrstreifen  $\mathbf{f}_1 \dots \mathbf{f}_N$  erzeugt. Diese ergeben sich direkt aus den Tupeln der Produktmenge  $M_{\text{class}} \times M_{\text{class}}$ :

$$M_{\text{lanes}} = \left\{ \underbrace{(k_j, k_l)}_{\mathbf{f}_1} \dots \underbrace{(k_n, k_m)}_{\mathbf{f}_N} \mid k_j, k_l \in M \wedge j \neq l \wedge (b_i > T_{\text{min}}^s \wedge b_i < T_{\text{max}}^s) \right\}. \quad (3.58)$$

Um die Anzahl möglicher Fahrstreifen weiter einzugrenzen, werden zusätzlich  $T_{\text{min}}^s$  und  $T_{\text{max}}^s$  als Schwellwerte für die minimal und maximal zulässige Fahrstreifenbreite eingeführt. Ihre Wahl kann in direkter Anlehnung an die Normen für die Anlage von Fahrstreifen erfolgen. Für die Bundesrepublik Deutschland sind diese in den „Richtlinien für die Anlage von Autobahnen“ (RAA) festgelegt. Für die Fahrstreifen (Tupel), die als mögliche Ego-Fahrstreifen in Betracht kommen, kann anschließend eine weitere Einschränkung erfolgen. Da sich bildlich gesprochen das Fahrzeug innerhalb eines solchen Fahrstreifens befindet, muss wenn  $j - u > 0$  gilt,  $l - u < 0$  gelten für  $j > l$ .

Diese Bedingungen lassen sich wieder in Mengenschreibweise zusammenfassen und die

Menge aller möglichen Ego-Fahrstreifen ergibt sich wie folgt:

$$M_{\text{ego}} = \{\mathbf{f} | f_i \in M_{\text{lanes}} \wedge (j - u > 0) \wedge (l - u < 0)\}. \quad (3.59)$$

#### Detektion benachbarter Fahrstreifen

Im zweiten Schritt werden zu den erzeugten möglichen Ego-Fahrstreifen (3.59) links und rechts solange Fahrstreifen aus (3.58) angefügt, bis alle Kombinationen aus  $M_{\text{lanes}}$  abgearbeitet wurden oder auf der entsprechenden Fahrbahnseite eine Fahrbahnmarkierung als durchgezogen klassifiziert wurde. In diesem Fall wird das Anfügen benachbarter Fahrstreifen vorzeitig beendet und es wird davon ausgegangen, dass die jeweilige Straßenbegrenzung erreicht wurde. Eine Detektion von falsch-positiven Fahrstreifen außerhalb der Fahrbahn kann somit vermieden werden. Es ist offensichtlich, dass diese Methodik zum Schutz vor falsch-positiven Fahrstreifen außerhalb der Fahrbahn bei Sondersituationen wie zum Beispiel bei einer doppelten Markierung (*gestrichelt-durchgezogen*) an ihre Grenzen stößt. Im Zweifelsfall gilt es daher abzuwägen, ob auf eine Detektion von weiteren angrenzenden Fahrstreifen in Sondersituation zu Gunsten der Sicherheit verzichtet werden kann.

#### Bewertung möglicher Fahrstreifen anhand des Signal-Rausch-Verhältnisses

Im letzten Schritt werden alle Kombinationen möglicher Ego-Fahrstreifen mit dazugehörigen Nachbarfahrstreifen über ihre Fahrstreifenanzahl  $n$  und den zu den Fahrbahnmarkierungen gehörenden Signal-Rausch-Abstand (3.46) bewertet. Anschließend wird die Permutation als gültiges Straßenmodell  $S$  ausgewählt, die das beste Signal-Rausch-Verhältnis aufweisen:

$$\max \sum_{i=1}^n \text{SNR}_{\text{dB}}(\mathbf{f}_i). \quad (3.60)$$

Die gewählte Kombination von Fahrstreifen repräsentiert somit die *global* bestmögliche Anordnung von Fahrstreifen unter der zuvor geschätzten Krümmung und Ausrichtung. Dies stellt zugleich einen der wesentlichen Vorteile des vorgestellten Verfahrens zur Parameterextraktion dar. Selbst bei Belegungskarten mit starkem additiven Rauschen, welches das Signal der Markierungen fast vollständig überlagert, ist eine erfolgreiche Detektion weiterhin möglich solange bis der in Abschnitt 3.4.4 festgelegte Schwellwert für das SNR einer Markierung unterschritten wird. Aus praktischen Überlegungen ist es jedoch sinnvoll, zusätzlich noch ein minimales Signal-Rausch-Verhältnis für eine gültige Straße zu definieren, um bei Belegungskarten mit einem global äußerst schlechten SNR die Ausgabe einer gültigen Straße unterbinden zu können.


Abschließend sind in den Abbildungen 3.26(a) bis 3.26(c) drei Szenarien für eine erfolgreiche Detektion und Klassifikation aller vorhandener Fahrstreifen visualisiert. Der verwendete Lidar-Sensor entspricht Laserscanner 1 aus Kapitel 6.1.2 welcher über einen horizontalen Öffnungswinkel von  $100^\circ$  und einem vertikalen Öffnungswinkel von  $3.2^\circ$  verfügt. Im ersten Szenario, Abbildungen 3.26(a), ist die Detektion der drei vorhandenen Fahrstreifen

bei dichtem Verkehr zu sehen. Durch den im Vergleich zu der Referenzkamera relativ großen horizontalen Öffnungswinkel ist auch die Detektion des rechten Fahrstreifens möglich. In Szenario 2, Abbildungen 3.26(a), wurden alle in einem Autobahnabschnitt vorhandenen fünf Fahrstreifen sicher erkannt und klassifiziert. Im dritten Szenario, Abbildungen 3.26(c), wurden beide vorhandenen Fahrstreifen in einem Landstraßenszenario erkannt und klassifiziert. Zugleich handelt es sich bei diesem Szenario um einen Sonderfall, der in einem regulären Autobahnscenario nicht vorzufinden ist. Die beiden äußeren Fahrbahnbegrenzungen sind in diesem Fall durch einen Bordstein gegeben und es sind keine zusätzlichen Fahrbahnmarkierungen vorhanden.


## 3.5 Zusammenfassung

Zu Beginn dieses Kapitels erfolgte ein umfassender Überblick über die Eigenschaften moderner Fahrbahnmarkierungen. Als für eine lidarbasierte Erkennung von Fahrbahnmarkierungen wurde die mit der Nachsichtbarkeit von Markierungen verbundene wichtige Eigenschaft der Retroreflexion eingeführt. Es wurde eine Unterteilung der Markierungssysteme in Standardmarkierungen (Typ I) und Markierungen mit erhöhter Retroreflexion bei Nässe (Typ II) vorgenommen. Ferner wurde gezeigt, wie sich das Phänomen der Retroreflexion quantitativ in Form des Leuchtdichtkoeffizienten bei Retroreflexion beschrieben werden kann. Aufbauend auf diesen Erkenntnissen, erfolgte die Definition des SNR zwischen Fahrbahnbelag und Fahrbahnmarkierungen als wichtige Größe bei der erfolgreichen Detektion von Markierungen mittels eines Lidars. Es wurde gezeigt, wie die Wahl der Anbauposition eines Sensors zur Optimierung des Signal-Rausch-Verhältnisses ausgenutzt werden kann und welche weiteren Faktoren wie beispielsweise die horizontale und vertikale Winkelauflösung und Strahlaufweitung die Detektion von Fahrbahnmarkierungen beeinflussen können. Es wurde eine Empfehlung betreffend dieser und weiterer Parameter gegeben, die ein zur Erkennung von Fahrbahnmarkierungen eingesetzter Lidar erfüllen sollte.


Anschließend wurden bestehende Modelle zur Beschreibung des Straßenverlaufs auf ihre Eignung hin überprüft und ein Vergleich der in der Literatur existierender Verfahren zur Detektion von Fahrbahnmarkierungen mit einem Lidar vorgenommen. Aufbauend auf der Erkenntnis, dass keines dieser Verfahren die gesetzten Anforderungen in vollem Maße erfüllt, wurde ein neues iteratives histogrammbasiertes Verfahren zur Detektion von Fahrbahnmarkierungen vorgestellt. Im Detail wurde gezeigt, wie die Bestimmung der Ausrichtung und Krümmung aller auf der Fahrbahn existierender Markierungen als ein nichtlineares Optimierungsproblem aufgefasst werden kann, nämlich der iterativen Suche nach einem optimalen Histogramm. Auf Basis des optimalen Histogramms wurden anschließend die Positionen potentieller Fahrbahnmarkierungen extrahiert und mittels des Autoleistungsspektrums klassifiziert. Auf Basis eines kombinatorischen Ansatzes wurde abschließend das endgültige Straßenmodell bestimmt. Das vorgestellte Verfahren ist äußerst robust gegen Fehldetektionen und Messrauschen und reduziert den Berechnungsaufwand durch die effiziente iterative Berechnung der benötigten Histogramme auf ein Minimum.



(a)



(b)



(c)

Abbildung 3.26: Drei Beispiele für eine erfolgreiche Fahrstreifendetektion und Klassifikation aller Fahrbahnmarkierungen. Gezeigt sind zwei Autobahnszenarien in (a) und (b) sowie ein Landstraßenszenario in (c).

---

## Fusion von lidar- und videobasierter Fahrstreifenerkennung

---

Dieses Kapitel behandelt die Fusion der in Kapitel 3 vorgestellten lidarbasierten Fahrstreifenerkennung mit einem videobasierten System zur Fahrstreifenerkennung. Ziel ist es, die Verfügbarkeit und die Robustheit eines allgemeinen Systems zur Fahrstreifenerkennung durch Verwendung von Sensoren mit unterschiedlichen Messprinzipien zu steigern.

Die von Seiten der lidarbasierten Fahrstreifenerkennung für eine Fusion zur Verfügung stehenden Daten sind die durch das histogrammbasierte Verfahren geschätzten allgemeinen Straßenparameter Krümmung  $\bar{c}$ , Ausrichtung  $\bar{\psi}$  und die für jeden Fahrstreifen existierenden Ablagen  $y_i$  und Breiten  $b_i$  (4.1).

$$\bar{\mathbf{f}}_i = [\bar{c} \quad \bar{\psi} \quad y_i \quad b_i]^T \quad (4.1)$$

Für die videobasierte Fahrstreifenerkennung wird ein System verwendet, welches in der BMW 5er Reihe ab dem Jahr 2007 für die sogenannte „Spurverlassenswarnung“ zum Einsatz kommt (siehe Kapitel 6.1.2 „Videokamera“). Das Kamerasystem stellt über einen echtzeitfähigen Fahrzeugbus zu jedem Messzyklus folgende Zustandsgrößen zur Verfügung:

$$\begin{aligned} \mathbf{f}_{\text{left}} &= [c_0 \quad \psi_0 \quad y_{\text{left}}]^T \\ \mathbf{f}_{\text{right}} &= [c_0 \quad \psi_0 \quad y_{\text{right}}]^T . \end{aligned} \quad (4.2)$$

wobei  $y_{\text{left}}$  den Abstand zu linken und  $y_{\text{right}}$  den Abstand zur rechten Fahrbahnmarkierung repräsentiert. Der Index 0 bezieht sich dabei auf den eigenen Fahrstreifen. Weitere und somit benachbarte Fahrstreifen werden von diesem System nicht erfasst. Eine wirkliche Fusion existiert somit in diesem Fall nur für den eigenen Fahrstreifen, bei den benachbarten Fahrstreifen handelt es sich lediglich um eine erweiterte Filterung der Zustandsgrößen der lidarbasierten Fahrstreifenerkennung. Für eine Übersicht über in der Literatur bestehende Verfahren zur videobasierten Fahrstreifenerkennung sei der Leser auf die Einleitung in Kapitel 1.1.3 verwiesen.




Abbildung 4.1: Schematisierter Aufbau der Fusion zwischen der lidar- und videobasierten Fahrstreifenerkennung.

Die in diesem Kapitel durchgeführte Fusion ist demnach eine *high-level* Fusion [Cra05], bei der zuerst auf den Rohdaten jedes Sensors eine eigenständige Merkmalsextraktion der modellierten Zustandsgrößen erfolgt, welche anschließend fusioniert werden. Dieses Kapitel ist dabei wie folgt aufgebaut: Zuerst erfolgt eine kurze Einführung in das Kalman-Filter als rekursiver Zustandsschätzer. Anschließend wird die eigentliche Fusion der gemeinsamen Zustandsgrößen der lidar- und videobasierten Fahrstreifenerkennung mittels eines Kalman-Filters beschrieben und es wird die Vorkonditionierung der Messdaten wie beispielsweise die Messdatenzuordnung abgehandelt. Weiter erfolgt die zeitliche Filterung der durch den Lidar gemessenen benachbarten Fahrbahnmarkierungen.

Abbildung 4.1 fasst den eben beschriebenen Aufbau zur Erstellung eines fusionierten Fahrbahnmodells zusammen. Neben den Eingabedaten des lidar- und videobasierten Systems in Form der Ablage, Krümmung und Ausrichtung werden für das dynamische Modell (Abschnitt 4.2.1) die Daten der im Fahrzeug verbauten Inertialen-Messeinheit (IMU) verwendet.

## 4.1 Rekursive Zustandsschätzung mittels Kalman-Filter

Das wohl am häufigsten verwendete Verfahren zur Zustandsschätzung von linearen Systemen ist das Kalman-Filter, welches 1960 von dem ungarischen Mathematiker Rudolf Kálmán vorgestellt wurde [Kal60]. Das Filter gehört zu der Klasse der Bayes-Filter-Algorithmus und repräsentiert einen optimalen Schätzer zur rekursiven Zustandsschätzung von linearen gaußschen Systemen unter der Annahme von weißem Rauschen [WB95].

Das Filter strebt dabei die Minimierung des Schätzfehlers  $\tilde{\mathbf{x}}_k$  an:

$$\tilde{\mathbf{x}}_k = \hat{\mathbf{x}}_k - \mathbf{x}_k. \quad (4.3)$$

Neben dem von Kálmán vorgestellten Verfahren zur Zustandsschätzung linearer Systeme, existieren in der Literatur auch Erweiterungen zur Schätzung nichtlinearer Systeme wie

beispielsweise das *extended* oder *unscented* Kalman-Filter [TBF05]. Das Kalman-Filter besteht aus einem Satz von mathematischen Gleichungen, mit denen in einem rekursiven Schema sowohl der Systemzustand, als auch die Unsicherheit des Systemzustands geschätzt werden.

Ein rekursiver Zyklus des Kalman-Filters besteht dabei aus zwei grundlegenden Schritten: Der Prädiktion und der Fusion. Zuerst wird der Systemzustand mit Hilfe des Systemmodells  $\mathbf{F}$  und des Systemzustands aus dem vorherigen Zeitschritt  $\hat{\mathbf{x}}_{k-1}$  prädiziert. Die Kontrolleingabe  $\mathbf{u}$ , welche keinem bekannten Rauschen unterliegt, wird durch die Eingangsmatrix  $\mathbf{B}$  berücksichtigt. Gleichung 4.4 beschreibt einen vollständigen Rekursionschritt zur Prädiktion des Systemzustands.

Zusätzlich wird die Unsicherheit des Systemzustandes geschätzt, welche durch die Kovarianzmatrix  $\mathbf{P}$  beschrieben wird. Dafür wird die Unsicherheit des vorherigen Zustandes  $\mathbf{P}_{k-1}$  aus Basis des Systemmodells prädiziert und die Systemunsicherheit um  $\mathbf{Q}$  erhöht (siehe Gleichung 4.5).

$$\hat{\mathbf{x}}_{k|k-1} = \mathbf{F}_k \hat{\mathbf{x}}_{k-1|k-1} + \mathbf{B}_k \mathbf{u}_k \quad (4.4)$$

$$\mathbf{P}_{k|k-1} = \mathbf{F}_k \mathbf{P}_{k-1|k-1} \mathbf{F}_k^T + \mathbf{Q}_k \quad (4.5)$$

Liegt zum aktuellen Zeitschritt eine Messung vor, kann der prädizierte Systemzustand auf Basis der neuen Messung und dem darin enthaltenen Wissen über den Systemzustand korrigiert (fusioniert) werden. Abhängig von der prädizierten Fehlerkovarianz  $\mathbf{P}_{k|k-1}$  und dem Messrauschen  $\mathbf{R}_k$  wird die Kovarianz der Innovation ermittelt (4.6) und die sogenannte Kalman-Verstärkung (engl. Kalman-Gain) berechnet (4.7).

$$\mathbf{S}_k = \mathbf{H}_k \mathbf{P}_{k|k-1} \mathbf{H}_k^T + \mathbf{R}_k \quad (4.6)$$

$$\mathbf{K}_k = \mathbf{P}_{k|k-1} \mathbf{H}_k^T \mathbf{S}_k^{-1} \quad (4.7)$$

Anschließend wird die Fehlerkovarianzmatrix  $\mathbf{P}_{k|k}$  korrigiert:

$$\mathbf{P}_{k|k} = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_{k|k-1}. \quad (4.8)$$

Um nun letztlich den prädizierten Systemzustand  $\hat{\mathbf{x}}_{k|k-1}$  mit der aktuellen Messung  $\mathbf{z}_k$  zu fusionieren, wird das Residuum zwischen der aktuellen Messung und dem prädizierten Systemzustand berechnet (4.9). Da die Größen des Messvektors allerdings nicht den Größen des Systemzustands entsprechen müssen, wird der Systemzustand mit Hilfe der sogenannten Messmatrix  $\mathbf{H}_k$  in den Messraum transformiert. Als abschließender Schritt wird der prädizierte Systemzustand  $\hat{x}_{k|k-1}$  unter Berücksichtigung der Kalman-Verstärkung  $\mathbf{K}_k$  und dem Residuum  $\tilde{\mathbf{y}}_k$  angepasst (4.10).




Abbildung 4.2: Zusammenhang der im Zustandsvektor  $\tilde{\mathbf{x}}$  modellierten Größen: Ablage zur Fahrstreifenmitte  $y$ , Kurswinkel  $\psi$ , Krümmung  $c$  und Fahrstreifenbreite  $b$ .

$$\tilde{\mathbf{y}}_k = \mathbf{z}_k - \mathbf{H}_k \hat{\mathbf{x}}_{k|k-1} \quad (4.9)$$

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k \tilde{\mathbf{y}}_k \quad (4.10)$$

## 4.2 Lokalisation im eigenen Fahrstreifen

Die Lokalisation innerhalb des eigenen Fahrstreifens wird anhand eines Kalman-Filters durchgeführt. Wie bereits bekannt, ist das Kalman-Filter ein erwartungstreuer Zustandschätzer, der zu jedem Zeitpunkt  $k$  aus einem gestörten Messvektor  $\mathbf{z}_k$  einen Schätzwert  $\hat{\mathbf{x}}_k$  des wahren Systemzustands  $\mathbf{x}_k$  berechnet. Die innerhalb des eigenen Fahrstreifens zu schätzenden Größen des Zustandsvektor  $\tilde{\mathbf{x}}$  entsprechen denen aus Gleichung 4.1 bereits bekannten Größen: Ablage zur Fahrstreifenmitte  $y$ , Kurswinkel  $\psi$ , Krümmung  $c$  und Fahrstreifenbreite  $b$ .

$$\tilde{\mathbf{x}} = [y \ b \ c \ \psi]^T \quad (4.11)$$

Der Vollständigkeit halber ist der Zusammenhang der eben beschriebenen Größen in Abbildung 4.2 noch einmal schematisiert.

Das für den Prädiktionsschritt benötigte Dynamikmodell und das für den Fusionschritt benötigte Messmodell wird in den beiden folgenden Abschnitten definiert.




Abbildung 4.3: Dynamikmodell des Eigenfahrzeugs in Relation zur Solltrajektorie.

### 4.2.1 Dynamikmodell

Die in Kapitel 3.3 vorgestellten Modelle beziehen sich auf eine *statische* Position und Ausrichtung des Fahrzeuges mit Bezug auf ein vorher festgelegtes Koordinatensystem. Diese Werte können sich aber selbstverständlich im zeitlichen Verlauf abhängig von der Fahrzeugdynamik und dem Straßenverlauf ändern. Die Aufgabe des dynamischen Modells ist es, diese Einflüsse zu modellieren.

Für diese Arbeit wird ein quadratisches Dynamikmodell verwendet, bei dem die relative Position und Ausrichtung des Fahrzeuges durch ein Polynom zweiten Grades beschrieben wird. Abbildung 4.3 visualisiert die bei der Modellierung der Fahrzeugbewegung relevanten Größen Gierrate  $\dot{\Psi}$ , Geschwindigkeit  $v$  und Schwimmwinkel  $\beta$ . Der Schwimmwinkel bezeichnet die Winkeldifferenz zwischen der Richtung, in die das Fahrzeug orientiert ist und der Richtung, in die es sich wirklich fortbewegt. Den wesentlichen Einfluss auf das Dynamikmodell besitzt die Gierrate  $\dot{\Psi}$ , welche die Drehung des Fahrzeuges um seine Hochachse beschreibt und die Geschwindigkeit  $v$ .

Die laterale Position eines Fahrzeuges, welches sich auf der Solltrajektorie bewegt, lässt sich wie folgt beschreiben:

$$y_T = y + x_T \cdot \psi + \frac{1}{2} \cdot x_T^2 \cdot c. \quad (4.12)$$

Unter Einbeziehung der Fahrzeugdynamik ergibt sich damit für das Dynamikmodell folgendes Gleichungssystem:

$$\begin{bmatrix} \dot{y} \\ \dot{b} \\ \dot{\psi} \\ \dot{c} \end{bmatrix} = \begin{bmatrix} 0 & 0 & v & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & v \\ 0 & 0 & 0 & 0 \end{bmatrix} \cdot \begin{bmatrix} y \\ b \\ \psi \\ c \end{bmatrix} + \begin{bmatrix} -v & 0 \\ 0 & 0 \\ 0 & -1 \\ 0 & 0 \end{bmatrix} \cdot \begin{bmatrix} \beta \\ \dot{\Psi} \end{bmatrix} \quad (4.13)$$

### 4.2.2 System- und Messmodell

Mit Hilfe des Systemmodells lassen sich die Zustandsgrößen auf Basis des dynamischen Modells vorhersagen (präzizieren). Es ist somit ein wesentlicher Bestandteil des Prädiktionsschritts eines Kalman-Filters. In dem vorherigen Abschnitt wurde das dynamische Modell für die Bewegung eines Fahrzeuges in der Form  $\dot{\mathbf{x}}(t) = \mathbf{F}(t) \cdot \mathbf{x}(t) + \mathbf{B}(t) \cdot \mathbf{u}(t)$  angegeben. Dies entspricht einer zeitkontinuierlichen Darstellung in Abhängigkeit von  $t$ . Da das Kalman-Filter ein zeitdiskretes Filter ist, muss die zeitkontinuierliche in eine zeitdiskrete Form überführt werden. Dies erfolgt mittels einer Reihenentwicklung. Die zeitdiskrete Systemmatrix  $\mathbf{F}_k$  kann mit der Zeitkonstanten  $T$  anhand einer Reihenentwicklung wie folgt beschrieben werden:

$$\mathbf{F}_k = \mathbf{I} + \mathbf{F}(t) \cdot T + \frac{1}{2} \cdot \mathbf{F}(t)^2 \cdot T^2 + \dots \quad (4.14)$$

Da die dritte Potenz der zeitkontinuierlichen Systemmatrix  $\mathbf{F}(t)^3$  einer Nullmatrix entspricht, ergibt sich die zeitdiskrete Systemmatrix  $\mathbf{F}_k$  wie folgt:

$$\begin{aligned} \mathbf{F}_k &= \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} + \begin{bmatrix} 0 & 0 & Tv & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & Tv \\ 0 & 0 & 0 & 0 \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 & \frac{1}{2}T^2v^2 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} \\ &= \begin{bmatrix} 1 & 0 & Tv & \frac{1}{2}T^2v^2 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & Tv \\ 0 & 0 & 0 & 1 \end{bmatrix} \end{aligned} \quad (4.15)$$

Für die Bestimmung der diskreten Eingangsmatrix  $\mathbf{B}_k$  wird der Schwimmwinkel  $\beta$  vernachlässigt. Die Kontrolleingabe  $\mathbf{u}$  beschränkt sich somit auf die Gierrate  $\dot{\Psi}$ :

$$\mathbf{B}_k = [0 \quad 0 \quad -1 \quad 0]^T. \quad (4.16)$$

Das vollständige dynamische Systemmodell des Kalman-Filters in der Form  $\hat{\mathbf{x}}_{k|k-1} = \mathbf{F}_k \hat{\mathbf{x}}_{k-1|k-1} + \mathbf{B}_k \mathbf{u}_k$  zur Positionierung innerhalb des eigenen Fahrstreifens ergibt sich damit wie folgt:

$$\begin{bmatrix} y \\ b \\ \psi \\ c \end{bmatrix} = \begin{bmatrix} 1 & 0 & Tv & \frac{1}{2}T^2v^2 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & Tv \\ 0 & 0 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} y \\ b \\ \psi \\ c \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ -T \\ 0 \end{bmatrix} \cdot \dot{\Psi}. \quad (4.17)$$

Um einen vollständigen Rekursionsschritt des Kalman-Filters durchzuführen, ist es neben dem für die Prädiktion benötigten dynamischen Systemmodell notwendig, ein Messmodell zu definieren. Zentrales Element des Messmodells ist die sogenannte Messmatrix  $\mathbf{H}$ . Die lidarbasierte Fahrstreifenerkennung stellt als Messung einen Vektor zur Verfügung, welcher dem Zustandsvektor entspricht (Gleichung 4.1 und Gleichung 4.11). Als Messungen der videobasierten Fahrstreifenerkennung sind der Abstand zur linken und rechten Fahrstreifenmarkierung ( $y_{\text{left}}$  und  $y_{\text{right}}$ ), der Kurswinkel  $\psi$ , sowie die Krümmung  $c$  gegeben. Um den Abstand zu den Markierungen in den Abstand zur Fahrstreifenmitte sowie die Fahrstreifenbreite zu transformieren, werden die Gleichungen 4.18 und 4.19 verwendet:

$$\text{Abstand zur Fahrstreifenmitte:} \quad y = \frac{y_{\text{left}} + y_{\text{right}}}{2} \quad (4.18)$$

$$\text{Fahrstreifenbreite:} \quad b = y_{\text{left}} - y_{\text{right}}. \quad (4.19)$$

Die Rücktransformation erfolgt mit Hilfe der Gleichungen 4.20 und 4.21:

$$\text{Abstand zur linken Markierung:} \quad y_{\text{left}} = y_0 + \frac{b}{2} \quad (4.20)$$

$$\text{Abstand zur rechten Markierung:} \quad y_{\text{right}} = y_0 - \frac{b}{2}. \quad (4.21)$$

Somit lässt sich das Messmodell des Kalman-Filters in der Form  $\hat{\mathbf{z}}_k = \mathbf{H}_k \hat{\mathbf{x}}_{k|k-1}$  aufstellen:

$$\begin{bmatrix} y_{\text{left}} \\ y_{\text{right}} \\ \psi \\ c \end{bmatrix} = \begin{bmatrix} 1 & 0.5 & 0 & 0 \\ 1 & -0.5 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} y \\ b \\ \psi \\ c \end{bmatrix}. \quad (4.22)$$

Steht durch die videobasierte Fahrstreifenerkennung lediglich eine einzelne Messung für die linke oder die rechte Markierung zur Verfügung, wird ein angepasstes Messmodell verwendet, um auch diese unvollständige Messung sinnvoll verwerten zu können. Der Messvektor  $\hat{\mathbf{z}}_k$  reduziert sich dadurch um entweder die linke ( $y_{\text{left}}$ ) oder rechte ( $y_{\text{right}}$ ) Markierung. Die Messmatrix  $\mathbf{H}_k$  reduziert sich in beiden Fällen um eine Dimension und es ergibt sich folgender Gleichungssatz:

$$\begin{bmatrix} y_{\text{left}} \\ \psi \\ c \end{bmatrix} = \begin{bmatrix} 1 & 0.5 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} y \\ b \\ \psi \\ c \end{bmatrix}, \quad (4.23)$$

$$\begin{bmatrix} y_{\text{right}} \\ \psi \\ c \end{bmatrix} = \begin{bmatrix} 1 & -0.5 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} y \\ b \\ \psi \\ c \end{bmatrix}. \quad (4.24)$$

### 4.3 Datenassoziation und Messfehlerkorrektur

Die beiden vorangegangenen Abschnitte befassten sich hauptsächlich mit der für einen Fusionsschritt notwendigen Modellbildung für die Prädiktion (Systemmodell) und die anschließende Fusion (Messmodell).

Für die praktische Umsetzung eines Kalman-Filters ist es sinnvoll, die für den Fusionsschritt herangezogenen Eingabedaten in Form des Messvektors  $\mathbf{z}_k$  zu plausibilisieren, um ein möglichst genaues und vor allem ein um Falschmessungen bereinigtes Fusionsergebnis zu erhalten. Als Falschmessung („falsch-positiv“) werden alle Messwerte bezeichnet, die dem Filter nicht zugehörig sind, beziehungsweise keine Information über den wahren Systemzustand  $\tilde{\mathbf{x}}_k$  enthalten. Als falsch-positive Messungen gelten demnach sowohl Geistermarkierungen also auch existierende Markierungen, die nicht dem aktuellen Fahrstreifen zuzuordnen sind.

Eine häufig verwendete Methodik, um die Zugehörigkeit einer Messung zu validieren, ist das sogenannte *Gating*. Ein *Gate* beschreibt dabei ein in einem mehrdimensionalen Raum endliches Gebiet, in dem eine dem Filter zugehörige Messung zu erwarten ist. In der Regel wird das Gate als eine mehrdimensionale Schranke (engl. gate) um den prädizierten Zustandsvektor  $\hat{\mathbf{x}}_{k|k-1}$  definiert. Zunächst wird das Residuum  $\tilde{\mathbf{y}}_k$  – auch Mess-Innovation genannt – zwischen dem prädizierten Zustand  $\mathbf{H}_k \hat{\mathbf{x}}_{k|k-1}$  und dem aktuellen Messwert  $\mathbf{z}_k$  gebildet

$$\tilde{\mathbf{y}}_k = \mathbf{z}_k - \mathbf{H}_k \hat{\mathbf{x}}_{k|k-1} \quad (4.25)$$

welches anschließend mit einer Schranke als Schwellwert verglichen wird. Messungen die diesen Schwellwert überschreiten und damit außerhalb der Schranke liegen, werden verworfen. Als Schranke wird wie in [BP99] ein Vielfaches der Standardabweichung des Residuums  $\sigma_r$  verwendet. Dieses berechnet sich aus der Varianz der Messwerte ( $\sigma_m^2$ ) und der Varianz der Prädiktion ( $\sigma_p^2$ ):

$$\sigma_r = \sqrt{\sigma_m^2 + \sigma_p^2}. \quad (4.26)$$

In der Praxis wird häufig das Dreifache der Standardabweichung  $\sigma_r$  als Testkriterium festgelegt, weshalb dies im Allgemeinen auch als 3  $\sigma$ -Test bezeichnet wird.

Messwerte, die als valide und damit dem Filter zugehörig gelten, müssen demnach folgende Bedingung erfüllen:

$$|\mathbf{z}_k - \hat{\mathbf{z}}_k| = |\tilde{\mathbf{y}}_k| \leq 3\sigma_r. \quad (4.27)$$

## 4.4 Erweiterung des Fahrbahnmodells zur Beschreibung weiterer Fahrstreifen

Wie bereits einleitend erwähnt, liefert systembedingt lediglich die lidarbasierte Fahrstreifenenerkennung Informationen über die Ablagen und somit auch die Anzahl an benachbarten Fahrstreifen. An dieser Stelle erfolgt deshalb eine separate Filterung unabhängig von der in den vorherigen Abschnitten vorgestellten Fusion.

Das Problem einer weiteren Filterung besteht jedoch im Wesentlichen darin, dass bei sich über die Zeit ändernden Signalen eine zusätzliche Filterlatenz entsteht. Durch die Eigenbewegung des Fahrzeuges verändert sich neben dem Abstand zu den eigenen Fahrbahnmarkierungen, automatisch auch der Abstand zu allen weiteren existierenden Markierungen. Eine Möglichkeit, um diesen Effekt zu kompensieren, besteht in der Verwendung eines dynamischen Modells(siehe Abschnitt 4.2.1), welches die durch eine Kontrolleingabe erzeugten Zustandsänderungen modelliert. Eine andere Möglichkeit, die ohne ein Dynamikmodell auskommt, ist ein Wechsel des Referenzkoordinatensystems in Kombination




Abbildung 4.4: Modellierte Abstände zu den Markierungen weiterer Fahrstreifen.

mit einer Filterung der Fahrstreifenbreite  $b_i$ . Anders als die Ablage  $y_i$ , ändert sich die Breite  $b_i$  eines Fahrstreifens unter normalen Bedingungen wesentlich langsamer als die Ablage und ist zudem vollkommen unabhängig von der Fahrzeugdynamik. Um aus einer Breite  $b_i$  die Ablage  $y_i$  unter Berücksichtigung der bereits gefilterten Position innerhalb des eigenen Fahrstreifens zu berechnen, werden alle weiteren Fahrstreifen mit  $\frac{1}{2}\hat{b} - \hat{y}$  als Koordinatenursprung „verankert“.

Abbildung 4.4 zeigt die Modellbildung auf Basis einer Fahrstreifenbreite  $b_i$  in Relation zu der Position einer der beiden Fahrbahnmarkierungen des eigenen Fahrstreifens. Als Tiefpassfilter wird ein gleitender Mittelwertfilter verwendet:

$$\hat{b}_{i,k} = \frac{1}{n} \sum_{j=k-n+1}^k b_{i,j}. \quad (4.28)$$

Nach der Filterung kann die Ablage zu jedem Fahrstreifen  $i$  unter Verwendung des geschätzten Zustandsvektors  $\hat{\mathbf{x}}_k$  des eigenen Fahrstreifens wie folgt bestimmt werden:

$$\hat{y}_{i,k} = \frac{1}{2}\hat{b} - \hat{y} + \hat{b}_{i,k}. \quad (4.29)$$

Der Kurswinkel des Fahrzeuges bezüglich der weiteren Fahrstreifenmarkierungen sowie deren Krümmung wird von dem Zustandsvektor  $\hat{\mathbf{x}}_k$  des Kalman-Filters übernommen.

## 4.5 Zusammenfassung

In diesem Kapitel wurde eine High-Level Fusion der lidarbasierten Fahrstreifenerkennung aus Kapitel 3 mit einem videobasierten System zur Fahrstreifenerkennung durchgeführt. Die Fusion der Ablage, des Kurswinkels und der Krümmung erfolgte auf Basis eines Kalman-Filters. Im Fokus stand die Fusion der Parameter für den eigenen Fahrstreifen, da diese für eine darauf aufbauende Querführung des Fahrzeuges die größte Bedeutung haben. Die in diesem Kapitel vorgestellte Fusion bildet die Grundlage für die in Kapitel 6.4 durchgeführte Abschätzung ob eine lidarbasierte Erkennung in Kombination mit einer videobasierten Erkennung von Fahrbahnmarkierungen einen echten Mehrwert für ein Gesamtsystem zur Fahrstreifenschätzung bietet.

---

## Modellbasierte Fahrbahnranderkennung

---

In diesem Kapitel wird ein histogrammbasiertes Verfahren zur robusten Fahrbahnranderkennung in Belegungskarten vorgestellt. Zur Generierung eines konsistenten Straßenmodells wird das bereits aus Kapitel 3 bekannte iterative Verfahren zur histogrammbasierten Parameterextraktion erweitert. Dieses auf einem iterativen Optimierungsverfahren basierte Verfahren ermöglicht es, die Ablage, Krümmung und Ausrichtung mehrerer Fahrbahnbegrenzungen in Echtzeit zu erfassen und im Gegensatz zu anderen Verfahren, die laterale Streuung der zu einer möglichen Begrenzung zugehöriger Messwerte zu bestimmen.

Im Gegensatz zu Fahrbahnmarkierungen, lassen sich auf Straßen mit mehreren Fahrstreifen keine direkten Informationen über die relative Position des Fahrzeuges zu den Fahrstreifen ableiten, da weder die Breite der Fahrstreifen noch deren Abstand zur Randbebauung als bekannt vorausgesetzt werden kann. Ist jedoch ihre Ablage zu den einzelnen Fahrstreifen durch zum Beispiel eine digitale Kartenbasis [KHWA10] bekannt, ist ihre Erkennung durchaus sinnvoll. Ein Beispiel für solche Fahrbahnbegrenzungen sind Betonabweiser, Leitplanken und Tunnelwände.

### 5.1 Stand der Technik

In der Literatur existieren neben der fahrbahnmarkierungsbasierten Positionierung eine Vielzahl an weiteren Verfahren zur Positions- und Verlaufsschätzung der Fahrbahn auf Basis unterschiedlichster Landmarken. Ziel ist es, eine Lokalisierung auch auf unmarkierten Straßen zu ermöglichen oder die limitierte Reichweite von Algorithmen zur Straßenverlaufsschätzung auf Basis von Fahrbahnmarkierungen zu erhöhen.

Eine Trennung zwischen generischen Verfahren zur Freiraum- oder Straßenverlaufsschätzung und lokalen Optimierungsverfahren, wie beispielsweise einer Fahrbahnranderkennung, ist dabei nicht immer zweifelsfrei möglich. Es kann jedoch zumindest anhand der verwendeten Modelle und der Distanz, bis zu welcher diese in der Lage sind mit einem akzeptablen

Fehler den Straßenverlauf zu repräsentieren, eine grobe Einteilung in zwei Klassen vorgenommen werden.

Verfahren der ersten Klasse, welche den Verlauf der Fahrbahn auch in größerer Entfernung schätzen, verwenden in der Regel zur Beschreibung des Fahrbahnverlaufs funktionale Modelle höherer Ordnung, beispielsweise Freiform-, Spline- oder Klothoidenmodelle. Als Beispiele zu nennen sind: Radar und Stereokamera basierte Straßenverlaufsschätzung mit einem kombinierten Kalman-Partikel-Filter Ansatz [LFS09], lidarbasierte Straßenverlaufsschätzung auf Basis generischer Stützstellen und anschließender Parameteroptimierung mittels Levenberg-Marquardt-Algorithmus [KSD10] und stereobasierte Freiraumschätzung mittels dynamischer Programmierung [BFM07].

Der zweiten Klasse gehören Verfahren an, die sich eher einer lokalen Optimierung im Nahfeld widmen und dessen Modelle über weniger Freiheitsgrade (Parabel oder Kreisfunktion) verfügen. Als Beispiele zu nennen sind auf dem Kalman-Filter [FSCW03, KGWB07, DKL10, LOG11], Partikel-Filter [MM11], RANSAC [GMM09] und auf Fuzzy-Logic [TFL<sup>+</sup>11] basierende Ansätze.

Ein Vorteil von Verfahren, die auf Modellen höherer Ordnung basieren, ist die funktionale Beschreibung von Straßenverläufen mit mehrfachen Krümmungsänderungen (S-Kurven). Ein entscheidender Nachteil ist jedoch der durch die Schätzung zusätzlicher Parameter erhöhte Rechenaufwand sowie eine verminderte Robustheit gegenüber Falschassoziationen und Messrauschen (siehe Abschnitt 3.3).

## 5.2 Erweiterung der histogrammbasierten Parameterextraktion

Das in diesem Kapitel vorgestellte Verfahren ist der zweiten Kategorie zuzuordnen und basiert wie der in [DSNG06] vorgestellte Algorithmus auf der Auswertung eines Histogramms. Mit dem wesentlichen Unterschied, dass neben der Ablage auch die Ausrichtung und die Krümmung geschätzt werden. Als Basis für das histogrammbasierte Verfahren dient eine stationäre Belegungskarte (siehe Kapitel 2.4.3).

Zur geeigneten Beschreibung von Fahrbahnbegrenzungen wird das Modell aus Kapitel 3.3 erweitert, da die getroffenen Annahmen über eine einheitliche Krümmung und Ausrichtung der Straße für Fahrbahnbegrenzungen nur eingeschränkte Gültigkeit besitzen. Abbildung 5.1 zeigt den Zusammenhang der drei modellierten Größen Ablage  $y$ , Kurswinkel  $\psi$  und Krümmung  $c$ . Im Folgenden wird angenommen, dass sich die Krümmung und relative Ausrichtung der Fahrbahnbegrenzungen zum Fahrzeug unterscheiden können:

$$\mathbf{r}_i^{\text{left}} = [\bar{c} \quad \bar{\psi} \quad y_i \quad b_i]^T \quad (5.1)$$

$$\mathbf{r}_j^{\text{right}} = [\tilde{c} \quad \tilde{\psi} \quad y_j \quad b_j]^T \quad (5.2)$$

$$R_{\text{left}} = \{\mathbf{r}_1^{\text{left}}, \dots, \mathbf{r}_n^{\text{left}}\} \quad (5.3)$$

$$R_{\text{right}} = \{\mathbf{r}_1^{\text{right}}, \dots, \mathbf{r}_m^{\text{right}}\}. \quad (5.4)$$





Abbildung 5.1: Modell zur Beschreibung von Fahrbahnbegrenzungen.


 Abbildung 5.2: Aufteilung einer Belegungskarte in ein linkes Histogramm  $H_i^{\text{left}}$  und rechtes Histogramm  $H_j^{\text{right}}$ .

Die für Fahrbahnbegrenzungen zu bestimmenden Parameter werden auf zwei Krümmungen  $\bar{c}$  und  $\tilde{c}$  und zwei relative Kurswinkel  $\bar{\psi}$  beziehungsweise  $\tilde{\psi}$  erweitert. Dies folgt der Annahme, dass sich die Krümmung und Ausrichtung möglicher Fahrbahnbegrenzungen je nach Position zum Eigenfahrzeug (*links* und *rechts*) unterscheiden können, jedoch Fahrbahnbegrenzungen auf derselben „Seite“ eine identische Krümmung und Ausrichtung besitzen. Die eigentliche Parameteroptimierung der Krümmungen und Ausrichtungen erfolgt dabei analog zu Abschnitt 3.4.3 mit dem Unterschied, dass für jeden Parametersatz ein eigenes Histogramm  $H_i^{\text{left}}$  (korrespondierend zu  $\mathbf{r}_i^{\text{left}}$ ) beziehungsweise  $H_j^{\text{right}}$  (korrespondierend zu  $\mathbf{r}_j^{\text{right}}$ ) über der Belegungskarte  $\mathbf{m}$  optimiert wird. Abbildung 5.3 zeigt als Beispiel das zu Abbildung 5.2 korrespondierende optimale linke beziehungsweise optimale rechte Histogramm. Aus dem optimalen Histogramm  $H_{\text{opt}}$  ist es nun möglich, diejenigen Klassen zu identifizieren, die mit ihren lokalen Maxima potentielle Fahrbahnbegrenzungen repräsentieren<sup>1</sup>. Eine Auswertung über einen Schwellwert auf den normierten Funktionswert einer

<sup>1</sup>Zur Vereinfachung wird nicht mehr explizit zwischen  $H_{\text{opt}}^{\text{left}}$  und  $H_{\text{opt}}^{\text{right}}$  differenziert.




Abbildung 5.3: Zu Abbildung 5.2 korrespondierendes optimales linkes Histogramm  $H_{\text{opt}}^{\text{left}}$  in (a) und optimales rechtes Histogramm  $H_{\text{opt}}^{\text{right}}$  in (b).

Klasse  $i$  aus  $H_{\text{opt}}$  ist in diesem Fall sinnvoll, da der Funktionswert in Relation zu der maximal möglichen Länge einer Fahrbahnbegrenzung steht. So ist es möglich, Klassen die beispielsweise in der Belegungskarte zu einem Fahrzeug korrespondieren, aufgrund nicht ausreichender Länge zu verwerfen. Alle Klassen dessen normalisierter Funktionswert  $\bar{k}_i$  (siehe Gleichung 3.33) einen festgelegten Schwellert  $T_{\text{min}}$  überschreitet und die unter Betrachtung der Funktionswerte ihrer direkten Nachbarn  $\bar{k}_{i-1}$  und  $\bar{k}_{i+1}$  ein lokales Maximum repräsentieren, werden der Klasse potentieller Fahrbahnbegrenzungen  $R_{\text{hypo}}$  hinzugefügt:

$$R_{\text{hypo}} = \{k_i \mid k_i \in H_{\text{opt}} \wedge \bar{k}_i > T_{\text{min}} \wedge (\bar{k}_i > \bar{k}_{i-1} \wedge \bar{k}_i > \bar{k}_{i+1})\}. \quad (5.5)$$

Wie bereits einleitend erwähnt, kann das Verfahren dazu verwendet werden, die laterale Streuung der Messwerte einer Fahrbahnbegrenzung als Gütekriterium zu verwenden. Dies ist insbesondere dann von Nutzen, wenn zwischen der Güte einer Fahrbahnbegrenzung für eine mögliche Eigenlokalisierung wie beispielsweise zwischen Büschen oder Leitplanken unterschieden werden muss. Die laterale Streuung der Messwerte korrespondiert dabei direkt zu der Breite  $b_i$  einer möglichen Fahrbahnbegrenzung in  $H_{\text{opt}}$ , welche sich mit den normalisierten Funktionswerten der benachbarten Klassen nach Algorithmus 5.1 berechnen lässt.  $T_{\text{width}}$  ist dabei der Schwellwert bis zu dem die an ein lokales Maxima angrenzenden Klassen noch in die Berechnung der Breite miteinbezogen werden.

Die Abbildungen 5.4 bis 5.5 zeigen zwei Beispiele für die Erkennung einer linken und rechten Randbebauung. Im ersten Beispiel ist die extrahierte Krümmung der linken und rechten Randbebauung fast identisch. Im zweiten Beispiel unterscheidet sich die geschätzte Krümmung und Ausrichtung zwischen der linken und rechten Fahrbahnseite bereits deutlich.

Abbildung 5.6 zeigt abschließend die Erkennung der linken Randbebauung, welche einer Leitplanke entspricht. Die in der Belegungskarte vorhandene rechte Begrenzung wurde zwar erkannt, jedoch anhand der geschätzten Breite wieder verworfen. Wie in dem dazugehörigen

---

**Algorithmus 5.1 : BESTIMMUNG DER BREITE  $b$  FÜR EINE KLASSE  $k_i$ .**


---

```

für alle  $k_i \in R_{hypo}$  tue
  |  $b = 1;$ 
  | für  $k_{i-1}$  bis  $k_{min}$  und  $k_{i+1}$  bis  $k_{max}$  tue
  |   | wenn  $\bar{k}_j \leq T_{width}$  dann
  |   |   |  $b=b+1;$ 
  |   |   | sonst
  |   |   |   |  $break;$ 
  |   |   | Ende
  | Ende
Ende

```

---

Videobild als Referenz zu erkennen ist, stammen diese Messungen von einem mit Gras bewachsenem Begrenzungswall, welcher sich nur bedingt für eine sinnvolle Unterstützung in der Querführung eignet.

## 5.3 Zusammenfassung

In diesem Kapitel wurde ein neues histogrammbasiertes Verfahren zur Detektion kontinuierlicher Fahrbahnbegrenzungen vorgestellt. Die Schätzung der Ausrichtungen und Krümmungen der auf der linken und rechten Fahrbahnseite existierenden Begrenzungen erfolgte durch eine iterative Histogrammoptimierung. Auf Basis der optimalen Histogramme jeder Fahrbahnseite können anschließend die Ablagen der einzelnen Fahrbahnbegrenzungen extrahiert werden. Ein großer Vorteil der histogrammbasierten Erkennung im Vergleich zu anderen Verfahren ist die Möglichkeit, ein Gütekriterium aus der lateralen Streuung der Messwerte für jede mögliche Fahrbahnbegrenzung aus dem Histogramm abzuleiten. Dies ist insbesondere dann von Nutzen, wenn zwischen der Güte einer Fahrbahnbegrenzung für eine mögliche Eigenlokalisierung wie beispielsweise zwischen Büschen oder Leitplanken unterschieden werden muss.




Abbildung 5.4: Beispiel für die Erkennung der linken und rechten Randbebauung mit fast identischer Krümmung und Ausrichtung.




Abbildung 5.5: Beispiel für die Erkennung der linken Randbebauung. Die rechte Hypothese wurde aufgrund der großen lateralen Streuung der Messwerte wieder verworfen.




Abbildung 5.6: Beispiel für die Erkennung der linken und zwei rechter Randbebauungen mit sich unterscheidender Krümmung und Ausrichtung.

---

### Evaluierung und Systembewertung

---

In diesem Kapitel werden die vorgestellten Algorithmen bezüglich ihrer Leistungsfähigkeit bewertet. Die Definition „Leistungsfähigkeit“ setzt sich aus den Teilaspekten Genauigkeit, Verfügbarkeit und Berechnungskomplexität zusammen. Ein System, welches keine ausreichend hohe Genauigkeit erzielen kann, ist prinzipiell nicht geeignet, eine automatisierte Querregelung zu ermöglichen. Das Gleiche gilt für die Systemverfügbarkeit, ist diese zu niedrig, ist der Nutzen nicht ausreichend und das bewertete System kann nicht sinnvoll eingesetzt werden. Darüber hinaus wird betrachtet, welchen Rechenzeitbedarf die vorgestellten Algorithmen beanspruchen und inwieweit eine Umsetzung auf automotiven Plattformen möglich ist.

Dieses Kapitel ist wie folgt aufgeteilt: Im ersten Teil erfolgt ein Überblick über die in dieser Arbeit verwendeten Sensoren, das Versuchsfahrzeug und die Systemarchitektur auf der die vorgestellten Algorithmen umgesetzt wurden. Anschließend wird auf die für eine Evaluierung der Genauigkeit benötigten Referenzdaten in Form einer hochgenauen digitalen Karte eingegangen. Darauf aufbauend erfolgt die Evaluierung der lidarbasierten Fahrstreifenenerkennung. Dies beinhaltet einen Vergleich der Genauigkeit zu einer aus DGPS und einer hochgenauen digitalen Karte abgeleiteten „Ground-Truth“, die Abschätzung der Verfügbarkeit in der EU und den USA durch die Betrachtung von Fahrbahnmarkierungsnormen und die Betrachtung mehrerer Testszenen im realen Straßenverkehr im Großraum München. Anschließend erfolgt die Bewertung der Fusion zwischen der lidar- und kamera-basierten Fahrstreifenenerkennung. Unter anderem wird die Fragestellung beantwortet, ob die Kombination der beiden Systeme eine echte diversitäre Redundanz bietet. Zum Abschluss dieses Kapitels erfolgt die Abschätzung der Genauigkeit einer lidar- und radarbasierten Randbebauungserkennung im Vergleich zu einer mit DGPS erzeugten Referenz und die Betrachtung der Berechnungszeit verschiedener Belegungskarten.

## 6.1 Versuchsträger

In diesem Abschnitt wird auf das für die Evaluierung und Systembewertung verwendete Versuchsfahrzeug eingegangen. Es erfolgt ein detaillierter Überblick über die einzelnen Sensoren mit ihren Eigenschaften und Verbauorten. Abschließend wird ein kurzer Überblick über die verwendete Systemarchitektur und den daraus resultierenden Informationsfluss zwischen Sensorik, Verarbeitung und Aktuatorik gegeben.

Abbildung 6.1 zeigt als Beispiel ein Forschungsfahrzeug der BMW 5er Baureihe von der BMW Group Forschung und Technik wie es in dieser Arbeit verwendet wurde.

### 6.1.1 Koordinatensysteme

Bevor im Detail auf die einzelnen Sensoren und deren Verbauort eingegangen wird, muss zunächst das in dieser Arbeit verwendete Koordinatensystem definiert werden. Alle Sensordaten werden mit Bezug auf das Fahrzeugkoordinatensystem abgespeichert. Dieses hat sein Zentrum im Fahrzeugemblem (siehe Abbildung 6.1) und die gewählte Achsenanordnung  $x$ - $y$ - $z$  folgt dem ENU-System (DIN 70000). Die Winkel  $\Psi$ ,  $\phi$  und  $\theta$  beschreiben den Gier-, Roll- und Nickwinkel des Fahrzeugs.

Da die Sensoren an unterschiedlichen Positionen im Fahrzeug verbaut sind, werden die Sensordaten zu Beginn durch eine homogene Koordinatentransformation in das Fahrzeugkoordinatensystem transformiert.



Abbildung 6.1: Verwendetes Fahrzeugkoordinatensystem mit den Sensorachsen  $x$ ,  $y$  und  $z$ . Die Winkel  $\Psi$ ,  $\phi$  und  $\theta$  beschreiben den Gier-, Roll- und Nickwinkel des Fahrzeugs.

### 6.1.2 Sensorik

In diesem Unterabschnitt wird im Detail auf die Eigenschaften der einzelnen Sensoren eingegangen. Mit Ausnahme eines GPS-Systems und der Inertialsensorik (Gierraten- und




Abbildung 6.2: Fahrumfelderfassende Sensorik bestehend aus zwei unterschiedlichen Laserscannern, einem scannenden Radar und einem Monokamerasystem.

Geschwindigkeitssensor), handelt es sich ausschließlich um fahrumfelderfassende Sensorik. Abbildung 6.2 zeigt die vier wesentlichen Sensortypen, die für eine 360° Umfelderfassung zur Verfügung stehen.

Der erste zu nennende Sensor ist ein vier-Ebenen Laserscanner (Laserscanner 1 aus Abbildung 6.2), welcher sowohl im Front- als auch im Heckbereich des Fahrzeugs verbaut ist (Abbildung 6.3). Der zweite Laserscanner (Laserscanner 2 aus Abbildung 6.2) ist jeweils im linken und rechten Seitenbereich des Fahrzeugs angebracht. Zusätzlich zu dem vorderen und hinteren Laserscanner, sind im Front- und Heckbereich ein beziehungsweise zwei scannende Radarsensoren integriert (Abbildung 6.3). Die so in den Schnittbereichen entstehende heterogene Redundanz (siehe Abbildung 6.4) bietet den Vorteil, dass dort befindliche Objekte mit einer hohen Zuverlässigkeit erfasst werden können. Durch die Dopplermessungen der Radarsensoren stehen zudem direkte Informationen über die Relativgeschwindigkeiten sich longitudinal bewegendere Objekte zur Verfügung. Als letzter Sensor zu nennen ist ein im Innenraum installiertes Kamerasystem, welches über eine Anbindung an den CAN-Bus die Ablage, Kurswinkel und die Krümmung der Fahrbahnmarkierungen des eigenen Fahrstreifens zur Verfügung stellt.

Die folgende Auflistung fasst die Spezifikationen der einzelnen Sensoren im Detail zusammen:

- Videokamera
  - Horizontaler Öffnungswinkel: 46° bei 640 Pixel
  - Vertikaler Öffnungswinkel: 34° bei 480 Pixel
  - Abtastfrequenz: 15 Hz
- Laserscanner 1
  - Scan-Ebenen: 4 parallele Ebenen
  - Horizontaler Öffnungswinkel: 100° mit 0.25° Winkelauflösung
  - Vertikaler Öffnungswinkel: 3.2° mit 0.8° Winkelauflösung
  - Genauigkeit in der Entfernung:  $\leq 0.1$  m
  - Reichweite: 0.3 m . . . 200 m
  - Mehrzielfähigkeit: 3 Ziele pro Winkelmessung und Ebene
  - Vorklassifizierung der Messungen in Objekt, Boden und ungültiger Messpunkt
  - Abtastfrequenz: 12.5 Hz




Abbildung 6.3: Die Abbildungen (a) und (b) zeigen die jeweiligen Anbauorte der fahrumfelderfassenden Sensorik. Die farbliche Kodierung entspricht der Sensorik-Legende aus Abbildung 6.2.

- Laserscanner 2
  - Scan-Ebenen: 1
  - Horizontaler Öffnungswinkel:  $162^\circ$  mit  $1.8^\circ$  Winkelauflösung
  - Genauigkeit in der Entfernung: 1 m
  - Reichweite: 120 m
  - Mehrzielfähigkeit: 2 Ziele pro Winkelmessung
  - Abtastfrequenz: 16 Hz
- Radar
  - Scannendes Doppler-Radar mit zwei Messbereichen (Fern- und Nahbereich)
  - Horizontaler Öffnungswinkel Nahbereich:  $56^\circ$  mit  $8^\circ$  Winkelauflösung
  - Horizontaler Öffnungswinkel Fernbereich:  $18^\circ$  mit  $2.5^\circ$  Winkelauflösung
  - Vertikaler Öffnungswinkel von  $4.2^\circ$
  - Genauigkeit in der Entfernung:  $\pm 0.25$  m oder 1.5%
  - Reichweite: 60 m Nahbereich und 200 m Fernbereich
  - Abtastfrequenz: 15 Hz
- IMU
  - Messung der Gierrate  $\dot{\Psi}$
  - Messung der Fahrzeuggeschwindigkeit  $v$
- DGPS-Empfänger

Abbildung 6.4 zeigt zusätzlich eine Übersicht der horizontalen Sichtfelder der fahrumfelderfassenden Sensorik aus Abbildung 6.2. Es ist zu erkennen, dass der Front- und Heckbereich über eine jeweils redundante Auslegung an Sensoren verfügt. Mit Bezug auf das in dieser Arbeit vorgestellte Fusionssystem zur Fahrstreifenenerkennung ist zudem zu erkennen, dass der horizontale Öffnungswinkel der Videokamera deutlich geringer ist als der des




Abbildung 6.4: Horizontaler Erfassungsbereich der einzelnen Sensoren. Farblich dargestellt ist der horizontale Öffnungswinkel der beiden Laserscanner (rot und blau), der drei Radarsensoren (gelb) und der Videokamera (grün). Die farbliche Kodierung entspricht der Sensorik-Legende aus Abbildung 6.2.

Laserscanners. Hieraus ergibt sich im Vergleich zu einem kamerabasierten System neben dem aktiven Messprinzip noch ein weiterer Vorteil, der dann zum Tragen kommt, wenn auch benachbarte Fahrstreifen in unmittelbarer Nähe des eigenen Fahrzeugs erfasst werden sollen. Für einen detaillierten Überblick über die „Stärken“ und „Schwächen“ der einzelnen umfelderfassenden Sensoren im Allgemeinen sei der interessierte Leser auf [Lin09] verwiesen.

### 6.1.3 Aktuatorik

Das Versuchsfahrzeug ist zudem mit den folgenden elektrischen Aktuatoren ausgestattet, um autonome Fahrfunktionen prototypisch zu erproben:

- Elektronisches Gaspedal
- Elektronische Bremse
- Elektronische Lenkung

Sie erlauben das Ausführen von automatischen Fahrfunktionen. Für diese Arbeit ist dabei die elektrische Lenkung von Bedeutung, um eine autonome Querführung innerhalb des eigenen Fahrstreifens durchzuführen. Für Funktionen wie den Nothalteassistenten (siehe

Kapitel 1), werden allerdings für die Längsführung auch das elektrische Gaspedal und die elektrische Bremse benötigt.

### 6.1.4 Systemarchitektur und Framework

Für die Ausführung der prototypischen Funktionen ist der Versuchsträger mit einer Reihe verschiedener Recheneinheiten ausgestattet:

- Umfelderfassungs-PC mit zyklischem Framework
- Autobox von dSPACE
- Electronic Control Unit (ECU)

Auf dem Umfelderfassungs-PC werden die Messdaten aller umfelderfassender Sensoren entgegengenommen und verarbeitet. Das Fahrzeug verfügt über einen Intel®Core2™Quad Prozessor mit 2.5GHz und eine Nvidia Grafikkarte für die GPGPU Entwicklung. Die Kommunikation zwischen den einzelnen Sensoren und dem Umfelderfassungs-PC erfolgt je nach Sensortyp entweder über das CAN-Bussystem oder Ethernet.

Die Datenverarbeitung wird in einem zyklischen Framework durchgeführt, welches über unterschiedliche Bussysteme Zugriff auf die nötigen Messgrößen besitzt. Die Zykluszeit des Frameworks ist dabei variabel und wurde für die durchgeführten Versuchsfahrten auf 80 ms festgelegt. Das zyklische Verhalten des Frameworks führt dazu, dass die Messwerte nicht sofort verarbeitet werden können. Aus diesem Grund wird den Messwerten ein Zeitstempel zugeordnet, sobald diese im Framework ankommen. Die Datenverarbeitung findet im folgenden Framework-Zyklus statt, wobei die Messwerte gemäß ihrem Zeitstempel verarbeitet werden. Das Framework bietet die Möglichkeit, die Messdaten sofort während der Fahrt im „Online-Modus“ zu verarbeiten oder aber die Messdaten zu speichern und die Verarbeitung „Offline“ vorzunehmen. Für diese Arbeit wurden verschiedene Messfahrten durchgeführt und dabei die Messdaten der Sensoren aufgezeichnet. Die Auswertung und Optimierung der Algorithmen erfolgte im Simulationsmodus des Frameworks.

Die Autobox ist eine Hardwareplattform der dSPACE GmbH, welche sich durch Erfüllung harter Echtzeitanforderungen insbesondere für den Einsatz bei zeitkritischen Regelungsaufgaben eignet. Ihr Einsatzgebiet befindet sich daher im Bereich der Assistenzfunktionen und der Quer- oder Längsführung des Fahrzeugs. Die Autobox ist über CAN und Ethernet mit dem Umfelderfassungs-PC verbunden und erlaubt so eine direkte Steuerung des Fahrzeuges durch Ansprechen der Aktuatorik.

Die „Electronic Control Unit“ (ECU) dient der Vorverarbeitung der Rohdaten des ersten Laserscanner Typs (Laserscanner 1 aus Abbildung 6.2). Auf ihr werden beispielsweise die Zeitsynchronisation mehrerer angebundener Laserscanner oder die in Abschnitt 3.4.2 eingeführte Bodenerkennung der einzelnen Messpunkte durchgeführt.

Abbildung 6.5 verdeutlicht den eben beschriebenen Kontrollfluss zwischen Sensoren, ECU, CarPC und Autobox.




Abbildung 6.5: Systemarchitektur mit Kontrollfluss zwischen den Sensoren, der ECU, dem PC und der Autobox. Die in dieser Arbeit entwickelten Algorithmen sind der Kategorie „Eigenlokalisierung“ zugeordnet und die Entwicklung erfolgt ausschließlich auf dem PC.

## 6.2 Referenzdatengewinnung

Um eine Systembewertung hinsichtlich der Genauigkeit durchführen zu können, ist es notwendig, über eine geeignete Vergleichsbasis zu verfügen, anhand derer anschließend eine Fehleranalyse durchgeführt werden kann. Im einfachsten Fall handelt es sich um einen einzigen Referenzsensor, der die für einen Vergleich benötigten Größen zur Verfügung stellt. Sowohl bei der Bewertung einer lidar- oder kamerabasierten Fahrstreifenenerkennung als auch bei der Bewertung der Randbebauungserkennung ergibt sich das Problem, dass ein solcher Vergleichssensor nicht existiert<sup>1</sup>. Um dennoch die erforderlichen Vergleichsgrößen einer echten „Ground-Truth“ zu berechnen, wird in dieser Arbeit auf eine Methode zurückgegriffen, die auf einem Differential-GPS (DGPS) in Kombination mit einem „Inertialen-Navigationssystem“ (IMS) basiert. Das genaue Vorgehen wird in den folgenden Abschnitten erläutert.

### 6.2.1 Globale Positionsbestimmung mit Differential-GPS

Beim „Global Positioning System“ (GPS) handelt es sich um ein System, welches es ermöglicht, eine absolute Positionsbestimmung auf der Erde durchzuführen. Das System besteht aus drei verschiedenen Komponenten: Satelliten, Kontrollstationen und den Empfänger-Modulen. Zum heutigen Zeitpunkt gibt es zwei Anbieter, welche eine weltweite Abdeckung durch Satelliten garantieren:

- NAVSTAR GPS, USA
- GLONASS, Russland
- GALILEO, Europa (noch im Aufbau)

<sup>1</sup>Nach Wissen des Autors existiert bei Erstellung dieser Arbeit kein Sensor, der direkt die benötigten Messgrößen in der geforderten Genauigkeit erfassen kann.

Das grundlegende Funktionsprinzip ist bei beiden Systemen gleich. Einem weltumspannenden Netz von Satelliten, welche sich auf geostationären Umlaufbahnen befinden, liegt sowohl die Information über ihre genaue eigene Position als auch die genaue Zeit in einer gemeinsamen Zeitbasis vor. Diese beiden Informationen werden zu den Empfänger-Modulen übermittelt, welche anschließend anhand der Positionen der Satelliten, der übertragenen Zeit und der Signallaufzeit ihre eigene Position wie folgt berechnen können:

$$c \cdot \Delta T_S = \sqrt{(X_S - X_E)^2 + (Y_S - Y_E)^2 + (Z_S - Z_E)^2} + c \cdot \delta_E. \quad (6.1)$$

Dabei sind  $X_S$ ,  $Y_S$  und  $Z_S$  die Koordinaten des Satelliten und  $X_E$ ,  $Y_E$  und  $Z_E$  die Koordinaten des Empfängers,  $c$  die Ausbreitungsgeschwindigkeit des Satelliten-Signals,  $\Delta T_S$  die gemessene Signallaufzeit und  $\delta_E$  der Uhrenfehler des Empfängers. Zur eindeutigen Berechnung der Empfänger-Position müssen die Signale von mindestens vier Satelliten empfangen werden, da mit den drei Positionskoordinaten und dem Uhrenfehler vier Freiheitsgrade existieren.

Aufgrund relativistischer Effekte müssen die Uhren der Satelliten regelmäßig synchronisiert werden. Schon ein Uhrenfehler von nur einer Mikrosekunde kann zu Positionsfehlern von 300 m auf der Erde führen [Wen07]. Aus diesem Grund erhalten die Satelliten mehrmals täglich Synchronisationssignale der Kontrollstationen mit denen ihre Atomuhren abgeglichen werden. Zudem bekommen die Satelliten aktualisierte Informationen über ihre Flugbahn, damit sie ihre eigene Position ebenfalls korrekt bestimmen können.

Die maximale erzielbare Genauigkeit eines GPS-Systems ist jedoch durch weitere Fehlerquellen, wie beispielsweise atmosphärische Störungen, limitiert [Wen07]. So ist die Ausbreitungsgeschwindigkeit der GPS-Signale in der Ionosphäre abhängig von der dort vorherrschenden Elektronendichte des dünnen Plasmas. Eine erhöhte Elektronendichte führt zu einer erhöhten Ausbreitungs- bzw. Gruppengeschwindigkeit. Außerdem beeinflussen in der darunter befindlichen Troposphäre Wolken und Niederschlag die Ausbreitungsgeschwindigkeit. Eine variierende Geschwindigkeit der Signale führt zu unterschiedlichen Zeitdifferenzen und demnach zu einer Ungenauigkeit in der absoluten Positionsbestimmung. Da diese Fehlerquellen allerdings recht großflächig sind, spricht man von sogenannten Common-Mode-Fehlern, welche in Regionen von mehreren Kilometern gleich sind.

Um die Genauigkeit eines GPS-Systems zu erhöhen werden daher mehrere sogenannte Basisstationen eingesetzt. Diese Stationen kennen ihre genaue Position und können durch den Vergleich ihrer bekannten Position und der Position, welche sie anhand der Satelliten berechnet haben, den jeweiligen lokalen Common-Mode-Fehler bestimmen. Aus diesem Fehler lassen sich anschließend Korrekturwerte errechnen, welche an mobile GPS Empfänger gesendet werden. Im Umkreis von mehreren Kilometern lassen sich so die atmosphärischen Störungen mit Hilfe dieses Korrektursignals kompensieren und die Positionsbestimmung kann erheblich verbessert werden.

Dieses kombinierte System wird daher auch als Differential-GPS (DGPS) bezeichnet. Je nach Anzahl an Satelliten und Güte der Korrektursignale, ist es heutigen DGPS Systemen möglich, die genaue Position auf der Erdoberfläche mit einer maximalen Abweichung von 1 cm zu bestimmen.



Abbildung 6.6: In (a), DGPS gestütztes Inertiales-Navigationssystem RT3003 der Firma „Oxford Technical Solutions“ [oxf]. Durch die Kombination von DGPS und IMS können die Ausrichtung gegen Norden und die Position äußerst genau bestimmt werden. In (b), GNSS System GPS1200 von „Leica Geosystems“ [lei], welches durch Kombination von DGPS und GLONASS eine Genauigkeit von 0.01 m erzielt.

### 6.2.2 Inertiales-Navigationssystem mit DGPS

Um einen Vergleich von Krümmung, Kurswinkel und Ablage auf Basis eines hochgenauen satellitengestützten Positionssystems durchzuführen, muss zunächst die genaue Position und Ausrichtung des Fahrzeuges relativ zu einem Bezugssystem bestimmt werden. Hierfür wird in dieser Arbeit ein mit DGPS gekoppeltes Inertiales-Navigationssystem, RT3003 der Firma „Oxford Technical Solutions“, verwendet (Abbildung 6.6(a)). Dieses System ist in der Lage, die genaue Ausrichtung gegen Norden mit einer Genauigkeit von  $0.1^\circ$  und die Position im WGS-84 Koordinatensystem [Lan06] mit einer Genauigkeit von 0.02 m bei einer Abtastrate von 100 Hz zu bestimmen. Da sich die longitudinalen und lateralen Koordinaten im WGS-84 System auf ellipsoidische Koordinaten beziehen, werden diese zunächst durch eine Gauß-Krüger-Projektion (siehe Gleichung A.1) in ein kartesisches Koordinatensystem überführt [Lan06]. Die so bestimmte Position und Ausrichtung wird im Folgenden als *Pose*  $P_{\text{ego}}$  bezeichnet.

$$P_{\text{ego}} = [x \ y \ \Psi_{\text{nord}}]^T \quad (6.2)$$

Vorausgesetzt, die zu bewertenden Sensoren wurden hinreichend genau mit Bezug auf das Inertiale-Messsystem kalibriert, können zu jedem Zeitpunkt die Positionen und Ausrichtungen der Sensoren in Relation zu dem vorher gewählten kartesischen Koordinatensystem berechnet werden.

### 6.2.3 Hochgenaue digitale Karte

Neben der Ausrichtung und Position der Sensoren mit Bezug zu einem festgelegten Koordinatensystem, ist es außerdem notwendig, die Positionen der einzelnen zu referenzierenden *Objekte* in Bezug zu diesem Referenzsystem zu setzen. Die gesamte Menge an Referenzobjekten wird als eine „hochgenaue“ digitale Karte bezeichnet. Da der Begriff einer hochgenauen digitalen Karte ohne Anwendungsfall keine Bedeutung aufweist, muss dieser zuerst definiert werden.

Die Hauptbedingung, die an eine solche Karte gestellt wird, ist die Positionsgenauigkeit. Die Referenz sollte mit einem Fehler von  $e_{\text{pos}} \leq 0.1$  m vorliegen. Für diese Arbeit wird eine Kartendarstellung verwendet, bei der die geometrische Information über eine verknüpfte Menge an zweidimensionalen Kontrollpunkten  $\mathbf{p}$  repräsentiert wird:

$$P_{\text{map}} = \{\mathbf{p}_1 \dots \mathbf{p}_N\} \text{ mit } \mathbf{p}_i = (x_i, y_i). \quad (6.3)$$

Aus den einzelnen Stützstellen kann anschließend durch Interpolation die für einen späteren Vergleich zusätzlich benötigte Information über die Krümmung abgeleitet werden. Eine Interpolation ist darüber hinaus zwingend notwendig, um eine hinreichend genaue Fehlerauswertung zwischen den Kontrollpunkten zu ermöglichen. Die Interpolation wird anhand von Kubischen-Splines durchgeführt [HB08]. Per Definition stimmt bei einem Kubischen-Spline jedes Teilintervall  $s_i(x)$  mit einem kubischen Polynom überein:

$$s_i(x) = ax^3 + bx^2 + cx + d. \quad (6.4)$$

Aus Abschnitt 3.3 ist bereits bekannt, dass ein kubisches Polynom sehr gut geeignet ist, um die Straßensegmente Gerade, Kreis und Klothoide mit einem geringen Modellfehler abzubilden. Zusätzlich sind Kubische-Splines durch die Nebenbedingung (6.5) an jedem Punkt zweimal stetig differenzierbar und bieten somit den Vorteil, dass auch die Krümmung immer stetig verläuft.

$$s_i''(x_{i+1}) = s_{i+1}''(x_i) \quad (6.5)$$

Ist keine geeignete a-priori Kartenbasis verfügbar, muss diese zuerst erstellt werden. Prinzipiell existieren bei der Erstellung einer Karte zwei unterschiedliche Entwurfsmethoden, die als *top-down* und *bottom-up* bezeichnet werden. Bei der top-down Vorgehensweise erfolgt der Entwurf vorab digital. Die georeferenzierten Positionen der Kontrollpunkte leiten sich dabei direkt aus dem Krümmungsverlauf der einzelnen Kartenabschnitte ab. Ein Beispiel hierfür ist die Markierung einer Straße nach den Vorgaben einer digitalen Karte. Bei dem bottom-up Entwurf, wird ein in der Realität bereits existierendes Objekt vermessen und in eine georeferenzierte Kartendarstellung überführt. Generell sind beide Ansätze gleichermaßen geeignet, um eine ausreichend genaue Referenz zu erstellen. Der top-down Ansatz ist jedoch zu bevorzugen, wenn es sich um in der Realität noch nicht existierende Objekte handelt.

In beiden Fällen ist es notwendig, die einzelnen Kontrollpunkte georeferenziert zu ver-

messen. Entweder um sie in eine Kartendarstellung zu überführen oder um sie in der Realität zu markieren. Dies erfolgt in dieser Arbeit mit einem GNSS Vermessungssystem von der Firma „Leica Geosystems“ (Abbildung 6.6(b)), welches unter anderem auch zur Landesvermessung eingesetzt wird und durch die Kombination von DGPS und GLONASS eine Positionsgenauigkeit von 0.01 m erzielen kann.

## 6.3 Bewertung der lidarbasierten Fahrstreifenerkennung

In diesem Abschnitt wird die lidarbasierte Fahrstreifenerkennung bewertet. Zuerst wird durch einen experimentellen Messaufbau eine allgemeine Abschätzung der Verfügbarkeit einer lidarbasierten Fahrstreifenerkennung in der EU und den USA durchgeführt. Dies beinhaltet zunächst keine Leistungsbewertung des in Kapitel 3 vorgestellten histogrammbasierten Verfahrens zur Parameterschätzung. Um die Genauigkeit der geschätzten Parameter Krümmung, Kurswinkel und Ablage des histogrammbasierten Verfahrens zu verifizieren folgt ein Vergleich mit einer aus DGPS und einer hochgenauen digitalen Karte abgeleiteten „Ground-Truth“. Für die Evaluierung der Verfügbarkeit des vorgestellten Systems zur Erkennung von Fahrbahnmarkierungen wird anschließend die Verfügbarkeit der Schätzgrößen auf Autobahnabschnitten mit einer Gesamtlänge von 104.65 km im Großraum München überprüft. Abschließend werden die Auswirkungen der Zellgröße einer Belegungskarte auf die histogrammbasierte Fahrstreifenschätzung ausgewertet.

### 6.3.1 Abschätzung der Verfügbarkeit durch die Betrachtung von Fahrbahnmarkierungsnormen

Wie bereits in der Einleitung dieses Kapitels erläutert, bildet die Verfügbarkeit einen wesentlichen Teilaspekt der Leistungsfähigkeit eines Systems. In Kapitel 3 wurde für eine erfolgreiche Detektion von Fahrbahnmarkierungen mit einem Lidar die Retroreflexion als entscheidende Eigenschaft festgelegt. Ferner wurde gezeigt, wie sich das Phänomen der Retroreflexion quantitativ in Form des „Leuchtdichtekoeffizienten bei Retroreflexion“  $R_L$  messen lässt. Die zwei Fragestellungen, die sich daraus indirekt ableiten, sind: Erstens, welchen Leuchtdichtekoeffizienten bei Retroreflexion müssen Fahrbahnmarkierungen mindestens aufweisen, damit sie von heutiger Lidar-Sensorik erfasst werden können. Zweitens, existiert eine allgemeingültige Mindestanforderung für den Leuchtdichtekoeffizienten bei Retroreflexion, anhand derer die Verfügbarkeit einer lidarbasierten Erkennung von Fahrbahnmarkierungen abgeschätzt werden kann. Ziel dieses Abschnittes ist es, diese Fragestellungen zu beantworten.

In dem folgendem Teilabschnitt wird zunächst in einem experimentellen Messaufbau eine untere Schranke für den „Leuchtdichtekoeffizienten bei Retroreflexion“ bestimmt. Diese dient anschließend als Vergleichswert für eine theoretische Abschätzung der Verfügbarkeit anhand von Fahrbahnmarkierungsnormen. Betrachtet werden 16 Mitgliedsstaaten der EU




Abbildung 6.7: Messaufbau zur Überprüfung der Mindestanforderungen an die Retroreflexion. Der Aufbau entspricht im Wesentlichen dem standardisierten Messaufbau der Eurogeometrie (Abbildung 3.4).

und die USA. Der letzte Teilabschnitt beschäftigt sich abschließend mit dem Einfluss von Nässe auf der Fahrbahn und den daraus resultierenden Einschränkungen für eine lidarbasierte Fahrstreifenenerkennung.

### Experimenteller Messaufbau

Um herauszufinden, welchen „Leuchtdichtkoeffizienten bei Retroreflexion“  $R_L$  eine Fahrbahnmarkierung mindestens aufweisen muss, damit sie noch von einem Lidar detektiert werden kann, wurden mehrere experimentelle Messungen mit dem in dieser Arbeit verwendeten Laserscanner (Laserscanner 1 aus Abschnitt 6.1.2) durchgeführt. Dieser Messaufbau ermöglicht zwar durch die Wahl eines bestimmten Sensortyps keine allgemeingültige Aussage, jedoch wird angenommen, wenn es einem heute technologisch verfügbarem System gelingt, Markierungen bis zu einem gewissen Schwellwert zu detektieren, dann ist dieses mit zukünftigen Technologien erst recht möglich. Für ein repräsentatives Ergebnis sollte der Messaufbau möglichst einer Messung unter „realen“ Bedingungen entsprechen. Zusätzlich sollte dieser möglichst viele Anforderungen der in Abschnitt 3.1.2 eingeführten Eurogeometrie (Abbildung 3.4) erfüllen, um einen späteren Vergleich mit bestehenden Normen zu ermöglichen. Zusammengefasst bedeutet dies, dass eine Detektion in einer maximalen Entfernung von 30 m bei einem Anleuchtungswinkel von etwa  $1.24^\circ$  erfolgen sollte. Um einen Anleuchtungswinkel von etwa  $1.24^\circ$  bei einer vorgegebenen Anbauhöhe des Laserscanners von 0,3 m zu erreichen, wird die Distanz auf 20 m verkürzt. Abbildung 6.7 verdeutlicht die Geometrie des Messaufbaus.

Letztlich bleibt noch zu klären, welches Material sich für die in Abbildung 6.7 gezeigte Testmarkierung eignet. Um festzustellen bis zu welchem Leuchtdichtkoeffizienten bei Retroreflexion eine Detektion möglich ist, müssen zwei Bedingungen erfüllt werden:

1. Das Material muss selbst bei einem Winkel von etwa  $1.24^\circ$  über retroreflektive Eigenschaften verfügen.
2. Die Retroreflektivität muss stufenweise veränderbar sein.

Nach umfangreicher Recherche konnte außer mit Reflexperlen besetzten temporären Fahrbahnmarkierungen kein weiteres Material identifiziert werden, welches die erste Bedingung erfüllt. Als problematisch erweist sich der extrem flache Winkel, unter dem die Eigenschaft




Abbildung 6.8: Für die Messungen verwendetes Fahrbahnmarkierungsmaterial mit Reflexperlen bei starker Vergrößerung. In (a) eine Markierung in unbehandeltem Zustand. In (b), Markierung mit herabgesetzter Retroreflektivität und in (c) mit noch stärkerer herabgesetzter Retroreflektivität.

der Retroreflexion gefordert wird. Um die zweite Bedingung zu erfüllen, müssen temporäre Markierungen mit diskret abgestuftem Leuchtdichtekoeffizienten bei Retroreflexion hergestellt werden. Alternativ kann die Retroreflexion einer Markierung auch stufenweise herabgesetzt werden, um anschließend durch genormte Messung den Wert für den Leuchtdichtekoeffizienten bei Retroreflexion zu bestimmen. Da eine individuelle Anfertigung von Fahrbahnmarkierungsmaterial sich als zu aufwändig erwies, wird die zweite Variante umgesetzt. Als Ausgangsmaterial für den Messaufbau wurden temporäre Fahrbahnmarkierungen der Firma 3M [3M] verwendet, welche in 3 Prüfstreifen mit jeweils 1.5 m Länge unterteilt wurden. Der erste Prüfstreifen blieb unverändert (Abbildung 6.8(a)). Für den zweiten (Abbildung 6.8(b)) und dritten Prüfstreifen (Abbildung 6.8(c)) wurde nach einer schwarzen Grundierung die Retroreflexion stufenweise durch Applizieren von Klarlack herabgesetzt. Aus Kapitel 3 ist bekannt, dass die Retroreflexion durch einen überdeckenden Wasserfilm stark herabgesetzt wird, da ein Großteil des einfallenden Lichtes bereits oberhalb der Reflexperlen gespiegelt wird. Analog gilt dieses Prinzip auch für Klarlack, welcher den Wasserfilm in gewisser Weise nachbildet.

Die Retroreflexion des zweiten Prüfstreifens (Abbildung 6.8(b)) wird nun soweit herabgesetzt, bis es zu „zyklischen“ Messaussetzern von mindestens einem der 3 möglichen Ziele des Laserscanners kommt<sup>2</sup>. Unter idealen Bedingungen erfolgt in jedem Messzyklus des Scanners eine Detektion von 3 Zielen auf den Prüfstreifen. Kommt es zu temporären Messaussetzern, ist eine Detektion prinzipiell noch möglich, jedoch ist die Anzahl an validen Messpunkten auf der Markierung bereits stark reduziert. Unter ungünstigen Bedingungen wie zum Beispiel bei Vorliegen eines Fahrbahnbelags mit hoher Oberflächenreflektivität, kann eine robuste Detektion von Fahrbahnmarkierungen bereits deutlich erschwert werden.

<sup>2</sup>Der in dieser Arbeit verwendete Laserscanner ist durch Mehrzielfähigkeit in der Lage, bis zu 3 Ziele in einer Messung zu detektieren.



Abbildung 6.9: Handreflectometer ZRM 6013 der Zehntner GmbH [zeh]. Der Leuchtdichtkoeffizient bei Retroreflexion wird innerhalb des Reflectometers durch einen miniaturisierten Eurogeometrieaufbau (Abbildung 3.4) bestimmt.

Für den letzten Prüfstreifen (Abbildung 6.8(c)) wird die Retroreflexion soweit herabgesetzt, bis in keinem Messzyklus mehr eine Detektion stattfindet. Es wird daher angenommen, dass die reflektierte Energie nicht mehr oberhalb des Rauschniveaus liegt und eine solche Markierung von dem Laserscanner nicht mehr detektiert werden kann.

Um den genauen Leuchtdichtkoeffizienten bei Retroreflexion der drei Prüfstreifen zu bestimmen, wurden diese an die Deutsche Studiengesellschaft für Straßenmarkierungen als zertifizierte Prüfstelle weitergereicht. Auf jedem Prüfstreifen wurden mit einem Reflectometer (Abbildung 6.9) fünf Messungen an verschiedenen Stellen durchgeführt.

Der Leuchtdichtkoeffizienten bei Retroreflexion für jeden Prüfstreifen wird anschließend durch eine Mittelwertbildung festgelegt. Tabelle 6.1 fasst die Ergebnisse der Messungen zusammen.

	$R_L$ (mcd/m <sup>2</sup> /lx)		
	Prüfstreifen 1	Prüfstreifen 2	Prüfstreifen 3
Messpunkt 1	350	63	37
Messpunkt 2	376	54	39
Messpunkt 3	410	53	39
Messpunkt 4	418	52	36
Messpunkt 5	410	79	30
$\bar{x}$	<b>393</b>	<b>60</b>	<b>36</b>

Tabelle 6.1: Messergebnisse des „Leuchtdichtkoeffizienten bei Retroreflexion“ für die 3 Testmarkierungen.

Wie erwartet, weist der erste und unbehandelte Prüfstreifen den größten Wert für den Leuchtdichtkoeffizienten bei Retroreflexion ( $R_L$ ) auf. Der zweite Prüfstreifen, bei dem eine Detektion mit vereinzelt Messaussetzern noch möglich war, besitzt einen Wert von 60 mcd/m<sup>2</sup>/lx. Dieser Wert wird als sogenanntes „Sicherheitsniveau“ festgelegt. Besitzt eine Fahrbahnmarkierung im Mittel einen Wert von mehr als 60 mcd/m<sup>2</sup>/lx, ist sehr wahrscheinlich eine sichere Detektion möglich. Der dritte Prüfstreifen weist lediglich noch einen Wert von 36 mcd/m<sup>2</sup>/lx auf. Unterhalb dieses Wertes war eine Detektion mit dem in dieser Arbeit verwendeten Laserscanner nicht mehr möglich. Ein Wert von 36 mcd/m<sup>2</sup>/lx wird

daher als untere „Schranke“ festgelegt.

Ob sich die in diesem Teilabschnitt ermittelten Werte mit eventuell bestehenden Mindestanforderungen an den „Leuchtdichtekoeffizienten bei Retroreflexion“ in der EU und den USA decken, wird in den folgenden zwei Teilabschnitten erarbeitet.

### Abschätzung Europa

Die Mindestanforderungen, die Materialien für Fahrbahnmarkierungen hinsichtlich der Retroreflexion (Abschnitt 3.1.1) in der EU erfüllen müssen, sind in der Norm EN 1436 [din] festgeschrieben. Diese ist dabei so ausgelegt, dass die darin enthaltenen Anforderungen nicht nur bei der Erstellung, sondern hinweg über die gesamte Einsatzdauer einer Markierung Bestand haben müssen. Jedes Mitgliedsland ist weiterhin verpflichtet, die europäische Norm durch Überführung in eine nationale Norm und darauf aufbauend in eine nationale Verwaltungsvorschrift rechtskräftig umzusetzen. Weisen alle nationalen Verwaltungsvorschriften in der EU einen größeren Wert für den Leuchtdichtekoeffizienten bei Retroreflexion auf als der, der in dem vorherigen Abschnitt experimentell als untere Schranke bestimmt wurde, ist eine flächendeckende Verfügbarkeit einer lidarbasierten Fahrstreifenerkennung prinzipiell gegeben.

Dieser etwas abstrakte Zusammenhang soll an dem Beispiel von Fahrbahnmarkierungen in der Bundesrepublik Deutschland zunächst verdeutlicht werden (Abbildung 6.10). Eine europäische Norm wird zunächst in eine DIN Norm überführt. Auf Basis dieser wird anschließend eine rechtskräftige Verwaltungsvorschrift (Richtlinie) abgeleitet. Betrachtet man im Detail die Anforderung an die Nachsichtbarkeit von permanenten Fahrbahnmarkierungen, so ist diese in der Bundesrepublik durch die BASt (Bundesanstalt für Straßenwesen) in der Richtlinie ZTV M 02 „Zusätzliche Technische Vertragsbedingungen und Richtlinien für Markierungen auf Straßen“ geregelt [bas]. So ist beispielsweise in der Richtlinie ZTV M 02 für den „Leuchtdichtekoeffizienten bei Retroreflexion“ festgelegt, dass dieser bei trockener Fahrbahn mindestens  $150 \text{ mcd/m}^2/\text{lx}$  aufweisen muss. Der wesentliche Unterschied




Abbildung 6.10: Überführung von europäischen Normen (EN) in DIN Normen und Ableiten nationaler Verwaltungsvorschriften.

zwischen einer europäischen Norm und einer daraus abgeleiteten Verwaltungsvorschrift besteht darin, dass die zugrunde liegende Norm eine Menge von möglichen Standards, die Verwaltungsvorschrift hingegen genau einen Standard repräsentiert.

Art und Farbe der Markierung		Klasse	$R_L$ (mcd/m <sup>2</sup> /lx)
dauerhaft	weiß	R0	Keine Anforderung
		R2	$\geq 100$
		R3	$\geq 150$
		R4	$\geq 200$
		R5	$\geq 300$
dauerhaft	gelb	R0	Keine Anforderung
		R1	$\geq 80$
		R3	$\geq 150$
		R4	$\geq 200$
temporär	gelb	R0	Keine Anforderung
		R3	$\geq 150$
		R5	$\geq 300$

Tabelle 6.2: Nachsichtbarkeitsklassen trocken nach EN 1436 [din].

Um eine Standardisierung von Mindestanforderungen bezüglich der Retroreflexion von Fahrbahnmarkierungen zu ermöglichen, wurde in der betreffenden EU Norm (EN-1436) eine Einteilung in Reflexionsklassen vorgenommen (Tabelle 6.2). Markierungen müssen mindestens den in einer Klasse vorgeschriebenen Wert für  $R_L$  erfüllen, um dieser Klasse zugeordnet werden zu dürfen.

Aus Tabelle 6.2 wird ersichtlich, dass die zur Auswahl stehenden Retroreflexionsklassen eine große Spanne an möglichen Mindestanforderungen abdecken. Der ungünstigste Fall aus Sicht einer lidarbasierten Fahrstreifenenerkennung ist die Klasse R0. Hier sind keine Eigenschaften festgelegt und demnach wäre es bei Vorliegen von R0 nicht möglich, eine theoretische Abschätzung der Verfügbarkeit durchzuführen. Wie aus dem vorherigen Abschnitt bereits bekannt ist, liegt die untere Schranke für einen heutigen automotiven Laser-scanner bei etwa 36 mcd/m<sup>2</sup>/lx. Alle Klassen ab R1 erfüllen somit die Anforderung an den „Leuchtdichtkoeffizienten bei Retroreflexion“ aus Sicht einer lidarbasierten Fahrstreifenenerkennung. Das Vorliegen der Klasse R0 erfordert es jedoch, eine separate Betrachtung durchzuführen. Tabelle 6.3 fasst die jeweiligen Retroreflexionsklassen für eine Auswahl von 16 EU Mitgliedsstaaten zusammen. In allen Staaten wurde mindestens die Klasse R2 ( $R_L \geq 100$  mcd/m<sup>2</sup>/lx) festgelegt.

Zusammenfassend lässt sich sagen, dass in allen betrachteten Staaten der „Leuchtdichtkoeffizienten bei Retroreflexion“ über einem Wert von 100 mcd/m<sup>2</sup>/lx liegen muss. Dies bedeutet, dass es für einen heutigen automotiven Lidar im Bereich des technisch Machbaren ist, Fahrbahnmarkierungen bei trockener Fahrbahn mit einer hohen Verfügbarkeit zu erfassen.

## Ausblick USA

Eine Abschätzung der Verfügbarkeit in den USA gestaltet sich wesentlich schwieriger als in der EU. Im Gegensatz zur europäischen Union existiert in den USA keine einheitliche

Land	Belgien	Deutschland	Dänemark	Finnland	Frankreich	Großbritannien	Italien*	Niederlande	Norwegen**	Österreich	Portugal	Schweden	Schweiz***	Slowakei	Spanien	Tschechien
Klasse	R2	R3	R2 R3 R4	R2	R3	R2	R2	R2	R2	R2	R4	R2	R4	R2	R2 R3 R4	R2
*)	Keine einheitliche Vorschrift.															
**)	Zweifarbensystem: Mittelmarkierung erfolgt in gelb.															
***)	Die aufgeführten Anforderungen sind vorgesehen.															

Tabelle 6.3: Anforderungen an die Nachtsichtbarkeit von Fahrbahnmarkierungen in Europa [Die07].

Mindestanforderung an die Eigenschaften von Fahrbahnmarkierungen. Das zuständige von der „Federal Highway Administration“ (FHWA) erstellte Regelwerk „Manual on Uniform Traffic Control Devices“ (MUTCD) [U.S09] enthält lediglich einen leeren Eintrag, der in einer geplanten Überarbeitung ausgearbeitet wird [U.S07]. So heißt es in dem betreffenden Kapitel 3 Abschnitt 3A.03 „Maintaining Minimum Pavement Marking Retroreflectivity“: „*This Section is reserved for future text based on FHWA rulemaking.*“.

Letztlich kann nur vermutet werden, welchen Standard die Federal Highway Administration bei einer Überarbeitung des MUTCD festlegen wird. Um dennoch einen Ausblick zu ermöglichen, werden die abschließenden Ergebnisse eines Forschungsberichtes der FHWA aus dem Jahr 2007 zitiert [U.S07], in welchem eine direkte Empfehlung für die anstehende Überarbeitung des MUTCD festgehalten ist. Tabelle 6.4 fasst die Empfehlungen des Forschungsberichtes in Abhängigkeit der Geschwindigkeit in Meilen pro Stunde zusammen.

Geschwindigkeit	$R_L$ (mcd/m <sup>2</sup> /lx)			
	ohne RRPMS			mit RRPMS
	≤50 mi/h	55-65 mi/h	≥70 mi/h	≥0 mi/h
Vollständig markierte Straßen	40	60	90	40
Nur Mittelmarkierung	90	250	575	50

Tabelle 6.4: Empfehlungen für  $R_L$  in Abhängigkeit der zulässigen Höchstgeschwindigkeit [U.S07].

Zusätzlich erschwerend erweist sich die Tatsache, dass in den USA neben Fahrbahnmarkierungen in Form von Farbe noch weitere Markierungssysteme zugelassen sind. Ein Beispiel hierfür sind sogenannte „Retroreflective Raised Pavement Markers“ (RRPMS) oder




Abbildung 6.11: Ein RPM ohne retroreflektive Eigenschaften in (a) und in (b) ein RRPM mit integriertem Retroreflektor [rpm09].

„Botts’ dots“ (RPMs). Die Abbildungen 6.11(a) und 6.11(b) zeigen jeweils ein Beispiel für ein RPM und RRPM. Anders als bei Fahrbahnmarkierungen, handelt es sich bei diesen Markierungssystemen um relativ kleine Punktziele. Zwar verfügen zumindest auch RRPM’s über retroreflektive Eigenschaften, so dass sie mit einem lidarbasierten System mit großer Wahrscheinlichkeit auch erfasst werden könnten, eine Evaluierung im Rahmen dieser Arbeit ist jedoch nicht möglich.

Zusammenfassend lässt sich für die USA festhalten, dass, falls die Empfehlungen aus dem Jahr 2007 für  $R_L$  übernommen werden sollten, zumindest eine Detektion auf Straßen mit Geschwindigkeiten  $\geq 55$  mi/h (Highway und Freeway) möglich wäre. Genauer zu betrachten bleiben allerdings Straßenabschnitte auf denen RPMs oder RRPMs zum Einsatz kommen.

### Verfügbarkeit bei nasser Fahrbahn

Wie in Abschnitt 3.1.3 erläutert, kann prinzipiell zwischen zwei verschiedenen Typen von Markierungen unterschieden werden: Standardmarkierungen (Typ-I) und Markierungen mit erhöhter Retroreflexion bei Nässe (Typ-II). Die Problematik gewöhnlicher Markierungen ist, dass sich bei nasser Fahrbahnoberfläche ein Wasserfilm auf der Markierungsfläche bildet, wodurch die Retroreflexion extrem herabgesetzt wird (Abbildung 3.6). Je nach Stärke des überdeckenden Wasserfilms, führt dies im ungünstigsten Fall zu einer totalen Spiegelung des Laserlichts. Dies hat zur Folge, dass eine Detektion praktisch nicht mehr möglich ist.

Bereits an dieser Stelle sei gesagt, dass für Typ-I Markierungen bei nasser Fahrbahn keine Mindestanforderungen an den „Leuchtdichtekoeffizienten bei Retroreflexion“ gestellt werden [Die07]. Eine theoretische Abschätzung der Verfügbarkeit auf Straßenabschnitten mit Typ-I ist somit nicht möglich. Betrachtet man zudem die USA, so finden sich in dem bereits zuvor erwähnten Bericht der FHWA [U.S07], in dem die Forschungsaktivitäten bezüglich der Anforderungen an Fahrbahnmarkierungen zusammengefasst wurden, keine Hinweise auf eine mögliche Unterscheidung zwischen trockener und nasser Fahrbahn.

Art der Markierung	Klasse	$R_L$ (mcd/m <sup>2</sup> /lx)
dauerhaft	RW0	Keine Anforderung
	RW1	$\geq 25$
	RW2	$\geq 35$
	RW3	$\geq 50$
	RW4	$\geq 75$

Tabelle 6.5: Nachtsichtbarkeitsklassen bei Nässe nach EN 1436 [din].

Um dennoch die Verfügbarkeit innerhalb der EU bei Abschnitten mit Typ-II Markierungen abzuschätzen, erfolgt eine gesonderte Betrachtung der Norm EN 1436 mit dem Fokus auf die Nachtsichtbarkeit bei Nässe.

Für die EU erfolgt wie bei trockener Fahrbahn eine Einteilung in sogenannte Reflexionsklassen. Tabelle 6.5 zeigt die Klassen RW0 bis RW5 mit ihren dazugehörigem  $R_L$ . Bereits hier wird deutlich, dass sich diese in ihrer Mindestanforderung von den Klassen bei trockener Fahrbahn erheblich unterscheiden. Legt man die zuvor experimentell bestimmte untere Schranke zu Grunde, erfüllen lediglich die Klassen RW3 und RW4 die gesetzte Mindestanforderung von 36.2 mcd/m<sup>2</sup>/lx. Tabelle 6.6 zeigt analog die festgelegten Standards für RW in 16 Mitgliedsstaaten der EU. Lediglich Großbritannien und die Schweiz besitzen mit RW3 und RW4 eine ausreichende Mindestanforderung. In allen anderen Staaten existieren entweder gar keine Anforderungen oder diese sind, wie beispielsweise auch in Deutschland, zu gering. Zwar liegen diese mit zum Teil RW2 in unmittelbarer Nähe von 36.2 mcd/m<sup>2</sup>/lx, jedoch kann daraus allenfalls auf eine Verfügbarkeit mit starken Einschränkungen geschlossen werden.

Festzuhalten bleibt, dass eine nasse Fahrbahnoberfläche keines Falls zu vernachlässigen ist. Eine allgemeine Aussage über die Verfügbarkeit ist durch die Existenz von Typ-I Markierungen nicht möglich. Selbst in Staaten, in denen ausreichende Mindestanforderungen für Typ-II Markierungen existieren, liegen diese teilweise in unmittelbarer Nähe zu der zuvor experimentell bestimmten unteren Schranke für  $R_L$ . Betrachtet man zusätzliche negative Einflüsse wie beispielsweise die partielle Verschmutzung einzelner Markierungen, kann bei nasser Fahrbahn auch auf Straßenabschnitten mit Typ-II Markierungen nicht mit einer zuverlässigen Erkennung gerechnet werden.

### 6.3.2 Bewertung der Genauigkeit mit DGPS und einer hochgenauen digitalen Karte

Soll die Abweichung eines geschätzten Zustands zu einem wahren Zustand bestimmt werden (6.6), stellt sich bei der Bewertung von Algorithmen, die auf Eingabedaten von fahrumfelderfassenden Sensoren basieren, zuerst die Frage nach einem geeigneten Referenzsystem. Diese Problematik wurde in Abschnitt 6.2 bereits aufgegriffen und eine auf DGPS und hochgenauen digitalen Karten basierte Lösung vorgestellt.

Bei der Evaluierung eines Systems zur Erkennung von Fahrbahnmarkierungen ergibt sich zusätzlich das Problem, dass keine Referenzstrecke mit ausreichender Länge und Ge-

Land	Belgien	Deutschland	Dänemark	Finnland	Frankreich	Großbritannien	Italien	Niederlande	Norwegen	Österreich	Portugal	Schweden	Schweiz*	Slowakei	Spanien	Tschechien
Klasse (RW)	-	2	-	-	-	3	-	0	-	2	0	-	4	0	0	-

\*) Die aufgeführten Anforderungen sind vorgesehen.

Tabelle 6.6: Anforderungen an die Nachsichtbarkeit von Fahrbahnmarkierungen in Europa bei nasser Fahrbahn [Die07].

naugigkeit verfügbar ist. Die hochgenaue Kartierung eines Straßenabschnitts im öffentlichen Straßennetz mit dem in Abschnitt 6.2 vorgestellten Systems ist praktisch ausgeschlossen. Für die Evaluierung wird deshalb in dieser Arbeit ein digitalisierter Streckenabschnitt auf einem BMW Testgelände verwendet. Der Streckenverlauf wurde zuerst digital entworfen (*top-down* Entwurfsmethode). Anschließend wurden die Fahrbahnmarkierungen auf Basis der Karteninformationen mit Hilfe des DGPS Referenzsystems aus Abschnitt 6.2 auf der Strecke appliziert. Abbildung 6.12 zeigt den für die Evaluierung verwendeten Streckenverlauf. Abbildung 6.13 zeigt zusätzlich exemplarisch ein Bild des Testgeländes mit den darauf




Abbildung 6.12: Streckenverlauf der für die Evaluierung verwendeten Teststrecke. Die Strecke verfügt über 7 Geradensegmente, 6 Übergangsegmente mit linearem Krümmungsanstieg (Klothoidensegmente) und 6 Segmente mit einem konstanten Radius von 1000 m.

applizierten Fahrbahnmarkierungen. Die Strecke verfügt über insgesamt zwei Fahrstreifen mit identischer Fahrstreifenbreite. Die mittlere Fahrbahnmarkierung wurde als *gestrichel-*




Abbildung 6.13: Referenzstrecke zur Evaluierung der Fahrstreifenerkennung. Die Positionen der Fahrbahnmarkierungen wurden mit einem DGPS System vermessen.

te Markierung ausgeführt. Mit Hilfe der digitalisierten Referenzstrecke, kann anschließend der Zustandsvektor  $\mathbf{x}$  aus der *Pose* des Eigenfahrzeugs in Relation zu den Kartendaten berechnet werden. Der Fehler der Zustandsschätzung  $\tilde{\mathbf{x}}$  ergibt sich dabei unmittelbar aus dem wirklichen Zustand  $\mathbf{x}$  und dem geschätzten Zustand  $\hat{\mathbf{x}}$ .

$$\tilde{\mathbf{x}} \equiv \hat{\mathbf{x}} - \mathbf{x} \quad (6.6)$$

Zur Bewertung des Schätzfehlers lassen sich unterschiedliche Fehlermetriken heranziehen. Drei dieser Messgrößen sollen kurz vorgestellt werden: der durchschnittliche Fehler einer Stichprobe  $\mu_{\tilde{\mathbf{x}}}$  (6.7), die Standardabweichung einer Stichprobe  $s_{\tilde{\mathbf{x}}}$  (6.8) und die mittlere quadratische Abweichung RMSE<sup>3</sup> (6.8). Der durchschnittliche Fehler gibt Aufschluss über den systematischen Schätzfehler, die Standardabweichung beschreibt die Schwankungsbreite der Stichprobe und der Quadratische-Mittelwertfehler als Kombination beider Fehlermetriken vereint sowohl die Schwankungsbreite als auch den systematischen Schätzfehler.

$$\mu_{\tilde{\mathbf{x}}} = \frac{1}{N} \sum_{k=1}^N \tilde{\mathbf{x}}(k) \quad (6.7)$$

$$\sigma_{\tilde{\mathbf{x}}} = \sqrt{\frac{1}{N-1} \sum_{k=1}^N (\tilde{\mathbf{x}}(k) - \mu_{\tilde{\mathbf{x}}})^2} \quad (6.8)$$

$$\text{RMSE} = \sqrt{\mu_{\tilde{\mathbf{x}}}^2 + \sigma_{\tilde{\mathbf{x}}}^2} \quad (6.9)$$

Im Folgenden werden die oben aufgeführten Fehlermetriken für die Krümmung  $c$ , den Kurswinkel  $\psi$  und die Ablage  $y$  im eigenen Fahrstreifen ausgewertet. Die Testfahrt erfolgte mit einer konstanten Geschwindigkeit von 100 km/h. Die Abbildungen 6.14 bis 6.16 zeigen die geschätzten Parameter Ablage, Kurswinkel und Krümmung im Vergleich zu der auf

<sup>3</sup>engl. root mean square error.




Abbildung 6.14: Vergleich der Ablage  $y$  zu der auf DGPS und einer hochgenauen digitalen Karten basierten Referenz.

	Fehlerabschätzung Lidar			Gesetzte Anforderungen		
	$y$ (m)	$\psi$ ( $^\circ$ )	$c$ ( $\text{m}^{-1}$ )	$y$ (m)	$\psi$ ( $^\circ$ )	$c$ ( $\text{m}^{-1}$ )
$\mu_{\tilde{\mathbf{x}}}$	-0.00	-0.01	$0.006 \times 10^{-3}$	-	-	-
$\sigma_{\tilde{\mathbf{x}}}$	0.03	0.06	$0.119 \times 10^{-3}$	0.2	0.25	$0.3 \times 10^{-3}$
RMSE	0.03	0.06	$0.119 \times 10^{-3}$	-	-	-

Tabelle 6.7: Fehlerauswertung der lidarbasierten Fahrstreifenenerkennung im Vergleich zu den in Kapitel 1.2.2 definierten Anforderungen an die Genauigkeit.

DGPS und einer hochgenauen digitalen Karte basierten Referenz.

Bei einer Abtastfrequenz von 12.5 Hz und einer Streckenlänge von etwa 2000 m stehen für jeden Parameter 906 Stichproben für eine Fehlerabschätzung zur Verfügung. In jedem Zeitschritt  $k$  werden hierzu die durch das iterative histogrammbasierte Verfahren geschätzten Größen für die Ablage  $y$ , den Kurswinkel  $\psi$  und die Krümmung  $c$  mit der Referenz verglichen und der jeweilige Schätzfehler  $\tilde{\mathbf{x}}(k)$  berechnet. Tabelle 6.7 zeigt die ausgewerteten Fehlergrößen für das in Abschnitt 3.4.3 vorgestellte Verfahren zur Fahrstreifenschätzung. Als Eingabe für die Erstellung der Belegungskarte diente der unter Abschnitt 6.1.2 aufgeführte mehrzeilige Laserscanner, welcher im Bereich der Frontstoßstange verbaut ist. Die Zellgröße wurde für die durchgeführte Auswertung auf 0.18 m und die Größe auf  $330 \times 330$  Zellen festgelegt. Der als „Historie“ zur Verfügung stehende Teil wurde auf 110 Zellen konfiguriert. Eine genaue Erklärung zu der Aufteilung einer quadratischen Belegungskarte in einen „vorderen“ und „hinteren“ Teil kann in Kapitel 2.4.3 gefunden werden.




Abbildung 6.15: Vergleich des Kurswinkels  $\psi$  zu der auf DGPS und einer hochgenauen digitalen Karten basierten Referenz.




Abbildung 6.16: Vergleich der Krümmung  $c$  zu der auf DGPS und einer hochgenauen digitalen Karten basierten Referenz.

**Diskussion der Ergebnisse.** Im Folgenden werden die durch die histogrammbasierte Fahrstreifenschätzung erzielten Ergebnisse mit Blick auf eine automatisierte Querführung diskutiert. Als Vergleich dienen die in Kapitel 1.2 festgelegten Grenzen für die drei Regelgrößen Ablage, Kurswinkel und Krümmung. Zuerst wird der durchschnittliche Fehler  $\mu_{\bar{x}}$  der Stichprobe betrachtet. Für alle drei Regelgrößen lässt sich konstatieren, dass der durchschnittliche Fehler in Relation zu den festgelegten Obergrenzen äußerst gering ist. Hieraus

lassen sich zwei Schlussfolgerungen ableiten. Erstens, die für die Auswertung verwendete Kalibrierung der Sensoren war äußerst akkurat. Eine Beeinträchtigung der Ergebnisse durch Fehler, die auf eine unzureichende Sensorkalibrierung zurückzuführen sind, kann daher ausgeschlossen werden. Zweitens, die auf der Belegungskarte aufbauende Parameterextraktion ist ebenfalls nicht durch einen systematischen Fehler beeinträchtigt.

Betrachtet werden im Weiteren die Standardabweichung  $\sigma_{\bar{x}}$  und der mittlere quadratische Fehler RMSE. Eine separate Betrachtung beider Größen ist nicht erforderlich, da der durchschnittliche Fehler zu vernachlässigen ist. Vergleicht man die durch das histogrammbasierte Verfahren erreichte Standardabweichung der drei Regelgrößen  $y$ ,  $\psi$  und  $c$  mit den in Kapitel 1.2 gesetzten Mindestanforderungen an die Genauigkeit ist zu erkennen, dass diese nicht nur erfüllt, sondern übertroffen werden konnten. Die auf der Teststrecke erzielte Genauigkeit in der Ablage übertrifft mit einer ermittelten Standardabweichung von lediglich 0.03 m die Mindestanforderung von einem mittleren Fehler von 0.2 m den Faktor 6-7.

Zusammenfassend lässt sich sagen, dass eine auf einem automotiven Laserscanner basierte Fahrstreifenenerkennung die für eine automatisierte Querführung benötigten Regelgrößen in ausreichender Genauigkeit zur Verfügung stellen kann. Zwar ist im realen Straßenverkehr durchaus mit Zusatzeffekten wie beispielsweise durch den Fahrbahnbelag erzeugtem Messrauschen zu rechnen, jedoch ist es unwahrscheinlich, dass diese das Resultat in einer Weise negativ beeinträchtigen, dass die Mindestanforderungen dauerhaft unterschritten werden.

### 6.3.3 Evaluierung der Verfügbarkeit

Die Verfügbarkeit der lidarbasierten Fahrstreifenenerkennung wird anhand mehrerer Messfahrten evaluiert, die auf Autobahnabschnitten im Großraum München aufgezeichnet wurden. Im Gegensatz zu der in Abschnitt 6.3.1 vorgenommenen theoretischen Abschätzung zu der Verfügbarkeit einer lidarbasierten Fahrstreifenenerkennung im Allgemeinen, gibt dieser Abschnitt Aufschluss über die zeitliche Verfügbarkeit des in Kapitel 3.4.3 vorgestellten Verfahrens zur Extraktion von Fahrbahnmarkierungen. Neben den reinen retroreflektiven Mindestanforderungen die Fahrbahnmarkierungsmaterialien für eine erfolgreiche Detektion erfüllen müssen, werden zusätzliche negative Einflüsse wie beispielsweise durch Bodenreflexionen erzeugtes Messrauschen oder die Verdeckung der Markierungen durch andere Verkehrsteilnehmer auf die Erkennungsrate sichtbar.

Tabelle B.1 zeigt eine Übersicht über die für die Evaluierung verwendeten Straßenabschnitte. Es wurde versucht, ein breites Spektrum an unterschiedlichen Situationen (wechselnder Fahrbahnbelag und Verkehrsdichte) mit einzubeziehen, um ein möglichst repräsentatives Ergebnis zu erzielen.

Alle Testszene wurden bei trockener Fahrbahn und Tageslicht aufgezeichnet. Die Szenenauswahl beinhaltet zudem unterschiedliche Beleuchtungsverhältnisse wie beispielsweise künstliche Beleuchtung in Tunnelsegmenten. Die Anzahl an gültigen Fahrstreifen (keine Beschleunigungs- oder Verzögerungsstreifen) variiert je nach Abschnitt zwischen zwei und vier Fahrstreifen. Auf jedem Streckenabschnitt wurden mehrere Fahrstreifenwechsel durchgeführt und die einzelnen Fahrstreifen mehrheitlich zu gleichen Anteilen befahren.

Sondersituationen wie beispielsweise Baustellen wurden nicht betrachtet. Alle untersuchten Streckenabschnitte wiesen zudem gültige und im visuellen Spektrum sichtbare Fahrbahnmarkierungen auf. Insgesamt wurde eine Strecke von 104.65 km betrachtet. Eine detaillierte Streckengliederung der für die Evaluierung der Verfügbarkeit betrachteten Straßenabschnitte ist in Tabelle B.1 zu finden.

### Verfügbarkeit des eigenen Fahrstreifens

Betrachtet wird zunächst die Verfügbarkeit der allgemeinen Straßenparameter Krümmung und Kurswinkel sowie der Ablage im eigenen Fahrstreifen, die sich unmittelbar aus der linken und rechten Markierung ableitet. Die Verfügbarkeit wird so definiert, dass der Abstand zur linken und rechten Markierung, der allgemeine Kurswinkel und die Fahrbahnkrümmung zur Verfügung stehen müssen. Sind diese Werte gegeben lässt sich prinzipiell eine Querführung im eigenen Fahrstreifen durchführen. Ist zu einem Zeitpunkt einer der Werte nicht ermittelbar, wird für diesen Zeitschritt die Fahrstreifeninformation als nicht verfügbar gewertet. Da die Zykluszeit des Frameworks 80 ms beträgt, vermindert sich die Verfügbarkeit der Fahrstreifenerkennung in jedem Zyklus um dieses Intervall.

In Tabelle 6.8 sind die Ergebnisse der Auswertung zusammengefasst. Eine detaillierte Auflistung der Verfügbarkeit innerhalb der einzelnen Testabschnitte ist in Tabelle B.2 zu finden. Die prozentuale Verfügbarkeit wurde über die Dauer der Verfügbarkeit und der Gesamtzeit der jeweiligen Szene errechnet. Es handelt sich hierbei demnach um eine zeitliche Verfügbarkeit. Da bei den Messfahrten meist mit einer konstanten Geschwindigkeit von etwa 120 km/h gefahren wurde, differiert die örtliche Verfügbarkeit kaum von der zeitlichen.

Strecke in km	Dauer in s	Verfügbarkeit	
		in s	in %
104.65	3232.1	3191.8	<b>98.76</b>

Tabelle 6.8: Verfügbarkeit des eigenen Fahrstreifens (Abstand zur linken und rechten Markierung, Kurswinkel und Krümmung).

Insgesamt wurde eine Streckenlänge von 104.65 km betrachtet, welche in 53 Minuten und 52 Sekunden durchfahren wurden. Die lidarbasierte Fahrstreifenerkennung erreicht eine Verfügbarkeit von 98.76%. In 1.24% der Zeit standen somit keine Informationen über beide zu einem Fahrstreifen gehörenden Fahrbahnmarkierungen zur Verfügung. Die Ausfälle können im Wesentlichen auf zwei Ursachen zurückgeführt werden: die Verdeckung einer Fahrbahnmarkierung durch einscherende Fahrzeuge benachbarter Fahrstreifen oder eine durch mögliche Verschmutzung hervorgerufene niedrige Retroreflexion der Fahrbahnmarkierungen bei gleichzeitiger hoher Reflektivität der Fahrbahnoberfläche (additives Rauschen). Betrachtet man die Tatsache, dass dieses Ergebnis unter realen Verkehrsbedingungen erzielt wurde, kann von einem äußerst vielversprechenden Ergebnis mit Bezug auf eine mögliche Querführungsunterstützung durch ein lidarbasiertes System ausgegangen werden.

Ob dieses Ergebnis ausreicht, um einen zusätzlichen Nutzen zu einer rein kamerabasierten Fahrstreifenerkennung zu bieten, wird in Abschnitt 6.4.4 genauer untersucht.

### Verfügbarkeit aller Fahrstreifen

Um die genaue Position des Fahrzeugs auf der Straße bestimmen zu können, muss die relative Lage aller existierenden Fahrstreifen hinreichend bekannt sein. Wird diese für eine Querführung innerhalb des eigenen Fahrstreifens nicht benötigt, ist diese jedoch von Bedeutung für eine allgemeine Positionsbestimmung auf der Fahrbahn, welche als Grundlage für hochautomatisierte Fahrmanöver dient. Ein Beispiel für ein solches Manöver ist ein Fahrstreifenwechsel innerhalb des Nothaltemanövers des von der BMW Group Forschung und Technik entwickelten Nothalteassistenten (siehe Kapitel 1.1.2).

Im Folgenden wird die durch die lidarbasierte Fahrstreifenerkennung erkannte Anzahl und Position aller Fahrstreifen evaluiert. Als zusätzliche Eingabe für den Algorithmus zur Fahrstreifenerkennung diente die Anzahl an existierenden Fahrstreifen aus einer im Fahrzeug verfügbaren Standardnavigationkarte als Begrenzung für die maximale Anzahl zu detektierender Fahrstreifen. Zusätzlich wird überprüft, ob die Position eines ausgegebenen Fahrstreifens mit der in einem Videobild sichtbaren Position des Fahrstreifens übereinstimmt. So kann verhindert werden, dass die erkannte Anzahl der Fahrstreifen zwar richtig, die detektierte Position allerdings falsch ist. Darüber hinaus werden erkannte Auf- und Abfahrten von Autobahnen, welche im übertragenen Sinne gültige Fahrstreifen darstellen, aus der Bewertung ausgeschlossen. Betrachtet werden wieder Szenarien aus Tabelle B.1. Die Zusammenfassung der Ergebnisse der Auswertung sind in Tabelle 6.9 und die detaillierte Auswertung in Tabelle B.3 zu finden.

Strecke in km	Dauer in s	Weniger Fahrstreifen detektiert		Alle Fahrstreifen detektiert	
		in s	in %	in s	in %
104.65	3232.1	64.98	<b>2.0</b>	3166.2	<b>98.0</b>

Tabelle 6.9: Verfügbarkeit der vollständigen Anzahl an Fahrstreifen.

Die Verfügbarkeit aller auf einem Straßenabschnitt existierender Fahrstreifen ist mit 98% etwas schlechter als die des eigenen Fahrstreifens mit 98.76%. In 2% standen weniger oder keine Informationen über die Anzahl und Position der Fahrstreifen zur Verfügung. Wie erwartet reduziert sich die Verfügbarkeit bei der Betrachtung benachbarter Fahrstreifen. Berücksichtigt man die Tatsache, dass zeitweise bis zu vier Fahrstreifen trotz möglicher Verdeckungen durch andere Verkehrsteilnehmer detektiert werden mussten, ist eine Detektionsrate von 98% als sehr akzeptabel zu betrachten. Die primären Ursachen für eine nicht erfolgte Detektion sind eine reduzierte Retroreflexion einzelner Fahrbahnmarkierungen bei gleichzeitiger hoher Reflektivität der Fahrbahnoberfläche oder die Verdeckung benachbarter Fahrbahnmarkierungen durch andere Verkehrsteilnehmer.

### 6.3.4 Einfluss der Zellgröße einer Belegungskarte auf die histogrammbasierte Fahrstreifenschätzung

In Abschnitt 6.3.2 wurde die erzielbare Genauigkeit der lidarbasierten Fahrstreifenschätzung auf einer Referenzstrecke untersucht. Die dabei erzielten Ergebnisse (siehe Tabelle 6.7) sind eng mit vorher festgelegten Rahmenbedingungen verbunden. Eine wichtige Rahmenbedingung ist die Wahl der Zellgröße einer Belegungskarte auf der die histogrammbasierte Parameterschätzung operiert. Es wird erwartet, dass mit abnehmender Zellgröße die Genauigkeit zunimmt. Im Gegensatz dazu, steigt – bei gleich bleibender Größe der Belegungskarte im Metern – bei einer zunehmenden Anzahl an Zellen die Komplexität und mit ihr die benötigte Rechenzeit.

Ziel dieses Abschnitts ist es daher herauszufinden, welche Zellgröße einen guten Kompromiss zwischen der Genauigkeit und der benötigten Rechenzeit darstellt. Dies kann analog als Kosten zu Nutzen Abschätzung angesehen werden, wobei der Nutzen die Genauigkeit und die Kosten die Rechenzeit sind.

#### Untersuchung der erzielbaren Genauigkeit in Abhängigkeit der Zellgröße

Zuerst wird der Einfluss variierender Zellgrößen auf die Genauigkeit der drei Größen Ablage, Kurswinkel und Krümmung untersucht. Die Gesamtgröße der Belegungskarte richtet sich dabei nach der in Abschnitt 6.3.2 festgelegten Größe von 60 m mit einer „Historie“ von 20 m. Betrachtet werden die Zellgrößen 0.1 m, 0.15 m, 0.2 m und 0.25 m. Die durchgeführte Testfahrt gleicht Abschnitt 6.3.2. Tabelle 6.10 fasst die erzielten Ergebnisse in Form der Standardabweichung zusammen.

Zellgröße	$\sigma_{\bar{x}}$		
	$y$ (m)	$\psi$ (°)	$c$ (m <sup>-1</sup> )
0.1 m	0.03	0.06	$0.11 \times 10^{-3}$
0.15 m	0.03	0.07	$0.116 \times 10^{-3}$
0.2 m	0.03	0.07	$0.122 \times 10^{-3}$
0.25 m	0.05	0.08	$0.135 \times 10^{-3}$

Tabelle 6.10: Auswertung der Standardabweichung im Vergleich zur Referenz.

Um zudem einen besseren visuellen Vergleich der Ergebnisse zu ermöglichen, wurde für jede der Abbildungen 6.14 bis 6.16 ein repräsentativer kurzer zeitlicher Abschnitt ausgewählt und vergrößert. Die Abbildungen 6.17 bis 6.19 zeigen jeweils einen vergrößerten Ausschnitt für die Ablage, den Kurswinkel und die Krümmung.

#### Laufzeitanalyse

Bevor in dem folgenden Unterabschnitt die Ergebnisse diskutiert werden können, muss zunächst die Laufzeit der Fahrstreifenschätzung in Abhängigkeit der jeweiligen Zellgröße




Abbildung 6.17: Exemplarisch vergrößerter Ausschnitt aus Abbildung 6.14 für den lokalen Vergleich der Ablage bei einer Zellgröße von 0.1 m, 0.15 m, 0.2 m und 0.25 m.




Abbildung 6.18: Exemplarisch vergrößerter Ausschnitt aus Abbildung 6.15 für den lokalen Vergleich des Kurswinkels bei einer Zellgröße von 0.1 m, 0.15 m, 0.2 m und 0.25 m.

erfolgen. Hierzu wird die auf dem bereits festgelegten Referenzsystem benötigte Rechenzeit für die histogrammbasierte Schätzung der Fahrstreifenparameter (siehe Kapitel 3.4) ermittelt. Da das vorgestellte Verfahren in der Laufzeit nahezu unabhängig von der vorliegenden Anzahl an Fahrstreifen ist, besitzt die auf der Teststrecke durchgeführte Evaluierung der




Abbildung 6.19: Exemplarisch vergrößerter Ausschnitt aus Abbildung 6.16 für den lokalen Vergleich der Krümmung bei einer Zellgröße von 0.1 m, 0.15 m, 0.2 m und 0.25 m.

Laufzeit allgemeine Gültigkeit. Es soll an dieser Stelle noch einmal explizit darauf hingewiesen werden, dass in diesem Abschnitt lediglich die Laufzeit der Parameterschätzung bei variierender Zellgröße betrachtet wird. Die Betrachtung der Komplexität bei der Erstellung einer Belegungskarte in Abhängigkeit zu der Gesamtanzahl an Zellen erfolgt gesondert in Abschnitt 6.6. Abbildung 6.20 zeigt die Auswertung der durchschnittlichen Laufzeit für die vier Belegungskarten mit unterschiedlicher Zellgröße. Die durchschnittliche Laufzeit wurde durch Mittlung aller zyklischer Laufzeiten der Algorithmik, welche die Schätzung der Krümmung und des Kurswinkels, die Extraktion möglicher Markierungen, Sub-Pixel Interpolation und die Klassifikation beinhaltet, berechnet. Da es bei einer festgelegten Größe der Belegungskarte von 60 m je nach Zellgröße zu Rundungen in der Anzahl an Zellen kommen kann, ist diese zusätzlich aufgeführt.

## Diskussion

Betrachtet werden zunächst die erzielten Genauigkeiten bei variierender Zellgröße. Vergleicht man exemplarisch die Genauigkeiten in der Ablage  $y$  aus Tabelle 6.10, so wird schnell deutlich, dass die Genauigkeit nicht linear mit der Zellgröße skaliert und durch diese auch nicht direkt begrenzt ist. Zwischen beispielsweise der kleinsten untersuchten (0.1 m) und der größten (0.25 m) Zellgröße ist zwar ein Unterschied vorhanden, jedoch äußert sich dieser lediglich in einem typisch durch eine Diskretisierung hervorgerufenem Rauschen um den „wahren“ Wert der Referenz (siehe Abbildung 6.17). Die maximale Abweichung von der Referenz kann mit kleiner als 5 cm abgeschätzt werden. Dieses Erkenntnis lässt sich analog auf den Kurswinkel (Abbildung 6.18) und die Krümmung (Abbildung 6.19) anwenden. Begründet werden kann dieses Ergebnis durch die Erstellung einer Belegungskarte, in




Abbildung 6.20: Laufzeit  $t$  der histogrammbasierten Fahrstreifenschätzung bei einer Zellgröße von 0.1 m, 0.15 m, 0.2 m und 0.25 m.

der die Unsicherheit in der Messung mit einem geeigneten Modell in die Belegungskarte übertragen wurde (siehe Abschnitt 2.4.1), mit einer anschließenden Interpolation zwischen benachbarten Zellen (siehe Abschnitt 3.4.5) der durch eine Diskretisierung entstandene Fehler wieder ausgeglichen wurde. Weiter lässt sich sagen, dass zwischen einer Größe von 0.1 m und 0.15 m kein erkennbarer Unterschied besteht. Eine Zellgröße von kleiner 0.15 m scheint daher wenig sinnvoll. Eine Zellgröße von 0.15 m bis 0.20 m kann daher als optimal angesehen werden. Unterhalb von 0.15 m ergibt sich nur eine marginale Verbesserung in der Krümmung. Oberhalb von 0.20 m ist wiederum mit einem durch die größere Diskretisierung verstärktem Rauschen zu rechnen.

Betrachtet man zusätzlich die Laufzeit des Algorithmus in Abhängigkeit der Zellgröße (Abbildung 6.20), so ist zu erkennen, dass die Laufzeit ab einer Zellgröße von kleiner als 0.15 m stark ansteigt. Dies entspricht im Wesentlichen der Annahme, dass die Laufzeit mit der Größe der Belegungskarte (Anzahl der Zellen) quadratisch skaliert. Setzt man dieses Ergebnis nun in Relation zu der erzielten Genauigkeit, stellt eine Zellgröße zwischen 0.15 m und 0.2 m nicht nur unter dem Aspekt der Genauigkeit einen guten Kompromiss dar, sondern auch unter Beachtung des benötigten zeitlichen Aufwands um dieses Ergebnis zu erreichen.

Betrachtet man zudem die benötigte maximale Berechnungszeit von 18 ms bei einer Zellgröße von bis zu 0.15 m auf einem Referenzprozessor mit 1.73 GHz, so ist die Realisierung der hier vorgestellten Fahrstreifenerkennung in zukünftigen FAS Steuergeräten durchaus denkbar. Zudem ist es möglich, die Histogrammbildung zu parallelisieren, wodurch die Komplexität auf mehrere Prozesse verteilt wird.

### 6.3.5 Zusammenfassung

In diesem Abschnitt wurden die theoretische Verfügbarkeit einer lidarbasierten Fahrstreifenerkennung im Allgemeinen und die Genauigkeit und die Verfügbarkeit des in dieser

Arbeit vorgestellten Verfahrens zur Fahrstreifenschätzung evaluiert.

Für die theoretische Abschätzung der Verfügbarkeit erfolgte im ersten Teil eine Betrachtung von Fahrbahnmarkierungsnormen in 16 EU Staaten und den USA. Mit Hilfe eines Messaufbaus wurde überprüft, ob die bestehenden Normen mit den Minimalanforderungen des Lidar Sensors übereinstimmen. Für die 16 untersuchten EU Staaten konnte eine theoretische Verfügbarkeit von 100% bei trockener Fahrbahnoberfläche ermittelt werden. Für die USA konnte keine endgültige Aussage getroffen werden, da keine einheitlichen Mindestanforderungen an Fahrbahnmarkierungen sowie unterschiedliche Fahrbahnmarkierungssysteme existieren. Eine Einschränkung im Allgemeinen stellt die Überdeckung von Fahrbahnmarkierungen mit einem Wasserfilm dar. Bei nasser Fahrbahnoberfläche existieren entweder keine oder nur unzureichende Normen mit Blick auf eine lidarbasierte Erkennung von Fahrbahnmarkierungen.

Im zweiten Teil wurde die Genauigkeit der histogrammbasierten Fahrstreifenschätzung auf einer Teststrecke mit einer hochgenauen digitalen Karte und die Verfügbarkeit im realen Straßenverkehr anhand mehrerer ausgewählter Autobahnabschnitte bestimmt. Die erzielte Genauigkeit übertrifft die zu Beginn dieser Arbeit gestellten Anforderungen um ein Vielfaches. Dies bedeutet, dass ein System mit einem in Fahrtrichtung gerichteten Lidar für die automatisierte Querführung eines Fahrzeugs geeignet ist. Neben der Genauigkeit, trägt die Verfügbarkeit eines solchen Systems unter realen Bedingungen einen wichtigen Bestandteil zu der Akzeptanz eines solchen Systems bei. Die ermittelte Verfügbarkeit für deinen eigenen Fahrstreifen von 98.76% kann als hervorragendes Ergebnis gewertet werden.

Abschließend wurde der Einfluss der Zellgröße einer Belegungskarte, welche als Basis für die Fahrstreifenschätzung dient, auf die Genauigkeit der histogrammbasierten Fahrstreifenschätzung ausgewertet. Eine Zellgröße von 0.15 m bis 0.20 m wurde als guter Kompromiss zwischen der Genauigkeit und Laufzeit des Algorithmus ermittelt.

## 6.4 Bewertung des Fusionssystems

Nachdem in dem vorangegangenen Abschnitt die Leistungsfähigkeit der lidarbasierten Fahrstreifenerkennung im Detail diskutiert wurde, folgt in diesem Abschnitt die Betrachtung des Fusionssystems aus Kapitel 4. Betrachtet werden analog zu Kapitel 6.3 die Genauigkeit und die Verfügbarkeit des Fusionssystems bestehend aus der lidar- und kamerabasierten Fahrstreifenerkennung. In dem Teilabschnitt zur Verfügbarkeit wird zudem die Fragestellung diskutiert, ob die Kombination der beiden Systeme eine echte diversitäre Redundanz bietet. Um einen direkten Vergleich zu ermöglichen, folgt der Aufbau der nächsten zwei Abschnitte im Wesentlichen der bereits aus Abschnitt 6.3 bekannten Abschätzung der Genauigkeit und der Verfügbarkeit des lidarbasierten Systems.

Zu Beginn dieses Kapitels erfolgt jedoch zunächst eine Bestimmung der für die Fusion mittels Kalman-Filter benötigten Größen wie die relative Sensorlatenz und des System- und Messrauschens.

### 6.4.1 Bestimmung des System- und des Messrauschens

Um einen vollständigen Rekursionsschritt (Prädiktion und Fusion) des Kalman-Filters durchzuführen, müssen das Systemrauschen in Form der  $\mathbf{Q}$  Matrix und das Messrauschen in Form der  $\mathbf{R}$  Matrix bestimmt werden (siehe Kapitel 4.1). In dem nächsten Teilabschnitt erfolgt zunächst eine experimentelle Bestimmung des Systemrauschens anhand mehrerer Fahrmanöver. Im zweiten Teil wird auf Basis der Evaluierung der Genauigkeit der einzelnen Sensorsysteme (Abschnitt 6.4.3) das Messrauschen abgeleitet.

#### Bestimmung des Systemrauschens

Das Systemrauschen gibt die Unsicherheit in der Modellierung des Systems durch das Systemmodell an. Durch das Systemrauschen wird direkt beeinflusst, wie stark einem prädierten Systemzustand  $\hat{\mathbf{x}}_{k|k-1}$  in dem darauf folgenden Fusionschritt vertraut wird. Das Systemrauschen sollte nach [BP99] maximal der möglichen Änderung pro Zeitschritt  $T$  der Systemzustände betragen. Da das Systemrauschen analytisch nur sehr schwer hergeleitet werden kann, bietet sich alternativ eine experimentelle Bestimmung an.

Um die maximalen Änderungen der Zustandsgrößen Ablage  $y$ , Kurswinkel  $\psi$  und Krümmung  $c$  zu ermitteln, wurden mehrere Fahrmanöver durchgeführt. Die maximale Änderung der Ablage  $y$  sowie des Kurswinkels  $\psi$  wird anhand eines „sinus-förmigen“ Fahrmanövers mit einer hohen Amplitude und Frequenz bestimmt (siehe Abbildung 6.21). Um die maximale Änderung in der Krümmung  $c$  zu ermitteln, wird eine Szene betrachtet, in der eine Kurve mit sehr kleinem Radius durchfahren wird. Die Fahrstreifenbreite ändert sich unter normalen Bedingungen gar nicht oder nur sehr langsam, weshalb hierfür zunächst keine Änderung modelliert wird. Die maximalen Änderungen der drei Zustandsgrößen sind in Tabelle 6.11 aufgeführt. Ausgehend von diesen Ergebnissen wird das Systemrauschen systematisch verändert, bis das gewünschte Filterverhalten erreicht ist. Die so empirisch bestimmten Größen  $\sigma_x$  für das Systemrauschen sind ebenfalls in Tabelle 6.11 zu finden.




Abbildung 6.21: Trajektorie zur Ermittlung des Systemrauschens.

Die Kovarianzmatrix  $\mathbf{Q}$  (siehe Kapitel 4.1) ergibt sich letztlich aus den einzelnen Varianzen  $\sigma^2$  der Rauschterme:

	$\Delta e_{\max}$	$\sigma$
Ablage $y$ (m)	0.13	0.04
Fahrstreifenbreite $b$ (m)	0	0.005
Kurswinkel $\psi$ ( $^\circ$ )	0.5	0.2
Krümmung $c$ ( $\text{m}^{-1}$ )	0.2	0.2

Tabelle 6.11: Maximale Änderung pro Zeitschritt  $\Delta e_{\max}$  und empirisch ermitteltes Systemrauschen  $\sigma_x$ .

$$\mathbf{Q} = \begin{bmatrix} \sigma_y^2 & 0 & 0 & 0 \\ 0 & \sigma_b^2 & 0 & 0 \\ 0 & 0 & \sigma_\psi^2 & 0 \\ 0 & 0 & 0 & \sigma_c^2 \end{bmatrix} \quad (6.10)$$

### Bestimmung des Messrauschens

Neben dem Systemrauschen, welches maßgeblichen Einfluss auf das Vertrauen des Systemmodells hat, steuert das Messrauschen direkt den Einfluss der Messwerte auf den fusionierten Zustandsvektor. Wird das Messrauschen niedrig gewählt, wird den mit Rauschen überlagerten Messwerten stärker vertraut und der Einfluss auf den Systemzustand ist relativ groß. Wird das Messrauschen erhöht, werden die Zustandsgrößen stärker geglättet und folgen eher dem Systemmodell. Wird das Messrauschen zu groß gewählt, steigt in einem dynamischen System mit einem geschlossenen Regelkreis die Gefahr einer Rückkopplung, welche im ungünstigsten Fall zu einem instabilen Reglerverhalten führt. Es ist daher wichtig, beide Rauschwerte richtig aufeinander abzustimmen. Im Folgenden wird das Messrauschen empirisch auf Basis der Standardabweichung der beiden Sensorsysteme bestimmt (siehe Tabelle 6.15). Anhand mehrerer Tests im realen Straßenverkehr wird das Messrauschen nun soweit verändert, bis sich in Kombination mit dem zuvor festgelegten Systemrauschen das gewünschte Systemverhalten ergibt. Das so ermittelte Messrauschen ist in Tabelle 6.12 aufgeführt.

	Lidar	Video
Ablage $\tilde{\sigma}_y$	0.1 m	0.1 m
Fahrstreifenbreite $\tilde{\sigma}_b$	0.05 m	0.05 m
Kurswinkel $\tilde{\sigma}_\psi$	0.2 $^\circ$	0.25 $^\circ$
Krümmung $\tilde{\sigma}_c$	0.5 $\text{m}^{-3}$	0.35 $\text{m}^{-3}$

Tabelle 6.12: Empirisch ermitteltes Messrauschen.

Die Kovarianzmatrix für das Messrauschen ergibt sich dann wie folgt:

$$\mathbf{R} = \begin{bmatrix} \tilde{\sigma}_y^2 & 0 & 0 & 0 \\ 0 & \tilde{\sigma}_b^2 & 0 & 0 \\ 0 & 0 & \tilde{\sigma}_\psi^2 & 0 \\ 0 & 0 & 0 & \tilde{\sigma}_c^2 \end{bmatrix}. \quad (6.11)$$

### 6.4.2 Bestimmung der Sensorlatenzzeiten

Wie in Abschnitt 6.1.4 erwähnt, ist jeder Messung ein eindeutiger Zeitstempel zugeordnet, der den Ankunftszeitpunkt innerhalb des zyklischen Frameworks enthält. Dieser unterliegt in der Regel jedoch einer sensorspezifischen Latenz, welche die Differenz zwischen dem Ankunftszeitpunkt und dem wahren Zeitpunkt der Messung darstellt. Um die durch mögliche Latenzzeiten induzierten Fehler zwischen dem prädizierten Systemzustand und dem Messupdate abschätzen zu können, ist es notwendig, diese Latenz zu schätzen. In Abbil-




Abbildung 6.22: Übersicht über Prädiktion und Messupdate im zyklischen Framework

Abbildung 6.22 ist schematisch der Ablauf eines Iterationsschritts des Kalman-Filters beschrieben. Die Fusion wird im aktuellen Zyklus ausgeführt und verarbeitet darin alle Messwerte, die bis zum Zeitpunkt  $t_k$  übermittelt wurden. Im Kalman-Filter erfolgt zuerst jeweils eine Prädiktion des Systemzustands bis zum Zeitpunkt der Messung, gefolgt vom Messupdate. Zuletzt wird der Systemzustand bis zum Start des aktuellen Zyklus prädiziert. Im optimalen Fall ist der genaue Messzeitpunkt durch eine gemeinsame Zeitbasis und einem vom Sensor übermittelten Zeitstempel bekannt. Für die Auswertung dieser Arbeit steht jedoch leider keine synchronisierte Zeitbasis zur Verfügung.

Im Folgenden wird daher beschrieben, wie die Latenz experimentell geschätzt werden kann. Hierzu wurden zwei Testfahrten durchgeführt, bei denen innerhalb des eigenen Fahrstreifens mehrere sinusförmige Fahrmanöver durchgeführt wurden. Zur Latenzzeitbestimmung wird der gemessene Kurswinkel  $\psi$  relativ zu den Fahrbahnmarkierungen betrachtet. Als Referenz dient die mit einer Frequenz von 50 Hz gemessene und integrierte Gierrate der Interiärsensorik des Versuchsfahrzeugs. In Tabelle 6.13 ist ein Überblick über die dafür durchgeführten Testfahrten gegeben.

Die Latenzzeiten werden bestimmt, indem die Kreuzkorrelation der Kurswinkel-Signale zu der Referenz berechnet wird. An deren Maximum lässt sich die Phasenverschiebung der beiden Signale ablesen, welche der durchschnittlichen Latenzzeit der beiden Sensoren entspricht. In Abbildung 6.23(a) ist ein Ausschnitt aus der zweiten Testfahrt abgebildet,

	Strecke (m)	Dauer (s)	$\hat{v}$
Testfahrt 1	466.8	35.28	47.63
Testfahrt 2	464.5	31.04	53.87

Tabelle 6.13: Länge, Dauer und Durchschnittsgeschwindigkeit der für die Bestimmung der Sensorlatenzzeiten verwendeten Testfahrten.

sowie die dazugehörige Kreuzkorrelation (Abbildung 6.23(b)). Die durch die Kreuzkorrelation ermittelten Latenzzeiten für die beiden Testfahrten und deren Mittelwerte sind in Tabelle 6.14 abzulesen.

	Video	Lidar
Testfahrt 1	119.87 ms	111.13 ms
Testfahrt 2	116.87 ms	108.47 ms
$\bar{x}$	<b>118.37 ms</b>	<b>109.8 ms</b>

Tabelle 6.14: Durch die Kreuzkorrelation ermittelte Latenzzeit für das lidar- und videobasierte System.


Wie in Tabelle 6.14 zu sehen, besitzen beide Systeme eine sehr geringe relative Latenz von ungefähr 10 ms. Es kann daher davon ausgegangen werden, dass der durch zeitliche Asynchronität induzierte relative Messfehler zu vernachlässigen ist. Für eine Iteration des Kalman-Filters ist jedoch zusätzlich von Bedeutung, welche Latenzen die Messungen in Relation zu denen für das Systemmodell verwendeten Größen besitzen. Da für diese Auswertung die integrierte Gierrate  $\dot{\Psi}$  als Referenz verwendet wurde, stimmt die Latenz zwischen den Messwerten und den Eingaben des Systemmodells (Geschwindigkeit  $v$  und Gierrate  $\dot{\Psi}$ ) mit den Mittelwerten aus Tabelle 6.14 überein.

Um den durch Asynchronität induzierten Fehler zwischen dem prädizierten Systemzustand und dem Messupdate zu reduzieren, werden die in dem Systemmodell verwendeten Größen entsprechend Tabelle 6.14 verzögert.


### 6.4.3 Bewertung der Genauigkeit mit DGPS und einer hochgenauen digitalen Karte

Im Folgenden werden die bereits aus Abschnitt 6.3 bekannten Fehlermetriken  $\mu_{\bar{x}}$  (6.7),  $s_{\bar{x}}$  (6.8) und RMSE (6.8) für die Krümmung  $c$ , den Kurswinkel  $\psi$  und die Ablage  $y$  im eigenen Fahrstreifen betrachtet.

Der Testaufbau und die Durchführung der Testfahrt gleicht Abschnitt 6.3. Die Abbildungen 6.24 bis 6.26 zeigen die geschätzten Parameter Ablage, Kurswinkel und Krümmung im Vergleich zu der auf DGPS und einer hochgenauen digitalen Karte basierten Referenz. Da sich die Fusion aus den zwei Einzelsystemen, der lidar- und videobasierten Fahrstreifen-erkennung, zusammensetzt, erfolgt zusätzlich der direkte Vergleich mit diesen beiden Sys-



(a) Kurswinkel



(b) Kreuzkorrelation

Abbildung 6.23: Bestimmung der Sensorlatenzzeiten am Beispiel der zweiten Testfahrt durch die Betrachtung der Phasenverschiebung in der Kreuzkorrelation.

temen. Die für das Kalman-Filter benötigten Rauschterme (Mess- und Systemrauschen) wurden mit den in dem folgenden Abschnitt 6.4.1 ermittelten Werten belegt.




Abbildung 6.24: Vergleich der Ablage  $y$  der Fusions und der lidar- und videobasierten Erkennung zu der auf DGPS und einer hochgenauen digitalen Karte basierten Referenz.




Abbildung 6.25: Vergleich des Kurswinkels  $\psi$  der Fusions und der lidar- und videobasierten Erkennung zu der auf DGPS und einer hochgenauen digitalen Karte basierten Referenz.




Abbildung 6.26: Vergleich der Krümmung  $c$  der Fusion und der lidar- und videobasierten Erkennung zu der auf DGPS und einer hochgenauen digitalen Karte basierten Referenz.

	Lidar			Video			Fusion		
	$y$ (m)	$\psi$ ( $^{\circ}$ )	$c \times 10^{-3}$ ( $\text{m}^{-1}$ )	$y$ (m)	$\psi$ ( $^{\circ}$ )	$c \times 10^{-3}$ ( $\text{m}^{-1}$ )	$y$ (m)	$\psi$ ( $^{\circ}$ )	$c \times 10^{-3}$ ( $\text{m}^{-1}$ )
$\mu_{\bar{x}}$	0.00	-0.01	0.006	0.01	0.01	0.003	0.00	0.01	0.001
$\sigma_{\bar{x}}$	0.03	0.06	0.119	0.04	0.11	0.076	0.04	0.08	0.077
RMSE	0.03	0.06	0.119	0.05	0.12	0.077	0.04	0.09	0.077

Tabelle 6.15: Fehlerauswertung der Fusion im Vergleich zur Referenz und dem video- und lidarbasierten System.

**Diskussion der Ergebnisse** Da bis zu diesem Zeitpunkt noch keine separate Betrachtung des videobasierten Systems erfolgt ist, wird zuvor die erzielte Genauigkeit des videobasierten mit der Genauigkeit des lidarbasierten Systems verglichen. Betrachtet wird der durchschnittliche Fehler  $\mu_{\bar{x}}$  des videobasierten Systems (Tabelle 6.15). Wie bei der Auswertung des durchschnittlichen Fehlers des lidarbasierten Systems (siehe Abschnitt 6.3.2), weist auch das videobasierte System keinen systematischen Fehler auf. Eine Beeinträchtigung des Fusionsergebnisses durch Fehler, die auf eine unzureichende Sensorkalibrierung der Kamera oder auf einen systematischen Fehler innerhalb der Serienkamerasystems zurückzuführen sind, können daher ausgeschlossen werden. Eine separate Betrachtung der Standardabweichung und des mittleren quadratischen Fehlers ist somit ebenfalls nicht erforderlich.

Vergleicht man die Standardabweichung  $\sigma_{\bar{x}}$  der drei Zustandsgrößen Ablage, Kurswinkel und Krümmung des video- mit dem lidarbasierten System zeigt sich, dass beide Systeme

eine vergleichbare Genauigkeit erzielen. Ein merklicher Unterschied zugunsten des lidarbasierten Systems ergibt sich bei dem Kurswinkel. Bei der Krümmung hingegen besitzt das videobasierte System eine geringere Standardabweichung. Der Unterschied in der Krümmung ist dadurch zu erklären, dass einem auf einer Videokamera aufbauendem System für die Schätzung einer genauen Krümmung wesentlich mehr Messwerte zur Verfügung stehen als dem in dieser Arbeit verwendeten Laserscanner. Auf Basis der Differenz in dem Kurswinkel kann keine direkte Aussage getroffen werden. Prinzipiell sollte es einem videobasierten System durch die größere Anzahl an Stützstellen auf den Markierungen möglich sein, einen vergleichbaren Wert zu erzielen.

Bestehen in einigen Zustandsgrößen geringfügige Unterschiede, so muss dennoch festgehalten werden, dass beide Systeme mit Blick auf die Mindestanforderung der einzelnen Parameter (siehe Kapitel 1.2) eine vergleichbare Genauigkeit erzielen. Für die Fusion beider Systeme stellt dies wichtige Erkenntnisse dar, die kurz erläutert werden sollen.

Sollten in der Fusion über ein längeres Zeitintervall keine Messwerte des videobasierten Systems für ein Messupdate vorliegen, ist nicht mit einer Verschlechterung der Güte<sup>4</sup> einer auf der Fusion aufbauenden Fahrzeugquerführung zu rechnen. In Kapitel 1.2 wurde neben den Anforderungen an die Genauigkeit eines Systems zur Unterstützung in der Querführung als Hauptziel die Steigerung der Robustheit angegeben. Im einfachsten Fall stehen, wie eben bereits erwähnt, keine Messwerte eines der beiden Systeme mehr zur Verfügung. Das Systemverhalten in diesem Fall ist einfach abzuschätzen. Liefern beide Systeme jedoch widersprüchliche Informationen im Sinne von „einer der beiden Messwerte ist falsch“, sollte der falsche Wert verworfen werden. In Abschnitt 4.3 wurde dies bereits erläutert und eine einfache Methode auf Basis des Residuums und einem Vielfachen der in den Messraum transformierten Fehlerkovarianzmatrix als Schranke (engl. Gate) vorgestellt. Liegt der fehlerhafte Messwert nun innerhalb der festgelegten Schranke, wird dieser zwar für das Messupdate verwendet, jedoch ist sein Einfluss bei annähernd gleichen Termen für das Messrauschen nicht stärker gewichtet. Liegt er außerhalb, wird die Messung bei beiden Systemen gleichermaßen schnell verworfen.

Betrachtet man abschließend die Standardabweichung der Fusion für die drei Zustandsgrößen  $y$ ,  $\psi$  und  $c$ , ergibt sich ein Filterergebnis welches sich unterhalb des jeweiligen schlechteren Wertes des Einzelsystems befindet. Als mögliche Ursache für dieses „nicht-optimale“ Filterergebnis bei mit Unsicherheit behafteten normalverteilten Messungen, gilt die Korrelation der Rauschterme des Messvektors der beiden Einzelsysteme mit dem dynamischen Modell des Filters.

#### 6.4.4 Evaluierung der Verfügbarkeit

Die Verfügbarkeit des Fusionssystems wird anhand derselben Messfahrten überprüft wie zuvor bei der Evaluierung der lidarbasierten Fahrstreifenenerkennung. Die gewählten Testbedingungen und die einzelnen Testszenen sind in Abschnitt 6.3.3 zu finden. Als verbleibende wichtige Fragen zu klären gilt es, welche Verfügbarkeit ein videobasiertes System im Ver-

<sup>4</sup>Hiermit ist das Komfortverhalten einer Regelung gemeint.

gleich zu einem lidarbasierten System erreicht und ob durch die Fusion beider Systeme eine Steigerung der Verfügbarkeit erzielt werden kann.

In Tabelle 6.16 sind die Ergebnisse der Auswertung zusammengefasst. Die prozentuale Verfügbarkeit wurde über die Dauer der Verfügbarkeit und der Gesamtzeit der jeweiligen Szene errechnet. Es handelt sich hierbei demnach wieder um eine zeitliche Auswertung der Verfügbarkeit.

Strecke in km	Dauer in s	Video		Lidar		Fusion	
		in s	in %	in s	in %	in s	in %
104.65	3232.1	3156.2	<b>97.65</b>	3191.8	<b>98.76</b>	3232.1	<b>100.00</b>

Tabelle 6.16: Verfügbarkeit des eigenen Fahrstreifens von der lidar- und videobasierte Fahrstreifenerkennung im Vergleich zu der Fusion beider Systeme.

Die gesamte Länge aller betrachteten Autobahnabschnitte beträgt wie bei der Evaluierung der lidarbasierten Fahrstreifenerkennung 104.65 km. Die lidarbasierte Fahrstreifenerkennung erreicht die bereits bekannte Verfügbarkeit von 98.76%. Im Vergleich dazu das videobasierte System mit einer gesamten Verfügbarkeit von 97.65%. In 2.35% der Zeit standen somit keine Informationen des videobasierten Systems über die linke und die rechte Fahrbahnmarkierung des eigenen Fahrstreifens zur Verfügung. Die Ausfälle des videobasierten Systems können im Wesentlichen auf zwei Ursachen zurückgeführt werden: die kurzzeitige Verdeckung einer Fahrbahnmarkierung durch Schattenwurf und die abrupte Veränderung der Umgebungshelligkeit bei der Unterfahung von Brücken oder der Durchfahung von Tunnelsegmenten. Eine Ausnahme bildet Testszene 17 (siehe Tabelle B.4), bei der eine Gegenlichtblendung zu einem längeren Ausfall des videobasierten Systems führte und in 34.56% der Zeit keine vollständigen Fahrstreifeninformationen verfügbar waren.

Die Fusion als Kombination beider Systeme erreicht auf den für die Evaluierung verwendeten Streckenabschnitten die maximal mögliche Verfügbarkeit von 100%. Diese ist dabei so definiert, dass zu jedem Zyklus des Frameworks mindestens ein System eine valide<sup>5</sup> Schätzung für die Ablage (errechnet sich aus dem linken und rechten Fahrstreifen), den Kurswinkel und die Krümmung ausgegeben hat.

Zusammenfassend lässt sich festhalten, dass die Kombination beider Sensorsysteme die Verfügbarkeit der jeweiligen Einzelsysteme, von 97.7% und 98.8%, auf 100.0% steigert. Zu jedem Zeitpunkt waren somit redundante Messdaten beider oder zumindest eines der beiden Systeme vorhanden. Daraus lässt sich schlussfolgern, dass zumindest in den für die Evaluierung verwendeten Szenarien beide Systeme eine diversitäre Redundanz bilden. In den Fällen, in denen das videobasierte System keine gültigen Messwerte geliefert hat, wurden diese durch das laserscannerbasierte System bereitgestellt und umgekehrt.

### 6.4.5 Zusammenfassung

In diesem Teilabschnitt wurden die Ergebnisse der Fusion zwischen der lidar- und videobasierten Fahrstreifenerkennung vorgestellt. Bewertet wurde zunächst die erzielte Genauigkeit

<sup>5</sup>Die Validität wurde mit Hilfe eines visuellen Referenzbildes überprüft.

des lidar- und videobasierten Systems im Vergleich zu einer aus DGPS und einer hochgenauen digitalen Karte bestehenden Referenz. Vergleicht man die Standardabweichung der drei Zustandsgrößen Ablage, Kurswinkel und Krümmung des lidar- mit dem kamera-basierten System zeigt sich, dass beide Systeme eine vergleichbare Genauigkeit erzielen. Als wichtige Erkenntnis gilt die Tatsache, dass ein lidarbasiertes System in der Lage ist, die Genauigkeit eines videobasierten Systems zu erreichen. Es ist zudem festzuhalten, dass beide Systeme die in Kapitel 1.2.2 gestellten Mindestanforderung nicht nur erfüllen sondern sogar übertreffen. Betrachtet man zudem die Genauigkeit des Fusionssystems, zeigt sich für jede Größe eine geringe Verbesserung in der Standardabweichung im Vergleich zu den Einzelsystemen. Dieses Ergebnis entspricht im Wesentlichen der Theorie des Kalman-Filters als rekursiver Zustandsschätzer bei mit Unsicherheit behafteten normalverteilten Messungen.

Als weitere wichtige Fragestellung zu diskutieren galt es, ob die Kombination der beiden Systeme eine echte diversitäre Redundanz bietet. Betrachtet man die Verfügbarkeit beider Systeme, so ist zu erkennen, dass zu jedem Zeitpunkt beide oder zumindest eines der beiden Systeme valide Messwerte liefern konnte. In den Fällen, in denen das videobasierte System keine gültigen Messwerte geliefert hat, wurden diese durch das laserscannerbasierte System bereitgestellt und umgekehrt. Daraus lässt sich schlussfolgern, dass zumindest in den für die Evaluierung verwendeten Szenarien beide Systeme eine diversitäre Redundanz bilden und eine Fusion aus Sicht der Verfügbarkeit durchaus sinnvoll ist.

## 6.5 Bewertung der Fahrbahnranderkennung mit DGPS und einer hochgenauen digitalen Karte

Die Bewertung der Genauigkeit der Fahrbahnranderkennung erfolgt wie bei der lidar- und videobasierten Fahrstreifenerkennung mit Hilfe eines Inertialen-Navigationssystems mit DGPS und einer hochgenauen digitalen Karte. Im Gegensatz zu Kapitel 6.3.2, dient eine im bottom-up Verfahren (siehe Abschnitt 6.2.3) mit DGPS vermessenen Randbebauung als Referenz. Hierzu wurden in Modulbauweise steckbare Baustellenbegrenzungen (Abbildung 6.27) auf einem Testgelände zu einer Randbebauung zusammengefügt und anschließend georeferenziert mit dem in Abbildung 6.6 gezeigten System in 1 m diskreten Abständen vermessen.

Wie in Kapitel 2, wurden zwei Belegungskarten berechnet, auf Basis derer die Fahrbahnranderkennung mit dem in Kapitel 5 vorgestellten Verfahren durchgeführt wurde. Die erste Karte wurde mit Laserscanner 1 und die zweite mit dem bildgebenden Radar aus Abschnitt 6.1.2 erstellt. Die Zellgröße der Belegungskarte wurde auf 0.16 m und die Größe auf  $300 \times 300$  Zellen mit einer Historie von 30 Zellen festgelegt. Eine genaue Erklärung zu der Aufteilung einer Belegungskarte ist in Kapitel 2.4.3 zu finden.

Zur Bewertung des Schätzfehlers wird der durchschnittliche Fehler einer Stichprobe  $\mu_{\bar{x}}$ , die Standardabweichung einer Stichprobe  $s_{\bar{x}}$  und der Quadratische-Mittelwertfehler RMSE ausgewertet. Tabelle 6.17 fasst die Fehler der histogrammbasierten Schätzung zusammen.

	Lidar			Radar		
	$y$ (m)	$\psi$ ( $^\circ$ )	$c$ ( $\text{m}^{-1}$ )	$y$ (m)	$\psi$ ( $^\circ$ )	$c$ ( $\text{m}^{-1}$ )
$\mu_{\tilde{x}}$	0.01	-0.04	$-0.06 \times 10^{-2}$	0.04	-0.29	$-0.03 \times 10^{-2}$
$s_{\tilde{x}}$	0.05	0.32	$0.28 \times 10^{-2}$	0.05	0.43	$0.2 \times 10^{-2}$
RMSE	0.05	0.32	$0.3 \times 10^{-2}$	0.06	0.52	$0.22 \times 10^{-2}$


Tabelle 6.17: Fehlerabschätzung der histogrammbasierten Fahrbahnranderkennung.

**Diskussion** Betrachtet wird zunächst der durchschnittliche Fehler der Stichproben  $\mu_{\tilde{x}}$  im Verhältnis zur Standardabweichung. Mit Ausnahme des durchschnittlichen Kurswinkelfehlers bei der auf dem Radar basierten Erkennung, weisen alle anderen Werte einen verhältnismäßig sehr geringen durchschnittlichen Fehler auf. Der erhöhte durchschnittliche Kurswinkelfehler von  $-0.29^\circ$  ist dabei auf einen möglichen Kalibrierungsfehler in dem Gierwinkel  $\Psi_s$  des Radarsensors zurückzuführen. Um die Ursache dieser Abweichung zweifelsfrei zu klären, bedarf es weiterer Testfahrten, die im Rahmen dieser Arbeit nicht möglich waren. Da sich zumindest bei einem Parameter die Standardabweichung und der Quadratische-Mittelwertfehler deutlich unterscheiden, erfolgt die weitere Betrachtung anhand des RMSE.


Sowohl die lidar- als auch die radarbasierte Randbebauungserkennung erzielen mit einem RMSE von 0.05 m beziehungsweise 0.06 m eine sehr genaue Schätzung der Ablage  $y$ . Hervorzuheben ist die erzielte Genauigkeit der radarbasierten Schätzung. Obwohl der Radarsensor lediglich über eine Entfernungsgenauigkeit von 0.25 m bei einer Winkelauflösung von  $2.5^\circ$  verfügt und die Breite der Randbebauung in der Belegungskarte ungefähr 1 m beträgt (Abbildung 6.28(b)), erreicht die Schätzung der Ablage eine wesentlich bessere Genauigkeit. Die Steigerung der Genauigkeit in der Ablage kann im Wesentlichen zwei Tatsachen zugeschrieben werden. Als Messwerte für die Belegungskarte wurden die in Form von Amplitudenbildern vorliegenden Roh-Messwerte verwendet. Unter der Annahme einer Gaußverteilung innerhalb dieser Bilder, entsteht durch die zeitliche Integration innerhalb der höher aufgelösten Belegungskarte ein *Super-Resolution* Effekt. Ein weiterer Vorteil des



Abbildung 6.27: Auf dem Testgelände zur Referenzierung verwendete modulare Baustellenbegrenzungen.



(a)



(b)

Abbildung 6.28: Histogrammbasierte Erkennung der zu einer Randbebauung zusammengeführten modularen Baustellenbegrenzungen mit einem Laserscanner in (a) und einem Radarsensor in (b).




Abbildung 6.29: Vergleich der ermittelten Ablage  $y$  der histogrammbasierten Fahrbahnranderkennung zu der aus einem Inertialen-Navigationssystem mit DGPS und einer mit DGPS vermessenen Randbebauung bestehenden Referenz.




Abbildung 6.30: Vergleich des ermittelten Kurswinkels  $\psi$  der histogrammbasierten Fahrbahnranderkennung zu der aus einem Inertialen-Navigationssystem mit DGPS und einer mit DGPS vermessenen Randbebauung bestehenden Referenz.




Abbildung 6.31: Vergleich der ermittelten Krümmung  $c$  der histogrammbasierten Fahrbahnranderkennung zu der aus einem Inertialen-Navigationssystem mit DGPS und einer mit DGPS vermessenen Randbebauung bestehenden Referenz.

vorgestellten histogrammbasierten Schätzverfahrens ist die Möglichkeit der Interpolation zur Erhöhung der Genauigkeit in der Ablage (siehe Kapitel 3.4.5).

Abschließend wird der RMSE des Kurswinkels und der Krümmung betrachtet. Die lidarbasierte Schätzung des Kurswinkels erreicht eine Genauigkeit, welche die in Kapitel 1.2 festgelegte maximale Standardabweichung für Querführungsaufgaben von  $0.25^\circ$  zwar knapp verfehlt, jedoch trotzdem als ein sehr gutes Resultat einer Fahrbahnranderkennung gewertet werden kann. Die Ursache für die weitaus größere Abweichung der radarbasierten Erkennung kann, wie bereits einleitend erwähnt, nicht zweifelsfrei geklärt werden. Bei der Betrachtung der Krümmung, erreicht die radarbasierte eine etwas bessere Schätzung als die lidarbasierte Erkennung. Betrachtet man jedoch zusätzlich den Verlauf der beiden Parameter in Abbildung 6.31, so wird deutlich, dass der größere Fehler des lidarbasierten Systems auf eine stärkere Verschiebung des Signals zurückzuführen ist.

## 6.6 Laufzeitanalyse der Berechnung stationärer Belegungskarten auf der GPU

Die Bewertung der Laufzeit – und damit direkt der Performance – des in Kapitel 2 vorgestellten Verfahrens zur effizienten Erstellung von Belegungskarten auf der GPU erfolgt mittels einer  $3 \times 3$  Laufzeitmatrix bestehend aus drei unterschiedlichen Sensor und GPU Varianten.

Um die Laufzeit des Algorithmus in Abhängigkeit zu der Rechenleistung einer GPU abzuschätzen, wurden drei unterschiedliche Grafikkarten verwendet. Die erste Grafikkarte, ein Nvidia ION, verfügt über 16 *Streamprozessoren* mit einer Rechenleistung von 52 *GFlops* und ist der untersten Leistungsklasse zuzuordnen. Der Begriff Streamprozessor und dessen Funktionsweise ist mitunter sehr komplex und wird in dieser Arbeit nicht weiter erläutert. Festgelegt wird lediglich, dass mit einer größeren Anzahl an Streamprozessoren eine größere Rechenleistung (gemessen in Giga-Flops) einhergeht, die aber nicht zwangsläufig linear mit der Anzahl an Streamprozessoren skalieren muss. Für eine genaue Erläuterung über den Aufbau moderner Grafikkarten mit einer *unified Shader* Architektur und die Bedeutung der Streamprozessoren ist auf [NVI11b] verwiesen. Die zweite Grafikkarte, eine Nvidia Quadro FX 2700M, verfügt über 48 Streamprozessoren mit einer Rechenleistung von 180 *GFlops* und ist der mittleren Leistungsklasse heutiger GPU's zuzuordnen. Die letzte, eine Nvidia Quadro 5000, repräsentiert mit 352 Streamprozessoren und einer Rechenleistung von 718 *GFlops* die oberste Schranke der Leistung heutiger Grafikkarten.

Zudem wurden für die Auswertung zwei Laserscanner und ein Radarsensor verwendet. Der erste Laserscanner entspricht Laserscanner 1 aus Abschnitt 6.1.2. Er verfügt über vier vertikale Messebenen mit einem horizontalen Öffnungswinkel von jeweils  $100^\circ$  bei einer Winkelauflösung  $0.25^\circ$ . Der zweite Laserscanner verfügt über einen horizontalen Öffnungswinkel von  $90^\circ$  bei einer Winkelauflösung von  $1^\circ$ . Er ist baugleich mit Laserscanner 2 aus Abschnitt 6.1.2 jedoch mit dem Unterschied, dass für den Test eine feinere Winkelauflösung ( $1^\circ$  anstelle von  $1.8^\circ$ ) bei reduziertem Öffnungswinkel gewählt wurde. Der letzte für

die Evaluierung verwendete Sensor ist der in Abschnitt 6.1.2 aufgeführte Radar, bei dem für den Aufbau der Belegungskarte der Fernbereich mit einem Öffnungswinkel von  $18^\circ$  verwendet wurde. Für jede Grafikkarten- und Sensorkombination wurde die Laufzeit für die Berechnung einer Belegungskarte mit einer Größe von  $256 \times 256$  und  $512 \times 512$  und einer Zellgröße von 0.2 m ausgewertet. Da die Komplexität des hier evaluierten Verfahrens lediglich von der maximalen Anzahl an Messwerten in dem Sichtbereich des jeweiligen Sensors und der Größe der Belegungskarte abhängt, ist eine Auswertung der Laufzeit unabhängig von der umgebenden Szenerie möglich. Für die Bewertung wurde deshalb für jeden Sensor eine einheitliche Testsequenz von 1000 Messwertupdates ausgewertet und jeweils der Mittelwert berechnet.

Die Abbildungen 6.32(a) bis 6.32(c) zeigen die erreichten Laufzeiten auf den drei zuvor genannten GPU's und Sensoren bei zwei Belegungskarten mit einer Größe von  $256 \times 256$  und  $512 \times 512$  Zellen. Als Resultat lässt sich festhalten, dass selbst bei Laserscanner 1 – welcher unter Laufzeitaspekten die höchste Komplexität besitzt – und einer Dimension von  $512 \times 512$  auf allen drei GPU's die in Kapitel 1.2.2 festgelegte maximale Rechenzeit von 80 ms weit unterschritten wird. Selbst auf dem Nvidia ION mit 16 Streamprozessoren, werden weniger als 16 ms für die gesamte Erstellung einer Belegungskarte inklusive Speichertransfer benötigt.

Die Abbildungen 6.33(a) bis 6.35(b) geben einen detaillierteren Überblick über die Zusammensetzung der zuvor in den Abbildungen 6.32(a) bis 6.32(c) gezeigten Gesamtlaufzeiten. Die Unterteilung in Stufen erfolgt dabei analog zu der in Kapitel 2 Abbildung 2.16 gezeigten Aufteilung in die Stufen 1-4. Zusätzlich ist die zusammengefasste Zeit für den Speichertransfer aufgetragen, welcher sich aus der Übertragung des Messvektors in den GPU Speicher und der Übertragung der Belegungskarte zurück in den CPU Speicher zusammensetzt. Anhand der Auswertung ist zu erkennen, dass der mit Abstand zeitlich aufwändigste Berechnungsschritt Stufe 3, die Abbildung einer temporären polaren auf eine temporäre kartesische Karte, ist. Dies kann dahingehend begründet werden, dass für den darin enthaltenen texture-mapping Ansatz eine Berechnung mehrerer mip-map Stufen sowie eine anschließende anisotrope oder bilineare Filterung erforderlich ist. Die anderen Stufen skalieren annähernd linear, wohingegen wie erwartet, der Speichertransfer quadratisch mit der Größe einer Belegungskarte skaliert. Da wie bereits erwähnt, bei dem Aufbau einer Belegungskarte mit nur einem Sensor alle betrachteten Kombinationen ein mehr als ausreichendes Ergebnis erzielen, ist die Notwendigkeit nach einer größeren Anzahl an Streamprozessoren genau dann gegeben, wenn die Belegungskarte zur Fusion mehrerer Sensoren verwendet werden soll. Bei der Integration von  $n$  Sensoren werden  $n$  Abbildungen temporärer polarer Belegungskarten auf ein kartesisches Koordinatensystem benötigt, welches auf einer GPU zu einem größeren Bedarf an Rechenleistung führt.




Abbildung 6.32: Laufzeitanalyse in Abhängigkeit der Größe einer Belegungskarte und der Leistung einer GPU für drei unterschiedliche Sensoren.




Abbildung 6.33: Detaillierte Laufzeitanalyse für Laserscanner 1 in Abhängigkeit der Größe einer Belegungskarte. Links die Ergebnisse für eine Belegungskarte mit  $512 \times 512$  Zellen und rechts mit  $256 \times 256$  Zellen.




Abbildung 6.34: Detaillierte Laufzeitanalyse für Laserscanner 2 in Abhängigkeit der Größe einer Belegungskarte. Links die Ergebnisse für eine Belegungskarte mit  $512 \times 512$  Zellen und rechts mit  $256 \times 256$  Zellen.




Abbildung 6.35: Detaillierte Laufzeitanalyse für den Radarsensor in Abhängigkeit der Größe einer Belegungskarte. Links die Ergebnisse für eine Belegungskarte mit  $512 \times 512$  Zellen und rechts mit  $256 \times 256$  Zellen.



## 7.1 Zusammenfassung

Eine große Herausforderung für zukünftige Fahrerassistenzsysteme besteht zunächst in der Abstraktion des Fahrumfelds durch geeignete Modelle. Zukünftige Modelle müssen in der Lage sein, die durch zeitlich aufeinander folgende Messdaten gegebene Szenerie mit hoher Präzision abzubilden. Zur Abbildung der Szenerie wurde deshalb in dieser Arbeit eine ortsbezogene Repräsentation in Form einer Belegungskarte vorgeschlagen, welche in der Lage ist, das Fahrumfeld in hoher Präzision und ohne eine vorherige Annahme über geometrische Modelle abzubilden. Die Berechnung von Belegungskarten stellt jedoch selbst für zukünftige automotiv taugliche Prozessoren, bedingt durch ihre große Anzahl an arithmetischen Operationen, eine anspruchsvolle Aufgabe dar. Um diese Aufgabe zu bewältigen, wurde ein auf dem Grafikprozessor (GPU) basiertes Verfahren entwickelt, welches eine extrem effiziente Berechnung von Belegungskarten mit einem maximalen Grad an Parallelität auf der GPU ermöglicht. Der in dieser Arbeit entwickelte Algorithmus bedient sich dabei der Berechnung von polaren Belegungskarten in Verbindung mit der anisotropen Filterung, um den durch ein im kartesischen Raum durchgeführtes „Ray-Casting“ entstehenden sogenannten Moiré Effekt zu vermeiden und in geschickter Weise die bestehende Messunsicherheit zu modellieren. Es wurde die erste in der Literatur bekannte vollständig GPU-basierte Erstellung probabilistischer Belegungskarten, basierend auf einem mehrzeiligen automotiven Laserscanner und einem bildgebendem Radar, durchgeführt. In der abschließenden Laufzeitanalyse konnte gezeigt werden, dass das Verfahren in der Lage ist, Belegungskarten mit einer großen räumlichen Abdeckung ( $512 \times 512$  Zellen) je nach GPU Leistungsklasse in 4-16 ms zu berechnen. Betrachtet man die schnell fortschreitende Entwicklung der GPU Leistung heutiger SOC-Lösungen in mobilen Endgeräten (Smartphones und Tablets), so ist eine Umsetzung des vorgestellten Verfahrens auf GPU's der nächsten Generation automotiver Plattformen durchaus möglich.

Anschließend erfolgte die gesamtheitliche Betrachtung der lidarbasierten Fahrstreifen-erkennung. Als eines der Hauptziele dieser Arbeit galt es zu klären, ob der Einsatz einer lidarbasierten Fahrstreifen-erkennung eine wirkliche Alternative zu einem videobasierten System darstellt. Dies beinhaltet sowohl die Genauigkeit als auch die Verfügbarkeit eines solchen Systems. Darüber hinaus ist es im Kontext von hochautomatisierten Fahrfunktionen wichtig, ob eine Kombination der beiden heterogenen Systeme eine diversitäre Redundanz bietet und ein lidarbasiertes System in den Fällen zuverlässig funktioniert, in denen ein kamerabasiertes System versagt. In diesem Zusammenhang wurde daher zunächst ein Vergleich von in der Literatur existierender Verfahren zur Detektion von Fahrbahnmarkierungen mit einem Lidar durchgeführt. Aufbauend auf der Erkenntnis, dass keines dieser Verfahren die gesetzten Anforderungen in vollem Maße erfüllt, wurde ein neues iteratives histogrammbasiertes Verfahren zur Detektion von Fahrbahnmarkierungen entwickelt. Im Detail wurde gezeigt, wie die Bestimmung der Ausrichtung und Krümmung aller auf der Fahrbahn existierender Markierungen als ein nichtlineares Optimierungsproblem aufgefasst werden kann, nämlich der iterativen Suche nach einem optimalen Histogramm. Auf Basis des optimalen Histogramms wurden die Positionen potentieller Fahrbahnmarkierungen extrahiert und klassifiziert. Das vorgestellte Verfahren ist äußerst robust gegen Fehldetektionen und Messrauschen und reduziert den Berechnungsaufwand durch die effiziente iterative Bestimmung der benötigten Histogramme auf ein Minimum. In der Systembewertung erfolgte eine Bewertung der Genauigkeit der Parameterschätzung auf einer Teststrecke auf Basis einer hochgenauen digitalen Karte und DGPS. Die erzielte Genauigkeit übertrifft die zu Beginn dieser Arbeit gestellten Anforderungen um ein Vielfaches. Dies bedeutet, dass ein System mit einem in Fahrtrichtung gerichteten Lidar für die automatisierte Querführung eines Fahrzeugs geeignet ist. Zusätzlich erfolgte eine theoretische Abschätzung der Verfügbarkeit einer lidarbasierten Fahrstreifen-erkennung in 16 EU Staaten und den USA. Für die untersuchten EU Staaten konnte eine theoretische Verfügbarkeit von 100% bei trockener Fahrbahnoberfläche ermittelt werden. Für die USA konnte keine allgemeingültige Aussage getroffen werden, da keine einheitlichen Mindestanforderungen an Fahrbahnmarkierungen existieren. Eine Einschränkung im Allgemeinen stellt die Überdeckung von Fahrbahnmarkierungen mit einem Wasserfilm dar. In diesem Fall ist davon auszugehen, dass eine Erkennung stark beeinträchtigt ist.

Aufbauend auf den vielversprechenden Erkenntnissen einer lidarbasierten Fahrstreifen-schätzung, erfolgte die Fusion mit einem kamerabasierten System. Primäres Ziel der Fusion war es, die Verfügbarkeit und die Robustheit eines allgemeinen Systems zur Fahrstreifen-erkennung durch Verwendung von Sensoren mit unterschiedlichen Messprinzipien zu steigern. In der Evaluierung konnte nachgewiesen werden, dass die Genauigkeit einer lidarbasierten Fahrstreifen-erkennung mit der eines kamerabasierten Systems vergleichbar ist und diese in der Ablage sogar übertrifft. Bei der Betrachtung der Verfügbarkeit beider Systeme konnte zudem gezeigt werden, dass eine lidarbasierte Erkennung mit 98.76% im Vergleich zu einem kamerabasierten System mit 97.65% sogar eine minimal bessere Erkennungsrate aufweist. Die bedeutendste Erkenntnis bei dieser Fusion ist jedoch, dass in den Fällen, in denen das videobasierte System keine gültigen Messwerte lieferte, diese durch das la-

serscannerbasierte System bereitgestellt werden konnten. Daraus lässt sich schlussfolgern, dass beide Systeme in den untersuchten Autobahnabschnitten eine diversitäre Redundanz bilden und eine Fusion aus Sicht der Verfügbarkeit sinnvoll ist.

Abschließend wurde ein histogrammbasiertes Verfahren zur robusten Fahrbahnranderkennung in Belegungskarten vorgestellt. Dieses bereits zuvor bei der Fahrstreifenschätzung angewendete iterative Optimierungsverfahren ermöglicht es, die Ablage, Krümmung und Ausrichtung mehrerer Fahrbahnbegrenzungen in Echtzeit zu erfassen. Der letzte Abschnitt der Systembewertung befasste sich daher mit der Evaluierung der Genauigkeit der Fahrbahnranderkennung. Die Bewertung der Genauigkeit erfolgte dabei wie bei der lidar- und videobasierten Fahrstreifenerkennung mit Hilfe eines Inertialen-Navigationssystems mit DGPS und einer hochgenauen digitalen Karte. Sowohl die lidar- als auch die radarbasierte Randbebauungserkennung erreichten eine sehr genaue Schätzung der Ablage sowie eine akzeptable Schätzung der Krümmung und Ausrichtung. Hervorzuheben ist dabei die erzielte Genauigkeit der radarbasierten Schätzung. Obwohl der Radarsensor über eine wesentlich schlechtere Entfernungsgenauigkeit und Winkelauflösung als der Laserscanner verfügt, konnte durch zeitliche Aggregation der Messwerte innerhalb einer Belegungskarte und durch geschickte Interpolation innerhalb des histogrammbasierten Verfahrens, die Genauigkeit über die eigentliche Messgenauigkeit des Radarsensors angehoben werden.

## 7.2 Wissenschaftlicher Beitrag

Ein wesentlicher Beitrag dieser Arbeit besteht in der gesamtheitlichen Betrachtung einer lidarbasierten Fahrstreifenerkennung im Kontext automatisierter Fahrfunktionen. Dies beinhaltet die Entwicklung eines neuen echtzeitfähigen histogrammbasierten Verfahrens zur Fahrstreifenschätzung und Klassifikation auf Basis einer probabilistischen Belegungskarte, die theoretische Abschätzung der Verfügbarkeit durch die Betrachtung des Leuchtdichtekoefizienten bei Retroreflexion in Kombination mit einem experimentellen Messaufbau, die Abschätzung der für eine lidarbasierte Fahrstreifenerkennung notwendigen intrinsischen und extrinsischen Sensorparametern sowie die Bestimmung der erzielbaren Genauigkeit im Vergleich zu einem videobasierten System und einer aus DGPS und einer hochgenauen digitalen Karte bestehenden Referenz.

Bei der Fusion der lidarbasierten mit einer videobasierten Fahrstreifenerkennung ist als Beitrag der Nachweis zu werten, dass ein kombinierter Einsatz beider Systeme eine diversitäre Redundanz bildet und die Ausfallsicherheit einer Fahrstreifenerkennung durch die Fusion beider System gesteigert werden kann.

In dem Kapitel zur effizienten Erstellung von Belegungskarten auf der GPU ist die Analyse der optimalen Parallelisierung auf SIMD Architekturen, die Erstellung polarer Belegungskarten auf der GPU unter Berücksichtigung von Sensoren mit mehreren vertikalen Messebenen, die Anwendung der anisotropen Filterung zur Verbesserung der Transformation der Polardarstellung auf eine kartesische Darstellung, die Fusion zu einer stationären Belegungskarte mit optimierten Speicherbedarf sowie die erste in der Literatur bekannte vollständige Berechnung von Belegungskarten auf der GPU auf Basis von reellen Sensor-

daten zu nennen.

Zusätzlich zu erwähnen ist die Anwendung des entwickelten histogrammbasierten Optimierungsverfahrens zur Schätzung der Ablage, Krümmung und Ausrichtung von Fahrbahnbegrenzungen in einer Belegungskarte auf Basis eines Laserscanners und bildgebenden Radars.

### 7.3 Ausblick

**Effiziente Berechnung von Belegungskarten** In dieser Arbeit wurde lediglich eine Umsetzung für einen Lidar- und Radarsensor betrachtet. Eine Erweiterung auf ein kamera-basiertes System, welches Distanz und Entfernungsinformationen in Form eines Disparitätsbildes liefert (Stereosystem), ist vorstellbar. Neben der Adaption des Verfahrens auf weitere Sensorgruppen, ist die Ersetzung der probabilistischen Belegungsinformation jeder Zelle durch einen Schätzwert für die Höhe (Elevation-Map) denkbar. Dies ist insbesondere dann sinnvoll, wenn ein Höhenprofil der Umgebung erstellt werden muss, um beispielsweise zwischen überfahrbaren und nicht überfahrbaren Bereichen zu unterscheiden. Ferner liegt eine Fusion von Belegungskarten unterschiedlicher Sensortypen nahe, beispielsweise Lidar mit Radar oder Radar mit Kamera, um individuelle sensorspezifische Eigenschaften (Dopplermessung bei Radar oder Höheninformation der Kamera) besser ausnutzen zu können und dadurch die Robustheit zu steigern.

**Lidarbasierte Fahrstreifenerkennung** Die Extraktion von Fahrbahnmarkierungen aus dem Histogramm und die logische Verknüpfung zu Fahrstreifen wurde in Kapitel 3.4.7 anhand eines kombinatorischen Ansatzes durchgeführt. Es ist jedoch durchaus denkbar, sowohl den Klassifikationsschritt als auch das Finden gültiger Fahrstreifen durch ein lernendes Verfahren, wie beispielsweise eine Support-Vector-Machine (SVM), zu ersetzen. Für eine erweiterte Abschätzung der Verfügbarkeit einer lidarbasierten Fahrstreifenerkennung ist es zudem notwendig, eine genauere Betrachtung anderer im Ausland zulässiger Markierungssysteme, wie beispielsweise „Retroreflective Raised Pavement Markers“ (RRPMs) oder „Botts’ dots“ (RPMs), vorzunehmen.

**Fusion von lidar- und videobasierter Fahrstreifenerkennung** Für eine High-Level Fusion einer lidarbasierten mit einer videobasierten Fahrstreifenerkennung ist es sinnvoll ein System zu betrachten, welches von Seiten des videobasierten Systems in der Lage ist, auch Fahrbahnmarkierungen benachbarter Fahrstreifen zu erkennen. Zudem ist eine zusätzliche Erweiterung der videobasierten Erkennung durch Integration einer Seiten- und Rückfahrkamera vorstellbar. In diesem Zusammenhang ist die Anwendung mehrerer paralleler Kalman-Filter zur Schätzung eines Systemzustands, wie beispielsweise das Multi-Hypothesen-Tracking (MHT), denkbar.

---

Koordinatentransformationen

---

WGS 84 → Gauss-Krüger konforme Koordinatentransformation [Sch82]:

$$\begin{aligned}\Delta L_a &= L_{a0} - L_a \\ \Delta L_o &= L_{o0} - L_o \\ x_f &= a_{10}\Delta L_a + a_{20}\Delta L_a^2 + a_{02}\Delta L_o^2 + a_{30}\Delta L_a^3 + a_{12}\Delta L_o^3 + a_{40}\Delta L_a^4 + \\ &\quad a_{22}\Delta L_a^2\Delta L_o^2 + a_{04}\Delta L_o^4 + a_{32}\Delta L_a^3\Delta L_o^2 + a_{14}\Delta L_a\Delta L_o^4\end{aligned}\quad (\text{A.1})$$

$$\begin{aligned}y_f &= a_{01}\Delta L_o + a_{11}\Delta L_a\Delta L_o + a_{21}\Delta L_a^2\Delta L_o + a_{03}\Delta L_o^3 + \\ &\quad a_{31}\Delta L_a^3\Delta L_o + a_{13}\Delta L_a\Delta L_o^3 + a_{41}\Delta L_a^4\Delta L_o + a_{23}\Delta L_a^2\Delta L_o^3 + \\ &\quad a_{05}\Delta L_o^5 + a_{33}\Delta L_a^3\Delta L_o^3\end{aligned}\quad (\text{A.2})$$

Gauss-Krüger → WGS 84 konforme Koordinatentransformation [Sch82]:

$$\begin{aligned}\Delta L_a &= b_{10}x_a + b_{20}x_a^2 + b_{02}y_a^2 + b_{30}x_a^3 + b_{12}x_a y_a^2 + b_{40}x_a^4 + b_{22}x_a^2 y_a^2 + \\ &\quad b_{04}y_a^4 + b_{32}x_a^3 y_a^2 + b_{14}x_a y_a^4 + b_{42}x_a^4 y_a^2 + b_{24}x_a^2 y_a^4 + b_{06}y_a^6\end{aligned}\quad (\text{A.3})$$

$$\begin{aligned}\Delta L_o &= l_{01}y_a + l_{11}x_a y_a + l_{21}x_a^2 y_a + l_{03}y_a^3 + l_{31}x_a^3 y_a + l_{13}x_a y_a^3 + \\ &\quad l_{41}x_a^4 y_a + l_{23}x_a^2 y_a^3 + l_{05}y_a^5 + l_{33}x_a^3 y_a^3 + l_{15}x_a y_a^5\end{aligned}\quad (\text{A.4})$$

$$L_a = L_{a0} + \Delta L_a$$

$$L_o = L_{o0} + \Delta L_o$$

Rotationsmatrix um die x-Achse:

$$R_x = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos \alpha & -\sin \alpha \\ 0 & \sin \alpha & \cos \alpha \end{bmatrix}\quad (\text{A.5})$$

Rotationsmatrix um die y-Achse:

$$R_x = \begin{bmatrix} \cos \alpha & 0 & -\sin \alpha \\ 0 & 1 & 0 \\ \sin \alpha & 0 & \cos \alpha \end{bmatrix} \quad (\text{A.6})$$

Rotationsmatrix um die z-Achse:

$$R_z = \begin{bmatrix} \cos \alpha & -\sin \alpha & 0 \\ \sin \alpha & \cos \alpha & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (\text{A.7})$$

Translationsmatrix:

$$T_l = \begin{bmatrix} 1 & 0 & x_f \\ 0 & 1 & y_f \\ 0 & 0 & 1 \end{bmatrix} \quad (\text{A.8})$$

## ANHANG B

### Tabellen

Szene	Autobahnabschnitt	Strecke (km)	Dauer (s)
1	A99 M-Neuherberg Richtung Stuttgart	9.48	277.84
2	A99 M-Neuherberg Richtung Stuttgart	3.99	120.96
3	A99 München Richtung Salzburg	7.06	203.20
4	A96 M-Sendling Richtung Lindau	6.20	242.56
5	A96 Germering Richtung Lindau	8.98	336.56
6	A952 Starnberg Richtung München	4.50	147.44
7	A95 Schäftlarn Richtung Garmisch	8.57	243.28
8	A95 Schäftlarn Richtung München	1.49	46.56
9	A95 Garmisch Richtung München	8.54	239.84
10	A8 Unterhaching Richtung Salzburg	9.10	286.16
11	A8 München Richtung Unterhaching	1.80	55.68
12	A99 Ottobrun Richtung Stuttgart (Südring)	4.33	117.04
13	A99 Ottobrun Richtung Stuttgart (Südring)	5.20	153.36
14	A99 Aschheim Richtung Stuttgart	6.08	182.08
15	A9 Garching Richtung München	6.43	197.06
16	A8 M-Allach Richtung Fürstenfeldbruck	7.54	213.35
17	A99 M-Neuherberg Richtung M-Allach	5.36	169.09

Tabelle B.1: Für die Evaluierung der Verfügbarkeit der Fahrstreifenerkennung untersuchte Straßenabschnitte.

	<b>Strecke</b>	<b>Dauer</b>	<b>Verfügbarkeit</b>	
	in km	in s	in s	in %
Szene 1	9.48	277.84	277.84	100.00
Szene 2	3.99	120.96	120.96	100.00
Szene 3	7.06	203.20	198.16	97.52
Szene 4	6.20	242.56	242.56	100.00
Szene 5	8.98	336.56	326.72	97.08
Szene 6	4.50	147.44	143.68	97.45
Szene 7	8.57	243.28	243.28	100.00
Szene 8	1.49	46.56	43.84	94.16
Szene 9	8.54	239.84	233.12	97.20
Szene 10	9.10	286.16	277.36	96.92
Szene 11	1.80	55.68	55.68	100.00
Szene 12	4.33	117.04	115.84	98.97
Szene 13	5.20	153.36	152.48	99.43
Szene 14	6.08	182.08	182.08	100.00
Szene 15	6.43	197.06	197.06	100.00
Szene 16	7.54	213.35	212.07	99.39
Szene 17	5.36	169.09	169.09	100.00
<b>Gesamt</b>	104.65	3232.1	3191.8	<b>98.76</b>

Tabelle B.2: Verfügbarkeit des eigenen Fahrstreifens (Abstand zur linken und rechten Markierung, Kurswinkel und Krümmung) bei der lidarbasierten Erkennung.

	Strecke in km	Dauer in s	Weniger Fahrstreifen detektiert		Alle Fahrstreifen detektiert	
			in s	in %	in s	in %
Szene 1	9.48	277.84	1.92	0.69	275.84	99.28
Szene 2	3.99	120.96	0.00	0.00	120.96	100.00
Szene 3	7.06	203.20	4.88	2.40	196.00	96.46
Szene 4	6.20	242.56	0.00	0.00	237.36	97.86
Szene 5	8.98	336.56	29.92	8.89	306.56	91.09
Szene 6	4.50	147.44	0.24	0.16	147.20	99.84
Szene 7	8.57	243.28	0.00	0.00	243.20	99.97
Szene 8	1.49	46.56	0.24	0.52	46.32	99.48
Szene 9	8.54	239.84	8.72	3.64	231.04	96.33
Szene 10	9.10	286.16	4.08	1.43	282.00	98.55
Szene 11	1.80	55.68	1.60	2.87	54.08	97.13
Szene 12	4.33	117.04	0.00	0.00	117.04	100.00
Szene 13	5.20	153.36	5.20	3.39	148.16	96.61
Szene 14	6.08	182.08	0.00	0.00	182.08	100.00
Szene 15	6.43	197.06	2.86	1.45	194.20	98.55
Szene 16	7.54	213.35	0.45	0.21	219.90	99.79
Szene 17	5.36	169.09	4.87	2.88	164.22	97.12
<b>Gesamt</b>	104.65	3232.1	64.98	<b>2.04</b>	3166.2	<b>97.96</b>

Tabelle B.3: Verfügbarkeit der vollständigen Anzahl an Fahrstreifen der lidarbasierten Fahrstreifenenerkennung.

	Strecke in km	Dauer in s	Video		Lidar		Fusion	
			in s	in %	in s	in %	in s	in %
Szene 1	9.48	277.84	277.28	99.80	277.84	100.00	277.84	100.00
Szene 2	3.99	120.96	120.72	99.80	120.96	100.00	120.96	100.00
Szene 3	7.06	203.20	200.48	98.66	198.16	97.52	203.20	100.00
Szene 4	6.20	242.56	241.44	99.54	242.56	100.00	242.56	100.00
Szene 5	8.98	336.56	333.28	99.03	326.72	97.08	336.56	100.00
Szene 6	4.50	147.44	146.72	99.51	143.68	97.45	147.44	100.00
Szene 7	8.57	243.28	242.48	99.67	243.28	100.00	243.28	100.00
Szene 8	1.49	46.56	46.24	99.31	43.84	94.16	46.56	100.00
Szene 9	8.54	239.84	238.56	99.47	233.12	97.20	239.84	100.00
Szene 10	9.10	286.16	284.80	99.52	277.36	96.92	286.16	100.00
Szene 11	1.80	55.68	55.52	99.71	55.68	100.00	55.68	100.00
Szene 12	4.33	117.04	116.64	99.66	115.84	98.97	117.04	100.00
Szene 13	5.20	153.36	153.04	99.79	152.48	99.43	153.36	100.00
Szene 14	6.08	182.08	181.68	99.78	182.08	100.00	182.08	100.00
Szene 15	6.43	197.06	195.23	99.07	197.06	100.00	197.06	100.00
Szene 16	7.54	213.35	211.49	99.13	212.07	99.39	213.35	100.00
Szene 17	5.36	169.09	110.65	65.44	169.09	100.00	169.09	100.00
<b>Gesamt</b>	104.65	3232.1	3156.2	<b>97.65</b>	3191.8	<b>98.76</b>	3232.1	<b>100.00</b>

Tabelle B.4: Verfügbarkeit des eigenen Fahrstreifens von der lidar- und videobasierten Fahrstreifenerkennung im Vergleich zu der Fusion beider Systeme.

1.1	Forschungsfahrzeug VaMoRs der UniBW München . . . . .	3
1.2	Siegerfahrzeuge Grand und Urban Challenge . . . . .	4
1.3	Leistungsfähigkeit eines Fahrers in Abhängigkeit zu dem Schwierigkeitsgrad einer Fahraufgab . . . . .	6
1.4	Manöver des Nothalteassistenten . . . . .	7
1.5	Wichtigste Systembausteine beim automatisierten Fahren . . . . .	8
1.6	Beispiel für durch externe Beleuchtungseinflüsse erzeugte schlechte Kontrastverhältnisse in 4 Videobildern . . . . .	10
1.7	Die Versuchsfahrzeuge „Caroline“ und „Leonie“ . . . . .	13
1.8	Versuchsfahrzeug der BMW Group Forschung und Technik. . . . .	14
2.1	Problematik bei der objektbasierten Repräsentation von zeitlich aufeinanderfolgenden Messungen bei komplexen Objektformen. . . . .	18
2.2	Moiré Effekt hervorgerufen durch ein auf dem Bresenham Algorithmus basierendem inversen Sensormodell. Die Belegungswahrscheinlichkeit der Zellen $p(m_i)$ ist als Graustufenbild kodiert, wobei $p(m_i) = 0$ als Weiß und $p(m_i) = 1$ als Schwarz dargestellt ist. . . . .	21
2.3	Vergleich der Architektur einer CPU mit einer GPU. . . . .	23
2.4	Logischer Aufbau der Compute Unified Device Architecture (CUDA) . . . . .	24
2.5	Logischer Aufbau des vorgestellten Frameworks Erstellung einer Belegungskarte. . . . .	26
2.6	Schematisierte polare Belegungskarte. . . . .	27
2.7	Verteilung der Wahrscheinlichkeiten innerhalb einer 1D Belegungskarte. . . . .	28
2.8	Aufteilung jeder eindimensionalen Belegungskarte $m'_k$ auf $N \times M$ Blöcke mit jeweils 256 Threads. . . . .	29
2.9	Mit simulierten Messwerten auf der GPU berechnete polare Belegungskarte. . . . .	29
2.10	Magnifikation und Minifikation. . . . .	30
2.11	Als Textur $T$ aufgefasste polare Belegungskarte $m'$ mit dem korrespondierenden Polygon $P$ im kartesischen Koordinatenraum. . . . .	31
2.12	Beispiel für die Erstellung von <i>Mip-Maps</i> . . . . .	32

2.13	Beispiel für eine temporäre kartesische Belegungskarte. . . . .	33
2.14	Vergleich der trilinearen mit der anisotropen Filtermethode. . . . .	35
2.15	Aufbau einer stationären Belegungskarte <b>m</b> . . . . .	37
2.16	Zusammenfassung der wesentlichen Schritte bei der Berechnung einer Belegungskarte auf der GPU. . . . .	38
2.17	Beispiel für eine auf der GPU mit Laserscannerdaten erstellte Belegungskarte in einem innerstädtischen Szenario. . . . .	39
2.18	Beispiel für eine mit einem mehrzeiligen Laserscanner erstellte Belegungskarte in einem Landstraßen- und in einem Autobahnszenario. . . . .	40
2.19	Beispiel für ein Amplituden- und Frequenzbild. . . . .	41
2.20	Beispiel für eine aus Amplitudenbildern erzeugte stationäre Belegungskarte. . . . .	42
3.1	Erste selbstfahrende Markiermaschine der Firma Baumbach aus Kassel und schlechte Sichtbarkeit von Fahrbahnmarkierungen in der Mitte des 20. Jahrhunderts. . . . .	45
3.2	Erläuterung von Spiegelung, diffuser Reflexion und Retroreflexion. . . . .	47
3.3	Beispiel für den Unterschied zwischen Lichtstärke und Beleuchtungsstärke. . . . .	48
3.4	Standardgeometrie zur Messung des Leuchtdichtekoeffizienten bei Retroreflexion. . . . .	49
3.5	Abbildung (a) zeigt die in der Farbe der Markierung eingebetteten Reflexperlen bei starker Vergrößerung. Abbildung (a) zeigt die Funktionsweise der Reflexperlen bei einfallendem Licht. . . . .	50
3.6	Beeinträchtigung der Funktionsweise von Typ I Markierungen bei Nässe. . . . .	51
3.7	Beispiel für zwei Agglomerat-Markierungen mit erhöhter Retroreflexion bei Nässe. . . . .	52
3.8	Aufnahme einer Typ II Agglomerat-Markierung bei Gegenlicht. . . . .	52
3.9	Darstellung der bedeutenden Größen zur Abtastung der Fahrbahnoberfläche mit einem Laserstrahl. . . . .	59
3.10	Beispiel für einen horizontalen Öffnungswinkel $\alpha_s$ von $100^\circ$ bei einer Winkelauflösung von $\vartheta_{\text{hor}} = 4^\circ$ und einer Strahldivergenz $\chi_{\text{hor}} = 2^\circ$ . . . . .	61
3.11	Darstellung der bedeutenden Größen für den vertikalen Erfassungsbereich. . . . .	62
3.12	Verwendetes Modell zur Beschreibung des Fahrstreifenverlaufs. . . . .	66
3.13	Erstes Beispiel für eine Belegungskarte mit Bodenpunkten. . . . .	73
3.14	Zweites Beispiel für eine Belegungskarte mit Bodenpunkten. . . . .	73
3.15	Drittes Beispiel für eine Belegungskarte mit Bodenpunkten. . . . .	74
3.16	Viertes Beispiel für eine Belegungskarte mit Bodenpunkten. . . . .	74
3.17	Fehler in der Ablage $e_y$ bei einer Distanz von bis zu 30 m. . . . .	77
3.18	Die Abbildung zeigt die wichtigsten Zusammenhänge bei der Berechnung eines beliebigen Histogramms $H_i$ . . . . .	78
3.19	Auswirkungen eines additiven Fehlers in der Krümmung auf das optimale Histogramm. . . . .	79
3.20	Auswirkungen eines additiven Fehlers in der Ausrichtung auf das optimale Histogramm. . . . .	80

3.21	Die quadratische Summe im Vergleich zur Entropie. . . . .	81
3.22	Beispiel für die Auswertung des Gütefunktional $q(H_i)$ in einem vordefinierten Intervall. . . . .	82
3.23	Beispiel für die einzelnen Schritte bei dem Nelder-Mead-Simplex Verfahren. . . . .	85
3.24	Fahrbahnmarkierungshypothesen im Histogramm . . . . .	87
3.25	Autoleistungsspektrum von synthetischen Rechteckfunktionen mit überlagertem gaußschen Rauschen. . . . .	89
3.26	Drei Beispiele für eine erfolgreiche Fahrstreifendetektion und Klassifikation aller Fahrbahnmarkierungen. . . . .	94
4.1	Schematisierter Aufbau der Fusion zwischen der lidar- und videobasierten Fahrstreifenerkennung. . . . .	96
4.2	Zusammenhang der im Zustandsvektor $\tilde{\mathbf{x}}$ modellierten Größen: Ablage zur Fahrstreifenmitte, Kurswinkel, Krümmung und Fahrstreifenbreite. . . . .	98
4.3	Dynamikmodell des Eigenfahrzeugs in Relation zur Solltrajektorie. . . . .	99
4.4	Modellierte Abstände zu den Markierungen weiterer Fahrstreifen. . . . .	103
5.1	Modell zur Beschreibung von Fahrbahnbegrenzungen. . . . .	107
5.2	Beispiel für die Aufteilung einer Belegungskarte in ein „linkes“ und „rechtes“ Histogramm. . . . .	107
5.3	Zu Abbildung 5.2 korrespondierendes optimales linkes Histogramm $H_{\text{opt}}^{\text{left}}$ in (a) und optimales rechtes Histogramm $H_{\text{opt}}^{\text{right}}$ in (b). . . . .	108
5.4	Beispiel für die Erkennung der linken und rechten Randbebauung mit fast identischer Krümmung und Ausrichtung. . . . .	110
5.5	Beispiel für die Erkennung der linken Randbebauung. Die rechte Hypothese wurde aufgrund der großen lateralen Streuung der Messwerte wieder verworfen. . . . .	110
5.6	Beispiel für die Erkennung der linken und zwei rechter Randbebauungen mit sich unterscheidender Krümmung und Ausrichtung. . . . .	110
6.1	Verwendetes Fahrzeugkoordinatensystem. . . . .	112
6.2	Umfelderfassende Sensorik des Versuchsträgers. . . . .	113
6.3	Anbauorte der fahrumfelderfassenden Sensorik. . . . .	114
6.4	Horizontaler Erfassungsbereich der Sensorik. . . . .	115
6.5	Systemarchitektur mit Kontrollfluss. . . . .	117
6.6	DGPS gestütztes Inertiales-Navigationssystem RT3003 der Firma „Oxford Technical Solutions“ und Leica Messplattform GPS1200 . . . . .	119
6.7	Messaufbau zur Überprüfung der Mindestanforderungen an die Retroreflexion . . . . .	122
6.8	Die im Messaufbau verwendeten Prüfstreifen . . . . .	123
6.9	Reflectometer der Firma Zehntner . . . . .	124
6.10	Überführung von europäischen Normen (EN) in DIN Normen und Ableiten nationaler Verwaltungsvorschriften. . . . .	125
6.11	Raised Pavement Markers . . . . .	128

6.12	Streckenverlauf der für die Evaluierung verwendeten Teststrecke. . . . .	130
6.13	Referenzstrecke zur Evaluierung der Fahrstreifenerkennung. . . . .	131
6.14	Vergleich der Ablage zu der auf DGPS und hochgenauen digitalen Karten basierten Referenz. . . . .	132
6.15	Vergleich des Kurswinkels zu der auf DGPS und hochgenauen digitalen Kar- ten basierten Referenz. . . . .	133
6.16	Vergleich der Krümmung zu der auf DGPS und hochgenauen digitalen Kar- ten basierten Referenz. . . . .	133
6.17	Exemplarischer Ausschnitt für den Vergleich der Ablage bei variierender Zellgröße. . . . .	138
6.18	Exemplarischer Ausschnitt für den Vergleich des Kurswinkel bei variierender Zellgröße. . . . .	138
6.19	Exemplarischer Ausschnitt für den Vergleich der Krümmung bei variierender Zellgröße. . . . .	139
6.20	Laufzeit $t$ der histogrammbasierten Fahrstreifenschätzung bei variierender Zellgröße. . . . .	140
6.21	Trajektorie zur Ermittlung des Systemrauschens. . . . .	142
6.22	Übersicht über Prädiktion und Messupdate im zyklischen Framework . . .	144
6.23	Bestimmung der Sensorlatenzzeiten am Beispiel der zweiten Testfahrt durch die Betrachtung der Phasenverschiebung in der Kreuzkorrelation. . . . .	146
6.24	Vergleich der Ablage der Fusion und der lidar- und videobasierten Erken- nung zu der auf DGPS und hochgenauen digitalen Karte basierten Referenz.	147
6.25	Vergleich des Kurswinkels der Fusion und der lidar- und videobasierten Er- kennung zu der auf DGPS und hochgenauen digitalen Karte basierten Re- ferenz. . . . .	147
6.26	Vergleich der Krümmung der Fusion, der lidar- und videobasierten Erken- nung zu der auf DGPS und hochgenauen digitalen Karte basierten Referenz.	148
6.27	Zur Referenzierung verwendete steckbare Baustellenbegrenzungen. . . . .	152
6.28	Histogrammbasierte Erkennung der zu einer Randbebauung zusamme- gefügt modularen Baustellenbegrenzungen mit einen Laserscanner und ei- nem Radarsensor. . . . .	153
6.29	Vergleich der ermittelten Ablage der histogrammbasierten Fahrbahnrand- erkennung zu der auf DGPS und hochgenauen digitalen Karte basierten Re- ferenz. . . . .	153
6.30	Vergleich des ermittelten Kurswinkels $\psi$ der histogrammbasierten Fahrbahn- randerkennung zu der auf DGPS und hochgenauen digitalen Karte basierten Referenz. . . . .	154
6.31	Vergleich der ermittelten Krümmung der histogrammbasierten Fahrbahn- randerkennung zu der auf DGPS und hochgenauen digitalen Karte basierten Referenz. . . . .	154
6.32	Laufzeitanalyse in Abhängigkeit der Größe einer Belegungskarte und der Leistung einer GPU für drei unterschiedliche Sensoren. . . . .	157

6.33	Detaillierte Laufzeitanalyse für Laserscanner 1 in Abhängigkeit der Größe einer Belegungskarte. Links die Ergebnisse für eine Belegungskarte mit $512 \times 512$ Zellen und rechts mit $256 \times 256$ Zellen. . . . .	158
6.34	Detaillierte Laufzeitanalyse für Laserscanner 2 in Abhängigkeit der Größe einer Belegungskarte. Links die Ergebnisse für eine Belegungskarte mit $512 \times 512$ Zellen und rechts mit $256 \times 256$ Zellen. . . . .	158
6.35	Detaillierte Laufzeitanalyse für den Radarsensor in Abhängigkeit der Größe einer Belegungskarte. Links die Ergebnisse für eine Belegungskarte mit $512 \times 512$ Zellen und rechts mit $256 \times 256$ Zellen. . . . .	159



---

## Tabellenverzeichnis

---

1.1	Geforderte Genauigkeit in der Ablage, Ausrichtung und Krümmung. . . . .	15
3.1	Vergleich der in der Literatur existierenden Verfahren zur lidarbasierten Fahrstreifenerkennung. . . . .	68
3.2	Betrachtung des relativen Krümmungsfehlers des i-ten Fahrstreifens bei variierender Entwurfsgeschwindigkeit. . . . .	76
6.1	Messergebnisse des „Leuchtdichtekoeffizienten bei Retroreflexion“ für die 3 Testmarkierungen. . . . .	124
6.2	Nachtsichtbarkeitsklassen trocken nach EN 1436 [din]. . . . .	126
6.3	Anforderungen an die Nachtsichtbarkeit von Fahrbahnmarkierungen in Europa [Die07]. . . . .	127
6.4	Empfehlungen für $R_L$ in Abhängigkeit der zulässigen Höchstgeschwindigkeit [U.S07]. . . . .	127
6.5	Nachtsichtbarkeitsklassen bei Nässe nach EN 1436 [din]. . . . .	129
6.6	Anforderungen an die Nachtsichtbarkeit von Fahrbahnmarkierungen in Europa bei nasser Fahrbahn [Die07]. . . . .	130
6.7	Fehlerauswertung der lidarbasierten Fahrstreifenerkennung im Vergleich zu den in Kapitel 1.2.2 definierten Anforderungen an die Genauigkeit. . . . .	132
6.8	Verfügbarkeit des eigenen Fahrstreifens. . . . .	135
6.9	Verfügbarkeit aller Fahrstreifen . . . . .	136
6.10	Auswertung der Standardabweichung im Vergleich zur Referenz. . . . .	137
6.11	Maximale Änderung pro Zeitschritt $\Delta e_{\max}$ und empirisch ermitteltes Systemrauschen $\sigma_x$ . . . . .	143
6.12	Empirisch ermitteltes Messrauschen. . . . .	143
6.13	Länge, Dauer und Durchschnittsgeschwindigkeit der für die Bestimmung der Sensorlatenzzeiten verwendeten Testfahrten. . . . .	145
6.14	Durch die Kreuzkorrelation ermittelte Latenzzeit für das lidar- und videobasierte System. . . . .	145

6.15	Fehlerauswertung der Fusion im Vergleich zur Referenz und dem video- und lidarbasierten System. . . . .	148
6.16	Verfügbarkeit des eigenen Fahrstreifens von der lidar- und videobasierte Fahrstreifenerkennung im Vergleich zu der Fusion beider Systeme. . . . .	150
6.17	Fehlerabschätzung der histogrammbasierten Fahrbahnranderkennung. . . . .	152
B.1	Für die Evaluierung der Verfügbarkeit der Fahrstreifenerkennung untersuchte Straßenabschnitte. . . . .	167
B.2	Verfügbarkeit des eigenen Fahrstreifens bei der lidarbasierten Erkennung. . . . .	168
B.3	Verfügbarkeit aller Fahrstreifen . . . . .	169
B.4	Verfügbarkeit des eigenen Fahrstreifens von der lidar- und videobasierten Fahrstreifenerkennung im Vergleich zu der Fusion beider Systeme. . . . .	170

- [AWK<sup>+</sup>10] ARDELT, M. ; WALDMANN, P. ; KÄMPCHEN, N. ; HOMM, F. ; AEBERHARD, M.: Fully Automatic Lane Change Maneuvers for Advanced Safety Systems in Complex Traffic Situations. In: *Proc. of the 19th Aachen Colloquium Automobile and Engine Technology*" Bd. 1, 2010, S. 867–893
- [AWKH10] ARDELT, M. ; WALDMANN, P. ; KÄMPCHEN, N. ; HOMM, F.: Strategic Decision-Making Process in Advanced Driver Assistance Systems. In: *Proc. of the International Federation of Automatic Control (IFAC) Symposium on Advances in Automotive Control*, 2010
- [HDK<sup>+</sup>10] HOMM, F. ; DUDA, A. ; KÄMPCHEN, N. ; WALDMANN, P. ; ARDELT, M.: Lidar-basierte Fahrstreifen- und Randbebauungserkennung mit Occupancy Grids für Spurhalte- und Spurwechselfunktionen. In: *4. Tagung Sicherheit durch Fahrerassistenz*, 2010
- [HKB11] HOMM, F. ; KAEMPCHEN ; BURSCHKA, D.: Fusion of Laserscanner and Video Based Lanemarking Detection for Robust Lateral Vehicle Control and Lane Change Maneuvers. In: *Intelligent Vehicles Symposium (IV), 2011 IEEE*, 2011
- [HKOB10] HOMM, F. ; KAEMPCHEN, N. ; OTA, J. ; BURSCHKA, D.: Efficient occupancy grid computation on the GPU with lidar and radar for road boundary detection. In: *Intelligent Vehicles Symposium (IV), 2010 IEEE*, 2010. – ISSN 1931–0587, S. 1006 –1013
- [KHWA10] KAEMPCHEN, N. ; HOMM, F. ; WALDMANN, P. ; ARDELT, M.: Umfelderkennung für den Nothalteassistenten - Ein System zum automatischen Anhalten bei plötzlich reduzierter Fahrfähigkeit des Fahrers. In: *11. Braunschweiger Symposium, AAET 2010*, 2010
- [WKAH10] WALDMANN, P. ; KÄMPCHEN, N. ; ARDELT, M. ; HOMM, F.: The emergency stop assistant - secured stop in case of abrupt health related loss of control by the driver. In: *3. Deutscher AAL-Kongress*, 2010



- [Dud09] DUDA, Alexander: *Laserscanner basierte Fahrstreifen- und Randbebauungserkennung zur GPS gestützten Lokalisation in einer hochgenauen digitalen Karte*, Technische Universität Darmstadt, Fachbereich Elektrotechnik und Informationstechnik, Diplomarbeit, 2009
- [Ulr10] ULRICH, Holger: *Fusion von video- und laserscannerbasierter Fahrspur- und Fahrbahnranderkennung zur robusten Eigenfahrzeuglokalisierung in Kombination mit Navigationskarten und GPS*, Karlsruher Institut für Technologie (KIT), Fakultät für Elektrotechnik und Informationstechnik, Diplomarbeit, 2010



- [3M] 3M Solutions GmbH. <http://solutions.3mdeutschland.de/>.
- [Alt02] ALT, WALTER: *Nichtlineare Optimierung: Eine Einführung in Theorie, Verfahren und Anwendungen*. Vieweg+Teubner, 2002.
- [AMHH08] AKENINE-MÖLLER, TOMAS, ERIC HAINES und NATTY HOFFMAN: *Real-Time Rendering 3rd Edition*. A. K. Peters, Ltd., Natick, MA, USA, 2008.
- [And09] ANDERT, F.: *Drawing stereo disparity images into occupancy grids: Measurement model and fast implementation*. In: *Intelligent Robots and Systems, 2009. IROS 2009. IEEE/RSJ International Conference on*, Seiten 5191 – 5197, 2009.
- [BA10] BAIG, Q. und O. AYCARD: *Low level data fusion of laser and monocular color camera using occupancy grid framework*. In: *Control Automation Robotics Vision (ICARCV), 2010 11th International Conference on*, Seiten 905 – 910, dec. 2010.
- [bas] Bundesanstalt für Straßenwesen (BASt). <http://www.bast.de/>.
- [BB98] BERTOZZI, M. und A. BROGGI: *GOLD: a parallel real-time stereo vision system for generic obstacle and lane detection*. *Image Processing, IEEE Transactions on*, 7(1):62 – 81, Januar 1998. 8
- [BB05] BENDER, MICHAEL und MANFRED BRILL: *Computergrafik: Ein anwendungsorientiertes Lehrbuch*. Carl Hanser Verlag GmbH, 2. Auflage Auflage, 2005.
- [BC11] BROWN, J. und D. CAPSON: *A Framework for 3D Model-Based Visual Tracking Using a GPU-Accelerated Particle Filter*. *Visualization and Computer Graphics, IEEE Transactions on*, PP(99):1, 2011.

- [BFM07] BADINO, HERNAN, UWE FRANKE, und RUDOLF MESTER.: *Free Space Computation Using Stochastic Occupancy Grids and Dynamic Programming*. In: *Dynamic Vision Workshop for ICCV*, 2007.
- [BGFM07] BLANCO, JOSE-LUIS, JAVIER GONZALEZ und JUAN-ANTONIO FERNANDEZ-MADRIGAL: *A New Method for Robust and Efficient Occupancy Grid-Map Matching*. In: *IbPRIA '07: Proceedings of the 3rd Iberian conference on Pattern Recognition and Image Analysis, Part II*, Seiten 194–201, Berlin, Heidelberg, 2007. Springer-Verlag.
- [BH10] BOUZOURAA, M.E. und U. HOFMANN: *Fusion of occupancy grid mapping and model based object tracking for driver assistance systems using laser and radar sensors*. In: *Intelligent Vehicles Symposium (IV), 2010 IEEE*, Seiten 294 –300, june 2010.
- [Bis07] BISHOP, CHRISTOPHER M.: *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Springer, 1st ed. 2006. Corr. 2nd printing Auflage, Oktober 2007.
- [BL02] BEYERER, JÜRGEN und FERNANDO P. LEÓN: *Die Radontransformation in der digitalen Bildverarbeitung*. *Automatisierungstechnik* 50, Nr. 10, 2002., 50(10), 2002.
- [BP99] BLACKMAN, SAMUEL und ROBERT POPOLI: *Design and Analysis of Modern Tracking Systems*. Artech House, 1999.
- [BR08] BERGER, CHRISTIAN und BERNHARD RUMPE: *Autonomes Fahren - Erkenntnisse aus der DARPA Urban Challenge (Autonomous Driving - Insights from the DARPA Urban Challenge)*. *it - Information Technology*, Seiten 258–264, 2008. 4
- [Bre65] BRESENHAM, J. E.: *Algorithm for computer control of a digital plotter*. *IBM Syst. J.*, 4:25–30, March 1965.
- [BS87] BAR-SHALOM, Y.: *Tracking and data association*. 1987.
- [BU10] BRINKSCHULTE, UWE und THEO UNGERER: *Mikrocontroller und Mikroprozessoren (eXamen.Press)*. Springer, 3. Aufl Auflage, 2010.
- [Cra05] CRAMER, HEIKO: *Modelle zur multisensoriellen Erfassung des Fahrzeugumfeldes mit Hilfe von Schätzverfahren*. Doktorarbeit, Technische Universität Chemnitz, 2005.
- [CTLM06] CHEN, C., C. TAY, C. LAUGIER und K. MEKHNACHA: *Dynamic Environment Modeling with Gridmap: A Multiple-Object Tracking Application*. In: *Proc. 9th International Conference on Control, Automation, Robotics and Vision ICARCV '06*, Seiten 1–6, 5–8 Dec. 2006.

- [CVG08] CORNELIS, NICO und LUC VAN GOOL: *Fast scale invariant feature detection and matching on programmable graphics hardware*. In: *2008 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, Seiten 1–8. IEEE, Juni 2008.
- [DBD<sup>+</sup>94] DICKMANN, E. D., R. BEHRINGER, D. DICKMANN, T. HILDEBRANDT, M. MAURER, F. THOMANEK und J. SCHIEHLEN: *The seeing passenger car 'VaMoRs-P'*. In: *Intelligent Vehicles '94 Symposium, Proceedings of the*, Oktober 1994. 3, 8
- [Die07] DIE DEUTSCHE STUDIENGESELLSCHAFT FÜR STRASSENMARKIERUNGEN E.V. (DSGS): *DSGS-Jahrbuch Fahrbahnmarkierung 2006/2007*, 2007.
- [din] DIN - Deutsches Institut für Normung e.V. <http://www.din.de/>.
- [DKF<sup>+</sup>05] DIETMAYER, K., N. KÄMPCHEN, K. FÜRSTENBERG, J. KIBBEL, W. JUSTUS und R. SCHULZ: *Roadway Detection and Lane Detection using Multilayer Laserscanner*. In: VALLDORF, JÜRGEN und WOLFGANG GESSNER (Herausgeber): *Advanced Microsystems for Automotive Applications 2005*, VDI-Buch, Seiten 197–213. Springer Berlin Heidelberg, 2005. dietmayer. 9
- [DKL10] DARMS, M., M. KOMAR und S. LUEKE: *Map based road boundary estimation*. In: *Intelligent Vehicles Symposium (IV), 2010 IEEE*, Seiten 609–614, 2010.
- [DM92] DICKMANN, ERNST D. und BIRGER D. MYSLIWETZ: *Recursive 3-D Road and Relative Ego-State Recognition*. *IEEE Trans. Pattern Anal. Mach. Intell.*, 14:199–213, February 1992. 8
- [DN09] DANESCU, R. und S. NEDEVSCHI: *Probabilistic Lane Tracking in Difficult Road Scenarios Using Stereovision*. *Intelligent Transportation Systems, IEEE Transactions on*, 10(2):272–282, 2009. 8
- [DSNG06] DANESCU, R., S. SOBOL, S. NEDEVSCHI und T. GRAF: *Stereovision-based side lane and guardrail detection*. In: *Intelligent Transportation Systems Conference, 2006. ITSC '06. IEEE*, Seiten 1156–1161, 2006.
- [Eff09] EFFERTZ, JAN: *Autonome Fahrzeugführung in urbaner Umgebung durch Kombination objekt- und kartenbasierter Umfeldmodelle*. Doktorarbeit, Fakultät für Elektrotechnik, Informationstechnik, Physik an der Technischen Universität Carolo-Wilhelmina zu Braunschweig, 2009.
- [Elf89] ELFES, A.: *Occupancy Grids: a probabilistic framework for robot perception and navigation*. Doktorarbeit, Carnegie Mellon University, 1989.
- [For95] FORSCHUNGSGESELLSCHAFT FÜR STRASSEN- UND VERKEHRSWESEN: *Richtlinien für die Anlage von Straßen RAS*, 1995.

- [For08] FORSCHUNGSGESELLSCHAFT FÜR STRASSEN- UND VERKEHRSWESEN: *Richtlinien für die Anlage von Autobahnen (RAA)*, 2008.
- [Für04] FÜRSTENBERG, K. DIETMAYER, K.: *Fahrzeugumfelderfassung mit mehrzeiligen Laserscannern*. In: *Journal Technisches Messen* 71, 2004.
- [FSCW03] FARDI, B., U. SCHEUNERT, H. CRAMER und G. WANIELIK: *Multi-modal detection and parameter-based tracking of road borders with a laser scanner*. In: *Intelligent Vehicles Symposium, 2003. Proceedings. IEEE*, Seiten 95 – 99, 2003.
- [FZ10] FELISA, M. und P. ZANI: *Robust monocular lane detection in urban environments*. In: *Intelligent Vehicles Symposium (IV), 2010 IEEE*, Seiten 591 –596, 2010.
- [GAVA08] GARCIA, R., O. AYCARD, TRUNG-DUNG VU und M. AHRHOLDT: *High level sensor data fusion for automotive applications using occupancy grids*. In: *Control, Automation, Robotics and Vision, 2008. ICARCV 2008. 10th International Conference on*, Seiten 530 –535, dec. 2008.
- [GHT<sup>+</sup>10] GACKSTATTER, C., P. HEINEMANN, S. THOMAS, B. ROSENHAHN und G. KLINKER: *Fusion of Clothoid Segments for a More Accurate and Updated Prediction of the Road Geometry*. In: *13th International IEEE Conference on Intelligent Transportation Systems (ITSC 10)*, Madeira, Sep 2010. IEEE.
- [GMM09] GUO, CHUNZHAO, S. MITA und D. MCALLESTER: *Stereovision-based road boundary detection for intelligent vehicles in challenging scenarios*. In: *Intelligent Robots and Systems, 2009. IROS 2009. IEEE/RSJ International Conference on*, Seiten 1723 –1728, 2009.
- [goo10] *Google Cars Drive Themselves in Traffic*. <http://www.nytimes.com/2010/10/10/science/10google.html?pagewanted=all>, Oktober 2010. 5
- [GSB05] GRISETTIYZ, G., C. STACHNISS und W. BURGARD: *Improving Grid-based SLAM with Rao-Blackwellized Particle Filters by Adaptive Proposals and Selective Resampling*. In: *Proc. IEEE International Conference on Robotics and Automation ICRA 2005*, Seiten 2432–2437, 18–22 April 2005.
- [HB08] HANKE-BOURGEOIS, MARTIN: *Grundlagen der Numerischen Mathematik und des Wissenschaftlichen Rechnens*. Vieweg+Teubner, 2008.
- [HJ61] HOOKE, ROBERT und T. A. JEEVES: “ *Direct Search*” *Solution of Numerical and Statistical Problems*. J. ACM, 8:212–229, April 1961.
- [HN10] HALLER, I. und S. NEDEVSCHI: *GPU optimization of the SGM stereo algorithm*. In: *Intelligent Computer Communication and Processing (ICCP), 2010 IEEE International Conference on*, Seiten 197 –202, aug. 2010.

- [HvW08] HIMMELSBACH, MICHAEL, FELIX VON HUNDELSHAUSEN und HANS-JOACHIM WÜNSCHE: *LIDAR-Based Perception for Offroad Navigation*. In: *Proceedings of FAS 2008, Fahrerassistenzsysteme Workshop 2008*, Walting, Germany, April 2008. C. Stiller and M. Maurer.
- [Jäh05] JÄHNE, BERND: *Digitale Bildverarbeitung*. Springer, 6., überarb. u. erw. Aufl Auflage, 2005.
- [KAKC10] KUK, JUNG GAP, JAE HYUN AN, HOYONG KI und NAM IK CHO: *Fast lane detection amp; tracking based on Hough transform with reduced memory requirement*. In: *Intelligent Transportation Systems (ITSC), 2010 13th International IEEE Conference on*, Seiten 1344 –1349, 2010.
- [Kal60] KALMAN, RUDOLPH EMIL: *A New Approach to Linear Filtering and Prediction Problems*. *Transactions of the ASME - Journal of Basic Engineering*, 82(Series D):35–45, 1960.
- [KGWB07] KODAGODA, K.R.S., S.S. GE, W.S. WIJESOMA und A.P. BALASURIYA: *IMMPDAF Approach for Road-Boundary Tracking*. *Vehicular Technology, IEEE Transactions on*, 56(2):478 –486, 2007.
- [KHS<sup>+</sup>08] KACZMARCZYK, CHRISTEL, HARALD, PETRA STRUPP, JÜRGEN SCHMIDT und ARNE SCHMIDT: *Bautechnik für Bauzeichner: Zeichnen - Rechnen - Fachwissen*. Vieweg+Teubner, 2008.
- [Kim08] KIM, ZUWHAN: *Robust Lane Detection and Tracking in Challenging Scenarios*. *Intelligent Transportation Systems, IEEE Transactions on*, 9(1):16 –26, 2008. 8
- [KJF05] KIBBEL, J., W. JUSTUS und K. FÜRSTENBERG: *Lane Estimation and Departure Warning using Multilayer Laserscanner*. In: *Proceedings of the 8th International IEEE Conference on Intelligent Transportation Systems*, 2005.
- [KLT03] KOLDA, TAMARA G., ROBERT MICHAEL LEWIS und VIRGINIA TORCZON: *Optimization by direct search: New perspectives on some classical and modern methods*. *SIAM Review*, 45:385–482, 2003.
- [KM10] KALAROT, R. und J. MORRIS: *Comparison of FPGA and GPU implementations of real-time stereo vision*. In: *Computer Vision and Pattern Recognition Workshops (CVPRW), 2010 IEEE Computer Society Conference on*, Seiten 9 –15, june 2010.
- [Kom08] KOMPASS, KLAUS: *Fahrerassistenzsysteme der Zukunft - auf dem Weg zum autonomen Pkw?* In: SCHINDLER, VOLKER (Herausgeber): *Forschung für das Auto von Morgen*, Seiten 261–285. Springer Berlin Heidelberg, 2008. 1, 5

- [Kon97] KONOLIGE, KURT: *Improved Occupancy Grids for Map Building*. *Auton. Robots*, 4(4):351–367, 1997.
- [KP08] KAMMEL, S. und B. PITZER: *Lidar-based lane marker detection and mapping*. In: *Intelligent Vehicles Symposium, 2008 IEEE*, Seiten 1137–1142, June 2008. 9
- [KSD10] KONRAD, M., M. SZCZOT und K. DIETMAYER: *Road course estimation in occupancy grids*. In: *Intelligent Vehicles Symposium (IV), 2010 IEEE*, Seiten 412 –417, june 2010.
- [Lan06] LANGE, NORBERT: *Geoinformatik in Theorie und Praxis*, 2006.
- [LB09] LIENKAMP, M. und A. BARTELS: *Automatisches Fahren: Logische Konsequenz der Assistenzsysteme oder Utopie?* In: *1. Automobiltechnisches Kolloquium, TU München*, 2009. 5, 6, 4
- [LDG<sup>+</sup>10] LATEGAHN, H., W. DERENDARZ, T. GRAF, B. KITT und J. EFFERTZ: *Occupancy grid computation from dense stereo and sparse structure and motion points for automotive applications*. In: *Intelligent Vehicles Symposium (IV), 2010 IEEE*, Seiten 819 –824, june 2010.
- [lei] *LeicaGeo Systems*. <http://www.leica-geosystems.com/de/>.
- [LFS09] LOOSE, H., U. FRANKE und C. STILLER: *Kalman Particle Filter for lane recognition on rural roads*. In: *Intelligent Vehicles Symposium, 2009 IEEE*, Seiten 60 –65, 2009.
- [LHK11] LATEGAHN, H., C. HASBERG und J. KITT, B.AND EFFERTZ: *Mapping in Dynamic Environments Using Stereo Vision*. In: *Intelligent Vehicles Symposium (IV), 2011 IEEE*, 2011.
- [Lin09] LINDL, RUDI: *Tracking von Verkehrsteilnehmern im Kontext von Multisensorsystemen*. Suedwestdeutscher Verlag fuer Hochschulschriften, 2009.
- [LK01] LEE, SUKHAN und WOONG KWON: *Robust lane keeping from novel sensor fusion*. In: *Robotics and Automation, 2001. Proceedings 2001 ICRA. IEEE International Conference on*, Band 4, Seiten 3704 – 3709 vol.4, 2001.
- [LLWJ10] LIANG, SHENSHEN, YING LIU, CHENG WANG und LIHENG JIAN: *Design and evaluation of a parallel k-nearest neighbor algorithm on CUDA-enabled GPU*. In: *Web Society (SWS), 2010 IEEE 2nd Symposium on*, Seiten 53 –60, aug. 2010.
- [LMT07] LEVINSON, J., M. MONTEMERLO und S. THRUN: *Map-based precision vehicle localization in urban environments*. In: *Proceedings of the Robotics: Science and Systems Conference*, 2007.

- [LOG11] LUNDQUIST, C., U. ORGUNER und F. GUSTAFSSON: *Extended Target Tracking Using Polynomials With Applications to Road-Map Estimation*. Signal Processing, IEEE Transactions on, 59(1):15–26, 2011.
- [LRW<sup>+</sup>09] LINDNER, P., E. RICHTER, G. WANIELIK, K. TAKAGI und A. ISOGAI: *Multi-channel lidar processing for lane detection and estimation*. In: *Intelligent Transportation Systems, 2009. ITSC '09. 12th International IEEE Conference on*, Seiten 1–6, 2009. 9
- [LRWW98] LAGARIAS, JEFFREY C., JAMES A. REEDS, MARGARET H. WRIGHT und PAUL E. WRIGHT: *Convergence Properties of the Nelder-Mead Simplex Method in Low Dimensions*. SIAM Journal of Optimization, 9:112–147, 1998.
- [LSB<sup>+</sup>08] LIPSKI, CHRISTIAN, BJORN SCHOLZ, KAI BERGER, CHRISTIAN LINZ, TIMO STICH und MARCUS MAGNOR: *A Fast and Robust Approach to Lane Marking Detection and Lane Tracking*. In: *Proceedings of the 2008 IEEE Southwest Symposium on Image Analysis and Interpretation*, Seiten 57–60, Washington, DC, USA, 2008. IEEE Computer Society. 8
- [LT10] LEVINSON, J. und S. THRUN: *Robust vehicle localization in urban environments using probabilistic maps*. In: *Robotics and Automation (ICRA), 2010 IEEE International Conference on*, Seiten 4372–4378. IEEE, 2010.
- [LWGE10] LATEGAHN, H., A. WEGE, T. GRAF und J. ANDKITT. B. EFFERTZ: *Schnelle Berechnung von detaillierten Belegungsgittern aus dichten Stereodisparitätsbildern*. In: *4. Tagung Sicherheit durch Fahrerassistenz*, 2010.
- [MBB<sup>+</sup>08] MONTEMERLO, MICHAEL, JAN BECKER, SUHRID BHAT, HENDRIK DAHLKAMP, DMITRI DOLGOV, SCOTT ETTINGER, DIRK HAEHNEL, TIM HILDEN, GABE HOFFMANN, BURKHARD HUHNKE, DOUG JOHNSTON, STEFAN KLUMPP, DIRK LANGER, ANTHONY LEVANDOWSKI, JESSE LEVINSON, JULIEN MARCIL, DAVID ORENSTEIN, JOHANNES PAEFGEN, ISAAC PENNY, ANNA PETROVSKAYA, MIKE PFLUEGER, GANYMED STANEK, DAVID STAVENS, ANTONE VOGT und SEBASTIAN THRUN: *Junior: The Stanford entry in the Urban Challenge*. J. Field Robot., 25:569–597, September 2008. 4
- [MD09] M. DARMS, M. KOMAR, S. LÜKE: *Gridbasierte Strassenrandschätzung für ein Spurhaltesystem*. In: *Proceedings of FAS 2009, Fahrerassistenzsysteme Workshop 2009*, 2009.
- [MM11] MATSUSHITA, Y. und J. MIURA: *On-line road boundary modeling with multiple sensory features, flexible road model, and particle filter*. Robotics and Autonomous Systems, In Press, Corrected Proof:–, 2011.

- [MMH08] MUFTI, F., R. MAHONY und J. HEINZMANN: *Spatio-Temporal RANSAC for Robust Estimation of Ground Plane in Video Range Images for Automotive Applications*. In: *Intelligent Transportation Systems, 2008. ITSC 2008. 11th International IEEE Conference on*, Seiten 1142 –1148, 2008.
- [MMSM<sup>+</sup>09] MEUTER, M., S. MULLER-SCHNEIDERS, A. MIKA, S. HOLD, C. NUNN und A. KUMMERT: *A novel approach to lane detection and tracking*. In: *Intelligent Transportation Systems, 2009. ITSC '09. 12th International IEEE Conference on*, Seiten 1 –6, 2009. 8
- [MNBI10] MCDANIEL, M.W., T. NISHIHATA, C.A. BROOKS und K. IAGNEMMA: *Ground plane identification using LIDAR in forested environments*. In: *Robotics and Automation (ICRA), 2010 IEEE International Conference on*, Seiten 3831 –3836, Mai 2010.
- [MPS09] MOOSMANN, F., O. PINK und C. STILLER: *Segmentation of 3D lidar data in non-flat urban environments using a local convexity criterion*. In: *Intelligent Vehicles Symposium, 2009 IEEE*, Seiten 215 –220, 2009.
- [MT04] MCCALL, J.C. und M.M. TRIVEDI: *An integrated, robust approach to lane marking detection and lane tracking*. In: *Intelligent Vehicles Symposium, 2004 IEEE*, Seiten 533 – 537, 2004.
- [MT06] MCCALL, J.C. und M.M. TRIVEDI: *Video-based lane estimation and tracking for driver assistance: survey, system, and evaluation*. *Intelligent Transportation Systems, IEEE Transactions on*, 7(1):20 –37, 2006. 8, 9
- [MT07] MIZUKAMI, Y. und K. TADAMURA: *Optical Flow Computation on Compute Unified Device Architecture*. In: *Proc. 14th International Conference on Image Analysis and Processing ICIAP 2007*, Seiten 179–184, 2007.
- [NC10] NUTHONG, C. und T. CHAROENPONG: *Lane detection using smoothing spline*. In: *Image and Signal Processing (CISP), 2010 3rd International Congress on*, Band 2, Seiten 989 –993, 2010.
- [NH04] NISCHWITZ, ALFRED und PETER HABERÄCKER: *Masterkurs Computergrafik und Bildverarbeitung*. Vieweg Friedr. und Sohn Verlag, 2004.
- [NM65] NELDER, J. A. und R. MEAD: *A Simplex Method for Function Minimization*. *The Computer Journal*, 7(4):308–313, 1965.
- [NVI] NVIDIA *Tegra Platform for Automotive Applications*. [http://www.nvidia.de/object/tegra\\_automotive\\_de.html](http://www.nvidia.de/object/tegra_automotive_de.html).
- [NVI11a] NVIDIA CORPORATION: *CUDA Best Practice Guide 4.0*, 2011.
- [NVI11b] NVIDIA CORPORATION: *CUDA Programing Guide 4.0*, 2011.

- [ONDM09] ONIGA, F., S. NEDEVSCHI, R. DANESCU und M.-M. MEINECKE: *Global map building based on occupancy grids detected from dense stereo in urban environments*. In: *Intelligent Computer Communication and Processing, 2009. ICCP 2009. IEEE 5th International Conference on*, Seiten 111–117, 2009.
- [OT06] OGAWA, T. und K. TAKAGI: *Lane Recognition Using On-vehicle LIDAR*. In: *Intelligent Vehicles Symposium, 2006 IEEE*, Seiten 540–545, 0-0 2006. 9
- [opt] *Oxford Technical Solutions*. <http://www.oxts.com/>.
- [Pha05] PHARR, MATT: *GPU Gems 2: Techniques for Graphics and Compute-Intensive Programming*. Addison-Wesley Longman, 2005.
- [Phy07] PHYSIKALISCH-TECHNISCHEN BUNDESANSTALT: *Das internationale Einheitensystem (SI)*, Deutsche Übersetzung der SI-Broschüre des BIPM. 8. Aufl. (erschienen als Sonderdruck aus den PTB-Mitteilungen), Auflage, 2007.
- [Pom95] POMERLEAU, DEAN: *RALPH: Rapidly Adapting Lateral Position Handler*. In: *IEEE Symposium on Intelligent Vehicles*, Seiten 506 – 511, September 1995. 8
- [PVB<sup>+</sup>09] PIETZSCH, SYLVIA, TRUNG-DUNG VU, JULIEN BURLET, OLIVIER AYCARD, THOMAS HACKBARTH, NILS APPENRODT, JÜRGEN DICKMANN und BERND RADIG: *Results of a Precrash Application Based on Laser Scanner and Short-Range Radars*. *IEEE Transactions on Intelligent Transportation Systems*, 10(4):584–593, 2009.
- [PYL10] PERROLLAZ, M., J. YODER und C. LAUGIER: *Using obstacles and road pixels in the disparity-space computation of stereo-vision based occupancy grids*. In: *Intelligent Transportation Systems (ITSC), 2010 13th International IEEE Conference on*, Seiten 1147–1152, 2010.
- [Rei96] REICHARDT, DIRK: *Kontinuierliche Verhaltenssteuerung eines autonomen Fahrzeugs in dynamischer Umgebung*. Doktorarbeit, Universität Kaiserslautern, 1996. 3, 11
- [Rey06] REYHER, A.: *Lidarbasierte Fahrstreifenzuordnung von Objekten für eine Abstandsregelung im Stop und Go-Verkehr*. Doktorarbeit, Technischen Universität Darmstadt, 2006. 9
- [RL10] ROSER, M. und P. LENZ: *Camera-based bidirectional reflectance measurement for road surface reflectivity classification*. In: *Intelligent Vehicles Symposium (IV), 2010 IEEE*, Seiten 340–347, 2010.
- [rpm09] *Bildquelle Wikipedia (en): Article about Raised Pavement Markers*. [http://en.wikipedia.org/wiki/Raised\\_pavement\\_marker](http://en.wikipedia.org/wiki/Raised_pavement_marker), 2009.

- [SB07] SHAMS, RAMTIN und NICK BARNES: *Speeding up Mutual Information Computation Using NVIDIA CUDA Hardware*. In: *Proceedings of the 9th Biennial Conference of the Australian Pattern Recognition Society on Digital Image Computing Techniques and Applications*, DICTA '07, Seiten 555–560, Washington, DC, USA, 2007. IEEE Computer Society.
- [Sch82] SCHÖDLBAUER, ALBERT: *Rechenformeln und Rechenbeispiele zur Landvermessung II*. Wichmann Herbert, 1982. 21
- [Sha48] SHANNON, C. E.: *A mathematical theory of communication*. Bell System Technical Journal, 27:379–423 and 623–656, July and October 1948.
- [SKP+08] STILLER, CHRISTOPH, SÖREN KAMMEL, BENJAMIN PITZER, JULIUS ZIEGLER, MORITZ WERLING, TOBIAS GINDELE und DANIEL JAGSZENT: *Team AnnieWAY's autonomous system*. In: *Proceedings of the 2nd international conference on Robot vision*, RobVis'08, Seiten 248–259, Berlin, Heidelberg, 2008. Springer-Verlag. 4
- [SKS96] SCHILLING, ANDREAS, GÜNTER KNITTEL und WOLFGANG STRASSER: *Texram: A Smart Memory for Texturing*. IEEE Comput. Graph. Appl., 16:32–41, May 1996.
- [SLK01] SHIN, HYUN-CHUL, JIN-AEON LEE und LEE-SUP KIM: *SPAF: subtexel precision anisotropic filtering*. In: *Proceedings of the ACM SIGGRAPH/EUROGRAPHICS workshop on Graphics hardware*, HWWS '01, Seiten 99–108, New York, NY, USA, 2001. ACM.
- [SMDW10] SCHMID, M.R., M. MAEHLISCH, J. DICKMANN und H.-J. WUENSCHKE: *Dynamic level of detail 3D occupancy grids for automotive use*. In: *Intelligent Vehicles Symposium (IV), 2010 IEEE*, Seiten 269–274, june 2010.
- [ST10] SIVERMANN, S. und M. TRIVEDI: *Improved Video-based Lane Tracker Performance Using Vehicle Localization*. In: *IEEE Intelligent Vehicles Symposium, San Diego, CA, USA, 2010*. 8
- [Sta11] STANFORD, RACING TEAM: *Roadrunner Stanford*. <http://cs.stanford.edu/group/roadrunner/>, 2011. 4
- [SW07] SCHMIDT, DORIS und HERMANN WINNER: *Kombination von Fahrdynamiksenor- und Globalen Navigationssatellitensystemdaten zur Performanceverbesserung von Fahrerassistenzsystemen*. In: *DGON Symposium Positionierung und Navigation*, 2007. 14
- [SW10] SCHWEITZER, MICHAEL und HANS-JOACHIM WUENSCHKE: *Einsatz von GPUs für automotives Sehen*. In: *Tagungsband VDI, Optische Technologien in der Fahrzeugtechnik*, Apr. 2010.

- [TBF05] THRUN, SEBASTIAN, WOLFRAM BURGARD und DIETER FOX: *Probabilistic Robotics*. MIT Press, 2005. 7
- [TFL<sup>+</sup>11] TSOGAS, MANOLIS, NIKOS FLOUDAS, PANAGIOTIS LYTRIVIS, ANGELOS AMDITIS und ARIS POLYCHRONOPOULOS: *Combined lane and road attributes extraction by fusing data from digital map, laser scanner and camera*. Inf. Fusion, 12:28–36, January 2011.
- [THKS91] THORPE, C., M. HERBERT, T. KANADE und S. SHAFER: *Toward autonomous driving: the CMU Navlab. I. Perception*. IEEE Expert, 6(4):31–42, August 1991. 8
- [Thr03] THRUN, SEBASTIAN: *Learning Occupancy Grid Maps with Forward Sensor Models*. Auton. Robots, 15(2):111–127, 2003.
- [TL10] THUY, MICHAEL und FERNANDO PUENTE LEÓN: *LANE DETECTION AND TRACKING BASED ON LIDAR DATA*. Metrol. Meas. Syst, XVII (2010):311–322, 2010. 9
- [TMD<sup>+</sup>06] THRUN, SEBASTIAN, MIKE MONTEMERLO, HENDRIK DAHLKAMP, DAVID STAVENS, ANDREI ARON, JAMES DIEBEL, PHILIP FONG, JOHN GALE, MORGAN HALPENNY, GABRIEL HOFFMANN, KENNY LAU, CELIA OAKLEY, MARK PALATUCCI, VAUGHAN PRATT, PASCAL STANG, SVEN STROHBAND, CEDRIC DUPONT, LARS-ERIK JENDROSSEK, CHRISTIAN KOELEN, CHARLES MARKEY, CARLO RUMMEL, JOE VAN NIEKERK, ERIC JENSEN, PHILIPPE ALESSANDRINI, GARY BRADSKI, BOB DAVIES, SCOTT ETTINGER, ADRIAN KAEHLER, ARA NEFIAN und PAMELA MAHONEY: *Stanley: The robot that won the DARPA Grand Challenge: Research Articles*. J. Robot. Syst., 23:661–692, September 2006. 4
- [UAB<sup>+</sup>08] URMSON, CHRIS, JOSHUA ANHALT, DREW BAGNELL, CHRISTOPHER BAKER, ROBERT BITTNER, M. N. CLARK, JOHN DOLAN, DAVE DUGGINS, TUGRUL GALATALI, CHRIS GEYER, MICHELE GITTLEMAN, SAM HARBAUGH, MARTIAL HEBERT, THOMAS M. HOWARD, SASCHA KOLSKI, ALONZO KELLY, MAXIM LIKHACHEV, MATT MCNAUGHTON, NICK MILLER, KEVIN PETERSON, BRIAN PILNICK, RAJ RAJKUMAR, PAUL RYBSKI, BRYAN SALESKY, YOUNG-WOO SEO, SANJIV SINGH, JARROD SNIDER, ANTHONY STENTZ, WILLIAM “RED” WHITTAKER, ZIV WOLKOWICKI, JASON ZIGLAR, HONG BAE, THOMAS BROWN, DANIEL DEMITRISH, BAKHTIAR LITKOUHI, JIM NICKOLAOU, VARSHA SADEKAR, WENDE ZHANG, JOSHUA STRUBLE, MICHAEL TAYLOR, MICHAEL DARMS und DAVE FERGUSON: *Autonomous driving in urban environments: Boss and the Urban Challenge*. J. Field Robot., 25:425–466, August 2008. 4
- [Urm07] URMSON, CHRIS: *Tartan Racing: A Multi-Modal Approach to the DARPA Urban Challenge*. Technischer Bericht, Carnegie Mellon University, 2007. 4

- [U.S94] U.S. DEPARTMENT OF TRANSPORTATION FEDERAL HIGHWAY ADMINISTRATION. PUBLICATION NO. FHWA-SA-93-001.: *Roadway Practice Handbook*, 1994.
- [U.S07] U.S. DEPARTMENT OF TRANSPORTATION FEDERAL HIGHWAY ADMINISTRATION. PUBLICATION NO. FHWA-HRT-07-059: *Updates to Research on Recommended Minimum Levels for Pavement Marking Retroreflectivity to Meet Driver Night Visibility Needs*, 2007.
- [U.S09] U.S. DEPARTMENT OF TRANSPORTATION FEDERAL HIGHWAY ADMINISTRATION.: *Manual on Uniform Traffic Control Devices (MUTCD)*, 2009.
- [VAA07] VU, TRUNG-DUNG, O. AYCARD und N. APPENRODT: *Online Localization and Mapping with Moving Object Tracking in Dynamic Outdoor Environments*. In: *Proc. IEEE Intelligent Vehicles Symposium*, Seiten 190–195, 13–15 June 2007.
- [VN08] VINEET, V. und P.J. NARAYANAN: *CUDA cuts: Fast graph cuts on the GPU*. In: *Proc. IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops CVPR Workshops 2008*, Seiten 1–8, 23–28 June 2008.
- [VNO10] VATAVU, A., S. NEDEVSCHI und F. ONIGA: *Real-time environment representation based on Occupancy Grid temporal analysis using a Dense Stereo-Vision System*. In: *Intelligent Computer Communication and Processing (ICCP), 2010 IEEE International Conference on*, Seiten 203 –209, 2010.
- [VSD07] VACEK, STEFAN, CONSTANTIN SCHIMMEL und RUDIGER DILLMANN: *Road-marking analysis for autonomous vehicle guidance*, Seiten 1–6. Nummer 1. ECMR, 2007.
- [VTNC08] VEIT, T., J.-P. TAREL, P. NICOLLE und P. CHARBONNIER: *Evaluation of Road Marking Feature Extraction*. In: *Intelligent Transportation Systems, 2008. ITSC 2008. 11th International IEEE Conference on*, Seiten 174 –181, 2008. 8
- [Wal09] WALDMANN, P.: *Entwicklung eines Fahrzeugführungssystems zum Erlernen der Ideallinie auf Rennstrecken*. Shaker Verlag, 2009. 9
- [Wan04] WANG, CHIEH-CHIH: *SIMULTANEOUS LOCALIZATION, MAPPING AND MOVING OBJECT TRACKING*. Doktorarbeit, Robotics Institute Carnegie Mellon University, 2004.
- [Wat02] WAT, ALAN: *3D-Computergrafik*. Pearson Studium, 2002.
- [WB95] WELCH, GREG und GARY BISHOP: *An Introduction to the Kalman Filter*, 1995.

- [Wen07] WENDEL, JAN: *Integrierte Navigationssysteme*. Oldenbourg, 2007.
- [Wün10] WÜNSCHE, H.-J.: *LRT8 - Institut für Technik Autonomer Systeme*. <http://www.unibw.de/lrt8/institut/>, 2010. 3
- [WSD07] WEISS, T., B. SCHIELE und K. DIETMAYER: *Robust Driving Path Detection in Urban and Highway Scenarios Using a Laser Scanner and Online Occupancy Grids*. In: *Proc. IEEE Intelligent Vehicles Symposium*, Seiten 184–189, 2007.
- [WSM10] WILLE, J. M., F. SAUST und M. MAURER: *Stadtpilot: Driving autonomously on Braunschweig's inner ring road*. In: *IEEE Intelligent Vehicles Symposium (IV)*, Juni 2010. 5, 13
- [WST00] WANG, YUE, DINGGANG SHEN und EAM KHWANG TEOH: *Lane detection using spline model*. *Pattern Recogn. Lett.*, 21:677–689, July 2000.
- [WTS04] WANG, YUE, EAM KHWANG TEOH und DINGGANG SHEN: *Lane detection and tracking using B-Snake*. *Image Vision Comput.*, 22(4):269–280, 2004.
- [YAL08] YGUEL, MANUEL, OLIVIER AYCARD und CHRISTIAN LAUGIER: *Efficient GPU-based Construction of Occupancy Grids Using several Laser Rangesfinders*. *International Journal Of Autonomous Vehicles*, 2008.
- [Zap88] ZAPP, A.: *Automatische Straßenfahrzeugführung durch Rechnersehen*. Doktorarbeit, Universität der Bundeswehr München, 1988. 2
- [zeh] *Zehntner GmbH*. <http://www.zehntner.com/>.
- [Zit04] ZITTERELL, DIRK: *Sensormodelle für probabilistische Verfahren zur Lokalisierung mobiler Roboter mit Abstandssensoren*. Diplomarbeit, Albert-Ludwigs-Universität Freiburg. Fakultät für Angewandte Wissenschaften - Arbeitsgruppe Autonome Intelligente Systeme, 2004.
- [ZJX<sup>+</sup>10] ZHOU, SHENGYAN, YANHUA JIANG, JUNQIANG XI, JIANWEI GONG, GUANGMING XIONG und HUIYAN CHEN: *A novel lane detection based on geometrical model and Gabor filter*. In: *Intelligent Vehicles Symposium (IV), 2010 IEEE*, Seiten 59–64, 2010. 8
- [ZS98] ZWAHLEN, H.T. und T. SCHNELL: *Pavement marking Visibility Research and Proposed Values for Minimum Required Pavement marking Retroreflectivity*. Technischer Bericht, Department of Industrial and Systems Engineering, Ohio University, 1998.