

TECHNISCHE UNIVERSITÄT MÜNCHEN
LEHRSTUHL FÜR DATENVERARBEITUNG

**Belegungskartenbasierte Umfeldwahrnehmung in Kombination
mit objektbasierten Ansätzen für Fahrerassistenzsysteme**

Dipl.-Ing. Mohamed Essayed Bouzouraa

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

Doktor-Ingenieurs (Dr.-Ing.)

genehmigten Dissertation.

Vorsitzender:	Univ.-Prof. Dr. techn. J. A. Nossek
Prüfer der Dissertation:	1. Univ.-Prof. Dr.-Ing. K. Diepold
	2. Univ.-Prof. Dr.-Ing. Chr. Stiller, Karlsruher Institut für Technologie

Die Dissertation wurde am 24.06.2011 bei der Technischen Universität München eingereicht und durch die Fakultät für Elektrotechnik und Informationstechnik am 12.12.2011 angenommen.

Vorwort

Die vorliegende Arbeit entstand während meiner Zeit als Doktorand bei der Audi AG in der Abteilung Entwicklung Fahrerassistenzsysteme in Zusammenarbeit mit dem Lehrstuhl für Datenverarbeitung an der Fakultät für Elektrotechnik und Informationstechnik der technischen Universität München.

An erster Stelle möchte ich meinem Doktorvater Prof. Dr.-Ing. Klaus Diepold vom Lehrstuhl für Datenverarbeitung der Technischen Universität München für die exzellente Betreuung der Arbeit, für die regelmäßigen wissenschaftlichen Anregungen und die interessanten Gespräche am Lehrstuhl danken.

Herrn Prof. Dr.-Ing. Christoph Stiller möchte ich für die Übernahme der Aufgabe als Zweitprüfer danken.

Mein Dank gilt auch den Kollegen von der Abteilung Entwicklung Fahrerassistenzsysteme bei der AUDI AG insbesondere Herrn Dr. Karl-Heinz Siedersberger und Herrn Dr. Ulrich Hofmann, die ein wissenschaftliches Arbeiten in der Vorentwicklung ermöglicht haben. Die intensive Betreuung und die zahlreichen intensiven fachlichen Diskussionen mit Dr. Hofmann haben einen großen Anteil am Erfolg dieser Arbeit. Danke Uli!

Auch die angenehme Zusammenarbeit mit den Kollegen Andreas Siegel, Mohamed Brahmi, Jens Storz, Waldemar Winter, Stefan Sandig, Kai Schüler, Tobias Weiherer, Benedikt Strasser, Michael Bär, Christoph Müller, Wladimir Entin und Markus Hörwick im Projekthaus hat sicherlich zu dem Gelingen der Arbeit beigetragen.

Den intensiven Austausch und die fruchtbare Zusammenarbeit mit dem Kollegen Michael Reichel möchte ich hier an dieser Stelle besonders hervorheben. Danke Michael!

Nicht zuletzt möchte ich meinen Eltern Abdelhamid und Hayet, meiner Schwester Jihene, meinem Bruder Fahd und insbesondere meiner Frau Ahlem für ihre stetige Liebe, Unterstützung und Rücksicht vom Herzen danken. Ohne sie wäre diese Arbeit nicht möglich.

Sayed Bouzouraa, Ingolstadt 2012.



Zusammenfassung

Zukünftige Fahrerassistenzsysteme mit hohem Automatisierungsgrad erfordern die zuverlässige und genaue Erfassung der Fahrzeugumgebung. Solche Systeme übernehmen z.B. die Längs- und Querverführung des Fahrzeugs oder leiten autonom einen Brems- oder Ausweichvorgang bei auftretenden Gefahrensituationen ein. Aufgrund der steigenden Anzahl von Assistenzsystemen und Sensortechnologien im Fahrzeug bei gleichzeitig hohen Anforderungen an den Energieverbrauch und begrenzter Rechenkapazität ist es notwendig, eine speicher- und recheneffiziente Umfeldrepräsentation zu schaffen, in der die Daten der verschiedenen Umfoldsensoren fusioniert werden.

Hierfür beschäftigt sich die Arbeit zunächst mit der aus der Robotik bekannten belegungskartenbasierten Repräsentation, die mit Hilfe von Umfoldsensoren eine explizite Darstellung der freien, belegten und unbekanntenen Bereiche ermöglicht. Das konventionelle zweidimensionale Belegungs-gitter wird hinsichtlich der Qualität der akkumulierten Daten und der Recheneffizienz verbessert und an die Randbedingungen der Fahrerassistenzsysteme angepasst. Zusätzlich werden eine neue recheneffiziente Methode zur Freiraumverfolgung, sowie eine Erweiterung des Belegungs-gitters um eine Höhenschätzung präsentiert. Dabei werden ein Serienradarsystem, ein seriennaher Laserscanner und ein 3D-Laser Forschungssensor eingesetzt. Die Sensoren werden in der Arbeit experimentell analysiert, so dass ihre Eigenschaften und Effekte in der Sensordatenverarbeitung berücksichtigt werden können.

Ein weiteres wichtiges Ziel der Arbeit besteht darin, die kartenbasierte Umfeldwahrnehmung mit der klassischen kompakten objektbasierten Beschreibung zu kombinieren, so dass ein konsistentes und harmonisches Wahrnehmungssystem entsteht. Trotz der Kombination mit der objektbasierten Beschreibung bleiben die große Datenmenge und das niedrige Abstraktionsniveau große Nachteile der Belegungskarte. Um diese Schwächen zu kompensieren, werden in der Arbeit Methoden zur assistenzsystemspezifischen Extraktion von Umfelddaten am Beispiel einer Stau-assistenz, eines Systems zur aktiven Gefahrenbremsung sowie einer Randbebauungserkennung vorgestellt.

Neben der Generierung der erforderlichen Umfelddaten ist die Schätzung der Datenqualität von großer Wichtigkeit für hochautomatisierte Fahrerassistenzsysteme. Von diesen Systemen wird gefordert, dass sie ihre Grenzen erkennen, falls z.B. ihre Wahrnehmungsleistung sich beträchtlich verschlechtert. Hierzu werden in der Arbeit Bewertungsmethoden entwickelt und validiert. Sie haben zum Ziel, einerseits die Qualität der Algorithmen der kartenbasierten Umfeldwahrnehmung im Entwicklungsprozess mit Hilfe eines Referenzsystems zu schätzen, andererseits online mit Hilfe von Gütemaßen eine Selbstdiagnose durchzuführen.

Abstract

An accurate and robust environment perception is essential to develop advanced driver assistance systems. Due to the increasing number of driver assistance systems in modern cars and the high requirements on the energy consumption and computation capacity, it is necessary to create a compact and efficient environment representation in which the data of different sensors can be fused.

This thesis concentrates on the occupancy grid map representation which is known from the robotics. The conventional occupancy grid map is improved concerning the quality of the accumulated data and the computation efficiency. Additionally, new map representations are introduced in order to track the free space in the car's environment and to extend the two dimensional grid map by height information. The deployed sensors consist in radar and lidar sensors. These sensors are systematically analyzed in order to consider different sensor effects in the map building process.

Another important objective of this work consists in combining the occupancy map representation with the object based environment description so that both sides can benefit from each other. Despite this combination, the grid map remains a representation with huge amount of data. Therefore, an extraction concept is introduced to generate different relevant and compact environment data from the map. The generated information can be transmitted on the car bus system in order to be used by the assistance systems.

In addition to the creation of the required environment data, the estimation of the data's quality is eminent for driver assistance systems with high automation level. These systems have to detect their limits, if e.g. their perception capacities are deteriorating. For this purpose, the work provides different methods which enable to evaluate the quality of a grid map both with and without a ground truth.

Inhaltsverzeichnis

Verzeichnis der verwendeten Symbole	xv
1 Einleitung	1
1.1 Motivation und Hintergrund	1
1.2 Stand der Technik	2
1.2.1 Fahrerassistenzsysteme mit vorausschauender Sensorik	3
1.2.2 Zweidimensionale Umfeldkartierung und Objektverfolgung	5
1.2.3 Überblick über dreidimensionale Umfeldkartierung und Objektverfolgung .	10
1.2.4 Forschungsaktivitäten im Bereich Fahrerassistenzsysteme und autonomes Fahren	13
1.3 Problemformulierung	14
1.4 Beiträge und Ziele der Arbeit	15
1.5 Struktur und Methodik der Arbeit	17
2 Grundlagen	19
2.1 Grundlagen der eingesetzten Sensoren	19
2.1.1 Grundlagen zur Radar-Sensorik	19
2.1.2 Grundlagen zu Laserscannersensoren	22
2.1.3 Der 3D Laser Sensor	24
2.1.4 Sensoren zur Erfassung der Eigenbewegung	26
2.1.5 Das Umfeldreferenzsystem	26
2.2 Koordinatensysteme	27
2.3 Grundlagen der kartenbasierten Umfeldwahrnehmung	29
2.3.1 Formale Definition	29
2.3.2 Formulierung des Kartierungsproblems	31
2.3.3 Aktualisierung nach Bayes für statische Umgebungen anhand von inversen Sensormodellen	32
2.4 Grundlagen der modellbasierten Objektbeschreibung und Verfolgung	33
2.4.1 Bewegungsmodelle	34
2.4.2 Formmodelle	34
2.4.3 Multi-Objekt Verfolgung	35
3 Analyse von Umfeldsensoren zur Herleitung von Sensormodellen	37
3.1 Motivation	37
3.2 Konzept	38
3.2.1 Modellierung des Einflusses unabhängiger Parameter	39
3.2.2 Analyse von Umfeldsensoren mit Hilfe eines Referenzsystems	41
3.3 Analyse eines Doppelradarsystems	42

3.3.1	Ermittlung des Radar-Sichtbereichs	42
3.3.2	Lage und Streuung des Reflexionspunkts	44
3.3.3	Ermittlung der Trennfähigkeit	46
3.3.4	Ermittlung der Latenzzeit	48
3.3.5	Erfassung von Leitplanken	50
3.4	Analyse eines Laserscanners	51
3.4.1	Analyse des Amplitudensignals	51
3.4.2	Genauigkeit der Entfernungsmessung	51
4	2D kartenbasierte Umfeldwahrnehmung	55
4.1	Zweidimensionale Belegungsgitter	55
4.1.1	Datenstrukturen	55
4.1.2	Effiziente Eigenbewegungskompensation	57
4.1.3	Vorverarbeitung der Laserrohdaten	59
4.1.4	Laserscannersensormodell für Belegungsgitter	62
4.1.5	Radarsensormodell für Belegungsgitter	66
4.2	Modellbasierte Freiraumverfolgung	71
4.2.1	Grundidee und Systemarchitektur	71
4.2.2	Intervallbasiertes Freiraummodell	72
4.2.3	Kompensation der Eigenbewegung	74
4.2.4	Freiraumextraktion aus Laserrohdaten	75
4.2.5	Freiraumextraktion aus Radardaten	76
4.2.6	Kalman-Filterung	76
4.2.7	Ergebnisse	77
4.3	Vergleich und Erkenntnisse	79
5	3D kartenbasierte Umfeldwahrnehmung	81
5.1	Motivation und Konzept	81
5.2	Erkennung der Bodenebene	82
5.3	2.5D Belegungskarte	84
5.3.1	Grundidee und Datenstruktur	84
5.3.2	Sensormodell	85
5.3.3	Multi-Hypothesen-Verwaltung	86
5.3.4	Schätzung der Höhe mit einem eindimensionalen Kalman-Filter	89
5.3.5	Experimentelle Ergebnisse	89
5.4	3D Intervallkarte	93
5.4.1	Motivation und Anforderungen	93
5.4.2	Grundprinzip und Datenstruktur	93
5.4.3	Intervallverwaltung	95
5.4.4	Experimentelle Ergebnisse	100
5.5	3D Voxel Karte	100
6	Fusion kartenbasierter Umfeldwahrnehmung mit der modellbasierten Objektverfolgung	105
6.1	Einleitung	105
6.1.1	Motivation	105

6.1.2	Konzept	106
6.2	Robuste Dynamikklassifikation mit Hilfe der Belegungskarte und von Rohdaten	108
6.2.1	Differenzbildung zwischen Laser-Rohdaten	109
6.2.2	Differenzbildung zwischen generierten Laser-Segmenten	110
6.2.3	Differenzbildung zwischen Belegungskarte und Rohdaten	111
6.2.4	Differenzbildung zwischen Belegungskarte und Segmenten	115
6.2.5	Zusammenfassung der Ergebnisse und Erkenntnisse	115
6.3	Objektbildung und Verfolgung	117
6.3.1	Gruppierung der klassifizierten Rohdaten	117
6.3.2	Zustandsextraktion aus gruppierten Rohdaten	118
6.3.3	Multi-Objektverfolgung	118
6.4	Kompensation der Bewegung dynamischer Hindernisse auf der Belegungskarte	121
6.4.1	Verwaltung der dynamischen Zellen und Verknüpfung zu der Objektliste	121
6.4.2	Prädiktion dynamischer Zellen und Gruppen von Zellen mit Modellierung der Unsicherheit	121
6.5	Belegungskarte als virtueller Sensor für die Objektverfolgung	122
6.5.1	Extraktion einer Sensormessung aus der Belegungskarte	123
6.5.2	Dekorrelation der zurückgespeisten Daten aus der Belegungskarte	123
6.6	Experimentelle Ergebnisse	125
7	Extraktion von Umfeldinformationen aus Belegungsgittern	127
7.1	Motivation und Konzept	127
7.2	Intervallbasierte Freiraum- und Belegungsextraktion	128
7.2.1	Erweiterter Bresenham-Algorithmus	131
7.2.2	Funktionsspezifische Steuerung	132
7.2.3	Ergebnisse	133
7.3	Randbebauungsextraktion aus Belegungsgittern	135
7.3.1	Motivation und Konzept	135
7.3.2	Bestimmung einer <i>Region Of Interest</i>	136
7.3.3	Segmentierung	139
7.3.4	Schätzung des Fahrbahnverlaufs	140
7.3.5	Erkennung der Fahrbahnbegrenzung	143
7.3.6	Bewertung und Ergebnisse	146
8	Methoden zur Bewertung von Belegungsgittern mit und ohne Hilfe eines Referenz- systems	151
8.1	Motivation und Methodik	151
8.2	Analyse der Fehlerquellen	151
8.3	Referenzierung des Belegungsgitters mit Hilfe eines Referenzsystems	153
8.3.1	Konzept	153
8.3.2	Generierung einer Referenz-Belegungskarte	154
8.3.3	Strahlenbasierter Vergleich zweier Belegungsgitter	155
8.3.4	ROI-basierter Vergleich zweier Belegungskarten	158
8.3.5	Bewertung mit Hilfe von Referenz-Objekten	159
8.3.6	Ergebnisse	160
8.4	Referenzierung des Belegungsgitters ohne ein Referenzsystem	162

8.4.1	Bewertung anhand der Kantendicke	162
8.4.2	Überwachung des Akkumulationsverhaltens	164
8.4.3	Ergebnisse	165
9	Zusammenfassung und Ausblick	167
9.1	Zusammenfassung	167
9.2	Ausblick	168
A	Versuchsträger	169
B	Formeln und Definitionen aus der Wahrscheinlichkeitstheorie	171
C	Zustandsschätzung	173
C.1	Zustandsraumdarstellung	173
C.2	Das Schätzproblem	174
C.3	Bayes Schätzer	175
C.4	Kalman-Filter und Erweiterungen	176
D	Der Bresenham-Algorithmus	179
E	Die Funktionen Stauassistent und Aktive Gefahrenbremsung	181
E.1	Die Aktive Gefahrenbremsung	181
E.2	Der Stauassistent	182
	Literaturverzeichnis	183

Verzeichnis der verwendeten Symbole

$\Delta\psi$	Änderung des Fahrzeuggierwinkels
δ	Abstand zwischen Belegung und Fahrzeugtrajektorie
δ_{pri}^*	Abstandsklasse des primären Fahrbahverlaufs
δ_{sek}^*	Abstandsklasse des sekundären Fahrbahverlaufs
η	Normierungskonstante nach Bayes
$\mathbf{N}(k)$	Messrauschen als Zufallsvariable
$\mathbf{V}(k)$	Systemrauschen als Zufallsvariable
$\mathbf{x}(k)$	Schätzgröße
$\mathbf{X}_{k-1:k}^{ego}$	Änderung in der Position des Eigenfahrzeugs zwischen den Zeitschritten $k-1$ und k
\mathbf{X}_{ego}	Position des Eigenfahrzeugs
$\mathbf{y}_{1:k}$	Messvektor, enthält Messungen bis zum Zeitschritt k
$\sigma_{h_i,k}^2$	Prädizierte Varianz der i -ten Hypothese für den k -ten Zeitschritt
$\sigma_{h_i,k}^2$	Schätzvarianz der i -ten Höhen-Hypothese zum Zeitpunkt k
σ_n^2	Messfehlervarianz
σ_v^2	Systemfehlervarianz
\hat{R}_{xy}	Schätzwert für die Kreuzkorrelationsfunktion der Signale x und y
A	Systemmatrix
a_{int}	Gewichtungsfaktor für die Erhöhung der Intervallverlässlichkeit
b_{int}	Gewichtungsfaktor für die Verringerung der Intervallverlässlichkeit
$D_k^{\mathbf{X}}$	Dynamikzustand der Zelle \mathbf{X} als Zufallsvariable
E	Menge von Zellen- oder Objekteigenschaften
e_{stoc}	Stochastischer Fehler in der Messung eines Sensors
e_{sys}	Systematischer Fehler in der Messung eines Sensors
H	Messmatrix
$h_{i,k}$	Höhenwert der i -ten Hypothese zum Zeitpunkt k
h_{i^*}	Gewählte Fahrzeugtrajektorie für den Fahrbahnverlauf
h_i	i -te Hypothese der Fahrzeugtrajektorie
I_i	i -tes Höhenintervall in der 3D Intervallkarte
\tilde{K}_k	Kalman-Verstärkung
L	Menge der Belegungen, die einen linken Fahrbahnverlauf bilden
M_k	Belegungskarte zum Zeitpunkt k
n_{mess}	Anzahl der gemessenen Reflexionspunkte innerhalb eines Intervalls
N_O	Anzahl der bereits verfolgten Objekte
n_{pot}	Anzahl der maximal möglichen Reflexionspunkte in einem Intervall
N_y	Anzahl der verfügbaren Messungen
O	Menge der detektierten Objekte

$O_k^{\mathbf{X}}$	Belegung der Zelle mit den ortsfesten Koordinaten \mathbf{X} für den Zeitpunkt k
P_d	Menge der deterministischen unabhängigen Parameter
p_{ego}	Position des Eigenfahrzeugs innerhalb des Belegungsgitters
p_i	i -ter Einflussparameter auf die Messung eines Sensors
P_s	Menge der stochastischen unabhängigen Parameter
R	Menge der Belegungen, die einen rechten Fahrbahnverlauf bilden
$R_{int,k}$	Intervallverlässlichkeit zum Zeitpunkt k
r_n	Gemessener Entfernungswert im n -ten Laserkanal
r_{sek}	Rangkorrelationskoeffizient nach Spearman
R_{xy}	Kreuzkorrelationsfunktion der Signale x und y
rg_X	Rang eines Elements X aus der Stichprobe
$v_{xL,i}$	Geschwindigkeit der linken Intervallgrenze des i -ten Intervalls in x -Richtung
$v_{xR,i}$	Geschwindigkeit der rechten Intervallgrenze des i -ten Intervalls in x -Richtung
v_{xTop}	Geschwindigkeit der vordersten Freiraumgrenze in x -Richtung
$v_{yL,i}$	Geschwindigkeit der linken Intervallgrenze des i -ten Intervalls in y -Richtung
$v_{yR,i}$	Geschwindigkeit der rechten Intervallgrenze des i -ten Intervalls in y -Richtung
v_{yTop}	Geschwindigkeit der vordersten Freiraumgrenze in y -Richtung
W	Lokale Welt
x_{Top}	x -Koordinate der vordersten Freiraumgrenze
$y_{L,i}$	Linke Intervallgrenze des i -ten Intervalls
$y_{R,i}$	Rechte Intervallgrenze des i -ten Intervalls
z	Höhenhypothese innerhalb einer Zelle
z_i	i -ter Höhenwert innerhalb einer Zelle
ACC	Adaptive Cruise Control
ADTF	Automotive Data and Time Triggered Framework
AGB	Aktive Gefahrenbremsung
BOF	Bayesian Occupancy Filter
CAN	Controller Area Network
CW	Continious Wave
DATMO	Detection and Tracking of Moving Objects
DGL	Differentialgleichung
DGPS	Differential Global Positioning System
FAS	Fahrerassistenzsystem
FFT	Fast Fourier Transformation
FMCW	Frequency Modulated Continuous Wave
FPGA	Field Programmable Gate Array
GNN	Global Nearest Neighbour
GPS	Global Positioning System
HEBF	Halbebenen-Block-Füll-Algorithmus
IQF	Integrierte Querführung
LIDAR	Light Detection And Ranging
LRR3	Long Range Radar 3. Generation
MMSE	Minimum Mean-Square Error
NN	Nearst Neighbor
RADAR	RAdio Detection And Ranging

RCS	Radar Cross Section
ROI	Region Of Interest
SAT	Separating Axes Theorem
SLAM	Simultaneous Localization and Mapping
SLAMMOT	Simultaneous Localization, Mapping and Moving Object Tracking
WLAN	Wireless Local Area Network

1 Einleitung

1.1 Motivation und Hintergrund

Die Mobilität des Menschen als seine Fähigkeit sich von Ort zu Ort zu bewegen und Gegenstände zu transportieren hat die menschliche Geschichte geprägt. Mit der Entwicklung besserer technischer Transport- und Fortbewegungsmittel erweiterten die Menschen ihren Horizont, ihre Möglichkeiten, und entwickelten sich selbst [8]. So hat sich die Form der Mobilität mit den technologischen und gesellschaftlichen Entwicklungen stark verändert. Heutige Trends wie Globalisierung, Urbanisierung, Flexibilisierung und Individualisierung prägen die Entwicklung der Gesellschaft und stellen die Gestaltung der Automobile der Zukunft vor großen Herausforderungen. Es wird nach einem sicheren, flexiblen und umweltbewussten Fahren gestrebt. Um diese Erwartungen zu erfüllen, werden für die Zukunft neue Mobilitätsformen benötigt. Schon heute ist ein großer Teil der Fahrzeuge mit Fahrerassistenzsystemen ausgestattet, die den Fahrer bei der Bewältigung der Fahraufgabe unterstützen. Dementsprechend steht dem Fahrer das assistierte Fahren neben dem klassischen manuellen Führen des Fahrzeugs als zusätzliche Möglichkeit zur Verfügung. Eine logische Konsequenz der Weiterentwicklung dieser Assistenzsysteme ist das autonome Fahren, bei dem dem Fahrer die Fahraufgabe komplett abgenommen wird.

Die Vorstellung automatisch fahrender Kraftfahrzeuge beschäftigt die Menschen seit Jahrzehnten [60]. Doch bis heute sind auf unseren Straßen keine autonom fahrenden Fahrzeuge zu finden. Eine vollständige Übernahme der Fahraufgabe durch das Fahrzeug wird wahrscheinlich zuerst nur in gewissen Szenarien stattfinden, deren Komplexität durch hoch automatisierte Fahrerassistenzsysteme bewältigbar ist. Dazu gehört beispielsweise das automatische Fahren im Stau auf der Autobahn. Dabei wird die Fahraufgabe im Stau von den meisten Fahrern als sehr langweilig empfunden. Gerade hier wäre ein hoher Nutzen für die Fahrer erzielbar, in dem sie die verlorene Zeit im Stau „zurückbekommen“. Während das Auto die Fahraufgabe übernimmt, kann der Fahrer die Zeit beispielsweise zum Bearbeiten von Mails oder für andere Formen der Unterhaltung nutzen. Neben diesen Fahrkomfort erhöhenden Systemen werden auf dem Weg zum autonomen unfallfreien Auto Sicherheitsassistenzsysteme eine große Rolle spielen. Die Bemühungen in aktuellen Forschungsprojekten wie z.B. AKTIV-AS (s. Abschnitt 1.2.4) und die positive Resonanz aktueller Systeme wie das *City Safety* System von Volvo belegen diesen Trend.

Eine Herausforderung, die den Zeitpunkt der Einführung hoch automatisierter Fahrerassistenzsysteme und autonomer Fahrzeuge mitentscheiden wird, besteht in der präzisen und robusten sensorbasierten Wahrnehmung des Fahrzeugumfelds. Die vorliegende Arbeit soll in diesem Feld einen Beitrag durch die Bereitstellung neuer Methoden und die Adaption bestehender Ansätze zur Nutzung der Technologie der Belegungskarten im Bereich der Fahrerassistenzsysteme leisten. Teile der Ergebnisse der Arbeit werden in den Forschungsprojekten **Stauassistent** und **Aktive Gefahrenbremsung** eingesetzt. Dabei wird die Strategie verfolgt, auf bestehende Serien-Sensor-

Systeme zurückzugreifen wie z.B. das Doppel-Radar System, das als Teil des *ACC (Adaptive Cruise Control)* seit 2010 im Audi A8 auf dem Markt ist (s. Abbildung 1.1). Diese Sensoren sollen um weitere serientaugliche Sensor-Technologien wie z.B. Laserscanner ergänzt und methodisch erweitert werden. Um den Blick auf die etwas fernere Zukunft nicht zu verlieren, wird außerdem ein 3D Laser-Sensor in der Arbeit eingesetzt.

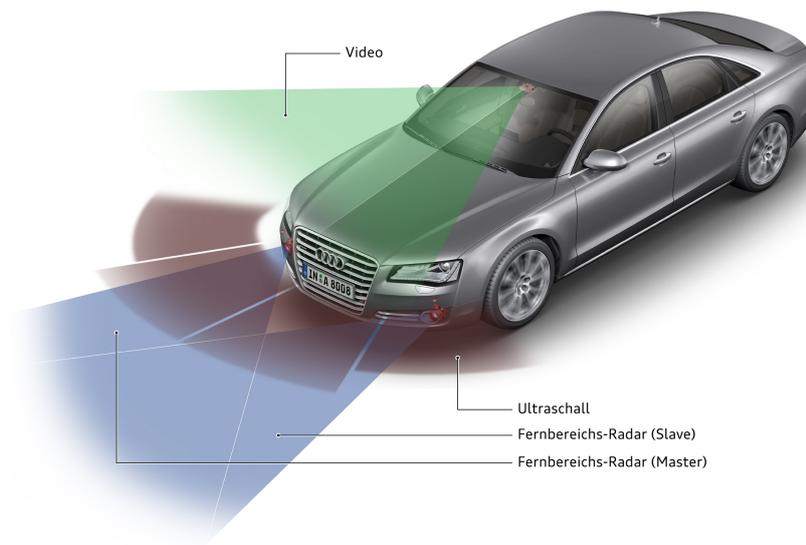


Abbildung 1.1: Audi A8 mit vorausschauender Sensorik (Quelle: Audi AG)

1.2 Stand der Technik

Im Bereich der maschinellen Umfeldwahrnehmung existiert eine weltweit breit gefächerte Forschungsgemeinde, die interdisziplinär die Felder der Robotik, der künstlichen Intelligenz, der Bildverarbeitung, Regelungs- und Automatisierungstechnik mit abdeckt. Viele der Forschungsbemühungen im Bereich der Fahrerassistenzsysteme konzentrieren sich auf die multisensorielle Umfeldwahrnehmung, weil die Umfelderkennung ein wichtiger Baustein eines Fahrerassistenzsystems ist.

Viele Fragestellungen in der Umfeldwahrnehmung sind bereits erfolgreich in der Robotik behandelt worden. Diese müssen lediglich an die Anforderungen und die Randbedingungen der Assistenzsysteme angepasst werden. Andere Problemstellungen hingegen, wie z.B. die zuverlässige Erkennung von Freiräumen und die Behandlung bewegter Hindernisse in Belegungskarten, sind noch nicht oder nur zum Teil gelöst und erfordern die Entwicklung neuer Ansätze. Im Folgenden wird ein Überblick über aktuelle Fahrerassistenzsysteme mit vorausschauender Umfeldsensorik und über die Forschungsaktivitäten der wichtigsten weltweiten Forschungsgruppen auf dem Gebiet der Belegungskarten und Objektverfolgung gegeben.

1.2.1 Fahrerassistenzsysteme mit vorausschauender Sensorik

In diesem Abschnitt wird auf einige bereits in Serie befindliche Fahrerassistenzsysteme eingegangen. Dabei liegt das Augenmerk ausschließlich auf Assistenzsystemen mit vorausschauender Umfeldsensorik und speziell auf Systemen, die von den Ergebnissen der vorliegenden Arbeit unmittelbar profitieren können.

ACC Stop and Go

Das ACC-System hat sich seit seiner Einführung in 1999 ständig weiterentwickelt und neue Funktionalitäten erhalten [86]. Ein ACC-System übernimmt die Längsführung des Fahrzeugs basierend hauptsächlich auf im vorderen Bereich eingebauten Radar-Sensoren. Diese Sensoren messen fortlaufend den Abstand zu anderen Verkehrsteilnehmern. Das System kann so die Distanz zum Vorderfahrzeug einregeln. Die Weiterentwicklung des ACC-Systems wurde durch bessere Sensorik (höhere Reichweite, größerer Öffnungswinkel, bessere Auflösung) und leistungsfähigere Aktorik ermöglicht. Dies umfasste die Erweiterung des Geschwindigkeitsbereichs, in dem die Funktion verfügbar ist, das Miteinbeziehen neuer Fahraufgaben wie das automatische Anhalten und Wiederanfahren (*ACC Stop and Go*) und die Erhöhung des Fahrkomforts durch z.B. Anpassung des Fahrverhaltens in kurvigen Straßen. Trotz dieser signifikanten Weiterentwicklung der ACC-Systeme muss sich vor allem die Umfeldwahrnehmung verbessern, um beispielsweise die Reaktion auf stehende Hindernisse und eine frühe zuverlässige Erkennung einsicherender Fahrzeuge zu ermöglichen.

Der Spurhalteassistent

Der Spurhalteassistent unterstützt den Fahrer in der Querführung des Fahrzeugs entweder durch eine Warnung beim Verlassen des Fahrstreifens oder durch einen aktiven Lenkeingriff, der das Verlassen des Fahrstreifens verhindert. Die meisten Systeme basieren auf einer nach vorne ausgerichteten Kamera, die die Fahrstreifenmarkierungslinien verfolgt. Aktuelle Systeme funktionieren hauptsächlich auf Autobahnen und reagieren nicht auf Hindernisse in der Umgebung. Die zuverlässige Erkennung von Freiräumen und Fahrbahnbegrenzungen würde die Verfügbarkeit der Systeme erhöhen und deren Einsatz in komplexen Szenarien wie z.B. Baustellen ermöglichen.

Der Einparkassistent

Auch bei der Parkaufgabe gibt es eine Vielzahl von Assistenzsystemen, die den Fahrer unterstützen. Die meisten Systeme basieren auf Ultraschall-Sensoren und Kameras. Der Funktionsumfang der Parkassistenten variiert von der einfachen Anzeige der Kamera-Bilder rund um das Fahrzeug über eine optische und akustische Warnung bis hin zu einem aktiven Eingreifen in den Einparkvorgang. Die neuesten Systeme lenken das Fahrzeug automatisch in Längs- und Querparklücken und parken zudem aus Längsparklücken aus. Abbildung 1.2 zeigt die verschiedenen Schritte, die das System zur Bewältigung der Parkaufgabe in einer Querlücke beherrscht.

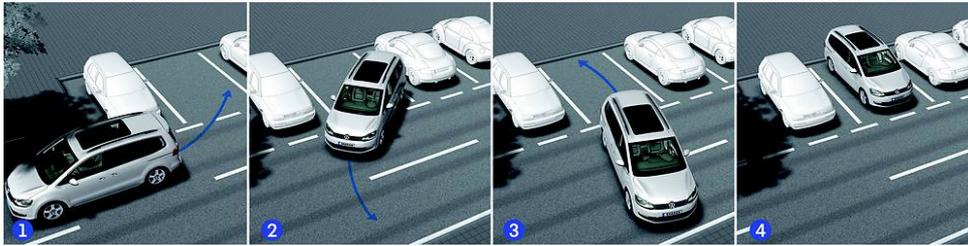


Abbildung 1.2: Automatisches Parken in einer Querlücke (Quelle: Volkswagen AG)

Trotz der Vielfalt an Einparkassistenten gibt es aktuell kein System, das in der Lage ist, das Einparken vollautomatisch durchzuführen. Bei den aktuellen Systemen muss noch der Fahrer Gas geben und bremsen. Außerdem muss der Fahrzeugführer ständig das System überwachen. Dies liegt vor allem an der fehlenden Überwachung des Freiraums und der Nicht-Beherrschung von komplexen Situationen, wie z.B. hoch dynamischen Szenen mit verschiedenen Hindernis-Klassen. Die Bereitstellung einer konsistenten Umfeldwahrnehmung, die sowohl dynamische Objekte, stationäre Hindernisse als auch Freiräume rund um das Fahrzeug darstellt, kann dazu beitragen, den Automatisierungsgrad von aktuellen Park-Assistenzsystemen entscheidend zu erhöhen.

Automatische Notbremse

Nach der Etablierung der ACC-Systeme sind weitere Funktionalitäten wie der Notbremsassistent im Markt eingeführt worden. Der Notbremsassistent ergreift beim Erkennen einer kritischen Situation durch Umfoldsensoren Sicherheitsmaßnahmen wie z.B. Bremsen. Das System gibt es in verschiedenen Varianten und baut auf unterschiedlichen Sensorprinzipien auf. Der im Audi A8 seit 2010 verfügbare Notbremsassistent basiert auf zwei Fernbereichsradaren, die links und rechts im vorderen Stoßfänger untergebracht sind, und einer Video Front-Kamera. Erkennt das Sicherheitssystem ein potentielles Hindernis, beispielsweise ein sich stark verlangsamendes oder angehaltenes Fahrzeug, wird in einem ersten Schritt die Bremse auf eine eventuell folgende Notbremsung vorbereitet. Reagiert der Fahrer nicht und nähert sich das Fahrzeug weiter, folgt eine akustische Warnung und anschließend eine von einem kurzen Bremsruck eingeleitete automatische Teilbremsung. Erfolgt trotzdem keine Reaktion und ist eine Kollision nicht mehr zu vermeiden, bremst das System mit maximaler Verzögerung, um die Folgen eines Unfalls zu mindern. Abbildung 1.3 verdeutlicht das verfolgte Warn- und Aktionskonzept des Notbremsassistenten des Automobilherstellers Audi.

Trotz neuer Systeme, wie das *City Safety* von Volvo, das im Niedergeschwindigkeitsbereich auf stehende Hindernisse bremst, reagieren die meisten Systeme aufgrund ihrer eingeschränkten Wahrnehmungsfähigkeit nur auf bewegte Objekte. Außerdem betrachten sie in der Regel nur ein relevantes Objekt, so dass eine Ausweichmöglichkeit aus System Sicht lange bestehen bleibt. Ein Bremsmanöver erfolgt daher spät und die Systeme wirken deswegen lediglich kollisionsfolgenmindernd [98]. Automatische Notbremsysteme können sehr stark von einer erweiterten Umfeldbeschreibung profitieren. Durch die Berücksichtigung sämtlicher Hindernisse und ihrer Ausdehnung in der Fahrzeugumgebung, z.B. Leitplanken und Betonwände, kann die Ausweichlosigkeit und somit die Gefahr einer Situation früher eingeschätzt werden. Folglich können Unfälle durch Brem-

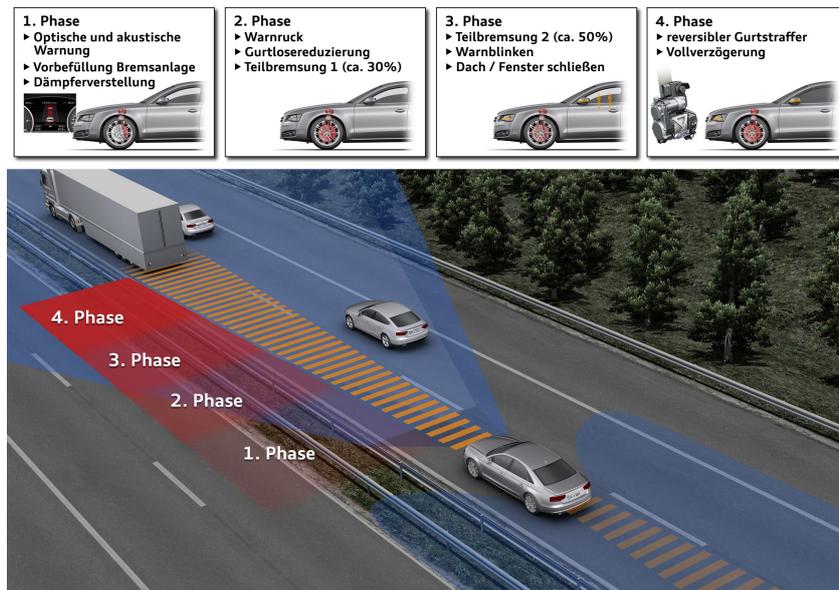


Abbildung 1.3: Warn- und Aktionskonzept des Notbremsassistenten (Quelle: Audi AG)

sen vermieden werden. Auch zukünftige Systeme, die ein Bremsmanöver um ein automatisches Ausweichen ergänzen, sind auf die zuverlässige Erfassung von Freiräumen angewiesen.

1.2.2 Zweidimensionale Umfeldkartierung und Objektverfolgung

Es existieren in der Literatur eine Reihe von Arbeiten speziell aus dem Bereich der Robotik, die sich mit der Thematik der Umfeldkartierung und Objekt-Verfolgung befassen. Die beiden Probleme sind unter den Namen **SLAM** und **DATMO** bekannt.

Unter dem **SLAM**-Problem (*Simultaneous Localization and Mapping*) wird generell die gleichzeitige Kartierung und die Schätzung der Position eines mobilen Roboters innerhalb der erstellten Belegungskarte verstanden. Das **SLAM**-Problem ist eines der wichtigsten und populärsten Themen der heutigen Robotikforschung. Bei der Umfeldkartierung wird die Umgebung des Roboters durch ein Raum-Modell klassischerweise als Gitterstruktur repräsentiert. Dem Raum werden Eigenschaften, wie z.B. Belegung und Überfahrbarkeit, zugeordnet, die zeitlich mit Hilfe von Sensordaten geschätzt werden. Unterschiedliche Techniken, wie *Extended Kalman Filter*, *Particle-Filter* oder *Scan-Matching*-Algorithmen, kommen dabei zum Einsatz. Für die vorliegende Arbeit stellt die Schätzung der globalen Fahrzeug-Position beim **SLAM**-Problem kein Schwerpunkt dar. Denn viele Arbeiten konzentrieren sich, etwa [42], auf eine Verbesserung von **SLAM**-Algorithmen in zyklischen Umgebungen, bei denen bestimmte Positionen gegebenenfalls mehrfach wiederbesucht werden. Für die Anwendung in Fahrerassistenzsystemen sind allerdings diese sogenannten globalen Karten weniger wichtig als die Erstellung einer konsistenten lokalen Umfeldkarte.

Als **DATMO**-Problem (*Detection and Tracking of Moving Objects*) ist die Erkennung und Verfolgung von dynamischen Objekten gemeint. Dies beinhaltet die Bildung von Objekten mit Hilfe

von Sensor-Rohdaten und die zeitliche Verfolgung dieser Objekte, indem bestimmte Objekt-Zustände (Position, Geschwindigkeit, Ausdehnung) geschätzt werden.

In den folgenden Abschnitten dieses Kapitels werden relevante Erkenntnisse aus wissenschaftlichen Veröffentlichungen der wichtigsten Forschungsgruppen zu den Themen Umfeldkartierung und Erfassung dynamischer Objekte zusammengefasst.

University of South Carolina, Los Angeles

In [99] befassen sich Denis Wolf und Gaurav S. Sukhatme von der *University of Southern California* mit der Entwicklung eines *SLAM*-Algorithmus für Roboter in geschlossenen Räumen mit dynamischen Objekten. Zielsetzung ist dabei die Unterscheidung zwischen statischen und dynamischen Gegenständen in der Umgebung sowie eine gleichzeitige Lokalisierung des Roboters. Die Tests wurden mit einem *Active Media Pioneer* Roboter durchgeführt, der seine Umgebung mit einem *SICK* Lasersensor abtastet.

Um die Unterscheidung zwischen dynamischen und statischen Objekten zu bewerkstelligen, werden in dem vorgestellten Ansatz zwei Belegungskarten berechnet. Der Wert einer Zelle der statischen Karte S repräsentiert die Wahrscheinlichkeit für das Vorhandensein eines statischen Objektes in diesem Bereich. Analog dazu entsprechen die Werte der dynamischen Karte D den Wahrscheinlichkeiten für das Vorkommen von dynamischen Objekten. Der erste Schritt bei der Erstellung der beiden Karten ist eine Unterscheidung zwischen den gemessenen Objekten. Dazu werden bei der Aktualisierung der Karten nicht nur die aktuelle Lasermessung, sondern auch die zuvor erstellten Belegungskarten berücksichtigt. Basierend auf bestimmten Regeln werden die Wahrscheinlichkeiten in der dynamischen und in der statischen Karte erhöht oder erniedrigt. Neu gemessene Objekte in bisher unbekanntem oder statischen Bereichen werden generell als statisch betrachtet. Bereiche der dynamischen Karte erhalten einen hohen Wahrscheinlichkeitswert, falls neue Objekte in einem als frei geltenden Bereich gemessen werden. Da die Odometrie-Daten des eingesetzten Roboters nur unzureichend genaue Ergebnisse liefern, führen Wolf und Sukhatme im Anschluss an die Dynamik-Klassifikation und die Kartenerstellung eine Lokalisierung durch. Ihr Ansatz basiert dabei auf der Wiedererkennung von Landmarken.

INRIA, Rohne Alpes

Die Forschungsgruppe „*e-Motion*“ vom französischen Forschungsinstitut *INRIA (Institut national de recherche en informatique et en automatique Rhône-Alpes)* befasst sich intensiv mit der maschinellen Umfeldwahrnehmung für Fahrzeug-Roboter, mit der Bahnplanung für autonome Navigation und mit der probabilistischen Inferenz. Dabei stellt auch das Belegungsgitter als Repräsentation ein Schwerpunkt in der Umfeldwahrnehmung dar. In einigen Arbeiten wie z.B. [13], [18] und [48] wurde die Technik der *Bayesian Occupancy Filter (BOF)* beschrieben und verwendet. Grundidee der *BOF*-Methode ist die Modellierung der dynamischen Umgebung im Belegungsgitter durch Schätzung der Geschwindigkeit jeder Zelle neben der Bestimmung ihrer Belegungswahrscheinlichkeit. Zunächst wurde das Konzept mit simulierten Sensordaten aufgezeigt. In [48] wurde zusätzlich ein Laserscanner eingesetzt.

Trung Dung Vu, Olivier Aycard, Julien Burlet und Nils Appenrodt ebenfalls von *INRIA* beschäftigen sich in [11] und [12] mit der Lösung des *SLAM*- und *DATMO*-Problems in dynamischen Umgebungen. Ziel ihrer Arbeit ist die Entwicklung eines echtzeitfähigen Algorithmus für Fahrzeuge, der vor kritischen Verkehrssituationen warnt. Dabei liegt der Fokus auf der Lokalisierung des eigenen Fahrzeugs und auf der Erfassung des Umfeldes in dynamischen Umgebungen. Zur Modellierung der statischen Umgebung wird ebenfalls eine Belegungskarte verwendet. Als Versuchsfahrzeug kommt ein Daimler mit zwei *short range radar* Sensoren und einem Laserscanner zum Einsatz. Der Radar-Sensor besitzt dabei eine Reichweite von $30m$ und einen Öffnungswinkel von 80° . Der Laserscanner hat eine Reichweite von $80m$ und einen Öffnungswinkel von 160° bei einer Auflösung von 1° . Zusätzlich werden die Odometrie-Sensoren zur Erfassung der Eigenbewegung verwendet. Die Größe der eingesetzten Belegungskarte beträgt $160m \times 200m$, die Gitterauflösung beträgt $20cm$. Laut [12] ist die Ermittlung der Eigenbewegung alleine aus den Odometriedaten ungenau. Aus diesem Grund findet eine Korrektur der Fahrzeug-Position durch ein sogenanntes *Scan-Matching*-Verfahren statt.

Die Objekterkennung und Verfolgung von INRIA baut auf der erstellten lokalen Karte. Dazu werden zum einen Inkonsistenzen zwischen dem aktuellen Laserscan und der zuvor erstellten Belegungskarte genauer betrachtet. Sollte ein Objekt an einer Position erkannt werden, die zuvor als frei erfasst wurde, muss es sich um ein dynamisches Objekt handeln. Sollte hingegen ein Objekt an einer belegten Kartenposition festgestellt werden, handelt sich wahrscheinlich um ein statisches Objekt. Über Objekte in zuvor nicht kartierten Positionen lassen sich a priori keine Aussagen treffen. Zusätzlich können vorherige Beobachtungen von dynamischen Objekten wichtige Hinweise liefern. So können beispielsweise Objekte in bestimmten Karten-Regionen, wo zuvor bewegte Objekte waren, generell als potentiell dynamisch gesehen werden. Die Bildung dynamischer Objekte läuft dann in zwei Schritten ab. Zunächst werden die Reflexionspunkte der aktuellen Lasermessung in die Belegungskarte projiziert und über die genannten Kriterien klassifiziert. Im zweiten Schritt werden die dynamischen Laserscan-Endpunkte zu Gruppen und somit bewegten Objekten zusammengefasst. Abbildung 1.4 verdeutlicht die beiden Teilschritte, die identifizierten Objekte werden in grünen Rechtecken angezeigt.



Abbildung 1.4: Erkennung von dynamischen Objekten [11]

Nach der Identifikation von bewegten Objekten durch die Laserdaten werden die erkannten Objekte zusätzlich mit Radar-Messungen verglichen [12]. Dadurch lassen sich zum einen Fehler in der vorangegangenen Klassifikation erkennen, zum anderen kann jedem dynamischen Objekt eine Geschwindigkeit zugeschrieben werden. Nach diesem Vorgang der Dynamikerkennung werden die Objekte in der Belegungskarte entfernt und nicht mehr betrachtet. Die Karte modelliert lediglich

die statische Welt. Anschließend findet eine Verfolgung der beweglichen Objekte statt. Dazu wird ein *Interacting Multiple Model Filter* verwendet, der in [12] genauer beschrieben wird.

Der vorgestellte Algorithmus wurde in verschiedenen Verkehrsszenarien getestet. Nach den Ergebnissen aus [11] wurden bei einer Autobahnfahrt mit 120km/h vorausfahrende und bei einer Landstraßenfahrt mit 80km/h vorausfahrende und entgegenkommende Fahrzeuge erfasst. Die Gesamtlaufzeit des SLAM und DATMO Systems betrug 20 bis 30ms auf einem 1.86 Ghz, 1GB RAM Linux-Laptop.

Carnegie Mellon University

Chieh-Chih Wang und Sebastian Thrun von der *CMU (Carnegie Mellon University Pittsburgh)* beschäftigen sich in mehreren Veröffentlichungen zwischen den Jahren 2002 und 2007 mit der gleichzeitigen Lösung des *SLAM*- und *DATMO*-Problems ([92], [93], [94]). Das neue Problem wird *SLAMMOT (Simultaneous Localization, Mapping and Moving Object Tracking)* genannt und beinhaltet die Umfeldkartierung mit der gleichzeitigen Lokalisierung des Eigenfahrzeugs und Verfolgung der dynamischen Objekte. Ihr Testfahrzeug ist mit einem *SICK LMS221* Lasersensor an der Fahrzeugfront und zwei *SICK LMS291* Lasersensoren an den Fahrzeugseiten ausgestattet. Die Testszenarien konzentrieren sich auf Fahrten in urbanen Gebieten. Dabei sollen Fußgänger und andere Fahrzeuge erkannt und verfolgt werden. Neben der praktischen Arbeit liefern Wang et al. in [94] und [16] auch eine mathematische Formulierung der *SLAM*- und *DATMO*-Probleme. Explizit wird in [93] auf die Abhängigkeiten zwischen *SLAM* und *DATMO* eingegangen. *SLAM* stellt eine genaue Positionsbestimmung sowie eine Umgebungskarte des Fahrzeugs zur Verfügung, die *DATMO* zur zuverlässigen Erkennung von dynamischen Objekten benötigt. Andererseits wird versucht, die *SLAM*-Ergebnisse durch ein Herausfiltern der beweglichen Objekte zu verbessern.

Ein Zyklus des Algorithmus beginnt mit der Segmentierung der ankommenden Laserdaten in zusammenhängende Objekte. Durch einen Abgleich mit einer Liste der bisher erfassten und gespeicherten dynamischen Objekte lässt sich ein Teil der gemessenen Objekte aussortieren. Bei den verbliebenen Objekten handelt es sich entweder um statische Objekte oder neue dynamische Objekte. Basierend auf diesen Daten werden anschließend die neuen bewegten Objekte erfasst und der *SLAM*-Algorithmus wird ausgeführt. Abschließend wird die statische Karte sowie die Liste der dynamischen Objekte aktualisiert.

Die Erkennung und Verfolgung dynamischer Objekte wird in [93] genauer erläutert. Zur Gruppierung der Laserdaten wird ein einfaches Distanz-Kriterium verwendet. Zwei Punkte werden demselben Segment zugeordnet, wenn ihr gegenseitiger Abstand weniger als 1 Meter beträgt. Diese Segmente werden anschließend wiederum durch Finden von Inkonsistenzen zwischen aktuellem Scan und zuvor erstellter Belegungskarte klassifiziert.

- Wird ein Objekt in einem Kartenbereich gefunden, der aufgrund der vorherigen Laserscans als frei gespeichert wurde, so muss dieses Objekt dynamisch sein.
- Wird ein Objekt hingegen in einem Kartenbereich gemessen, der bisher nicht erfasst wurde, so lässt sich keine Aussage über den Zustand dieses Objektes treffen.

Die Erkennung von dynamischen Objekten läuft daher in zwei Teilen ab. Im ersten Teil werden dynamische Punkte durch Vergleich mit dem Inhalt der Belegungskarte klassifiziert. Im zweiten Teil werden diese Erkenntnisse mit den Ergebnissen der zuvor durchgeführten Segmentierung kombiniert. Eine Gruppe von Punkten wird als dynamisch klassifiziert, wenn der Anteil ihrer dynamischen Punkte höher als 0.5 ist. Zur Realisierung des Trackings verwenden Wang et al. ebenfalls eine *Interacting Multiple Model* und *Multiple Hypothesis Tracking*. Das genaue Verfahren kann in [94] nachgelesen werden.

Ein anderer Ansatz, der vom Team der *Carnegie Mellon University* in der *urban challenge* eingesetzt wurde, wird in [24] von Dave Gerguson, Michael Darms, Chris Urmson und Sascha Kolski beschrieben. Die Arbeit basiert auf der Fusion von verschiedenen Radar- und Laser-Sensoren zur Erkennung und Vorhersage von bewegten Objekten. Ausgangsposition ihres Vorgehens ist eine vektorisierte a priori Straßenkarte, in der Fahrbahnverläufe und Kreuzungen abgebildet sind. Die dynamischen Objekte selbst werden in einer Liste verwaltet. Jeder Eintrag dieser Liste enthält Informationen über die Form des Objektes, seine Position und seine Dynamik-Eigenschaften. Im vorgestellten Ansatz werden die Modell-Annahmen getroffen, dass es sich entweder um ein rechteckiges oder punktförmiges Objekt handelt. Um dynamische Objekte zuverlässig zu erkennen, werden die Ergebnisse verschiedener Laser- und Radarsensoren kombiniert. Jeder Sensor versucht, Objekt-Merkmale zu extrahieren. Die Radar-Sensoren liefern z.B. Geschwindigkeitsmessungen, die Laser-Sensoren L-förmige Objekte. Die gemessenen Objekte werden anschließend mit der bisher geführten Liste abgeglichen und verfolgt. Auch hier werden in der Belegungskarte statische Hindernisse repräsentiert.

Fazit: Eine entscheidende Schwäche der aufgezeigten Ansätze besteht darin, dass die Belegungskarte nicht von der Erkennung dynamischer Objekte profitiert, denn die dynamischen Objekte und ihre Konturen werden aus der statischen Karte entfernt. Es findet keine Kompensation der Bewegung dynamischer Hindernisse im Belegungsgitter statt. Außerdem profitiert die Objekt-Verfolgung nicht von den Akkumulationsmechanismen der Belegungskarte. D.h., die akkumulierten Form-Informationen werden nicht dazu verwendet, die Zustandsvektoren von dynamischen Objekten zu korrigieren.

Universität Ulm

Am Institut für Mess-, Regel- und Mikrotechnik der Universität Ulm werden im Bereich Fahrerassistenz speziell zu dem Thema Belegungskarte verschiedene Forschungsaktivitäten betrieben. In [96] stellen Thorsten Weiss, Bruno Schiele und Klaus Dietmayer ihre Arbeit vor. Ihr Ziel besteht in der Entwicklung einer laserbasierten Belegungskarte, die die Erkennung von Fahrbahnrandverläufen ermöglicht. Dazu sollen nur statische Hindernisse miteinbezogen werden. Dynamische Objekte werden erkannt und aus der Belegungskarte entfernt. Das eigene Fahrzeug bewegt sich virtuell über die erstellte Karte. Diese wird unter dem Fahrzeug linear verschoben, aber nicht gedreht. Weiss et al. verwenden für ihre Tests den Laserscanner *ALASCA XT* der Firma *IBEO AS*. Er besitzt einen horizontalen Öffnungswinkel von bis zu 270° und einen vertikalen Öffnungswinkel von 3.2° bei einer Auflösung von bis zu 0.125° . Die Umgebung wird mit einer Frequenz von $10Hz$ abgetastet.

Die Erkennung dynamischer Objekte basiert auf den unscharfen Spuren, die Objekte wäh-

rend ihrer Bewegung in die gleiche Richtung als das Eigenfahrzeug in der Belegungskarte hinterlassen. Diese Spuren sind ein Hinweis auf dynamische Objekte. Entlang der Fahrzeug-Ausrichtung wird daher der Verlauf der Belegungswahrscheinlichkeit analysiert und nach dem typischen Muster gesucht, der ein bewegtes Objekt hinterlässt (s. Abbildung 1.5(a)). Die Fahrtrichtung des erkannten Objektes verläuft senkrecht zu den festgestellten Peaks in der Belegungskarte. Des Weiteren lässt sich seine Geschwindigkeit durch den durchschnittlichen Abstand der Peaks unter Zuhilfenahme der Abtastfrequenz errechnen. Die verfolgte Methode funktioniert nur für den Längsverkehr und ist rechenaufwendig vor allem in Umgebungen mit sehr vielen Objekten. Außerdem ist die Methode träge, da erst der typische „Schweif“ entstehen muss, um bewegte Objekte erkennen zu können. Dieser „Schweif“ könnte außerdem zu Fehlauflösungen bei Sicherheitsassistenzsystemen führen.

Das Belegungsgitter wird bei der Universität Ulm auch für **die Bestimmung der Fahrbahnbegrenzung** eingesetzt. Hierzu wird entlang der Fahrzeugausrichtung auf dem Belegungsgitter nach statischen Merkmalen gesucht. Dazu wird die Längsachse des Fahrzeugs in kleine Segmente unterteilt. Ausgehend von jedem Segment wird dann rechts und links nach belegten Zellen gesucht. Das Zentrum des Segments wird Richtung der nächsten Belegung geschoben. Der Fahrbahnverlauf wird durch die geschobenen Segmente rechts und links beschrieben. Die Methodik wurde in einer weiteren Arbeit [55] ergänzt, so dass der Fahrbahnverlauf durch Klothoiden und Parabel repräsentiert werden kann. Die Modell-Parameter werden online geschätzt. Die verfolgten Ansätze sind vor allem für Autobahnen und Landstraßen mit regelmäßigen begrenzenden Hindernissen konzipiert.

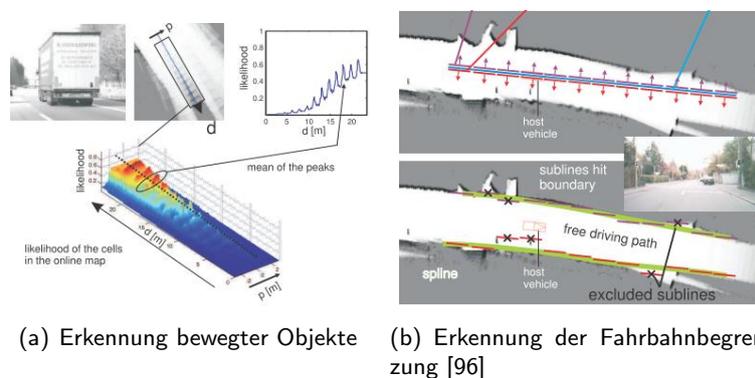


Abbildung 1.5: Belegungsgitter der Universität Ulm [96]

1.2.3 Überblick über dreidimensionale Umfeldkartierung und Objektverfolgung

Nach Einführung der zweidimensionalen Belegungsgitter durch Moravec und Elfes [66] [22] entstand in der Folge eine Vielzahl von Arbeiten im Bereich der Robotik über den Einsatz von Belegungsgittern. Mit der Zunahme der verfügbaren Rechenleistung wurden diese Karten auch immer häufiger in Richtung dreidimensionaler Umfeldkartierung erweitert. Im Folgenden soll ein Überblick über den Stand der Technik im Bereich der 3D-Umfeldkartierung und 3D-Objektverfolgung dargestellt werden.

Zweidimensionale Karten mit Höheninformationen

Eine erste Möglichkeit zur Beschreibung der Höhe in Belegungskarten besteht in der Erweiterung der klassischen Gitterstruktur um eine Höheninformation. Solche Karten werden als Höhenkarten oder 2.5D Karten bezeichnet. Jede Zelle speichert neben oder anstelle einer Belegungswahrscheinlichkeit einen oder mehrere Höhenwerte. Für die Berechnung dieser Höhenwerte existieren verschiedene Ansätze. Im Folgenden wird auf einige Arbeiten in diesem Bereich eingegangen.

In [43] wird eine zweidimensionale Gitterstruktur mit 301x301 Zellen zur Speicherung eines gemittelten Höhenwertes sowie dessen Varianz und Zuverlässigkeit in jeder Zelle mit Hilfe eines 3D Lidar-Sensors verwendet. Außerdem wird ein „*terrain label*“ als Klassifizierung der Geländeart in der Zelle eingetragen. Die Aktualisierung des Höhenwertes findet anhand einer laufenden Mittelwertbildung unter Berücksichtigung der Zuverlässigkeit, der Historie sowie der aktuellen Messung statt. Die Informationen aus der Karte werden für die Pfad-Planung von autonomen Geländefahrzeugen verwendet. Abbildung 1.6 zeigt ein Beispiel für eine solche Karte.

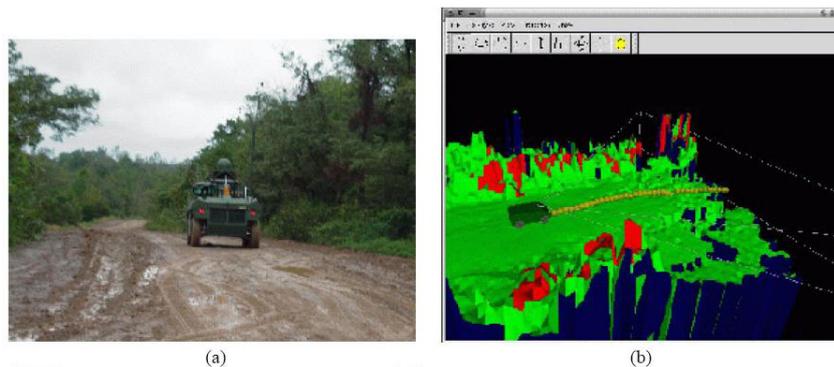


Abbildung 1.6: Beispiel einer Höhenkartierung (aus [43]): (a) Versuchsfahrzeug im Gelände (b) Höhenkarte

Auch bei [26] bildet eine zweidimensionale Gitterstruktur die Basis der Belegungskarte. Hier wird in jeder Zelle neben der höchsten belegten Höhe auch eine Belegungsverlässlichkeit dieser Höhe gespeichert. Sollte eine neue Höhenmessung durch die verwendeten *SICK*-Lasersensoren über der bisher gespeicherten liegen, so wird die neue Höhe in der Zelle gespeichert, ansonsten bleibt die bisherige Höhe erhalten. Fällt die neue Messung in einen Toleranzbereich um die bisherige Höhe, so findet eine Aktualisierung der Verlässlichkeit nach *Bayes* (s. Kapitel 2.3.3) statt. Sollte ein Sensorstrahl eine bisherige Höhe durchschießen, so wird die Verlässlichkeit dieser Höhe herabgesetzt.

[50] und [36] gehen einen alternativen Weg zur Berechnung einer Höhenkarte des Umfeldes von intelligenten Rollstühlen und kleinen zweibeinigen Laufrobotern mit kamerabasierter Wahrnehmung. Hier wird zuerst eine dreidimensionale Belegungskarte des Umfeldes mittels Stereo-Kameras erstellt. Diese wird dann auf eine 2.5D Darstellung heruntergebrochen, indem für jede xy -Position die höchste Zelle mit einer Belegungswahrscheinlichkeit über einem festgelegten Grenzwert ermittelt wird. Diese wird als Höhe der jeweiligen xy -Zelle angenommen. Eine Aktualisierung mit 32x64x32 Zellen der dreidimensionalen Karte dauert bei [50] ca. acht Sekunden.

[46] erweitern das Prinzip der 2.5D Karte dahingehend, dass sie mehrere Höhenwerte in jeder Zelle speichern. Die so entstehenden *Multi-Level Surface Maps* können auch überhängende und negative Hindernisse abbilden. Mit Hilfe der Nachbarschaft jeder Zelle kann die Überquerbarkeit der Zelle ermittelt werden. Ein Algorithmus für die Berechnung neuer optimaler Aussichtspunkte, um neue Informationen über die zu kartierende Umwelt zu sammeln, wird ebenfalls vorgestellt. Die Algorithmen wurden auf einem mobilen Roboter mit einem *SICK*-Lasersensor in verschiedenen Szenarien getestet.

Dreidimensionale Karten im Bereich Robotik

Neben den zweidimensionalen Belegungskarten mit Höhen-Werten gab es auch in der Vergangenheit eine Reihe von Arbeiten, bei denen die komplette dreidimensionale Belegungskarte im Vordergrund stand.

[47] stellte bereits 1993 ein Verfahren zur Parallelisierung des Aufbaus dreidimensionaler Belegungskarten vor. Dabei wurde der aus der Computergrafik bekannte *Bresenham*-Algorithmus (s. Anhang D) zur Diskretisierung von Linien verwendet, um die Strahlen eines Laser-Sensors in die 3D-Belegungskarte einzutragen. Die einzelnen Strahlen wurden auf parallelen Prozessoren berechnet. Damit konnte eine 64x128x192 Zellen große Karte durch eine 128x128 Sensorstrahlen umfassende Messung in 800 Millisekunden aktualisiert werden. Auch Moravec, einer der Begründer der Belegungsgitter, präsentiert in [67] eine dreidimensionale Belegungskarte mit 256x256x64 Zellen, die mit Hilfe eines Stereo-Kamera-Systems erstellt wurde. Die Aktualisierung dieser Karte benötigte noch mehrere Sekunden. In [68] ist jedoch schon von einer dreidimensionalen Karte mit 512x512x128 Zellen zu lesen, deren Aktualisierung nur noch etwa eine Sekunde dauern soll.

Die Arbeit [31] beschäftigt sich ausführlich mit der Umfeldkartierung für Laufmaschinen im Gelände. Hier werden mehrere konkrete Möglichkeiten der Umfeldkartierung wie z.B. topologische Karten, Belegungsgitter, Inferenzgitter und Histogrammgitter näher beleuchtet. [31] setzt schließlich auf ein laserbasiertes dreidimensionales Inferenzgitter, das neben der Belegungswahrscheinlichkeit weitere Daten zu den Messungen speichert. Gespeichert werden die Daten mit Hilfe eines *Octrees*.

Andreas Nüchter stellt in seiner Dissertation [70] semantische dreidimensionale Karten für mobile Roboter vor. Diese Karten beinhalten neben den rein geometrischen Informationen auch Zuordnungen von Punkten im Raum zu Objektklassen oder bekannten Strukturen. Die Karten beruhen hier nicht auf einem Belegungsgitter, sondern speichern direkt die vom Sensor erfassten Datenpunkte mit ihrer jeweiligen Position als 3D Punktwolke. Zur Speicherung der Karten werden Baumstrukturen wie die *k-d-trees* vorgestellt.

In [79] wird ein *Octree* basiertes dreidimensionales Belegungsgitter präsentiert, das mit Hilfe eines Laserscanners mit einer Ebene und einem vertikalen Öffnungswinkel von 3.0 Grad aufgebaut wird. Hier wird der Effekt genutzt, dass überhängende Hindernisse in großen Entfernungen als Wand gesehen werden. Mit dem Annähern des Fahrzeugs verschwindet das Hindernis aus dem Sichtbereich des Sensors und die zuvor entstandene Wand wird durchschossen. Das überhängende Hindernis wird somit in der richtigen Höhe im Belegungsgitter abgebildet.

1.2.4 Forschungsaktivitäten im Bereich Fahrerassistenzsysteme und autonomes Fahren

DARPA Urban Challenge

In November 2007 organisierte die DARPA (*Defense Advanced Research Projects Agency*) einen Wettbewerb zur Förderung der Entwicklung autonomer Fahrzeuge. Das Rennen fand in bebautem Gebiet einer verlassenen Kaserne statt, und sollte die Fähigkeit von autonomen Fahrzeugen zeigen, sich in einer komplexen Umgebung zu orientieren und selbständig zu fahren. Insgesamt sind 89 Teams angetreten, von denen 11 Teams, es ins Finale geschafft haben. Die Strecke ist im Vorfeld in Form von GPS-Punkten bekannt. Zusätzlich sollen auch weitere Verkehrsteilnehmer im dynamischen Umfeld berücksichtigt werden. Bei den meisten Teams kamen hoch genaue 3D Lidar-Sensoren zum Einsatz. Die Integration der Sensoren in einem Serien-Fahrzeug, wie in Abbildung 1.7(a) ersichtlich ist, ist noch nicht gegeben. Außerdem kann im seriennahen Entwicklungsumfeld nicht auf eine teure Ortungssensorik wie bei der *Urban Challenge* zurückgegriffen werden.

Kognitive Automobile

In 2006 wurde von der Deutschen Forschungsgemeinschaft der Sonderforschungsbereich (SFB) Transregio *Kognitive Automobile* gegründet. Beteiligt sind Wissenschaftler der Universität, des Forschungszentrums und des Fraunhofer IITB in Karlsruhe sowie der Technischen Universität und der Universität der Bundeswehr in München. Übergeordnete Themenstellungen dieser Forschungsinitiative sind die systematische und interdisziplinäre Erforschung der maschinellen kognition mobiler Systeme als Grundlage maschinellen Handelns [87]. Das kognitive Automobil soll dabei sowohl zu individuellem als auch zu kooperativem Wahrnehmen und Handeln fähig sein. Dazu werden Wahrnehmungsstrategien, die sowohl auf onboard-Umfeldsensorik wie Radar, Video und Lidar als auch auf die kooperative Kommunikation zwischen den Fahrzeugen basieren. Als Fusionsmethode kommen hier auch zweidimensionale Belegungsgitter zum Einsatz, in denen die Daten des 3D Lidar-Sensor *Velodyne* akkumuliert werden. In jeder Zelle sind Informationen über die Elevation an dieser Stelle enthalten. Abbildung 1.7 zeigt das Roboter-Fahrzeug „AnnieWay“ der Universität Karlsruhe und ein Beispiel des zweidimensionalen Belegungsgitters.

AKTIV

Die deutsche Forschungsinitiative AKTIV [27] („**A**daptive und **K**ooperative **T**echnologien für den **i**ntelligenten **V**erkehr“) besteht aus 29 Partnern aus der Industrie und Forschung. Dabei werden die Schwerpunkte „Verkehrsmanagement“, „Aktive Sicherheit“ und „Cooperative Cars“ verfolgt.

Das Themengebiet „Aktive Sicherheit“ umfasst die Weiterentwicklung der Fahrerassistenzsysteme „Aktive Gefahrenbremsung (AGB)“, „Integrierte Querführung (IQF)“, „Kreuzungsassistenz“, „Sicherheit für Fußgänger und Radfahrer“ und „Fahrsicherheit und Aufmerksamkeit“ [28]. Speziell für das Teil-Projekt „Aktive Gefahrenbremsung (AGB)“ wird die Fragestellung behandelt,

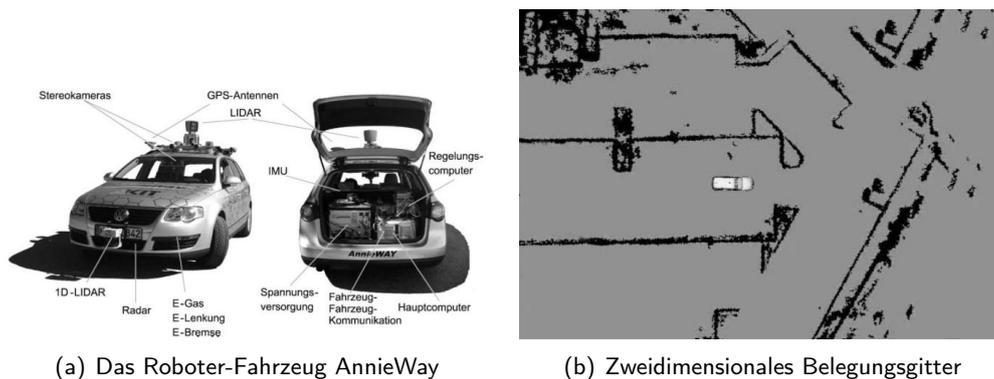


Abbildung 1.7: Kognitive Automobile [87]

wie eine automatische Notbremsung aufgrund eines erweiterten Umfeldwissens (Erfassung von Freiräumen und Randbegrenzungen) möglichst früh eingeleitet werden kann, ohne den Fahrer zu bevormunden. Die Fragestellung der erweiterten Umfelderkennung mit Hilfe von Radar- und Laser-Sensoren beschäftigt auch die vorliegende Arbeit. Die erzielten Ergebnisse wurden im Rahmen der AKTIV-Forschungsinitiative eingesetzt (s. Anhang E.1)

1.3 Problemformulierung

Eine wichtige Voraussetzung für die Einführung hoch automatisierter Fahrerassistenzsysteme (Systeme mit automatischer Längs- und Querführung und Systeme mit automatischen Notbrems- und Ausweichmanövern) ist die zuverlässige, präzise und vollständige Erkennung der relevanten Komponenten der Fahrzeugumgebung. Hier dient der Mensch mit seiner Fähigkeit, seine Umgebung wahrzunehmen, auf die relevanten Teile zu fokussieren, ihnen Bedeutungen zuzuordnen und im Gesamtkontext der Szene ein Situationsverständnis zu verschaffen, als Vorbild. Die maschinelle Umfelderkennung hat die Aufgabe, alle relevanten Informationen über das Fahrzeugumfeld aus unsicheren und fehlerbehafteten Sensorsignalen zu extrahieren. Dies beinhaltet die Erkennung sämtlicher Verkehrsteilnehmer inklusive Fußgänger, der Fahrbahninfrastruktur bestehend aus verschiedenen Fahrbahnbegrenzungen und Markierungslinien, aber auch der Freiräume und der Gebiete, die sensoruell aufgrund von Verdeckungen und eingeschränkten Sichtbereichen der Sensoren nicht erfasst werden können.

Dabei spielen ähnlich wie beim menschlichen Wahrnehmungsprozess **Modelle** vom Gesehenen und **Repräsentationen** des erworbenen Wissens eine grundlegende Rolle [82]. Es bedarf einer gleichzeitig **kompakt, einfach interpretierbaren** und möglichst vollständigen Umfeldrepräsentation, damit die nachgeschalteten FAS-Komponenten (Situationsanalyse und Verhaltensentscheidung) möglichst einfach die Umfelddaten weiterverarbeiten können. Insbesondere wird neben den etablierten objektbasierten Ansätzen eine ergänzende Repräsentation, ähnlich wie die Belegungskarten aus der Robotik benötigt, die die Repräsentation von Freiräumen und unstrukturierten durch einfache Objekt-Modelle schwer beschreibbare Hindernisse ermöglicht. Aufgrund der Vielfalt der in der Wahrnehmung eingesetzten Methoden ist es wichtig, dass die generier-

ten Umfelddaten **konsistent** zueinandergehalten werden. Gleichzeitig sollen die Daten trotz ihres hohen **Detaillierungsgrades** und aufgrund der begrenzten Rechenkapazität in Fahrzeug-Steuergeräten und Bandbreite von Fahrzeugbussystemen möglichst kompakt und **verdichtet** sein.

Darüber hinaus wird von der Umfeldwahrnehmung verlangt, die eigene Leistung fortlaufend zu schätzen. Die Grenzen der Wahrnehmungsfähigkeit und somit des Gesamtsystems müssen zuverlässig erkannt werden, damit übergeordnete System-Komponenten wie beispielsweise Diagnose-Module die notwendigen Maßnahmen einleiten können. Dies erfordert die **Einschätzung der Qualität** der vom Wahrnehmungssystem generierten Daten sowohl im Entwicklungsprozess z.B. mit Hilfe eines Referenzsystems als auch während des Betriebs ohne die Verfügbarkeit einer „Ground Truth“.

1.4 Beiträge und Ziele der Arbeit

Trotz der breit gefächerten Forschungsgemeinde, die sich mit der sensorbasierten Umfeldwahrnehmung und speziell mit der Technologie der Belegungskarten vor allem in der Robotik beschäftigt, sind einige wissenschaftliche Lücken vorhanden, deren Schließung notwendig ist, um die im letzten Abschnitt formulierte Problemstellung erfolgreich behandeln zu können:

- Die bestehenden Methoden und Umfeldrepräsentationen sind trotz der gestiegenen Rechenleistung noch nicht effizient genug, um eine **echtzeitfähige** zwei- und dreidimensionale Umfeldkartierung für Fahrerassistenzsysteme auf aktuellen Fahrzeug-Steuergeräten zu realisieren. Die Recheneffizienz der kartenbasierten Umfeldwahrnehmung im Hinblick auf Rechenzeit und Speicherverbrauch bleibt eine Herausforderung.
- Die Bemühungen der Forschungsgemeinde auf dem Gebiet der Belegungskarten konzentrieren sich auf den zeitlichen Aufbau und Aktualisierung der Belegungskarte mit Hilfe von Umfelsesensoren. Ebenso wichtige Punkte sind einerseits die Analyse der Umfelsesensoren und die Modellierung ihrer Eigenschaften, andererseits die Extraktion der relevanten Informationen aus der Belegungskarte, so dass Fahrerassistenzsysteme sie nutzen können.
- In der Literatur wird die Annahme getroffen, dass nur statische Hindernisse in einer Belegungskarte beschrieben werden können. Bewegte Objekte werden nur in der zustandsbasierten Schätzung behandelt. Dies schränkt die Einsatzmöglichkeiten der kartenbasierten Umfeldwahrnehmung stark ein. Außerdem fehlt in der Literatur ein vollständiges Konzept über die Kombination der Belegungskarten mit den objektbasierten Ansätzen für Fahrerassistenzsysteme, um Konsistenz des Umfeldmodells zu gewährleisten und Vorteile der beiden Ansätze zu kombinieren.
- Ein wichtiger Punkt, der in den bisherigen Forschungsarbeiten im Bereich der Belegungskarte nicht detailliert behandelt wird, ist die Referenzierung der kartenbasierten Umfeldwahrnehmung.
- Ein wichtiger Aspekt, der viele wissenschaftliche Arbeiten und Veröffentlichungen im Bereich maschinelle Umfeldwahrnehmung verbindet, besteht im Einsatz von teuren und hoch

1. Einleitung

performanten Umfoldsensoren. Diese Sensoren können aber für die Serienfahrerassistenzsysteme aufgrund ihrer hohen Kosten und Baugrößen nicht verwendet werden. Seriennahe Umfoldsensoren hingegen sind meistens durch eine höhere Unsicherheit bei eingeschränkter Leistungsfähigkeit gekennzeichnet. Es erfordert hier robuste und neue Methoden, um diese Sensoren optimal einsetzen zu können.

Die Arbeit adressiert genau diese Lücken und versucht sie durch verschiedene wissenschaftliche Methoden zu schließen. Sie beschäftigt sich intensiv mit belegungskartenbasierter Umfeldrepräsentation als wichtigen Grundstein eines stark vernetzten Wahrnehmungssystems. Dieses System basiert auf verschiedenen Experten-Modulen, die auf bestimmte Wahrnehmungsaufgaben spezialisiert sind und die sich gegenseitig befruchten. In der Arbeit wird daher sowohl die direkte Nutzung der Belegungskarte für Fahrerassistenzsysteme als auch ihre Verwendung innerhalb der Wahrnehmung zur Stützung der anderen Module beschrieben. Abbildung 1.8 zeigt eine vereinfachte Systemarchitektur der Wahrnehmung. Die rot gekennzeichneten Module und Kommunikationspfade werden von der vorliegenden Arbeit behandelt. Die Extraktionsmodule stellen hier eine Zwischenschicht zwischen den Basis-Wahrnehmungsmodulen und der Situationsanalyse und Verhaltensentscheidung. Die entwickelten Methoden werden prototypisch für die Realisierung einer Aktiven Gefahrenbremsung (AGB) und einer Stauassistentz eingesetzt.

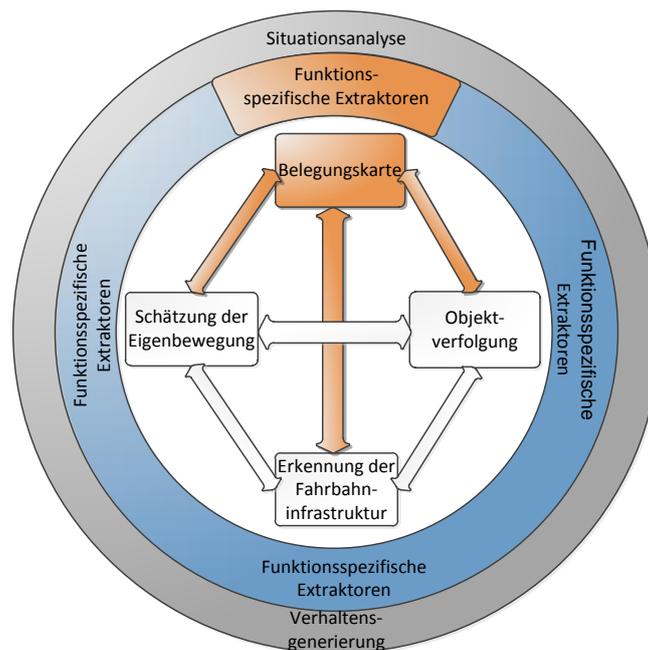


Abbildung 1.8: Grobe Systemarchitektur der Umfeldwahrnehmung und ihre Schnittstellen zur Situationsanalyse und Verhaltensentscheidung

Die Ziele der Arbeit können in den folgenden Punkten zusammengefasst werden:

1. Bereitstellung von theoretischen und praktischen Methoden für die Analyse von Umfoldsensoren mit dem Ziel, probabilistische Sensormodelle herzuleiten.
2. Entwicklung und Vergleich verschiedener zwei- und dreidimensionaler belegungskartenba-

- sierter Umfeldrepräsentationen u.a. zur Freiraumerkennung unter Berücksichtigung von Effekten und Unsicherheiten verschiedener Umfeldsensoren.
3. Entwicklung von Extraktionsmethoden zur Verdichtung der Daten aus dem Belegungs-gitter und zur Herleitung von nutzbaren Umfelddaten für Fahrerassistenzsysteme.
 4. Erarbeitung und prototypische Umsetzung eines Konzepts zur Erweiterung des Belegungs-gitters um die Beschreibung bewegter Hindernisse und zur Kombination der belegungs-kartenbasierten Umfeldrepräsentation mit der modellbasierten Objekt-Verfolgung. Beide Ansätze sollen voneinander wechselseitig profitieren.
 5. Entwicklung und Validierung von Methoden zur quantitativen Bewertung von zweidimen-sionalen Belegungs-gittern sowohl mit und ohne Hilfe einer Referenz.

1.5 Struktur und Methodik der Arbeit

Die Struktur der Arbeit leitet sich aus der verfolgten Methodik (siehe Abbildung 1.9) und der Kette der Datenverarbeitung innerhalb der Umfeldwahrnehmung ab. Nach den einleitenden Gedanken zu Fahrerassistenzsystemen und Umfeldwahrnehmung folgt in Kapitel 1 die Problemformulierung und ein Überblick über die Forschungsaktivitäten auf dem Gebiet der Belegungskarte und Objekt-Verfolgung. Aus den wissenschaftlichen Lücken, den Anforderungen zukünftiger Fahrerassistenzsysteme und der Zielarchitektur des Wahrnehmungssystems lassen sich unmittelbar die Ziele der Arbeit ableiten.

Die notwendigen Grundlagen für diese Arbeit werden in Kapitel 2 präsentiert. Hier werden neben der Beschreibung der eingesetzten Umfeldsensoren eine Einführung in die Schätztheorie und ihre Anwendung zur Aktualisierung der Belegungskarten und in der Objektverfolgung gegeben. In diesem Kapitel erfolgt auch eine Begriffsklärung, die den Unterschied zwischen einer belegungs-kartenbasierten Umfeldrepräsentation und einer Objektbeschreibung verdeutlichen soll.

Als Basis für die Sensordatenverarbeitung und für die Umfeldwahrnehmung wird in Kapitel 3 die Sensordatenanalyse detailliert behandelt und der Beitrag der Arbeit in diesem Bereich vorgestellt. Hier werden sowohl ein probabilistischer Ansatz zur Sensormodellierung als auch Methodiken zur Sensordatenanalyse, gestützt durch experimentelle Ergebnisse an Beispielen der Radar- und Laserscannersensoren, präsentiert. Daran schließt sich in Kapitel 4 die Diskussion verschiedener Repräsentationen für eine kartenbasierte Umfeldwahrnehmung. Eine besonders innovative und effizient umsetzbare Idee stellt dabei die modellbasierte Freiraum-Verfolgung dar. Eine Erweiterung um die dritte Dimension erfolgt dann in Kapitel 5, wo schrittweise die Überfahrbarkeit und die Ausdehnung der Hindernisse in der vertikalen Richtung mit Hilfe von verschiedenen Ansätzen eingeführt werden.

Da die Einsatzgebiete von Fahrerassistenzsystemen meistens hoch dynamisch sind, wird in Kapitel 6 ein Konzept zur Erweiterung der kartenbasierten Umfeldwahrnehmung um die Beschreibung dynamischer Hindernisse und zu deren Kopplung mit der modellbasierten Objekt-Verfolgung beschrieben und dessen Umsetzung diskutiert.

Aufgrund der großen Datenmenge eines Belegungs-gitters und dessen niedrigen Abstraktionsni-

veaus ist ein Extraktionsschritt für die Übertragung der Daten auf einem Bussystem und somit die Realisierung einer Assistenzfunktion essentiell. Deshalb wird in Kapitel 7 ein Konzept zur funktionsgesteuerten Extraktion von verschiedenen Umfeldinformationen aus Belegungskittern beschrieben.

Anschließend beschäftigt sich Kapitel 8 mit der Bewertung von Belegungskittern. Es werden hier sowohl Methoden, die auf ein Umfeldreferenzsystem basieren, als auch Verfahren zur online Selbstdiagnose und ihrer Validierung aufgeführt. Die Arbeit wird dann mit einer Zusammenfassung der Beiträge und einem Ausblick hinsichtlich möglicher Erweiterungen abgeschlossen.

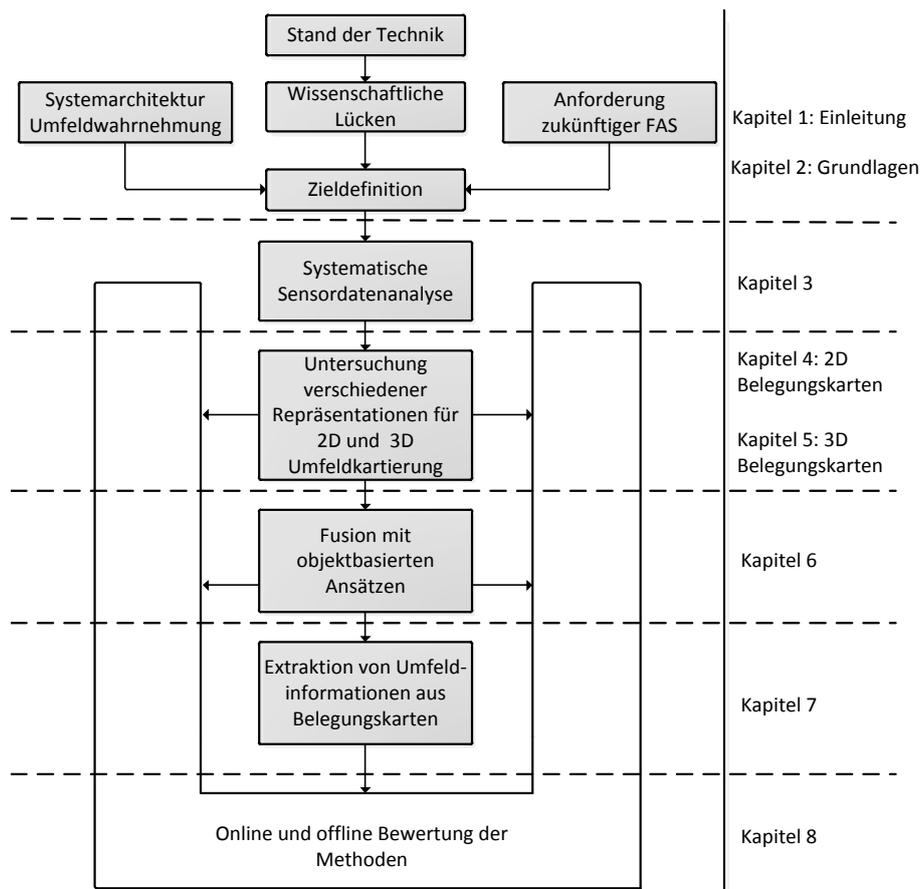


Abbildung 1.9: Methodik und Struktur der Arbeit

2 Grundlagen

Dieses Kapitel enthält eine Reihe von Grundlagen, die dem Verständnis der weiter- und neuentwickelten Methoden in der vorliegenden Arbeit dienen sollen. Es beginnt mit einem Überblick über die eingesetzten Umfoldsensoren, ihre Funktionsprinzipien und ihre grundsätzlichen Eigenschaften. Danach wird auf einige Grundlagen der Schätztheorie sowie ihre Anwendung in der kartenbasierten Umfeldwahrnehmung und in der multisenoriellen modellbasierten Objektverfolgung eingegangen. Eine gute Ergänzung zu diesem Grundlagen-Kapitel bietet der Anhang.

2.1 Grundlagen der eingesetzten Sensoren

In der vorliegenden Arbeit kommen vorwiegend Radar- und Laser-Sensortechnologien zum Einsatz. Auf die Grundlagen und Beschreibung der verwendeten Systeme beider Technologien wird in diesem Unterkapitel eingegangen.

2.1.1 Grundlagen zur Radar-Sensorik

Der Begriff Radar bedeutet *RA*dio *D*etection *A*nd *R*anging. Radarsysteme detektieren und lokalisieren reflektierende Objekte durch das Senden von elektromagnetischen Wellen und Empfangen deren Echos. Dabei können folgende Informationen gewonnen werden [Brahmi 2010]:

- Entfernung über die Laufzeit
- Geschwindigkeit über den Dopplereffekt
- Winkel über die Richtwirkung

Allgemein empfängt ein Radar mit gerichteter Antenne (Antennengewinn G und effektiver Wirkfläche A der Empfangsantenne) und der Sendeleistung P_T ein Echo eines Objektes mit der Reflexionsfläche σ in der Entfernung R mit der folgenden Leistung [76]:

$$P_R = \frac{P_T G^2 \lambda^2 \sigma}{(4\pi)^3 R^4} \quad (2.1)$$

Die letzte Gleichung ist auch in der Literatur als Radar-Gleichung bekannt. In der Automobilindustrie werden vorwiegend Primärradare¹ verwendet, die bei einer Frequenz von meist 77 GHz ar-

¹Im Gegensatz zu Primärradaren senden transpondergestützte Sekundärradare elektromagnetische Wellen, die von einem am Objekt vorhandenen Transponder empfangen werden. Die empfangenen Signale werden verarbeitet und mit zusätzlichen Informationen wieder in Form einer elektromagnetischen Welle zurück an das Radar gesendet. Einsatz findet dieses Radar hauptsächlich im militärischen Bereich und in der Flugsicherung.

beiten und zur Bestimmung von Entfernungen und Geschwindigkeiten dienen. Hierfür wird beim Messprinzip zwischen dem Impulsradar und dem CW-Radar (Dauerstrichradar, engl. **C**ontinuous **W**ave Radar unterschieden. Das Impulsradar sendet elektromagnetische Wellen in Form von kurzen Pulsen und empfängt diese wieder. Beim CW-Radar hingegen werden elektromagnetische Wellen konstant gesendet und parallel empfangen. Die Entfernungsmessung kann beim CW-Radar am einfachsten stattfinden, wenn das Sendesignal frequenzmoduliert wird. Das Radar wird dann auch als *FMCW*-Radar (frequenzmoduliertes Dauerstrichradar, engl. **F**requency **M**odulated **C**ontinuous **W**ave Radar) bezeichnet. Abbildung 2.1 beschreibt die Arbeitsweise des FMCW-Radars.

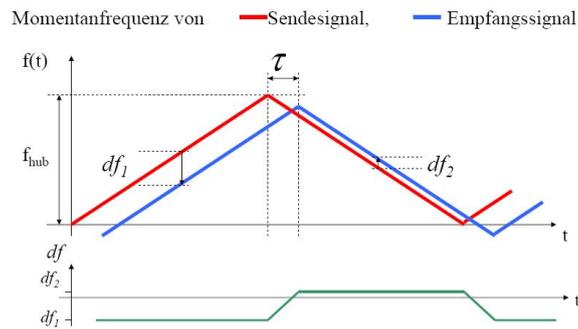


Abbildung 2.1: Sendesignalform eines linearen FMCW-Radars [76]

Bestimmung der Entfernung und Geschwindigkeit mit Hilfe eines FMCW-Radars

Ein FMCW-Radar sendet ein lineares frequenzmoduliertes Trägersignal mit der Trägerfrequenz f_0 . Dabei setzt sich das Sendesignal aus verschiedenen Segmenten zusammen, deren Frequenz rampenförmig moduliert wird. Seine Frequenz f_S kann wie folgt ausgedrückt werden [76]:

$$f_S(t) = \begin{cases} f_0 + \frac{f_{hub}}{T} \cdot t & \text{für } 0 \leq t \leq T \\ f_0 + f_{hub} - \frac{f_{hub}}{T} \cdot (t - T) & \text{für } T \leq t \leq 2T \end{cases} \quad (2.2)$$

Befindet sich ein Radarziel mit der Relativgeschwindigkeit v_r in der Anfangsentfernung R_0 , so lässt sich seine radiale Entfernung zeitlich wie folgt beschreiben:

$$R(t) = R_0 + v_r \cdot t \quad (2.3)$$

Das Empfangssignal ist um die Signallaufzeit τ gegenüber dem Sendesignal verzögert. Elektromagnetische Wellen breiten sich mit der Lichtgeschwindigkeit c , so dass folgender Zusammenhang für die Laufzeit gilt:

$$\tau = \frac{2R}{c} \quad (2.4)$$

Durch den Dopplereffekt weist außerdem das empfangene Signal eine Dopplerfrequenzverschiebung f_D auf, die gemäß Gleichung 2.5 proportional zur Relativgeschwindigkeit ist [44].

$$f_D = -\frac{2f_0v_r}{c} \quad (2.5)$$

Mit Hilfe eines Mischer und einer FFT (**F**ast **F**ourier **T**ransformation), kann die Frequenzverschiebung zwischen der Empfangsfrequenz f_E und der Sendefrequenz f_s mit Hilfe der folgenden Gleichung gewonnen werden [44]:

$$df(t) = |f_S(t) - f_E(t)| = \begin{cases} \frac{f_{hub}}{T} \cdot \tau - f_D & \text{für } \tau \leq t \leq T \\ \frac{f_{hub}}{T} \cdot \tau + f_D & \text{für } T + \tau \leq t \leq 2T \end{cases} \quad (2.6)$$

Daraus lassen sich die Laufzeitfrequenzverschiebung f_R und die Entfernung R ableiten:

$$f_R = \frac{f_{hub}}{T} \cdot \tau \quad (2.7)$$

$$R = \frac{c}{2} \cdot \tau = \frac{c}{2} \cdot T \cdot \frac{f_R}{f_{hub}} \quad (2.8)$$

Wie aus Gleichung 2.6 ersichtlich ist, enthält die Frequenzverschiebung sowohl die Laufzeitfrequenzverschiebung als auch die Dopplerfrequenzverschiebung. Daher werden in der Regel zwei Frequenz-Rampen verwendet, um die beiden Unbekannten f_R und f_D bestimmen zu können.

Winkelbestimmung

Die Bestimmung des Winkels kann über die Richtwirkung der Antenne oder über Triangulationsverfahren erfolgen [98]. Erfolgt die Winkelbestimmung über die Richtwirkung der Antenne, so werden mehrere sogenannte Radar-“Keulen“ ausgesendet. Werden nun die Amplituden der Antennendiagramme der Echos miteinander verglichen, so kann auf den Winkel mit dem das Echo eintrifft, geschlossen werden. Der Überlappungsbereich der Antennendiagramme ist entscheidend für die Genauigkeit des Amplitudenvergleichs.

Das Doppel Long Range Radar System

Beim eingesetzten Radar-System handelt sich um zwei Long Range Radar-Sensoren (LRR3) der dritten Generation. Diese Sensoren arbeiten im Frequenzbereich zwischen 76 und 77 GHz und eignen sich vor allem zur Erkennung von weit entfernten Objekten bis zu 250 m. Die beiden Sensoren werden am Platz der Nebel-Scheinwerfer eingebaut (s. Abbildung A.1(a)) und besitzen zusammen einen Öffnungswinkel von 60 Grad im Nahbereich. Einige charakteristische Eigenschaften eines LRR3-Sensors sind in Tabelle 2.1 zusammengefasst

Tabelle 2.1: Technische Daten des Long Range Radar Sensors der dritten Generation

Öffnungswinkel	30°
Reichweite	0,5 ... [250]m
Objekttrennfähigkeit	
über den Abstand	[1]m
über die Geschwindigkeit	[0,6]m/s
über den Winkel	≈ 4°

2.1.2 Grundlagen zu Laserscannersensoren

Für den Aufbau der 2D und der 2.5D Belegungskarten wurden in der Arbeit für die Automobilindustrie taugliche Laserscannersensoren eingesetzt. Solche Sensoren sind besonders gut geeignet für eine kartenbasierte Umfeldrepräsentation, weil sie ein detailreiches Bild der Umgebung liefern. Außerdem lassen sich aus den Rohdaten eines Laserscanners relativ einfach Informationen über Freiräume ableiten. Das Messprinzip eines Laserscanners basiert auf Lichtlaufzeitmessung. Eine Laser-Diode sendet ein ultrakurzes Laserimpuls aus, das von der Oberfläche eines in der Ausbreitungsrichtung befindlichen Gegenstandes diffus reflektiert wird. Je nach Eigenschaft der Oberfläche des vermessenen Objektes und Einfallswinkel wird der einfallende Laserimpuls zu unterschiedlichen Anteilen absorbiert, reflektiert und diffus gestreut. Ein Teil von der reflektierten Welle gelangt wieder zurück zum Laserscanner und wird von einem Lasersensor im Empfänger registriert. Aus der Zeit, die dieser Vorgang benötigt und der bekannten Lichtgeschwindigkeit, lässt sich die Entfernung zum getroffenen Objekt bestimmen. Konkret werden beim Senden des Laserimpulses mehrere Zähler gestartet, die mit der Überschreitung einer vordefinierten Spannungsschwelle am Empfänger gestoppt werden. Dadurch ist das Verfahren in der Theorie mehrzielfähig. Dabei hängt die erreichte Entfernungsauflösung von der Zähler-Frequenz und -Genauigkeit ab. Abbildung 2.2 verdeutlicht dieses Prinzip.

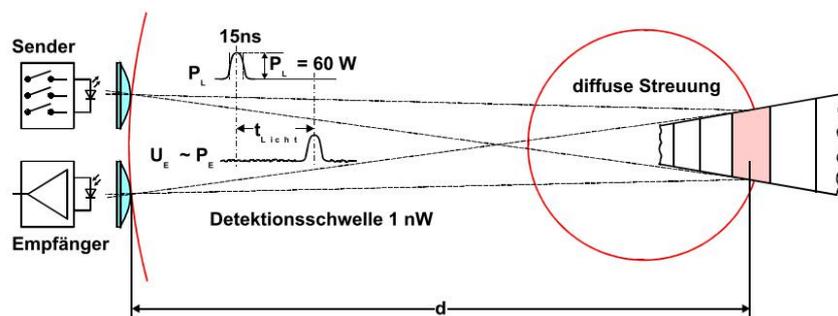


Abbildung 2.2: Laufzeitmessung und diffuse Streuung [84]

Beim Laserscanner wird der Laserstrahl durch einen rotierenden Spiegel in eine bestimmten Raumrichtung abgelenkt. Jeder Winkelschritt wird als Kanal bezeichnet. Durch die Scan-Eigenschaft des Sensors entstehen somit asynchrone Abstandsinformationen, denn jede Kanalmessung entspricht dem Zeitpunkt, wann der Rotor den Winkel des Kanals erreicht.

Wird für das zu erfassende Objekt von einem diffusen Strahler ausgegangen, so lässt sich die empfangene Rückstreuleistung gemäß der Strahlgeometrie in Abbildung 2.3 wie folgt berechnen [84] [32].

$$P_E = c \cdot \frac{P_L}{\pi^2 \cdot \sin^2 \chi \cdot d^4} \cdot A \cdot \cos \eta \cdot \cos \gamma \quad (2.9)$$

Dabei haben die genutzten Variablen folgende Bedeutungen:

- c : Reflektivität des Gegenstands,
- P_L : Sendeleistung des Senders,
- χ : Strahldivergenz des Lasersignals,
- γ : Einfallswinkel auf den Empfänger,
- η : Einfallswinkel auf das Objekt,
- d : Distanz zum Objekt,
- $A = \pi \cdot \sin^2 \chi \cdot d^2$: Querschnittsfläche des Lasersignals.

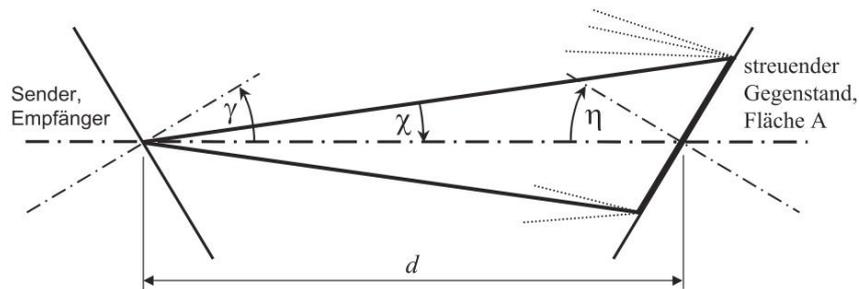


Abbildung 2.3: Strahlgeometrie bei der Vermessung eines Hindernisses mit einem Laserstrahl [32]

Aus Gleichung 2.9 wird ersichtlich, dass die empfangene Leistung auf einen niedrigen Wert fällt, falls die Laser-Signale bei spitzen Einfallswinkeln auf den Empfänger oder auf den reflektierenden Gegenstand treffen. Außerdem sinkt die Energie am Empfänger proportional zu $1/d^2$ ab, solange die vom Laser bestrahlte Fläche kleiner als die Objektfläche ist. Ist die ausgestrahlte Fläche größer als das Objekt, resultiert eine Verringerung der Energie proportional zu $1/d^4$.

Der IDIS Laserscanner

Abbildung 2.4 zeigt den in der Arbeit eingesetzten seriennahen Laserscanner der Firma Hella mit einer Scan-Ebene. Dieser Sensor ist durch eine niedrige Auflösung am Rand seines Sichtbereiches (4°) gegenüber einer höheren Auflösung im zentralen Bereich (1°) gekennzeichnet. Tabelle 2.2 fasst die wichtigsten Eigenschaften des Sensors zusammen.



Abbildung 2.4: Der eingesetzte Vorserien Laserscannersensor

Horizontaler Öffnungswinkel	max. 160°
Anzahl der Kanäle	max. 91 Kanäle
Horizontale Auflösung	min. 1°, max. 4°
Vertikaler Öffnungswinkel	3°
Zykluszeit	60 ms
Reichweite	100 m
Genauigkeit Abstandsmessung	± 0.5 m
Auflösung Abstandsmessung	0.1 m
Wellenlänge	905 nm
Motordrehfrequenz	16.6 Hz

Tabelle 2.2: Eigenschaften des eingesetzten Laserscanners

Der Ibeo Lux Sensor

Alternativ wurde der *Ibeo LUX* Laserscanner eingesetzt. Er besitzt, wie in Abbildung 2.5(a) dargestellt, einen vertikalen Öffnungswinkel von 3.2°, unterteilt in vier Scanebenen mit je 0.8°. Der horizontale Sichtbereich der Ebenen 1 und 2 erstreckt sich von -60° bis 35° und der Ebenen 3 und 4 von -50° bis 50° . Insgesamt ergibt sich somit ein Winkel von 110° . Bei einer Scanfrequenz von 12.5 Hz erreicht der Sensor innerhalb einer Ebene im zentralen Bereich zwischen -10° und $+10^\circ$ eine Winkelauflösung von 0.25° und durch die Verschiebung von zwei Ebenen (s. Abbildung 2.5(c)) insgesamt 0.125° . In den Intervallen $[-30^\circ; -10^\circ]$ und $[10^\circ; 30^\circ]$ beträgt die Auflösung insgesamt 0.25° und im restlichen äußeren Bereich 0.5° .

2.1.3 Der 3D Laser Sensor

Für die später beschriebenen Methoden zur dreidimensionalen Umgebungserfassung kam in dieser Arbeit ein 3D LIDAR Sensor zum Einsatz. Die Abkürzung LIDAR bedeutet dabei **L**ight **D**etection **A**nd **R**anging und bezeichnet die Entfernungsmessung durch Laserstrahlen.

Der 3D Laser Sensor nimmt ähnlich wie eine gewöhnliche Digitalkamera ein Bild der Umgebung auf. Zusätzlich zu einem Intensitätswert liefert der Sensor jedoch zu jedem Pixel eine Entfernungsinformation. Das System besteht aus einer Sendeeinheit, die die Umgebung mit einem ultrakurzen Lasersignal genannt *Flash* ausleuchtet. Über eine Optik im Sensor werden die reflektierten Signale auf die fokale Ebene bestehend aus einer Detektor-Matrix gelenkt. Jedes Element der Matrix - auch Pixel genannt - deckt einen Bereich im Raum ab und kann getrennt getriggert

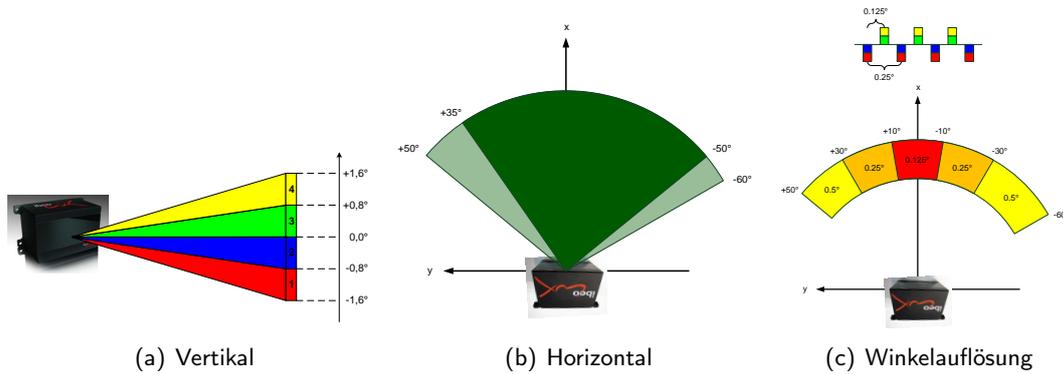


Abbildung 2.5: Öffnungswinkel des ibeo LUX Laserscanners

werden. Es ist somit in der Lage eine Entfernung zu dem reflektierenden Objekt durch das Zählen der Signallaufzeit zu bestimmen. Über ein geeignetes Modell der Optik kann für jedes Pixel eine Position im Raum berechnet werden. Abbildung 2.6 zeigt ein Beispiel für eine 3D Punktwolke und ein zugehöriges Kamerabild. Die Helligkeit der Punkte entspricht dabei der gemessenen Intensität.

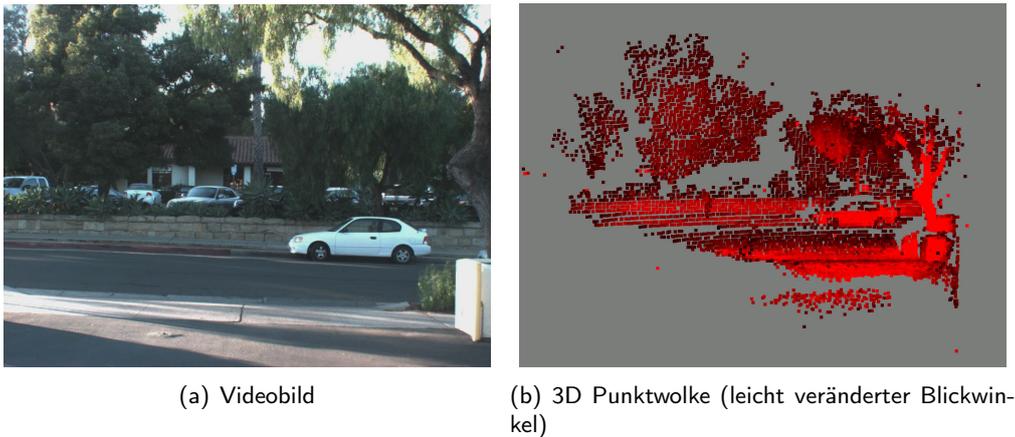


Abbildung 2.6: Rohdaten des eingesetzten 3D Sensors

Vorteile dieser Technologie liegen in der Möglichkeit, eine vollständige 3D Rekonstruktion der Szene unter Benutzung kompakter Send- und Empfangskomponenten durchzuführen, ohne aufwändige Rechenalgorithmen wie bei Stereo-Systemen und ohne die Verwendung beweglicher Teile wie bei der Scan-Technologie.

Der im Rahmen dieser Arbeit verwendete 3D Sensor ist ein prototypischer Sensor mit einer Auflösung von 128x128 Pixeln bei einem horizontalen und vertikalen Öffnungswinkel von 45°. Die Taktfrequenz des Sensors liegt zwischen 10 Hz und 20 Hz. Details zur Modellierung dieses Sensors werden in Kapitel 5 bei der Vorstellung der dreidimensionalen kartenbasierten Umfeldwahrnehmung behandelt.

2.1.4 Sensoren zur Erfassung der Eigenbewegung

Neben den Umfoldsensoren, die die Umgebung des Fahrzeugs abtasten, ist die Erfassung der Position und Bewegung des Eigenfahrzeugs von entscheidender Bedeutung. Mit Hilfe der Eigenbewegungsdaten können die Sensordaten der Umfoldsensoren korrekt interpretiert werden. Denn die im Fahrzeug verbauten Umfoldsensoren bewegen sich mit dem Fahrzeugaufbau, so dass sich ihre Lage und Position stets ändern. Für die zeitliche Korrelation der Messdaten aus den Umfoldsensoren ist das Wissen über den vom Eigenfahrzeug zurückgelegte Weg notwendig. Außerdem ist die Lage der Umfoldsensoren (Nick-, Wank-, und Gierwinkel) im Bezug zur Fahrbahnoberfläche insbesondere für 3D messende Sensoren eine wichtige Information.

In der vorliegenden Arbeit konnte auf ein System zur Eigenbewegungsschätzung zurückgegriffen werden. Kern dieses Systems ist eine Inertialplattform, die in Serienfahrzeugen der Oberklasse eingesetzt wird. Die Inertialplattform liefert mit Hilfe von Sensoren die Beschleunigungen und die Drehraten in den drei Raumdimensionen.

Neben der Inertialplattform besteht das System aus Odometrie-Sensoren, die die Bewegung an jedem Rad erfassen. Diese werden in der Recheneinheit der Inertialplattform mit den Daten aus den Beschleunigungs- und Drehratensensoren fusioniert. Außerdem verfügt das System über einen Algorithmus für die Berechnung der absoluten Winkel und zur Offsetkompensation, die aufgrund der auftretenden Drifteffekte der Sensoren erforderlich ist. Für die Herstellung des Bezugs zur Fahrbahnoberfläche werden zusätzlich die Höhenstand-Sensoren vom Fahrwerk, die u.a. für die Luftfederung eingesetzt werden, miteinbezogen. Der Ansatz wurde in [Bär 2009] vorgestellt.

2.1.5 Das Umfeldreferenzsystem

Die in Kapitel 8 beschriebenen Bewertungsmethoden von zweidimensionalen Belegungsgittern basieren auf ein bestehendes Referenzsystem für Umfoldsensoren [7]. Ein Referenzsystem für Umfeldwahrnehmung muss per Definition um ein vielfaches genauer als die eingesetzten Umfoldsensoren sein und das perfekte Abbild der Realität - sogenannte „*Ground Truth*“ - möglichst gut annähern. Da „*Ground Truth*“ ein theoretisches Konzept ist, wird versucht durch die Kombination verschiedener hochgenauer Lokalisierungssysteme wie z.B. satellitengestützte Inertialplattformen die Realität zu approximieren.

Das eingesetzte Referenzsystem [7] basiert auf *Differential GPS* (DGPS), das die hochgenaue Position- und Geschwindigkeitsbestimmung eines Fahrzeugs im cm-Bereich ermöglicht. Probleme dieser Technologie sind die begrenzte Verfügbarkeit aufgrund der notwendigen freien Sicht zu den Satelliten und die meistens geringe Messrate. Aufgrund dieser Nachteile wurde das System durch eine Inertialplattform ergänzt, welche die Beschleunigungen und Drehraten des Fahrzeugs dreidimensional messen kann. Durch die zweifache Integration der Daten aus der Inertialplattform können die Position, die Geschwindigkeit und die Lage eines Fahrzeugs mit hohen Messraten und Verfügbarkeit ausgegeben werden. Dazu wird durch die regelmäßige DGPS-Stützung der Positionsdrift der Inertialnavigation kompensiert. Werden sowohl das Eigenfahrzeug als auch ein Fremdfahrzeug mit diesem System ausgestattet, so können die Bewegungszustände beider Fahrzeuge in cm-Bereich bestimmt. Durch eine anschließende Koordinatentransformation können auch die relativen Zustandsgrößen des Fremdfahrzeugs ermittelt werden. Die Referenz für

die Länge, Breite und Höhe ist aufgrund des a priori-Wissens über die eingesetzten Fahrzeuge vorhanden. Zusätzlich ist es möglich, die Position von statischen Objekten offline einzumessen und diese durch die Verfügbarkeit der globalen Position des Eigenfahrzeugs in eine relative Information umzurechnen. Zur online Bestimmung der relativen Lage des Vorderfahrzeugs z.B. während der Durchführung eines Testmanövers, kann ein WLAN-Netzwerk dazu genutzt werden, die Daten in einem der beiden Fahrzeuge zu sammeln. Die Synchronisation der unterschiedlichen Datenströme kann über die hochgenauen GPS-Zeitstempel erfolgen. Abbildung 2.7 zeigt den Aufbau dieses Referenzsystems für die beispielhafte Bewertung eines Radar-Sensors.

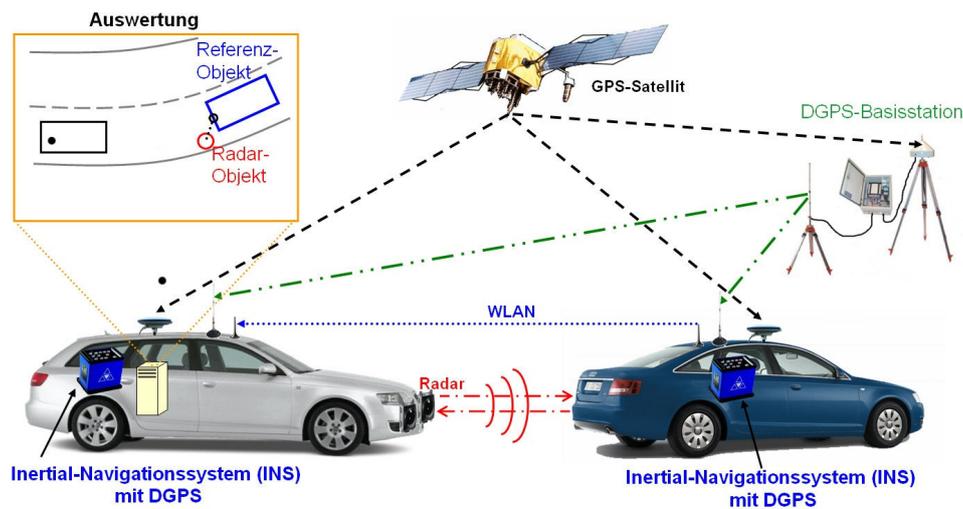


Abbildung 2.7: Der Referenzmessaufbau

Trotz der hochgenauen und teuren Messsysteme, liefert das Referenzsystem ein Abbild der Realität mit nur einer endlichen Genauigkeit, die abhängig von den Szenenbedingungen ist. Außerdem ist dieses Abbild oft unvollständig, weil nicht alle Objekte in der Umgebung mit dem System vermessen werden können. Zusätzlich ist die Referenzierung beschränkt auf die abstrakte Objektbeschreibung des Umfelds, weil das System ursprünglich für die Referenzierung von objektmessenden Sensoren konzipiert wurde. Aus diesen Gründen sind verschiedene Transformations- und Verarbeitungsschritte notwendig für z.B. die Analyse von Rohdaten eines Laserscanners (s. Unterkapitel 3.4) oder für die Bewertung einer kompletten Belegungskarte (s. Kapitel 8). Dieser letzte Punkt wird in der Arbeit gezielt behandelt.

2.2 Koordinatensysteme

Koordinatensysteme sind wichtige Hilfsmittel, um die Einbaulagen von Umfoldsensoren, ihre Messdaten und die fusionierten Umfelddaten in einem multisensoriellen System beschreiben zu können. In der vorliegenden Arbeit werden folgende Typen von Koordinatensystemen verwendet:

- **Das Konstruktionskoordinatensystem:** In diesem Koordinatensystem werden die Ein-

baupositionen und Lagen der Umfoldsensoren beschrieben. Dieses Koordinatensystem hängt von den jeweiligen Konstruktionsdaten des Fahrzeugs ab. Sein Ursprung liegt ungefähr bei der Mitte der Vorderachse.

- **Die Sensorkoordinatensysteme:** In diesen Koordinatensystemen werden die Daten des jeweiligen Sensors beschrieben. Der Ursprung liegt in der Regel in der Mitte des Senders des jeweiligen Sensors.
- **Das Umfeldkoordinatensystem:** In diesem Koordinatensystem werden die fusionierten Sensordaten sowie alle generierten Daten in der Umfeldwahrnehmung beschrieben. Der Ursprung dieses Koordinatensystems liegt bei der Mitte der Hinterachse projiziert auf dem Boden.
- **Das Kartenkoordinatensystem:** Für die Beschreibung der Zellen innerhalb des zweidimensionalen Belegunggitters wird auf einem mit dem Fahrzeug mitgeführten und global ausgerichteten Koordinatensystem zurückgegriffen. Die Ausrichtung des Koordinatensystems entspricht der Anfangsorientierung des Fahrzeugs.

Abbildung 2.8 fasst grafisch die eingesetzten Koordinatensysteme zusammen.

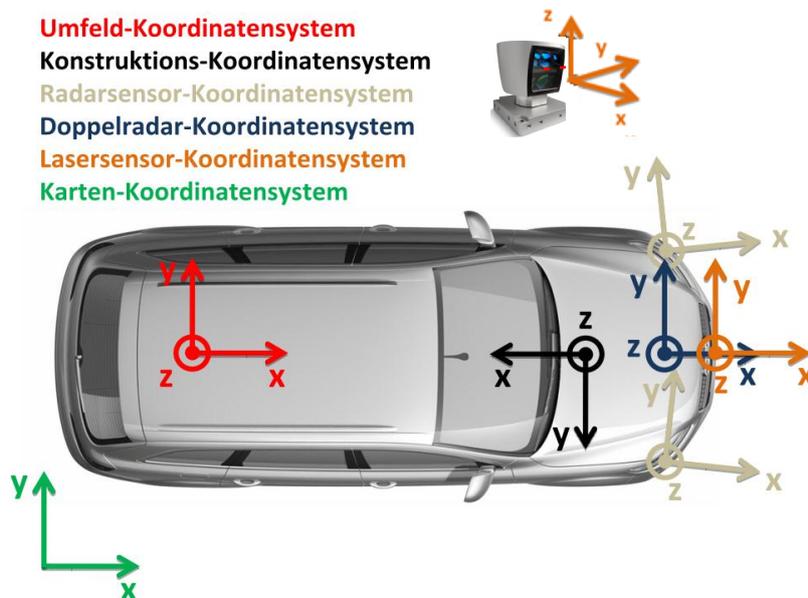


Abbildung 2.8: Verwendete Koordinatensysteme

2.3 Grundlagen der kartenbasierten Umfeldwahrnehmung

2.3.1 Formale Definition

Für den Einsatz der Belegungskarten im Bereich der Fahrerassistenzsysteme ist eine präzise, formale und handhabbare Definition des Begriffs Belegungskarte notwendig. Auch der Unterschied zu der Objektliste muss klar dargestellt sein, damit diese beiden Umfeldrepräsentationen miteinander kombiniert werden können. Eine erste Abhilfe im Definitionsprozess kann die Betrachtung der geographischen Karten aus dem Gebiet der Kartographie verschaffen. Dort werden Karte und Kartographie beispielsweise wie folgt definiert:

Eine Karte ist eine maßstäblich verkleinerte, generalisierte und erläuterte Grundrissdarstellung von Erscheinungen und Sachverhalten der Erde, der anderen Weltkörper und des Weltraumes in einer Ebene. [37]

Eine Karte präsentiert ein maßgebundenes und strukturiertes Modell räumlicher Bezüge und Objekte. [51]

In der Kartographie gilt als raumbezogene Information jede Angabe, in der zur Sachaussage über ein Objekt auch dessen geometrische Festlegung in einem Bezugssystem gehört. [38]

Aus diesen Definitionen können drei typische Aspekte für eine Karte entnommen werden:

- **Der Raumbezug:** Eine Karte enthält raumbezogene Daten, die unterschiedlich abstrakt sein können. Für die Nutzung der Karte ist außerdem eine Referenzposition innerhalb der Karte z.B. die eigene Position notwendig.
- **Die geometrische Darstellung:** Aus dem Maßstab einer Karte, können die enthaltenen Daten in eine geometrische Darstellung überführt werden.
- **Die Notwendigkeit einer Interpretation:** Eine Karte bildet verschiedene Daten auf dem Raum ab. Die Herleitung von Bedeutungen, komplexen Zusammenhängen und Sachverhalten erfordert die gezielte Interpretation und Analyse der Karteninhalte.

Analog zu den geographischen Karten hat eine Belegungskarte im Bereich der Fahrerassistenzsysteme die Aufgabe, lokale Umfeldinformationen relativ zum Eigenfahrzeug möglichst genau abzubilden. Im Gegensatz zu vielen Forschungsarbeiten im Bereich der Robotik, die sich mit topologischen Karten beschäftigen, beschränkt sich diese Arbeit auf die Betrachtung von metrischen Belegungskarten auch geometrische Karten genannt. Basierend auf diesen ersten Betrachtungen kann eine formale Definition einer Belegungskarte angegeben werden.

Definition Belegungskarte: Eine Karte M wird als ein Tupel $(W, f, E, \mathbf{X}_{ego})$ definiert. Die enthaltenen Variablen haben folgende Bedeutungen.

- W bezeichnet den Raum oder die lokale Welt, in der sich das Fahrzeug gerade befindet. W ist ein Paar (R, g) , wobei $R = \{r_1, \dots, r_n\}$ ist eine Menge von Raumelementen, die die lokale Welt beschreiben. Eine besondere Eigenschaft dieser Raumelementen ist, dass jeder Element eine Nachbarschaftsbeziehung zu mindestens einem weiteren Raumelement

besitzt. D.h mit Hilfe der Funktion $g : R \rightarrow 2^R$ können die Nachbarn eines Elements r_i erreicht werden. Abbildung 2.9 zeigt mögliche Realisierungen der Raumelemente.

- $f : R \rightarrow 2^E$ ist eine Funktion, die jedem Raumelement r_i eine Untermengenmenge aus der Menge der Eigenschaften $E = \{e_1, \dots, e_K\}$ zuweist. Der Inhalt der Menge E definiert den Begriff Belegung. D.h jedes Raumelement ist belegt mit einer oder mehreren Eigenschaften aus der Menge E .
- \mathbf{X}_{ego} enthält alle Informationen über die Position und die Lage des Eigenfahrzeugs auf der Karte. Ohne diese Information ist die Interpretation des Inhalts der Belegungskarte unmöglich. Auch die Unsicherheit in der Eigenlokalisierung resultiert in einer fehlerhaften Interpretation der Kartendaten. Da hier nur ein lokaler Ausschnitt W der Welt betrachtet wird, ist eine globale Angabe der Position des Eigenfahrzeugs nicht notwendig.

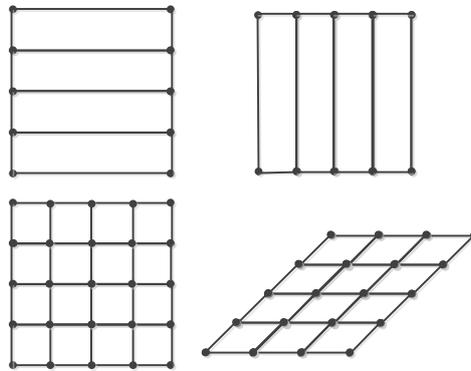


Abbildung 2.9: Mögliche Raummodelle

Zusätzlich wird verlangt, dass die Raumelemente eine lückenlose und zusammenhängende Beschreibung der lokalen Welt W wiedergeben. Diese Bedingung impliziert, dass die Eckpunkte der Raumelemente ein sogenanntes Gitter bilden. Das ist wahrscheinlich auch der Grund, warum meistens eine Belegungskarte in der Literatur mit einer Gitterstruktur in Verbindung gesetzt wird. In der Literatur [39] wird zwischen regelmäßigen strukturierten Gittern und unstrukturierten Gittern unterschieden. Die einfachste Art der Anordnung der Eckpunkte der Raumelemente ist eine äquidistante Verteilung. Ein Beispiel für ein solches Gitter ist in Abbildung 2.10(a) dargestellt. Größter Vorteil dieser Anordnung besteht darin, dass die Nachbarschaftsbeziehung, beschrieben durch die Funktion g , nicht explizit gespeichert werden muss, da sich die Indizes der Nachbarraumelemente anhand der Struktur des Gitters einfach berechnen lassen. Bei unstrukturierten Gittern besitzt jeder Eckpunkt eine freie Position im Raum. Die Nachbarschaftsbeziehung muss hierbei explizit gespeichert werden, beispielsweise indem jeder Eckpunkt die Adressen seiner Nachbarn kennt. Vorteil einer solchen Anordnung ist das hohe Potential für Adaptivität. D.h. wo eine hohe Genauigkeit notwendig ist, wird die Dichte an Gitterelementen erhöht. Im Gegenfall wird die Dichte reduziert, was eine Speichersparnis ermöglicht.

In der vorliegenden Arbeit wird unter **Belegungsgitter** die klassische Form einer Belegungskarte mit quadratischen Zellen verstanden. Der Begriff **Belegungskarte** wird als die allgemeine Form einer Umfeldkarte betrachtet.

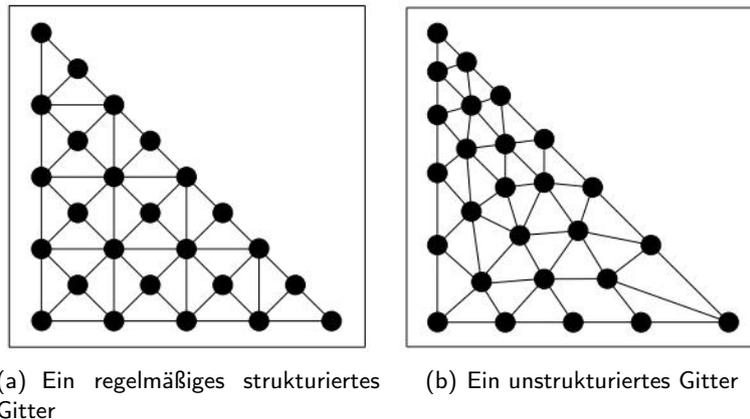


Abbildung 2.10: Strukturierte und Unstrukturierte Gitter

2.3.2 Formulierung des Kartierungsproblems

Die Formulierung des Kartierungsproblems soll dazu dienen, die notwendigen Schritte der Umfeldkartierung zu verstehen und die Besonderheiten der Fahrerassistenzsysteme zu beachten. Für die Formulierung des Problems wird von einer Belegungskarte in Form von einem Gitter ausgegangen, wie sie z. B. in [66] betrachtet wird. Die Formulierung kann an andere Formen der Belegungskarte angepasst werden. Es werden folgende Variablen benötigt:

- M_k : Belegungskarte zum Zeitpunkt k .
- $\mathbf{y}_{1:k}$: Sensormessungen bis zum Zeitpunkt k .
- $O_k^{\mathbf{X}}$: Zufallsvariable, die die Belegung einer Zelle mit den ortsfesten Koordinaten \mathbf{X} beschreibt. Im klassischen Belegungsgrid besteht die Belegungsinformation aus „belegt“ oder „frei“, d.h. $O_k^{\mathbf{X}} \in \{belegt, frei\}$. Zur Vereinfachung werden $p(O_k^{\mathbf{X}} = belegt)$ als $p(O_k^{\mathbf{X}})$ und $p(O_k^{\mathbf{X}} = frei)$ als $p(\neg O_k^{\mathbf{X}})$ bezeichnet.
- $\mathbf{X}_{k-1:k}^{ego}$: Zufallsvariable, die die Änderung in der Bewegung des Eigenfahrzeugs zwischen den Schritten $k-1$ und k beschreibt. Diese Daten werden von einem Modul zur Eigenbewegungsschätzung bereitgestellt.

Die Aufgabe der Umfeldkartierung mit Hilfe von Umfoldsensoren, die im Eigenfahrzeug fest eingebaut sind, besteht in der Berechnung einer Wahrscheinlichkeitskarte M_k , gegeben die Größen $\mathbf{y}_{1:k}$, und $\mathbf{X}_{k-1:k}^{ego}$. Das entspricht der Berechnung der Wahrscheinlichkeit $p(M_k | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k})$. Aus der letzten Formel wird ersichtlich, dass die Wahrscheinlichkeitskarte abhängig zum einen von den Aktionen des Eigenfahrzeugs (in dem Fall die Bewegung) ist, zum anderen von den gesammelten Messungen aus den Umfoldsensoren. In Kapitel 6 Abschnitt 6.1.2 wird zusätzlich die Abhängigkeit von der Bewegung fremder Objekte eingeführt.

Im Gegensatz zu vielen Anwendungen in der Robotik soll die Belegungskarte die lokale Umgebung des Fahrzeugs beschreiben. Dies führt dazu, dass die Karte an die Bewegung des Fahrzeugs fortlaufend angepasst wird. Das Wissen außerhalb des Aufmerksamkeitsbereiches der Karte wird

verworfen.

Die Annahme der statistischen Unabhängigkeiten der einzelnen Zellen ermöglicht das Zurückführen des Problems auf die Bestimmung der Wahrscheinlichkeit $p(O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k})$ für jede Zelle der Belegungskarte.

$$p(M_k | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k}) = \prod_{\mathbf{X}} p(O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k}) \quad (2.10)$$

2.3.3 Aktualisierung nach Bayes für statische Umgebungen anhand von inversen Sensormodellen

Die Aufgabe der Umfeldkartierung kann als eine wahrscheinlichkeitsbasierte Schätzung des Zustands $O_k^{\mathbf{X}}$ betrachtet werden, so dass die Überlegungen der Bayes-Schätzung vom Abschnitt C.3 eingeführt werden können. In diesem speziellen Fall handelt sich um ein binäres Bayes-Filter, das die Zustände „belegt“ und „frei“ schätzt.

$$p(O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k}) = \eta \cdot p(\mathbf{y}_k | O_k^{\mathbf{X}}) \cdot p(O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k-1}) \quad (2.11)$$

Dabei bezeichnet η eine normierungskonstante, die gemäß Gleichung C.11 bestimmt werden kann. $p(\mathbf{y}_k | O_k^{\mathbf{X}})$ stellt das Sensormodell dar. Es beschreibt die Wahrscheinlichkeit einer Messung \mathbf{y}_k , wenn die Zelle belegt ist. Auf das Sensormodell wird in Kapitel 3 und 4 näher eingegangen. $p(O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k-1})$ ist die Erwartung an die Belegungswahrscheinlichkeit der Zelle aufgrund der vorhergehenden alten Messungen.

Im Fall einer statischen Umgebung hängt diese a-priori Wahrscheinlichkeit ausschließlich von der Änderung in der Fahrzeugposition ab. Sie ist eine Funktion von der alten Belegung $p(O_{k-1}^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k-1})$. Im einfachsten Fall wird der folgende Zusammenhang genutzt:

$$p(O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k-1}) = p(O_{k-1}^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k-1}) \quad (2.12)$$

Die normierungskonstante $\eta = p(\mathbf{y}(k) | \mathbf{y}_{1:k-1})$ kann eliminiert werden, indem durch $p(-O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k})$ in Gleichung 2.11 dividiert wird. Es entsteht folgende Gleichung:

$$\frac{p(O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k})}{p(-O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k})} = \frac{p(\mathbf{y}_k | O_k^{\mathbf{X}})}{p(\mathbf{y}_k | -O_k^{\mathbf{X}})} \cdot \frac{p(O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k-1})}{p(-O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k-1})} \quad (2.13)$$

Um die Abhängigkeit vom inversen Sensormodell einzuführen, wird der Bayes-Satz (s. Anhang B) nochmal auf die Wahrscheinlichkeit $p(\mathbf{y}_k | O_k^{\mathbf{X}})$ angewendet. Es resultiert folgende Gleichung:

$$\frac{p(O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k})}{p(-O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k})} = \frac{p(O_k^{\mathbf{X}} | \mathbf{y}_k)}{p(-O_k^{\mathbf{X}} | \mathbf{y}_k)} \cdot \frac{p(-O_k^{\mathbf{X}})}{p(O_k^{\mathbf{X}})} \cdot \frac{p(O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k-1})}{p(-O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k-1})} \quad (2.14)$$

Dabei bezeichnet $p(O_k^{\mathbf{X}})$ die a-priori Belegungswahrscheinlichkeit der Zelle aufgrund eines Vorwissens. I. d. R. wird $p(O_k^{\mathbf{X}})$ zu 0.5 gewählt, so dass der Term $\frac{p(-O_k^{\mathbf{X}})}{p(O_k^{\mathbf{X}})}$ 1 wird.

Zur weiteren Vereinfachung wird in der Literatur die Funktion $Odds(x) = \frac{p(x)}{1-p(x)}$ eingeführt, so dass folgender Zusammenhang resultiert [89]:

$$Odds(O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k}) = Odds(O_k^{\mathbf{X}} | \mathbf{y}_k) \cdot Odds^{-1}(O_k^{\mathbf{X}}) \cdot Odds(O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k-1}) \quad (2.15)$$

Nun werden die Terme in Gleichung 2.15 mit Hilfe der Funktion $LogOdds(x) = \log(Odds(x))$ logarithmiert. Der Vorteil der Logarithmierung liegt in der effizienten Berechnung der neuen Zellenbelegung. Hierfür vereinfacht sich die Aktualisierung der Zelle zu einer Addition eines Werts aus dem Sensormodell zu dem alten Inhalt der Zelle nach der Kompensation der Eigenbewegung.

$$LogOdds(O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k}) = LogOdds(O_k^{\mathbf{X}} | \mathbf{y}_k) + LogOdds(O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k-1}) - LogOdds(O_k^{\mathbf{X}}) \quad (2.16)$$

2.4 Grundlagen der modellbasierten Objektbeschreibung und Verfolgung

Im Gegensatz zu der kartenbasierten Beschreibung des Fahrzeugumfelds, bei der bestimmte Eigenschaften dem Raum zugeordnet werden, werden bei objektbasierten Ansätzen Objekten bestimmte Attribute oder Zustände wie Position und Geschwindigkeit zugewiesen. Jedes Objekt gehört zu einer Objektklasse, deren Eigenschaften das Objekt kennzeichnen. Beispiele für Objekte sind Fahrzeuge, Fußgänger, Fahrstreifenmarkierungen oder Leitpfosten. Die Festlegung von Objektzuständen erfordert implizit die Festlegung eines Objektmodells. Ein Modell ist eine kompakte und abstrakte Beschreibung des Objektes beruhend auf bestimmten Annahmen und Vereinfachungen der Realität. Meistens verhelfen in der sensorbasierten Umfelderkennung für Fahrerassistenzsysteme ein Formmodell, das die Geometrie des Objektes wiedergibt und ein Bewegungsmodell, das die Bewegung des Objektes charakterisiert, Objektzustände zu beschreiben. Als Beispiele können hier das Bounding-Box-Modell für Fahrzeuge oder die Beschreibung der Fußgängerbewegung durch die Bewegung seiner Beine und Arme genannt werden. Basierend auf diesen Überlegungen wird in der Arbeit folgende Definition für die objektbasierte Beschreibung des Fahrzeugumfeldes verwendet.

Definition zustandsbasierte Objektdarstellung: Eine zustandsbasierte Objektdarstellung wird als folgender Tupel (O, X, f) definiert. Dabei haben die Variablen O , X und f folgende Bedeutungen:

- O bezeichnet die Menge der detektierten Objekte in der Umgebung des Eigenfahrzeugs.
- X bezeichnet die Menge an möglichen Zuständen bzw. Attributen der Objekte.

- $f : O \longrightarrow 2^X$ bezeichnet eine Abbildung, die einem Objekt aus der Objektmenge O mindestens einen Zustand aus der Zustandsmenge X zuordnet.

Die Vorteile der objektbasierten Repräsentation bestehen einerseits in der einfachen Implementierbarkeit und Interpretierbarkeit, andererseits in der Kompaktheit der Repräsentation. Allerdings lassen sich regelhafte Zusammenhänge zwischen einzelnen Objekten nicht ohne Weiteres darstellen. Außerdem bringt die Repräsentation des Umfelds in Form von einer Liste aus Objekten und Attributen ein Assoziationsaufwand mit sich. Denn jedes neu erworbene Wissen wie z.B. Messungen von Umfeldsensoren müssen auf die interne Objektliste übertragen werden, um diese internen Daten anzureichern.

Sind die Form- und Bewegungsmodelle festgelegt, so kann eine Objektverfolgung stattfinden. Die Verfolgung bezeichnet die zeitliche Beobachtung der Objektzustände mit Hilfe von Messungen und der festgelegten Objektmodelle. Die zentrale Aufgabe einer Objektverfolgung besteht daher in der Schätzung der Zustandsgrößen unter Berücksichtigung ihrer Historie und der Unsicherheiten in den eingesetzten Sensoren und in den ausgewählten Modellen. Bei einer Multi-Objekt Verfolgung kommt noch eine Verwaltungsaufgabe hinzu. Alte nicht mehr beobachtete Objekte müssen gelöscht werden. Neue detektierte Objekte müssen initialisiert werden. Neu eintreffende Messungen müssen bestimmten Objekten zugeordnet werden.

2.4.1 Bewegungsmodelle

Die Bewegungsmodelle dienen zur Beschreibung der dynamischen Aspekte von Objekten. Die Auswahl der Modelle hängt zum einen von den Zielszenarien ab, in denen das System eingesetzt wird. So sind für die Beschreibung von Fahrmanövern fremder Fahrzeuge, wie z.B. ein Fahrstreifenwechselmanöver oder ein Einschermanöver spezielle Modelle notwendig. Zum anderen wird die Auswahl der Modelle durch die Beobachtbarkeit der Zustandsgrößen mit Hilfe von Umfeldsensoren eingeschränkt. In der Arbeit werden Modelle mit konstanter Beschleunigung für die modellbasierte Freiraumverfolgung 4.2 eingesetzt. Für die Schätzung der Höhe in der 2.5D Belegungskarte (Kapitel 5.3) und der Intervallgrenzen bei der 3D Intervallkarte (Kapitel 5.4) kommen sogenannte „*zero velocity*“ Modelle also statische Modelle zum Einsatz. Bei diesem Modell verfügt das betrachtete Objekt über keine Dynamik, d.h. es wird angenommen, dass es statisch ist. Genauere Details über die eingesetzten Dynamikmodelle werden in den Kapitel 4.2, 4 und 5 beschrieben. Weitere Modelle, die zusätzliche Annahmen über die Bewegung der Objekte enthalten, können in der Literatur z.B. in [59] gefunden werden.

2.4.2 Formmodelle

Neben der Berücksichtigung der Objekt-Dynamik durch Bewegungsmodelle spielt auch die geometrische Objekt-Form eine wichtige Rolle in seiner Beschreibung. Dabei orientiert sich die Festlegung der Formmodelle an den notwendigen Größen für die Realisierung des Assistenzsystems. Das ausgewählte Formmodell muss auch von den benutzten Umfeldsensoren messbar sein. Aus der Literatur ist eine ganze Fülle unterschiedlicher Methoden zur Beschreibung der Form fester, dreidimensionaler Körper bekannt. Ein Überblick über diese Möglichkeiten und über ihre Vor- und Nachteile enthält z.B. [1]. In der Arbeit kommt hauptsächlich das allgemeine Quadermodell-

wie in Abbildung 2.11 dargestellt - zum Einsatz. Als Formparameter werden Länge L , Breite B , und Höhe H gewählt:

$$\mathbf{x}_f = (L, B, H)^T \quad (2.17)$$

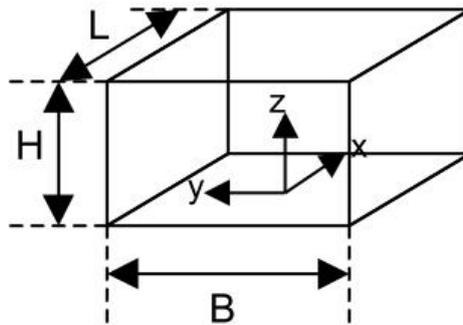


Abbildung 2.11: Quader als Formmodell

2.4.3 Multi-Objekt Verfolgung

Fahrerassistenzsysteme werden in der Regel in dynamischen Szenen eingesetzt. Andere Verkehrsteilnehmer sowie stationäre Hindernisse können zu beliebigen Zeiten bedingt durch deren Bewegung oder durch die des Eigenfahrzeugs in die Sichtfelder der Sensoren eintreten oder diese wieder verlassen. D.h. die Anzahl der zu beobachtenden Objekte ist zeitvariant und a priori unbekannt. Die Aufgabe der Multi-Objekt Verfolgung besteht darin, alle für die FAS-Funktion relevanten Objekte im Umfeld des Fahrzeuges zu erfassen und diese über die Zeit zu verfolgen. Die aufgrund der Szenendynamik notwendige Zuordnung neuer Messungen zu bestehenden Objekten und das dynamische Aufnehmen und Löschen von Objekten erschweren die Mehrobjektverfolgung gegenüber der Verfolgung eines isolierten Objektes. Die beiden Aspekte der Datenassoziationsverfahren und der Objektverwaltung stellen keine Schwerpunkte der vorliegenden Arbeit dar. Sie werden der Vollständigkeit halber im folgenden Abschnitt kurz beschrieben.

Datenassoziationsverfahren

Beim Problem der Datenzuordnung wird die Fragestellung behandelt, welche Messung welchem Objekt zuzuordnen ist. Prinzipiell kann eine neue Objektmessung folgende Zugehörigkeitsmöglichkeiten haben:

- Die Objektmessung entspricht einem der bereits verfolgten Objekte.
- Die Objektmessung entspricht einem bisher nicht beobachteten Objekt.
- Die Objektmessung ist auf eine fehlerhafte Messung durch den Sensor zurückzuführen. Diese Messung wird Falschalarm genannt.

Die Aufgabe der Datenzuordnung besteht deswegen darin, eine zum Zeitpunkt k gegebene Anzahl von Messungen \mathbf{y}_j mit $j = 1, \dots, N_y$ auf die Menge der bereits verfolgten Objekte O_i mit $i = 1, \dots, N_O$ abzubilden. Zur Lösung dieser Aufgabe gibt es verschiedene Methoden, die sich hinsichtlich ihrer Entscheidungstechniken (harte/weiche Entscheidung) und weiter bezüglich ihrer Komplexität (Ein-/Multihypothesen) unterscheiden. Verfahren mit harten Entscheidungen ordnen jede Messung genau einem Objekt zu. Verfahren mit weichen Entscheidungen hingegen können Messungen gewichtet mehreren Objekten zuweisen. Die bekannteste Methode aus der Familie der Verfahren mit harten Entscheidungen ist der *Nearst Neighbor (NN)* Ansatz. Bei den Verfahren mit den weichen Entscheidungen ist vor allem das *Joint Probabilistic Data Association Filter* zu nennen.

Vor der eigentlichen Datenzuordnung findet üblicherweise das sogenannte *Gating* statt. In diesem Schritt werden um die prädizierten Zustandsvektoren herum Einzugsbereiche definiert und jede Messung, die innerhalb einer dieser Bereiche liegt, wird als potentieller Kandidat für eine Zuordnung mit jeweiligem Objekt betrachtet. Der Vorteil dieses Schrittes liegt im frühzeitigen Aussortieren der unwahrscheinlichen Zuordnungen und das genaue Lösen verbleibender Mehrdeutigkeiten durch die aufwändigen Assoziationsverfahren.

Objektverwaltung

Der Einsatz einer Multi-Objektverfolgung für Fahrerassistenzsysteme in einer dynamischen Szenarie erfordert eine Objektverwaltung. Eine solche Objekt-Verwaltung basiert auf einer Strategie zur Initialisierung der Zustandsschätzer neuer Objekte und zum Löschen alter nicht bestätigter Objekte. In der Regel verfügt die Objektverwaltung über einen internen „vorläufigen“ Zustand für die Objekte, bevor sie nach außen ausgegeben werden oder sie aus der Ausgangsschnittstelle entfernt werden. Objekte, die neu hinzugekommen sind, werden zunächst als unbestätigte Objekthypothesen markiert. Sie werden intern verfolgt, sind aber für weitere Systemkomponenten unsichtbar. Erst, wenn die Existenzwahrscheinlichkeit solcher Objekte signifikant steigt, werden sie der eigentlichen Anwendung zur Verfügung gestellt. Gleichmaßen werden Objekte gelöscht, denen über einen längeren Zeitraum keine Messungen zugeordnet werden können. Ein Indikator für die Existenzwahrscheinlichkeit eines Objektes sind z.B. die Anzahl der Innovationsschritte für ein Objekt. Zu dem Thema Existenzwahrscheinlichkeiten in Schätzfiltern sei auf die Literatur z.B. auf [65] verwiesen.

3 Analyse von Umfeldsensoren zur Herleitung von Sensormodellen

Ein Modell soll die als richtig angesehenen Eigenschaften des Vorbilds ausdrücken, die unwichtigen oder nebensächlichen außer Acht lassen, um durch Vereinfachungen zu einem übersehbaren oder mathematisch berechenbaren oder zu experimentellen Untersuchungen geeigneten Modell zu kommen [Brockhaus 19. Auflage].

Wie bereits in der Einleitung der Arbeit erwähnt, spielen Modelle eine große Rolle in der maschinellen Wahrnehmung. Modelle enthalten Vorstellungen und Annahmen über die betrachteten Systeme und ermöglichen so die Beschreibung ihrer Verhalten. Mit Hilfe von Modellen können z.B. Messdaten eines Sensors Bedeutungen zugeordnet werden. Das Ziel des vorliegenden Kapitels besteht in der mathematischen Beschreibung der Sensormodellierung sowie in der Herleitung von Methoden zur Analyse von Umfeldsensoren und ihren Eigenschaften. Die praktische Anwendung dieser Methoden wird am Beispiel der eingesetzten Laser- und Radar Sensoren beschrieben.

3.1 Motivation

Dieses Kapitel behandelt Modelle von Umfeldsensoren, die dazu dienen, möglichst präzise die Messdaten eines Umfeldsensors zu interpretieren. Das Sensormodell ist im Prinzip die Beschreibung der Sensorfähigkeit, Informationen aus seiner Umgebung zu extrahieren. Das setzt möglichst viel Wissen über die Funktionsweise eines Sensors und die Wechselwirkung mit seiner Umwelt voraus. Erst mit diesem Wissen kann die Sensor-Information optimal interpretiert und weiterverarbeitet werden. Modelle der Sensoren sind insbesondere notwendig, weil die Messungen oft fehler- und unsicherheitsbehaftet sind. Mit Hilfe von genauen Sensormodellen kann die Einschätzung der Qualität einer Messung und die Detektion eines Sensorfehlverhaltens, ohne die „wahren Größen“ zu wissen, gelingen. Diese Fähigkeit der Selbstdiagnose ist essentiell für semiautonome und autonome Systeme, die vom Fahrer während des Betriebs nicht überwacht werden. Mit dieser Fähigkeit können Fahrerassistenzsysteme die Grenzen ihrer Wahrnehmungsleistung detektieren.

Sensormodelle können dazu verwendet werden, eine Erwartung an den Ausgang des betrachteten Sensor-Systems zu generieren. In diesem Fall ist die Rede von einem **vorwärts-Sensormodell** bzw. von einem **Simulationssensormodell**. Dieses Modell simuliert das Verhalten des Sensors. Hierfür muss die wahre Größe (*Ground-Truth*), die der Sensor misst oder zumindest eine Schätzung dieser Größe bekannt sein (s. Abbildung 3.1). Des Weiteren kann ein Sensormodell dazu dienen, möglichst genau Informationen über die gemessene Umgebung aus den Messdaten herzuleiten. In diesem Fall handelt es sich um ein **inverses Sensormodell**. In Abbildung 3.1 sind

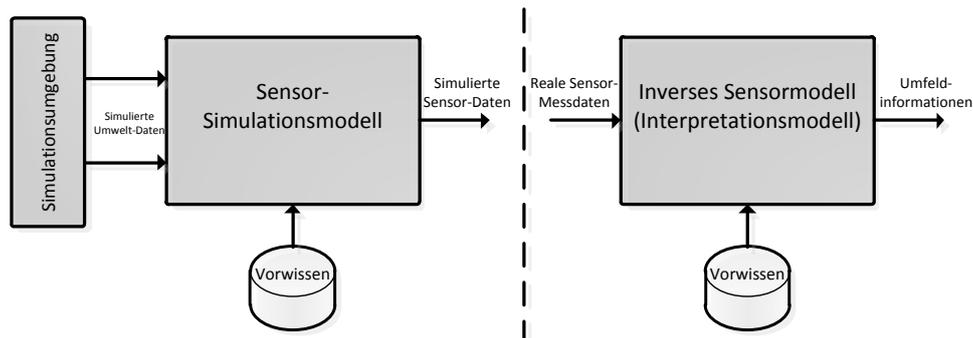


Abbildung 3.1: Gegenüberstellung eines Sensorsimulationsmodells und eines inversen Sensormodells

die beiden Konzepte aufgetragen. In [89] wird detaillierter auf die Unterschiede zwischen den Modellen für Ultraschallsensoren eingegangen.

3.2 Konzept

Die Betrachtung der typischen Grundstruktur eines intelligenten Umfoldsensors hilft bei der Identifikation der relevanten Daten für ein Sensormodell (siehe Abbildung 3.2). Die Struktur besteht typischerweise aus einem elementaren physikalischen Sensor, der in direkter Interaktion mit der Umwelt steht und elektrische Signale generiert. Neben dem physikalischen Sensor ist die sensorinterne Datenverarbeitung ein wichtiger Bestandteil eines intelligenten Sensorsystems. Dabei unterscheidet sich die Auswertung der Sensorsignale je nach Sensortechnologie und Messprinzip. Diese kann beispielsweise eine einfache Tiefpassfilterung der Signale oder eine komplette Objektverfolgung z.B. zur Filterung der Radar-Rohzielen enthalten. Ein weiterer wichtiger Aspekt bei modernen Fahrerassistenzsystemen besteht im Einsatz eines multisensoriellen Systems. Die Sensoren ergänzen sich als Teile eines „Teams“ für die Bewältigung der Wahrnehmungsaufgabe. Basierend auf diesen Grund-Überlegungen wird die Modellierung des Sensors in der vorliegenden Arbeit in drei Ebenen betrachtet:

- Die Modellierung der sensorinternen Zustände und Vorgänge.
- Die Modellierung der Interaktion mit der Umwelt bzw. die Abhängigkeit von der Szene und der Fahrsituation.
- Die Modellierung des Zusammenhangs bzw. Abhängigkeiten mit den anderen Sensoren im multisensoriellen System.

Diese drei Informationsquellen bilden die Grundlage für den Aufbau des Sensormodells. Dabei verläuft die Modellierung in zwei Hauptschritten:

1. **In einem offline-Schritt** werden die fehlenden Informationen über das Funktionsprinzip des Sensors und die Abhängigkeiten seiner Messung von verschiedenen Einfluss-Parametern (Witterung, Abhängigkeit von Fahrzeug-Bewegung, Abhängigkeit von der Komplexität der

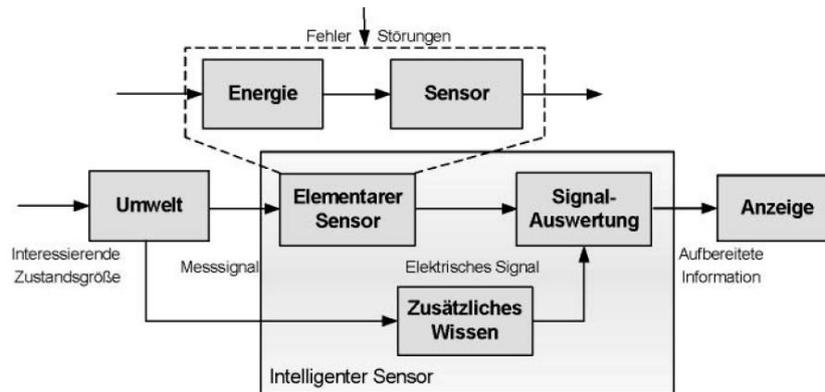


Abbildung 3.2: Allgemeine Grundstruktur eines Sensorsystems inklusive Auswertung [80]

Umgebung, Latenzzeit...) gezielt analysiert und gesammelt. In diesem Schritt werden ebenfalls die Verteilungen der Sensorfehler bestimmt. Hierzu ist eine „*Ground-Truth*“ notwendig, um die Messdaten in Bezug zur realen Welt setzen zu können.

2. **In einem online-Schritt** werden die zuvor gesammelten Informationen mit dem Vorwissen über den Sensor (Experten-Wissen, Datenblatt...) kombiniert, um entweder eine Erwartung an die Messung des Sensors zu generieren (**direktes Sensormodell**) oder um aus empfangenen Messungen bestimmte Schätzgrößen (**inverses Sensormodell**) abzuleiten.

3.2.1 Modellierung des Einflusses unabhängiger Parameter

Die Sensormodelle werden in der Arbeit in Verbindung mit Schätzaufgaben (z.B. Schätzung des Belegungszustandes einer Zelle im Belegungsgitter oder Korrektur des Zustandsvektors eines verfolgten Objektes) eingesetzt. In diesem Fall beschreibt das Sensormodell mathematisch den Zusammenhang zwischen den Messgrößen \mathbf{y} und den zu ermittelnden Schätzgrößen \mathbf{x} . Dabei ist es wichtig die Fehler aufgrund der Nichtidealitäten im Sensor und des Unwissens über den Zusammenhang zwischen den Größen zu berücksichtigen. Wird von einem additiven Fehlermodell ausgegangen, so kann das Sensormodell wie folgt ausgedrückt werden:

$$\mathbf{y} = \mathbf{h}(\mathbf{x}, p_1, p_2, p_3, \dots, p_N) \quad (3.1)$$

$$\mathbf{y} = \mathbf{g}(\mathbf{x}) + e_{sys}(p_1, p_2, \dots, p_N) + e_{stoc}(p_1, p_2, \dots, p_N) \quad (3.2)$$

Die Funktion g beschreibt den deterministischen Zusammenhang zwischen den Messgrößen und den Schätzgrößen. Sie kann eine nichtlineare mehrdimensionale Funktion sein. Ändert der Sensor über die Zeit seine Ausgangsgrößen nicht, so kann in der Regel von einem zeitlich konstanten Zusammenhang ausgegangen werden, analog zu zeitinvarianten dynamischen Systemen. Der systematische Fehler, wie z.B. ein Kalibrierfehler oder ein Temperatur-Drift, wird durch den Term $e_{sys}(p_1, p_2, \dots, p_n)$ beschrieben. $e_{stoc}(p_1, p_2, \dots, p_n)$ beschreibt hingegen den zufälligen Fehler, der einer bestimmten Wahrscheinlichkeitsverteilung unterliegt. Die Größen p_1, p_2, \dots, p_n stellen Parameter dar, von denen die Fehler abhängen. Ein Teil dieser Einflussgrößen beschreibt sensorinterne

Parameter wie z.B. die Latenzzeit der Messdaten. Ein zweiter Teil repräsentiert externe Größen zusammen wie z.B. Witterungseinflüsse. Die Menge dieser externen Parameter kann also als eine Beschreibung der Szene oder Situation interpretiert werden. Während der systematische Fehler in einer Kalibrier-Phase des Umfeldsensors bestimmt werden kann, ist die Ermittlung des zufälligen Fehlers wesentlich komplexer. Mit Hilfe dieses einfachen mathematischen Modells kann das Problem der Sensormodellierung auf die Bestimmung der bedingten Wahrscheinlichkeitsverteilung $p(\mathbf{y}|\mathbf{x}, p_1, p_2, p_3, \dots, p_n)$ bzw. der Verteilung des zufälligen Fehlers e_{stoc} zurückgeführt werden:

$$p(e_{stoc}|p_1, p_2, p_3, \dots, p_N) = p(\mathbf{y} - \mathbf{g}(\mathbf{x}) - e_{sys}|p_1, p_2, p_3, \dots, p_N) \quad (3.3)$$

Für die Herleitung des inversen Sensormodells muss entsprechend die bedingte Wahrscheinlichkeit $p(\mathbf{x}|\mathbf{y}, p_1, p_2, p_3, \dots, p_n)$ ermittelt werden, indem die Verteilungen des stochastischen Fehlers entsprechend invertiert betrachtet werden.

Der in dieser Arbeit verfolgte Ansatz beruht auf der Identifikation dominanter und unabhängiger Sensoreigenschaften bzw. Effekte und deren Einfluss auf die Sensormessungen. Einige Parameter sind selbst nicht deterministisch, unbekannt und können nur wahrscheinlichkeitsbasiert beschrieben werden. Diese sind vor allem Situationsaspekte, die den Messvorgang des Sensors beeinflussen. Es werden deswegen die Menge der unabhängigen deterministischen Parameter $P_d = p_{d1} \cup p_{d2} \cup p_{d3} \cup \dots \cup p_{dD}$ und der stochastischen Parameter $P_s = p_{s1} \cup p_{s2} \cup p_{s3} \cup \dots \cup p_{sS}$ betrachtet. Dabei können die einzelnen unabhängigen Parametermengen aus einzelnen abhängigen Parametern bestehen $p_{d1} = \{p_{d11}, p_{d12}, p_{d13}, \dots\}$. Mit Hilfe dieser einfachen Vorüberlegungen und der Bayes-Theorie (s. Anhang B) kann das Problem wie folgt ausgedrückt werden.

$$p(e_{stoc}, P_s|P_d) = p(e_{stoc}|P_d, P_s) \cdot p(P_s|P_d) \quad (3.4)$$

Der erste Term $p(e_{stoc}|P_d, P_s)$ kann dann mit Hilfe der Bayes-Formel (s. Anhang B) in einzelne unabhängige Terme umgeformt werden:

$$p(e_{stoc}|P_d, P_s) = \frac{p(p_{d1}, p_{d2}, \dots, p_{dD}, p_{s1}, p_{s2}, \dots, p_{sS}|e_{stoc})}{p(p_{d1}, p_{d2}, \dots, p_{dD}, p_{s1}, p_{s2}, \dots, p_{sS})} \cdot p(e_{stoc}) \quad (3.5)$$

$$= \frac{p(p_{d1}|e_{stoc}) \cdots p(p_{dD}|e_{stoc}) \cdot p(p_{s1}|e_{stoc}) \cdots p(p_{sS}|e_{stoc}) \cdot p(e_{stoc})}{p(p_{d1}) \cdots p(p_{dD}) \cdot p(p_{s1}) \cdots p(p_{sS})} \quad (3.6)$$

$$= \frac{p(e_{stoc}|p_{d1}) \cdots p(e_{stoc}|p_{dD}) \cdot p(e_{stoc}|p_{s1}) \cdots p(e_{stoc}|p_{sS}) \cdot p(e_{stoc})}{p(e_{stoc}) \cdot p(e_{stoc}) \cdots p(e_{stoc})} \quad (3.7)$$

$$= \frac{p(e_{stoc}|p_{d1}) \cdots p(e_{stoc}|p_{dD}) \cdot p(e_{stoc}|p_{s1}) \cdots p(e_{stoc}|p_{sS})}{p(e_{stoc})^{S+D-1}} \quad (3.8)$$

$$\propto p(e_{stoc}|p_{d1}) \cdots p(e_{stoc}|p_{dD}) \cdot p(e_{stoc}|p_{s1}) \cdots p(e_{stoc}|p_{sS}) \quad (3.9)$$

Der zweite Term kann aufgrund der angenommenen Unabhängigkeiten zwischen P_s und P_d stark vereinfacht werden:

$$p(P_s|P_d) = p(P_s) \quad (3.10)$$

$$= p(p_{s1}) \cdot p(p_{s2}) \cdots p(p_{sS}) \quad (3.11)$$

Gleichungen 3.4 und 3.11 zeigen, dass der Einfluss der unabhängigen Parameter zusätzlich mit der Wahrscheinlichkeiten der stochastischen situativen Parameter gewichtet wird. Beispiele für solche Parameter sind das a-priori Wissen über die Umgebung des Fahrzeugs oder die Erkennung eines bestimmten Fahrmanövers wie z.B. der Einschervorgang eines vorausfahrenden Fahrzeugs. Die Abschnitte 4.1.4 und 4.1.5 vom Kapitel 4 verdeutlichen, wie dieses zusätzliche situative Wissen in der inversen Sensormodellierung miteinbezogen werden kann.

Gleichung 3.9 zeigt, dass der Einfluss der verschiedenen unabhängigen Parameter multiplikativ auf den Fehler in der Messung einwirkt. Der Term $p(e_{stoc})$ entspricht der A-priori Wahrscheinlichkeit des Messfehlers und kann z.B. dem Datenblatt des Sensors entnommen werden, oder mit Hilfe der Schätzvarianzen, die bestimmte Umfeldsensoren liefern, rekonstruiert werden. Der Einfluss der einzelnen Parameter $p(e_{stoc}|p_i)$ muss in einer offline Phase bestimmt werden, was der Analyse des Sensors und der Ermittlung seiner Eigenschaften entspricht.

3.2.2 Analyse von Umfeldsensoren mit Hilfe eines Referenzsystems

Um eine Aussage über die Genauigkeit einer Messung und allgemein über ihre Qualität treffen zu können, muss diese in Bezug zu der Realität gesetzt werden. Da die Realität in der Regel unbekannt ist, ist der Einsatz eines zweiten um ein vielfaches genaueres Messsystems erforderlich. Letzteres ermöglicht die Bestimmung von Umfeld-Informationen (z.B. Vermessen von Objekten und ihren Eigenschaften) mit hoher Genauigkeit und dient folglich als Referenz für den zu untersuchenden Sensor. Aufgrund der Unabhängigkeit der beiden zu vergleichenden Systeme (das Referenzsystem und der zu untersuchende Umfeldsensor) sieht das verfolgte Konzept eine Reihe von Verarbeitungsschritten vor, die zur Herstellung der Vergleichbarkeit dienen:

- **Zeitliche Synchronisation:** Eine wichtige Voraussetzung für den Vergleich eines Umfeldsensors mit einem Referenzsystem ist ein gemeinsamer Zeitbezug. Dies kann erreicht werden, in dem z.B. eine echte Hardware-Synchronisation stattfindet. In diesem Fall triggert z.B. der Umfeldsensor das Referenzsystem, um zeitsynchron eine Referenzmessung zu erzeugen. Alternativ können die Daten des Referenzsystems auf den Messzeitpunkt des zu untersuchenden Sensors durch Prädiktion umgerechnet werden.
- **Räumliche Synchronisation:** Eine Transformation der Daten in ein gemeinsames Koordinatensystem ist ebenfalls erforderlich, da die Systeme in der Regel in unterschiedlichen Positionen im Fahrzeug verbaut sind. Als gemeinsames Koordinatensystem kann das Umfeld-Koordinatensystem verwendet werden.
- **Transformation der Referenzdaten:** Dieser Schritt ist notwendig, falls sich der Messraum des Referenzsystems vom Messraum des zu bewertenden Umfeldsensors unterscheidet. Daher ist eine Transformation zwischen den verschiedenen Messräumen notwendig. Hierfür muss der Zusammenhang zwischen den Messdaten und den Referenzdaten bekannt sein. Ein Beispiel dafür sind die Entfernungsmessdaten eines Laserscanners, die mit den als Objektzustände verfügbaren Referenzdaten nicht übereinstimmen. Hier ist also eine Transformation des Objektmodells aus der Referenz in Entfernungsmessdaten, die mit Daten des Laserscanners vergleichbar sind (s. Abschnitt 3.4.2) notwendig. Dieser Schritt kann auch als eine Generierung von idealen Messdaten mit Hilfe eines Simulationsmodells aus den

Referenzdaten verstanden werden. Falls eine Herleitung der Messdaten aus den Referenzdaten unmöglich ist, ist das gewählte Referenzsystem nicht geeignet für die Bewertung des Umfeldsensors.

- **Bestimmung des Messbezugspunkts falls unbekannt:** Ein Vergleich zwischen *Ground Truth* und realen Messdaten eines zu bewertenden Sensors ist unmöglich, solange der Bezugspunkt, auf dem die Messung sich bezieht, unbekannt ist. Viele Sensoren können diesen Bezug der Messungen mitliefern. Eine laserscannerbasierte Objektverfolgung kann z.B. die Kontur von Objekten vermessen und somit mitangeben, ob die Zustandsgrößen des Objektes auf einer bestimmten Ecke oder auf dem Schwerpunkt sich beziehen. Falls der Bezugspunkt unbekannt ist, muss dieser bestimmt werden. Hier verhelfen einerseits bestimmte Annahmen über den Funktionsprinzip des Sensors z.B., dass sich die Messung innerhalb eines aufgeweiteten Laser-Kanals auf die Kanalmitte bezieht. Andererseits kann der unbekannte Bezugspunkt in systematischen Tests mit Hilfe der Referenz geschätzt werden. Hierzu können z.B. mehrere Hypothesen für den Bezugspunkt aufgestellt werden und eine Statistik der relativen Lage dieser Hypothesen zu den Messdaten des Umfeldsensors aufgebaut werden. Dabei ist es wichtig, dass die erwarteten Bezugspunkte aus den Hypothesen mit hoher Genauigkeit z.B. durch ein Referenzsystem bestimmt werden. Der nächste Bezugspunkt zu der Messung ist wahrscheinlich der Punkt, auf den sich die Messung bezieht.
- **Assoziation der Referenzdaten mit den zu untersuchenden Daten:** Der letzte Verarbeitungsschritt vor dem eigentlichen Vergleich besteht in der Assoziation der generierten Erwartungen aus den Referenzdaten mit den Messdaten des Umfeldsensors. Für jedes zu bewertende Messdatum muss die entsprechende Größe aus der Referenz gesucht und diesem zugeordnet werden.

3.3 Analyse eines Doppelradarsystems

Der Einsatz eines FMCW-Radars wie in der vorliegenden Arbeit erfordert einen hohen Modellierungsaufwand und somit einen hohen Analyseaufwand, damit möglichst viele Informationen aus den Radarmessungen extrahiert werden können. Dies liegt u.a. daran, dass der Radar keine Ausdehnung der Objekte misst. Der Bezugspunkt, auf den sich die Messdaten beziehen, ist also unbekannt und kann irgendwo auf der Fläche des Objekts liegen. Zusätzlich kann der Sichtbereich des Radars aufgrund der Ausbreitungseigenschaften elektromagnetischer Wellen und der unbekanntes Antennen-Charakteristik des Radars nicht genau und einfach angegeben werden. Dieser muss gezielt für bestimmte Hindernisklassen bestimmt werden. Des Weiteren erfordern weitere Eigenschaften des Radars wie die eingeschränkte Trennfähigkeit und vor allem das fehlende Wissen über die sensorinterne Algorithmik und Signalverarbeitung die genaue und systematische Untersuchung des Sensors.

3.3.1 Ermittlung des Radar-Sichtbereichs

Der Sichtbereich eines Umfeldsensors beschreibt den Gesamttraumbereich, in dem Hindernisse vom Sensor erfasst werden können. Der Sichtbereich umfasst die Teil-Parameter Öffnungswinkel

und Reichweite und ist deswegen eine Funktion vom Abstand r und Winkel φ des zu erfassenden Objektes. Wird der Messfehler im Sichtbereich betrachtet, so muss die Verteilung $p(e_{stoc}|r, \varphi)$ bestimmt werden.

In der vorliegenden Arbeit werden zwei Wege für die Bestimmung des Radar-Sichtbereiches vorgeschlagen. Die erste Methode benötigt keine Referenz und beruht auf dem Aufbau einer hinreichend großen Statistik mit den Sensordaten. Die akkumulierten Messungen ermöglichen dann, eine **qualitative Aussage** über den Öffnungswinkel und die Reichweite des Sensors zu treffen. Abbildung 3.3 zeigt das Ergebnis einer solchen Untersuchung. Der Öffnungswinkel des Sensorsystems und die grobe Radar-Keulen-Charakteristik sind zu erkennen. Außerdem ist auch zu erkennen, dass die Häufigkeit der Messungen mit der Entfernung abnimmt. Dies liegt daran, dass nicht hinreichend Messungen in großen Entfernungen durchgeführt wurden. Der Schwerpunkt lag in der Arbeit auf Entfernungen bis 80 m.

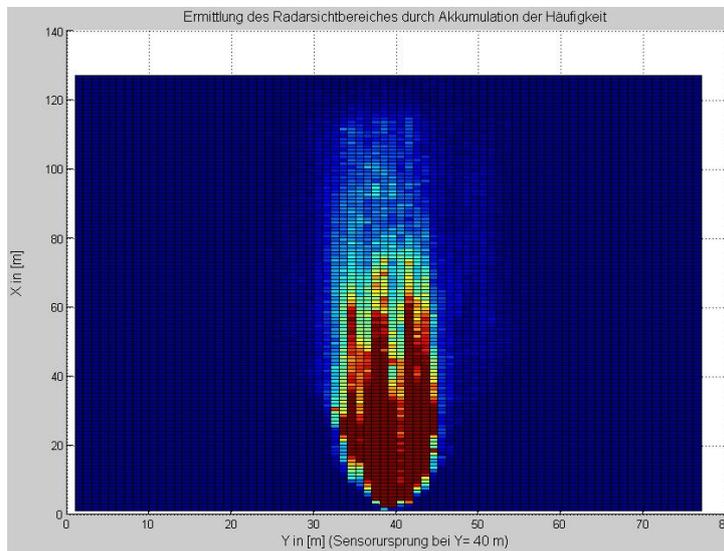
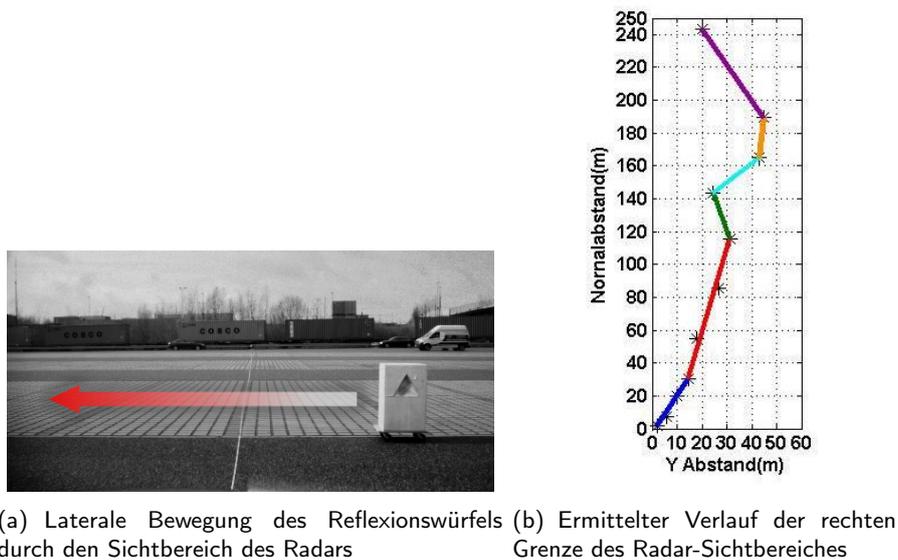


Abbildung 3.3: Ermittelter Sichtbereich des Doppelradarsystems

Das Ziel der zweiten Methode besteht in der **quantitativen Beschreibung** des Radar-Sichtbereiches für eine bestimmte Hindernisklasse. Hierfür steht das Eigenfahrzeug auf einer freien Fläche, auf der sich keine störenden Hindernisse befinden. Um nun den tatsächlichen Öffnungswinkel des Radars überprüfen zu können, wird ein Reflexionswürfel (s. Abbildung 3.4(a)) mit einem definierten Radarrückstreuquerschnitt (RCS) lateral durch den Sichtbereich des Radars mit einer konstanten Geschwindigkeit geschoben. Um Tracking-Effekte auszuschließen, die sich in zusätzlichen Plausibilisierungsschritten bei der Erstdetektionen ausdrücken, wird der Reflexionswürfel sehr langsam in den Sichtbereich geschoben (s. Abbildung 3.4(a)). Dabei wird die Position des Hindernisses beim Eintreten in den Sichtbereich des Sensors sehr genau mit Hilfe eines Referenzsystems vermessen. Durch die Variation des normalen Abstands des Hindernisses können die Grenzen des Sichtbereiches rekonstruiert werden, wie etwa in Abbildung 3.4(b) für den rechten Rand repräsentiert ist. Der Verlauf des Sichtbereiches wurde hier mit Hilfe eines Polygonzugs angenähert.



(a) Laterale Bewegung des Reflexionswürfels durch den Sichtbereich des Radars (b) Ermittelte Verlauf der rechten Grenze des Radar-Sichtbereiches

Abbildung 3.4: Experimentelle Bestimmung des Radar-Sichtbereiches

3.3.2 Lage und Streuung des Reflexionspunkts

Der eingesetzte Radar liefert nur die Messdaten eines punktförmigen Objektes. Aus diesem Grund ist es notwendig die Lage und Streuung dieses Reflexionspunktes zu kennen, um möglichst genau die Messung nutzen und interpretieren zu können. Für die Bestimmung der Lage des Reflexionspunktes kann auf die im Abschnitt 3.2.2 vorgeschlagene Methode zurückgegriffen. Hierbei wird der Bezugspunkt der Messung in systematischen Tests mit Hilfe der Referenz identifiziert.

Streuung am Heck eines Fahrzeugs

Für die Untersuchung der Streuung der Radar-Messungen am Fahrzeug-Heck, wurden Langzeitbeobachtungen durchgeführt. Hierzu werden Test-Fahrzeuge in verschiedenen Normal-Abständen zum Eigenfahrzeug platziert und die Messdaten aufgenommen. Die Untersuchungen haben gezeigt, dass die Messungen auf dem gesamten Heck des Fahrzeugs gemäß einer Normalverteilung streut. Im Mittel stimmt der Messpunkt des Radars mit dem Mittelpunkt des Fahrzeug-Hecks überein. Bei den Untersuchungen konnte auch keine Abhängigkeiten von den Normal-Abständen festgestellt werden.

Reflexion an seitlichen und einscherenden Fahrzeugen

Ein besonders wichtiges Szenario für die Funktion Stauassistent (siehe E.2) ist das Einscheren von Fremd-Fahrzeugen vor dem Eigenfahrzeug. Aus diesem Grund wurden verschiedene Einschervorgänge erprobt. Dabei wurden der longitudinale Abstand des einscherenden Fahrzeugs

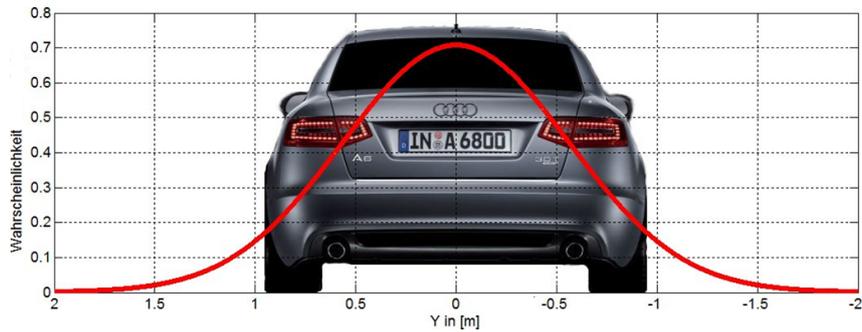


Abbildung 3.5: Gaußverteilung des Radar-Reflexionspunktes in y-Richtung am Fahrzeug-Heck

und die Geschwindigkeiten beider Fahrzeuge variiert und die Radardaten mit den Referenzdaten verglichen. Aus Radar-Sicht kann der Einschervorgang in drei Phasen unterteilt werden. Bei der ersten Phase ist nur ein Teil der Seitenfläche im Radarsichtbereich sichtbar. Der Radar-Reflexionspunkt liegt ungefähr in der Mitte der sichtbaren Fläche (Abbildung 3.6 (a)). Wird das Heck des Fahrzeugs teilweise sichtbar für den Radar, springt der Reflexionspunkt kurzzeitig zum hinteren Kotflügel (Abbildung 3.6 (b)) und anschließend auf die Mitte des Hecks, falls dieses vollständig im Radarsichtbereich liegt (Abbildung 3.6 (c)).

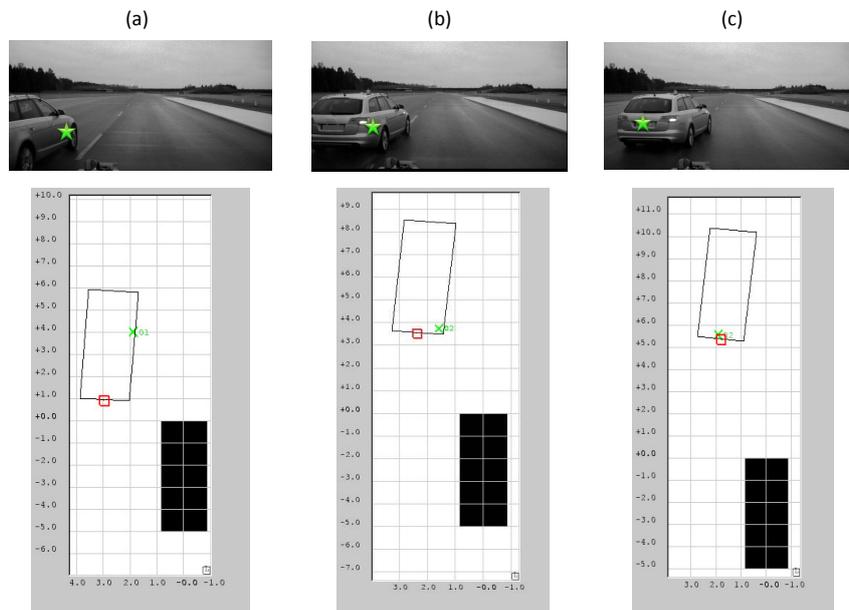


Abbildung 3.6: Einschervorgang (Referenzfahrzeug (weiß), Eigenfahrzeug (schwarz), Radar-Reflexionspunkt (grün))

Da es praktisch unmöglich ist, aus einem Radar-Reflex zwischen einer Heck-Fläche und einer Seiten-Fläche zu unterscheiden, können die drei Phasen des Einschervorgangs alleine mit dem Radar nicht aufgelöst werden. Hier ist eine Kooperation zwischen dem Radar-System und dem Laserscanner notwendig. Durch die Zuordnung eines Radar-Objektes zu einem Laser-Segment,

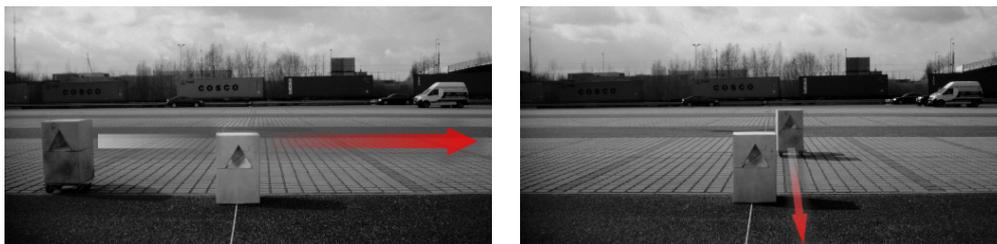
kann der Bezugspunkt der Radarmessung identifiziert und so die Messung mit angepassten Unsicherheiten interpretiert werden.

3.3.3 Ermittlung der Trennfähigkeit

Die Fähigkeit des Radar-Sensors, zwei nah beieinander liegenden Objekte zu trennen, wird anhand von Experimenten untersucht, bei denen zwei Reflexionswürfel relativ zueinander verschoben werden. Um den Effekt der Trennung beider Objekte anhand der Geschwindigkeitsmessung auszuschließen, wurden die Messungen mit stationären Objekten durchgeführt. Dabei wurden sowohl die laterale als auch longitudinale Trennfähigkeit untersucht.

Laterale Trennfähigkeit

Für die Bestimmung der lateralen Trennfähigkeit werden bei verschiedenen Entfernungen beide Reflexionswürfel so positioniert, dass der Radar-Sensor zunächst zwei unterscheidbare Objekte erfasst. Dabei wird der erste Reflexionswürfel im Lot positioniert und der zweite Reflexionswürfel anschließend lateral, knapp am ersten Reflexionswürfel vorbei, über den Sichtbereich mit konstanter Geschwindigkeit bewegt (s. Abbildung 3.7(a)).



(a) Laterale Bewegung eines Reflexionswürfels hinter einem stationär positionierten Reflexionswürfel (b) Longitudinale Bewegung eines Reflexionswürfels neben einem stationär positionierten Reflexionswürfel

Abbildung 3.7: Experimentelle Untersuchung der Trennfähigkeit

Der laterale Abstand, bei dem die Objekte zum ersten Mal zusammengefasst werden, wird mit einem Laserentfernungsmessgerät vermessen und charakterisiert die laterale Trennfähigkeit des Sensors. Das Experiment wird dann für unterschiedliche longitudinale Abstände wiederholt. Abbildung 3.8 zeigt einen Auszug aus dem Experiment. Im Diagramm sind alle vom Sensor gelieferten Objekte aufgetragen. Aus Tabelle 3.1 lassen sich außerdem die ermittelten minimalen lateralen Versätze, bei denen die Objekte getrennt werden konnten und die dazugehörigen Winkel entnehmen.

Longitudinale Trennfähigkeit

Bei der longitudinalen Trennfähigkeit geht es darum, den minimalen Versatz in der Längsrichtung zwischen zwei Objekten zu bestimmen, bei dem der Sensor die Objekte trennen kann. Hierzu

Abstand[m]	$Y_{min}[m]$	Winkel[°]
10	1,2	6,84
15	1,52	5,78
50	5,06	5,77

Tabelle 3.1: Minimale laterale Abstände und dazugehörige Winkel für die laterale Trennfähigkeit

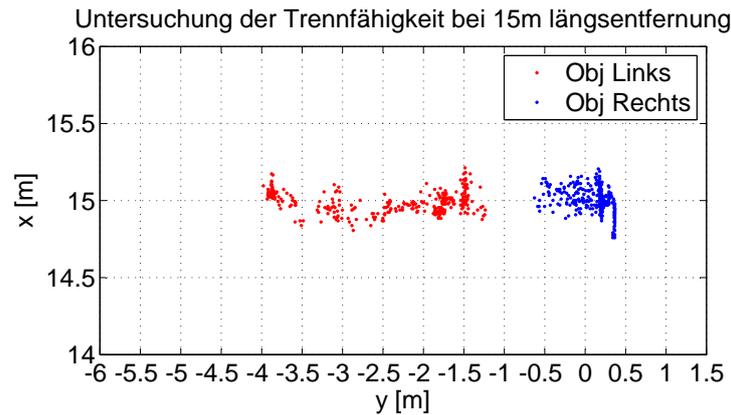


Abbildung 3.8: Laterale Trennung von zwei Objekten in 15 m Entfernung

wird der zweite Reflexionswürfel longitudinal, knapp am ersten Reflexionswürfel vorbei, mit konstanter Geschwindigkeit bewegt (s. Abbildung 3.7(b)). Dabei wird analog zur Bestimmung der lateralen Trennfähigkeit der erste Reflexionswürfel in verschiedenen Entfernungen zum Sensor positioniert.

Die Ergebnisse in Tabelle 3.2 zeigen, dass die longitudinale Trennfähigkeit des Doppelradar-Systems wesentlich besser als die laterale Trennfähigkeit ist.

Abstand[m]	5	10	15	50
$X_{min}[m]$	0,65	0,85	0,82	1,27

Tabelle 3.2: Minimaler Abstand für die longitudinale Trennfähigkeit

Die Erkenntnisse aus der Analyse der Trennfähigkeit können für eine bessere Interpretation der Radardaten genutzt werden. Werden beispielhaft zwei sich annähernde Objekte länger verfolgt, so kann ihre Verschmelzung beim Erreichen des Trennabstands erkannt werden. Mit Hilfe der kooperativen Sensormodellierung können die Radardaten mit den Laserdaten plausibilisiert werden. Somit kann das aus der Verschmelzung zweier Gegenstände resultierende Objekt als zwei getrennte Objekte interpretiert werden.

3.3.4 Ermittlung der Latenzzeit

Die Latenzzeit eines Messsignals ist die Zeitdifferenz zwischen dem Messzeitpunkt und dem Ankunftszeitpunkt des Signals in der Recheneinheit für die Weiterverarbeitung. Der Messzeitpunkt ist als der Zeitpunkt definiert, zu dem die Messung gültig ist. Dies entspricht bei aktiv messenden Umfeldsensoren dem Zeitpunkt, in dem die Reflexion des Sendesignals an dem Messobjekt stattfindet. Die Latenzzeit enthält also die sensorinterne Verarbeitungszeit wie z.B. die Signalauswertung zur Laufzeitbestimmung und die Übertragungszeit der Messsignalen zu der Recheneinheit. Denn bei einem verteilten Fahrerassistenzsystem kann die Steuereinheit vom Sensor getrennt sein, so dass eine Übertragung der Signale mit Hilfe eines Buskommunikationssystems notwendig ist. Es entsteht in der Regel ein Latenz-Fehler, wenn der Hardware-Zeitstempel bzw. der Messzeitpunkt unbekannt ist und dem Ankunftszeitpunkt gleichgesetzt wird. Abbildung 3.9 zeigt beispielhaft das zeitlich verschobene Geschwindigkeitssignal des Radars gegenüber der Messung aus dem Referenz-System.

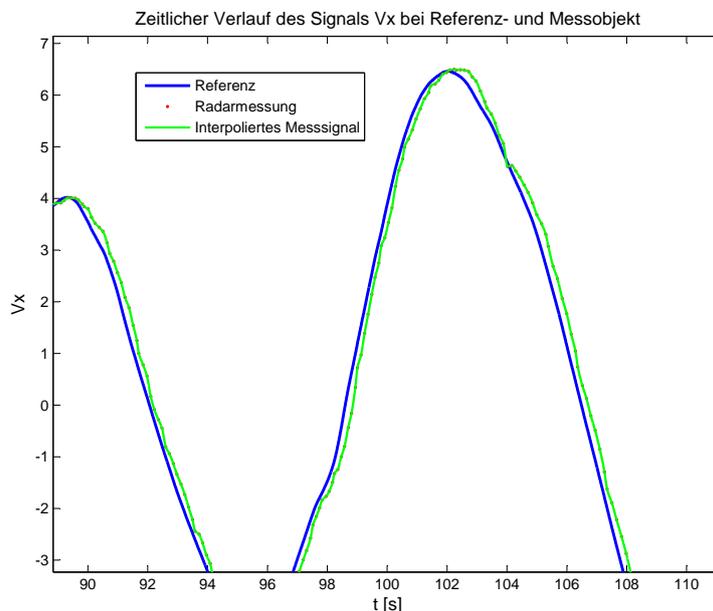


Abbildung 3.9: Vergleich zwischen Geschwindigkeitssignal aus Referenz und aus dem Radar

Für die Untersuchung der Ähnlichkeit von Signalen und zur Laufzeitmessung eignet sich die Anwendung der Korrelationstechnik. Speziell kann mit Hilfe der Kreuzkorrelationsfunktion zweier stochastischer Prozesse die Ähnlichkeit von zufälligen Signalen untersucht werden. Für die praktische Anwendung der Korrelationstechnik ist jedoch die Auswahl geeigneter Signale von großer Bedeutung. Zunächst wird von einem ergodischem Prozess ausgegangen. D.h. der Mittelwert zu einem Zeitpunkt t über die Schar aller möglichen Musterfunktionen entspricht dem Zeitmittelwert einer festen Musterfunktion des Prozesses [53]. Leistungssignale und speziell die Klasse der beschränkten und periodischen Signale sind für die Berechnung der Kreuzkorrelation geeignet, da diese Musterfunktionen ergodischer Prozesse sein können. Die Kreuzkorrelation zweier periodischen Leistungssignale ist über das Innenprodukt wie folgt definiert [53]:

$$R_{xy} = \langle x(t + \tau), y(t) \rangle \quad (3.12)$$

$$= \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-T/2}^{T/2} x(t + \tau) y(t) dt \quad (3.13)$$

Da in der praktischen Anwendung die Messung nach endlicher Zeit abgebrochen werden muss, können nur *Kurzzeitkorrelationsfunktionen* gemessen werden. Somit resultiert ein Schätzwert $\widehat{R}_{xx}(\tau)$ für die Korrelation, der selbst wieder eine Zufallsvariable ist:

$$\widehat{R}_{xy}(\tau) = \frac{1}{T} \int_0^T x(t + \tau) y(t) dt \quad (3.14)$$

Aufgrund der Umsetzung der Kreuzkorrelation in einem Rechner, stehen nur N zeitdiskrete Abtastwerte x_n und y_n der Signale $x(t)$ und $y(t)$ zur Verfügung. Die Kreuzkorrelation wird dabei durch die Summe der Multiplikationen der Abtastwerte geschätzt [78].

$$\widehat{R}_{xy}(k) = \frac{1}{N} \sum_{n=0}^{N-1} x_n y_{n+k} \quad (3.15)$$

mit $k = -(N - 1) \dots 0 \dots (N - 1)$. Die Ausgabe ist ein Vektor der Länge $2N - 1$. Die maximale Ähnlichkeit ergibt sich dann, wenn $\widehat{R}_{xy}(k)$ maximal wird. Konkret lässt sich für das Radar-System die Latenzzeit durch die Simulation einer dynamischen *Stop and Go* Situation zweier Fahrzeuge bestimmen. Das Zielfahrzeug beschleunigt und bremst abwechselnd stark und das Eigenfahrzeug führt dieselbe Bewegung zeitverzögert durch, so dass der Abstand zwischen den beiden Fahrzeugen eine Sinuskurve über die Zeit darstellt. Infolge der hohen dynamischen Bewegungen kann schließlich durch Vergleich des gemessenen Abstands vom Eigen- zum Zielfahrzeug bzw. der gemessenen Relativgeschwindigkeit des Zielfahrzeugs von Referenz und Radar auf die Latenzzeit geschlossen werden (s. Abbildung 3.9). In einem Intervall von 10 ms werden neue Referenzdaten und in unregelmäßigen Zeitabständen – zwischen 60 ms und 120 ms – neue Radardaten gemessen. Deshalb werden beide Signale zunächst interpoliert, so dass sich jeweils ein zeitdiskretes Signal der Länge N mit einem Intervall von 1 ms ergibt. Anschließend wird die diskrete Kreuzkorrelation mit dem Referenzsignal x_n und dem gemessenen Radarsignal y_n gebildet. Die Kreuzkorrelationsfunktion hat ihr Maximum bei der Zeitverschiebung der beiden Signale. Nun kann die Verschiebung in [ms] leicht herausgelesen und die Latenzzeit somit angegeben werden.

Bei der Analyse der Latenzzeit des Radars wurde festgestellt, dass diese stark abhängig von Einsatz-Szenario ab. Bei Szenen mit mehreren Objekten war die ermittelte Latenzzeit höher als bei Szenen mit wenigen Objekten. Dieses Ergebnis stellt eine plausible Erkenntnis dar. Denn die interne Verarbeitungszeit steigt mit der Anzahl der Messungen. Aufgrund dieses experimentellen Ergebnisses, wurde die Latenz-Untersuchungen bei verschiedenen Szenarien durchgeführt und

es wurde eine empirische Abhängigkeit der Latenzzeit von der Anzahl der gelieferten Objekte abgeleitet, mit der online eine Kompensation der Latenzzeit stattfinden kann:

$$\text{Latenzzeit} = 120 \text{ ms} + \text{Anzahl der Objekte} \cdot 4 \text{ ms} \quad (3.16)$$

3.3.5 Erfassung von Leitplanken

Die Erkennung von Randbebauungsverläufen ist von großer Bedeutung für Fahrerassistenzsysteme, die den Fahrer in der Querführung des Fahrzeugs unterstützen oder diese vollständig übernehmen. Um Erkenntnisse über die Erfassung solcher ausgedehnten stationären Hindernisse wie z.B. Leitplanken zu gewinnen, wurden verschiedene Fahr-Demos durchgeführt, bei dem das Eigenfahrzeug entlang einer langen Leitplanke fährt. Abbildung 3.10 zeigt die beispielhafte Erfassung einer Leitplanke durch das Radar-System. Diese wird vom Radar als eine Vielzahl entlang des Verlaufs liegender stationärer Objekte erfasst. Der Abstand zweier benachbarter Objekte, die zu einer Leitplanke gehören, liegt dabei i. d. R. zwischen 2 m und 15 m.

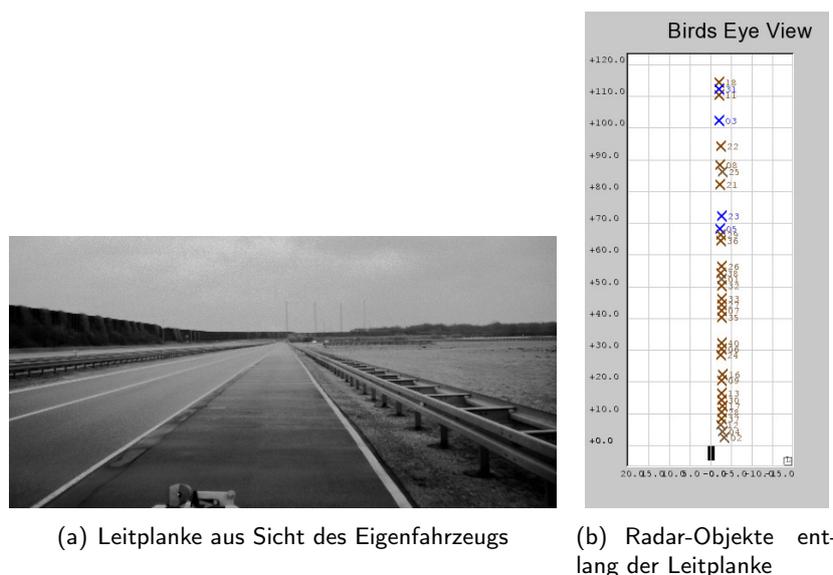


Abbildung 3.10: Erfassung einer Leitplanke durch den Radar-Sensor

Dabei nimmt die Anzahl der Leitplankenobjekte mit dem radialen Abstand ab. Je mehr Sigma-Pfosten und Distanz-Stücke eine Leitplanke besitzt, desto mehr Objekte kann der Radarsensor daraus bilden und desto näher liegen benachbarte Objekte, die einer Leitplanke angehören. Die bei der Analyse der Leitplankenerfassung gewonnenen Erkenntnisse werden bei einem Algorithmus zur Leitplankenerkennung eingesetzt. Der Algorithmus kombiniert verschiedene Indikatoren, um die Wahrscheinlichkeit $p(\text{„leitplanke“})$ zu bestimmen. Diese Wahrscheinlichkeit wird dann vom Radar-Sensormodell als Gewicht für die Unsicherheiten $p(e_{stoc} | \text{„leitplanke“})$ entlang der Leitplanke verwendet. Die Abbildung der Leitplanken-Unsicherheiten auf einem zwei-dimensionalen Belegungsgitter wird in Kapitel 4.1.5 behandelt.

3.4 Analyse eines Laserscanners

In der Arbeit kam ein seriennaher Laserscanner zum Einsatz. Dieser wurde bereits in Kapitel 2.1.2 präsentiert. Der Laserscanner stellt aufgrund des hohen Detaillierungsgrads seiner Messdaten und seiner Fähigkeit, einen Hinweis über den Freiraum in der Umgebung des Fahrzeugs zu geben, einen primären und somit einen sehr wichtigen Sensor für die untersuchten belegungskartenbasierten Ansätze dar. Daher wurde der Sensor auch systematisch untersucht. Im folgenden werden die Ergebnisse der Analyse des Amplitudensignals sowie der Genauigkeit der Entfernungsmessung vorgestellt und diskutiert.

3.4.1 Analyse des Amplitudensignals

Der eingesetzte Laserscanner liefert neben den Entfernungsmessdaten ein Amplitudensignal als Maß für die empfangene Leistung. Es handelt sich um ein Sensor internes Signal, dessen Wertebereich zwischen 0 und 80 liegt. Der Verlauf des Amplitudensignals entlang der Reflexionsfläche wurde für verschiedene Hindernisklassen untersucht. Dabei wurde festgestellt, dass viele Objekte einen typischen Amplituden-Verlauf abhängig von der Verteilung der Reflektivität entlang ihrer Oberfläche besitzen. Insbesondere für PKWs wurde ein typischer Verlauf mit meistens zwei ausgeprägten und symmetrischen Maxima (rechts und links) und einem kleineren Maximum in der Mitte festgestellt. Abbildung 3.11(a) bestätigt diese Erkenntnisse. Hier sind verschiedene Amplituden-Messungen für Vorderfahrzeuge in Entfernungen zwischen 10 m und 15 m aufgetragen. Die drei Maxima entsprechen wahrscheinlich den beiden Rück-Leuchten und dem Nummern-Schild, die eine höhere Reflektivität als der Rest des Hecks aufweisen.

Ein weiterer Effekt, der bei der Analyse des Amplitudensignals festgestellt wurde, besteht in der Überstrahlung bei stark reflektierenden Zielen. Dabei erscheinen am Rand von Zielen mit starker Reflektivität Messpunkte, die in der Realität gar nicht existieren. (siehe Reflexionspunkte auf dem Heck des Vorderfahrzeugs in Abbildung 3.11(b)). Der Effekt tritt verstärkt bei zur Fahrtrichtung orthogonalen Hindernissen wie z.B. Verkehrsschilder, Vorderfahrzeuge und Leitpfosten und in großen Entfernungen auf. Der Effekt ist wahrscheinlich auf die unscharfe Optik im Sender und Empfänger zurückzuführen. Die Objekte erscheinen in dem Laserscan aufgrund dieser Überstrahlung zu breit (s. Abbildung 3.11(b)). Bei abnehmender Entfernung zum Objekt reduziert sich der Effekt und die Breite des Objekts erscheint plausibel. Aus der Analyse konnte ebenfalls die Feststellung gewonnen werden, dass die falschen Reflexionspunkte, die am Rand der realen Objekte auftreten, einen niedrigen Amplitudenwert haben. Genau diese Eigenschaft wird in Kapitel 4.1.3 dazu genutzt, dem Effekt der Überstrahlung bei der Aktualisierung des Belegunggitters entgegen zu wirken.

3.4.2 Genauigkeit der Entfernungsmessung

Neben der Untersuchung des Amplitudensignals wurde auch die Genauigkeit der Entfernungsmessung des Laserscanners analysiert. Dabei war die Zielsetzung einerseits eine quantitative Aussage über die Qualität der Messung zu treffen, andererseits Abhängigkeiten wie z.B. von der Entfernung und Winkellage des gemessenen Objektes abzuleiten.

3. Analyse von Umfeldsensoren zur Herleitung von Sensormodellen

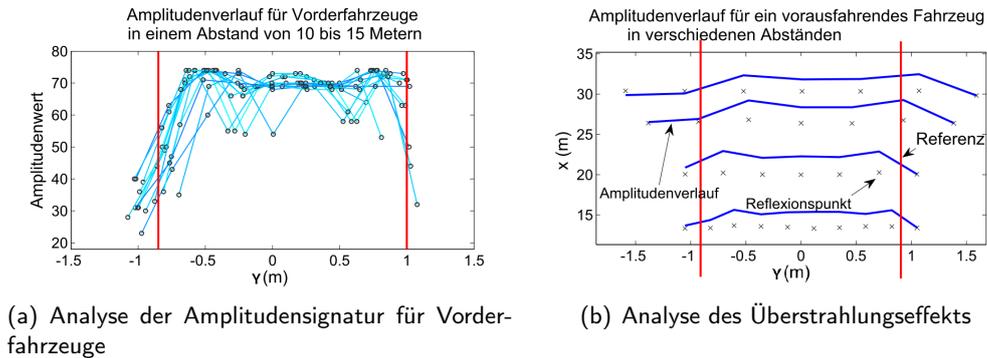


Abbildung 3.11: Auswertung des Amplitudensignals für Vorderfahrzeuge

Eine Referenzierung von Laser-Rohdaten ist wesentlich komplexer als die Bewertung von Objekt-Zuständen. Dies liegt zum einen an dem hohen Detaillierungsgrad der Rohdaten. Zum Anderen setzt die Bewertung der Rohdaten die Verfügbarkeit eines Referenz-Messsystems voraus, das eine ähnliche Detaillierung aufweist und gleichzeitig eine höhere Genauigkeit als das zu bewertende System besitzt. Für die Bewertung der Messungen des Laserscanners in der vorliegenden Arbeit kam das in Abschnitt 3.2.2 vorgestellte Konzept zum Einsatz. Dabei werden die Referenzdaten, die in Form von Zustandsvektoren ausgedehnter Objekte wie Linien oder Boxen vorliegen in Reflexionspunkte eines virtuellen Laserscanners transformiert. Hierzu wird ein Simulationsmodell verwendet, das ideale Reflexionspunkte gemäß einer Parameter-Konfiguration (Öffnungswinkel, Kanal-Breite, Reichweite) aus den Referenzdaten generiert. Das Simulationsmodell basiert auf geometrischen Berechnungen, die die sichtbaren Flächen der Objekte mit den Laser-Kanälen schneiden. Zwar nimmt die Aussagekraft der Bewertung abhängig von den getroffenen Annahmen über die Funktionsweise des Sensors ab, wie z.B. die Annahme, dass der Reflexionspunkt in der Mitte des Laser-Kanals liegt, das Konzept bietet aber verschiedene Möglichkeiten für die Bewertung. Es ist möglich z.B. den eigenen Sensor mit einem virtuellen höher aufgelöstem Sensor zu vergleichen. Die Ergebnisse einer solchen Simulation sind in Abbildung 3.12 dargestellt. Hier wurden eine Leitplanke und ein Vorderfahrzeug mit Hilfe des Referenz-Systems sehr genau vermessen. Die Reflexionspunkte vom zu bewertenden Laserscanner sind ebenfalls in der Abbildung als blaue Kreuze zu sehen.

Mit Hilfe der vorgestellten Bewertungsmethodik wird die Messgenauigkeit in jedem Kanal untersucht. Dabei wird eine hinreichend große Statistik gesammelt und die Verteilung des Fehlers betrachtet. Um die Abhängigkeit von der Entfernung zu ermitteln, wird die Fehler-Verteilung für verschiedene Abstände bestimmt. Die Verteilungen werden zunächst anhand von Häufigkeits-histogrammen beschrieben. In einem zweiten Schritt werden die Histogramme durch bekannte Verteilungen in dem Fall durch eine Normalverteilung approximiert. Die Ergebnisse der Untersuchungen für den mittleren Laser-Kanal sind in Abbildung 3.13 zusammengefasst. Die Ergebnisse zeigen, dass der Fehler durch eine Normalverteilung statistisch beschrieben werden kann. Auffällig ist, dass der Fehler nicht mittelwertfrei ist. Der Mittelwert steigt mit der Entfernung. Dies deutet auf einen systematischen Fehler (z.B. Kalibrierfehler) hin, der abhängig von der Entfernung zwischen Messobjekt und Sensor ist.

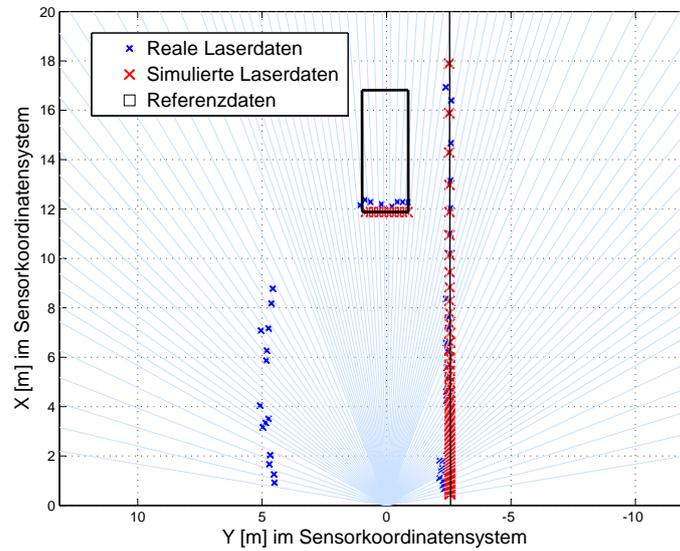


Abbildung 3.12: Vergleich der Lasermessdaten mit simulierten Laserdaten aus der Referenz

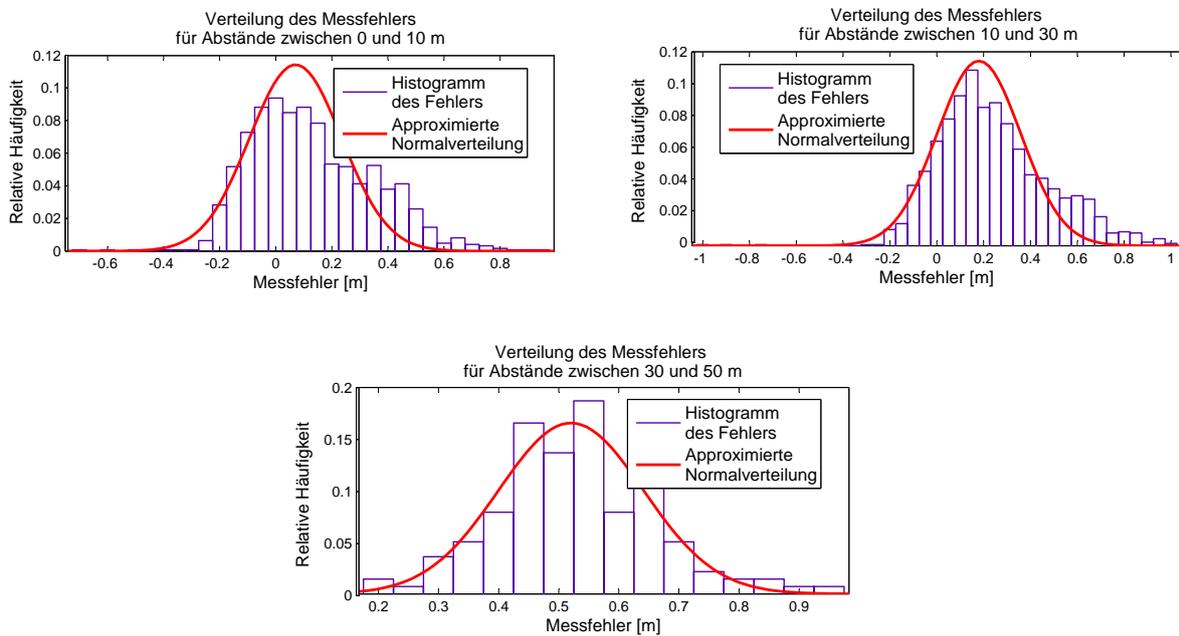


Abbildung 3.13: Genauigkeit des Laserscanners in Abhängigkeit des Abstands

4 2D kartenbasierte Umfeldwahrnehmung

Die im letzten Kapitel diskutierten Methoden zur Sensormodellierung werden in Verbindung von Schätzaufgaben eingesetzt. Im Fall der kartenbasierten Umfeldrepräsentation werden freie, belegte und unbekannte Räume anhand von Sensordaten geschätzt. In diesem Kapitel werden zwei belegungskartenbasierte Repräsentationen vorgestellt. Im ersten Teil des Kapitels wird das aus dem Stand der Technik bekannte zweidimensionale Belegungsgrid behandelt. Danach wird die Idee der modellbasierten Freiraumverfolgung als neuer Ansatz zur Beschreibung und Erfassung von Freiräumen mit Hilfe von Radar- und Laser-Sensoren beschrieben.

4.1 Zweidimensionale Belegungsgrid

Zunächst wird auf die klassische Form einer Belegungskarte nämlich das Belegungsgrid eingegangen. Der Augenmerk liegt dabei auf den Beiträgen der Arbeit zur Verbesserung des zweidimensionalen Belegungsgrid hinsichtlich der Qualität der akkumulierten Daten, der Speicher- und Recheneffizienz. Hierfür wurden verschiedene Maßnahmen in der Auswahl der Datenstruktur, in der Eigenbewegungskompensation und in der genauen Sensormodellierung ergriffen.

4.1.1 Datenstrukturen

In Anlehnung an die in Kapitel 2.3.1 präsentierte Definition einer Belegungskarte, besteht das Belegungsgrid aus einer Gitterstruktur. D.h. die Raumelemente sind quadratische Zellen, denen verschiedene Eigenschaften wie z.B. eine Belegungswahrscheinlichkeit zugeordnet werden. Abbildung 4.1 zeigt eine Zellenstruktur, mit verschiedenen Informationen, die eine Zelle enthalten kann.

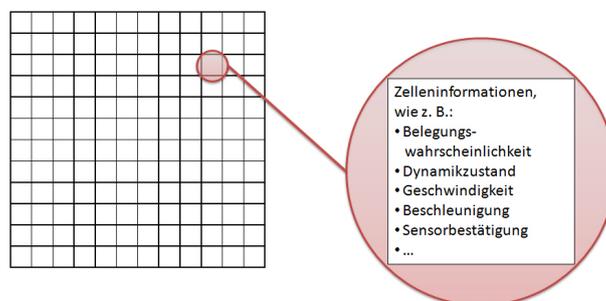


Abbildung 4.1: Aufbau eines zweidimensionalen Belegungsgrid

Wird die Belegungswahrscheinlichkeit betrachtet, so besteht die Aufgabe der Umfeldkartierung in der Bestimmung der Wahrscheinlichkeiten der Belegungskarte M für den Zeitschritt k , die durch die bedingte Wahrscheinlichkeit $p(M_k | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k})$ beschrieben wird. Die Änderung in der Position des Eigenfahrzeugs und die Messungen aus den Umfoldsensoren $\mathbf{y}_{1:k}$ und ihre Fehler-Verteilungen werden als bekannt angenommen. Eine Vereinfachung des Problems stellt die getrennte Betrachtung der einzelnen Zellen dar. Diese angenommene statistische Unabhängigkeit ist nicht immer gegeben, denn die Umgebung einer Zelle beeinflusst den Messvorgang des Sensors. Somit kann die Belegung der Zelle von ihren Nachbarzellen abhängen. Trotzdem ermöglicht diese Annahme einen recheneffizienten Aufbau des Belegungsgitters. Die Effekte dieser Vereinfachung werden durch Maßnahmen in der Sensormodellierung kompensiert.

Das Belegungsgitter ist im Speicher als eindimensionales Feld hinterlegt. Dadurch bildet die Belegungskarte einen zusammenhängenden Bereich im Speicher. Die Navigation auf der Karte kann schnell durch Inkrementierung oder Dekrementierung der Speicheradressen durchgeführt werden. Eine solche Methode hat zwar einen größeren Speicheraufwand als z. B. die Verwendung einer Baumstruktur zur Folge. Baumstrukturen wie *k-d-trees* ([83], [100], [91]) unterteilen den Raum in innere Knoten, die wiederum aus Unterknoten bestehen. Dabei werden die Unterknoten nur betrachtet, falls diese andere Informationen als der übergeordnete Knoten enthalten. Bei nur spärlich besetzten Szenen benötigen *k-d-trees* im Gegensatz zu statischen Arrays mit fester Diskretisierung wesentlich weniger Speicherplatz, da uniforme Bereiche nicht weiter unterteilt werden müssen. Solche Baumstrukturen sind aber wenig geeignet, dynamische Szenen zu kartieren. Denn durch die Bewegung des Eigenfahrzeugs und der Objekte in der Umgebung, muss die Baumstruktur aufwändig angepasst werden. Die hier eingesetzte Indizierung der Zellen und Ablage im Speicher als eindimensionales Array ist den Baumstrukturen hinsichtlich des Laufzeitverhaltens beim Aktualisieren der Belegungskarte überlegen. Diese Erkenntnis wurde bereits in frühere Arbeiten wie z.B. [57] gezeigt.

Subzellmodellierung der Belegung

Eine Maßnahme zur Erhöhung der Genauigkeit der Kartierung ohne zu viel Speicher zu nutzen besteht in der Subzellmodellierung der Belegung. Hierzu wird in jeder Zelle auf dem Belegungsgitter ein lokales Koordinatensystem angelegt, wie im linken Teil der Abbildung 4.2 dargestellt ist. Dieses beschreibt den Schwerpunkt der Belegung innerhalb der Zelle, so dass eine höhere Genauigkeit als die Zellenauflösung erzielt werden kann. Dadurch könnten z.B. kleine Bewegungen von Objekten auf der Belegungskarte aufgelöst werden, was bisher als eine der großen Schwächen der gitterbasierten Ansätze galt. Für die Beschreibung der Koordinaten des Subzellwertes werden jeweils ein 8 Bit langer Wert genutzt, so dass 256 Stufen dargestellt werden können. Bei einer Karte von 120 m×120 m mit einer Zellenauflösung von 20 cm und 64Bit pro Zelle erzielt die Subzellmodellierung ein Speicherersparnis von 68% gegenüber der Verdopplung der Auflösung. Durch das Hinzunehmen des Belegungsschwerpunkts erweitert sich die Aufgabe der Umfeldkartierung um die Schätzung der Belegungskoordinaten innerhalb der Zelle. Diese können z.B. mit Hilfe einer gewichteten Mittelwertbildung kombiniert werden, so dass ein neuer Subzellwert bei einer neu eintreffenden Messung entsteht. Der Ansatz ermöglicht ein genaueres Aktualisieren des Belegungsgitters und somit auch eine genauere Informationsgewinnung im Extraktionsschritt (siehe rechten Teil in Abbildung 4.2). Die Idee wurde im Rahmen der Arbeit in [Bouzouraa 2010]

vorgelegt.

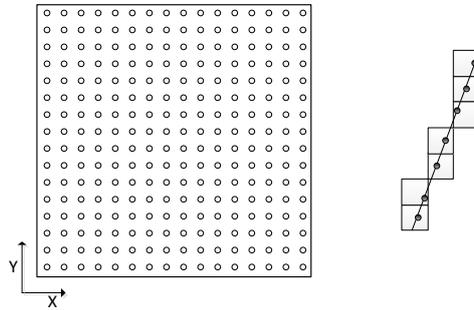


Abbildung 4.2: Subzellmodellierung der Belegung. Links: Lokales Koordinatensystem innerhalb der Zelle, Rechts: Nutzung der Subzellanforderung beim Aktualisieren der Zellen

4.1.2 Effiziente Eigenbewegungskompensation

Die Aufgabe der Eigenbewegungskompensation besteht darin, das Belegungsgitter aufgrund der Bewegung des Eigenfahrzeugs zwischen zwei Messzeitpunkten anzupassen. Durch diese Anpassung wird das Belegungsgitter für die Aktualisierung mit neuen Umfeldsensordaten vorbereitet. Dieser Schritt entspricht der Bestimmung der Wahrscheinlichkeit $p(O_{\mathbf{x}}|\mathbf{X}_{k-1:k}^{ego}, M_{k-1})$ für jede Zelle.

Kompensation der translatorischen Bewegung

Das Verschieben der Karte aufgrund der translatorischen Fahrzeugbewegung kann durch Umkopieren von Zellen geschehen, wie es in Abbildung 4.3 grafisch dargestellt ist. Hier müssen die rot umrahmten Zellen so umkopiert werden, dass die überflüssigen Zellen hinter dem Fahrzeug überschrieben werden und Zellen vor dem Fahrzeug für die neu erfassten Bereiche frei werden. Dieses Umkopieren erfordert zeitaufwendige Operationen auf dem Speicher.

Eine alternative Lösung dieses Problems besteht in der Einführung eines Start-Zeigers. Dieser Start-Zeiger, symbolisiert durch den roten Pfeil in Abbildung 4.4, gibt an, wo im Speicher sich die erste Zelle der Karte, in Abbildung 4.4 grün markiert, befindet. Die bei der Bewegung der Karte vom Start-Zeiger übersprungenen Zellen werden dabei neu initialisiert und stehen zum Speichern neu hinzu getretener Bereiche bereit, wie es auf der rechten Seite in Abbildung 4.4 angedeutet ist. Die Ablagereihenfolge im Speicher wird durch die grünen Pfeile verdeutlicht. Die gleichen Mechanismen werden für eine Bewegung in y -Richtung angewendet, so dass das Belegungsgitter als ein zweidimensionaler Ringpuffer im Speicher vorliegt. Für den Zugriff auf die Zellen wird der Offset des Start-Zeigers in x - und y -Richtung bezüglich seiner Position bei der ersten Erstellung der Karte gespeichert.

Da die Umgebung um das Fahrzeug auf der Belegungskarte diskretisiert ist, kann die Translationsbewegung nur quantisiert auf dem Belegungsgitter übertragen werden. Aus diesem Grund

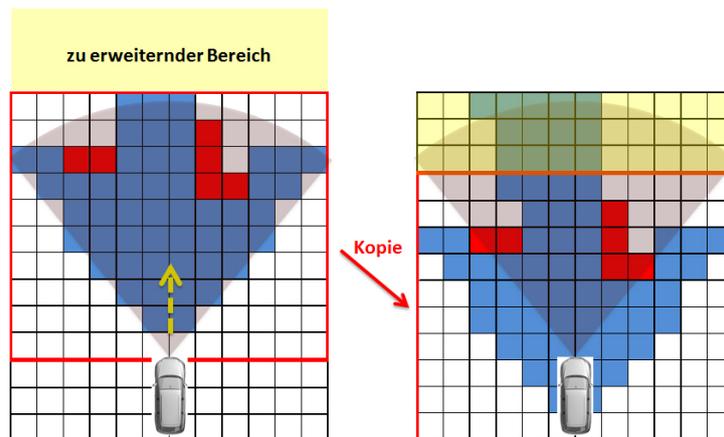


Abbildung 4.3: Ineffiziente Eigenbewegungskompensation durch Umkopieren

wird die exakte Position des Fahrzeugbezugspunktes (Mitte Hinterachse) innerhalb einer Zelle bestimmt und gespeichert werden. Diese Technik wird in der Arbeit **Subzellbestimmung der Fahrzeugposition** bezeichnet und ist notwendig, um kleine Bewegungen des Eigenfahrzeugs auf der Belegungskarte aufzulösen. Dies ist wichtig z.B. für die Funktion Stauassistent im Niedriggeschwindigkeitsbereich. Die genaue Fahrzeugposition wird dann beim Aktualisieren der Belegungskarte sowie bei der Extraktion von Belegungsinformationen (s. Kapitel 7) verwendet.

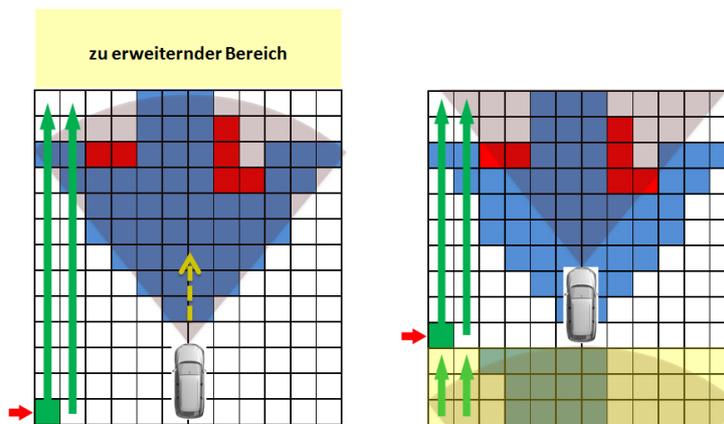


Abbildung 4.4: Effiziente Eigenbewegungskompensation mit Hilfe von Zeigeroperationen

Kompensation der Gierbewegung

Neben der translatorischen Bewegung führt das Fahrzeug auch Rotationsbewegungen in Form von Gierbewegungen durch. Diese müssen ebenfalls zwischen zwei Zeitschritten auf das Belegungsgitter übertragen werden. Da die Drehung der Gitterzellen rechenintensiv ist, wird das Fahrzeug in der Mitte des Belegungsgitters platziert und entsprechend den Daten aus der Eigenbewegungsschätzung (siehe 2.1.4) rotiert. Die Orientierung des Karten-Koordinatensystems bzw.

der Zellen entspricht der Anfangsausrichtung des Fahrzeugs und ist deswegen statisch. Abbildung 4.5 verdeutlicht nochmal das Prinzip der Eigenbewegungskompensation auf dem Belegungsgitter.

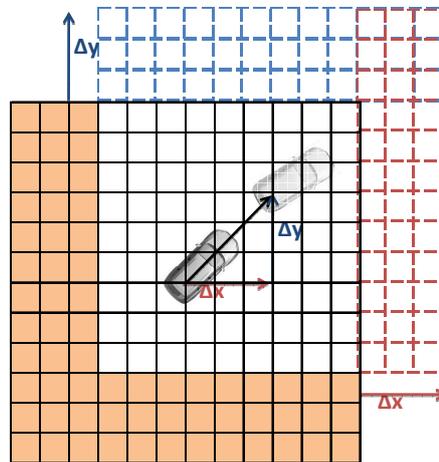


Abbildung 4.5: Eigenbewegungskompensation auf dem Belegungsgitter

Berücksichtigung der Unsicherheit in der Eigenbewegungsschätzung

Neben den notwendigen Mechanismen für die effiziente Eigenbewegungskompensation ist die Berücksichtigung der Unsicherheiten der Eigenbewegungsschätzung ein wichtiger Aspekt für den Aufbau eines konsistenten und genauen Belegungsgitters. Die Daten, die die Bewegung des Fahrzeugs beschreiben, sind aufgrund von Unsicherheiten in den eingesetzten Sensoren fehlerbehaftet. Ein möglicher Weg für die Berücksichtigung dieser Effekte besteht darin, die komplette Belegungskarte bei jedem Schritt der Eigenbewegungskompensation mit einer zusätzlichen Unsicherheit zu behaften. Diese Methode ist zwar genau, würde aber einen erheblichen Rechenaufwand mit sich bringen. Ein wesentlich effizienter Weg besteht in dem Zurückführen der Ungenauigkeiten der Eigenbewegungsdaten auf eine Unsicherheit in der Position des Umfeldsensors (Laser oder Radar). Diese Unsicherheiten können dann beim Aktualisieren der Belegungskarte berücksichtigt werden. Mit Hilfe dieser Idee können aber nur die Zellen, die von den Sensordaten aktualisiert werden profitieren, was ein kleiner Nachteil darstellt.

4.1.3 Vorverarbeitung der Laserrohdaten

Die Vorverarbeitung der Laserrohdaten hat zum Ziel, einerseits frühzeitig Fehlmessungen zu erkennen und somit die Sensordaten zu plausibilisieren. Andererseits werden die Messdaten in diesem Schritt mit weiteren Informationen angereichert (z.B durch die Segmentierung der Laserreflexionspunkte), so dass das inverse Sensormodell möglichst viele Nutzinformationen aus den Messungen für die Aktualisierung der Belegungskarte extrahieren kann. In den folgenden beiden Abschnitten werden zwei der in der Arbeit eingesetzten Vorverarbeitungsschritte beschrieben.

Segmentierung der Laserrohdaten

Bei der Segmentierung der Laserrohdaten werden die Reflexionspunkte in lineare Segmentlinien überführt. Viele der Hindernisse in der Umgebung des Fahrzeugs können durch solche Segmente beschrieben werden. Die Idee der Vorverarbeitung durch die Segmentierung besteht darin, die zu Segmentlinien gehörenden Rohdaten zu markieren. Diese Information wird dann mittels des inversen Lasersensormodells dazu genutzt, das Belegungsgitter möglichst genau zu aktualisieren. Aus der Segmentierung der Rohdaten können eine Vielzahl von Informationen abgeleitet werden. So können die Messdaten pro Laserkanal um zusätzliche Attributen erweitert werden, wie z.B. die Länge des dazugehörigen Segments, seine Ausrichtung gegenüber des eigenen Fahrzeugs und die Güte der Beschreibung des dazugehörigen Hindernisses durch eine Linie.

In der Literatur sind eine Vielzahl von Ansätzen zur Segmentierung von Laserreflexionspunkten zu finden. Bei der Auswahl einer geeigneten Methode für die vorliegende Arbeit, waren die Berücksichtigung der Strahldivergenz (Unschärfe innerhalb der Laserkanäle), das Miteinbeziehen der Messunsicherheit und die Generierung eines Gütemaßes über die Beschreibung einer Gruppe von Reflexionspunkten durch ein lineares Segment ausschlaggebende Kriterien. Der verwendete Ansatz verläuft in drei Schritten:

1. **Gruppierung der Reflexionspunkte** durch Detektion von Diskontinuitäten innerhalb eines Entfernungsscans.
2. **Bestimmung der Knick- und Eckpunkte**, die die verschiedenen Linien trennen.
3. **Berechnung der Regressionsgerade** für jede Gruppe.

Die Gruppierung der Reflexionspunkte basiert auf der *Adaptive Breakpoint Detector*-Methode, die in [4] vorgestellt wird. Grundidee dieses Ansatzes ist die Detektion von Diskontinuitäten innerhalb eines Entfernungsscans. Eine Diskontinuität entsteht, falls ein Laserkanal keine Messung enthält. Bereiche innerhalb eines Scans, die keine Diskontinuitäten aufweisen, beschreiben eine Gruppe von Punkten, die wahrscheinlich zu einem Objekt gehören. Damit werden zwei Punkte $p_{n-1} = (r_{n-1}, \varphi_{n-1})$ und $p_n = (r_n, \varphi_n)$ der gleichen Gruppe zugewiesen, falls der euklidische Abstand zwischen den Punkten kleiner als D_{max} ist. r und φ bezeichnen respektive die gemessene Entfernung und der Winkel des Reflexionspunktes. Die Schwelle D_{max} hängt dabei von einem minimalen Einfallswinkel λ , der Kanalbreite $\Delta\varphi$ und dem vorhergegangenen Entfernungswert r_{n-1} ab (s. Abbildung 4.6). Dementsprechend berücksichtigt der Ansatz durch $\Delta\varphi$ die Strahldivergenz und durch λ die Reflexionseigenschaften des Sensors.

Aus der maximalen Entfernung D_{max} und dem Kanalwinkel φ_n ergibt sich ein Segment, auf dem der Punkt p_n liegt, falls p_{n-1} und p_n zum gleichen Objekt gehören. Das Segment ist in Abbildung 4.6 durch r_{nL}^h und r_{nU}^h beschrieben. Die genaue Herleitung der adaptiven Schwelle D_{max} kann in [4] nachgelesen werden.

Nach der Gruppierung der Reflexionspunkte werden die Eckpunkte bestimmt, die die verschiedenen Linien trennen. Hierzu wird auf das bekannte *IEPF* („*Iterative Endpoint Fit*“-Verfahren zurückgegriffen. Der Algorithmus wurde zum ersten Mal in [74] vorgestellt. Seine Grundidee beruht auf der Berechnung des Abstands zwischen dem untersuchten Punkt und der Gerade, die durch den Anfangs- und Endpunkt der Gruppe definiert ist. Die Punkte der Gruppe werden nacheinander abgearbeitet. Übersteigt der maximale Abstand zur Gerade eine Schwelle, so wird der

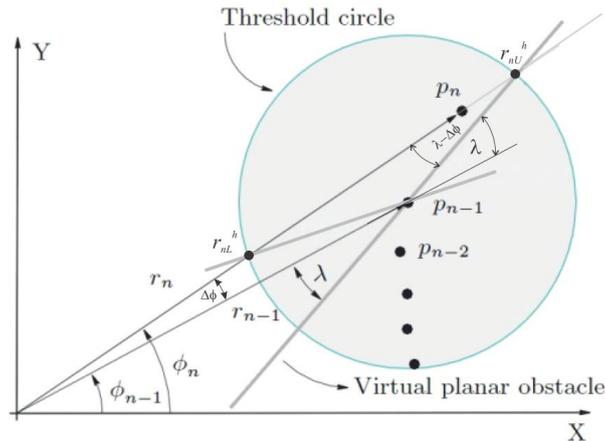


Abbildung 4.6: „Adaptive Breakpoint Detector“-Methode [4]

dazugehörige Punkt als Eckpunkt bzw. Knickpunkt markiert. Anschließend wird die Suche nach weiteren Eckpunkten für die Untergruppen durchgeführt. Der Standard IEPF-Ansatz neigt beim verwendeten Laserscanner dazu, zu viele Eckpunkte zu erzeugen. Deshalb wurde das Verfahren um ein Winkel-Kriterium erweitert. D.h. der Winkel, der durch den potentiellen Eckpunkt und die beiden Extrema der Gruppe muss eine gewisse Schwelle überschreiten, damit, der Messpunkt als Eckpunkt klassifiziert wird. Außerdem wurde das Distanz-Kriterium abhängig von der Entfernung der zu untersuchenden Punkte skaliert. Im Nahbereich werden größere Distanz-Schwellen für die Bestimmung der Eckpunkte als im Fernbereich verwendet.

Im letzten Schritt der Segmentierung wird für jede Gruppe von Punkten, die zu einer Linie gehören eine Regressionsgerade berechnet. Hierfür wird auf die „Least Squares“-Methode zurückgegriffen werden [71], [34].

Plausibilisierung anhand des Amplitudensignals

In 3.4.1 wurde bereits das Problem des Überstrahlungseffekts bei stark reflektierenden Objekten beim eingesetzten Laserscanner diskutiert. Aufgrund dieses Effektes erscheinen die erfassten Hindernisse breiter als in der Realität. Abbildung 4.7 zeigt die projizierten Laser-Daten in ein Video-Bild. In der Abbildung ist deutlich zu erkennen, dass an den Rändern des Vorderfahrzeugs links und rechts Fehlmessungen vorhanden sind. Dieses Problem führt bei Vorbeifahrten an Verkehrsschildern oder parkenden Fahrzeugen zu Fehlauflösungen beim System der aktiven Gefahrenbremsung (E.1). Denn aufgrund der zu breiten Hindernisse schätzt das System fälschlicherweise die Situation kritischer als in der Realität und leitet deswegen eine Warnung oder eine autonome Bremsung ein.

Aus diesen Gründen wurde in der Arbeit einen Algorithmus entwickelt, der diese Fehlmessungen möglichst deplausibilisieren soll. Der Algorithmus baut auf die Erkenntnisse aus der Analyse des Amplitudensignals in 3.4.1. Dort wurde festgestellt, dass die Amplitude des reflektierten Signals an den Rändern stark reflektierender Hindernisse abnimmt. Deshalb werden zunächst die Laser-Rohdaten gemäß das Verfahren aus Abschnitt 4.1.3 gruppiert und segmentiert. Für die fast

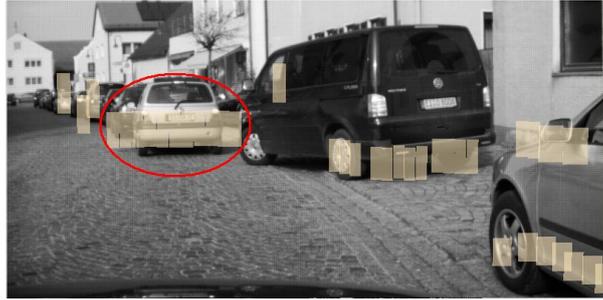


Abbildung 4.7: Projektion der Laserrohdaten in das Bild der onboard-Kamera

zur Fahrzeuglängsachse orthogonalen Segmenten findet eine genaue Untersuchung der Amplitudenverteilung über die dazugehörigen Laser-Kanäle statt. Dabei wird innerhalb der Gruppe der Laserkanal mit der maximalen Amplitude gesucht. Danach werden die Amplituden der zum Segment gehörenden Kanäle auf die maximale Amplitude normiert. Die resultierenden Werte werden als Gewichte betrachtet. Unterschreitet das Gewicht eines Kanals eine vorgegebene Schwelle, wird die Messung innerhalb dieses Kanals als unplausibel markiert. Die Schwelle wurde basierend auf die experimentellen Ergebnisse der Sensordatenanalyse in 3.4.1 festgelegt.

4.1.4 Laserscannersensormodell für Belegungsgitter

Die Aufgabe des Sensormodells bei der Schätzung des Belegungszustands $O_k^{\mathbf{X}}$ einer Zelle \mathbf{X} zum Zeitpunkt k besteht allgemein darin, die Wahrscheinlichkeit $p(\mathbf{y}_k | O_k^{\mathbf{X}}, p_1, \dots, p_n)$ zu bestimmen. \mathbf{y}_k stellt die Sensormessung im Zeitschritt k dar und p_1 bis p_n sind Einflussgrößen auf die Messungen des Sensors. Für die Aktualisierung des Belegungsgitters nach Bayes wird eher das inverse Sensormodell, beschrieben durch die Wahrscheinlichkeit $p(O_k^{\mathbf{X}} | \mathbf{y}_k, p_1, \dots, p_n)$, betrachtet. Die Verwendung des inversen Modells vereinfacht das Kartierungsproblem, da es die direkte Übertragung der Sensormessung auf die räumliche Zellenstruktur zulässt. Die gesuchte Verteilung bzw. Wahrscheinlichkeit des inversen Sensormodells kann aus den Fehlermodellen der Sensoren aus dem Kapitel 3 hergeleitet werden. Hierzu muss der Messfehler auf einen Fehler im Belegungszustand übertragen werden. Es resultiert eine Verteilung, wie in Abbildung 4.8 dargestellt ist. Zellen, die vor der Entfernungsmessung $y_k = d$ liegen, werden als frei betrachtet und erhalten deswegen eine niedrige Belegungswahrscheinlichkeit. Solche die in der Umgebung der Sensormessung sich befinden, erhalten eine Wahrscheinlichkeit entsprechend dem Fehlermodell des Sensors. Der Belegungszustand der Zellen hinter der vorliegenden Messung wird als unbekannt eingestuft. Die resultierende Verteilung bietet eine Grundlage für die Berücksichtigung der Einflussgrößen p_1 bis p_n .

Dieses Verfahren der inversen Sensormodellierung für Belegungsgitter ist in der Literatur weit verbreitet [22] [23], da es eine effiziente Umfeldkartierung mit Hilfe von Laserscannern ermöglicht. Durch das inverse Sensormodell kann der Aufbau des Belegungsgitters als einzelne getrennte Schätzprobleme (pro Zelle ein Schätzproblem) behandelt werden [89]. Das Zurückführen der Umfeldkartierung auf ein mehrdimensionales Problem, wie in [89] der Fall, hat zu nicht echtzeitfähigen Lösungen geführt. In [89] dauert die Berechnung eines Belegungsgitters bis zu einer

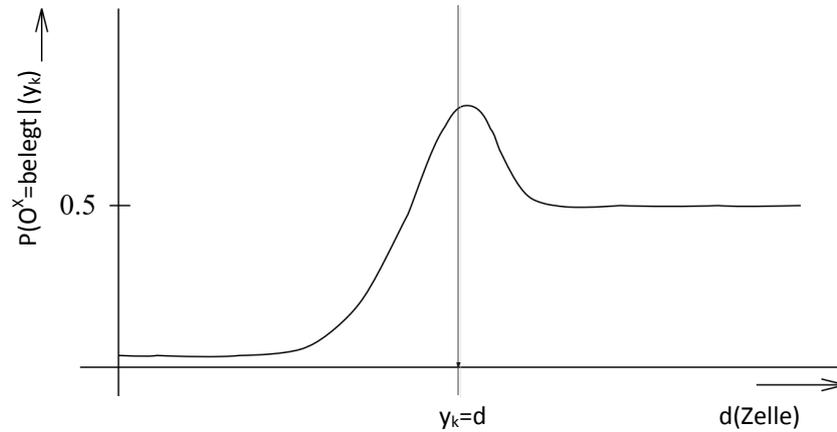


Abbildung 4.8: Qualitative Darstellung der Verteilung des Sensormodells für den Zustand „belegt“

Minute.

In der vorliegenden Arbeit wird die Annahme der statistischen Unabhängigkeiten einzelner benachbarter Zellen stark geschwächt, indem einzelne dominante Sensor-Effekte wie z.B. die Reflexion entlang zum Eigenfahrzeug parallel verlaufender Hindernisse berücksichtigt werden. Weitere physikalische Eigenschaften des Sensors wie z.B. das Amplitudensignal werden außerdem bei der Interpretation der Messdaten stärker in Betracht gezogen. Dadurch werden bestimmte Abhängigkeiten zwischen den einzelnen Messungen (z.B. die Zugehörigkeit der Laser-Messpunkte zu einer Gruppe mit einer gewissen Amplitudenverteilung) früh erkannt. Mit diesem zusätzlichem Wissen werden die einzelnen Messungen angereichert. Anschließend können die Zellen im Belegungsgitter getrennt und somit recheneffizient unter Berücksichtigung des generierten Vorwissens aktualisiert werden. Die Schätzung des Belegungsgitters mit Hilfe der Laserscannerdaten kann dann auf die Befüllung einer gerasterten Fläche zurückgeführt werden (s. Abbildung 4.9).

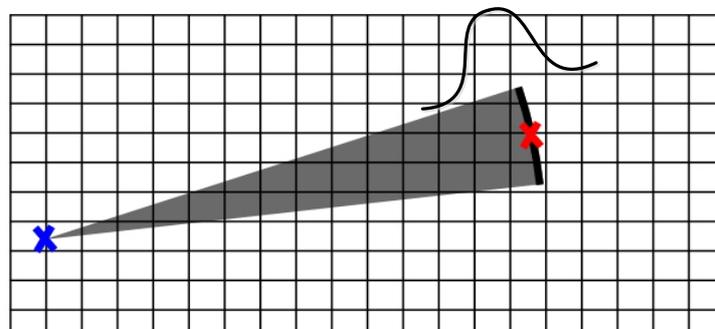


Abbildung 4.9: Modellierung der Frei- und Belegungsinformation innerhalb eines Laser-Kanals

Modellierung der Strahldivergenz durch Befüllen von gerasterten Dreiecken

Aufgrund von Kosten-Nutzen Abwägungen haben serientaugliche Laserscanner-Sensoren oft die Eigenschaft, dass sie eine gewisse Unschärfe im gesendeten Lasersignal besitzen [84]. Dies liegt an den Eigenschaften der Sensor-Optik und an der begrenzten Rechenleistung des Sensors. Die Winkellage des Hindernisses innerhalb eines Kanals ist somit nicht genau bekannt. Die Belegungsinformation muss deshalb auf einen gesamten Sektor verteilt werden (s. Abbildung 4.9). Dieser Sektor kann für kleine Kanalwinkelbreiten (1° bis 4°) durch ein Dreieck angenähert werden.

In der vorliegenden Arbeit wurde eine effiziente Methode für die Füllung eines gerasterten Dreiecks entwickelt. Diese nutzt die einfache mathematische Eigenschaft, nach der eine Gerade die Ebene in zwei Hälften teilt. Ein Punkt (x, y) in der Ebene liegt genau auf der durch den Start- (x_1, y_1) und den Endpunkt (x_2, y_2) definierten Gerade, falls folgende Bedingung erfüllt ist:

$$f(x, y) = (x_2 - x_1) \cdot (y - y_1) - (y_2 - y_1) \cdot (x - x_1) = 0 \quad (4.1)$$

Die Funktion f aus Gleichung 4.1 ist dann positiv auf der einen Seite von der Gerade und negativ auf der anderen. Wird diese Bedingung für die drei Kanten des Dreiecks gewertet, so ist sichergestellt, dass der Punkt innerhalb des Dreiecks liegt. Die Optimierung dieser einfachen Idee erfolgt dann schrittweise:

- **Festlegung einer ROI (*Region Of Interest*):** Die Anzahl der zu überprüfenden Bedingungen kann erheblich reduziert werden, indem eine rechteckige ROI um das Dreieck angelegt wird (s. Abbildung 4.10). Nur die Punkte, die innerhalb der ROI liegen, werden genau untersucht, ob sie auch innerhalb des Dreiecks liegen.
- **Berechnung der Konstanten:** Die enthaltenen Konstanten der Funktion in Gleichung 4.1 können im Vorfeld berechnet und im Speicher hinterlegt werden.
- **Einführung einer Rekursion:** Durch die zeilenweise Analyse der ROI, kann eine Rekursion eingeführt werden. Die Berechnung der Bedingung eines Pixels kann von den Berechnungen seiner Nachbar-Pixel profitieren. Es resultiert eine weitere Reduzierung der Rechenoperationen.
- **Block-Verarbeitung:** Ein weiterer großer Vorteil der eingesetzten Methode ist die Möglichkeit einer Block-Verarbeitung der Zellen. Liegen die äußeren Zellen eines zum Beispiel 8×8 Blocks außerhalb des Dreiecks, so sind zwangsweise auch die anderen Zellen des Blocks außerhalb des Dreiecks. Die Auswertung der Bedingungen für die inneren Pixel muss folglich nicht durchgeführt werden.
- **Parallele Verarbeitung:** Die eingeführten Blöcke können schließlich parallel verarbeitet werden, falls ein Multiprozessorsystem, oder ein FPGA (*Field Programmable Gate Array*) zum Einsatz kommt.

Das Verfahren wird in der vorliegenden Arbeit HEBF(**H**alb**e**benen-**B**lock-**F**üll)-Algorithmus genannt. Dieser Ansatz ist besonders geeignet für kleine Dreiecke und somit genau passend für die Aufgabe des Sensormodells. Im Rahmen der Arbeit wurde in [Bouzouraa 2010] ein Vergleich zwischen dem HEBF-Algorithmus und den Abtastlinien-Algorithmen (*Scan Line-Algorithmen*)

aus der Computergrafik [9] hinsichtlich der Rechenzeit durchgeführt. Die im Mittel gemessene Berechnungszeit für eine 140m x 140m große Karte mit 20cm Zellauflösung beträgt bei dem HEBF-Algorithmus 4.4 ms. Eine Implementierung mit Hilfe des standard Scanline-Algorithmus dauert hingegen im Mittel 30ms. Die Messungen wurden auf einem *Intel Centrino Core 2 Duo* Laptop mit 2.2 GHz Taktfrequenz durchgeführt.

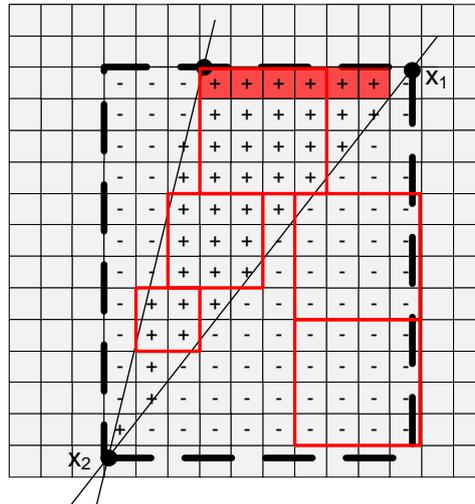


Abbildung 4.10: Effizientes Befüllen von gerasterten Dreiecken

Berücksichtigung der Segment-Informationen

Die Umrisse vieler der relevanten Hindernisse (Fahrzeuge, Seitenbegrenzungen, Gebäude,...) für Assistenzsysteme können durch lineare Segmente beschrieben werden. Deshalb werden die Laser-Reflexionspunkte im Segmentierungsschritt (s. Abschnitt 4.1.3) unter Berücksichtigung der Strahldivergenz zu Segmenten transformiert. Anschließend werden die Gruppen von Messungen markiert, die mit Hilfe eines linearen Segments gut beschrieben werden. Dieses Vorwissen wird dazu genutzt, die Belegungsinformation auf dem Belegungsgrid entlang der Verbindungslinie eingetragen, zu der zwei benachbarte Reflexionspunkte angehören. Vor allem bei parallelen seitlichen Fahrbahnbegrenzungen wie Beton-Mauer oder Leitplanken führt die Methode zu einer deutlichen Verbesserung der Erfassung im Belegungsgrid.

Wie wichtig diese Sensormodellierungsmaßnahmen für Assistenzsysteme sind, zeigt Abbildung 4.11. Durch die bessere und frühe Erfassung einer langen Seitenbegrenzung, wie im rechten Teil der Abbildung zu sehen, kann das System zur aktiven Gefahrenbremsung die Kritikalität der Situation besser einschätzen und früher einen Bremsmanöver aufgrund der Unmöglichkeit eines Ausweichens einleiten.

Berücksichtigung der Amplituden-Plausibilisierung

Die Vorverarbeitung der Laserrohdaten anhand des Amplitudensignals 4.1.3 generiert für jeden Kanal i eine binäre Variable $p_{Amp,i} \in \{0, 1\}$. Diese hat den Wert 0, falls die Messung aufgrund

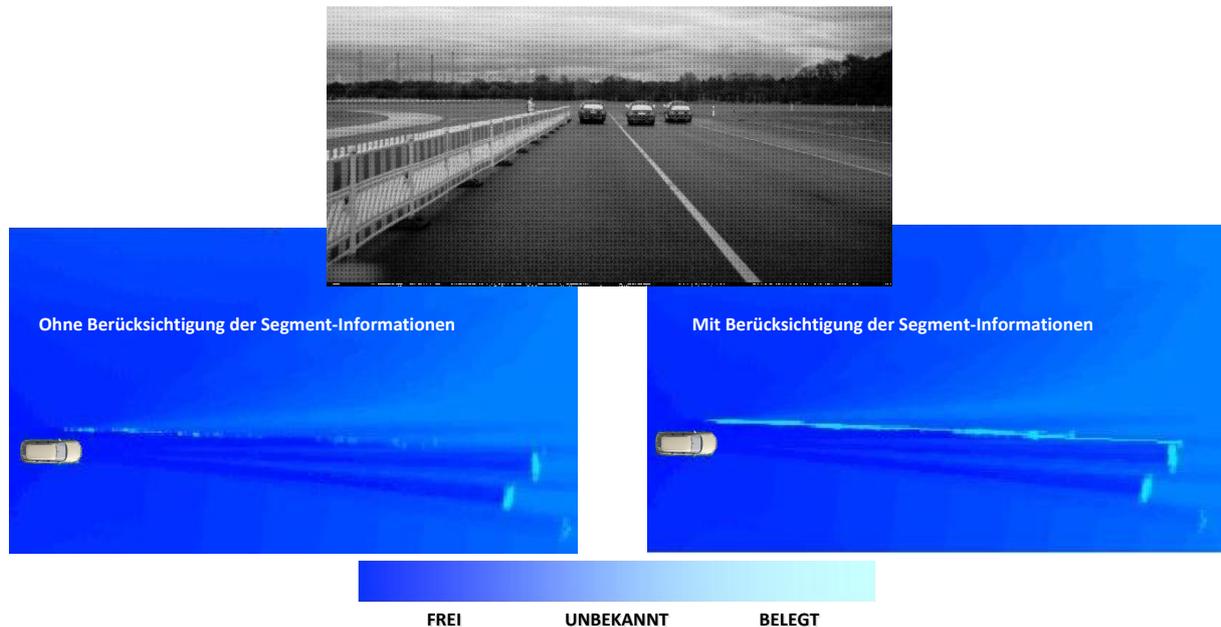


Abbildung 4.11: Verbesserte Randbebauungserfassung auf dem Belegungsgitter durch Berücksichtigung der Segment-Informationen

des Überstrahlungseffekts als nicht plausibel klassifiziert wurde. Das inverse Sensormodell nutzt dieses Vorwissen, um die Qualität des Belegungsgitters bei der Aktualisierung zu erhöhen. Wird eine Messung eines Kanals als unplausibel markiert, wird keine Belegt-Information auf dem Belegungsgitter eingetragen. Die Freirauminformation wird vom Sensorursprung bis zu einer Entfernung, die etwas größer als die unplausible Messung ist eingetragen. Dadurch werden die Breiten der Hindernisse genauer erfasst. Lücken zwischen Fahrzeugen und Randbebauungen können folglich aufgelöst werden. Die Auswirkung der Berücksichtigung der Amplituden-Plausibilisierung auf der Qualität des Belegungsgitters zeigt Abbildung 4.12.

4.1.5 Radarsensormodell für Belegungsgitter

Analog zum Laserscanner wurden in der Arbeit inverse Radarsensormodelle für Belegungsgitter entwickelt. Die Entwicklung des Radarsensormodells basiert auf die experimentellen Erkenntnisse aus der Analyse des Doppelradar-Systems in Kapitel 3.3.

Modellierung der Unsicherheit

Kern der Radarmodellierung für Belegungsgitter ist die Modellierung der Unsicherheiten in den Radarmessungen und deren Übertragung auf das Belegungsgitter. Im vorherigen Kapitel 3.3.2 wurde festgestellt, dass die Verteilung des Radar-Reflexionspunktes auf Fahrzeug-Hecks z.B. jeweils in x und y (im Sensor-Koordinatensystem) durch eine Gauß-Verteilung approximiert werden

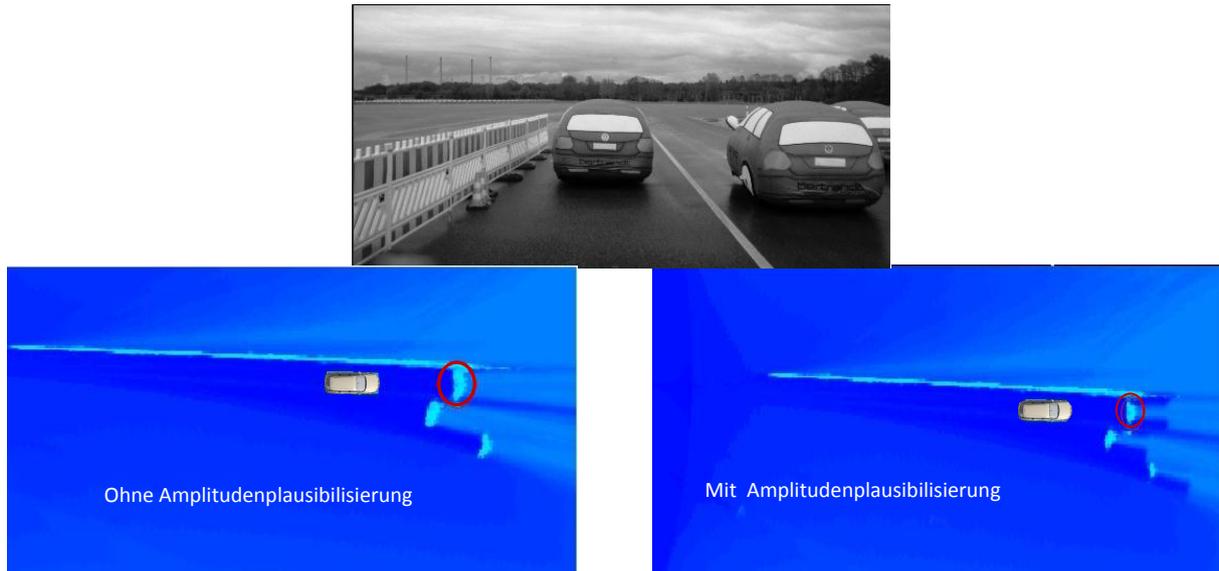


Abbildung 4.12: Verbesserung der Belegungskarte durch Berücksichtigung der Amplitudenplausibilisierung

kann. Außerdem sind die Fehler in x und y nach den experimentellen Ergebnissen voneinander unabhängig. Daher wird eine zweidimensionale Gauß-Verteilung (s. Abbildung 4.13(a)) verwendet, die diskretisiert und in die Ebene projiziert wird (s. Abbildung 4.13(b)). Es ergeben sich somit diskretisierte Unsicherheitsellipsen. Jede Zelle der Ellipse erhält einen Wahrscheinlichkeitswert, der für die Aktualisierung des Belegungskitters gemäß des Bayes-Satzes genutzt werden kann.

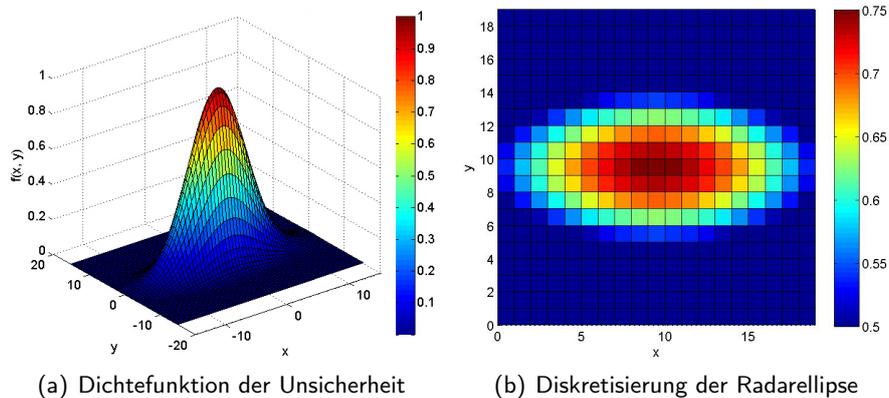


Abbildung 4.13: Modellierung der Radarunsicherheit

Da die eingesetzten Radar-Sensoren die Ausrichtung eines Objekts nicht messen können, liegen keine Informationen über die Orientierung der Radarobjekte vor. Aus diesem Grund wird die Ausrichtung einer Ellipse durch die Bewegungsrichtung des dazugehörigen Objektes angenähert. Aus den vom Radar-System gelieferten x - und y -Geschwindigkeitskomponenten im Sensorkoordinatensystem kann die Bewegungsrichtung eines Objektes berechnet werden. Bei stationären

Objekten richtet sich die Ausrichtung der Ellipse nach der Orientierung des Eigenfahrzeugs.

Die Diskretisierung einer zweidimensionalen Gaußverteilung und deren Rotation sind rechenintensive Vorgänge, die in jedem Zeitschritt und für jedes Objekt durchgeführt werden müssen. Um die Recheneffizienz der Umfeldkartierung zu gewährleisten, werden deshalb die Ellipsen offline berechnet und in sog. „Look Up Tables“ abgelegt. Dabei genügt eine Berechnung der Ellipsen für die Winkel zwischen 0 und 90°, da sich die Ellipsen für größere Winkel durch entsprechende Spiegelung der bereits berechneten Ellipsen ergeben. Es ist außerdem ausreichend, die Orientierung aus der Bewegungsrichtung in 10°-Schritten zu quantisieren und die Ellipsen entsprechend zu berechnen (s. Abbildung 4.14). Diese Maßnahmen reduzieren erheblich den Speicheraufwand.

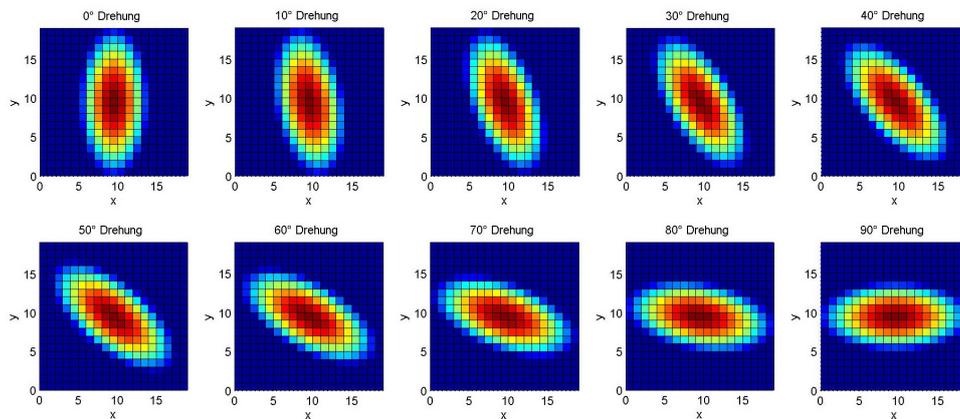


Abbildung 4.14: Generierte Ellipsen in 10° Schritten

Die Modellierung verschiedener Sensoreffekte erfordert den Einsatz verschiedener Verteilungen. Aus diesem Grund werden abhängig von der Objektklasse und der vorliegenden Fahrsituation verschiedene Ellipsen generiert und im Speicher hinterlegt. Im online Betrieb schaltet das Sensormodell abhängig von der vom Sensor gelieferten Objekt-Klasse und der erkannten Situation zwischen den verschiedenen Verteilungen. Folgende Ellipsenvarianten (s. Abbildung 4.15) werden verwendet:

- Ellipse für bewegte PKWs
- Ellipse für hochdynamische Objekte (hohe relative Geschwindigkeit bzw. Beschleunigung)
- Ellipse für stationäre Objekte
- Ellipse zur Modellierung von Leitplanken
- Ellipse zur Modellierung von LKWs

Leitplankenmodellierung

Randbebauungen und speziell Leitplanken auf Autobahnen stellen eine wichtige Hindernisklasse für die Assistenzfunktionen Stauassistent und Aktive Gefahrenbremsung dar. Im Abschnitt

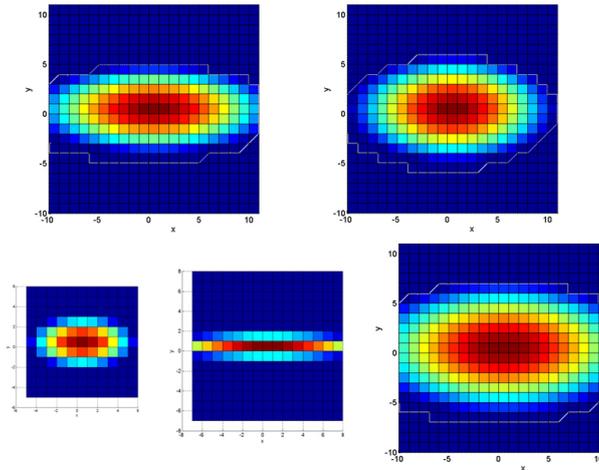


Abbildung 4.15: Ellipsen-Varianten (von links oben: dynamisch, hochdynamisch; von links unten: statisch, Leitplanke, LKW)

3.3.5 vom Kapitel 3.3.5 wurde bereits festgestellt, dass der Radar die Leitplanke als eine Vielzahl entlang des Verlaufs liegender stationärer Objekte erfasst. Die ermittelten lateralen Radar-Unsicherheiten für PKWs sind auf Leitplanken nicht übertragbar, denn diese stellen keine in der Breite ausgedehnten Objekte dar. Die experimentelle Analyse der Leitplankenerfassung hat zudem gezeigt, dass der laterale Fehler bzw. Unsicherheit geringer als bei der Erfassung von PKWs ist. Dies liegt u.a. daran, dass die Leitplanken durch die sog. Sigma-Pfosten gut reflektierende und schmale Hindernisse für den Radar darstellen. Die Unsicherheiten bzw. Fehler in der Längsrichtung sind hingegen größer. Diese Tatsache ist dadurch zu erklären, dass die Radar-Reflexionsobjekte auf der in der Längs-Richtung ausgedehnte Schutzplanke schwanken.

Um diese Effekte möglichst gut in der Interpretation der Sensordaten miteinbeziehen zu lassen, wird in der Arbeit auf geeignete Fehlermodelle umgeschaltet, falls eine Leitplanke in der Umgebung des Fahrzeugs erkannt wird. Hierzu wird ein Algorithmus zur Leitplankenerkennung eingesetzt, mit Hilfe dessen die Wahrscheinlichkeit $p(p_s = \text{„Leitplanke vorhanden“})$ ermittelt wird. Diese Wahrscheinlichkeit fließt gemäß Gleichung 3.4 aus Kapitel 3 in der Sensormodellierung mit ein. Der Algorithmus zur Leitplankenerkennung arbeitet regelbasiert, indem folgende Bedingungen bewertet und verknüpft werden.

1. Die Objekte müssen stationär sein.
2. Die Objekte müssen in einer „*Region Of Interest*“ liegen. Dieser Aufmerksamkeitsbereich wird durch Seitenbereiche rechts und links vom Fahrzeug (s. Abbildung 4.16) definiert.
3. Die durch die beiden ersten Bedingungen vorgefilterten Radar-Objekte werden mit Hilfe eines Segmentierungsalgorithmus zu Linien-Segmenten zusammengefasst. Dabei wird überprüft, ob eine Segmentierung mit festgelegten Schwellen für folgende Parameter möglich ist.
 - Maximal erlaubter Abstand zwischen zwei benachbarten Objekten.
 - Maximale Entfernung der Objekte von der generierten Segment-Linie. Der mittlere

Fehler in der Regressionsrechnung kann für die Berechnung der Wahrscheinlichkeit für das Vorliegen einer Leitplanke verwendet werden. Ein kleiner Segmentierungsfehler deutet auf eine hohe Wahrscheinlichkeit für das Vorliegen einer Leitplanke in der Nähe des Fahrzeugs

- Mindestanzahl an Objekten, die ein Segment haben muss.
4. Die Steigung der aus der Segmentierung gewonnenen Linie muss unter einer bestimmten Schwelle liegen. Die Abweichung der Steigung zur Schwelle kann als zusätzliches Gewicht in der Leitplankenerkennung benutzt werden.

Der Algorithmus nutzt in seiner einfachen Variante nur Radardaten und basiert auf einer linearen Segmentierung. Er kann einfach um zusätzliche Leitplankenindikatoren und komplexere geometrische Modelle (gekrümmte Linien) erweitert werden. Für den Fall einer erkannten Leitplanke werden spezielle Unsicherheitsellipsen eingesetzt (s. Abbildung 4.15). Diese besitzen die gleiche Ausrichtung wie die erkannte Segment-Linie und sind durch eine höhere Unsicherheit entlang der Leitplankenlinie als in der orthogonalen Richtung gekennzeichnet. Es resultiert eine bessere Abbildung von Leitplanken im Belegungsgrid, wie in Abbildung 4.16(b) schematisch dargestellt ist.

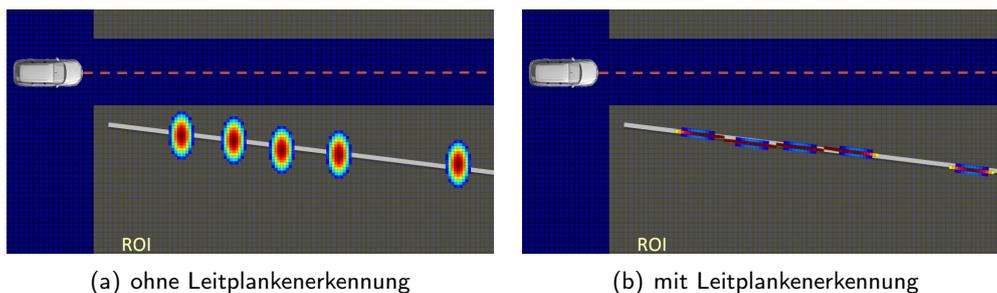


Abbildung 4.16: Auswirkung des Leitplankenalgorithmus auf eine Belegungskarte

Mit diesem Ansatz wird die Auswirkung der Umgebung auf dem Messvorgang des Sensors modelliert. Dadurch wird die Annahme der statistischen Unabhängigkeit der Zellen auf dem Belegungsgrid geschwächt. Denn die Zellen, die auf einer Leitplanke liegen, werden bei der Aktualisierung des Belegungsgrid als zusammenhängend betrachtet.

„L-Shape“-Modellierung

Mit „L-shape“ ist die Form eines Fahrzeugs gemeint, das sich mit zwei Kanten im Sichtbereich eines Umfeldsensors befindet. Ziel der „L-shape“-Modellierung ist die Herleitung einer solchen Form aus den Radardaten. Hierfür werden die segmentierten Laserdaten miteinbezogen, indem sie Radar-Objekten zugeordnet werden. Wird ein Lasersegment-Paar bestehend aus zwei orthogonalen Lasersegmenten mit einem Radar-Objekt assoziiert, wird die Unsicherheit der Radarmessung entlang der dazugehörigen Fahrzeugfläche interpretiert. Wird z.B. der Radar-Objekt mit einer Fahrzeug-Seitenfläche assoziiert, so wird die entsprechende bei der Sensordatenanalyse ermittelte Fehlerverteilung für die Aktualisierung des Belegungsgrid genommen. Außerdem

werden die Radar-Ellipsen entsprechend der Orientierung des Segment-Paares ausgerichtet. Darüber hinaus werden weitere Radar-Daten wie Geschwindigkeiten und Klassifikation auf die beiden Lasersegmente übertragen.

4.2 Modellbasierte Freiraumverfolgung

Trotz der erzielten Verbesserungen des Belegungsgitters im Hinblick auf die Rechenzeit und die Qualität der akkumulierten Daten, bleibt das Gitter eine speicher- und rechenintensive Repräsentationsform. Aufgrund des niedrigen Abstraktionsniveaus des Belegungsgitters wird außerdem ein Extraktionsschritt für die Generierung der relevanten Umfelddaten benötigt. Trotz dieser Nachteile stellt das Belegungsgitter eine sehr geeignete Repräsentation dar, um Freiräume in der Fahrzeugumgebung zu beschreiben. Es stellt sich die Frage nach der Möglichkeit einer kompakteren Freiraumkartierung als das Belegungsgitter, bei der die Assistenzfunktion früh den Datenverarbeitungsprozess in der Umfeldwahrnehmung steuert.

4.2.1 Grundidee und Systemarchitektur

Bei der Suche nach einer Alternative zum Belegungsgitter für die Beschreibung von Freiräumen kann die in Kapitel 2.3.1 erarbeitete Definition einer Belegungskarte Abhilfe schaffen. Dort wird der lokale Raum durch sogenannte Raumelemente mit Nachbarschaftsbeziehungen abgebildet. Gelingt es ein kompakteres geometrisches Modell für die Raumelemente zu finden, das mit den Umfeldsensoren beobachtbar ist, dann kann die Freirauminformation effizient dargestellt werden. Hierzu werden die einzelnen Freiraumelemente als Objekte der Klasse Freiraum interpretiert, so dass jedes Freiraumelement kompakt durch bestimmte Zustandsgrößen beschrieben werden kann. Hierfür werden analog zu den Hindernis-Objekten Form- und Dynamikmodelle benötigt, um die Zustände der Freiraumelemente zeitlich verfolgen zu können. Beim Freiraummodell hängt die zeitliche Entwicklung von der Bewegung des Eigenfahrzeugs und der Bewegung der Hindernisse ab, die den Freiraum begrenzen. Diese Idee stellt eine Kombination aus einer kartenbasierten Darstellung der Umgebung und einer objektbasierten Beschreibung dar, was bereits in der Einleitung als wichtiges Ziel der Arbeit definiert wurde. Der Freiraum wird mit Hilfe von Freiraumelementen abgebildet, die abstrakt als Objekte betrachtet werden. Die Freiraumelemente sind zusammenhängend und in einer bestimmten Reihenfolge strukturiert, wodurch die Navigation zwischen den Elementen erleichtert wird.

Das hier aufgezeigte Konzept zur modellbasierten Freiraumverfolgung wird prototypisch für Assistenzsysteme umgesetzt, die laterale Freiraumbegrenzungen benötigen wie z.B. ein Baustellenassistent oder ein Stauassistent. Es kann auf die Erfassung von belegten und unbekanntem Bereichen erweitert und an die Anforderungen weiterer Assistenzsysteme wie z.B. Sicherheitssysteme angepasst werden. Grundlagen dieses Konzeptes sind die Untersuchungen von [Schuster 2009] im Rahmen der vorliegenden Arbeit.

Der erste wichtige Schritt in der Entwicklung der Freiraumverfolgung besteht darin, die erforderlichen Form- und Dynamikmodelle für den Freiraum festzulegen. Ein gutes Freiraummodell sollte so einfach wie möglich und nur so komplex wie nötig sein. Die Berechnungskomplexität für die Schätzung der Modellparameter sowie für die Vorhersage der zeitlichen Entwicklung des

Freiraums müssen beherrschbar bleiben. Die Form des Freiraums kann auf sehr unterschiedliche Arten angenähert werden. Im Folgenden sind einige Beispiele aufgeführt:

- **Rechteck:** Das einfachste geometrische Modell für einen Freiraum ist ein Rechteck, dessen Unterkante an die Eigenfahrzeugfront angrenzt. Die seitlichen Begrenzungen des Freiraums bestimmen die rechte und linke Kanten des Rechtecks, während die maximale Freiraumbegrenzung in der Längsrichtung die obere Kante definiert. Die Parameter dieses einfachen Modells lassen sich sehr effizient berechnen. Allerdings kann diese rechteckige Beschreibung des Freiraums nur bedingt für Fahrerassistenzsysteme eingesetzt werden, da sie nur eine linke und rechte Freiraumbegrenzung des Freiraums zulässt. Außerdem ist diese Beschreibung wenig aussagekräftig bei Kurvenfahrten.
- **Kurven:** Die Modellierung eines relativ beliebig geformten Freiraums kann über Methoden des *Active Contour Trackings* [3] erfolgen. Dabei wird der Freiraum über eine Kurve beschrieben, die beispielsweise durch *B-Splines (Snake Model)* [95], *Level-Sets* [75] oder *Active Rays* [19] dargestellt wird. Diese Methoden stammen aus der Bildverarbeitung und werden zur echtzeitfähigen Verfolgung von Objekten in Bildern verwendet [3]. Die Schätzung der Kurvenparameter anhand von Sensormessungen sowie die Prädiktion der Kurvenbeschreibung aufgrund der Bewegung des Eigenfahrzeugs und der Veränderungen in der Fahrzeugumgebung kann allerdings relativ rechenaufwendig werden.
- **Polygonzug:** Eine einfachere Modellierung des Freiraums mit weniger Parametern besteht darin, die Freiraumgrenzen durch einen Polygonzug anzunähern. Dadurch bleibt die Dimension des Zustandsraumes klein und die Extraktion der Freiraumbeschreibung gestaltet sich einfacher. Allerdings ist die Genauigkeit niedriger als bei einer Kurvenbeschreibung.
- **Intervalle:** Eine weitere Abstraktion des Freiraums stellt eine Modellierung über mehrere Intervalle oder Rechtecke dar, deren Anzahl, Breiten und Gesamthöhe variabel sind (s. Abbildung 4.17). Sie ermöglicht eine effiziente Implementierung der Verfolgungsalgorithmen und bietet bei entsprechend großer Anzahl von Intervallen trotzdem eine ausreichend hohe Genauigkeit. In dieser Arbeit wird ein Ansatz verfolgt, der auf äquidistanten Intervallen in der Längsrichtung basiert. Auf die genaue Beschreibung des Modells wird im nächsten Abschnitt eingegangen.

4.2.2 Intervallbasiertes Freiraummodell

Die intervallbasierte Freiraummodellierung beruht auf einer Diskretisierung des Raums in der Längsrichtung und einer kontinuierlichen Erfassung der lateralen Freiraumbegrenzungen. Die Beschreibung besteht aus einer Menge zusammenhängender Intervalle. Die maximale Anzahl N_{max} an Intervallen ist während der Verfolgung fest, die aktuelle Anzahl N hängt von der Distanz zum ersten, direkt vor dem Fahrzeug liegenden, Hindernis ab. Das Modell des Freiraums ist in Abbildung 4.17 graphisch dargestellt. Es lässt sich durch den folgenden Zustandsvektor

mit $(6 \cdot N_{max} + 2)$ Parametern beschreiben:

$$\mathbf{x} = \begin{pmatrix} \mathbf{x}_0 \\ \vdots \\ \mathbf{x}_i \\ \vdots \\ \mathbf{x}_{N_{max}} \\ x_{Top} \\ vx_{Top} \end{pmatrix}, \mathbf{x}_i = \begin{pmatrix} y_{L,i} \\ vy_{L,i} \\ vx_{L,i} \\ y_{R,i} \\ vy_{R,i} \\ vx_{R,i} \end{pmatrix} \quad (4.2)$$

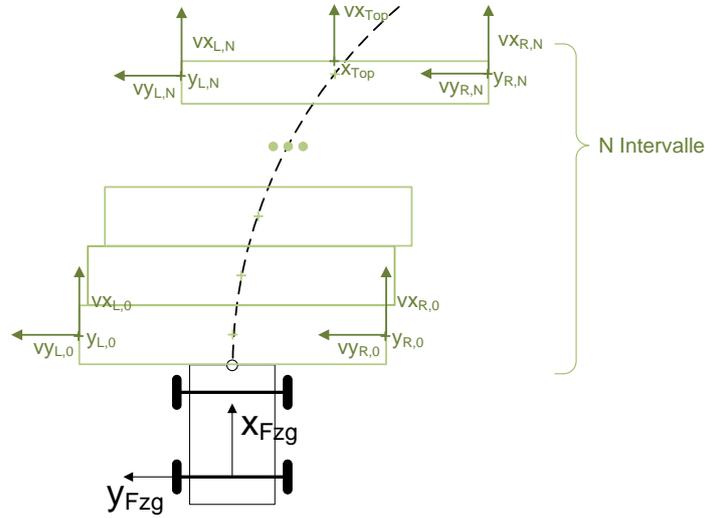


Abbildung 4.17: Freiraummodell mit äquidistanten Intervallen

Für jedes Intervall i haben die Parameter folgende Bedeutungen:

- $y_{L,i}, y_{R,i}$: Linke und Rechte Intervallgrenzen, definieren die Breite des Freiraumintervalls.
- $vy_{L,i}, vy_{R,i}$: Relative Geschwindigkeiten in y -Richtung an den Intervallseiten.
- $vx_{L,i}, vx_{R,i}$: Relative Geschwindigkeiten in x -Richtung an den Intervallseiten.

Die globalen Parameter x_{Top} und vx_{Top} bezeichnen respektive die x -Koordinate der vordersten Freiraumgrenze und die relative Geschwindigkeit in x -Richtung an der Mitte des vorderen Intervalls. Da bis auf das vorderste alle Intervalle eine feste Länge besitzen, ist durch x_{Top} implizit auch die aktuelle Anzahl an Intervallen N gegeben. Die Länge des vordersten Intervalls kann aus x_{Top} berechnet werden.

Die Mittelpunkte der Intervalle liegen immer auf der aktuellen Fahrzeug-Trajektorie (in Abbildung 4.17 schwarz gestrichelt), die aus dem Lenkwinkel und Gierrate sich berechnen lässt. Folglich werden ausgehend von der Fahrzeugtrajektorie die Intervallgrenzen gesucht. Da y_L und y_R unabhängig voneinander gesucht werden, sind die gefundenen Intervalle im Allgemeinen nicht

symmetrisch bzgl. der Trajektorie. Weitere Möglichkeiten für die Steuerung der Freiraumsuche sind die Nutzung der Informationen aus der Fahrstreifenmarkierungserfassung oder die Durchführung einer einfachen linearen Suche vor dem Fahrzeug. Denkbar ist auch eine gezielte Steuerung der Ressourcen (Speicher und Rechen-Ressourcen), indem z.B. Intervalle im Nahbereich mit einer feinen x -Auflösung und im Fernbereich mit einer groben Auflösung verwendet werden oder, indem eine geschwindigkeitsabhängige Diskretisierung der Intervalle eingeführt wird. Im Allgemeinen kann hier das zu untersuchende Gebiet und die Parameter des Freiraummodells von der Assistenzfunktion vorgegeben werden.

4.2.3 Kompensation der Eigenbewegung

Wie beim Belegungsgrid spielt bei der Freiraumverfolgung die Kompensation der Eigenbewegung eine wichtige Rolle in der Generierung von konsistenten Freiraumdaten. Die Modellierung des Freiraums erfolgt relativ zum Fahrzeug d.h. alle Koordinaten und Geschwindigkeiten sind relative Größen. Da das Fahrzeug selber sich bewegt, verändert sich das Bezugssystem ständig. Die Freiräume selbst sind ortsfest, daher ist eine Kompensation der Eigenbewegung notwendig. Diese findet zunächst in x -Richtung statt. Hierfür wird fortlaufend die aktuelle genaue Position des Fahrzeugs in x -Richtung innerhalb des ersten Intervalls gespeichert. Sobald dieses nach vorne verlassen wird, wird das Intervall gelöscht, alle nachfolgenden Intervalle werden verschoben und am vorderen Ende des Freiraumes wird ein neues eingefügt. Dieses Verfahren ist in Abbildung 4.18 dargestellt, x_{Pos} bezeichnet dabei die aktuelle Position des Fahrzeugs in x -Richtung innerhalb des Freiraumes.

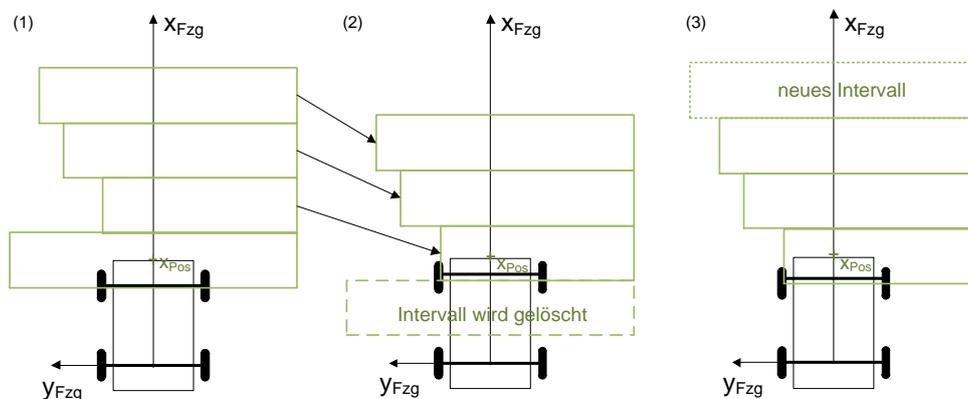


Abbildung 4.18: Ortsfeste Freiraum-Modellierung durch Kompensation der Vorwärtsbewegung:
 (1) Initial: x -Position in Intervallmitte (2) Vorwärtsbewegung: x -Position im zweiten Intervall und Verschiebung der Intervalle (3) Initialisierung eines neuen Intervalls

Neben der Kompensation der linearen Bewegung in x -Richtung ist auch ein Ausgleich der Rotationsbewegung des Fahrzeugs zwischen zwei Schritten erforderlich. Dabei werden die Intervalle und ihre Zustandsgrößen um den Winkel $\Delta\psi$ gedreht (siehe Abbildung 4.19). Um die aufwendigen trigonometrischen Operationen zu sparen, kann die Rotation auf eine lineare Verschiebung

der Intervalle in y -Richtung zurückgeführt werden. Der durch diese Annäherung verursachte Fehler bleibt klein bei Fahrscenarien mit geringer Gierwinkeländerung wie z.B. Autobahnfahrten und kann durch das Prädiktionsrauschen des Schätzfilters abgefangen werden.

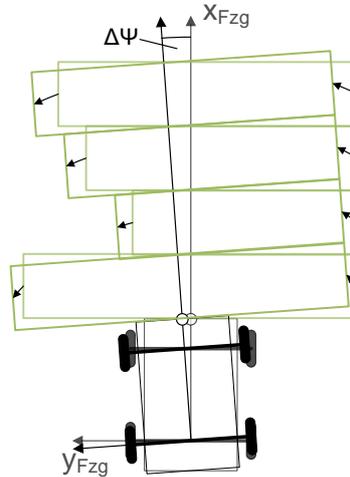


Abbildung 4.19: Kompensation der Fahrzeug-Gierbewegung

4.2.4 Freiraumextraktion aus Laserrohdaten

Die Aufgabe der Freiraumextraktion besteht darin, die Zustandsgrößen des Freiraummodells aus Laserrohdaten zu extrahieren. Die extrahierten Zustandsdaten werden dann als Messungen in das verwendete Filter eingespeist. Wie beim Belegunggitter werden die Laserkanäle als Kreissektoren mit einer Winkelbreite α modelliert. Jeder schmale Kreissektor kann als Vereinfachung durch ein Dreieck angenähert werden. Die Hindernisinformation wird somit entlang der kurzen Dreiecksseite interpretiert. Der hinter dem Hindernis liegende Bereich wird als unbekannt betrachtet. Die durch das Dreieck definierte Fläche gilt hingegen als frei.

Die Extraktion beginnt mit der Bestimmung der vorderen Begrenzung x_{Top} . Hierzu wird das nächste Hindernis in x -Richtung innerhalb eines Schlauchs um die aktuelle Trajektorie gesucht. In einem zweiten Schritt werden die seitlichen Intervallgrenzen $y_{L/R}$ extrahiert. Dies entspricht der Bestimmung des Schnitts der in Abbildung 4.20 als rot schraffierten dargestellten Bereiche mit den Freiraumrechtecken. Die rot schraffierten Bereiche repräsentieren die aus einer Messung extrahierten belegt, und unbekannt- Informationen. Im allgemeinen Fall wäre für die Schnittberechnung der Einsatz eines Algorithmus unter Verwendung des *Separating Axes Theorem (SAT)* zum Schnitt beliebiger Polygone denkbar. Dieser Ansatz wird häufig zur Kollisionserkennung benutzt und ist in [21] genauer beschrieben. In der vorliegenden Arbeit kommt allerdings ein eigener optimierter Algorithmus zum Einsatz, der auf die hier vorkommenden Formen und Ausrichtungen zugeschnitten ist und nur die benötigten Ergebnisse (die seitlichen Intervallgrenzen) berechnet. Dabei wird zwischen den fünf in Abbildung 4.20 dargestellten Fällen differenziert.

Die Unterscheidung erfolgt anhand der Lage der kurzen Dreiecksseite des Lasersektors (jeweils für die linke Begrenzung): In (1) schneidet sie die obere Intervallbegrenzung, in (2) liegt sie mitten

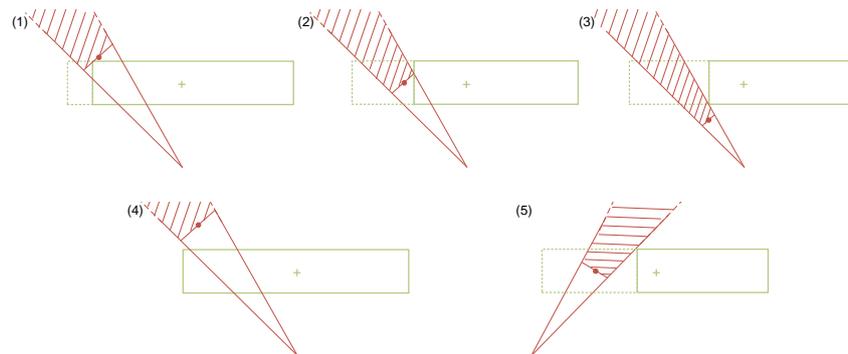


Abbildung 4.20: Freiraumextraktion: Schnitt Lasersektor (rot) mit Freiraum-Intervall (grün)

im Intervall und bei (3) unterhalb des Intervalls. Wenn sie die untere Intervallgrenze schneidet, wird es wie Fall (2) gehandhabt. Liegt dagegen, wie bei (4), die kurze Dreiecksseite komplett oberhalb des Intervalls, gilt dieses als frei. Durch die Anpassung der Intervalle an die Trajektorie kann es vorkommen, dass auch von links nach rechts verlaufende Laserstrahlen die linke Intervallhälfte schneiden. Dies entspricht der Darstellung in (5). Dasselbe Verfahren wird analog, mit einigen Vorzeichenänderungen, auch für die rechte Freiraumbegrenzung verwendet. Zusätzlich werden die Unsicherheiten der Entfernungsmessungen in Unsicherheiten für die Intervallgrenzen umgerechnet. Um trotz der teilweise aufwändigen Berechnungen die Rechenzeit zu reduzieren, werden räumlich irrelevante Messdaten möglichst früh im Verarbeitungsprozess aussortiert.

Zur besseren Erfassung vertikal verlaufender Hindernisbegrenzungen, werden wie beim Belegsgitter die Lasermesspunkte verkettet. Dabei wird das in Abschnitt 4.1.3 beschriebene Segmentierungsverfahren eingesetzt. Gehören die Messpunkte zu einem zusammenhängenden Verlauf, wird die Verbindungslinie zwischen den Messpunkten als Begrenzung für den Freiraum betrachtet.

4.2.5 Freiraumextraktion aus Radardaten

Die Messungen des Radarsensors werden zum einen für die Geschwindigkeiten an den Freiraumgrenzen herangezogen, zum anderen begrenzen die punktförmigen Radarobjekte auch direkt den Freiraum. Für die Interpretation der Radardaten werden analog zum Belegsgitter die in der Sensoranalyse ermittelten Unsicherheiten miteinbezogen. In Abbildung 4.21 ist eine Radar-Objektmessung als blauer Punkt mit v_x und v_y -Geschwindigkeitsvektoren dargestellt. Die gemessene Position, als Punkt interpretiert, begrenzt den Freiraum. Die gemessenen Relativgeschwindigkeiten werden dem angrenzenden Freiraum-Intervall zugeordnet (grüne Vektorpfeile).

4.2.6 Kalman-Filterung

Für die Schätzung der Freiraumzustände wird ein Kalman-Filter eingesetzt. Die Assoziation der Messungen zu den Freiraumobjekten geschieht über die räumliche Zuordnung. D.h. Messungen, die auf ein bestimmtes Freiraumintervall fallen, werden dazu genommen, seinen Zustandsvektor

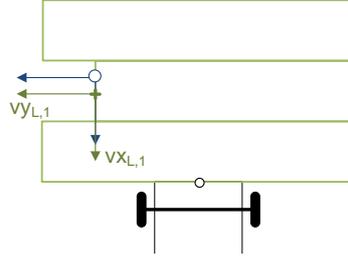


Abbildung 4.21: Freiraumbegrenzung durch Radarmessung (blau)

zu korrigieren. Um eine hohe Recheneffizienz zu erreichen, wird der Zustandsvektor des gesamten Freiraums in einzelne kleinere Vektoren $\mathbf{x}_{i,L/R} = (y_{i,L/R} \ vy_{i,L/R} \ vx_{i,L/R})^T$ aufgeteilt, deren Zustände getrennt gefiltert werden. Zusätzlich wird die vordere Freiraumgrenze $\mathbf{x}_{Top} = (x_{Top} \ x_{Top})^T$ verfolgt. Das eingesetzte Kalman-Filter besteht im wesentlichen aus einer direkten Umsetzung der Filtergleichungen aus Kapitel C.4 für jedes Fragment des Freiraumzustands $\mathbf{x}_{i,L/R}$. Für eine beliebige Freiraumseite mit dem Index i werden folgende Matrizen bei der Verarbeitung einer Messung $\mathbf{y}_{i,k} = (y_{i,k,L/R} \ vy_{i,k,L/R} \ vx_{i,k,L/R})^T$ z.B. aus dem Radar verwendet.

$$A = \begin{pmatrix} 1 & \Delta T & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} \quad C_{VV} = \begin{pmatrix} q_y & 0 & 0 \\ 0 & q_{vy} & 0 \\ 0 & 0 & q_{vx} \end{pmatrix} \quad H = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} \quad C_{NN} = \begin{pmatrix} \sigma_y & 0 & 0 \\ 0 & \sigma_{vy} & 0 \\ 0 & 0 & \sigma_{vx} \end{pmatrix} \quad (4.3)$$

Die Systemmatrix A stellt eine einfache Bewegung mit konstanter Geschwindigkeit dar. q_y , q_{vy} und q_{vx} sind die im Bewegungsmodell verwendeten Varianzen. σ_y , σ_{vy} und σ_{vx} bezeichnen die Messvarianzen. Die Initialisierung der Kalman-Filter erfolgt anhand der ersten eintreffenden Messung.

Da bei dem hier gewählten Freiraummodell die Dimension der einzelnen Zustandsvektor-Fragmente fest ist, hängt die Laufzeitkomplexität der Freiraumverfolgung nur linear von der Anzahl der Intervalle N_{max} ab, sie liegt damit in der Komplexitätsklasse $O(N_{max})$. Unter der Voraussetzung, dass die Messungen parallel vorliegen, kann außerdem die Kalman-Filterung durch die Zerlegung des Zustandsvektors in unabhängige Teile parallelisiert und somit die Rechenzeit signifikant reduziert werden.

4.2.7 Ergebnisse

In diesem Abschnitt werden einige Ergebnisse aus der Freiraumverfolgung präsentiert. Abbildung 4.22 zeigt drei Schnappschüsse (1), (2) und (3) einer Stadtdurchfahrt, die in einem Abstand von jeweils 1s aufgenommen wurden. Der linke Teil der Abbildung enthält Erläuterungen zu der verwendeten Visualisierung der Freiraumintervalle und deren Zustände. Der Freiraum ist bei dieser Fahrt $10 \text{ m} \times 30 \text{ m}$ groß und ist durch maximal 20 Intervalle modelliert.

Das System ist in der Lage die Grenzen der Freiräume in einer dynamischen Szene mit unterschiedlichen Hindernisklassen zu verfolgen. Im Teilbild (3) ist zu erkennen, dass der Laserscanner das entgegenkommende Fahrzeug Nr.(4) nicht erfasst hat. Durch die Fusion mit dem

4. 2D kartenbasierte Umfeldwahrnehmung

Radarsensor und die Nutzung der Historie können diese Schwächen kompensiert werden. Die vx -Geschwindigkeitsvektoren der stationären Hindernisse entsprechen der Geschwindigkeit des Eigenfahrzeugs mit umgekehrtem Vorzeichen, da hier nur relative Geschwindigkeiten modelliert werden.

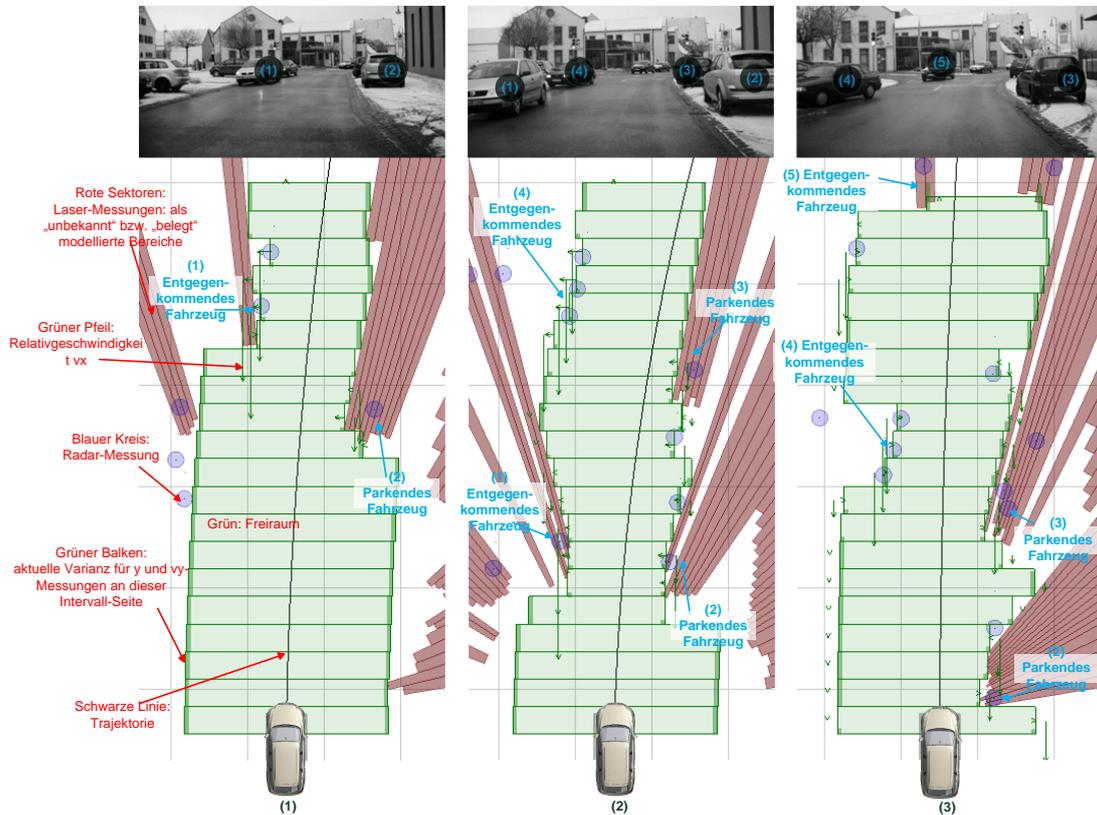


Abbildung 4.22: Zeitliche Entwicklung des Freiraums bei einer Ortsdurchfahrt

Beachtung der Fahrzeugtrajektorie

Ein wichtiger Aspekt bei der Modellierung des Freiraums ist die Steuerung der Freiraumsuche. In dieser Arbeit wird eine aus Lenkradwinkel und Gierrate berechneten Trajektorie dazu genutzt, die Mittelpunkte der Freiraumintervalle zu bestimmen. Diese Suchstrategie ermöglicht die Erfassung des Freiraums im relevanten Teil der Umgebung. Im rechten Teil der Abbildung 4.23 ist der Freiraum unter Berücksichtigung der, als schwarze Kurve dargestellten, Trajektorie zu sehen. Die linke Hälfte hingegen zeigt den Freiraum in der selben Fahrsituation ohne Beachtung der Fahrzeugtrajektorie. Wie zu erkennen ist, ermöglicht die Verschiebung der Intervall-Mittelpunkte entlang der Fahrzeugtrajektorie schon bei kleinen Kurvenradien eine sinnvolle Anordnung der Freiraumintervalle. Daraus resultiert eine vorausschauende Freiraumerfassung im Raum-Bereich, der für die nahe Zukunft der Fahrt (die nächsten Sekunden) voraussichtlich relevant sein wird.

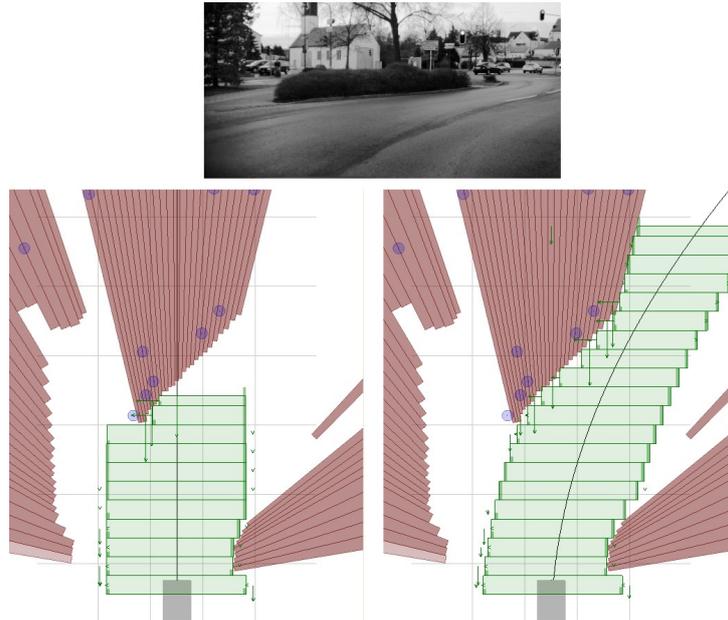


Abbildung 4.23: Freiraumverfolgung mit Berücksichtigung der Fahrzeugtrajektorie (rechts) und ohne (links)

Rechenzeit

Für die Bewertung der Recheneffizienz der Freiraumverfolgung wurden statistische Messungen der Verarbeitungszeit durchgeführt. Diese beinhalten die Eigenbewegungskompensation, die Freiraumextraktion und die Zustandsschätzung. Diese Zeiten sind in der nachfolgenden Tabelle 4.2.7 für verschiedene Fahrscenarien und Größen des Freiraums aufgetragen. Die angegebenen Werte sind die Mittelwerte aus jeweils drei Testdurchläufen, deren Ergebnis wiederum aus je 800 Zeitmessungen gemittelt wurde, das entspricht jeweils ca. 48 s einer aufgezeichneten Testfahrt. Die gemessenen Daten bestätigen, dass die Laufzeit linear mit der Anzahl der Intervalle skaliert ist. Außerdem erhöht sich die Rechenzeit bei Stadtszenarien aufgrund der Komplexität der Umgebung. Die Messungen erfolgten auf einem *Intel Centrino Core 2 Duo* Laptop mit 2.2 GHz Taktfrequenz.

4.3 Vergleich und Erkenntnisse

In diesem Abschnitt soll eine Gegenüberstellung des Belegungsgitters mit der intervallbasierten Freiraumerfassung kurz diskutiert werden. Hinsichtlich des Informationsgehaltes stellt das Belegungsgitter eine detailreiche Repräsentation dar, die Informationen über freie, belegte und unbekannte Bereiche enthält. Die intervallbasierte Freiraumverfolgung hingegen kann nur den Freiraum und seine Grenzen beschreiben. Was die Genauigkeit der enthaltenen Daten betrifft, kann diese beim Belegungsgitter sehr hoch sein, falls die Auflösung des Gitters entsprechend gewählt wird. Mit der intervallbasierten Freiraumerfassung kann auch eine sehr hohe laterale

Größe des Freiraums	Fahrscenario	Rechenzeit
20 Intervalle (10 m × 30 m)	Stadt	0.62 ms
	Landstraße	0.58 ms
20 Intervalle (20 m × 60 m)	Stadt	0.74 ms
	Landstraße	0.66 ms
40 Intervalle (20 m × 60 m)	Stadt	1.1 ms
	Landstraße	0.92 ms

Tabelle 4.1: Benötigte Rechenzeit in Abhängigkeit von der Anzahl der Freiraumintervalle und des Fahrzenarios

Genauigkeit erreicht werden, da hier keine Diskretisierung vorhanden ist. Aufgrund der groben Quantisierung in der Längsrichtung bleibt die Genauigkeit in dieser Richtung aber eingeschränkt. Bezüglich der Rechenzeit und des Speicheraufwandes gibt es hier eindeutige Vorteile für die intervallbasierte Freiraumverfolgung. Bei der Nutzung für Fahrerassistenzsysteme ist das Belegungsgitter eine universellere Umfeldrepräsentation. Denn aufgrund der eingeführten Annahmen und funktionspezifischen Steuerung in der Freiraumverfolgung ist diese Repräsentation nur für eine bestimmte Klasse von Fahrerassistenzsystemen geeignet. Schließlich ist die Interpretation des Belegungsgitters wesentlich schwieriger als die Interpretation der Freiraum-Intervallstruktur. Beim Belegungsgitter bedarf in der Regel eines Extraktionsschrittes, der relevante Umfeldinformationen wie Freiraum oder Fahrbahnbegrenzung extrahiert. Bei der Freiraumverfolgung können die relevanten Daten direkt von der Datenstruktur abgeleitet werden, da die Umfeldinformationen kompakt und relativ zum Eigenfahrzeug hinterlegt sind. Die Vor- und Nachteile der beiden Repräsentationen sind in Tabelle 4.2 zusammengefasst.

	Belegungsgitter	Freiraumverfolgung
Informationsgehalt	++	--
Genauigkeit	+	++ (Quer), - (Längs)
Rechenzeit	--	++
Interpretierbarkeit	-	+
Nutzung für verschiedene FAS-Systeme	++	-
Speicheraufwand	--	++

Tabelle 4.2: Vergleich zwischen der gitterbasierten Umfeldkarte und der intervallbasierten Freiraumverfolgung hinsichtlich verschiedener Kriterien

5 3D kartenbasierte Umfeldwahrnehmung

5.1 Motivation und Konzept

Die zweidimensionalen Methoden der Belegungsgitter und der modellbasierten Freiraumverfolgung sind trotz ihrer Robustheit und Genauigkeit eingeschränkt bezüglich der Klassifikation der Hindernisse hinsichtlich ihrer Über- und Unterfahrbarkeit. Gerade diese Informationen eröffnen Möglichkeiten für neue Fahrerassistenzsysteme. So kann der Stauassistent durch die Erkennung kleiner nicht überfahrbarer Hindernisse ein automatisches Ausweichmanöver im eigenen Fahrstreifen einleiten. Außerdem ermöglicht die Erfassung in der Höhe ausgedehnte Objekte die Unterfahrbarkeitskontrolle z.B. in einem Parkhaus.

Ausgehend von den im Kapitel 4 näher beschriebenen Vorarbeiten und basierend auf dem *Ibeo Lux*-Sensor und dem 3D Laser-Sensor (s. Abschnitt 2.1.3) besteht das Ziel der dreidimensionalen kartenbasierten Umfeldwahrnehmung in der Entwicklung von Konzepten zur räumlichen Umfeldkartierung und deren prototypischen Umsetzung. Einige der in diesem Kapitel vorgestellten Methoden sind im Rahmen der vorliegenden Arbeit in [Rauch 2009] entstanden. Auf dem Weg zu einer dreidimensionalen Belegungskarte mit Bayes-Aktualisierung der Belegungswerte werden zwei weitere Möglichkeiten der räumlichen Kartierung vorgestellt. Die erste Möglichkeit besteht aus einer Höhenkarte mit einer Multi-Hypothesen Verwaltung für die Höhe in einer Zelle. Diese Art von Höhenkarte stellt eine Erweiterung der im Stand der Technik bisher publizierten Ansätze dar (s. Kapitel 1.2) und bietet Vorteile in ihrem Konvergenzverhalten. Ein nächster Schritt ist die Erweiterung dieser Höhenkarte zu einer dreidimensionalen Intervallkarte. Diese Intervallkarte beruht immer noch auf einer zweidimensionalen Gitterstruktur. Anders als bei den in Kapitel 1.2 erwähnten *Multi-Level Surface Maps* sollen hier aber nicht nur mehrere Höhenwerte, sondern mehrere belegte Intervalle pro Zelle gespeichert werden können. Dadurch können komplexere Umgebungsstrukturen als bei der Höhenkarte richtig erfasst werden, ohne dabei die Grund-Struktur des Belegungsgitters aufzugeben. Als letzte Kartierungsmöglichkeit wird die in drei Dimensionen diskretisierte Belegungskarte präsentiert.

Grundlage einer genauen und robusten dreidimensionalen Umfeldkartierung ist die Erkennung von Messpunkten, die auf die Bodenebene fallen. Mit dem Wissen über die Lage der Fahrbahnebene können die relevanten Messungen markiert werden. Aus diesem Grund präsentiert der erste Abschnitt dieses Kapitels einen Algorithmus zur Identifikation von 3D-Bodenpunkten als wichtiger Vorverarbeitungsschritt vor der Umfeldkartierung.

5.2 Erkennung der Bodenebene

Um Hindernisse hinsichtlich ihrer Über- oder Unterfahrbarkeit zu klassifizieren, muss deren korrekte Höhe bekannt sein. Die dafür ausschlaggebende Höhe ist die Höhe über Boden, im vorliegenden Fall also über der Fahrbahnoberfläche. Um diese Höhe korrekt zu detektieren, ist eine Erkennung bzw. Schätzung dieser Bodenebene unabdingbar. Abbildung 5.1 veranschaulicht diese Notwendigkeit. Bei gerader Fahrbahn ist das Hindernis in Abbildung 5.1 (a) ohne Weiteres erkennbar. Bei geneigter Fahrbahn wie in Abbildung 5.1 (b) kann das Hindernis jedoch nicht als relevant erfasst werden, falls die Fahrbahn als eben angenommen wird (angedeutet durch die gestrichelte Linie).

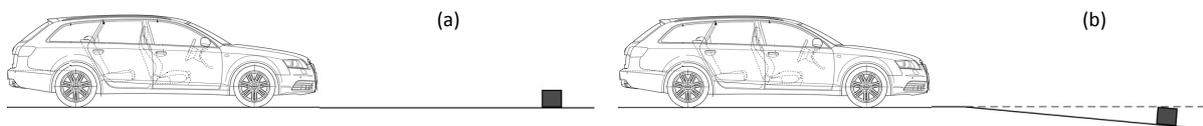


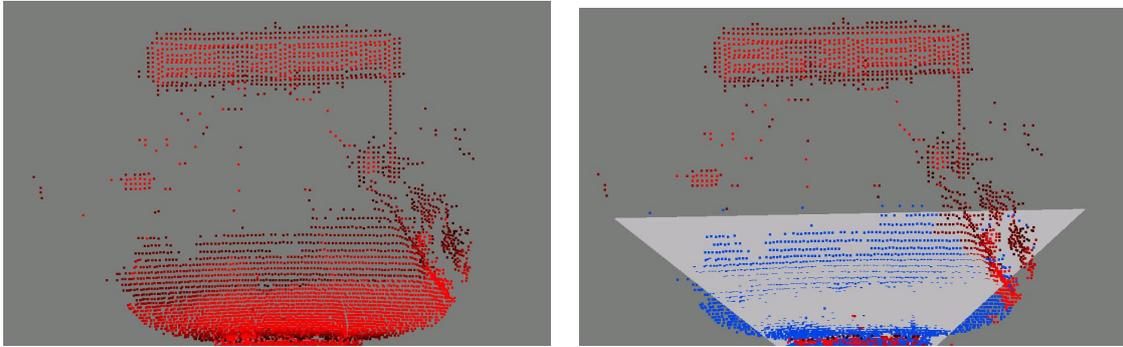
Abbildung 5.1: Notwendigkeit einer lokalen Fahrbahnebenenschätzung: Links kleines Hindernis bei ebener Fahrbahn, rechts kleines Hindernis bei geneigter Fahrbahn

Abbildung 5.2(a) zeigt beispielhaft eine 3D Punktwolke der vom 3D Laser-Sensor gelieferten Rohdaten aus Fahrzeugsicht. Dabei sind die Reflexionspunkte, die in den Rohdaten als Entfernung vorliegen, bereits anhand eines Sensormodells in das kartesische Sensorkoordinatensystem umgerechnet worden. Auf dem Sensormodell des 3D Sensors wird später im Abschnitt 5.4.2 eingegangen. In Abbildung 5.2(a) handelt es sich um Daten einer Autobahnfahrt. Zu erkennen ist die Fahrbahn direkt vor dem Auto, eine Schilderbrücke, sowie andere Fahrzeuge auf dem linken Fahrstreifen. Um die Bodenebene aus dieser 3D Punktwolke zuverlässig schätzen zu können, ist zuerst eine Klassifizierung der zur Bodenebene gehörigen Punkte notwendig. Die in dieser Arbeit verwendete Methode wurde in Anlehnung an dem Ansatz von [88] entwickelt.

Bei der Erkennung der Bodenpunkte werden die Messdaten punktweise verarbeitet. Dabei wird das vom 3D Laser-Sensor gelieferten und transformierten Distanzbild mit einer Auflösung von 128×128 Bildpunkten zeilenweise in einer zuvor festgelegten *Region Of Interest* von unten nach oben abgearbeitet. Für jeden Punkt wird hierbei die geometrische Position relativ zu den Punkten in seiner Nachbarschaft untersucht. Ausschlaggebend hierfür sind der vertikale Abstand zu den Nachbarpunkten, sowie der Winkel, den die Verbindungsgerade zwischen dem Punkt und einem Nachbarpunkt mit der horizontalen Ebene bildet. Überschreitet der vertikale Abstand der zwei Punkte eine Schwelle, die die minimale Höhe eines Hindernisses angibt, so wird der Winkel der Verbindungsgeraden zur horizontalen Ebene des Koordinatensystems berechnet. Überschreitet dieser Winkel einen Schwellwert, liegt der Nachbarpunkt also innerhalb eines gewissen Kegels unter- oder oberhalb des untersuchten Punktes, so werden beide Punkte als Hindernis klassifiziert. Die oben genannte Schwelle für den Winkel stellt einen maximalen Steigungswinkel dar, ab dem eine Oberfläche als nicht mehr befahrbar gilt, und wurde in dieser Arbeit zu 15° gewählt. Für die Schwelle des vertikalen Abstandes wurden 10 cm festgelegt.

Die am Ende der Untersuchung nicht als Hindernis klassifizierten Punkte gelten als Bodenpunkte und werden im Anschluss zur Schätzung der Bodenebene verwendet. Diese Schätzung geschieht mit Hilfe der Methode der kleinsten Fehlerquadrate. Abbildung 5.2(b) zeigt das Ergebnis einer

solchen Ebenenschätzung für die Rohdaten aus Abbildung 5.2(a). Dabei sind die zum Boden gehörig klassifizierten Punkte blau markiert. Die Ebenenschätzung ist als hellgraues Dreieck in die Grafik eingezeichnet.



(a) Sensorrohdaten als Basis für die Ebenenschätzung (b) Ebenenschätzung auf Basis der als Boden klassifizierten Punkte

Abbildung 5.2: Klassifikation der Bodenpunkte und Schätzung der Bodenebene

Entscheidend für die nachgeschaltete Höhekartierung sind die Hindernisse, die höher als die geschätzte Bodenebene sind. Daher gilt diese Ebene stets als lokale Bodenebene der entwickelten Höhen-Karten. Folglich findet vor der eigentlichen Kartierung eine Transformation der Sensordaten vom Sensorkoordinatensystem in das Kartenkoordinatensystem unter Berücksichtigung der Einbaulage des Sensors im Fahrzeug und der aktuellen Lage des Sensors relativ zur lokalen Bodenebene (Hub, Nick- und Wankwinkel) statt. Durch diese Transformationen gibt das Kartenkoordinatensystem die Lage und Höhe der eingetragenen Hindernisse entsprechend der jeweiligen geschätzten Bodenebene an. Abbildung 5.3 verdeutlicht grafisch den Unterschied zwischen der realen Welt und der Karte. Die roten Koordinatenkreuze an den Hindernissen symbolisieren die Ausrichtung der jeweiligen geschätzten Bodenebene.

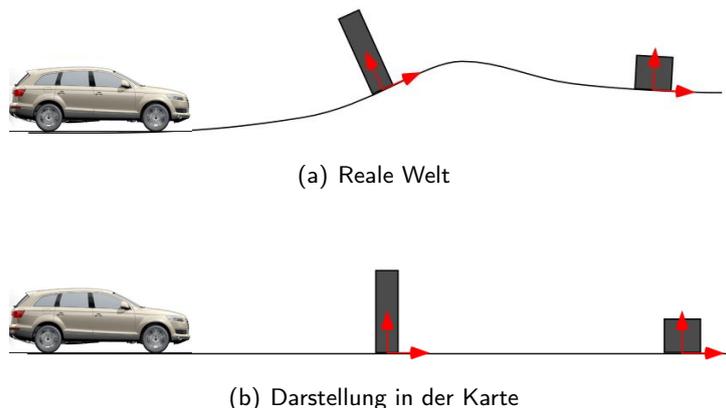


Abbildung 5.3: Unterschied zwischen realer Welt und Darstellung in der Karte

5.3 2.5D Belegungskarte

Dieser Abschnitt beschreibt eine kartenbasierte Umfeldrepräsentation, die im Gegensatz zu den weit verbreiteten zweidimensionalen Belegungskarten zusätzlich eine Höheninformation speichert und so eine Aussage über die Überfahrbarkeit von Hindernissen ermöglichen soll. In der Arbeit wurde ein neuer Multi-Hypothesen-Ansatz in Verbindung mit einer Kalman-Filterung für die Schätzung der Höhe entwickelt.

5.3.1 Grundidee und Datenstruktur

Die im Rahmen dieser Arbeit entwickelte und umgesetzte 2.5D Karte beruht auf der Datenstruktur des in Kapitel 4.1 behandelten Belegungsgitters. Dabei enthält jede Zelle der Gitter-Struktur eine Hypothesen-Verwaltung, die bis zu drei Höhen-Hypothesen aggregieren kann. Eine Hypothese besteht aus einer Annahme über die Höhe in der betroffenen Zelle und einem zugehörigen Kalman-Filter, das für die rekursive Schätzung des Höhen-Wertes mit Hilfe der Sensormessungen zuständig ist. Ausgegeben wird jeweils die Hypothese mit der aktuell geringsten Varianz. Sollte eine Hypothese durch die Sensormessungen geschwächt werden und ihre Varianz dadurch eine gewisse Schwelle überschreiten, so wird diese Hypothese gelöscht. Neue Zellen werden stets mit einer Hypothese der Höhe Null initialisiert.

Die Wahl fiel auf diesem Ansatz aus mehreren Gründen. Zum einen misst der Sensor aufgrund seines relativ schmalen vertikalen Öffnungswinkels (3.2 Grad) und aufgrund von weiteren Unsicherheiten nicht immer dieselben Objekte in der Höhe. Abbildung 5.4 illustriert z.B. die Annäherung des Eigenfahrzeugs auf zwei Hindernisse mit verschiedenen Höhen. Ab einer bestimmten Entfernung ist das höhere Hindernis für den Sensor nicht mehr sichtbar. Die Messungen müssen deswegen als zwei unterschiedliche Hypothesen behandelt werden. Sie dürfen nicht miteinander kombiniert werden, weil ansonsten bei einer einfachen Mittelwertbildung ein gemittelter Höhenwert entstehen würde, der die Realität nicht wiedergibt. Zum anderen kann ein hypothesenbasierter Ansatz mit abrupten Höhen-Änderungen und dynamischen Vorgängen in der vertikalen Richtung besser umgehen als eine einfache Mittelung der Höhenwerte wie z.B. in [43] der Fall ist. Schließlich bietet der Einsatz einer Kalman-Filterung in Verbindung mit einer Hypothesenverwaltung große Vorteile. Für jede Hypothese stellt das Kalman-Filter durch die Schätzvarianz ein statistisches Maß für die Verlässlichkeit der Höhen-Schätzung bereit. Außerdem bietet das Kalman-Filter die Möglichkeit der Prädiktion bereits erfasster Höhen mit entsprechender Anpassung der Schätzvarianz. Genau solche Mechanismen sind notwendig, um durchgeschossene Höhen-Hypothesen zu altern und abhängig von ihren Varianzen zu verwerfen. Eine einfache Mittelwertbildung verfügt hingegen über keinerlei Verlässlichkeitsmaße über die geschätzten Höhen-Werte.

Abbildung 5.5(a) veranschaulicht die Unterschiede zwischen einer einfachen Mittelung und dem gewählten Ansatz anhand eines Beispiels mit zwei nacheinander folgenden Messungen unterschiedlicher Höhen. Durch eine zweite höhere Messung, dargestellt durch den oberen, roten Sensorstrahl sowie die transparente Säule, wird die aktuell ausgegebene Höhe aufgrund der Mittelwertbildung erhöht, symbolisiert durch den roten Pfeil in Abbildung 5.5(a).

Bei der Multi-Hypothesen-Verwaltung wird in diesem Falle eine neue Hypothese H_2 für die höhere Messung angelegt (durch den oberen, roten Sensorstrahl symbolisiert). Da diese Hypothese zu

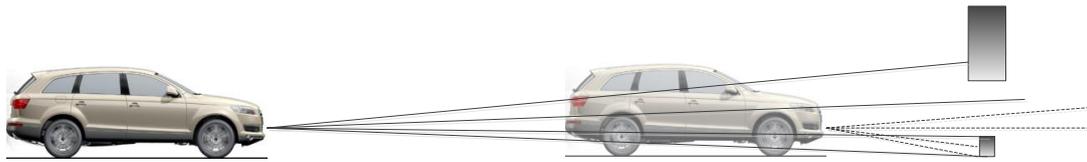
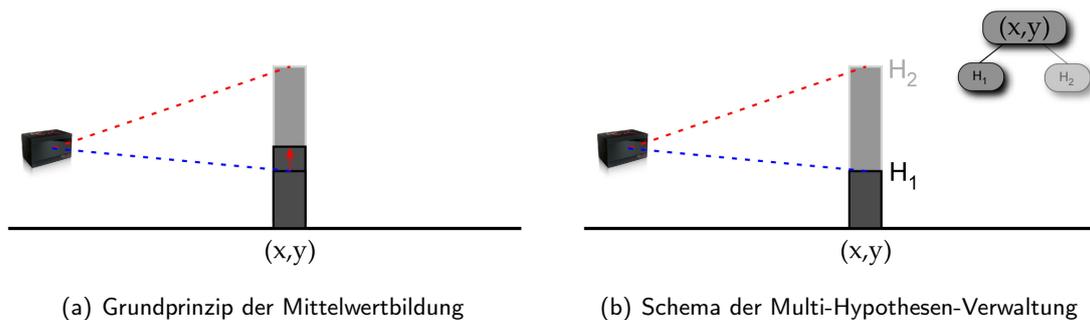


Abbildung 5.4: Erfassung der Hindernishöhen in verschiedenen Entfernungen

Beginn eine weitaus höhere Varianz besitzt als die bisher bestätigte Hypothese H_1 für die Höhe in dieser Zelle, ändert sich nichts am ausgegebenen Wert für diese Zelle. Die neu angelegte Hypothese bleibt im Hintergrund erhalten. Sollte sie sich durch zukünftige Messungen nicht bestätigen, wird sich die Varianz der Hypothese noch weiter erhöhen, bis sie schließlich wieder gelöscht wird. Die entwickelten Verfahren der 2.5D Umfeldkartierung benötigen keine extra Erkennung der Bodenpunkte, da der Sensor über eine interne Klassifikation von Boden-Reflexionspunkten verfügt. Diese müssen lediglich vor der Verarbeitung aussortiert werden.



(a) Grundprinzip der Mittelwertbildung

(b) Schema der Multi-Hypothesen-Verwaltung

Abbildung 5.5: Gegenüberstellung der Höhen-Mittelwertbildung und des Multihypothesen Ansatzes

5.3.2 Sensormodell

Das verwendete Laserscanner Sensormodell für die 2.5D Belegungskarte beruht weitgehend auf den Überlegungen des Laser-Sensormodells für zweidimensionale Belegungsgitter vom Kapitel 4.1.4. Dabei wird die wichtige Annahme getroffen, dass der Bereich zwischen dem Sensor und dem jeweiligen gemessenen Reflexionspunkt frei ist. Die Bestimmung der freien und belegten Zellen geschieht analog zum zweidimensionalen Belegungsgitter mithilfe des in 4.1.4 präsentierten Füllalgorithmus. Um ihn für die 2.5D Karte nutzbar zu machen, mussten die Sensorposition um die Einbauhöhe z und die Wank- und Nickwinkel der Einbaulage im Fahrzeug erweitert werden. Außerdem werden aus den vom Sensor gelieferten Reflexionspunkten Höhenwerte für die betroffenen Zellen extrahiert. Bei den geschätzten Höhenwerten handelt es sich um absolute Höhen über die lokale Bodenebene. Aus diesem Grund ist es wichtig, die Nickbewegung des Fahrzeugs und ihren Einfluss auf die Einbaulage des Sensors fortlaufend zu berücksichtigen. Des Weiteren ist für die 2.5D Belegungskarte wichtig zu berechnen, in welcher Höhe z eine freie Zelle vom

Sensorstrahl durchschossen wird, da hier keine Aktualisierung einer Belegungswahrscheinlichkeit statt findet, sondern die in der Zelle abgelegten Höhen-Hypothesen aktualisiert werden müssen. Die entsprechende Höhe wurde für jede Zelle mit Hilfe des Wissens über die vertikale Anordnung der Sensor-Ebenen und ihrer vertikalen Strahldivergenz berechnet.

Die Höhenmessungen aus den vier Ebenen innerhalb einer Zelle (x, y) werden miteinander verglichen. Liegt mindestens eine freie Ebene zwischen zwei Messungen, so werden zwei Höhenhypothesen initialisiert. Liegen die Messungen hingegen in benachbarten Ebenen, so wird eine Höhenhypothese mit der maximalen Höhe initialisiert. Die so gewonnen Höheninformationen stellen die Eingangsinformationen für das im nächsten Abschnitt beschriebene Multi-Hypothesen-Verwaltung der Zellen dar. Ähnlich wie beim 2D Belegungsgitter berücksichtigt das Sensormodell die Unsicherheiten der Entfernungsmessungen beim Befüllen der Gitterstruktur mit Höhenwerten. Darüber hinaus wird die vertikale Strahldivergenz als Unsicherheit für die extrahierte Höhe innerhalb einer Zelle betrachtet.

5.3.3 Multi-Hypothesen-Verwaltung

Der genau Ablauf der Aktualisierung der Gitter-Zellen mit Höhenwerten aus den Sensormessungen sowie die Verwaltungsmechanismen verschiedener Hypothesen innerhalb einer Zelle wird im Folgenden anhand eines Beispiels verdeutlicht.

Vor der ersten Sensormessung sind alle Zellen der Karte mit einer Hypothese der Höhe Null initialisiert. Ein sich in Zelle (x, y) befindendes Hindernis der Höhe z wurde vom Sensor noch nicht erkannt und erscheint deshalb auch noch nicht in der Karte. Abbildung 5.6(a) veranschaulicht diese Ausgangssituation.

In der ersten Sensormessung treffen nun die untersten drei Ebenen des Sensors wie in Abbildung 5.6(b) dargestellt auf das Hindernis. Wie oben bereits erwähnt werden in einem Vorverarbeitungsschritt die Reflexionspunkte der unteren beiden Ebenen ignoriert, da die höchste detektierte Höhe in der Zelle entscheidend ist. Nun wird von der Hypothesen-Verwaltung der Zelle überprüft, ob es bereits eine Hypothese gibt, die sich innerhalb eines Toleranzbereichs um die als belegt ermittelte Höhe z befindet. Die Toleranz richtet sich dabei nach der vertikalen Divergenz des jeweiligen Kanals in der jeweiligen Entfernung (s. Abbildung 2.5(a) auf Seite 25 für den *Ibeo LUX* Sensor). Die Kanäle des Sensors sind keine wirklichen Strahlen, sondern vielmehr Kegel, und erfassen damit in vertikaler Richtung stets mehr als nur einen Punkt. Da im vorliegenden Fall in der Zelle nur die Null-Hypothese hinterlegt ist, die als genügend weit von der Höhe z entfernt angenommen wird, erstellt die Hypothesen-Verwaltung eine neue Höhen-Hypothese und initialisiert sie mit der vom Sensor gelieferten Höhe. Die Varianz der Null-Hypothese, die sich bei dieser Messung nicht bestätigt hat, wird mit einem Prädiktionsschritt des Kalman-Filters entsprechend der Systemfehlervarianz erhöht. Auf die Kalman-Filterung wird im nächsten Unterkapitel noch detaillierter eingegangen.

Wenn sich nun die Höhe z in den darauf folgenden Messungen weiter bestätigt, wird sie jeweils mit einem Prädiktions- und Korrekturschritt des Kalman-Filters aktualisiert, was dazu führt, dass sich die Varianz dieser Hypothese immer weiter verringert. Die Varianz einer Hypothese kann also als ein Maß für ihre Verlässlichkeit betrachtet werden. Im Gegenzug wird die Null-Hypothese durch wiederholtes Ausführen des Prädiktionsschrittes ohne den Korrekturschritt des

Kalman-Filtern immer unzuverlässiger. Überschreitet die Varianz einer Hypothese schließlich eine festgelegte Schwelle, so wird die Hypothese gelöscht. Abbildung 5.6(c) veranschaulicht dies.

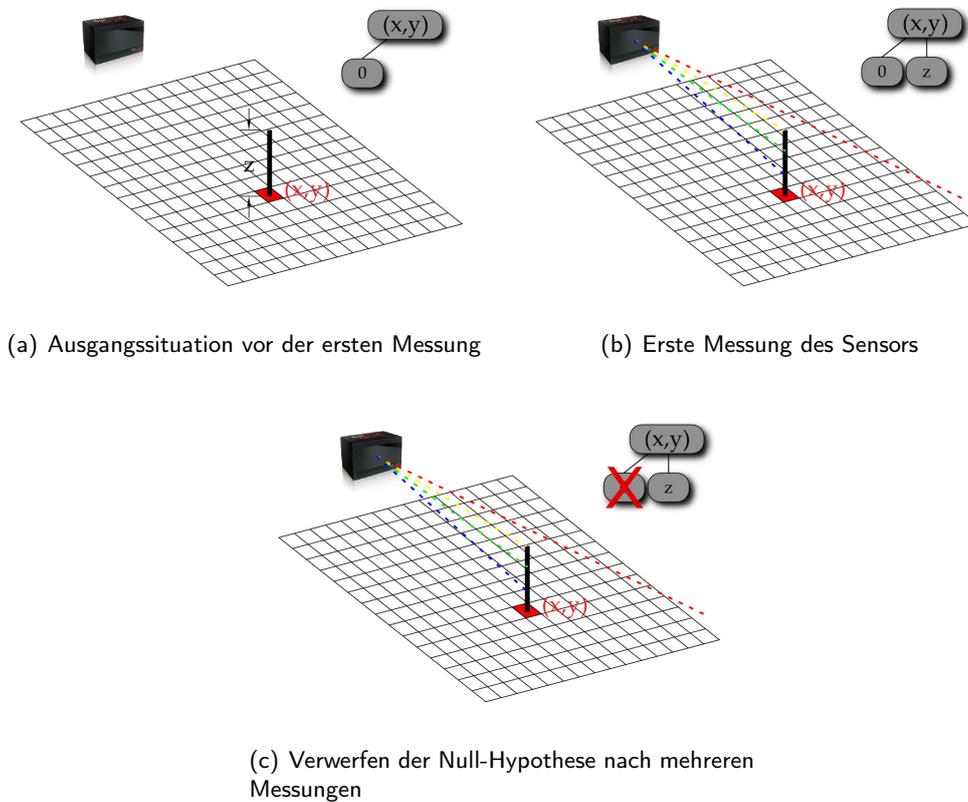


Abbildung 5.6: Ablauf der Hypothesen-Verwaltung

Insgesamt kann eine Zelle gleichzeitig bis zu drei Hypothesen verwalten. Ausgegeben wird die zurzeit wahrscheinlichste, also diejenige mit der geringsten Varianz des zugehörigen Kalman-Filtern. Sollte zu drei bereits vorhandenen Hypothesen noch eine vierte hinzutreten, dann wird die Hypothese mit der höchsten Varianz gelöscht, um die Beschränkung auf drei Hypothesen einzuhalten. Diese Beschränkung trägt vor allem der Forderung nach Echtzeitfähigkeit Rechnung, da jede weitere zu verwaltende Hypothese einen Zuwachs an Rechenaufwand bedeutet.

Neben der bisher beschriebenen Aktualisierung der vom Sensor als belegt gemeldeten Zellen wird zusätzlich eine Freiraum-Aktualisierung durchgeführt. Abbildung 5.7 illustriert die verschiedenen möglichen Fälle. Die drei schwarzen Säulen markieren Hypothesen in den jeweiligen Zellen, die vom Füll-Algorithmus gesetzt wurden. Die Höhen-Hypothese der mittleren Zelle, mit **Ⓑ** gekennzeichnet, wird dabei von den Sensorkanälen aus den unteren drei Sensorebenen durchschossen. Bei einem solchen Durchschuss werden alle betroffenen Hypothesen durch einen Prädiktionsschritt des Kalman-Filtern in ihrer Varianz erhöht. Überflogene Hypothesen, in Abbildung 5.7 mit **Ⓐ** gekennzeichnet, werden dabei ignoriert, sofern sie sich in der Vergangenheit genügend oft bestätigt haben. Sollte die Varianz einer überflogenen Hypothese eine gewisse Schwelle überschreiten, so wird deren Varianz ebenfalls durch einen Prädiktionsschritt erhöht. Diese Maßnahme dient da-

zu, bodennahe, vom Sensorrauschen oder mangelnder Kompensation der Fahrzeug-Nickbewegung hervorgerufene Hypothesen herauszufiltern. Notwendig wird die spezielle Behandlung dieser Hypothesen wegen des geringen Öffnungswinkels des eingesetzten Sensors, der den Boden direkt vor dem Fahrzeug nicht mehr erfassen und so fälschlicherweise eingetragene Hypothesen nicht mehr deplausibilisieren kann.

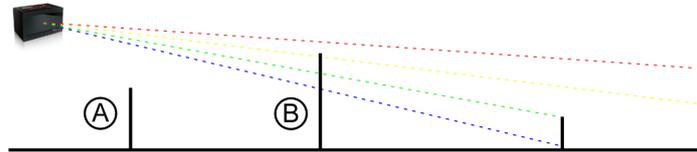


Abbildung 5.7: Möglichkeiten bei der Freiraum-Aktualisierung

Im Folgenden werden die wichtigsten Schritte des in der 2.5D Karte verwendete Algorithmus zusammengefasst:

- Zu Beginn werden alle Zellen mit einer Null-Hypothese initialisiert. Das zugehörige Kalman-Filter wird mit einer Start-Varianz initialisiert.
- Die vom Sensor gelieferten Reflexionspunkte werden entsprechend der Sensorposition und -orientierung unter Berücksichtigung der Fahrzeug-Nickbewegung in das kartesische Karten-Koordinatensystem umgerechnet.
- Messungen, die in benachbarten Ebenen liegen, und auf einer xy -Zelle fallen werden zu einer Messung mit der höchsten Höhenwert zusammengefasst.
- Für die generierten Messungen wird überprüft, ob sie in der jeweiligen xy -Zelle in den Bereich einer bestehenden Hypothese fallen.

Falls ja: Für die betroffene Hypothese wird sowohl ein Prädiktionsschritt als auch ein Korrekturschritt des Kalman-Filters mit der gemessenen Höhe durchgeführt. Dadurch sinkt ihre Varianz und die Hypothese wird damit zuverlässiger. Bei nicht betroffenen Hypothesen wird nur der Prädiktionsschritt durchgeführt, und die Varianz damit erhöht.

Falls nein: Eine neue Hypothese inklusive Kalman-Filter mit der gemessenen Höhe als Schätzgröße wird initialisiert. Die bereits existierenden Hypothesen werden mit einem Prädiktionsschritt des jeweiligen Kalman-Filters aktualisiert.

- Für die Zellen, die in einem Sensorstrahl zwischen Sensorposition und Messwert liegen, wird ein Prädiktionsschritt aller durchschossenen Hypothesen und derjenigen überflogenen Hypothesen, deren Varianz über einem festgelegten Schwellwert liegt, durchgeführt.
- Anschließend werden Hypothesen, deren Varianz einen gewissen Schwellwert übersteigt, gelöscht.
- Falls die Anzahl der Hypothesen in einer Zelle einen vordefinierten Schwellwert (im vorliegenden Fall drei) überschreitet, wird die Hypothese mit der höchsten Varianz gelöscht.
- Falls die Anzahl der Hypothesen in einer Zelle am Ende gleich Null ist, wird die Zelle mit einer Null-Hypothese initialisiert.

5.3.4 Schätzung der Höhe mit einem eindimensionalen Kalman-Filter

Das verwendete Kalman-Filter für die Schätzung der Höhen-Hypothesen nutzt ein statisches Systemmodell ohne Eingangsgrößen. Es handelt sich um ein eindimensionales Kalman-Filter, das die Höhe in der jeweiligen Zelle schätzt. Die Höhe wird direkt gemessen und als konstant angenommen. In der realen Welt ist dies nicht immer gegeben, da sich Objekte in der Umgebung des Fahrzeugs dynamisch verhalten können. So können beispielsweise Büsche am Straßenrand durch den Wind bewegt werden, oder eine Schranke sich öffnen und ihre Höhe somit ändern. Diese Unsicherheit wird durch die Systemfehlervarianz σ_v^2 modelliert. Der Prädiktionsschritt des Kalman-Filters vereinfacht sich unter den getroffenen Annahmen zu einer einfachen Addition der Systemfehlervarianz zur Varianz der Hypothese wie in Gleichung 5.1 angedeutet.

$$\sigma_{h_i,k}^{2-} = \sigma_{h_i,k-1}^2 + \sigma_v^2 \quad (5.1)$$

$\sigma_{h_i,k}^{2-}$ bezeichnet hier die prädizierte Varianz der i -ten Hypothese h_i für den k -ten Zeitschritt, $\sigma_{h_i,k-1}^2$ steht für die Varianz der Hypothese nach Abschluss des Korrekturschrittes zum Zeitpunkt $k-1$. Da hier nur eine einzige Größe geschätzt wird, handelt es sich ausschließlich um skalare Größen.

Auch der Korrekturschritt vereinfacht sich durch die getroffenen Annahmen signifikant. Die Berechnung der Kalman-Verstärkung wird durch Gleichung 5.2 beschrieben.

$$K_k = \frac{\sigma_{h_i,k}^{2-}}{\sigma_{h_i,k}^{2-} + \sigma_n^2} \quad (5.2)$$

Die Bestimmung der Messfehlervarianz σ_n^2 orientiert sich einerseits an der vertikalen Strahldivergenz der Sensor-Ebenen in der jeweiligen Zelle, andererseits an dem möglichen Fehler in der Kompensation der Fahrzeug-Nickbewegung. Diese Bewegung führt dazu, dass sich die Lage des Sensors stets ändert. Mit Hilfe der Kalman-Verstärkung K_k und der neuen Messung z_k kann der neue Schätzwert $\hat{h}_{i,k}$ für die Höhe h_i der Hypothese gemäß Gleichung 5.3 berechnet werden.

$$\hat{h}_{i,k} = \hat{h}_{i,k-1} + K_k (z_k - \hat{h}_{i,k-1}) \quad (5.3)$$

Zusätzlich wird die Varianz des neuen Schätzwertes mit Hilfe der Kalman-Verstärkung ermittelt.

$$\sigma_{h_i,k}^2 = (1 - K_k) \sigma_{h_i,k}^{2-} \quad (5.4)$$

5.3.5 Experimentelle Ergebnisse

In diesem Abschnitt werden experimentelle Ergebnisse aus der 2.5D Belegungskarte in verschiedenen Szenarien präsentiert. Abbildung 5.8 zeigt einige Beispiele der 2.5D Belegungskarte mit

5. 3D kartenbasierte Umfeldwahrnehmung

dazugehöriger Bild einer onboard Kamera auf. Die entwickelte Belegungskarte hat eine Größe von 140 m x 140 m auf bei einer Zellauflösung von 20 x 20 cm. Die Säulen in den Zellen symbolisieren die momentan wahrscheinlichste Hypothese der entsprechenden Zelle. Die Dunkelheit der Farbe der Säulen dekodiert die Höhe, wobei schwarz bedeutet die Höhe Null. Die Transparenz der Säulen, gibt Aufschluss über deren Varianz, wobei transparente Säulen eine hohe Varianz und damit eine geringe Verlässlichkeit aufweisen. Die Ebene der Höhe Null ist durch ein graues Schachbrett dargestellt. Das Eigenfahrzeug wird in der grafischen Darstellung durch das 3D Modell eines Fahrzeugs in der Mitte der Karte symbolisiert. Der Sensor wurde auf der Motorhaube mit einer speziellen Halterung montiert.

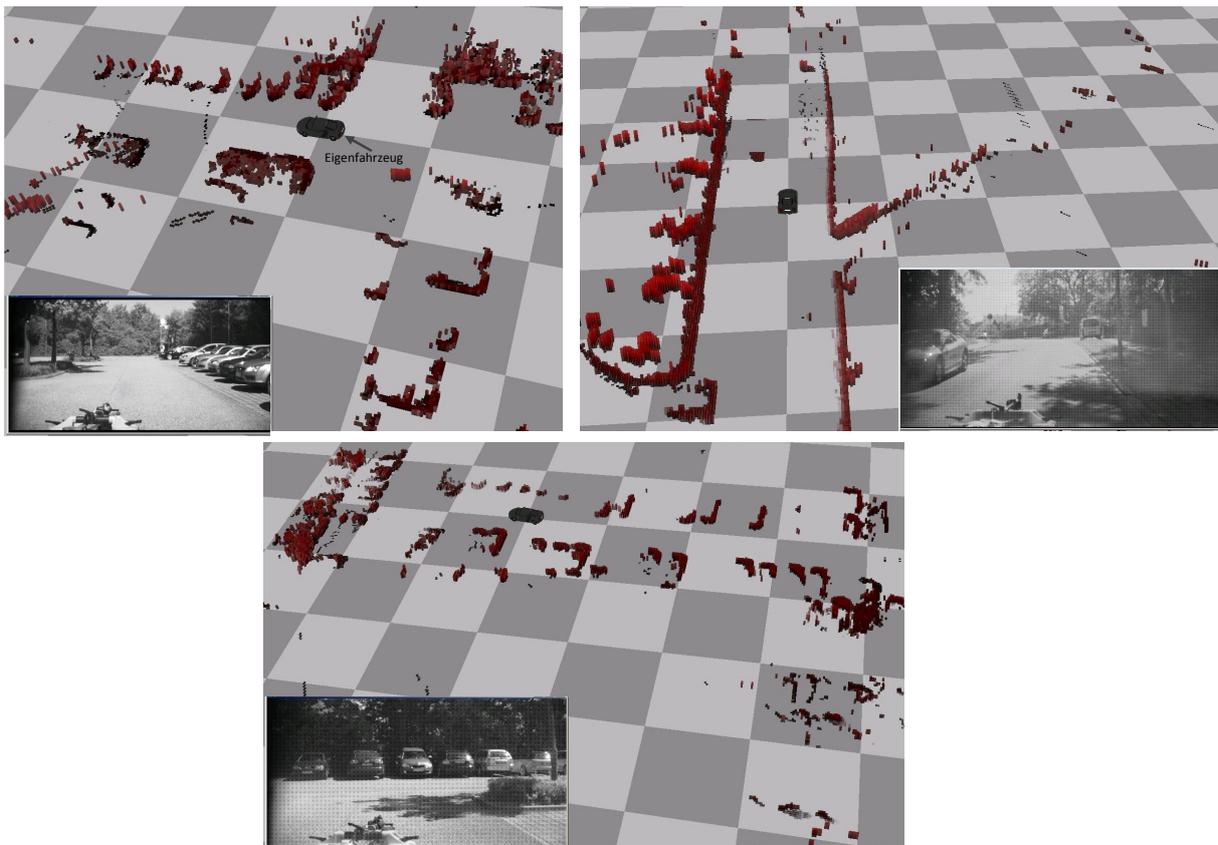


Abbildung 5.8: Beispiele von 2.5D Belegungskarten

Die Rechenzeiten blieben bei dieser Karte stets unter 10 ms für die gesamte Aktualisierung durch eine neue Sensormessung des *Ibeo LUX*, wobei der Durchschnitt in etwa bei 8 ms lag. Diese Werte liegen deutlich unter der minimalen Zykluszeit des Sensors von 40 ms. Gemessen wurden diese Zeiten auf einem Intel Centrino Core 2 Duo mit 2.2 GHz Taktfrequenz und 2 GB Arbeitsspeicher.

Um die Vorteile des Multi-Hypothesen-Ansatzes gegenüber anderen Methoden zu verdeutlichen, werden die Ergebnisse mit der einer einfacheren laufenden Mittelwertbildung der Höhe in einer Zelle verglichen. Hierzu werden die in einer Zelle gemessenen Höhen anhand eines laufenden Mittelwertes zu einem geschätzten Höhenwert kombiniert. Sollte eine Höhe von einem Sensorka-

nal durchschossen werden, so wird die Durchschusshöhe als Messung für die Mittelwertbildung aufgefasst. Ein Vergleichstest wurde an einer Schranke durchgeführt, die sich anfangs durch Sensormessungen bestätigt, sich dann aber öffnet und aus dem Sichtfeld des Sensors verschwindet. Abbildung 5.9 zeigt die Karte und das Videobild für dieses Szenario bei noch geschlossener Schranke.

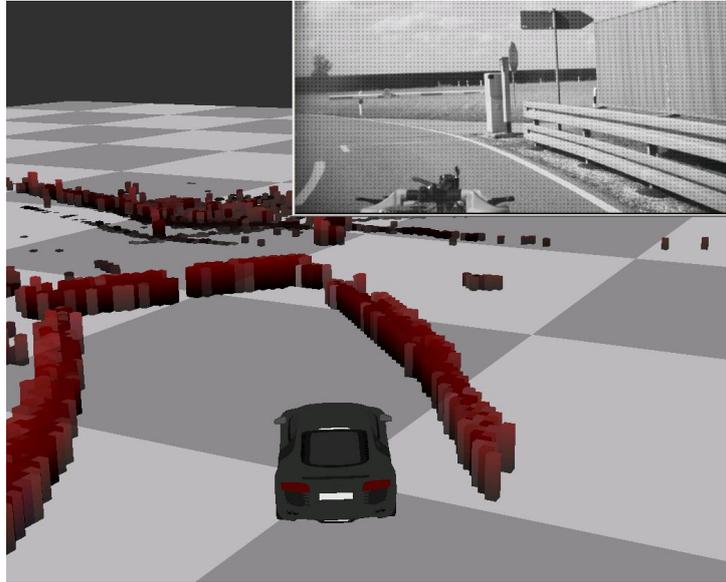


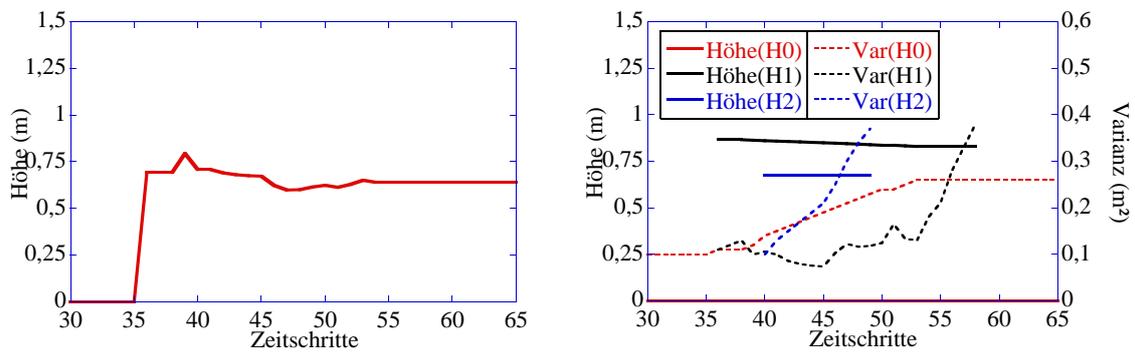
Abbildung 5.9: Beispielszenario für den Vergleichstest mit einem verschwindenden Hindernis

Abbildung 5.10(b) zeigt die Höhenwerte (durchgezogene Linien) und Varianzen (gestrichelte Linien) der Hypothesen für die gleiche Zelle bei Verwendung der Multi-Hypothesen-Höhenschätzung. In Abbildung 5.10(a) ist die entsprechende Konvergenzkurve für die Mittelwertbildung aufgetragen.

Deutlich zu erkennen ist, dass bei der Mittelwertbildung der Wert der geschätzten Höhe im Mittel deutlich unter dem Höhenwert der Schranke von etwa 85 cm bleibt, was wahrscheinlich darin begründet liegt, dass die unteren Sensorkanäle die Schranke unterschießen, und somit den Höhenwert zusätzlich nach unten ziehen. Der Mechanismus der Mittelwertbildung schlägt hier fehl. Der entscheidende Unterschied liegt jedoch daran, dass die Schranke nach dem Öffnen bzw. Unterschießen nicht mehr von der Karte gelöscht wird. Bei der Mittelwertbildung werden verschwindende Hindernisse nur maximal bis auf die Höhe des untersten die Zelle durchschießenden Sensorkanals herunter korrigiert.

Beim Multi-Hypothesen-Ansatz liegt der geschätzte Wert bei etwa 85 cm. Eine dritte Hypothese, die wahrscheinlich durch eine Fehlmessung bedingt initialisiert wurde, wurde nach einigen Messungen wieder gelöscht. Nach dem Verschwinden der Schranke ab dem 53. Zeitschritt steigt die Varianz der Hypothese H1 abrupt an und die Hypothese wird nach einigen Zeitschritten zu Gunsten der Null-Hypothese verworfen. Die Wahl der Schwelle für die Varianz, ab der Hypothesen gelöscht werden, wurde hier zu $0,4m^2$ gewählt.

Ein abschließender Test wurde mit kleinen Hindernissen auf der Fahrbahn durchgeführt. Abbil-



(a) Konvergenzkurve der Höhe einer Zelle für die Mittelwertbildung (b) Konvergenzkurven der Hypothesen einer Zelle für die Multi-Hypothesenschätzung

Abbildung 5.10: Konvergenzkurven für die Mittelwertbildung und für die Multi-Hypothesenschätzung

Abbildung 5.11 zeigt die Ergebnisse für die 2.5D Belegungskarte mit dem Multi-Hypothesen-Ansatz. Wie aus der grafischen Darstellung der Karte zu entnehmen ist, treten nur zwei der drei Hindernisse, die auf dem Kamerabild zu sehen sind, auf der Karte in Erscheinung. Das rechte der drei Hindernisse ist zu klein um als Hindernis erkannt zu werden. Die Größen der betrachteten Hindernisse lagen zwischen 5 cm und 30 cm.

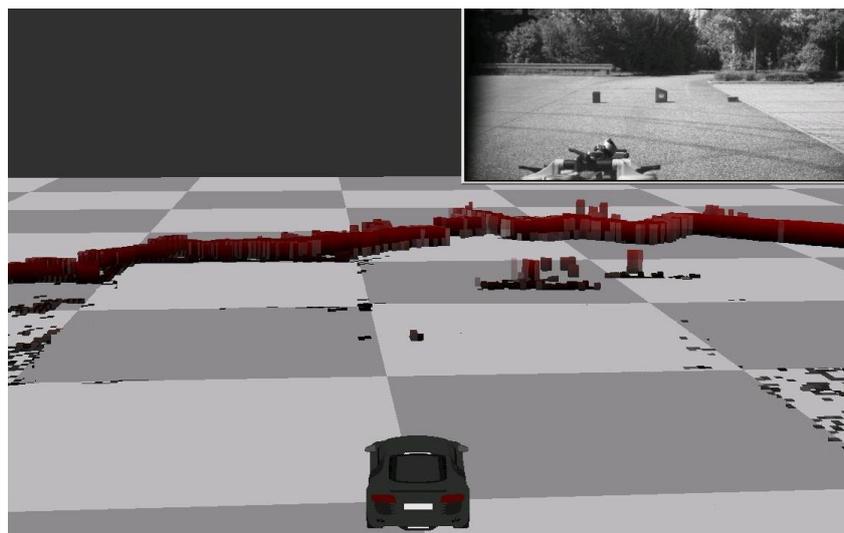


Abbildung 5.11: Beispielszenario für kleine Hindernisse auf der Fahrbahn

5.4 3D Intervallkarte

5.4.1 Motivation und Anforderungen

Die in Kapitel 5.3 beschriebene 2.5D Karte stößt an ihre Grenzen, falls die Umgebung des Fahrzeuges komplexere, z.B. überhängende Hindernisse enthält. Abbildung 5.12 zeigt ein mögliches Szenario, das in der 2.5D Karte nur unzureichend abgebildet werden kann. Sofern diese Unterführung komplett vom Sensor erfasst wird, wird sie als Hindernis erkannt und in ihrer vollen Höhe vom Boden als solches in die Karte eingetragen, wie es auch schon bei der Schranke in Abbildung 5.9 der Fall war. Die Sensorstrahlen, die durch den Bogen hindurch schießen, schwächen die aufgestellten Hypothesen jedoch wieder, was zum erneuten Löschen dieser Hypothesen führen kann. Die Unterführung tritt also auf der Karte entweder als massives Hindernis oder gar nicht in Erscheinung. Der tatsächliche Bogen als unterfahrbares Hindernis kann dabei in der einfachen Höhenkarte nicht richtig dargestellt werden.

Um solche Szenarien handhaben zu können, muss die 2.5D Belegungskarte erweitert werden. Eine solche Erweiterung in Richtung Unterfahrbarkeit von Hindernissen kann z.B. durch Speicherung belegter Höhen-Intervalle in jeder Zelle erfolgen. Diese Höhen-Intervalle können dann aufgrund ihrer oberen und unteren Grenze hinsichtlich ihrer Kritikalität für die Unter- oder Überfahrbarkeit untersucht werden. In der Literatur finden sich an vergleichbaren Konzepten nur die sogenannten *Multi-Level Surface Maps* bei [46], bei denen pro Zelle mehrere Höhenwerte für verschiedene Oberflächen gespeichert werden. Belegte Intervalle können aber auch in diesen Karten nicht richtig dargestellt werden.

Wie oben bereits für den Fall der Unterführung angedeutet ist zur Erfassung von geometrisch komplexen Umgebungssituation mit zum Beispiel überhängenden Hindernissen auch ein Sensor mit entsprechendem Öffnungswinkel nötig. Aus diesem Grund findet die Umgebungskartierung mit der im Weiteren beschriebenen Intervallkarte auf Basis der Daten des 3D Sensors statt, wie er im Grundlagen-Kapitel vorgestellt wurde. Um nicht überfahrbare Hindernisse vom Boden zu unterscheiden, benötigt die 3D Intervallkarte als ersten Verarbeitungsschritt den in 5.2 präsentierten Algorithmus zur Erkennung der Bodenpunkte und zur Schätzung der Boden-Ebene. Alle Punkte, die über die geschätzte Boden-Ebene liegen, werden für die Intervall-Kartierung betrachtet. Auch bei dieser Repräsentation muss die Echtzeitfähigkeit gewährleistet werden, weshalb es auf die Effizienz der Algorithmen geachtet werden muss.

5.4.2 Grundprinzip und Datenstruktur

In diesem Unterkapitel sollen kurz das Grundprinzip und die Datenstruktur der 3D-Intervallkarte anhand eines Beispiels beschrieben werden.

Abbildung 5.12(a) zeigt die aus der Motivation bereits bekannte Unterführung. Der Sensor, angedeutet durch die schwarze Box am linken unteren Bildrand, erfasst die Unterführung mit mehreren Sensorstrahlen. Die Reflexionspunkte sind in Abbildung 5.12(a) durch rote Kreuze dargestellt. Anders als bei der 2.5D Karte wird bei der Intervallkarte nicht nach der höchsten belegten Höhe in jeder xy -Zelle gesucht, sondern nach zusammenhängenden, belegten Höhenintervallen in

jeder Zelle. Die Front der Unterführung könnte durch diese Intervalle wie in Abbildung 5.12(b) vergrößert durch die roten Balken dargestellt repräsentiert werden.

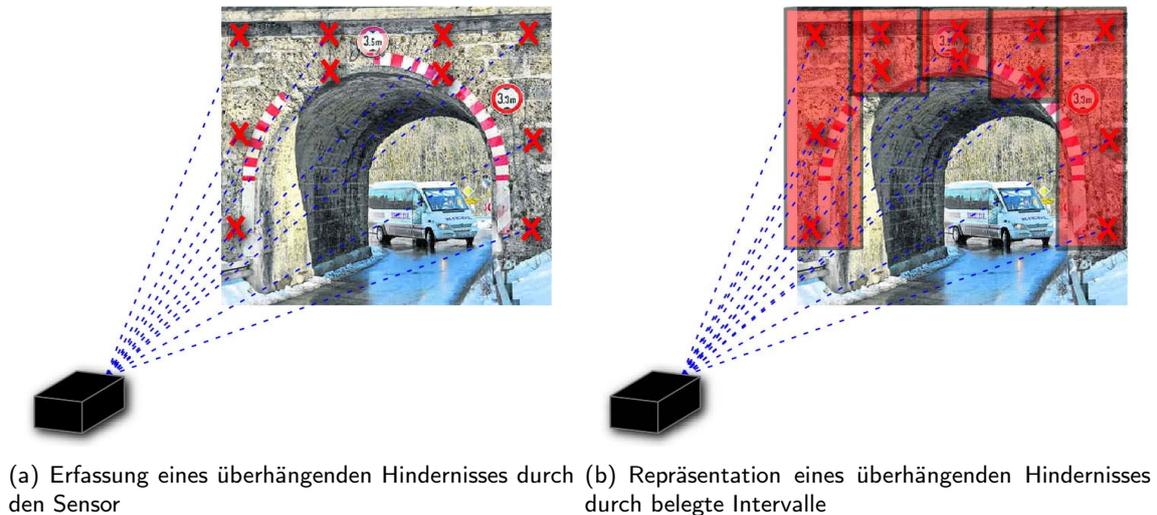


Abbildung 5.12: Sensorielle Erfassung einer Unterführung

Vorteil dieser Methode ist auch, dass sie auf die gleiche zweidimensionale Struktur aufsetzt wie das zweidimensionale Belegungsgitter und die 2.5D Belegungskarte aufsetzen kann. Statt der aus der 2.5D Hypothesen-Verwaltung in jeder Zelle muss hierbei eine Intervall-Verwaltung eingeführt werden. Diese Verwaltung speichert beliebig viele belegte Intervalle mit Ober- und Untergrenze sowie einer Intervallverlässlichkeit. Abbildung 5.13 stellt dies grafisch dar. Die Zelle mit den Koordinaten (x, y) beinhaltet zwei belegte Intervalle. Die unterschiedliche Verlässlichkeit bzw. Wahrscheinlichkeit der beiden Intervalle wird durch deren unterschiedliche Transparenz ausgedrückt. Die Höhe der Ober- und Untergrenze eines Intervalls wird, analog zur Höhen-Hypothese der 2.5D Karte, durch ein Kalman-Filter geschätzt.

Im nächsten Schritt werden die Reflexionspunkte aus dem kartesischen Sensorkoordinatensystem in das Kartenkoordinatensystem umgerechnet. Die Verschiebungen der Koordinatensysteme untereinander in x - und y -Richtung berechnen sich dabei aus der Fahrzeugposition und -ausrichtung auf der Karte, die aus der Sensorik zur Eigenzustandsschätzung stammen, sowie der Einbauposition des Sensors.

Sensormodell

Um die Daten des 3D Laser-Sensors möglichst präzise auf der Datenstruktur der 3D-Intervallkarte abzubilden, wurde ein Zwei-Schritt Interpretationsprozess der Sensordaten entwickelt.

- zunächst wird mit Hilfe eines Optik-Modells die Tiefeninformation in den Pixel des Sensors in eine 3D Darstellung im kartesischen Koordinatensystem überführt. Dies beinhaltet die Bestimmung der 3D Koordinaten des Reflexionspunktes sowie den vom Pixel belegten realen Raum. Diese letzte Größe stellt die Unsicherheit des Sensors dar und muss aufgrund

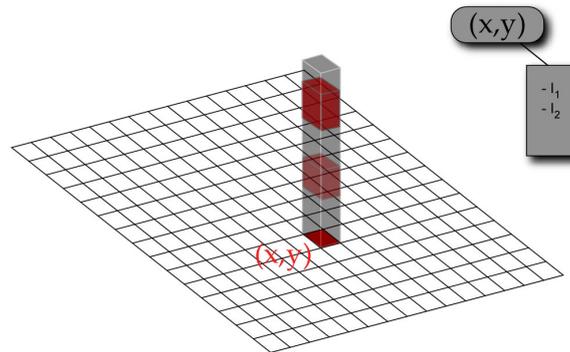


Abbildung 5.13: Grundprinzip der Intervallkarte

der beschränkten Pixelauflösung berücksichtigt werden. Für die Bestimmung der realen Größen eines Pixels wird ein einfaches Lochkameramodell [81] [45], wie in Abbildung 5.14 dargestellt, eingesetzt. Mit Hilfe der Bildweite b in [mm], die auch in der Literatur wie z.B. in [10] als Brennweite f bezeichnet wird, und den Pixelabmessungen (Breite und Höhe) s_x und s_y in [mm] kann z.B. der Raumwinkel β eines Pixels mit der vertikalen Bildkoordinate x aus einem Gesamtbild mit N Pixeln wie folgt berechnet werden.

$$\beta = \arctan\left(\frac{|x - \frac{N}{2}|}{b/s_x}\right) - \arctan\left(\frac{|x - 1 - \frac{N}{2}|}{b/s_x}\right) \quad (5.5)$$

- Im zweiten Schritt wird mit Hilfe eines Pyramidenmodells zwischen dem optischen Zentrum der Kamera und den Ecken des vom Pixel belegten Raums die Freirauminformation extrahiert (s. Abbildung 5.14 (a)). D.h. es wird angenommen, dass zwischen dem Sensorursprung und dem Reflexionspunkt frei ist. Der aufgeweitete Sehstrahl in Form einer Pyramide kann mit Hilfe von Füll-Algorithmen auf der diskretisierten $x - y$ Ebene projiziert werden. Zusätzlich wird zu jedem Pixel (x_i, y_i) die beiden Schnittpunkte der Unsicherheitspyramide mit der dreidimensionalen Gerade $\{x, y, z | x = x_i, y = i\}$ berechnet. Mit diesem Konzept werden die Sensordaten effizient für den wichtigen Schritt der Intervall-Aktualisierung vorbereitet. Anschließend werden die Reflexionspunkte den Zellen zugeordnet, in die sie fallen. Diese Zuordnung ist Grundlage für die Aktualisierung und Verwaltung der belegten Intervalle innerhalb einer Zelle.

5.4.3 Intervallverwaltung

Kern der 3D Intervallkarte ist die Intervall-Verwaltung in den einzelnen Zellen. Die Aktualisierung der belegten Intervalle läuft nach dem folgenden Schema ab.

- Zu Beginn werden alle Zellen als leer initialisiert.

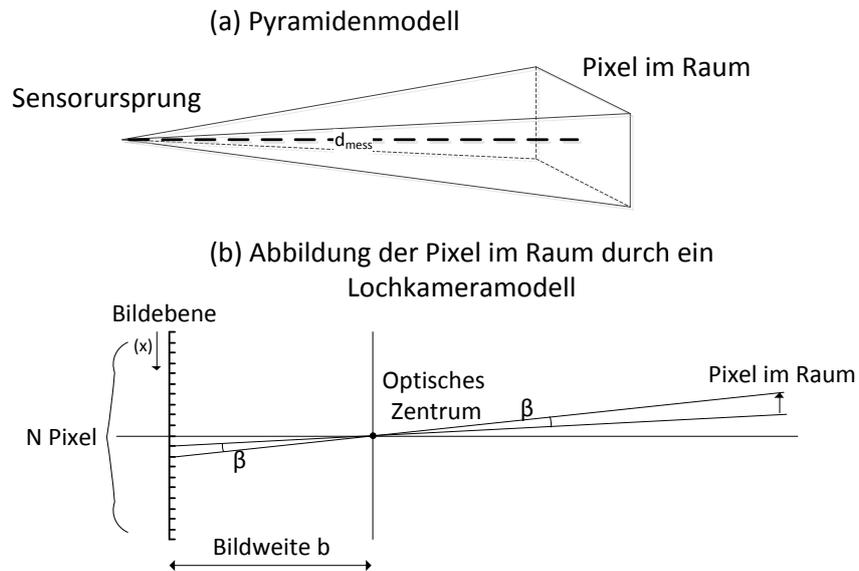


Abbildung 5.14: Sensormodell für den 3D Laser-Sensor

- Die vom Sensor gelieferten Reflexionspunkte werden entsprechend der Sensor-Einbaulage und Fahrzeug-Nickbewegung relativ zu der geschätzten Bodenebene in das Karten-Koordinatensystem umgerechnet und den jeweiligen Zellen zugeordnet. Den Zellen, die von den Sensorstrahlen durchschossen werden, werden außerdem die Durchschusshöhen für die Freiraum-Aktualisierung zugeordnet. Abbildung 5.15 veranschaulicht diese Ausgangssituation grafisch. Der Zelle mit den Koordinaten (x, y) wurden in diesem Beispiel vier Reflexionspunkte mit den Höhen z_1, z_2, z_3 und z_4 über Boden zugeordnet.

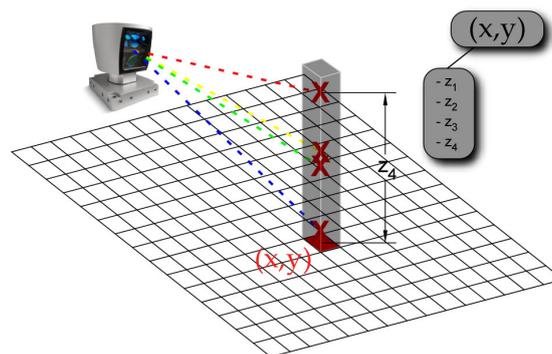


Abbildung 5.15: Zuordnung von Reflexionspunkten zu einer Zelle

- Die gemessenen Höhen, die einer Zelle zugeordnet wurden, werden nun mit der kleinsten beginnend der Reihe nach von der Intervall-Verwaltung verarbeitet. Es wird überprüft, ob in unmittelbarer Nähe der jeweiligen Höhe bereits ein belegtes Intervall besteht bzw. ob

die Höhe in einem solchen liegt. Der hierfür notwendige Assoziationsbereich definiert sich über die vertikale Divergenz des Sensors in der jeweiligen Entfernung und über die Schätzvarianzen der betrachteten Intervallgrenzen. Sollte ein Reflexionspunkt in einen Bereich fallen, in dem noch kein belegtes Intervall existiert, so wird ein neues Intervall initialisiert. Reflexionspunkte, die zu benachbarten Sehstrahlen angehören werden zu einem Intervall zusammengefasst. Abbildung 5.16 illustriert die Initialisierung von neuen Intervallen in einer zweidimensionalen Seitenansicht des Szenarios aus Abbildung 5.15. Dabei werden insgesamt drei neue Intervalle initialisiert, wobei die gemessenen Höhen z_2 und z_3 zu einem Intervall zusammengefasst wurden.

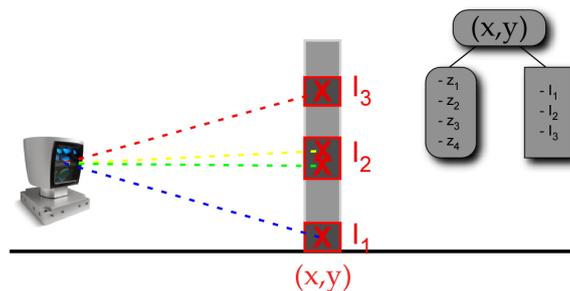


Abbildung 5.16: Initialisierung neuer Intervalle

- Reflexionspunkte, die im Toleranzbereich eines bereits bestehenden belegten Intervalls fallen, werden diesem Intervall zugeordnet und werden für die Aktualisierung der Intervallgrenzen und der Intervallverlässlichkeit verwendet. Abbildung 5.17 stellt dies für ein Intervall exemplarisch dar. Hier fallen vier Messpunkte in den Toleranzbereich des Intervalls I_2 . Mit Toleranzbereich wird dabei wieder den Bereich gemeint, den das Intervall abdeckt, jedoch an beiden Grenzen um jeweils den Wert der Sensordivergenz erweitert.

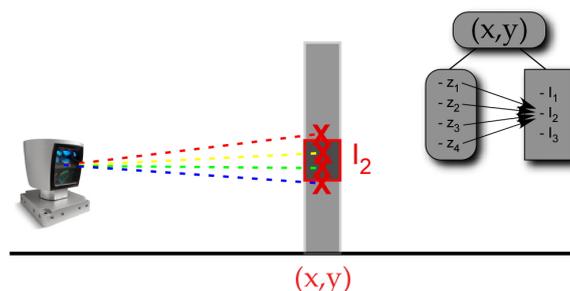


Abbildung 5.17: Zuordnung von Reflexionspunkten zu einem bestehenden Intervall

- Anschließend erfolgt eine Aktualisierung der Intervallgrenzen sowie der Intervallverlässlichkeit mit Hilfe der neuen zu den Intervallen zugeordneten Messdaten. Für die Schätzung der Intervallgrenzen wird ähnlich wie bei der 2.5D Belegungskarte ein Kalman-Filter mit statischem Systemmodell eingesetzt. Der Schätzvorgang beginnt mit einer Prädiktion der

beiden Grenzen eines Intervalls. Sollte nun die oberste bzw. unterste Sensormessung, die dem Intervall zugeordnet wurde, in die unmittelbare Nähe der oberen bzw. unteren Grenze des Intervalls fallen, so wird diese Grenze mit der Messung korrigiert, ansonsten bleibt es bei der Prädiktion. Die unmittelbare Nähe einer Grenze definiert sich über die vertikale Divergenz des Sensors an der jeweiligen Stelle und der prädizierten Schätzvarianz der jeweiligen Grenze. Weiter weg liegende Messpunkte werden nicht zur Aktualisierung der Grenzen herangezogen, da in diesem Fall die betroffene Grenze durch ein davor liegendes Hindernis verdeckt sein könnte und die Aktualisierung die Grenze fälschlicherweise verschieben würde. Abbildung 5.18 veranschaulicht diese Mechanismen am Beispiel aus Abbildung 5.17. Die Grenzen des Intervalls wurden durch die Messungen z_1 und z_4 aktualisiert. Nach der Aktualisierung ist das Intervall leicht angewachsen, angedeutet durch das schwarz umrandete Rechteck im Hintergrund.

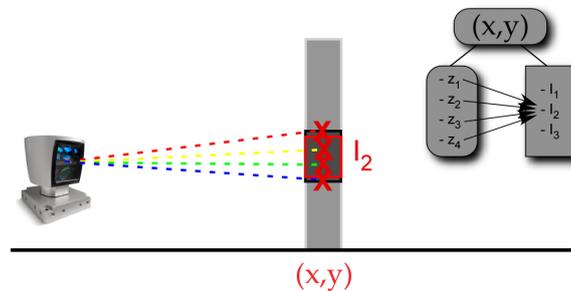


Abbildung 5.18: Aktualisierung der Intervallgrenzen

Als weiterer Schritt erfolgt eine Aktualisierung der Intervallverlässlichkeit. Hierzu wird berechnet, wie viele Reflexionspunkte aufgrund der Ausdehnung des Intervalls und der Sensordivergenz an der entsprechenden Stelle maximal in den Bereich des Intervalls fallen können. Der Quotient aus der Anzahl der tatsächlich dem Intervall zugeordneten Reflexionspunkte in der aktuellen Messung und dem theoretischen Maximum wird dazu benutzt, um mit Hilfe einer laufenden Mittelwertbildung die Intervallverlässlichkeit zu aktualisieren. Gleichung 5.6 stellt die Aktualisierungsvorschrift mathematisch dar. R_{int} bezeichnet hier die Intervallverlässlichkeit, n_{pot} steht für die Anzahl der maximal möglichen Reflexionspunkte im Intervall, n_{mess} für die tatsächlich gemessenen. a_{int} ist ein zusätzlicher Faktor, der zwischen 0 und 1 liegt und durch den die Konvergenz der Verlässlichkeit beeinflusst werden kann.

$$R_{int,k+1} = R_{int,k} + a_{int} (1 - R_{int,k}) \frac{n_{mess}}{n_{pot}} \quad (5.6)$$

Alternativ zur laufenden Mittelwertbildung kann diese Aktualisierung gemäß der Bayes-Formel wie in Gleichung 2.11 beschrieben geschehen. In beiden Varianten bewegt sich die Intervallverlässlichkeit zwischen 0 und 1, wobei Werte nahe bei 1 für eine hohe Intervallverlässlichkeit stehen.

- Durchschossene Intervalle werden ebenfalls aktualisiert. Dazu wird die Grenze, die näher am Durchschuss liegt, mit der Durchschusshöhe korrigiert, und die Intervallverlässlichkeit in Abhängigkeit der Durchschussstelle verringert. Neben der Aktualisierung der Intervalle durch 3D-Messpunkte wird auch die aus den Sensordaten extrahierte Freirauminformation in der Schätzung der Intervallgrenzen und der Intervallverlässlichkeit miteinbezogen. Hierzu wird überprüft, ob der Sensorstrahl zwischen dem Sensorursprung und dem Reflexionspunkt ein bereits belegtes Intervall und in welcher Höhe durchschiesst. Ein solches von einem Sensorstrahl durchschossenes Intervall wird ebenfalls aktualisiert. Dabei wird die Grenze, die näher an der Durchschusshöhe liegt, prädiziert und mit der Durchschusshöhe korrigiert. Abbildung 5.19 illustriert diese Vorgehensweise für das bereits bekannte Intervall. Hier befindet sich der Durchschuss nahe der oberen Intervallgrenze. Diese wird durch den Korrektur-Schritt des Kalman-Filters leicht nach unten gezogen.

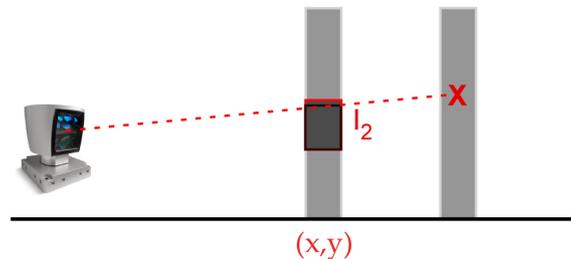


Abbildung 5.19: Freiraum-Aktualisierung bei einem durchschossenen Intervall

Die Intervallverlässlichkeit wird abhängig vom Abstand des Durchschusses zur Mitte des Intervalls verringert. Dabei wirken sich Durchschüsse nahe der Mitte stärker aus als am Rand gelegene. Gleichung 5.7 stellt die Aktualisierungsvorschrift mathematisch dar. R_{int} steht für die Intervallverlässlichkeit, d bezeichnet den Abstand des Durchschusses zur Intervallmitte und h die Gesamthöhe des Intervalls. b_{int} ist ein Gewichtungsfaktor. Auch hier kann alternativ eine Aktualisierung nach Bayes stattfinden.

$$R_{int,k+1} = R_{int,k} \left(b_{int} + (1 - b_{int}) \frac{2d}{h} \right) \quad (5.7)$$

- Nach der Aktualisierung durch eine neue Sensormessung kann es vorkommen, dass Intervalle plötzlich sehr nahe beieinander liegen oder sogar überlappen. Diese Intervalle werden zu einem Intervall verschmolzen und deren Intervallverlässlichkeit dabei gemittelt.
- Intervalle, deren Verlässlichkeit unter eine vordefinierte Schwelle gesunken ist oder die eine Mindestausdehnung unterschreiten, werden gelöscht.

5.4.4 Experimentelle Ergebnisse

In diesem Abschnitt werden experimentelle Ergebnisse mit der Intervallkarte präsentiert. Die Intervallkarte ist wie auch schon die 2.5D Karte 140 x 140 m groß bei einer Zellgröße von 20 x 20 cm. In der Höhe ist sie im vorliegenden Fall auf 6 m beschränkt. Diese Höhe wurde so gewählt, dass auch typische unterfahrbare Hindernisse wie z.B. Schilderbrücken auf der Autobahn noch auf der Karte zu sehen sind. Abbildung 5.20 zeigt einige Beispiele aus der 3D Intervallkartierung. In 5.20 (b) ist die Szene mit der Schilderbrücke aus Abbildung 5.2(b) zu sehen. Die Intervalle sind dabei wie die Höhen-Hypothesen der 2.5D Karte als Säulen mit quadratischer Grundfläche dargestellt. Die Farbe der Säulen korrespondiert zur jeweiligen Höhe, wobei schwarz der Höhe Null und hellrot der maximalen Höhe von 6 m entspricht. Je kräftiger der Farbton einer Säule ist, desto höher ist die zugehörige Intervallverlässlichkeit. Die Schilderbrücke, die in der Karte zu sehen ist, ist bei der maximalen Höhe von 6 m abgeschnitten.

In Abbildung 5.20 (c) stellt das Ergebnis der Kartierung für ein Szenario dar, das dem aus der Beschreibung des Grundprinzips der Karte sehr ähnlich ist. Hier wurde eine Unterführung durch 3D Intervallkarte korrekt abgebildet. Des Weiteren können mit der entwickelten Kartierung Bordsteine und Bäume am Fahrbahnrand repräsentiert werden, wie aus Abbildungen 5.20 (a) und 5.20 (d) zu entnehmen ist.

Abbildung 5.21(a) stellt die Funktionsweise der Intervall-Verwaltung abschließend an einem realen Beispiel einer Zelle dar. Hier wird zu Beginn ein Intervall bei einer Höhe von circa 5 m initialisiert. Die Ober- und Untergrenze des Intervalls werden dabei durch die beiden roten Kurven in Abbildung 5.21(a) dargestellt. Nach 8 Zeitschritten wird vom Sensor ein weiteres belegtes Intervall detektiert und zur Zelle hinzugefügt. Dieses Intervall liegt unter dem ersten auf einer Höhe von etwa 3 m und wird durch zwei schwarze Linien dargestellt. Die Obergrenze des zweiten Intervalls wächst rasch in Richtung des darüber liegenden Intervalls. Bei Zeitschritt 10 detektiert der Sensor wohl erstmals Punkte, die die beiden Intervalle miteinander verbinden, zuvor jedoch von beispielsweise einem davor liegenden Objekt verdeckt waren. Die Intervall-Verwaltung verschmilzt die beiden Intervalle zu einem großen Intervall, dessen Grenzen in Abbildung 5.21(a) durch zwei schwarze Linien wiedergegeben werden. Der von den Intervallen belegte Bereich ist stets grau schraffiert dargestellt. Die Intervallverlässlichkeiten der ursprünglichen Intervalle werden dabei zu einer neuen Verlässlichkeit gemittelt, wie in Abbildung 5.21(b) zu sehen ist.

Die Rechenzeit bei der 3D Intervallkarte liegt im Mittel bei 20 ms. Gemessen wurden diese Zeit auf einem *Intel Centrino Core 2 Duo* Laptop mit 2.2 GHz Taktfrequenz und 2 GB Arbeitsspeicher.

5.5 3D Voxel Karte

Als Vergleich-Repräsentation für die 2.5D Belegungskarte und für die 3D Intervallkarte, wurde in der Arbeit eine dreidimensionale Voxel-Belegungskarte implementiert. Das Grundprinzip der 3D Karte beruht auf dem Prinzip der Belegungskarten, wie sie bereits von Moravec und Elfes vorgestellt wurden ([69]). Die Umgebung des Fahrzeuges wird dabei in Zellen diskretisiert, für die abhängig von den Sensormessungen Belegungswahrscheinlichkeiten berechnet werden. Im Fall der dreidimensionalen Belegungskarte handelt es nicht mehr wirklich um Zellen, sondern vielmehr

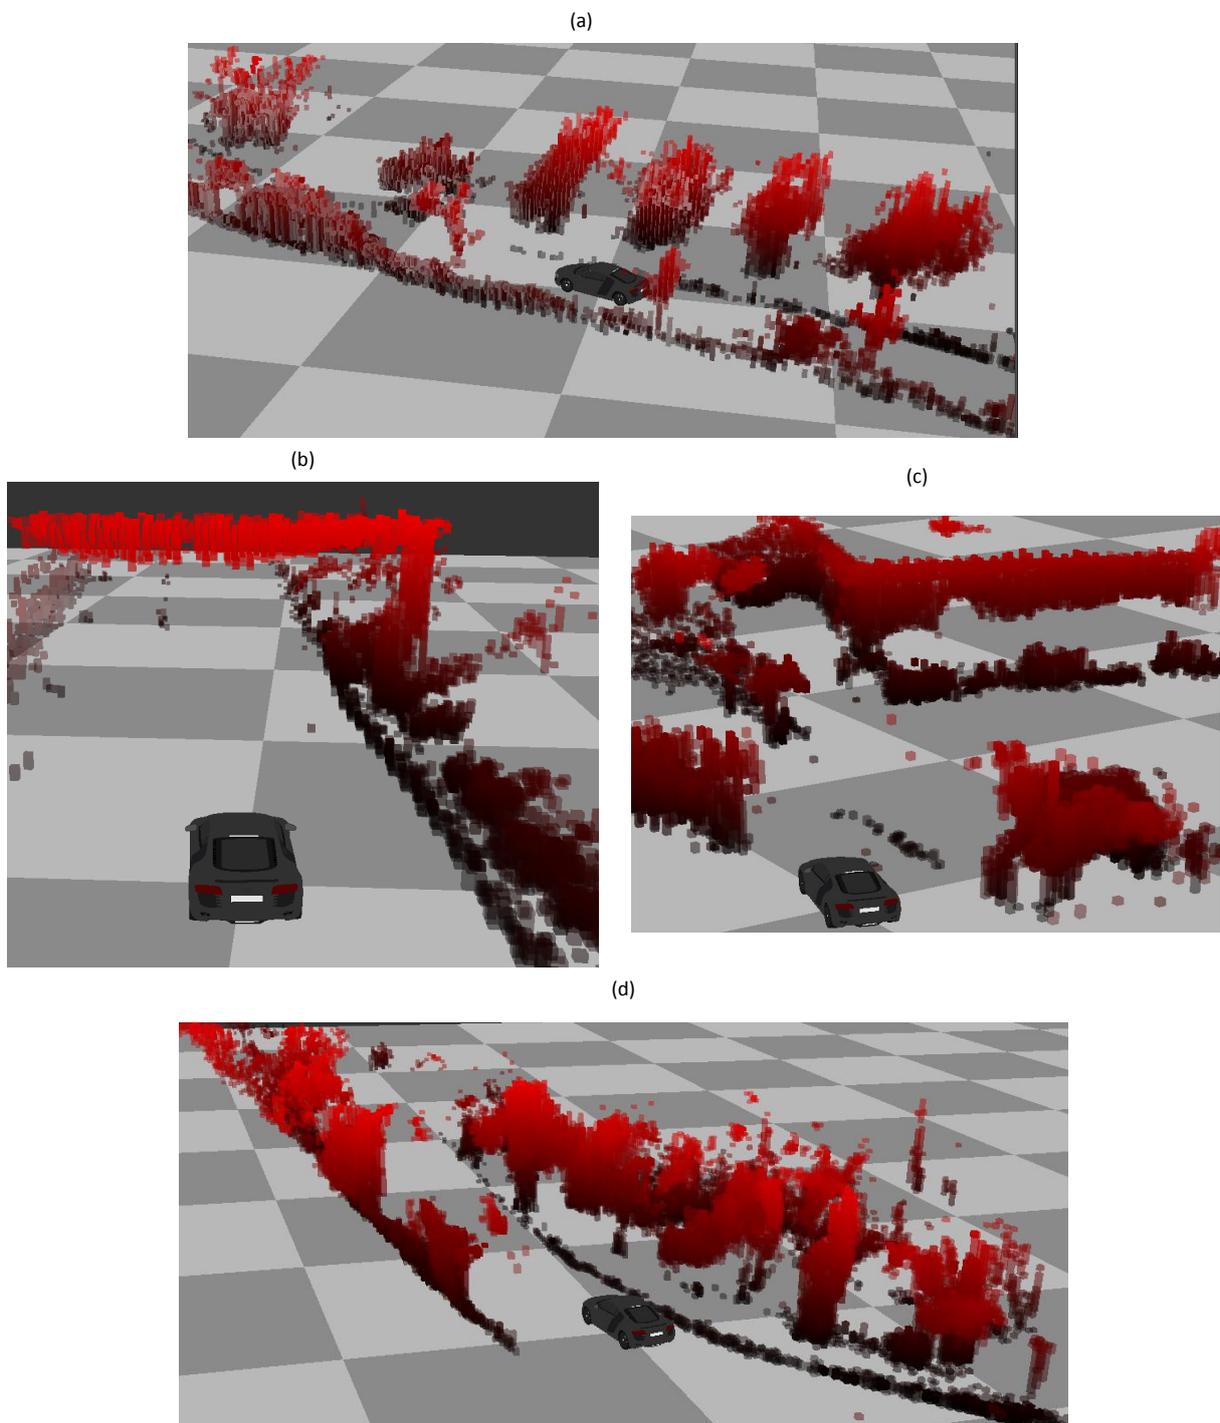
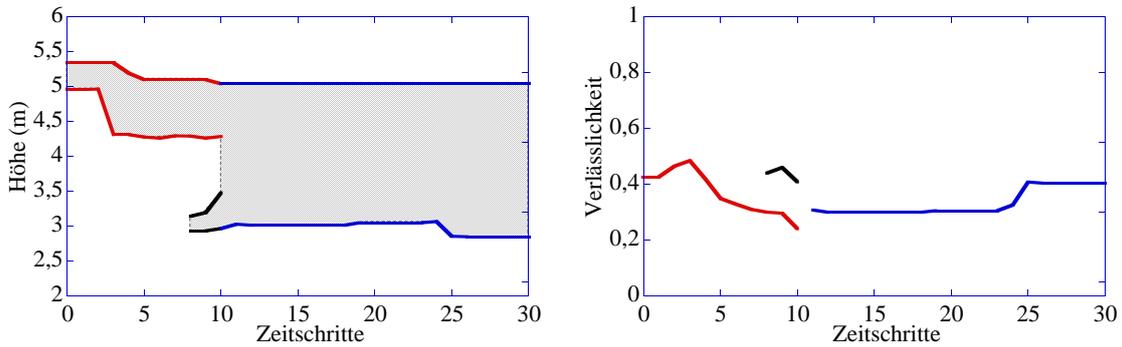


Abbildung 5.20: Ergebnisse der 3D Intervallkartierung

5. 3D kartenbasierte Umfeldwahrnehmung

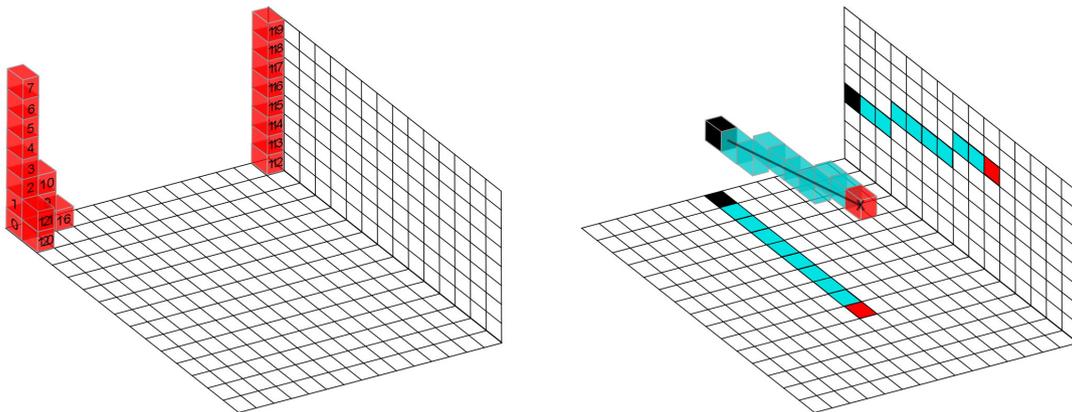


(a) Verschmelzung zweier Intervalle in einer Zelle (Intervallgrenzen) (b) Verschmelzung zweier Intervalle in einer Zelle (Verlässlichkeit)

Abbildung 5.21: Aktualisierung der Intervalle innerhalb einer Zelle

um Quader bzw. Volumen Pixel, sogenannte Voxel.

Abgelegt im Speicher wird die dreidimensionale Karte wie schon die 2.5D Karte und die Intervallkarte in einem eindimensionalen Ringpuffer. Dazu ist die Anpassung des Nummerierungsschemas, wie es in den beiden anderen Karten verwendet wurde an die nun dreidimensionale Struktur der Karte notwendig. Die Zellen bzw. Voxel werden dabei zuerst entlang der Höhen- bzw. z -Achse, dann entlang der y - und schließlich entlang der x -Achse durchnummeriert und gemäß dieser Nummerierung im Speicher abgelegt. Wirklich gespeichert wird dabei nur der Wahrscheinlichkeitswert der Belegung jedes Voxels. Damit müssen für eine Karte gleicher Größe zwar wesentlich mehr Voxel gespeichert werden als bei der Intervallkarte, die einzelnen Voxel beinhalten jedoch weniger Daten. Abbildung 5.22(a) illustriert das Nummerierungsschema am Beispiel der $15 \times 15 \times 8$ Voxel großen Karte.



(a) Nummerierungsschema der Datenstruktur der 3D Karte

(b) 3D Bresenham-Algorithmus

Abbildung 5.22: Datenstruktur der 3D Voxel Karte und der 3D Bresenham Algorithmus

Die translatorischen Bewegungen des Fahrzeugs auf der Karte werden dabei wie bei den ersten beiden Karten mit Hilfe eines Start-Zeigers abgebildet. Da sich das Fahrzeug nur auf der Bodenebene bewegt, wird dieser Start-Zeiger auch nur in der xy -Ebene durch Offsets verschoben und damit der aktuelle Ursprung der Karte und die neu zu initialisierenden Voxel festgelegt. Bei der Aktualisierung der Voxel-Karte werden die aus den Sensordaten extrahierten Belegt- und Freirauminformation auf der Voxel-Struktur der Karte abgebildet. Hierbei werden die Reflexionspunkte aber nicht mehr nur einer xy -Zelle zugerechnet, sondern gleich einem einzelnen Voxel mit zugehöriger xyz -Koordinate. Die Belegungswahrscheinlichkeit eines Voxels, in das ein Reflexionspunkt fällt, muss im nächsten Schritt erhöht werden. Auch bei der 3D Karte findet eine Freiraum-Aktualisierung statt. Hier müssen alle Voxel im dreidimensionalen Raumbereich zwischen Sensor und dem Pixel im Raum bestimmt werden, da sie als frei angenommen werden. Hierzu kann dieser Raumbereich durch eine Linie approximiert werden, so dass eine dreidimensionale Version Bresenham-Algorithmus zur Diskretisierung von Linien zum Einsatz kommen kann. Ein solcher Algorithmus wurde bereits bei [57] vorgestellt und implementiert. Abbildung 5.22(b) stellt das Ergebnis dieses Algorithmus grafisch dar. Die Belegungswahrscheinlichkeiten der zuletzt bestimmten Voxel müssen erhöht bzw. verringert werden. Dies geschieht analog zum zweidimensionalen Belegungsgitters anhand der Bayes-Regel.

Die in der Arbeit implementierte 3D Karte bedeckt wie schon die beiden anderen Karten eine Fläche von 140 x 140 m. In der Höhe ist sie wie die Intervallkarte auf 6 m beschränkt. Ein Voxel entspricht dabei einem Würfel von 20 x 20 x 20 cm. Somit setzt sich die gesamte Karte aus 14.700.000 Voxeln zusammen. In den nachfolgenden Grafiken sind die Voxel als kleine Würfel eingezeichnet. Die Farbe der Würfel korreliert wie schon bei den anderen Karten mit der Höhe auf der sich ein Würfel befindet, wobei schwarz wiederum der Höhe Null und hellrot der maximalen Höhe von 6 m entspricht. Die Sättigung der Farbe gibt den Belegungswert des Voxels an. Dargestellt werden nur Voxel mit einer Belegungswahrscheinlichkeit von mehr als 0,5, also nur die Voxel, die als belegt gelten. Freie und unbekannte Voxel erscheinen aus Gründen der Übersichtlichkeit nicht.

Abbildung 5.23 zeigt ein Szenario mit einem überhängenden Dach mit dem darunter geparkten Auto (blaues Oval).

Hinsichtlich der Rechenzeiten schneidet die 3D Karte besser als die 3D Intervallkarte ab, da es sich bei der Karten-UAktualisierung mit Hilfe der Bayes-Formel auch lediglich um simple Additionen und Subtraktionen handelt, und nicht wie bei der Intervallkarte eine aufwendige Intervall-Verwaltung dahinter steckt. Die Rechenzeiten der 3D Karte lagen im Schnitt bei den getesteten Daten bei etwa 10 ms, bei Autobahnfahrten mit wenig Randbebauung sogar noch darunter. Gemessen wurden die Rechenzeiten wie schon bei den anderen Karten auf einem Intel Centrino Core 2 Duo mit 2.2 GHz Taktfrequenz und 2 GB Arbeitsspeicher.

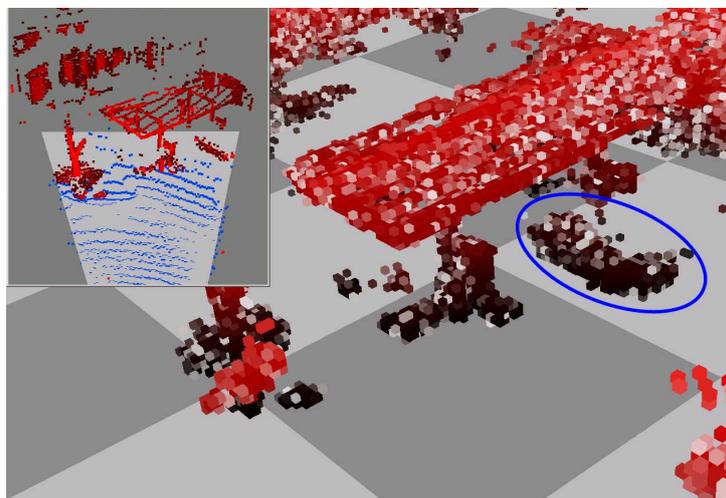


Abbildung 5.23: Ergebnis der 3D Kartierung am Beispiel eines überhängenden Daches

6 Fusion kartenbasierter Umfeldwahrnehmung mit der modellbasierten Objektverfolgung

6.1 Einleitung

In diesem Kapitel wird ein Konzept zur Kopplung der belegungskartenbasierten Umfeldwahrnehmung mit der modellbasierten Objektverfolgung präsentiert. Die Voraussetzungen für die Realisierung des Konzepts sowie dessen Umsetzung werden in den Abschnitten des Kapitels diskutiert. Das Konzept ist für die verschiedenen Formen der Umfeldkartierung (s. Kapitel 4 und 5) anwendbar. Die prototypische Umsetzung wird in diesem Kapitel anhand der zwei- und dreidimensionalen Belegungsgitter gezeigt.

6.1.1 Motivation

Wie bereits in Kapitel 1 erwähnt, stellt die Kombination der belegungskartenbasierten Umfeldwahrnehmung mit der objektbasierten Umfeldrepräsentation ein wichtiges Ziel der vorliegenden Arbeit dar. Diese angestrebte Kopplung zwischen den beiden Umfeldrepräsentationen hat verschiedene Motivationsgründe.

Einerseits ergänzen sich die beiden Ansätze für die Generierung einer möglichst präzisen und vollständigen Beschreibung der Fahrzeugumgebung. Die objektbasierte Beschreibung stellt ein kompaktes und einfach interpretierbares Wissen über das Umfeld in Form von Objektzuständen zur Verfügung. Starke Vereinfachungen in den Modellen zur Beschreibung der Objekte hingegen können zu einer fehlerhaften Umfelderfassung führen. Außerdem ist die Objektbeschreibung stets auf eine korrekte Assoziation der Messungen zu den verfolgten Objekten angewiesen. Die Belegungskarte ist eine weitere robuste Umfeldrepräsentation. Sie ermöglicht die Beschreibung der belegten, freien und unbekanntenen Bereiche in der Umgebung des Fahrzeugs. Sie ist gekennzeichnet durch einen hohen Rechen- und Speicheraufwand und ein niedriges Abstraktionsniveau, das das Interpretieren der Daten erschwert.

Andererseits erfordert die Nutzung der Technologie der Belegungskarte im Bereich der Fahrerassistenzsysteme die Erweiterung dieser Methode um die Beschreibung dynamischer Hindernisse. Die Einsatzmöglichkeiten der belegungskartenbasierten Methoden werden dadurch, dass sie in der Literatur hauptsächlich für die Beschreibung des stationären Teils der Umgebung eingesetzt werden, stark eingeschränkt.

Schließlich gibt es in der Literatur kein vollständiges Konzept, das die Umfeldkartierung mit der objektbasierten Beschreibung so koppelt, dass beide Umfeldrepräsentationen voneinander profitieren. Wissenschaftliche Arbeiten wie [93] und [16] konzentrieren sich auf das Lösen des SLAM-Problems oder die Erkennung dynamischer Hindernisse mit Hilfe der Belegungskarte. Die in [13] und [18] gezeigte Ansätze zur Verfolgung dynamischer Hindernisse auf einem Belegungsgrid erfordern einen hohen Rechenaufwand und benötigen einen aufwändigen Extraktionsschritt zur Erzeugung der Objektbeschreibung.

6.1.2 Konzept

Der verfolgte Ansatz sieht eine enge Kopplung der beiden Umfeldrepräsentationen vor. Die Objektverfolgung kann die Belegungskarte nutzen, um schnell und robust dynamische Hindernisse von stationären zu unterscheiden. Außerdem kann die Objektverfolgung von der zeitlichen Akkumulation der Rohdaten und von der detailreichen Hindernisbeschreibung in der Belegungskarte profitieren, falls die angenommenen Bewegungs- und Formmodelle nicht passend sind. Die Belegungskarte hingegen kann aus dem Modellwissen des Objekt-Trackers Nutzen erzielen, um die Bewegung dynamischer Hindernisse in der Karte zu kompensieren. Als Ergebnis der Kopplung resultieren Objekte und dazugehörige dynamische Zellen, die eine kompakte, detailreiche und einfach interpretierbare Beschreibung der dynamischen Hindernisse darstellen.

Für die Realisierung dieser Kopplung müssen folgende Voraussetzungen in der Belegungskarte und in der Objektverfolgung geschaffen werden:

- **Erweiterung der Belegungskarte um die Beschreibung dynamischer Hindernisse:** Der Einsatz der belegungskartenbasierten Umfelderkennung in Fahrerassistenzsystemen erfordert die Beschreibung der stationären und der dynamischen Hindernisse. Hierzu muss die Annahme, dass der Inhalt der Zellen in der Belegungskarte statisch ist, abgeschafft werden. Gegenüber der klassischen Belegungskarte aus der Robotik erfordert dies die Einführung der folgenden beiden Erweiterungen:
 1. **Robuste Erkennung dynamischer Zellen und Rohdaten:** Damit die zu bewegten Objekten gehörigen Sensorrohdaten und Zellen speziell behandelt werden, müssen sie zunächst als dynamisch (bewegt) erkannt werden. In Abschnitt 6.2 wird dieser wichtige Verarbeitungsschritt diskutiert.
 2. **Einführung von Mechanismen in der Belegungskarte zur Kompensation der Bewegung dynamischer Hindernisse:** Wurden bestimmte Zellen als bewegt erkannt und haben sie Objekt-Zustandsgrößen zugewiesen bekommen, so müssen die Zellen zwischen zwei Aktualisierungsschritten entsprechend ihrer Bewegung in der Karte geschoben werden. Mit Hilfe dieser Dynamikkompensation verschwinden die charakteristischen „Schweife“ dynamischer Hindernisse aus der Belegungskarte. Außerdem wird durch die fortlaufende Prädiktion der dynamischen Zellen und der Aktualisierung der Belegungskarte eine Akkumulation der Objektform erzielt (s. Abschnitt 6.4).

Zum Verständnis der notwendigen Schritte für die Behandlung dynamischer Objekte wird die mathematische Formulierung des Kartierungsproblems vom Abschnitt 2.3.3 in Kapitel

2 um die Berücksichtigung dynamischer Hindernisse erweitert. Die binäre Zufallsvariable $D_k^{\mathbf{X}}$ wird eingeführt. Sie beschreibt den Dynamikzustand der Zelle mit den ortsfesten Koordinaten \mathbf{X} , d. h. $D_k^{\mathbf{X}} \in \{\text{statisch}, \text{bewegt}\}$. Neben der Berücksichtigung der Änderung der Fahrzeugposition muss daher auch der Dynamikzustand der Zelle betrachtet werden.

$$p(O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k-1}) = \sum_{D_k^{\mathbf{X}}} p(O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k-1}, D_k^{\mathbf{X}}) \cdot p(D_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k-1}) \quad (6.1)$$

Falls die Zelle dynamisch ist, so ist es erforderlich, die Abhängigkeit von der alten Position des dazugehörigen Objekts miteinzubeziehen. Sei \mathbf{X}_{k-1} die alte Position auf der Karte, die die Belegung der Zelle mit den Koordinaten \mathbf{X} enthalten hat. $O_{k-1}^{\mathbf{X}_{k-1}}$ sei entsprechend die Belegung der Zelle \mathbf{X}_{k-1} . Mit Hilfe des Satzes der totalen Wahrscheinlichkeit kann die zusätzliche Abhängigkeit eingeführt werden.

$$p(O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k-1}, D_k^{\mathbf{X}} = \text{bewegt}) = \int P_1 \cdot P_2 dO_{k-1}^{\mathbf{X}_{k-1}} \quad (6.2)$$

$$P_1 = p(O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k-1}, D_k^{\mathbf{X}} = \text{bewegt}, O_{k-1}^{\mathbf{X}_{k-1}}) \quad (6.3)$$

$$P_2 = p(O_{k-1}^{\mathbf{X}_{k-1}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k-1}, D_k^{\mathbf{X}} = \text{bewegt}) \quad (6.4)$$

- **Bereitstellen von Modellwissen durch die Objektverfolgung:** Die Belegungskarte verfügt über keine modellbasierte Schätzung der Objektzustände. Damit die Bewegung dynamischer Zellen in der Belegungskarte kompensiert wird, müssen deren Dynamikgrößen wie Geschwindigkeit und Beschleunigung vom Objekt-Tracker zur Verfügung gestellt werden.
- **Einführung von Zwangskopplungen zur Sicherung der Datenkonsistenz:** Bei der Kombination der Belegungskarte mit der Objektverfolgung ist es besonders wichtig, dass die Daten in beiden Komponenten zueinander konsistent gehalten werden. Zu jedem aus Sensorrohdaten stammenden Objekt existiert eine Liste dynamischer Zellen. Alte, nicht bestätigte Zellen werden von der Liste entfernt. Wird ein Objekt durch die Objektverwaltung gelöscht, so werden die dazugehörigen Zellen zurückgesetzt. Außerdem muss die zeitliche Konsistenz der Daten (Objektliste und dazugehörige Zellen) aus beiden Repräsentationen sichergestellt werden. Dies kann erreicht werden, indem beide Module ihre generierten Daten zum gleichen Zeitpunkt und mit gleicher Rate generieren.
- **Integration des Kartenwissens in die Objektverfolgung:** In der Belegungskarte entsteht eine zeitliche Akkumulation der Objektform. Damit die Objektverfolgung von dieser rohdattennahen Beschreibung profitieren kann, muss dieses Wissen in die Objektverfolgung zur Korrektur der Objektzustände zurückfließen. In diesem Fall fungiert die Belegungskarte als virtueller Sensor für die Zustandsschätzung. Hierfür werden in Abschnitt 6.5 geeignete Mechanismen beschrieben.

Abbildung 6.1 fasst das Konzept zusammen. Hier sind Signalpfade zwischen den beiden Systemkomponenten dargestellt. Außerdem sind die wichtigsten Schritte zur Umfeldkartierung und Objektverfolgung aufgeführt.

Das entwickelte Konzept wurde im Rahmen der vorliegenden Arbeit in [Bouzouraa 2010] und [Bouzouraa 2011] vorgestellt. Es eröffnet neue Möglichkeiten zum Erreichen einer robusten und konsistenten maschinellen Umfeldwahrnehmung für Fahrerassistenzsysteme. Ideen zu diesem Zweck werden im Kapitel 9.2 als Ausblick vorgestellt und kurz diskutiert.

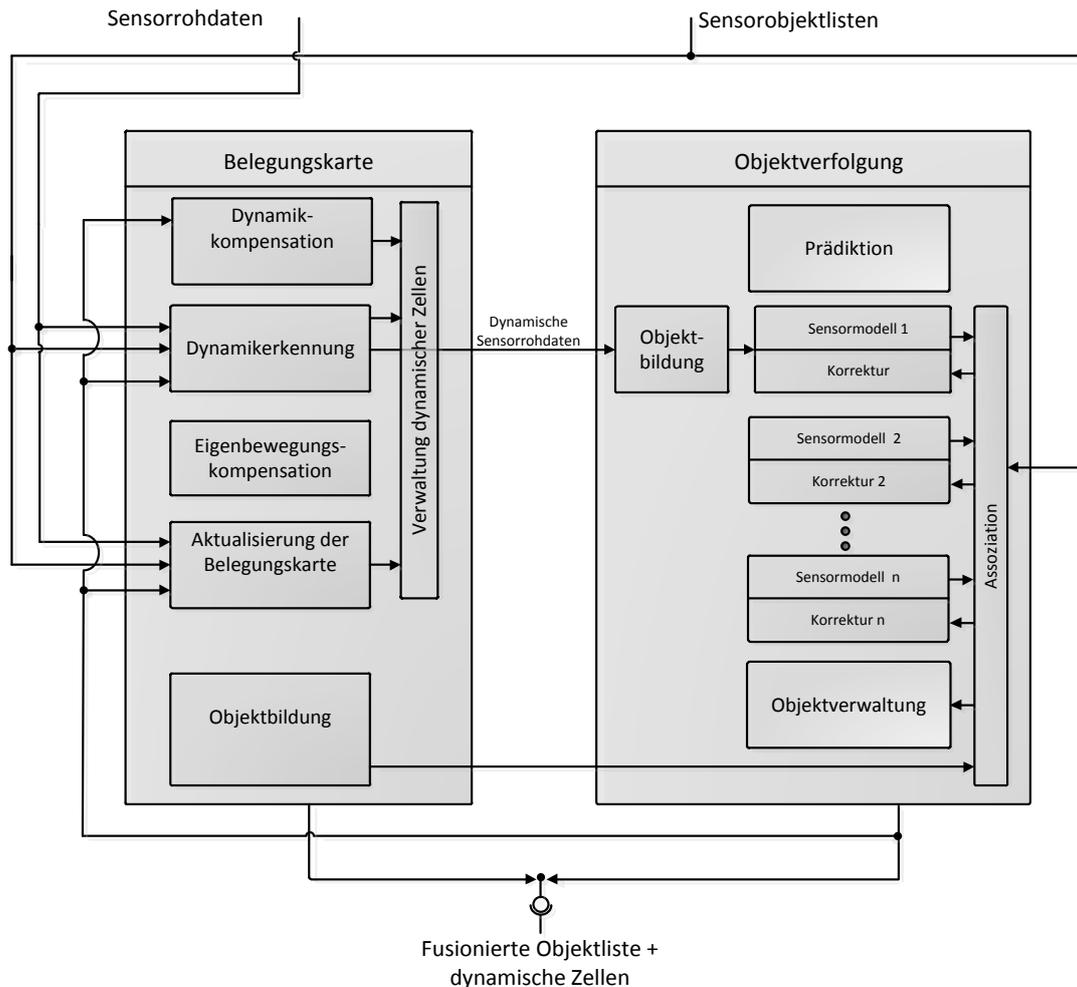


Abbildung 6.1: Kopplung der Belegungskarte mit der Objektverfolgung

6.2 Robuste Dynamikklassifikation mit Hilfe der Belegungskarte und von Rohdaten

Ziel der Dynamikklassifikation ist die Bestimmung der Wahrscheinlichkeit, dass der Inhalt einer Zelle gegeben der Bewegungsdaten des Eigenfahrzeugs und der alten Messungen

($p(D_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k-1})$) zu einem bewegten Objekt gehört. Da die alte Belegungskarte das Wissen über alte Messungen beinhaltet, entspricht die Dynamikklassifikation der Ermittlung der Wahrscheinlichkeit

$p(D_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, M_{k-1})$. Als Vereinfachung des Problems kann die Aufgabe auf die Bestimmung der Information, ob die Zelle und die dazugehörige Messung dynamisch, statisch oder unbekannt sind, zurückgeführt werden.

Prinzipiell gibt es verschiedene Informationsquellen zum Erkennen bewegter Hindernisse:

- Zum einen können geschwindigkeitsmessende Sensoren wie ein Radar-Sensor eine Information über den Dynamikzustand der gemessenen Hindernisse liefern. Dabei wird die zum Eigenfahrzeug relative Geschwindigkeit gemessen. Mithilfe der Eigenbewegungsdaten können die gemessenen relativen Dynamikgrößen in absolute Größen umgerechnet werden. Für die Übertragung dieser Information auf einem Belegungsgitter ist ein geeignetes inverses Sensormodell notwendig, wie in dieser Arbeit für die Radarsensoren entwickelt und in Kapitel 4.1.5 beschrieben wurde.
- Als weitere Quelle für die Erkennung dynamischer Hindernisse eignet sich die Liste der verfolgten Objekte und ihre Historie. Mit Hilfe der Schätzmechanismen der Objektverfolgung wird die Objekt-Geschwindigkeit bestimmt. Außerdem liefert die Historie der Objekte einen wichtigen Hinweis über die Räume in der Fahrzeugumgebung, die von dynamischen Objekten befahren werden.
- Falls nur die Messrohdaten (Reflexionspunkte) und die daraus generierte Belegungskarte für die Erkennung dynamischer Hindernisse eingesetzt werden, so kann auf Differenzbildungsmechanismen zurückgegriffen werden. Die Grundidee der Differenzbildung besteht im Vergleich der gesammelten Historie über die Umgebung mit neu gemessenem Wissen. In der Arbeit wurden die zu vergleichenden Informationsquellen variiert (Belegungskarte, Messrohdaten, segmentierte Rohdaten), so dass verschieden Differenzbildungsmechanismen für den zweidimensionalen Fall untersucht werden konnten [Weiherer 2009].

Die oben aufgeführten Informationsquellen können prinzipiell fusioniert werden, um bewegte Zellen von statischen zu unterscheiden. Der Schwerpunkt der Arbeit liegt aber auf den Differenzbildungsmechanismen, da diese aus Sicht der Belegungskarte unabhängige Methoden gegenüber der Objektverfolgung und geschwindigkeitsmessender Sensoren darstellen.

6.2.1 Differenzbildung zwischen Laser-Rohdaten

Grundprinzip

Ein einfacher Vergleich zwischen zwei aufeinanderfolgenden Lasermessungen \mathbf{y}_k und \mathbf{y}_{k-1} kann bereits Hinweise auf das Vorhandensein von dynamischen Objekten liefern. Treffen in einer Region mehrere Laserstrahlen auf ein Hindernis, obwohl bei der vorherigen Messung dort kein Objekt festgestellt wurde, ist das erkannte Hindernis wahrscheinlich dynamisch. Dadurch können die Kanäle der aktuellen Lasermessungen $\mathbf{y}_k = \{y_{1,k}, \dots, y_{N,k}\}$ in Messungen von statischen Hindernissen $y_{i,k}^{stat}$ und dynamischen $y_{i,k}^{dyn}$ Objekten unterteilt werden. Zur Vereinfachung wird

angenommen, dass eine Messung einem Punkt in der Mitte des Öffnungswinkels des jeweiligen Kanals gleicht.

Der Vergleich erfolgt in verschiedenen Schritten:

1. Zunächst werden die alten \mathbf{y}_{k-1} und neuen Sensorrohdaten \mathbf{y}_k in ein gemeinsames Koordinatensystem z. B in das Umfeldkoordinatensystem transformiert.
2. Da sich zwischen den Zeitschritten $k - 1$ und k dem Eigenfahrzeug fortbewegt hat, muss die Eigenbewegung in den alten Sensordaten kompensiert werden. Dadurch entsteht eine Erwartung $\tilde{\mathbf{y}}_k$ aufgrund der Eigenbewegung an die neuen Sensormessungen.
3. Im letzten Schritt findet eine Assoziation der neuen Sensordaten mit der Erwartung aus den alten Daten statt. Eine einfache Strategie wäre der Vergleich der Messdaten von jeweils gleichen Kanälen (D.h. Sensorstrahlwinkeln) in beiden Messungen. Allerdings kann vorkommen, dass dasselbe Objekt aufgrund der relativen Bewegung zum Eigenfahrzeug in aufeinander folgenden Messungen von unterschiedlichen Kanälen erfasst wird. Deshalb wird für jeden aktuellen Messpunkt ein minimaler Abstand zu einem Punkt aus den neuen Messungen bestimmt. Ein Messpunkt wird dann als bewegt klassifiziert, wenn der dazugehörige minimale Abstand über einem gewissen Schwellwert liegt. Liegt hingegen ein Punkt in der Nähe eines alten Punktes, wird der Punkt als statisch betrachtet. Der Dynamikzustand der restlichen Punkte wird als unbekannt klassifiziert. Die Idee ist leicht erweiterbar für den dreidimensionalen Fall.

Bewertung

Der Vorteil des einfachen Vergleichs von Lasermesspunkten liegt hauptsächlich in der niedrigen Laufzeit-Komplexität. Außerdem ist das Verfahren frei von Diskretisierungseffekten im Gegensatz zu anderen Methoden, die ein Belegungsgitter einsetzen.

Durch die vereinfachte Betrachtungsweise ergeben sich jedoch einige erhebliche Einschränkungen bei der Genauigkeit und Zuverlässigkeit des Verfahrens. Zum einen werden Messpunkte, die keinem alten Punkt zugeordnet werden konnten, grundsätzlich als bewegt klassifiziert. Dies liegt an der fehlenden Modellierung der Zustände frei, unbekannt und belegt. Ein weiteres Problem stellt die fehlende Berücksichtigung der Laser-Kanalbreiten aufgrund der Laser-Strahldivergenz.

6.2.2 Differenzbildung zwischen generierten Laser-Segmenten

Grundprinzip

Eine Weiterentwicklung des einfachen Vergleichs von Laserrohdaten zur Erkennung dynamischer Objekte stellt der Vergleich von Objekt-Hypothesen dar, die aus den Messdaten generiert werden. Ein geläufiges Vorgehen ist dabei die Extraktion von geometrischen Primitiven aus den Lasermesspunkten, wie etwa in Kapitel 4.1.3 durch Verwendung von linearen Segmenten vorgestellt wurde. Auch hier findet vor der eigentlichen Differenzbildung eine Kompensation der Eigenbewegung statt.

Um die Ähnlichkeit von zwei berechneten Linien angeben zu können, kann beispielsweise der quadrierte Abstand der Anfangs-, Mittel- und Endpunkte beider Linien berechnet werden. Nach der Festlegung eines Schwellwertes für die Abstände können die Segmente in bewegte und statische Objekte klassifiziert werden.

Bewertung

Die Ergebnisse der Differenzbildung auf Basis der Laser-Segmente hängen stark von der Güte der Segmentierung und der Segment-Assoziation ab. Außerdem liefert die Methode fehlerhafte Klassifikation in Szenarien, wo sich geometrische Primitive, vor allem lineare Segmente, nur bedingt zur Beschreibung von Konturen in der Umgebung eignen (z.B. städtische Umgebung).

Gute Ergebnisse hingegen werden in strukturierten Umgebungen erzielt, bei denen die Segmentbeschreibung sich gut eignet. In Grafik 6.2 ist ein solches Szenario abgebildet. Schwarze Linien signalisieren statische Objekte, vorausfahrende Fahrzeuge sind in grün dargestellt.



Abbildung 6.2: Ergebnisse der Differenzbildung auf Basis Laser-Segmente

6.2.3 Differenzbildung zwischen Belegungskarte und Rohdaten

Grundprinzip

Die Idee der Differenzbildung zwischen einer generierten Belegungskarte und Sensorrohdaten wurde bereits in vielen wissenschaftlichen Arbeiten wie [40], [41], [92] und [73] für die Detektion dynamischer Objekte eingesetzt. In der vorliegenden Arbeit wird den Ansatz hinsichtlich Robustheit und Berücksichtigung der Effekte seriennaher Laserscannersensoren (Rauschen, Strahldivergenz bzw. Unschärfe, niedrige Auflösung) erweitert.

Bei der Differenzbildung mithilfe der Belegungskarte wird zunächst die Eigenbewegung auf der Karte kompensiert, so dass eine Erwartung an die Umgebung des Fahrzeugs aufgrund seiner

Positionsänderung generiert werden kann. Das entspricht der Bestimmung der Wahrscheinlichkeit $p(O_k^X | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k-1})$ für jede Zelle. Danach werden die Lasermesspunkte (Reflexionspunkte in der Mitte der Kanäle) auf die Belegungskarte projiziert. Alle Messungen, die auf Zellen mit Belegungswahrscheinlichkeit über einem bestimmten Schwellwert treffen, werden als statisch klassifiziert. Messungen, die einem niedrigen Wahrscheinlichkeitswert entsprechen, werden als dynamisch erkannt. Die restlichen Messdaten werden als unbekannt eingestuft. Die Methode ist auch im Fall einer dreidimensionalen Belegungskarte und Rohdaten anwendbar. Hierfür werden die 3D-Rohdaten bestimmten *Voxels* auf der Belegungskarte zugeordnet.

Modellierung der Unsicherheit und der Strahldivergenz

Aufgrund der Unschärfe in den Kanälen des eingesetzten 2D-Laserscanner (s. Abschnitt 2.1.2) wird die Messung als eine Linie modelliert, welche die gesamte Breite eines Kanals abdeckt. Die Annahme, dass das detektierte Objekt in der Mitte des Kanals liegen muss, kann bei großen Reichweiten zu einer falschen Interpretation der Messungen führen. Abbildung 6.3 verdeutlicht die unterschiedlichen Betrachtungsweisen anhand von Messungen innerhalb zwei benachbarter Kanäle.

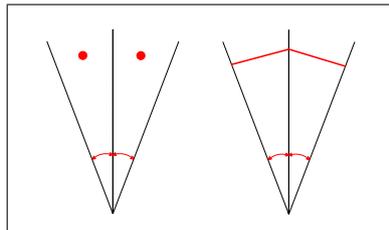


Abbildung 6.3: Verschiedene Interpretationen von Lasermessungen, links ohne, rechts mit Divergenz

Durch die Berücksichtigung der Strahldivergenz des Sensors erweitert sich die Differenzbildung zu einem Vergleich zwischen dem Belegungsgitter und einer Linie. Hierzu werden die Anfangs- und Endpunkte der gemessenen Linien bestimmt. Anschließend wird die Linie gemäß der Diskretisierung der Belegungskarte mit Hilfe des Bresenham-Algorithmus (s. Anhang D) gerastert. Dieser Schritt ist vergleichbar mit dem Eintragen der Messungen auf der Belegungskarte (s. Abschnitt 4.1.4).

Um den Einfluss von Diskretisierungsfehlern und ungenauen Messungen oder von Fehlern in der Eigenbewegungsschätzung bei der Erkennung von dynamischen Objekten zu mindern, können die gerasterten Linien zu größeren Regionen erweitert werden. Ein allgemeines Verfahren zum Erweitern von Regionen in Binärbildern stellt die sogenannte Dilatation dar ([85]). Mathematisch gesehen wird dabei die Minkowski-Summe aus einer Region R und einem strukturierendem Element S gebildet:

$$R \oplus S = \{r + s \mid r \in R, s \in S\} \quad (6.5)$$

Anschaulich bedeutet dies, dass an jedem Bildpunkt r der Region R das Element S eingefügt und

somit die Form von R ausgedehnt wird. Um eine einfache Erweiterung der gemessenen Linien um ein Pixel in alle Richtungen zu erreichen, kann als strukturierendes Element ein Kreuz aus jeweils drei Pixeln gewählt werden. Folglich wird für jedes Pixel der gerasterten Linie eine Vierer-Nachbarschaft berechnet. Dieser Vorgang ist in Abbildung 6.4 verdeutlicht. Für die 2.5D Karte und die 3D Intervallkarte wären die Zellen, die die Höhenwerte enthalten sowie deren 4er- oder 8er-Nachbarschaft von Bedeutung. Für die 3D Karte wird die Nachbarschaft des betrachteten Voxels für den Vergleich miteinbezogen.

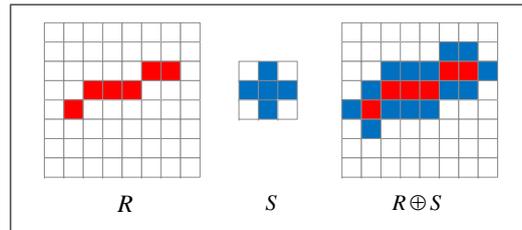


Abbildung 6.4: Dilatation von gerasterten Linien

Im nächsten Schritt werden die Belegungswahrscheinlichkeiten der ermittelten Zellen nach dem folgenden Schema interpretiert:

- Gibt es im zu analysierenden Gebiet mindestens eine belegte Zelle, so wird davon ausgegangen, dass es sich hierbei um die Messung eines **statischen Objekts** handelt. Dieses Objekt wird durch die Messung bestätigt.
- Sollte es keine belegte Zelle im zu analysierenden Bereich geben, so wird der durchschnittliche Belegungswert in diesem Bereich berechnet. Sollte der Durchschnittswert unter einer festgelegten Schwelle liegen, der Bereich der Nachbarschaft also als frei gelten, so handelt es sich wahrscheinlich um eine **dynamische Messung**. Die dazugehörigen Zellen werden bei der Aktualisierung der Belegungskarte entsprechend gesetzt.
- Trifft keine der beiden vorherigen Aussagen zu, kann aufgrund der Informationen der Karte noch keine Unterscheidung vorgenommen werden. Die Messung und die dazugehörigen Zellen sind potentielle Kandidaten für ein dynamisches Hindernis. Es könnte sich hierbei aber genauso gut um ein statisches Objekt handeln, das soeben in den Sichtbereich des Sensors eingetreten ist und damit zum ersten Mal in die Karte eingetragen wird. Die Messungen werden als potentiell **dynamisch** bzw. **unbekannt** eingestuft.
- Bereiche in der Belegungskarte, die bis jetzt als belegt gegolten haben, dessen Belegungswert im Rahmen der Freiraum-Aktualisierung der aktuellen Messung aber plötzlich verringert werden, werden als „**alt-dynamisch**“ markiert. In diesem Fall könnte es sich um Objekte handeln, die sich von ihren ursprünglichen Aufenthaltsorten weg bewegt haben, und damit als dynamisch gelten.

Generell können die Abweichungen zwischen den festgestellten Belegungswahrscheinlichkeiten und den festgelegten Schwellen als Maß für die Berechnung einer Wahrscheinlichkeit für die getroffene Aussage über den Dynamikzustand verwendet werden.

Die einzelnen Regeln zur Bestimmung des Dynamikzustandes von Messpunkten und Zellen sind in Tabelle 6.1 zusammengefasst.

		Belegungskarte		
		frei	unbekannt	belegt
Messung	belegt	dynamischer Messpunkt bzw. Zelle	potentiell dynamischer Messpunkt bzw. Zelle	statischer Messpunkt bzw. Zelle
	frei	freie Zelle	freie Zelle	alte dynamische Zelle

Tabelle 6.1: Regeln zur Bestimmung dynamischer Messpunkte und Zellen

Bewertung

Durch die Interpretation der Unschärfe in den Lasermessungen lässt sich ein Teil der Fehlklassifikationen des einfachen Vergleichs mit Messpunkten ausschließen. So werden bei diesem Verfahren auch Messungen, die nur im Randbereich eines Kanals auf ein bisher bekanntes Objekt treffen, als statisch klassifiziert. Die Methode bringt auch zusätzliche Robustheit mit sich, da sie auf die Belegungskarte zurückgreift. Die Belegungskarte enthält eine Reihe von Messungen, die sich zeitlich bestätigt haben.

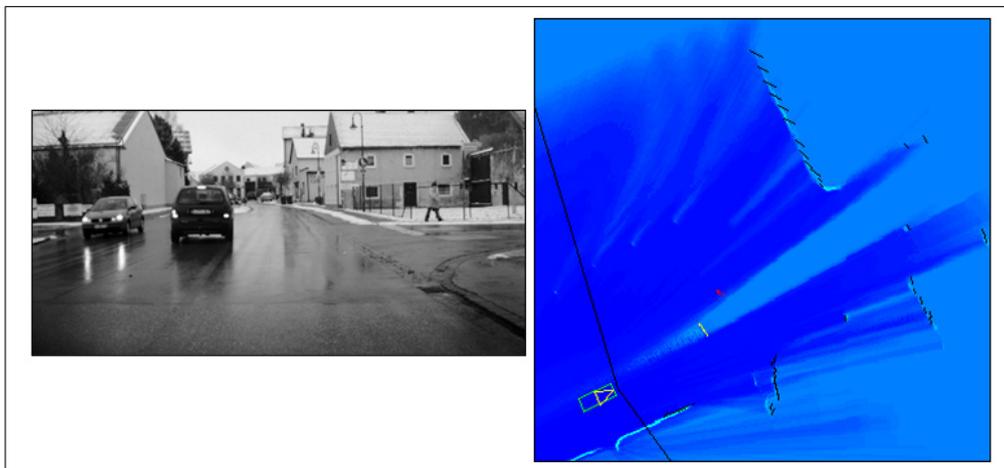


Abbildung 6.5: Vergleich zwischen Belegungskarte und defokussierter Lasermessung

Durch die im vorherigen Abschnitt beschriebene Dilatation der gerasterten Linien lassen sich zusätzlich die Einflüsse von Sensorrauschen und Fehler in der Eigenbewegung minimieren. Allerdings führt eine zu große Erweiterung der gerasterten Linien bei bestimmten Situationen (wenn z.B. ein bewegtes Objekt in der Nähe eines statischen Hindernisses sich befindet) auch zu Fehlern bei der Erkennung dynamischer Objekte. Abbildung 6.5 zeigt exemplarisch das Ergebnis eines Vergleichs zwischen defokussierter Lasermessung und zuvor erstellter Belegungskarte. Alle als statisch eingeordnete Messungen werden durch schwarze Striche markiert. Das entgegenkommende Fahrzeug wird als dynamisch klassifiziert und rot dargestellt. Über das vorherfahrende Auto kann aufgrund der Information der Belegungskarte noch keine Aussage getroffen werden,

es wird gelb dargestellt.

Die Methode leidet in seltenen Fällen über nicht hinreichend akkumulierten Daten in der Belegungskarte vor allem im Randbereich, so dass stationäre Hindernisse nicht richtig klassifiziert werden können.

6.2.4 Differenzbildung zwischen Belegungskarte und Segmenten

Grundprinzip

Analog zum Vorgehen bei der Differenzbildung zwischen Rohdaten und Belegungskarte können auch segmentierte Laser-Rohdaten betrachtet werden. Der Vergleich erfolgt in folgenden Schritten:

- Zunächst wird die Eigenbewegung $\mathbf{X}_{k-1:k}^{ego}$ auf der alten Belegungskarte M_{k-1} kompensiert.
- Danach werden die Laser-Rohdaten mit Hilfe des in 4.1.3 vorgestellten Segmentierungsverfahrens zu linearen Segmenten transformiert.
- Anschließend werden die generierten Linien auf der Belegungskarte projiziert und mit Hilfe des Bresenham-Algorithmus gerastert.
- Der mittlere Belegungswert der aus den Regressionslinien ermittelten Zellen wird berechnet. Ist dieser Wert unter einer Schwelle, werden das Segment, die dazugehörigen Kanäle und Zellen als bewegt klassifiziert. Ist der Belegungswert hoch, werden sie hingegen als statisch markiert.

Bewertung

Auch hier sind die Ergebnisse wie beim Segment-Segment Vergleich 6.2.2 stark abhängig von der Qualität der Segmentierung. Da außerdem Regressionslinien meist nur eine unzureichende Vereinfachung der tatsächlichen Objektkonturen darstellen, werden bei der Rasterung der Linie oft Kartenbereiche untersucht, die nicht zum Objekt gehören. Die Methode profitiert aber von der zeitlichen Filterung der Sensordaten durch die Karte, so dass sie insgesamt robuster als der einfache Segment-Segment Vergleich. Abbildung 6.6 zeigt eine beispielhafte Szene, bei der die Differenzbildung zwischen Belegungskarte und Laser-Segmenten gute Ergebnisse liefert. Hier ist möglich das vorausfahrende Fahrzeug durch Zuordnung des Segments zu der Historie des Fahrzeugs als bewegt zu erkennen und ihm eine Geschwindigkeit zuzuordnen.

6.2.5 Zusammenfassung der Ergebnisse und Erkenntnisse

Um eine quantitative Aussage über die Leistungsfähigkeit der Algorithmen zu erhalten, wurde eine statistische Auswertung für den zweidimensionalen Fall hinsichtlich der Erkennungsrate des Dynamikzustands sowie der benötigten Rechenzeit durchgeführt.

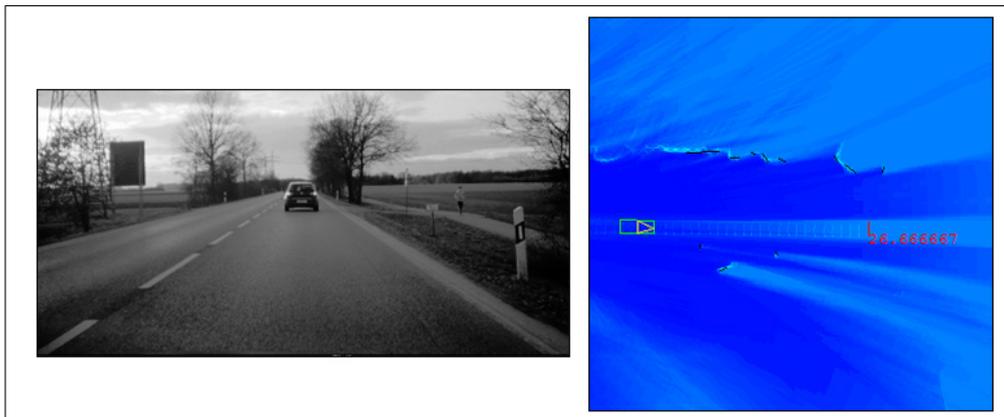


Abbildung 6.6: Vergleich zwischen Belegungskarte und extrahierten Linien

Aufgrund der fehlenden „Ground-Truth“ wurden die Algorithmen manuell referenziert. Durch die Zuhilfenahme der Daten der im Fahrzeug installierten Kameras lässt sich der Anteil der korrekt klassifizierten statischen und dynamischen Objekte in einzelnen Szenen abschätzen. Um die generelle Eignung der Verfahren zu untersuchen, wurde der Testdatensatz in gleich bleibenden Zeitintervallen ausgewertet und die Ergebnisse abschließend gemittelt.

Als Testdatensatz wurde eine Fahrt im Stadtgebiet mit zahlreichen vorausfahrenden und entgegenkommenden Fahrzeugen verwendet. Die Aufnahme dauert etwa 60 Sekunden und wurde in Abständen von 1 Sekunde ausgewertet. Die so gewonnenen Daten können zwar aufgrund der begrenzten Statistik nicht als allgemeingültige Auskunft für die Zuverlässigkeit und Genauigkeit eines Verfahrens angenommen werden, liefern aber für das untersuchte Szenario einen guten Hinweis auf die Unterschiede zwischen den angewandten Strategien und bestätigen die im vorherigen Abschnitt erwähnten Effekte und Erkenntnisse. Tabelle 6.2 fasst die ermittelten Ergebnisse zusammen.

Verfahren	Laufzeit in ms	Erkennungsrate statische Objekte	Erkennungsrate dynamische Objekte
Rohdaten-Rohdaten	0,24	86 %	71 %
Segment-Segment	0,47	61 %	45 %
Karte-Rohdaten	0,27	86 %	82 %
Karte-Rohdaten erweitert	0,38	94 %	96 %
Karte-Segment	0,27	84 %	45 %

Tabelle 6.2: Ergebnisse der statistischen Auswertung

Die Ansätze, die die Laser Segmente einsetzen, sind stark abhängig von der Eignung der Segmentierungsmodelle. Zwar verhilft dieses zusätzliche Modellwissen in geeigneten Szenarien (z.B. Randbebauung und Häuser-Wände) die Robustheit der Dynamikerkennung zu erhöhen, führt aber zu fehlerhaften Klassifikationen in weiteren Szenen, wo die Beschreibung der Hindernisse durch Linien ungeeignet ist. Aus der Tabelle lässt sich außerdem anmerken, dass die Differenzbildungsverfahren, die auf der Belegungskarte beruhen, in der Regel, robuster sind. Die besten

Ergebnisse liefert der Vergleich zwischen Rohdaten und Belegungskarte mit Modellierung der Sensordivergenz und weiteren Fehlerquellen. Dieses Verfahren bildet die Grundlage für die nächsten Schritte der Objektbildung und Verfolgung.

6.3 Objektbildung und Verfolgung

Die Objektbildung und Verfolgung stellt in der Arbeit keinen Schwerpunkt dar, da das Ziel in der Umsetzung des Konzepts aus Sicht der Belegungskarte besteht. Aus diesem Grund werden aus der Literatur bekannte Methoden eingesetzt. In den folgenden Abschnitten werden die Schritte der Gruppenbildung, der Zustandsextraktion und der Objektverfolgung kurz beschrieben.

6.3.1 Gruppierung der klassifizierten Rohdaten

Nach der Unterteilung der Sensorrohdaten in die drei Klassen statisch, bewegt und unbekannt, werden sie gruppiert. In diesem Schritt werden dynamische oder unbekannte Rohdaten markiert, die zum selben Objekt gehören. Für den zweidimensionalen Fall kann die „*Adaptive Breakpoint Detector*“-Methode [4] eingesetzt, die bereits in Kapitel 4.1.3 beschrieben wurde. Für den dreidimensionalen Fall gestaltet sich die Gruppierung etwas aufwändiger. Hier kann ein Gruppierungsverfahren mit Hilfe eines Abstandskriteriums verwendet werden, wie etwa in [54] präsentiert wurde. Hierzu wird die Liste aller nicht-statischen Messpunkte sequentiell abgearbeitet. Dabei wird für jeden Punkt überprüft, ob einer seiner bereits gruppierten Vorgänger innerhalb eines definierten Abstandes zu ihm liegt. Sollte dies der Fall sein, so wird der aktuelle Punkt der gleichen Gruppe zugeordnet wie dieser Vorgänger. Sollte keiner der Vorgängerpunkte innerhalb dieses Abstandes zum aktuell betrachteten Punkt liegen, so wird für den aktuellen Punkt eine neue Gruppe initialisiert. Abbildung 6.7 zeigt beispielhafte Ergebnisse aus der Gruppierung der als dynamisch klassifizierten 3D Rohdaten des 3D Laser-Sensors. Die drei vorausfahrenden Fahrzeuge werden in drei dynamische Gruppen aufgeteilt. Die dazugehörigen Punkte sind in Grün dargestellt. Die restlichen Punkte haben die Farbe rot.

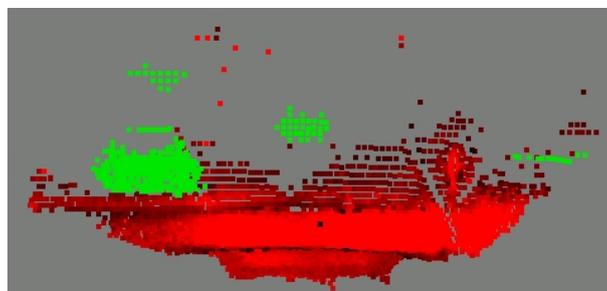


Abbildung 6.7: Ergebnisse der Gruppierung dynamischer 3D-Rohdaten

6.3.2 Zustandsextraktion aus gruppierten Rohdaten

Der nächste Schritt in der Objektbildung besteht in der Extraktion eines Messvektors, dessen Größen sich am festgelegten Formmodell für die zu verfolgenden Objekte anlehnen. In der Arbeit wird das Quadermodell (s. Kapitel 2.4.2) für die Objektrepräsentation eingesetzt. Deshalb werden aus den bereits gruppierten Rohdaten die Größen Position, Länge, Breite und Ausrichtung extrahiert. Dabei bezieht sich die extrahierte Position auf einen Bezugspunkt auf dem Quader. Hierzu werden die möglichen Referenzpunkte im Vorfeld festgelegt und codiert. Abhängig von den sichtbaren Objektflächen entscheidet sich die Zustandsextraktion für einen Referenzpunkt, der aus Sensorsicht das beste Wissen darstellt. Die Interpretation der Messdaten und die Umrechnung der Positionsdaten in eine für die Objektverfolgung zentrale Repräsentation ist eine Aufgabe der Assoziation.

Für die Objektbildung aus 2D-Rohdaten wird das Segmentierungsverfahren vom Kapitel 4.1.3 verwendet. Um dieses robuste Verfahren auf die dreidimensionalen Punktwolken sinnvoll anwenden zu können, wird nur ein Teil der 3D Reflexionspunkte betrachtet. Die Punkte, die innerhalb einer bestimmten Höhenschicht liegen, in der ein möglichst geschlossener und rechteckiger Umriss der Fahrzeuge erwartet wird, werden einer zweidimensionalen Segmentierung unterzogen. Nach der Generierung der linearen Segmente werden Paare aus zusammenhängenden und zueinander orthogonalen Segmenten zur Bildung eines „*L-Shapes*“ gesucht. Aus diesem „*L-Shapes*“ kann dann eine Breite, Länge und Ausrichtung berechnet werden.

In Abbildung 6.8(a) wird das nah einscherende Fahrzeug vom Laserscanner erfasst. Aus den als bewegt klassifizierten 2D Laser-Daten wird ein Quader gebildet. Dem Objekt wird ein Referenzpunkt zugewiesen, auf den sich die Positionsdaten des Objektes beziehen. Abbildung 6.8(b) zeigt das Ergebnis der Annäherung durch Geradenstücke im dreidimensionalen Fall für zwei Fahrzeuge. Das weiter entfernte Fahrzeug ist dabei nur noch von hinten zu sehen und wird deshalb durch nur eine Gerade, in Dunkelblau dargestellt, angenähert. Das andere Fahrzeug wird von schräg hinten vom Sensor erfasst. Folgerichtig nähert der Algorithmus die Punktwolke durch zwei in etwa senkrecht aufeinander stehende Geradenstücke an. Die für die Bestimmung der Geraden verwendeten Punkte sind hier in Hellblau dargestellt.

6.3.3 Multi-Objektverfolgung

Das entwickelte Konzept erweitert die Zustandsbeschreibung der Objekte um dynamische Zellen und ihre Belegungswahrscheinlichkeiten (s. Abbildung 6.9). Die dynamischen Zellen stellen eine genauere Beschreibung der Objektform als die groben Formmodelle wie das Quader-Modell dar. Außerdem profitiert die Objektverfolgung von der Dynamikdetektion, indem Fehllassoziationen mit statischen Objekten vermieden werden und indem geeignete Bewegungsmodelle gemäß des Dynamikzustands der Objekte ausgewählt werden. In der prototypischen Umsetzung des Konzepts beschränkt sich aber die Objektverfolgung auf die Schätzung der Zustände bewegter Objekte.

Für die Kalman-basierte Schätzung der Zustände Position, Geschwindigkeit und Beschleunigung wird ein *Constant Acceleration* Modell verwendet. Es ergibt sich folgender Zustandsvektor und

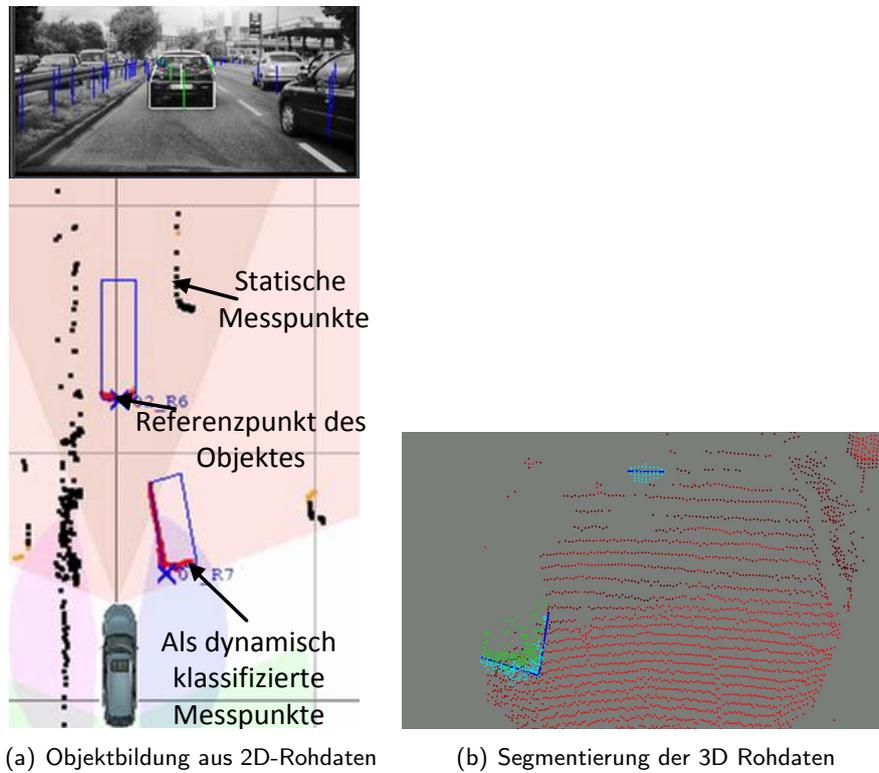


Abbildung 6.8: Ergebnisse aus der Zustandsextraktion

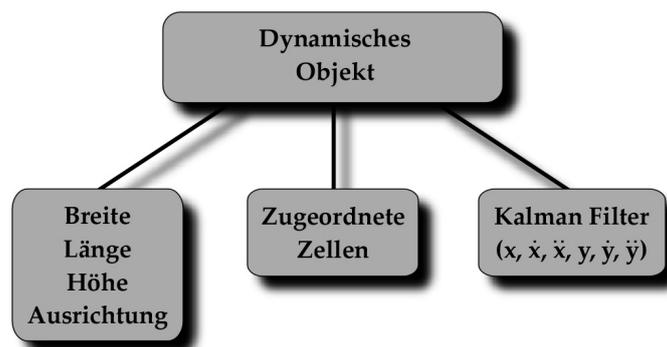


Abbildung 6.9: Bestandteile eines dynamischen Objektes

folgende Systemmatrix:

$$\mathbf{x} = [x, \dot{x}, \ddot{x}, y, \dot{y}, \ddot{y}]^T \quad (6.6)$$

$$A = \begin{pmatrix} 1 & \Delta T & \frac{1}{2}\Delta T^2 & 0 & 0 & 0 \\ 0 & 1 & \Delta T & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & \Delta T & \frac{1}{2}\Delta T^2 \\ 0 & 0 & 0 & 0 & 1 & \Delta T \\ 0 & 0 & 0 & 0 & 0 & 1 \end{pmatrix} \quad (6.7)$$

ΔT wird dabei entsprechend der Zykluszeit des Sensors gesetzt. Bei einem multisensoriellen System entspricht ΔT der Zykluszeit der Sensordatenfusion. Als Messgrößen dienen die aktuellen Koordinaten des aus den Messungen extrahierten Objekt-Bezugspunkts, in diesem Fall x und y , was zu folgender Messmatrix führt:

$$H = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \end{pmatrix} \quad (6.8)$$

Vor dem Einspeisen einer Messung erfolgt zunächst eine Assoziation mit den bestehenden Objekten. Dazu wird der Bezugspunkt der internen Repräsentation auf dem Bezugspunkt des Messobjektes umgerechnet (z.B. Vorne links auf Mitte hinten). Danach wird die Ähnlichkeit der Messung zu den internen Objekten ermittelt. Hierfür nutzt die Assoziation einen einfachen Ansatz mit einem Abstandskriterium. Der Ansatz ist bekannt unter dem Namen *Global Nearest Neighbour (GNN)* [72] und assoziiert das nächste Objekt zu der Messung. Falls keine Assoziation möglich ist, wird ein neues Objekt mit Verweis auf die dazugehörigen dynamischen Zellen initialisiert. Bei potentiell dynamischen Gruppen von Messpunkten wird überprüft, ob sich in deren unmittelbarer Nähe eine Gruppe von alten dynamischen Zellen befindet (s. Tabelle 6.1). Nur falls eine solche Menge von Zellen, die durchschossen wurden, existiert, wird für die betrachteten Gruppen von Messpunkten ein neues Objekt initialisiert. Objekte, denen keine Messung zugeordnet werden kann, werden nur über ihre Kalman-Filter prädiziert. Sollte ein Objekt über mehrere Zeitschritte hinweg nicht durch eine Messung bestätigt werden und seine Varianzen damit gewisse Schwellwerte übersteigen, wird dieses Objekt zunächst noch für ein paar Schritte im Speicher mitgeführt, ohne ausgegeben zu werden, dann aber schließlich gelöscht. Gleichzeitig wird die dazugehörige Liste dynamischer Zellen gelöscht und die entsprechenden Stellen auf der Belegungskarte zurückgesetzt.

Die geometrischen Größen des Objekts (Länge, Breite, Höhe) werden über laufende Mittelwertbildung geschätzt. Die Trägheit der Mittelwertbildung für die Schätzung der Größen Länge, Breite und Höhe hängt dabei vom Vorzeichen der Abweichung zwischen dem alten Schätzwert und der neuen Messung ab. D.h., wenn ein Wert für diese Größen über mehrere Schritte sich

bestätigt hat, dann wird er bei niedrigeren Messungen sehr langsam verringert. Dies hat den Grund, dass die eingesetzten Sensoren und Laser-Segmentierungsverfahren die Tendenz haben, die Ausdehnung der Objekte als zu klein zu erfassen.

6.4 Kompensation der Bewegung dynamischer Hindernisse auf der Belegungskarte

In diesem Unterkapitel werden die entwickelten Mechanismen auf Seite der Belegungskarte zur Behandlung dynamischer Hindernisse diskutiert. Dies beinhaltet zum einen die Verwaltung der dynamischen Zellen und zum anderen die Prädiktionsmechanismen der Belegung dynamischer Zellen.

6.4.1 Verwaltung der dynamischen Zellen und Verknüpfung zu der Objektliste

Bei dem verfolgten Ansatz existiert für jedes Objekt zusätzlich zu seinem Zustandsvektor eine Liste zugehöriger dynamischer Zellen mit Verweisen auf ihre Positionen und Belegungsdaten auf der Belegungskarte. Beim Initialisieren eines neuen Objektes wird auch die Liste der dynamischen Zellen erzeugt. Parallel werden auch innerhalb der Datenstruktur der Belegungskarte die betroffenen Zellen gekennzeichnet. Diese Zellen werden als bewegt markiert und erhalten als Attribut die „ID“ (Index) der Objekte, zu denen sie gehören.

Die Liste von Zellen, die zu einem Objekt gehören, wird dabei laufend aktualisiert. Bei der Aktualisierung der Karte mit Sensordaten werden die Belegungsdaten wie z. B. Belegungswahrscheinlichkeit sowohl auf der Belegungskarte als auch auf der am Objekt angehängten Zellen-Liste geändert. Treffen Sensor-Reflexionspunkte eines bewegten Objektes auf Zellen, die noch nicht zu diesem Objekt gehören, werden diese Zelle zur Liste hinzugefügt. Des Weiteren werden die Belegungszustände der Zellen überwacht, weil sie im Prädiktionsschritt gealtert werden. Sollte sich eine Zelle durch Messungen nicht bestätigen und ihr Belegungswert somit unter der Schwelle von 0.5 (unbekannt) fallen, dann gilt diese nicht mehr als belegt. Folgerichtig wird diese Zelle aus der Liste gelöscht.

6.4.2 Prädiktion dynamischer Zellen und Gruppen von Zellen mit Modellierung der Unsicherheit

Damit die Belegungskarte auch für die Beschreibung dynamischer Objekte geeignet wird, muss die Dynamik bewegter Objekte berücksichtigt werden. Die Dynamik der Objekte bedeutet, dass die Belegungen in der Belegungskarte zwischen zwei Zeitschritten ihre Positionen aufgrund der Bewegungen der Objekte ändern. Die Abhängigkeit von alten Belegungszuständen wurde bereits in Gleichung 6.2 hergeleitet. Allerdings lässt sich das Integral in Gleichung 6.2 sehr aufwendig berechnen, da sämtliche Übergangswahrscheinlichkeiten $p\left(O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k-1}, D_k^{\mathbf{X}} = bewegt, O_{k-1}^{\mathbf{X}}\right)$ berücksichtigt werden müssen.

Die Einführung bestimmter Annahmen und die Vorwärts-Betrachtung der Abhängigkeit zwischen $O_k^{\mathbf{X}}$ und $O_{k-1}^{\mathbf{X}^{k-1}}$ vereinfacht das Problem. Es wird angenommen, dass die neue Position jeder dynamischen Belegung aus einer Vorgänger-Zelle und der Nachbarschaft um diese alte Zelle entsteht. Außerdem wird zur Vereinfachung der Verarbeitung analog zur Kalman-Filterung ein Prädiktions-schritt eingeführt. In der Prädiktion wird eine Vorhersage über die neuen Positionen der zu dynamischen Objekten gehörigen Belegungsinformationen durchgeführt.

Damit noch nicht verarbeitete Zellen während des Prädiktionsvorgangs nicht überschrieben werden, werden alle dynamischen Zellen sequenziell abgearbeitet. Die neuen Positionen der Zellen aufgrund ihrer Bewegung werden in den an Objekten angehängten Listen gehalten, die am Ende der Abarbeitung auf die Belegungskarte übertragen werden. Des Weiteren werden die Belegungen der Zellen durch die Multiplikation mit der Wahrscheinlichkeit

$p\left(O_k^{\mathbf{X}} | \mathbf{X}_{k-1:k}^{ego}, \mathbf{y}_{1:k-1}, D_k^{\mathbf{X}} = bewegt, O_{k-1}^{\mathbf{X}^{k-1}}\right)$ gealtert. D. h., ihr Belegungswert wird mit jeder Prädiktion auf der Karte verringert. Die alte Zelle, die vom Objekt während der Prädiktion verlassen wurde, erhält einen niedrigen Wahrscheinlichkeitswert (kleiner als 0.5). Denn es wird angenommen, dass das Objekt nach seiner Bewegung einen Freiraum hinterlässt. Der verlassene Raum kann auch von einem anderen Objekt belegt werden. Die neue Position \mathbf{X}_k erhält die gealterte Belegungswahrscheinlichkeit, die als a-priori Wahrscheinlichkeit für die Bayes-Aktualisierung dient.

Zur Berücksichtigung der vorhandenen Unsicherheiten in den Dynamikgrößen (Geschwindigkeit und Beschleunigung) und im Bewegungsmodell während des Prädiktionsvorgangs könnten zwei Wege verfolgt werden. Zum einen kann bei der Prädiktion einer dynamischen Zelle die Belegungsinformation auf die Nachbarschaft der neuen Position erweitert werden. Bei der Übertragung der neuen Positionen auf der Belegungskarte werden die Beiträge aus den verschiedenen Vorgänger-Zellen gemäß dem Integral in Gleichung 6.2 aufsummiert. Zellen, die mehrere Vorgänger haben, erhalten somit eine höhere Prädiktionswahrscheinlichkeit. Ein alternativer Weg besteht in der zunächst einfachen Prädiktion jeder dynamischen Zelle ohne Erweiterung um neue Zellen. Nach der Prädiktion wird jedes Gebiet auf der Belegungskarte, das von einem dynamischen Objekt belegt ist, mithilfe des Dilatations-Verfahrens (s. Abschnitt 6.2.3) erweitert. In beiden Fällen kann auf die Schätzkovarianzen der Zustandsschätzung in der Objektverfolgung als Maß für die Unsicherheit in der Position zurückgegriffen werden.

Ein weiteres wichtiges Werkzeug, das die Prädiktion nutzt, ist die Subzellmodellierung der Belegung. Hierbei wird der Schwerpunkt der Belegung innerhalb der Zelle, wie bereits in Kapitel 4.1.1 erwähnt ist, als Attribut gemerkt. Mit diesem Mechanismus können kleine Bewegungen innerhalb einer Zelle aufgelöst und eine bessere Akkumulation der Objektform erzielt werden.

6.5 Belegungskarte als virtueller Sensor für die Objektverfolgung

Ein wichtiger Schritt in der Kopplung der belegungskartenbasierten Umfeldrepräsentation mit der objektbasierten Beschreibung besteht in der Nutzung der Belegungskarte für die Korrektur und Verbesserung der modellbasierten Objektverfolgung. Hierbei wird die Belegungskarte als ein virtueller Rohdaten-Sensor betrachtet, der die Form eines Objektes beschreibt. Im Gegensatz zu einer echten Messung \mathbf{y}_k aus einem Rohdaten-Sensor (z.B. ein Laser-Scan oder ein 3D

Tiefenbild) enthält die Belegungskarte M_k zum Zeitpunkt k das Wissen über alle Messungen $y_{1:k}$. Außerdem steht durch die Belegungswahrscheinlichkeiten ein Maß für die Zuverlässigkeit dieser virtuellen Messungen zur Verfügung. Durch die fortlaufende Anwendung der Prädiktion dynamischer Zellen und Aktualisierung der Belegungskarte mit echten Sensordaten akkumuliert sich die Objekt-Form. Die Beschreibung der Objekt-Geometrie in Form von akkumulierten Zellen stellt eine wertvolle Information dar, die aufgrund der Annahmen in der Objektverfolgung nur teilweise vorhanden ist. Diese zusätzliche Informationsquelle kann für die Verbesserung der Zustandsschätzung eingesetzt werden.

6.5.1 Extraktion einer Sensormessung aus der Belegungskarte

Prinzipiell können zwei Wege zur Integration des Wissens aus der Belegungskarte als Messung in die Objektverfolgung verfolgt werden:

- Bei der ersten Möglichkeit werden objektbeschreibende Merkmale aus der Belegungskarte extrahiert. Objektmerkmale sind z. B. bei Fahrzeugen Objekt-Kanten, Kontur-Linien oder Objekt-Ecken und ihre Positionen relativ zum Eigenfahrzeug. Mit einem geeigneten Messmodell findet eine Transformation der Zustände vom Zustandsraum in den Merkmalsraum statt. Das einfachste Messmodell entsteht, wenn die extrahierten Merkmale den zu schätzenden Objekt-Zuständen entsprechen.
- Als alternativer Weg kann direkt mit der zellenbasierten Beschreibung gearbeitet werden. D.h., es werden keine Merkmale aus der Belegungskarte extrahiert. Vielmehr wird die Zustandsbeschreibung in eine Zellenbeschreibung überführt. Somit ist dieser Weg ein Spezialfall der ersten Methode, bei dem die Merkmale gleich den Rohmessungen sind. Es entsteht eine Erwartung an die Objekt-Geometrie aufgrund des Objekt-Modells. Die Abweichung zwischen der erwarteten Messung und dem Zellen-Inhalt im Belegungsgitter wird als Residuum in der Kalman-Filterung eingespeist.

In der vorliegenden Arbeit wurde die Rückkopplung gemäß der ersten Methode realisiert. Mit Hilfe von ähnlichen Verfahren wie in Abschnitt 6.3.2 wird aus den dynamischen Zellen eines Objekts ein einhüllender Quader extrahiert. D.h., es findet eine Segmentierung der dynamischen Zellen bzw. Voxels statt. Diese Objekthypothese wird in der Objektverfolgung als Sensormessung behandelt.

6.5.2 Dekorrelation der zurückgespeisten Daten aus der Belegungskarte

Eine Voraussetzung für die korrekte Nutzung der Belegungskarte als virtueller Sensor für die Objektverfolgung ist die Durchführung einer Dekorrelation zwischen den extrahierten Messungen aus den Karten-Daten und der Zustandsbeschreibung der Objekte in der Objektverfolgung. Denn trotz der unterschiedlichen Verarbeitungsmechanismen stammen die Daten aus der Belegungskarte und der Objektverfolgung teilweise aus den gleichen Sensordaten. Außerdem steckt in den Messungen aus der Belegungskarte zum Teil das Wissen von der Objektverfolgung in Form von Modellwissen (Geschwindigkeit, Beschleunigung). Damit die Objektverfolgung von der Belegungskarte profitieren kann, dürfen nur noch nicht vorhandene Informationsanteile eingespeist

werden.

Auf dem Gebiet der Sensordatenfusion haben sich mehrere wissenschaftliche Arbeiten wie [14], [20] und [29] mit der Fusion von korrelierten Daten beschäftigt. In [15] wurden verschiedene Methoden vorgestellt, die eine Dekorrelation zwischen einzelnen Schätzfiltern durchführen. Diese Methoden finden Anwendungen in verteilten und hierarchischen Fusionsarchitekturen, die im Gegensatz zu einer zentralen Fusion aus einzelnen Schätzfiltern bestehen. Dabei können die Schätzergebnisse eines Filters in einen anderen Filter als Messung eingespeist werden. Als Konsequenz sind die Schätzfehler der zu kombinierenden Filter statistisch korreliert. Diese Methoden können nicht direkt für die vorliegende Aufgabe angewendet werden, da sie meistens nur für einzelne Kalman-basierte Zustandsschätzer geeignet sind. Zum Nutzen dieser Methoden wird ein lokaler Zustandsschätzer benötigt, der aus den extrahierten Karten-Messungen Objektzustände schätzt. Im Folgenden wird dieser Filter lokaler Karten-Filter genannt. Dieser Schätzer ist entkoppelt von der eigentlichen zentralen Objektverfolgung und liefert die für die Anwendung der Verfahren notwendigen Schätzgrößen und Schätz-Kovarianzen. Im folgenden werden die Grundideen zweier bekannten Dekorrelationsverfahren und ihre Verwendung für die Fusion der Messung aus der Belegungskarte mit der Zustandsschätzung in der Objektverfolgung kurz beschrieben. Die Herleitung dieser Verfahren und das genaue Schema, nach denen sie funktionieren, finden sich in der Literatur [17], [14], [29] und [30].

- **Informationsdekorrelation in der Fusion:** Die Grundidee der in [17] und [14] gezeigten Methode besteht in der Identifikation der gemeinsamen Information in den beiden zu kombinierenden Filtern und dem Entfernen dieser Information im Fusionsschritt. Konkret wird dies realisiert, indem der Beitrag des gemeinsamen Informationsanteils in der Kalman-Filterung in der Fusion abgezogen wird. Im Fall der Belegungskarte und der Objektverfolgung stellt der Zustandsvektor der Objektverfolgung, mit dem die Prädiktion auf der Belegungskarte durchgeführt wurde, die gemeinsame Informationsquelle dar. Diese enthält zum einen den Beitrag der klassifizierten Sensor-Rohdaten, zum anderen enthält sie auch die geschätzten Dynamikgrößen Geschwindigkeit, Beschleunigung und ihre Schätzvarianzen. Damit die Daten aus der Belegungskarte korrekt eingespeist werden, werden der Beitrag des erwähnten Zustandsvektors und seine Schätzvarianzen beim Einspeisen der Messung aus der Karte entfernt. Laut [15] ist diese Methode vor allem bei niedrigem Prozessrauschen und genügend hoher Datenrate der genutzten Sensoren geeignet.
- **Dekorrelation durch Generierung einer äquivalenten Messung:** Diese Methode wurde in [29] und [30] für militärische Anwendungen vorgestellt. Hier basiert die Dekorrelation auf der Erzeugung einer äquivalenten Messung gegeben der letzten eingespeisten Messung, der neuen einzuspeisenden Messung und ihrer Fehlerkovarianzen, beide vom sendenden Filter. Gesucht wird die Messung, die den einspeisenden Filter vom letzten zum empfangenden Filter gesendeten Zustand in den neuen einzuspeisenden Zustand bringt. Diese äquivalente Messung ist mithilfe der Kalman-Gleichung einfach zu ermitteln. Sie ist mit dem Zustand des empfangenden Filters dekoriert und kann somit als Messung für seine Korrektur eingesetzt werden. Für die Anwendung der Idee auf das vorliegende Problem wird die äquivalente Messung gesucht, die den lokalen Karten-Filter von dem für die Prädiktion der Belegungskarte genutzten Zustandsvektor zum aktuellen Zustand des lokalen Karten-Filters transformiert. Diese Messung enthält die Informationsanteile, die zusätzlich durch die Verarbeitungsmechanismen der Belegungskarte erzeugt wurden. Sie

kann somit als Messung für die Objektverfolgung genutzt werden.

6.6 Experimentelle Ergebnisse

Zur Validierung des Konzepts der Kombination der belegungskartenbasierten Ansätze mit der modellbasierten Objektverfolgung wurden verschiedene Experimente mit realen Sensordaten durchgeführt. Das Augenmerk liegt dabei auf der notwendigen Rechenzeit sowie den erzielten Verbesserungen vor allem aus Sicht der Belegungskarte.

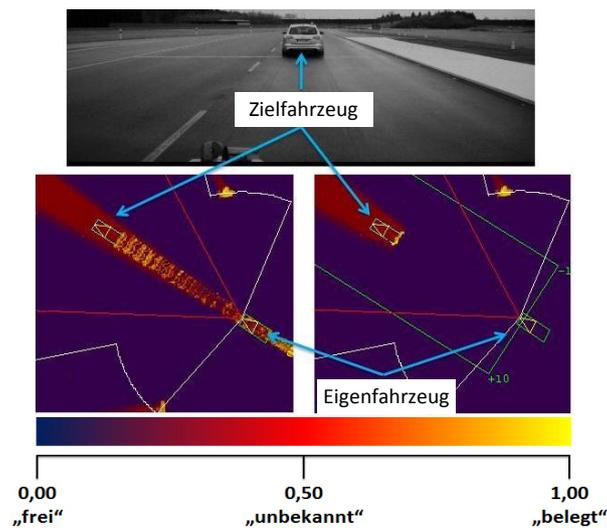


Abbildung 6.10: Verbesserung der Belegungskarte durch Kompensation der Bewegung dynamischer Hindernisse links ohne, rechts mit Kompensation

Die Erweiterung des Belegungsgitters um die Beschreibung bewegter Objekte führt zu einer erheblichen Verbesserung der Datenqualität des Belegungsgitters. Diese Tatsache wird in Abbildung 6.10 verdeutlicht. Durch die Kompensation der Bewegung dynamischer Hindernisse hinterlassen vorausfahrende Fahrzeuge keine „Schweife“ mehr auf der Belegungskarte. Der Freiraum wird somit korrekt erfasst (s. den rechten Teil der Abbildung), und eine Bahnplanung auf Basis der Belegungskarte ist möglich.

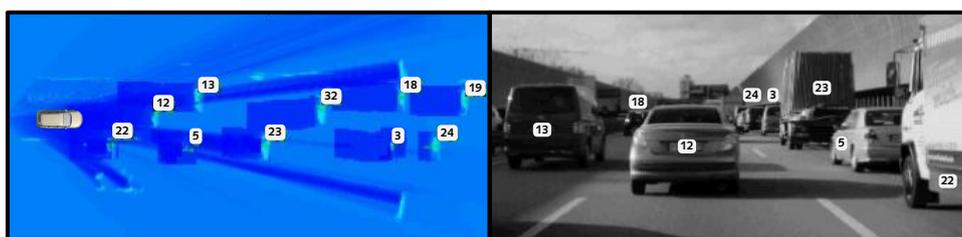


Abbildung 6.11: Dynamische Objekte im Belegungsgitter und die dazugehörigen Objekt-IDs

Abbildung 6.11 zeigt ein weiteres Beispiel aus einer realen Stau-Szene. Hier werden verschiedene

Objekte vom Laserscanner und von den Radar-Sensoren erfasst. Auf dem Belegungsgrid werden die Zellen, die zu Objekten gehören, mit den Indizes dieser Objekte markiert. In der Abbildung sind außerdem die Freiräume zu sehen, die aus der Prädiktion bewegter Objekte resultieren.

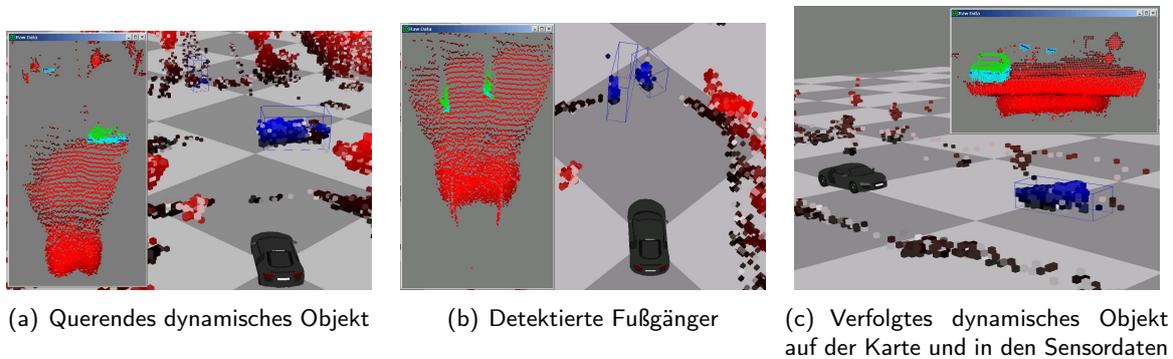


Abbildung 6.12: Ergebnisse aus der Erfassung dynamischer Hindernisse

Abbildung 6.12 enthält eine Reihe von Ergebnissen aus der dreidimensionalen Umfeldkartierung mit Verfolgung bewegter Hindernisse. In den Abbildungen sind die Rohdaten des 3D-Sensors (rote Punkte), die statischen Zellen (rot) und die dynamischen Zellen (blau) abgebildet. Ein wichtiges Ergebnis der entwickelten Fusion der Belegungskarte mit der Objektverfolgung besteht in der Akkumulation der Objekt-Form, wie in Abbildung 6.12(c) zu erkennen ist. Das Objekt wurde aus verschiedenen Ansichten erfasst. Die dynamischen Zellen, die in der Abbildung blau dargestellt sind, geben die Form des Objektes wieder. Außerdem sind die Verfahren in der Lage querende Fahrzeuge in Kreuzungssituationen (s. Abbildung 6.12(a)) und Fußgänger (s. Abbildung 6.12(b)) an Ampeln korrekt zu erkennen und verfolgen.

Zur Bewertung der Objektverfolgung wurde das Umfeldreferenzsystem eingesetzt, das in Kapitel 2.1.5 vorgestellt wurde. Mit Hilfe dieses Systems können die Position des Eigenfahrzeugs und die eines weiteren Fahrzeugs mit hoher Genauigkeit bestimmt werden. Abbildung 6.13 zeigt die Verläufe der Position und Geschwindigkeit in x Richtung aus der Referenz und aus der entwickelten Objektverfolgung bei einer dynamischen Fahrt. Der mittlere Fehler der Position in x Richtung lag bei ca. 20 cm.

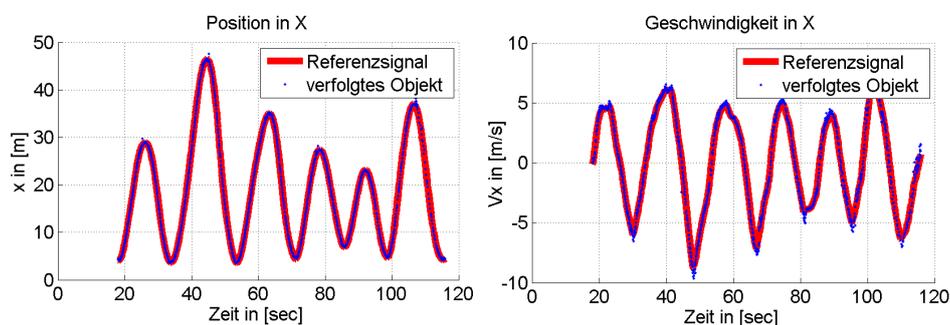


Abbildung 6.13: Vergleich der Objektverfolgung mit der Referenz

7 Extraktion von Umfeldinformationen aus Belegungsgittern

Automaten sehen ohne Bilder. Nur am Anfang ihres Sehens steht eine bildhafte Information, die im Verlauf des Prozesses in Merkmale, Objekte, Entscheidungen oder Handlungen überführt wird [6].

7.1 Motivation und Konzept

Trotz des hohen Detaillierungsgrads einer Belegungskarte weist diese vor allem in ihrer klassischen Form als Belegungsgitter aufgrund des niedrigen Abstraktionsniveaus und des hohen Speicherbedarfs bedeutende Nachteile auf. Die Interpretation eines Belegungsgitters ist vergleichbar mit dem Interpretationsvorgang eines Bildes. Das Bild der realen Welt muss in eine für den Betrachter günstigere Beschreibung überführt werden, bei der nur noch die wichtige Information erhalten bleibt und die unwichtige entfällt. Diese Trennung von wichtiger und unwichtiger Information wird auch beim Sehen von biologischen Informationssystemen „automatisch“ durchgeführt [82]. Analog dazu ist es notwendig die für Fahrerassistenzsysteme relevanten Informationen aus dem Belegungsgitter herzuleiten. Dieser Verarbeitungsschritt wird als Extraktion bezeichnet. Der Extraktionsvorgang hat folgende Ziele:

- Reduzierung der Datenmenge durch Verdichtung der Daten auf die für die Funktion relevanten Informationen. Diese Verdichtung erfolgt durch die Steuerung der Informationsextraktion durch die FAS-Funktion.
- Entkopplung der Fahrerassistenzfunktion von der sensornahen Datenverarbeitung (Belegungsgitter) durch Einführung einer Extraktionschicht mit definierten Schnittstellen.
- Vereinfachung der Interpretierbarkeit durch z.B. Herstellung des Bezugs zum Eigenfahrzeug und die Überführung der wahrscheinlichkeitsbasierten Repräsentation in eine zustandsbasierte Beschreibung.
- Erhöhung des Abstraktionsgrads durch Extraktion von Informationen, die eine Bedeutung besitzen wie z.B. Objekte, Freiräume und Randbebauungsverläufe.
- Bereitstellung von Informationen, die andere Wahrnehmungsmodule nutzen können (Verbesserung der Eigenbewegung, Verbesserung der Objektverfolgung...)

Abbildung 7.1 fasst den verfolgten Ansatz zusammen. Durch die Einführung von funktionspezifischen Extraktoren resultiert eine Entkopplung der Umfeldwahrnehmung von der FAS-Funktion,

die die Verhaltensgenerierung und die Fahrzeugregelung enthält. Dadurch kann die Umfeldwahrnehmung verschiedene Funktionen bzw. Assistenzsysteme bedienen. Sind die Wahrnehmungsmodule und die Funktionsmodule auf verschiedenen Recheneinheiten bzw. Steuergeräten verteilt, so werden die extrahierten Daten aus der Belegungskarte über das Fahrzeugbussystem wie CAN oder Flexray übertragen. Damit die extrahierten Daten möglichst kompakt gehalten werden, dürfen nur die relevanten Daten aus der Belegungskarte abhängig von dem zu realisierenden Assistenzsystem über den Bus transportiert werden. Dies erfordert eine FAS spezifische Extraktion aus der Belegungskarte und das Wissen über die Auslegung der FAS-Funktion wie z.B. den Aktionsbereich des Systems. Falls weitere Informationen von der Funktion benötigt werden, muss auch ein Rückkanal für die Steuerung der Extraktionsalgorithmen sichergestellt werden. Ein weiterer wichtiger Aspekt besteht in der Koordination der verschiedenen Extraktionsvorgänge. Die zeitliche Reihenfolge der Zugriffe auf der Belegungskarte muss gemäß der zur Verfügung stehenden Zeit-Ressourcen und der Priorität der zu extrahierenden Daten festgelegt werden. Mithilfe dieser Maßnahmen werden gleichzeitige Zugriffe auf der Belegungskarte vermieden und die Belegungskarte wird nicht eine lange Zeit blockiert.

Der Extraktionsvorgang selbst erfolgt in drei Hauptschritten:

1. Im ersten Schritt wird ein Aufmerksamkeitsgebiet bzw. eine *Region Of Interest* für die Extraktion festgelegt. Hierzu wird der Suchbereich auf dem Belegungskitter unter Zuhilfenahme von Vorwissen eingeschränkt, so dass interessante Informationen über das Umfeld möglichst schnell und einfach gefunden werden können. Eine solche Suchstrategie wird in der Literatur auch als heuristische oder informierte Suche bezeichnet [77].
2. Im nächsten Schritt findet eine Merkmalextraktion analog zur Bildverarbeitung statt, in der Kanten, Ecken und Kennwerte wie z.B. der Erwartungswert der Belegung, die maximale Belegungswahrscheinlichkeit und die Größe des Freiraums extrahiert werden.
3. Im dritten Schritt werden diese Merkmale um weiteres Wissen angereichert und interpretiert, um daraus eine Bedeutung für das Assistenzsystem herzuleiten (z.B. Bildung von Fahrbahnverläufen aus extrahierten Merkmalen).

Der Rest des vorliegenden Kapitels behandelt exemplarisch zwei Extraktoren: zum einen die intervallbasierte Freiraum- und Belegungsextraktion, zum anderen die Randbebaugungsextraktion. Andere Extraktoren wie etwa die Dynamikklassifikation mithilfe der Belegungskarte und die Extraktion von Belegungsinformationen für den Vergleich zweier Belegungskarten wurden jeweils in Kapitel 6 und 8 vorgestellt.

7.2 Intervallbasierte Freiraum- und Belegungsextraktion

Die Analyse der Anforderungen der beiden Assistenzsysteme Stauassistent und Aktive Gefahrenbremsung an die Umfeldwahrnehmung haben zu folgenden Feststellungen geführt:

- Die Genauigkeitsanforderungen an die Erfassung der Hindernisse in der zum Eigenfahrzeug lateralen Richtung sind deutlich höher als die Genauigkeit in der Längsrichtung. Die Ausweichanalyse der Aktiven Gefahrenbremsung benötigt die lateralen Abstände zu Hindernissen mit hoher Genauigkeit (s. Kapitel E.1). Die Funktion Stauassistent muss ebenfalls

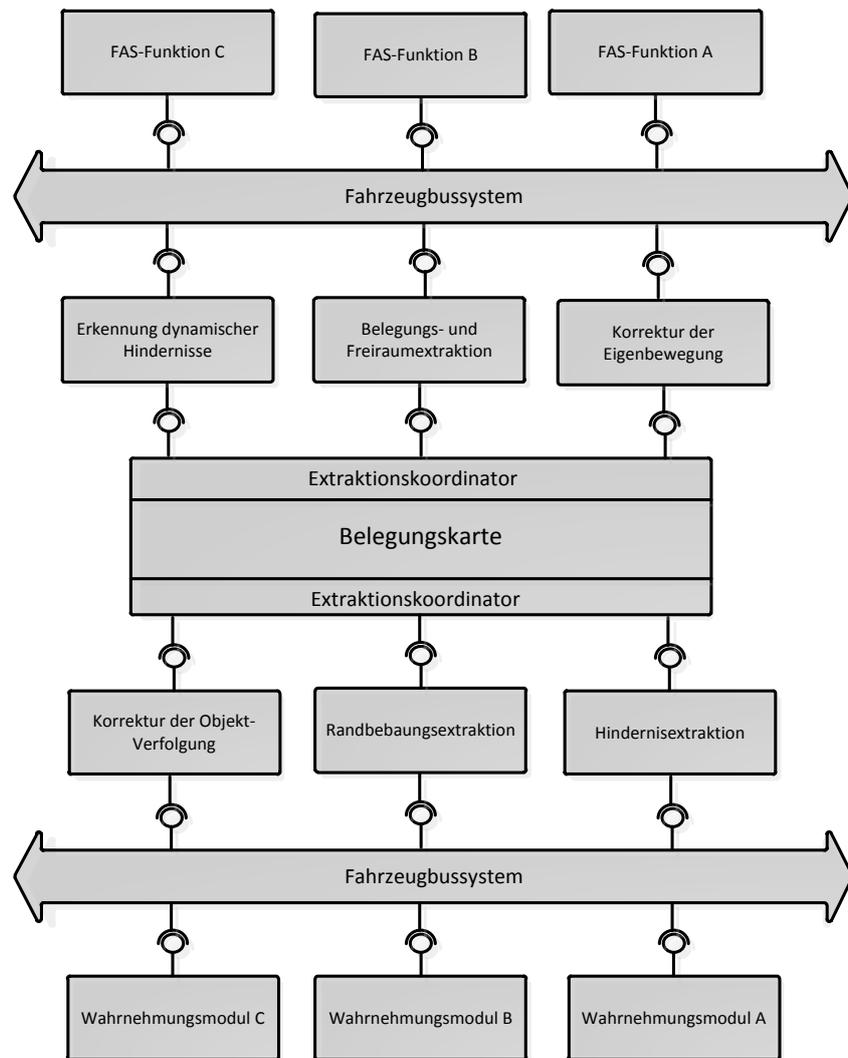


Abbildung 7.1: Extraktionskonzept

7. Extraktion von Umfeldinformationen aus Belegungsgittern

sehr genau die Position von seitlichen Hindernissen für die Querregelung kennen (s. Kapitel E.2).

- Die Genauigkeitsanforderungen an die Erfassung der Hindernisse in der Längsrichtung sind höher im Niedergeschwindigkeitsbereich.
- Sowohl der Stauassistent als auch die Aktive Gefahrenbremsung benötigen die Freiraum-, und Belegungsinformation in einem kleinem Ausschnitt aus dem Belegungsgitter. Dieser Ausschnitt hängt vom Aktionsraum des jeweiligen Systems ab.

Aufbauend auf diesen Erkenntnissen aus der Anforderungsanalyse wurde die intervallbasierte Raumdarstellung als eine Umfeldrepräsentation zwischen dem Belegungsgitter und der Funktion eingeführt. Die Grundidee dieser Darstellung besteht in der Nutzung einer gröberen Diskretisierung in der Längsrichtung als die Auflösung des Belegungsgitters. In der lateralen Richtung hingegen wird die volle Genauigkeit des Belegungsgitters verwendet. Aufgabe der Extraktion ist es dann die Belegungsinformationen in einem vordefinierten Bereich auf dem Belegungsgitter in Intervalle zu überführen. Dabei findet auch eine Transformation der wahrscheinlichkeitsbasierten Repräsentation des Belegungsgitters in eine zustandsbasierte Darstellung statt. D.h., die Belegungsinformation wird auf die wenigen Zustände „belegt“, „frei“ und „unbekannt“ reduziert. Durch diese Maßnahmen erfolgt eine erhebliche Reduzierung der Datenmenge. Abbildung 7.2 zeigt das Prinzip der intervallbasierten Freiraum- und Belegungsextraktion.

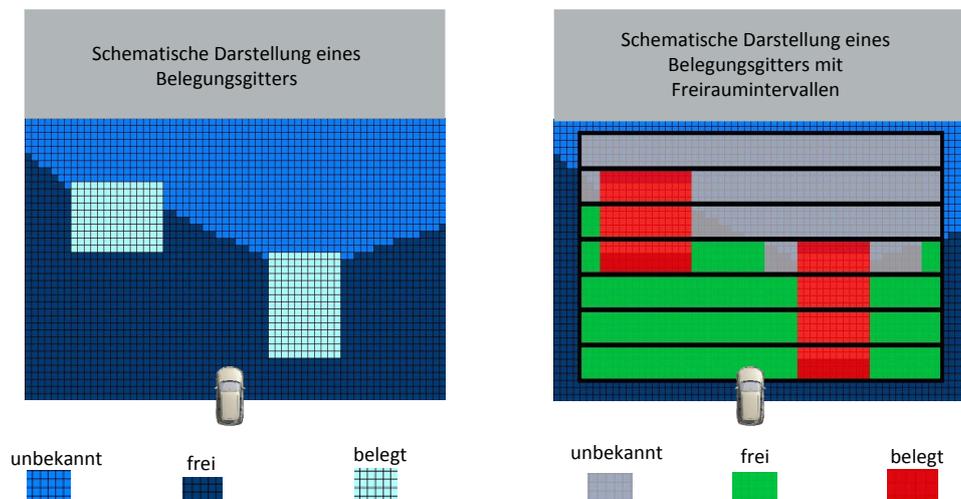


Abbildung 7.2: Prinzip der intervallbasierten Freiraum- und Belegungsextraktion

Die Extraktion bzw. Analyse innerhalb eines Intervalls kann auf die gezielte Füllung dieses Intervalls unter dem Einbeziehen einer Suchrichtung zurückgeführt werden. Die Standard-Methoden der Computergrafik zum Füllen von Polygonen (Abtastlinien-Algorithmen bekannt unter dem Namen *Scan Line* [9]) können aber hier nur bedingt eingesetzt werden, da bei ihnen die Suchrichtung keine Rolle spielt. Diese Algorithmen durchlaufen die Gitterstruktur zeilen- oder spaltenweise. Die Intervalle müssen deswegen mithilfe von Linien untersucht werden. Dabei ist die Suchrichtung parallel zur Fahrzeug-Längsachse und die Laufrichtung bzw. die Füllrichtung ist

orthogonal zur Fahrzeug-Längsachse. Die Extraktion innerhalb eines Intervalls startet in seiner Mitte. Von dort wird das Intervall schrittweise in Richtung seiner beiden Enden analysiert. In jedem Schritt wird mithilfe des Bresenham-Algorithmus orthogonal zur Laufrichtung eine Linie bestimmt. Die Belegungen der zur gerasterten Linie gehörenden Pixel werden abgefragt. Dabei wird auch die Sub-Zell-Position der Belegung extrahiert, um eine höhere Genauigkeit als die Auflösung des Belegungsgitters erzielen zu können. Entsprechend der funktionspezifischen Extraktionsregeln wird für jede dieser Linien ein dominanter Belegungszustand bestimmt. Sobald dieser Zustand von der Belegung aus der vorherigen Linie sich unterscheidet, wird ein neuer Zustand mit entsprechender Position innerhalb des Intervalls angelegt. Gleicht der neu extrahierte Zustand dem alten, wird dieser fortgesetzt. Anschließend werden die extrahierten Daten in das Fahrzeugkorrdiantensystem transformiert und ausgegeben. Abbildung 7.3 verdeutlicht den Ablauf der Extraktion innerhalb eines Intervalls.

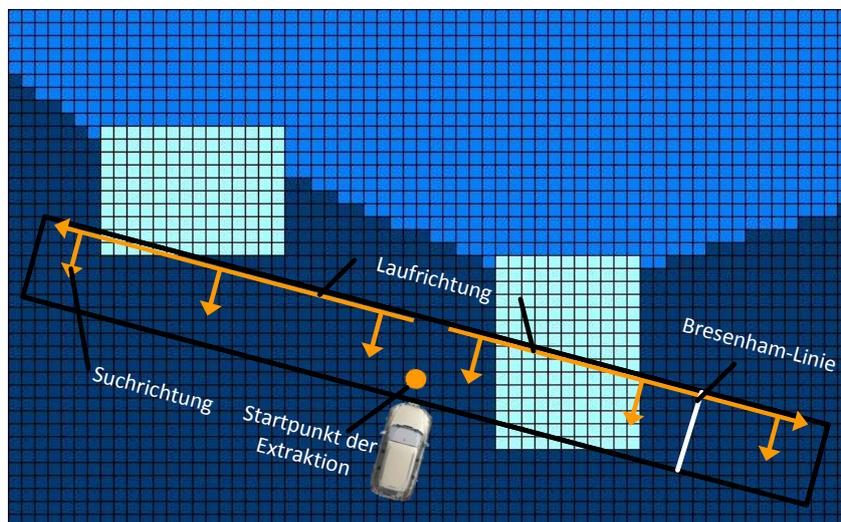


Abbildung 7.3: Ablauf der Extraktion innerhalb eines Intervalls

7.2.1 Erweiterter Bresenham-Algorithmus

Für die Bestimmung der Belegungszustände innerhalb eines Intervalls muss dieses mit Hilfe von diskretisierten Linien vollständig durchlaufen werden. Die Linien sind parallel zur Fahrzeugausrichtung auf dem Belegungsgitter und sind somit verdreht gegenüber der Ausrichtung des Belegungsgitters. Deshalb muss beim Befüllen eines Intervalls auf den Bresenham-Algorithmus zurückgegriffen werden (s. Anhang D). Hierbei entstehen aufgrund von Quantisierungseffekten Lücken, die nicht besuchten Pixeln entsprechen. Die Lücken resultieren beim Wechsel von der schnellen in die langsame Richtung im Ablauf des Bresenham-Algorithmus. Mathematisch passiert das, wenn das Fehler-Signal des Bresenham-Algorithmus (Abweichung zwischen kontinuierlichen und gerasterten Linie) das Vorzeichen wechselt. Werden die Wechsel-Pixel von den anderen parallelen Linien nicht gesetzt, bleiben sie unbesucht und deren Belegungswerte werden nicht abgefragt.

Um diesem Problem entgegen zu wirken, wurde der Standard Bresenham-Algorithmus so erweitert, dass beim Untersuchen eines Intervalls keine Lücken entstehen. Hierzu wurde beim Setzen einer Zelle in der langsamen Richtung die Linie in der Füllrichtung gedoppelt und eine Erweiterungszelle gesetzt. Dadurch schließen sich die potentiellen Lücken und es werden alle Zellen abgefragt. Allerdings werden durch diese Maßnahme die Bresenham-Linien breiter, was zu der doppelten Abfragung führen kann. In diesem Fall kann ein Fehler in der Beschreibung der Hindernis-Position entstehen. Der maximale Fehler ist in der Größenordnung einer Zelle. Dieser mögliche kleine Fehler ist aber nicht so kritisch wie der Fehler durch Lücken.

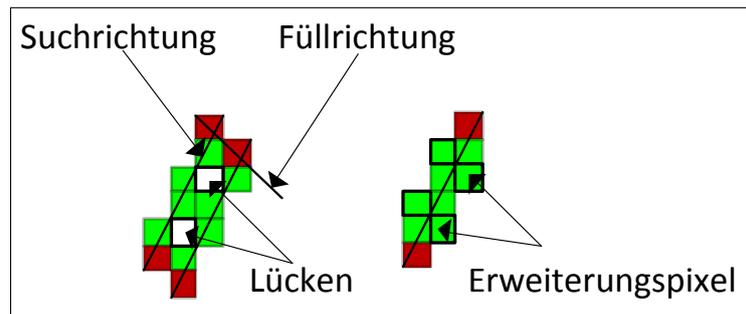


Abbildung 7.4: Lücken-Problematik und Erweiterung des Bresenham-Algorithmus

7.2.2 Funktionsspezifische Steuerung

Abbildung 7.1 zeigt, dass die Extraktoren die Schnittstelle zwischen der Umfeldwahrnehmung und den FAS-Funktionen darstellen. In dieser Zwischenschicht sollen funktionspezifisch die relevanten Daten für die verschiedenen FAS-Systeme aufbereitet werden. Hierfür erfolgt eine Steuerung der Extraktionsparameter sowie der Interpretation der Daten aus dem Belegungsgitter durch die FAS-Funktion. Im Folgenden werden einige Beispiele für die funktionspezifische Steuerung der intervallbasierten Extraktion an den Beispielen der Stauassistent und der Aktiven Gefahrenbremsung aufgeführt.

- **Steuerung der Grenzen des Extraktionsgebiets:** Das relevante Extraktionsgebiet hängt direkt von der Auslegung des FAS-Systems ab. D.h., die FAS-Funktion steuert die Aufmerksamkeit der Umfeldwahrnehmung gemäß ihrer Aktionen. Die notwendige Längsvorausschau, in der die Hindernisse erfasst werden müssen, erhöht sich mit der Zunahme der Eigengeschwindigkeit. Sie hängt bei der aktiven Gefahrenbremsung von der festgelegten maximalen Eigengeschwindigkeit ab, bei der eine Kollision mit einem Objekt vermieden werden soll. Beim Stauassistenten kann die notwendige Vorausschau aus der notwendigen Zeit für eine komfortable Reaktion auf ein Hindernis im Fahrstreifen des Eigenfahrzeugs hergeleitet werden. In der lateralen Richtung ist prinzipiell eine Überwachung des Freiraums innerhalb des eigenen Fahrstreifens für einen Stauassistenten hinreichend. Die seitlichen Grenzen des Extraktionsgebiets für das System der Aktiven Gefahrenbremsung entspricht den Grenzen des fahrphysikalisch erreichbaren Raumes ausgehend von der aktuellen Dynamik des Eigenfahrzeugs.
- **Steuerung der Diskretisierung:** Die Diskretisierung der Intervalle in der Längsrichtung

stellt einen wichtigen Parameter in der Extraktion dar. Sie ist eingeschränkt durch die zur Verfügung stehenden Ressourcen insbesondere der Speicher und die Bandbreite in den Rechen-Einheiten und im Bussystem. Abhängig von diesen Ressourcen und von der Fahr-situation kann die Diskretisierung adaptiv bestimmt werden. Bei hohen Geschwindigkeiten ist in der Regel eine höhere Vorausschau notwendig. Dies impliziert den Einsatz einer gro-ben Quantisierung der Intervalle. Bei niedrigen Geschwindigkeiten können hingegen die vorhandenen Ressourcen auf eine begrenzte Vorausschau verteilt werden. Somit kann eine feine Diskretisierung verwendet werden.

- **Steuerung der Belegungsinterpretation:** Die Interpretation der Belegungswahrscheinlichkeiten hängt ebenfalls von der Auslegung der FAS-Funktion und ihrer Definition ab. Dies beinhaltet zum einen die Festlegung der Schwellen für die Bestimmung der Zustände „belegt“, „frei“ und „unbekannt“. Zum anderen wird die Interpretation dieser Belegungszustände von der FAS-Funktion bestimmt. So kann z.B. der Zustand „unbekannt“ von der Aktiven Gefahrenbremsung als frei interpretiert werden, weil der Fahrer in den als „unbekannt“ markierten Raum ausweichen kann. Ist das „unbekannt“-Gebiet hinreichend groß für ein Ausweichmanöver, ist ein Eingriff des Systems nicht erforderlich, da eine Ausweichmöglichkeit besteht. Bei der Funktion Stauassistent hingegen wird der Zustand „unbekannt“ als „belegt“ behandelt, weil dort ein Hindernis sich befinden kann, das ein automatisches Fahrmanöver einschränken kann. Außerdem sind gewisse Regeln notwendig, falls innerhalb einer zum Intervall orthogonalen Suchlinie mehrere Belegungszustände detektiert werden. So überstimmt z.B. der Zustand „belegt“ die restlichen Zustände „frei“ und „unbekannt“ bei beiden betrachteten FAS-Systemen.

In Abbildung 7.7 sind zwei Extraktionsbeispiele für die Systeme Stauassistent und Aktive Gefahrenbremsung für die gleiche Szene abgebildet.

7.2.3 Ergebnisse

Die intervallbasierte Extraktion wurde als Schnittstelle zu den Funktionen Stauassistent und Aktive Gefahrenbremsung eingesetzt. Sie führte zu einer wesentlichen Vereinfachung der Interpretation der Daten aus dem Belegungsgitter. Sie stellt eine kompakte Darstellung der freien, belegten und unbekannt Räume dar und ermöglicht somit die Nutzung der Belegungskarte für Fahrerassistenzsysteme. Abbildung 7.5 zeigt die detektierten freien und belegten Gebieten aus der intervallbasierten Extraktion. Diese wurden in das Bild einer onboard-Kamera projiziert.

Die intervallbasierte Extraktion führte vor allem zu einer erheblichen Reduzierung der Datenmenge, die auf dem Bussystem übertragen werden muss. In Abbildung 7.6 ist der Verlauf des von der Extraktion benötigten Speichers für eine neun Minuten lange Fahrt zu sehen. Die Extraktion wurde für die Funktion Stauassistent in einer typischen Stau-Szene mit hohen Umgebungsdetails durchgeführt. Während dieser Fahrt betrug der Speicherverbrauch pro Zeitschritt maximal ca. 7.5 KBytes. Im Vergleich dazu benötigt das Belegungsgitter ca. 2 MBytes, was einer Ersparnis von 99 % entspricht.

Die Unterschiede in der Extraktion zwischen einer Komfort-Funktion und einer Sicherheitsfunktion ist in Abbildung 7.7 zu sehen. Hier sind die Ergebnisse der Extraktion für beide Systeme und

7. Extraktion von Umfeldinformationen aus Belegungsgittern

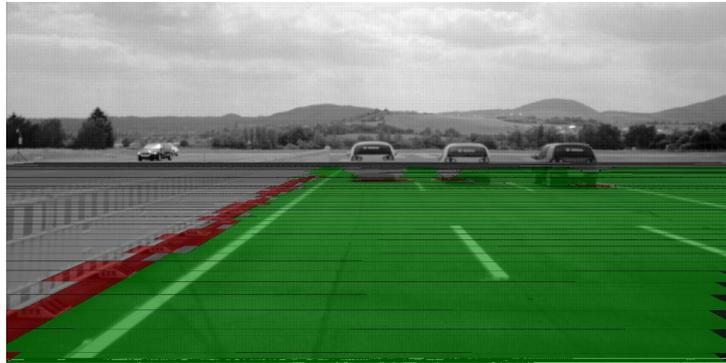


Abbildung 7.5: Ergebnisse der intervallbasierten Extraktion auf dem Video Bild einer Onboard-Kamera

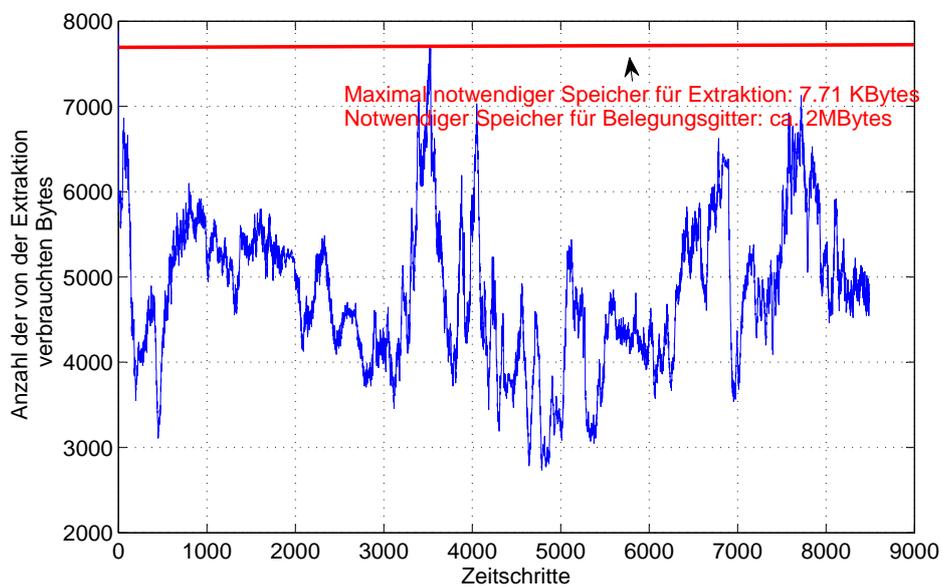


Abbildung 7.6: Speicherverbrauch des Freiraum- und Belegungsextraktors bei einer für den Stauassistenten typischen Fahrt

in der gleichen Szene aufgetragen. Auffällig sind die trompetenförmigen Grenzen des Extraktionsgebiets bei der Aktiven Gefahrenbremsung. Diese entsprechen den Grenzen des fahrphysikalisch erreichbaren Raums. Beim Stauassistenten hingegen sind die Grenzen durch Fahrzeugausrichtung und die notwendige Vorausschau für die adäquate Reaktion auf einscherende Fahrzeuge und Randbebauungen gegeben.



Abbildung 7.7: Intervallbasierte Belegungsextraktion für den Stauassistent und für die Aktive Gefahrenbremsung in der gleichen Szene

7.3 Randbebauungsextraktion aus Belegungsgittern

7.3.1 Motivation und Konzept

Die Fahrbahninfrastruktur insbesondere die Fahrbahn-Randbegrenzungen stellen eine wichtige Komponente der Fahrzeugumgebung dar. Die maschinelle Erfassung dieser Randbebauung ist erforderlich, um Assistenzsysteme in komplexen Szenen wie Baustellen, engen Kurven und Fahrbahnen mit fehlenden Markierungslinien zu ermöglichen. In der Literatur liegt der Schwerpunkt meistens auf die videobasierte Erkennung von Fahstreifenmarkierungen. In der vorliegenden Arbeit wird das Ziel verfolgt, sowohl die Fahrbahn begrenzenden Hindernisse als auch die Verläufe, die diese Hindernisse bilden, zu detektieren und zu beschreiben. Hierbei wird zwischen massiven Verläufen wie Leitplanken und Betonwänden und virtuellen Verläufen wie Verbindungen zwischen Leitpfosten unterschieden. Die Beiträge dieses Abschnittes bauen auf den Ergebnissen von [Nyga 2009] auf.

Die Nutzung des Belegungsgitters als Basis für die Randbebauungserkennung bietet einige Vorteile. Einerseits werden die Unsicherheiten der Sensormessungen durch die Filterwirkung der Bayes-Akkumulationsmechanismen teilweise kompensiert. Andererseits ist die Historie der detektierten Hindernisse im Belegungsgitter mitenthalten, was die Erkennung der Fahrbahnbegrenzungen stützen kann. Außerdem ermöglicht das Belegungsgitter die Unterscheidung zwischen den dynamischen und stationären Hindernissen, sodass nur die relevanten Objekte für die Erkennung der Randbebauung miteinbezogen werden.

Abbildung 7.8 beschreibt die Systemarchitektur und die notwendigen Komponenten einer Randbebauungserkennung basierend auf einem Belegungsgitter. Im ersten Schritt erfolgt die Berech-

nung des für die Randbebauungsextraktion relevanten Bereiches in der Belegungskarte. Diese *Region Of Interest*, die den Suchraum auf dem Belegungsgitter eingrenzt, wird in Abschnitt 7.3.2 beschrieben. Auf Basis der ROI findet anschließend eine Segmentierung des Belegungsgitters statt, deren Ergebnis ein binäres Bild ist, in dem die Hindernisse abgebildet sind. Um Randverläufe aus segmentierten Hindernissen bilden zu können, muss zunächst der Verlauf der Fahrbahn geschätzt werden. Dieser Verlauf ist notwendig, damit die Hindernisse in „rechts“ und „links“ klassifiziert werden können. Ein einfacher und effizienter Algorithmus zu diesem Zweck wird in Abschnitt 7.3.4 vorgestellt. Im letzten Schritt werden die klassifizierte Hindernisse gruppiert, die einen potentiellen Randverlauf beschreiben. Hierzu wurden zwei verschiedene Algorithmen entworfen und verglichen. Die extrahierten Verläufe werden anhand von Polygonzügen beschrieben. Dabei wird zwischen virtuellen Verbindungen (z.B. zwischen zwei Leitpfosten) und realen Verbindungen (aufgrund von massiven Hindernissen wie Leitplanken) unterschieden.

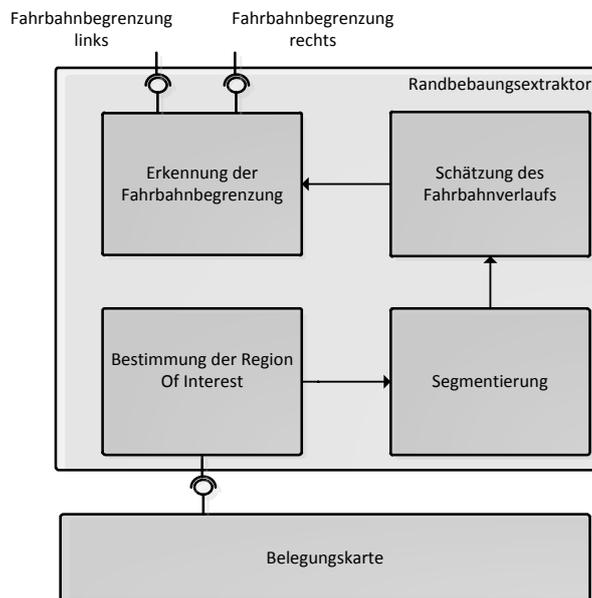


Abbildung 7.8: Systemarchitektur der Randbebauungsextraktion

7.3.2 Bestimmung einer *Region Of Interest*

Die Festlegung einer *Region Of Interest* bzw. eines Aufmerksamkeitsgebiets für die Randbebauungserkennung auf dem Belegungsgitter dient hauptsächlich der optimalen Ausnutzung der vorhandenen Rechenressourcen innerhalb des relevanten Bereichs. Eine Suche innerhalb des gesamten Belegungsgitters ist aufgrund des hohen erforderlichen Rechenaufwands nicht durchführbar. Außerdem befinden sich die relevanten Hindernisse meistens in unmittelbarer Nähe des Eigenfahrzeugs. Weite Teile des Gitters enthalten die Belegungsinformationen frei oder unbekannt. Solche Informationen tragen nicht zur Erkennung der Randbebauung bei.

Wie bereits in Kapitel 4 erwähnt, befindet sich das Eigenfahrzeug in der Mitte des Belegungsgitters und ist auch gegenüber der Ausrichtung des Gitters um ψ verdreht. Die normierten Vektoren

$\mathbf{v} = \begin{pmatrix} -\cos \psi \\ -\sin \psi \end{pmatrix}$ und $\mathbf{n} = \begin{pmatrix} \sin \psi \\ -\cos \psi \end{pmatrix}$ beschreiben respektive die Ausrichtung des Fahrzeugs im Kartenkoordinatensystem und die normale Richtung dazu. Die Begrenzungen einer rechteckigen ROI der Länge l und der Breite b , in deren Mitte sich der Bezugspunkt des Eigenfahrzeugs befindet, lassen sich somit durch die folgenden vier Eckpunkte beschreiben. \mathbf{p}_{ego} bezeichnet dabei die Position des Eigenfahrzeugs innerhalb des Gitters.

$$\begin{aligned}
 \mathbf{p}_1 &= \mathbf{p}_{ego} + \frac{l}{2} \cdot \mathbf{v} + \frac{b}{2} \cdot \mathbf{n}, & \mathbf{p}_2 &= \mathbf{p}_{ego} + \frac{l}{2} \cdot \mathbf{v} - \frac{b}{2} \cdot \mathbf{n}, \\
 \mathbf{p}_3 &= \mathbf{p}_{ego} - \frac{l}{2} \cdot \mathbf{v} - \frac{b}{2} \cdot \mathbf{n}, & \mathbf{p}_4 &= \mathbf{p}_{ego} - \frac{l}{2} \cdot \mathbf{v} + \frac{b}{2} \cdot \mathbf{n}
 \end{aligned}$$

Eine solche ROI (s. Abbildung 7.9) lässt sich einfach berechnen und kann mit Hilfe von Füllalgorithmen aus der Computergrafik effizient abgearbeitet werden. Obwohl dieses einfache ROI-Modell bei gerader Fahrt in der Lage ist, die relevanten Hindernisse für Randbegrenzungen abzubilden, offenbaren Kurvenfahrten erhebliche Mängel, wie in Abbildung 7.9 zu erkennen ist. Im schematisch dargestellten Szenario in Abbildung 7.9 stellen die rot markierten Punkte Belegungen im Belegungsgitter (z.B. Leitpfosten am Fahrbahnrand) dar. In dieser Szene fährt das Eigenfahrzeug eine Kurve. Ein großer Bereich der ROI befindet sich auf einer Seite der Fahrbahn, während zwei der acht Fahrbahnbegrenzungen überhaupt von der ROI erfasst werden. Sie sind aber zur Schätzung des weiteren Fahrbahnverlaufs relevant.

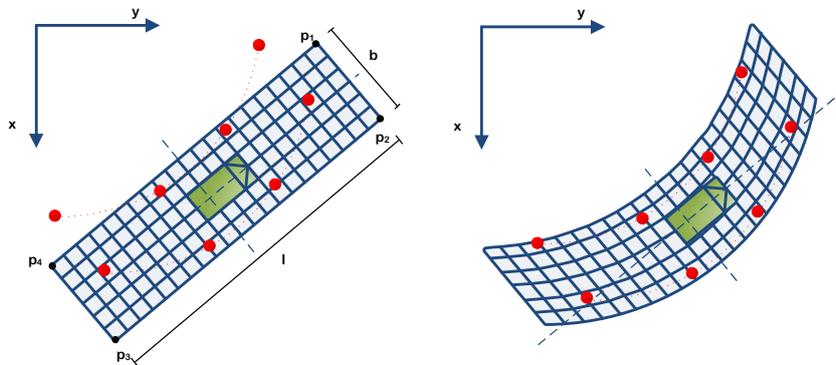


Abbildung 7.9: Gegenüberstellung einer rechteckigen ROI (a) und einer gemäß der Fahrbahn gekrümmten ROI (b)

Es liegt daher nahe, die ROI wie der Verlauf der Fahrbahn zu krümmen. Da der Straßenverlauf erst geschätzt werden soll, ist es sinnvoll die Gierrate $\Delta\psi$ für die Krümmung der ROI zu verwenden. Eine solche gekrümmte ROI ist in Abbildung 7.9 (b) dargestellt. Im Straßenbau werden Klothoiden als Übergangselemente eingesetzt. Klothoiden haben gegenüber Kreisbögen den Vorteil, dass die Querschleunigung beim Einlenken in die Kurve nicht ruckartig einsetzt, sondern mit dem Lenkeinschlag linear wächst. Die Beschreibung der ROI wird deshalb mit Hilfe einer Klothoide erweitert, um die Suche nach Merkmalen dem Straßenverlauf anzupassen. Eine Klothoide lässt sich durch folgende Kurvengleichung beschreiben:

$$\begin{pmatrix} x \\ y \end{pmatrix} = a\sqrt{\pi} \int_0^t \begin{pmatrix} \cos \frac{\pi\xi^2}{2} \\ \sin \frac{\pi\xi^2}{2} \end{pmatrix} d\xi, \quad t = \frac{l}{a\sqrt{\pi}}, \quad r = \frac{a^2}{l}, \quad a > 0 \quad (7.1)$$

Der Krümmungsradius r der Klothoide ist umgekehrt proportional zur Bogenlänge l , die die auf der Klothoide zurückgelegte Strecke vom Punkt $(0,0)^T$ bis zum Punkt $(x,y)^T$ beschreibt, und a ist ein konstanter Klothoidenparameter. In der Literatur wird meistens die Klothoide durch Reihenentwicklungen der Koordinaten x und y auf der Ursprungstangente ausgerechnet. Ausgehend aus Gleichung 7.1 können folgende Annäherungen für die Klothoide hergeleitet werden [62]:

$$a^2 = l \cdot r(\Delta\psi), \quad t = \frac{l^2}{2 \cdot a^2}$$

$$x(l) = l \cdot \left(1 - \frac{t^2}{2! \cdot 5} + \frac{t^4}{4! \cdot 9} - \frac{t^6}{6! \cdot 13} + \dots \right) \quad (7.2)$$

$$y(l) = l \cdot \left(\frac{t}{3} - \frac{t^3}{3! \cdot 7} + \frac{t^5}{5! \cdot 11} - \frac{t^7}{7! \cdot 15} + \dots \right) \quad (7.3)$$

Die Reihenglieder für x und y konvergieren auf Grund der stark wachsenden Fakultätsfunktion bereits nach wenigen Schritten gegen 0. Die Funktion $r(\Delta\psi)$, die den Krümmungsradius der Klothoide in Abhängigkeit von dem Gierwinkel-Differenz $\Delta\psi$ beschreibt, wurde für das implementierte System empirisch gemäß der folgenden Formel bestimmt. λ ist dabei eine empirisch ermittelte Konstante.

$$r(\Delta\psi) \approx \frac{\lambda}{\Delta\psi} \quad (7.4)$$

Abschließend ist eine Transformation der Klothoidenpunkte in das übergeordnete Koordinatensystem des Belegungsgitters erforderlich. Der durch die Klothoide approximierter Verlauf lässt sich somit im globalen Bezugssystem wie folgt beschreiben:

$$\mathbf{k}(l) = \mathbf{p}_{ego} + \begin{pmatrix} \cos \psi & -\sin \psi \\ \sin \psi & \cos \psi \end{pmatrix} \begin{pmatrix} x(l) \\ y(l) \end{pmatrix}. \quad (7.5)$$

Mithilfe der Funktion $k(l)$ und anschließender Translation mit \mathbf{n} lassen sich die Begrenzungs- punkte der ROI - mit vorgegebener Länge l - zwar berechnen, es existieren allerdings keine effiziente Verfahren, um eine auf diese Weise definierte Fläche abzuarbeiten. Es ist daher noch eine weitere Anpassung des ROI-Modells notwendig. Hierzu wird die gesamte Fläche der ROI gemäß Abbildung 7.9 (b) in eine Gitterstruktur überführt, indem sie in Vierecke zerlegt wird.

Die Zellen der ROI sind hier gröber aufgelöst als das Belegungsgitter. Dabei wird der diskretisierte Verlauf in der Längsrichtung nur einmal berechnet. Die Koordinaten der Vierecke bzw. Zellen lassen sich durch Translation um den Vektor \mathbf{n} ermitteln. Bezeichnen w die Breite und s die Länge eines solchen Vierecks, so liefern die folgenden Gleichungen die zugehörigen globalen Kartenkoordinaten:

$$\begin{aligned} \mathbf{p}_1 &= \mathbf{k}(i \cdot s) \pm j \cdot w \cdot \mathbf{n}, & \mathbf{p}_2 &= \mathbf{k}((i + 1) \cdot s) \pm j \cdot w \cdot \mathbf{n} \\ \mathbf{p}_3 &= \mathbf{k}((i + 1) \cdot s) \pm (j + 1) \cdot w \cdot \mathbf{n}, & \mathbf{p}_4 &= \mathbf{k}(i \cdot s) \pm (j + 1) \cdot w \cdot \mathbf{n}, \quad i, j \in \mathbb{N} \end{aligned}$$

wobei i und j Indizes einzelner Vierecke sind. Entsprechend der Position links oder rechts des Fahrzeugs muss ein Vielfaches des Normalvektors \mathbf{n} addiert oder subtrahiert werden. Das Ergebnis ist eine gitterförmige Region Of Interest, die sich in Abhängigkeit von der Fahrzeugausrichtung ψ und vom Gierwinkel $\Delta\psi$ der Dynamik des Fahrzeugs anpasst. Die Zellen der ROI können effizient mit Methoden der Computergrafik abgearbeitet werden.

7.3.3 Segmentierung

Ein erster kritischer Schritt in vielen Anwendungen der Bildanalyse ist die Segmentierung des Bildes. Segmentierung bezeichnet den Prozess, ein Bild auf Grundlage von Pixelähnlichkeiten in Gruppen zu zerlegen, denen gewisse Gemeinsamkeiten zugeschrieben werden können, wie beispielsweise Helligkeit, Farbe oder Oberfläche [77]. Die Segmentierung zerlegt damit ein Bild in semantische Einheiten und stellt so eine Verbindung zwischen der subsymbolischen Ebene und der wissensverarbeitenden Ebene dar.

Es existieren eine Vielzahl an unterschiedlichen Segmentierungsverfahren, die sich für unterschiedliche Zwecke eignen und unterschiedlich viel Vorwissen über die im Bild zu erwartenden Objekte voraussetzen [90]. Ziel der Segmentierung in der Randbebauungsextraktion ist die Hervorhebung von Hindernissen, also belegten Bereichen im Belegungsgitter. Zu diesem Zweck wird eine einfache *Schwellenwertsegmentierung* eingesetzt. Bezeichnet $\text{Belegung}(x, y)$ den Belegungswert der Zelle mit den Koordinaten $(x, y)^T$ und B den Segmentierungsschwellwert, so lässt sich die Segmentierung über die folgende einfache Funktion beschreiben:

$$\text{Seg}(x, y) = \begin{cases} 1 & \text{falls } \text{Belegung}(x, y) > B \\ 0 & \text{sonst} \end{cases} \quad (7.6)$$

Während des Segmentierungsvorgangs kann das Belegungsgitter als Bild interpretiert werden. Die Belegungen des Gitters entsprechen dann den Grauwerten eines Bildes. Abbildung 7.10 zeigt das Histogramm von Grauwerten, das aus 500 aufeinanderfolgenden Frames des Belegungsgitters gemittelt wurde. Deutlich zu erkennen sind drei große Häufungspunkte bei den Grauwerten 0, 127 und 255. Sie entsprechen den Belegungszuständen „frei“, „unbekannt“ und „belegt“. Das Ergebnis der Segmentierung ist ein binäres Belegungsgitter (s. Abbildung 7.10 (c)).

Speziell für die Randbebaugungsextraktion findet die Segmentierung innerhalb der festgelegten ROI statt. Dabei werden die ROI-Zellen mit Hilfe von effizienten Füll-Algorithmen abgearbeitet. Zusätzlich zu der Schwellwertsegmentierung wird auch die Position der nächsten Belegung zum Eigenfahrzeug markiert, weil diese die relevante Belegung für die Assistenzsysteme darstellt. Die Positionen der Hindernisse werden in den nachfolgenden Verarbeitungsschritten benötigt.

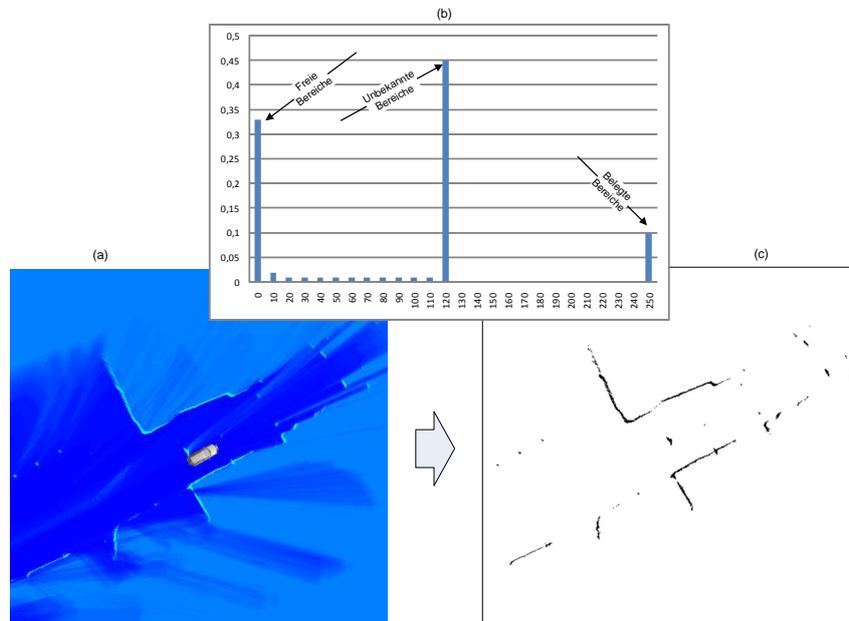


Abbildung 7.10: (a) Beispielhafter Auszug aus dem Belegungsgitter (b) Über 500 Frames der Karte gemitteltetes Grauwerthistogramm mit freien, unbekanntem und belegten Bereichen und (c) Ergebnis der Schwellwertsegmentierung

7.3.4 Schätzung des Fahrbahnverlaufs

Die Schätzung des Fahrbahnverlaufs ist für eine zuverlässige Erkennung von Fahrbahnbegrenzungen von zentraler Bedeutung. Anhand des Fahrbahnverlaufs kann für jedes reale Hindernis bestimmt werden, ob es sich rechts oder links der Fahrbahn befindet. Hierfür wurde in der Arbeit eine Methode entwickelt, die dazu dient, frühzeitig anhand der Verteilung der erkannten Hindernisse aus dem Belegungsgitter den Verlauf der Fahrbahn zu schätzen.

Ein sehr einfacher Ansatz besteht in der Annahme eines linearen Verlaufs der Fahrbahn mit derselben Ausrichtung wie das Eigenfahrzeug. In diesem Fall werden die Hindernisse gemäß ihrer Lage zu der Längsachse des Fahrzeugs zu „rechts“ oder „links“ klassifiziert. Der Ansatz würde gute Ergebnisse bei gerader Fahrt liefern, versagt jedoch bei Kurvenfahrten. Aus Abbildung 7.11 lässt sich entnehmen, dass Belegungen links der Längsachse auftreten können, die aber zur rechten Fahrbahnbegrenzung gehören und daher als rechts der Trajektorie kategorisiert werden müssten.

Eine erste Maßnahme um dieses Problem entgegen zu wirken, wurde bereits durch die Festlegung

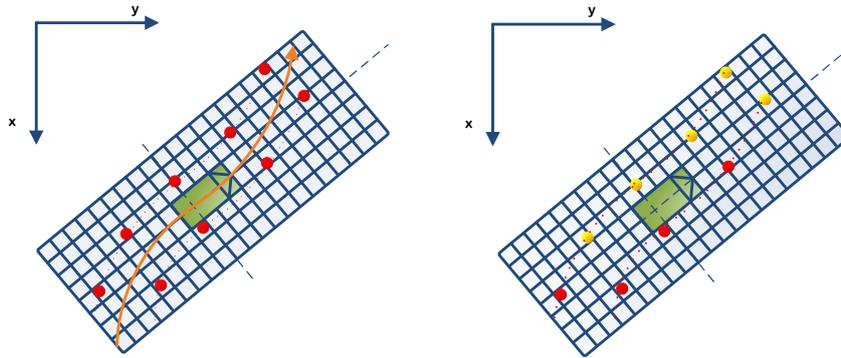


Abbildung 7.11: (a) Szenario einer Kurvenfahrt und (b) Falschklassifikation der Fahrbahnbegrenzungen

der ROI getroffen. Durch die Nutzung einer gekrümmten ROI werden möglichst viele relevante Belegungen aus dem Belegungsgitter miteinbezogen. Das Klothoidenmodell $k(l)$ wird somit als separierender Verlauf herangezogen. Trotzdem ist die Krümmung der ROI anhand der Gierrate des Eigenfahrzeugs unzureichend. Dies liegt daran, dass eine Gierbewegung über die Gierrate detektiert werden kann, erst nachdem das Fahrzeug bereits in eine Kurve eingelenkt wurde. Der Verlauf der Fahrbahn muss daher früher erkannt werden. Zu diesem Zweck wurde ein hypothesenbasierter Ansatz entwickelt, der aus verschiedenen vorgegebenen Trajektorien diejenige auswählt, die den Verlauf der Fahrbahn am besten beschreibt. Im Allgemeinen existieren sehr viele potenzielle Trajektorien, die zu überprüfen sind. Daher ist eine Einschränkung des Hypothesenraums notwendig.

Abbildung 7.12 zeigt beispielhaft einige Hypothesen einer 20×8 Zellen großen ROI. Eine Hypothese beschreibt dabei einen Parabelbogen vom Mittelpunkt der ROI (entspricht der Position der Fahrzeughinterachse) zu jeweils einem Eckpunkt der vordersten Gitterzellen.

Zur Bewertung der einzelnen Hypothesen werden die Abstände in y -Richtung aller Belegungen in der ROI betrachtet. Aus den Abständen der Belegungen wird für jede Hypothese ein Histogramm erstellt, dessen Klassen den (diskretisierten) Abständen entsprechen. Negative Abstände entsprechen dabei dem linken Bereich, positive Abstände dem rechten Bereich bezüglich der Hypothese. Jede Belegung wird entsprechend ihrem y -Abstand zur Hypothese in eine der Klassen eingeordnet. Die Bewertung einer Hypothese wird nun anhand des zugehörigen Abstandshistogramms vorgenommen. Für den Fall, dass eine Hypothese den Verlauf der Fahrbahn korrekt wiedergibt, haben im Idealfall alle Fahrbahnbegrenzungen denselben Abstand zur Trajektorie. Sie werden somit derselben Histogrammkategorie zugeordnet, wodurch sich ein stark ausgeprägter Häufungspunkt ergibt. Der Bewertungsalgorithmus nutzt daher die Eigenschaft, dass eine Hypothese, deren Histogramm nur wenige, aber dafür sehr stark ausgeprägte Häufungspunkte aufweist, eine plausible Beschreibung des Straßenverlaufs darstellt, als eine Hypothese, für die die Abstände der Belegungen nahezu gleich verteilt sind. Sei $\text{hist}(h_i, \delta)$ die Funktion, die zu einer gegebenen Hypothese h_i und dem Abstand δ ($\delta \in \mathbb{Z}$) die Menge derjenigen Belegungen liefert, die dem Abstand δ im zugehörigen Histogramm zugeordnet wurden. Dann wird die Bewertungsfunktion einer Hypothese h_i wie folgt definiert:

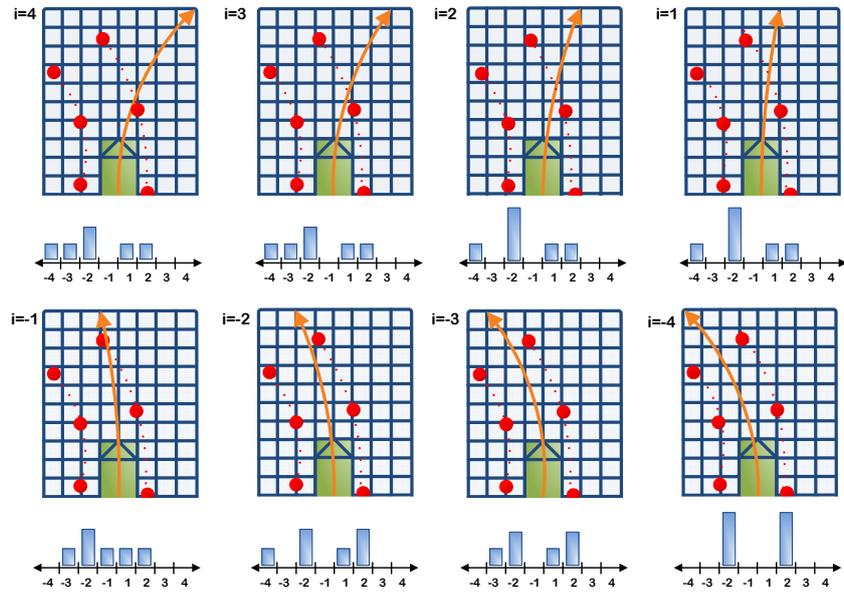


Abbildung 7.12: Hypothesen möglicher Fahrzeugtrajektorien für den vorderen Bereich einer 20x8 Gitterzellen großen ROI

$$q(h_i) = \begin{cases} 0 & \text{falls } \text{hist}(h_i, \delta_0) \neq \emptyset \ (\delta_0 \in \{-1, +1\}) \\ \frac{1}{|\{\delta \mid \text{hist}(h_i, \delta) \neq \emptyset\}|} & \text{sonst } (\delta \in \mathbb{Z}) \end{cases} \quad (7.7)$$

Eine Hypothese wird hierbei strikt mit 0 bewertet, falls es Belegungen gibt, die sehr nahe an der Trajektorienhypothese liegen, sodass eine Durchfahrt mit dem Fahrzeug im Freiraum unmöglich wäre. Die geschätzte Trajektorie h_{i^*} des Fahrzeugs ergibt sich somit zu:

$$h_{i^*} = \arg \max_{h_i} q(h_i) \quad (7.8)$$

In Abbildung 7.12 sind die Hypothesen und die dazugehörigen Histogramme dargestellt. In dem abgebildeten Szenario wird die Hypothese h_{-4} mit $q(h_{-4}) = 1/2$ nach dem vorgestelltem Schema am besten bewertet, was, wie die Abbildung zeigt, einer plausiblen Beschreibung der Fahrbahn entspricht.

Rückwärtiger Fahrbahnverlauf

Neben der vorausschauenden Bestimmung des Fahrbahnverlaufs vor dem Fahrzeug, kann auch der rückwärtige Fahrbahnverlauf (hinter dem Eigenfahrzeug) für die Stützung der Randbebauungserkennung verwendet werden. Denn meistens sind die Fahrbahnbegrenzungen im Bereich vor dem Fahrzeug eine Fortsetzung der hinteren Begrenzungen. Für den rückwärtigen Teil der ROI

ist keine hypothesenbasierte Schätzung des Fahrbahnverlaufs notwendig. Vielmehr wird auf die vom Eigenfahrzeug gefahrene Trajektorie zurückgegriffen. Hierzu werden die Fahrzeugpositionen innerhalb der ROI gemerkt. Der durch diese Positionen gebildete Verlauf definiert die Trajektorie und somit den Verlauf der Fahrbahn.

Strategie bei komplexen Szenarien

Trotz der vielen Hypothesen, die bewertet werden, können diese nicht alle Situationen abdecken. Insbesondere in Komplexen Situationen wie Bau- und Engstellen kann es vorkommen, dass keine der Hypothesen geeignet ist. In diesem Fall wird die Strategie verfolgt, die Vorausschau für die Bewertung der Hypothesen zu reduzieren. Hierzu wird der Fahrbahnverlauf bis zu einer gewissen Länge geschätzt. Diese Strategie entspricht dem menschlichen Verhalten bei z.B. eingeschränkter Sicht oder Wahrnehmungsfähigkeit.

7.3.5 Erkennung der Fahrbahnbegrenzung

Eine Trajektorien-schätzung, wie sie in Abschnitt 7.3.4 beschrieben wurde, ermöglicht für jede Belegung, d.h. für jedes Hindernis in der ROI, eine Zuordnung links oder rechts der Trajektorie. Diese Information ist wichtig, denn die Fehlklassifikation auch nur einer Belegung kann unmittelbar zu einer fehlerhaften Fahrbahnbegrenzung und möglicherweise zu einer falschen Bahnplanung führen. Trotzdem ist die Schätzung des Fahrbahnverlaufs unzureichend für die Detektion der relevanten Hindernisse, die die Fahrbahn begrenzen. Oftmals stellt sich die Situation so dar, dass sich verschiedenste Hindernisse (Leitpfosten, Baken, Bäume, Betonwände...) am Fahrbahnrand in unterschiedlichen Entfernungen zur Fahrzeug-Trajektorie befinden. Es ist daher ein weiterer Verarbeitungsschritt notwendig, der aus allen Belegungen links und rechts der geschätzten Fahrzeugtrajektorie diejenigen Belegungen ermittelt, die am wahrscheinlichsten den tatsächlichen Verlauf der Fahrbahn markieren. Diese Belegungen werden als Stützpunkte für ein virtuelles Hindernis ausgewählt. Zu diesem Zweck wurden in der Arbeit zwei Ansätze untersucht, die im folgenden erläutert werden.

Algorithmus A: Hypothesenbasierter Ansatz

Der erste Lösungsansatz knüpft unmittelbar an dem Abstandshistogramm des geschätzten Fahrbahnverlaufs. Er basiert auf der Annahme, dass Belegungen, die einen begrenzenden Verlauf bilden, in etwa demselben Abstand zum geschätzten Fahrbahnverlauf liegen. Sie gehören somit zu derselben Abstandsklasse im Histogramm der Trajektorienabstände.

In der Regel besteht das Histogramm aus mehreren Abstandsklassen. Bei der Randbebauungserkennung muss für eine Klasse, die die Fahrbahnbegrenzung bildet, entschieden werden. Ein einfacher Ansatz besteht in der Auswahl der stärksten Abstandsklassen (mit den meisten Belegungen) jeweils rechts und links. Dieser Ansatz funktioniert gut, sofern die stärkste Abstandsklasse auch die nächste zur Fahrzeugtrajektorie ist. Ein solches Szenario ist in Abbildung 7.13 (a) abgebildet. Die stärkste Abstandsklasse besteht aus den rot markierten Belegungen. Diese sind näher zur Fahrzeugtrajektorie als die gelb markierten Hindernisse und somit relevanter. Diese

7. Extraktion von Umfeldinformationen aus Belegungsittern

Konstellation tritt auf, falls z.B. Bäume oder Verkehrsschilder hinter Leitpfosten vorhanden sind. Mathematisch werden die linke und rechte Begrenzung nach diesem Ansatz gemäß der folgenden Gleichungen gebildet:

$$L = \text{hist}(h_{i^*}, \delta^*), (\delta^* \leq -1) \text{ und} \quad (7.9)$$

$$R = \text{hist}(h_{i^*}, \delta^*), (\delta^* \geq 1) \quad (7.10)$$

L und R sind jeweils die Menge der Belegungen, die einen linken und rechten begrenzenden Verlauf beschreiben. i^* bezeichnet hierbei die stärkste Hypothese der geschätzten Trajektorien und δ^* die Abstandsklasse, die als Begrenzung der Fahrbahn gewählt wurde.

Leider tritt diese Konstellation nicht immer auf. Denn in Abbildung 7.13 (a) sind die Klassen, welche die Fahrbahnbegrenzungen beinhalten, durch die beiden größten Häufungspunkte im Histogramm gegeben. Dies ist keineswegs immer so, denn durch Leitplanken oder Mauern hinter der eigentlichen Begrenzung können viel größere Häufungspunkte im Histogramm entstehen, wie es in dem Szenario in Abbildung 7.13 (b) gezeigt ist.

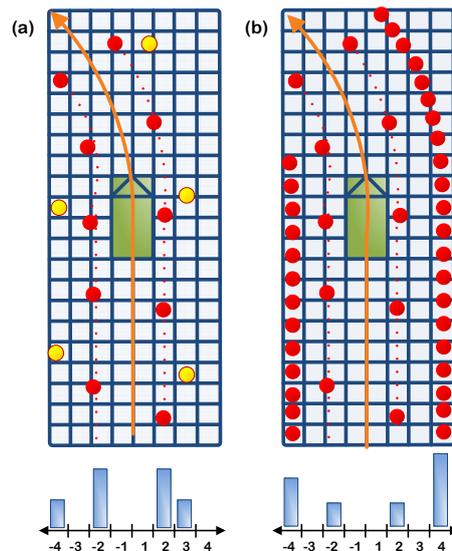


Abbildung 7.13: Zwei verschiedene Fahrbahn-Szenarien und die dazugehörigen Abstandshistogramme

Der Ansatz wurde daher erweitert, so dass jeweils zwei Schätzungen für linke und rechte Fahrbahnbegrenzungen generiert werden. Dabei ist die primäre Schätzung des Fahrbahnverlaufs durch die Abstandsklasse im Abstandshistogramm gegeben, die am nächsten an der Fahrzeugtrajektorie liegt und das Generieren eines virtuellen Hindernisses zulässt. D.h. die dazugehörige Abstandsklasse besteht aus mindestens zwei Belegungen der ROI. Die sekundäre Schätzung hingegen ist durch den größten Häufungspunkt im Histogramm gegeben, sofern dieser weiter außerhalb zur Trajektorie liegt als die primäre Schätzung:

$$\delta_{pri}^* = \min_{\delta} \{|\delta| \mid |\text{hist}(i^*, \delta)| \geq 2\} \quad (7.11)$$

$$\delta_{sek}^* = \arg \max_{\delta} \{|\text{hist}(i^*, \delta)| \mid |\delta| > |\delta_{pri}^*|\} \quad (7.12)$$

Für das Beispiel aus Abbildung 7.13 (a) liefert dieser hypothesenbasierte Ansatz somit für die linke Fahrbahnbegrenzung $\delta_{pri}^* = -2$ und entsprechend $\delta_{pri}^* = 2$ für die rechte Seite. Eine sekundäre Schätzung findet in diesem Fall nicht statt, da die primäre Schätzung bereits durch die stärkste Hypothese im Abstandshistogramm repräsentiert wird. Für das Beispiel in (b) entsprechen die primären Schätzungen ebenfalls den Klassen $\delta_{pri}^* = -2$ und $\delta_{pri}^* = 2$. Da diese jedoch nicht die stärksten Hypothesen repräsentieren, liegen die sekundären Schätzungen bei $\delta_{sek}^* = \pm 4$.

Algorithmus B: Minimale Abstände

Der hypothesenbasierte Ansatz funktioniert gut in Szenarien mit sehr regelmäßig auftauchenden Hindernissen am Fahrbahnrand. Dies trifft in vielen Umgebungen wie Landstraßen und Autobahnen zu. Insbesondere die Schätzung von zwei Hypothesen macht diesen Algorithmus zu einem sehr interessanten Ansatz, da z.B. auf Autobahnen die primäre Schätzung durch überholende bzw. überholte Fahrzeuge links und rechts des Eigenfahrzeugs entsteht und diese somit eine Beschreibung des eigenen Fahrstreifens zulässt. Die sekundäre Schätzung hingegen resultiert aus Leitplanken oder Betonwände und repräsentiert somit den Verlauf der gesamten Fahrbahn. Allerdings sind regelmäßige Begrenzungen der Fahrbahn nicht immer gegeben. Vor allem in urbanen Umgebungen mit hohem Detaillierungsgrad sind Leitpfosten oder Leitplanken keine typische Randbegrenzungen. Vielmehr sind hier unregelmäßige Begrenzungen wie Bordsteine oder Verkehrsinseln zu finden. Auch in Baustellenszenarien sind in der Regel die Randbegrenzungen nicht in regelmäßigem Abstand zur Fahrzeugtrajektorie vorhanden, so dass die Grundannahme des ersten Ansatzes nicht immer zutrifft. Ein solches Szenario ist in Abbildung 7.14 (a) dargestellt.

Eine einfache Idee zur Abdeckung dieser etwas komplexeren Szenarien besteht in der Einführung der Annahme, dass die relevanten Randbegrenzungen die nächsten zur Fahrzeugtrajektorie sind. Ein Beispiel für die Schätzung der Fahrbahnbegrenzung basierend auf dieser einfachen Idee ist in Abbildung 7.14 (b) zu sehen. Diese Auswahlstrategie selektiert jedoch auch fälschlicherweise Belegungen, die zwischen zwei Fahrbahnbegrenzungen auftauchen, was in einer nicht plausiblen Beschreibung der Fahrbahn resultiert, wie Abbildung 7.14 (b) veranschaulicht. Um diesem Problem zu begegnen wurden räumliche Beobachtungsfenstern eingeführt. Konkret wird die ROI der Länge nach in äquidistante Intervalle aufgeteilt, aus denen jeweils nur eine Belegung, nämlich die dem geschätzten Straßenverlauf am nächsten liegende, selektiert. Abbildung 7.14 (c) zeigt eine ROI, die in Intervalle der Länge $n = 4$ aufgeteilt wurde. Die gelb markierten Belegungen repräsentieren dabei diejenigen, die durch die Intervallbildung verworfen werden. Rot markierte Belegungen werden als Begrenzung der Fahrbahn interpretiert.

Die Qualität der Ergebnisse dieser Suchstrategie ist sehr stark von der Wahl der Intervalllänge n abhängig. Hier gilt es, einen Kompromiss zwischen der Berücksichtigung der relevanten Begrenzungen und der Schätzung eines gleichmäßigen nicht springenden Verlaufs zu finden. Wird

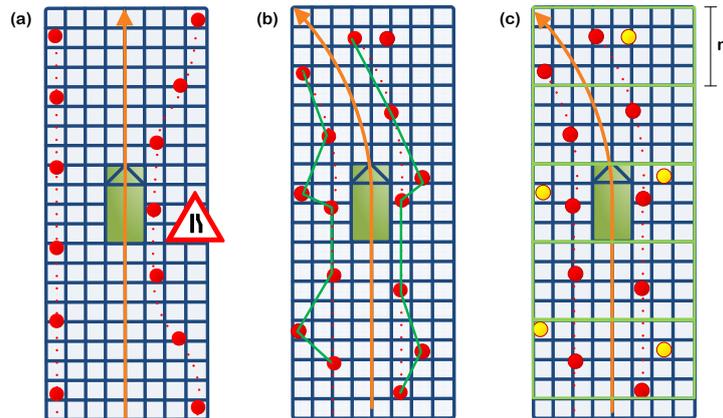


Abbildung 7.14: Verschiedene Fahrbahn-Szenarien: (a) Beispiel einer Fahrbahn-Verengung, (b) Fahrbahnschätzung mit Algorithmus B ohne Nutzung von räumlichen Beobachtungsfenstern, (c) Fahrbahnschätzung mit Algorithmus B unter Nutzung von räumlichen Beobachtungsfenstern

n zu groß gewählt, so werden eventuell für Fahrbahnbeschreibung wichtige Belegungen verworfen, bei zu kleinen Werten für n wird die Beschreibung des Straßenverlaufes durch zahlreiche irrelevante Belegungen verfälscht. Die Intervalllänge n sollte daher kleiner sein, je dichter die Begrenzungen der Fahrbahn liegen. Je größer die Abstände zwischen den Begrenzungen sind, desto größer sollte auch die Wahl von n ausfallen. In der Arbeit wird die Länge eines Suchfensters abhängig von der Fahrsituation adaptiert. Bei Stadt-Szenarien und Szenarien mit niedriger Geschwindigkeit werden Intervalle mit reduzierter Länge ausgewählt. Auf Autobahnen und Landstraßen werden Intervalle mit größerer Länge genommen. Hierzu fließen neben den Daten über die Eigenbewegung auch Informationen aus der digitalen Karte über die Domäne ein, in der sich das Eigenfahrzeug befindet. Prinzipiell kann diese Methodik so erweitert werden, dass z.B. die FAS-Funktion die Länge der Beobachtungsintervalle abhängig von der Verhaltensentscheidung und den Aktionsplänen des Systems vorgibt.

7.3.6 Bewertung und Ergebnisse

Um die Leistungen der entwickelten Methoden untereinander vergleichen zu können und daraus Erkenntnisse für Fahrerassistenzsysteme abzuleiten, ist eine systematische Bewertung erforderlich. Hierbei spielen zwei Kriterien eine wichtige Rolle in der Bewertung. Zum einen soll die Fähigkeit der Algorithmen, in alltäglichen Fahrsituationen zuverlässig sowohl den Fahrbahnverlauf als auch die Fahrbahnbegrenzungen zu erkennen, bewertet werden. Zum anderen ist die Analyse der Laufzeit der verschiedenen Algorithmen von hoher Bedeutung.

Die Komplexität der Aufgaben, die die Randbebauungserkennung zu bewältigen hat, variiert sehr stark von den Einsatz-Szenarien. So ist die Schätzung des Fahrbahnverlaufes auf Landstraßen viel weniger komplex als z.B. ein Stadtszenario, in dem parkende Autos, Kreuzungen, Gebäude und enge Kurven vorhanden sind. Daher liegt es nahe, die Bewertung nach Szenarien getrennt

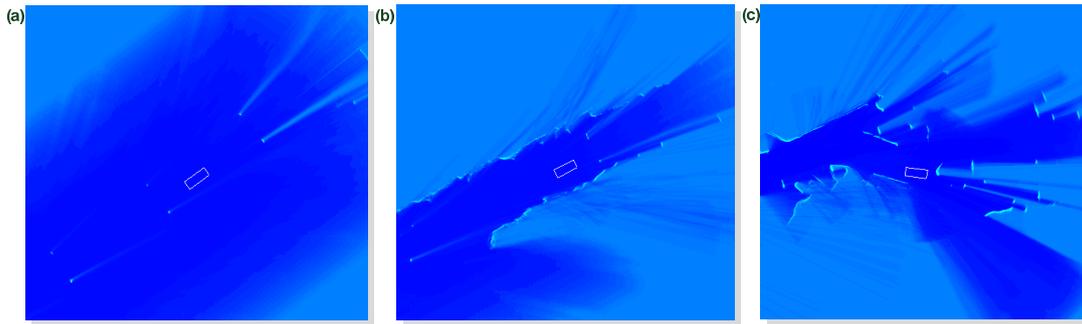


Abbildung 7.15: Beispielhafte Belegungskarten der unterschiedlichen Testszenarien: (a) einfache Fahrbahnbegrenzung durch Leitpfosten, außerorts, keine weiteren Hindernisse (b) Fahrbahnbegrenzung durch Leitpfosten, mit Bäumen und Sträuchern durchsetzt (c) Stadtszenario mit engen Kurven und vielen Hindernissen.

durchzuführen. Abbildung 7.15 vermittelt ein Gefühl über die Komplexitätsunterschiede zwischen den Szenarien. Die Testszenarien werden nach folgenden Klassen aufgeteilt:

- **Außerorts, einfache Fahrbahnbegrenzung:** Hierbei handelt es sich um das wohl einfachste Szenario. Die Straße wird durch Reflektorpfosten oder Leitplanken zur Seite begrenzt und es befinden sich keine weiteren Hindernisse in der Fahrzeugumgebung, die die Interpretation der Fahrbahnbegrenzung erschweren könnten. Abbildung 7.15 (a) zeigt beispielhaft die Belegungskarte in diesem Szenario.
- **Außerorts, beliebige Fahrbahnbegrenzung:** Deutlich komplexer ist dieses Szenario, in dem sich das Fahrzeug auf einer Landstraße mit nur sanften Kurven bewegt. Die Begrenzung der Fahrbahn ist jedoch durch verschiedene unregelmäßige Hindernisse gegeben. Leitpfosten können beispielsweise mit Gebüsch durchsetzt sein. Durch Betonwände und Leitplanken, die hinter der eigentlichen Fahrbahnbegrenzung liegen, steigt das Risiko einer Fehlinterpretation (s. Abbildung 7.15 (b)).
- **Urbane Umgebung:** Das komplexeste Szenario stellt der Stadtverkehr dar. Hier existieren in der Regel keine definierten Fahrbahnbegrenzungen wie Pfosten oder Leitplanken. Der Fahrbahnverlauf muss daher aus einer Vielzahl verschiedenster Hindernisse wie Gebäudewände, Verkehrsschilder oder parkende Autos am Straßenrand abgeleitet werden (s. Abbildung 7.15 (c)). Auch Kreisverkehre werden zu diesem Szenario hinzugezählt.

Für die Auswertung der Daten der verschiedenen Szenarien wird eine ähnliche Methodik wie bei der Dynamikerkennung in Kapitel 6.2 eingesetzt. Dazu werden gleichgroße Datensätze von jeweils ca. drei Minuten Länge pro Szenario ausgewählt und aus jedem Szenario 50 Stichproben zur Auswertung herangezogen. Die 50 Stichproben sind dabei über das ganze dreiminütige Intervall zufällig, unabhängig und gleich verteilt ausgewählt. Eine Stichprobe wird als „korrekt“ bewertet, wenn die von dem jeweiligen Algorithmus gefundenen Fahrbahnbegrenzungen einer plausiblen Beschreibung des Straßenverlaufs genügen, und „inkorrekt“ andernfalls (falsch-positiv). Des Weiteren wird eine Stichprobe als „inkorrekt“ bewertet, falls eine Fahrbahnbegrenzung eindeutig im Belegungsgitter zu erkennen ist, diese aber von dem jeweiligen Algorithmus nicht erkannt wird (falsch-negativ). Da keine Referenz über die Fahrbahnbegrenzung vorliegt, wurde die Bewer-

tung manuell durchgeführt. Von großer Hilfe sind die mit aufgezeichneten Video-Daten, die das Bewerten der Situation wesentlich vereinfachen.

Bewertung der Fahrbahnverlaufsschätzung

In Abbildung 7.16 sind eine Folge von realen Fahrsituationen abgebildet. Die geschätzte Fahrzeugtrajektorie bzw. der Fahrbahnverlauf sind als eine Folge weißer Punkte dargestellt. Die ermittelten Fahrbahnbegrenzungen sind als rote Polygonzüge in das Belegungsgitter eingezeichnet. In diesem Beispiel wurde Algorithmus B aus Abschnitt 7.3.5 zur Ermittlung der Begrenzungen verwendet. Wie in den Videoausschnitten zu sehen ist, verläuft die Fahrbahn zunächst in einer leichten Rechtskurve, gefolgt von einer Linkskurve, und mündet schließlich in einem geraden Verlauf.

In (b), (c) und (d) ist sehr deutlich erkennbar, dass nur mit Hilfe der Berechnung des Straßenverlaufs eine plausible Schätzung der Fahrbahn möglich ist. In (b) erscheinen zwei am linken Straßenrand parkende Fahrzeuge auf der rechten Seite der Fahrzeuglängsachse. Ohne korrekte Links-Rechts-Klassifikation der Belegungen in der Karte werden sie daher als rechte Begrenzung der Fahrbahn interpretiert. Die generierte Fahrbahnbegrenzung schneidet damit die tatsächliche Fahrbahn und die weitere Planung einer sicheren Fahrzeugtrajektorie ist damit nicht mehr möglich. Analoges gilt für (c). In (d) wird die Fahrbahn im Teil der ROI, der hinter dem Eigenfahrzeug liegt, ohne das Speichern der abgefahrenen Trajektorienpunkten falsch geschätzt.

Auch in anderen Szenarien liefert die Fahrbahnschätzung sehr gute Ergebnisse. Vor allem bei Autobahnausfahrten und Landstraßen schafft das System die Kurven frühzeitig zu erkennen, noch bevor es Rückmeldung über die Gierrate bekommt. Das eröffnet neue Anwendungsmöglichkeiten für das entwickelte System. Denkbar ist z.B. ein **Kurvenassistent**, der den Fahrer vor engen Kurven warnt und informiert. Der Kurvenassistent kann auch z.B. das ACC (Adaptive Cruise Control) unterstützen, so dass die Geschwindigkeit automatisch an die Krümmung der Kurve rechtzeitig angepasst wird. Abbildung 7.17 zeigt die erkannten Randbebauungsverläufe in einer engen Autobahnausfahrt.

Bewertung der Fahrbahnbegrenzungserkennung

Die Bewertung der Ergebnisse nach Szenarien haben zu folgenden Erkenntnissen geführt:

- **Algorithmus A:** Der erste Ansatz liefert bei den beiden ersten Szenarien gute Ergebnisse (über 90% korrekt). Dies liegt vor allem, dass die Hindernisse in diesen Szenarien in regelmäßigen Abständen am Fahrbahnrand zu der Fahrzeug-Trajektorie auftreten. Allerdings führen die harten Bedingungen, die dieser Ansatz an die Belegungen stellt, in einigen Fällen zur nicht vollständigen Erkennung der Fahrbahnbegrenzungen, obwohl diese im Belegungsgitter erkennbar wären. Dieser Effekt tritt etwas verstärkt bei dem dritten Szenario auf, weil sich in der urbanen Umgebung nicht alle Begrenzungen der Fahrbahn in gleichem Abstand zur Fahrzeugtrajektorie befinden.
- **Algorithmus B:** Das erste Szenario bereitet keine Schwierigkeiten für den Algorithmus B (minimale Abstände). Hier konnten bei den untersuchten Daten keine Fehlschätzungen

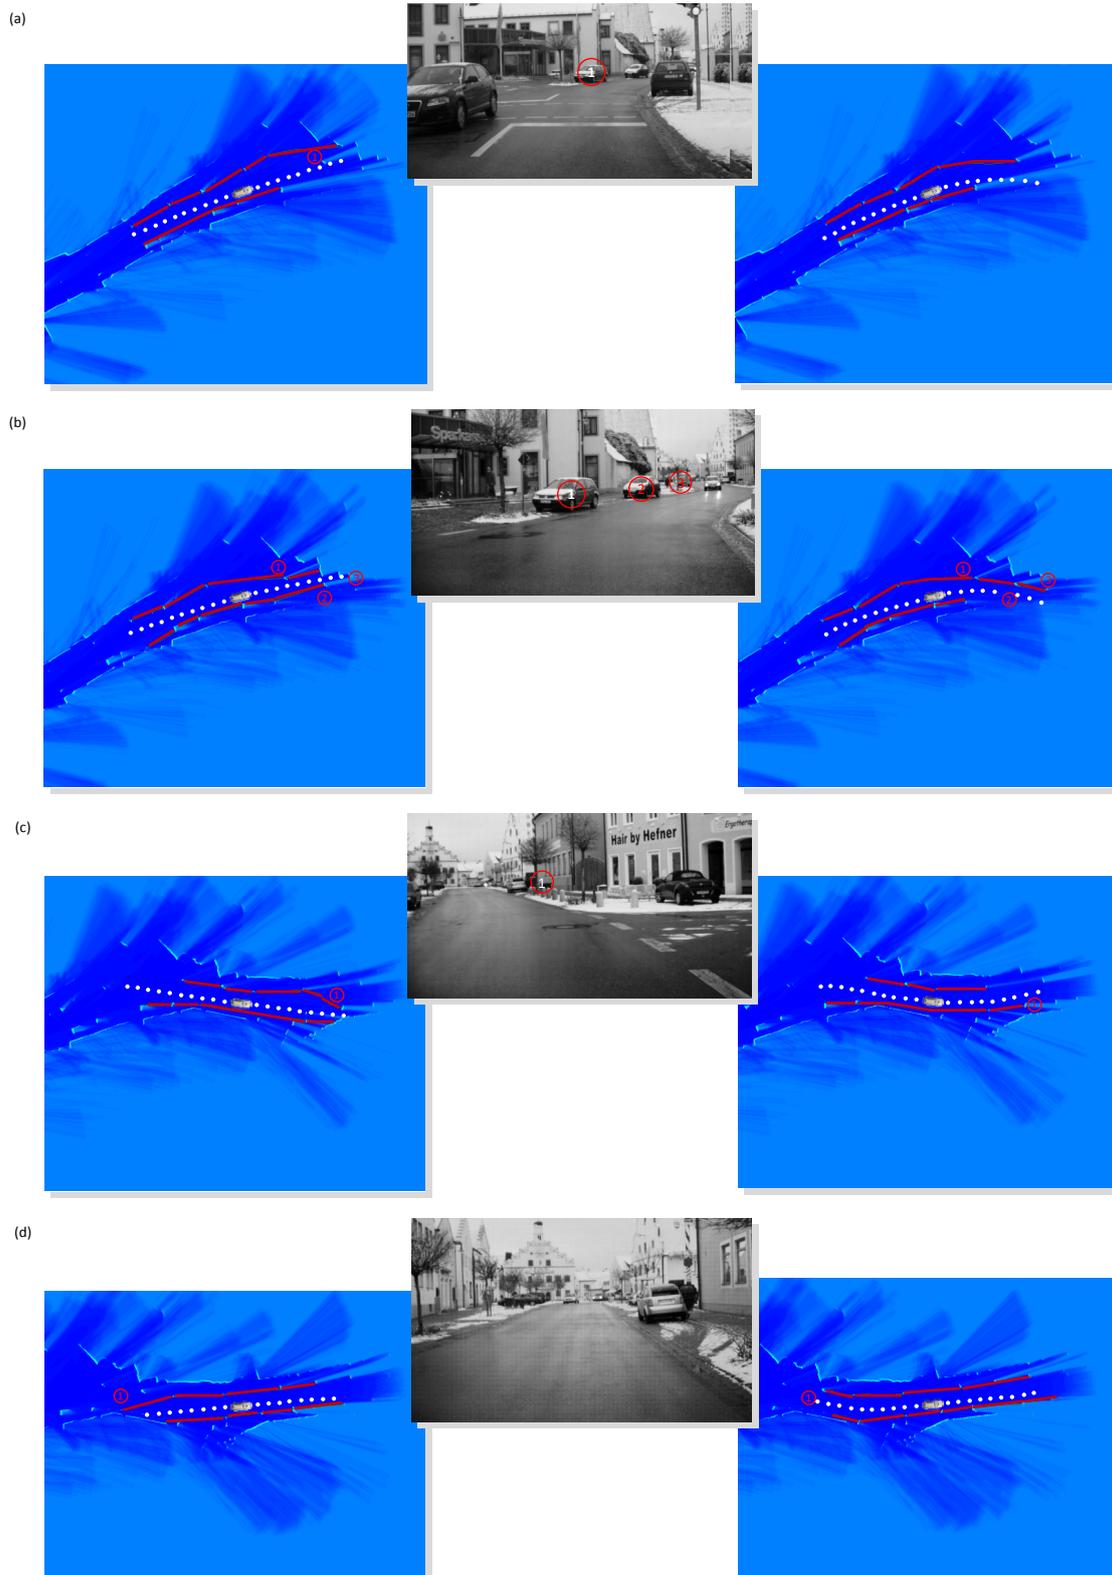


Abbildung 7.16: Beispiele für Ergebnisse der Fahrbahnverlaufsschätzung. *Links*: ohne Schätzung des Fahrbahnverlaufs. *Rechts*: Mit Schätzung des Fahrbahnverlaufs. Die geschätzten Fahrbahnbegrenzungen wurden mit Algorithmus B ermittelt und sind als rote Segmente eingezeichnet.

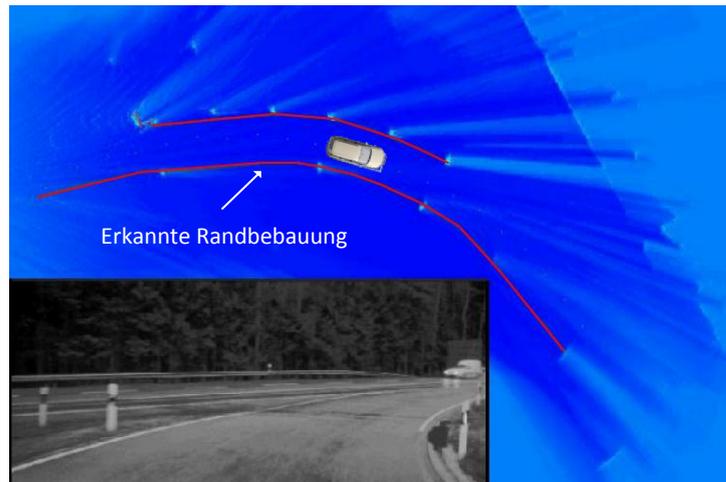


Abbildung 7.17: Erkannte Randbebauungsverläufe in einer engen Autobahnausfahrt

festgestellt werden. Der Algorithmus arbeitet im Vergleich zu dem hypothesenbasierten Ansatz mit weicheren Bedingungen. Diese Tatsache resultiert aus der wesentlich größeren Flexibilität dieses Lösungsansatzes, die auch die Nachbildung nahezu beliebiger Verläufe der Straße zulässt, da dem Algorithmus kein strenges geometrisches Modell zu Grunde liegt. Das ermöglicht bessere Ergebnisse in den Szenarien 2 und 3 als der hypothesenbasierte Ansatz. Allerdings führte auch diese hohe Flexibilität in 4% der Fälle in Szenario 2 und in 18% der Fälle in Szenario 3 zu Falsch-positiv-Klassifizierungen.

Tabelle 7.1 fasst die erzielten Ergebnisse zusammen. Aus der Tabelle lässt sich entnehmen, dass sich die entwickelten Ansätze zum Teil bei der Bewältigung der Aufgabe in den verschiedenen Szenarien ergänzen. Daher ist ein Umschalten zwischen den verschiedenen Verfahren je nach Fahrsituation denkbar.

Szenario	Algorithmus	Korrekt	Inkorrekt		Laufzeit	
			false pos.	false neg.	μ	σ
Szenario 1	Algorithmus A	98%	0%	2%	2.15ms	0.33ms
	Algorithmus B	100%	0%	0%	2.43ms	0.44ms
Szenario 2	Algorithmus A	92%	6%	2%	2.83ms	0.66ms
	Algorithmus B	96%	4%	0%	2.45ms	0.32ms
Szenario 3	Algorithmus A	78%	4%	18%	2.39ms	0.26ms
	Algorithmus B	82%	18%	0%	2.59ms	0.47ms

Tabelle 7.1: Zusammenfassung der Evaluation nach Testszenarien, implementierten Algorithmen, Erkennungsraten und Laufzeiten

8 Methoden zur Bewertung von Belegungskittern mit und ohne Hilfe eines Referenzsystems

8.1 Motivation und Methodik

Die Bewertung von Belegungskarten insbesondere von Belegungskittern stellt eine Lücke in den bisherigen wissenschaftlichen Arbeiten dar. Oft werden die Algorithmen der Belegungskarte in der Simulation bewertet. Oft wird auch die Belegungskarte visuell als Bild der Umgebung evaluiert. Dies liegt vor allem an der fehlenden Referenz, im Englischen bekannt als „*Ground Truth*“. In der vorliegenden Arbeit wurde die Bewertung der aus den Sensordaten generierten Belegungskarten als Schwerpunkt zur Schließung dieser Lücken definiert. Dabei verfolgt die Referenzierung der Belegungskarte verschiedene Ziele. Zum einen sollen mit Hilfe dieser Bewertungsmethoden quantitative Aussagen über die Qualität eines Belegungskitters getroffen werden. Zum anderen soll möglich sein, den Einfluss bestimmter Parameter auf die Qualität des Belegungskitters zu untersuchen. Mit Hilfe dieser Untersuchungen sollen Maßnahmen zur Optimierung der maschinellen Umfeldwahrnehmung anhand der Belegungskarte gefunden werden. Ein genauso wichtiges Ziel ist die Entwicklung der Fähigkeit, die Güte der vom belegungskartenbasierten Wahrnehmungssystem erzeugten Daten ohne eine externe Referenzquelle zu schätzen. Wie bereits erwähnt, verhilft diese Fähigkeit hoch automatisierten Fahrerassistenzsystemen, die Grenzen ihrer Leistung selbstständig zu ermitteln und entsprechend zu handeln.

Die verfolgte Methodik basiert zunächst auf der Analyse der Einfluss-Parameter auf die Qualität eines Belegungskitters. Danach werden Methoden entwickelt und eingesetzt, die mit Hilfe des in 2.1.5 vorgestellten Referenzsystems eine Referenz-Belegungskarte generieren und diese mit der zu bewertenden Karte vergleichen. Darüber hinaus werden Kriterien definiert, die die Qualität eines Belegungskitters ohne den Einsatz eines Referenzsystems angeben. Ihre Eignung wird ebenfalls validiert. Einige Grundlagen dieses Kapitels sind im Rahmen der vorliegenden Arbeit in [Demiral 2010] entstanden.

8.2 Analyse der Fehlerquellen

Bei der Analyse der Fehlerquellen sollen die Einflussparameter auf die Qualität eines Belegungskitters identifiziert und ihre Einflussstärke in einer einfachen Simulation bewertet werden. Der Vorteil der Simulation besteht darin, dass die ideale Welt fortlaufend bekannt ist, sodass sie für den Vergleich mit den zu bewertenden Daten miteinbezogen werden kann. In der Simulation wer-

den für die Eigenbewegung und für die Umfoldsensoren ideale Daten generiert und daraus eine Referenz-Karte gebildet. Speziell wurde ein konfigurierbares Simulationsmodell für Laserscanner entwickelt, das unter der Vorgabe der Eckpunkte von rechteckigen Hindernissen eine Liste von Entfernungswerten aufgrund der Reflexion des Lasersignals liefert. Gleichzeitig werden die Simulationsdaten mit verschiedenen Effekten verfälscht. Folgende Fehlerquellen wurden untersucht:

- **Fehler in der Eigenbewegung:** Dies betrifft Fehler in den Größen Position, Geschwindigkeit, Gierrate und Beschleunigung, die notwendig für den Aufbau der Belegungskarte sind.
- **Sensorspezifische Fehler:** Die Einbaulage, die Kalibrierung und die Latenzzeit sind neben dem Sensorrauschen sensorspezifische Fehlerquellen.
- **Fehler in der Datenverarbeitung:** z. B. Fehler in der zeitlichen Synchronisation zwischen den Eigenbewegungsdaten und den Sensordaten oder Diskretisierungsfehler aufgrund der Rasterung im Belegungsgitter.

Die Ergebnisse der Analyse in der Simulation zeigen, dass die Karten-Algorithmen vor allem gegenüber Fehler in der Geschwindigkeit, Beschleunigung und Gierrate des Eigenfahrzeugs anfällig sind. Diese Größen sind relative Dynamikgrößen, deren Fehler zu einer Änderung in der Fahrzeugposition führen. Genau die Änderung der Position ist entscheidend für die zeitliche Akkumulation der Sensordaten. Die Algorithmen sind hingegen gegen Sensorrauschen bis zu einem gewissen Grad aufgrund der Filter-Wirkung der Belegungskarte robust. Die Verfälschung anderer Parameter wie eine falsche Einbaulage des Sensors oder konstante Latenzzeit führt zu systematischen Fehlern im Belegungsgitter, wie z.B. die Verschiebung der erfassten Hindernisse zu falschen Positionen. Die Abbildungen 8.1 und 8.2 zeigen beispielhaft die Wirkung von Fehlern in der Geschwindigkeit und der Gierrate bei einer Geradeausfahrt. Hier führen die Fehler zu verschwommenen Hindernis-Konturen. Diese Feststellungen werden in Abschnitt 8.4 für die Festlegung von Kriterien für die Selbstdiagnose der Belegungskarte genutzt.

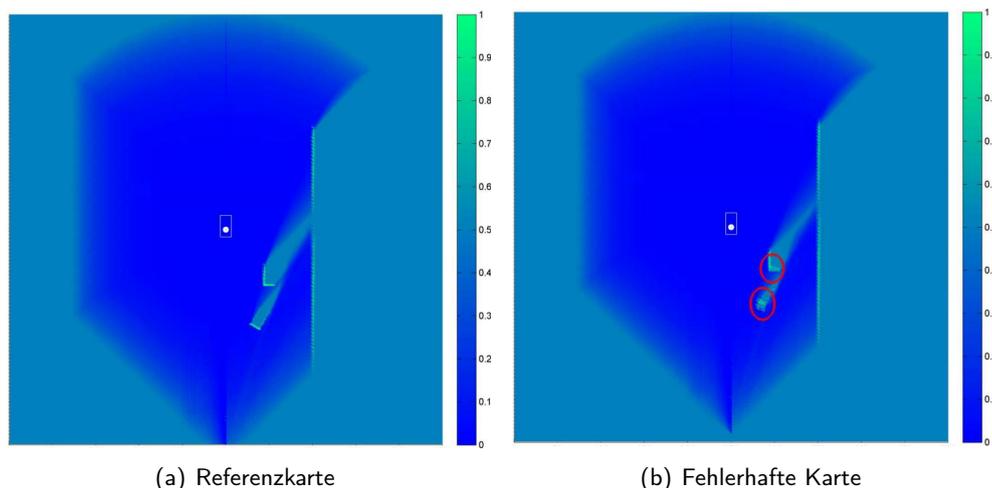


Abbildung 8.1: Wirkung eines Geschwindigkeitsfehlers von -10% bei einer Geradeausfahrt

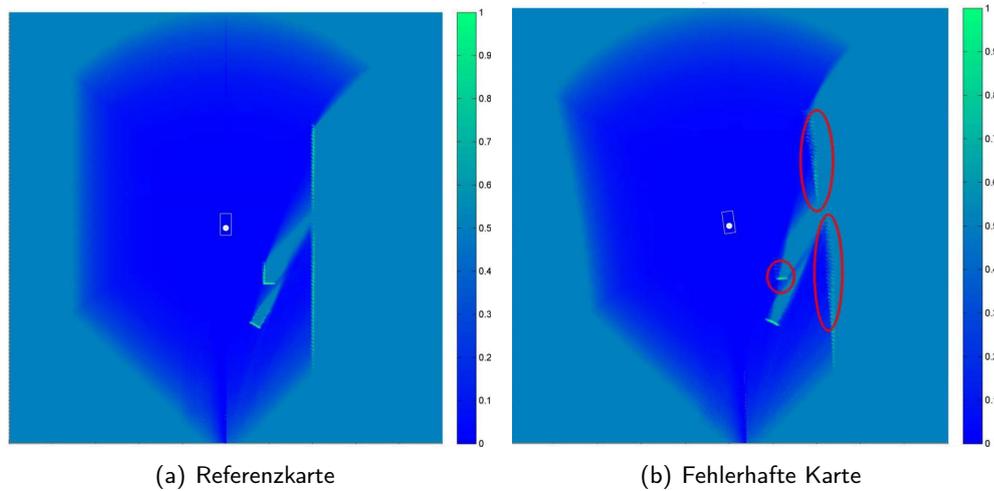


Abbildung 8.2: Wirkung eines Gierratenfehlers von $+2 \frac{\text{Grad}}{\text{s}}$ bei einer Geradeausfahrt

8.3 Referenzierung des Belegungsgitters mit Hilfe eines Referenzsystems

Die Verfügbarkeit eines Referenzsystems, das Teile der Umgebung sowie die Eigenbewegung mit hoher Genauigkeit messen kann, stellt eine große Chance für die Bewertung der Algorithmen der Umfeldwahrnehmung dar. Trotzdem ist eine direkte Referenzierung nicht gegeben, denn die Referenz-Daten und die zu bewertenden Daten haben nicht immer die gleiche Repräsentation. Es bedarf weiterer Verarbeitungsschritte der Referenzdaten, damit ein Belegungsgitter bewertet werden kann. Im Folgenden werden das entwickelte Konzept zur Referenzierung von Belegungsgittern sowie einige Ideen für seine Umsetzung präsentiert und diskutiert.

8.3.1 Konzept

Das verfolgte Referenzierungskonzept ist in Abbildung 8.3 zusammengefasst. Es basiert in einer ersten Idee auf der Erstellung einer Referenz-Karte aus den Referenzdaten. Damit die generierte Belegungskarte mit der zu bewertenden Karte vergleichbar wird, müssen beide Karten in eine einheitliche Repräsentation transformiert werden. Dieser Schritt ist notwendig aufgrund z.B. der unterschiedlichen Ausrichtungen, Auflösungen oder Dimensionen in den jeweiligen Karten. Nach der Herstellung der Vergleichbarkeit werden die Daten aus den beiden Karten gegenübergestellt und ihre Ähnlichkeit bzw. ihre Unterschiede anhand von Vergleichsmaßen ausgedrückt. Die Vorteile dieser Methode bestehen in der Möglichkeit der Bewertung von belegten, freien und unbekanntem Bereichen und in der hohen Flexibilität.

In einer zweiten Idee werden aus den Referenz-Objekten unter Berücksichtigung der Eigenschaften der Umfoldsensoren (Reichweite, Öffnungswinkel ...) eine Erwartung an den Inhalt des Belegungsgitters erzeugt. Die Projektion der Erwartung auf das Belegungsgitter ermöglicht den direkten Vergleich mit dessen Inhalt. Dieser Ansatz kann einfach implementiert werden, lässt

aber keine Bewertung der freien und unbekanntenen Bereiche in der Karte zu.

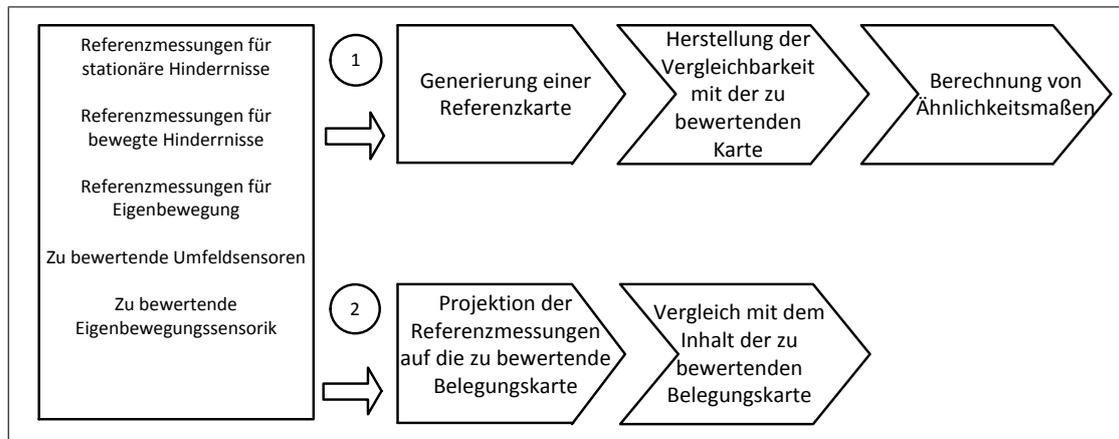


Abbildung 8.3: Bewertung der Belegungskarte mit Hilfe von Referenzsensorik

8.3.2 Generierung einer Referenz-Belegungskarte

Für die Generierung einer möglichst idealen Belegungskarte werden die Eigenbewegungsdaten und die gemessenen Objekt-Daten aus dem Referenzsystem verwendet. Der verfolgte Ansatz funktioniert nach dem folgenden Schema:

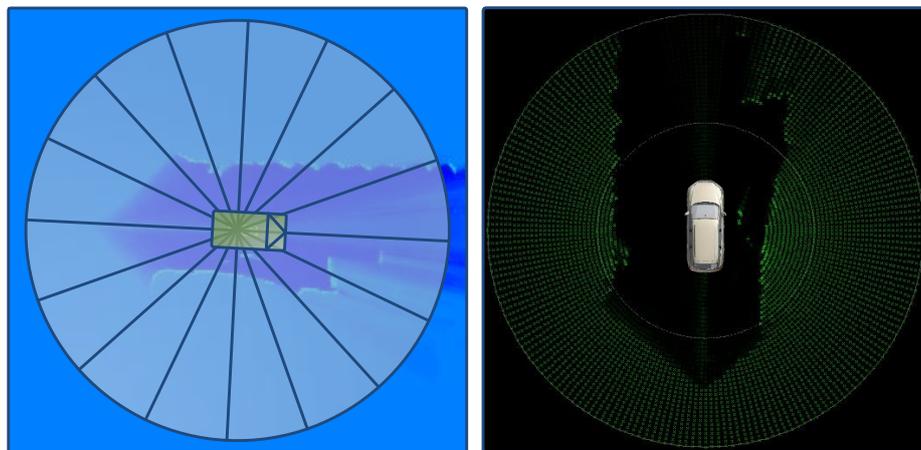
- Zunächst wird versucht, möglichst ideale Sensor-Daten, speziell Reflexionspunkte eines Laserscanners aus den Referenzdaten zu generieren. Hierzu wird ein ähnliches Simulationsmodell wie in den Abschnitten 2.1.5 und 8.2 eingesetzt. Die Simulation transformiert die Quader-Beschreibung der Objekte bzw. die Segment-Beschreibung von Leitplanken und weiteren seitlichen Hindernissen in Reflexionspunkte. Das Simulationsmodell ist so konzipiert, dass verschiedene Parameter von Laserscannern (Öffnungswinkel, Reichweite, Anzahl der Kanäle, Winkel-Auflösung, Zykluszeit ...) eingestellt werden können.
- Anschließend werden die hoch genauen Eigenbewegungsdaten aus der Referenz-Sensorik mit den simulierten Sensordaten synchronisiert. Hierfür können die Eigenbewegungsdaten auf den Zeitpunkt der simulierten Laser-Daten präzisiert werden.
- Die erstellten Eingangsdaten werden in die Karten-Algorithmen eingespeist und verarbeitet. Aufgrund der hohen Qualität der Eingangsdaten kann auf die Bayes-Mechanismen zur Schätzung der Belegungen in den Zellen verzichtet werden. D. h., es wird die Information, ob die Zelle belegt ($p = 1$), frei ($p = 0$) oder unbekannt ($p = 0.5$) ist, eingetragen.

Der Hauptvorteil des vorgestellten Konzepts ist die hohe Flexibilität. Denn die verschiedenen Einfluss-Parameter (s. Abschnitt 8.2) können in den Verarbeitungsstufen der Umfeldkartierung variiert werden. Daraus resultiert, dass eine Referenz-Belegungskarte nicht immer ideal ist. Die Variation der Einfluss-Größen ermöglicht die Erfassung ihrer Wirkung auf die Qualität der Belegungskarte.

So können z.B. die realen Umfoldsensordaten mit den Eigenbewegungsdaten aus der Referenz-Sensorik für die Erstellung einer Belegungskarte kombiniert werden. Die generierte Karte dient als Referenzkarte. Dadurch kann der Einfluss der Fehler in der Eigenbewegung gezielt untersucht werden.

8.3.3 Strahlenbasierter Vergleich zweier Belegunggitter

Die Herausforderung in dem Vergleich zweier unterschiedlicher Belegungskarten besteht in der Herstellung der Vergleichbarkeit. Denn die Belegunggitter können unterschiedliche Größen und Auflösungen haben und können im Vergleich zueinander verdreht sein. Diese Verdrehung entsteht vor allem aufgrund der unterschiedlichen Eigenbewegungssensoren, die in unterschiedliche Gierwinkel resultieren. Die standard-Eigenbewegungssensoren weisen gegenüber den teureren aber hoch genauen Referenz-Sensoren der Inertialplattform in der Regel höhere Drift-Effekte auf. Eine Lösung zur Kompensation der Unterschiede in der Größe, in der Auflösung und in der Verdrehung ist die Interpretation der Inhalte der zu vergleichenden Belegungskarten relativ zum Eigenfahrzeug. Die radiale Extraktion der Belegungsinformation ausgehend vom Eigenfahrzeug stellt eine besonders geschickte Methode dar, um den Bezug zum Eigenfahrzeug herzustellen. Die Extraktion wird auf beiden Karten in diskreten und äquidistanten Winkelbereichen bis zu einer vorgegebenen maximalen Entfernung R durchgeführt. Abbildung 8.4 zeigt das Prinzip dieser Idee.



(a) Schematische Darstellung der strahlenbasierten Extraktion (b) Extrahierte Daten aus einem realen Belegunggitter

Abbildung 8.4: Strahlenbasierte Extraktion

Bei der Extraktion der Belegungsinformation gibt es prinzipiell zwei Möglichkeiten:

1. Es werden alle Zellen, die ein gewisses Kriterium erfüllen, betrachtet. Beispielsweise alle Zellen, deren Belegungswert größer als 0.5 ist.
2. Bis zur maximalen Entfernung R wird eine vorgegebene Anzahl von m äquidistanten Zellen extrahiert.

Um festzustellen, welche Abhängigkeit- bzw. Ähnlichkeitsmaße für die Bewertung infrage kommen, wurde zunächst die Verteilung der Belegungswahrscheinlichkeit untersucht. Dazu wird die zweite vorgestellte Variante der Extraktion angewandt und eine Stichprobe über τ Kartenaktualisierungen erhoben. Nach jeder Aktualisierung werden aus den beiden zu vergleichenden Karten paarweise die Belegungswahrscheinlichkeiten der m äquidistanten Zellen auf allen n Strahlen gezogen. Auf diese Weise ergibt sich eine bivariate Stichprobe.

Bewertung anhand des *Spearman* Rangkorrelationskoeffizienten

Der *Spearman* Rangkorrelationskoeffizient wird eingesetzt, wenn die Verteilung unbekannt ist und die Bestimmung des Korrelationskoeffizienten nach *Pearson* nicht sinnvoll erscheint [52]. Außerdem setzt der *Spearman* Rangkorrelationskoeffizient im Gegensatz zum Korrelationskoeffizienten nach *Pearson* [2] keinen linearen Zusammenhang zwischen den Zufallsvariablen voraus. Für eine bivariate Stichprobe $(X_1, Y_1), \dots, (X_p, Y_p) \in \mathbb{R}^2$ mit Umfang p müssen zur Bestimmung der Rangkorrelation von X und Y zuerst die Ränge sämtlicher Elemente aus beiden Komponenten ermittelt werden.

Zur Rangbestimmung von X_i , $1 \leq i \leq p$, werden zunächst die Werte von X in aufsteigender Reihenfolge sortiert und als \mathbf{X}^* markiert. Sei dabei n_i der Index, den der Wert X_i erhält, also $X_i = X_{n_i}^*$. Der Rang $rg(X_i)$ von X_i wird folgendermaßen bestimmt:

- Existiert ein Wert nur einmalig, ist also $X_{n_i-1}^* \neq X_{n_i}^* \neq X_{n_i+1}^*$, so erhält X_i den Rang n_i , es ist $rg(X_i) = n_i$.
- Existiert $X_i = \tilde{X}$ allerdings mehrfach, so ist der Rang gerade der Mittelwert der Indizes der \tilde{X} im sortierten Vektor \mathbf{X}^* . Sei nun der Wert \tilde{X} genau k -fach in \mathbf{X}^* vorhanden und sei n_i der Index des ersten Vorkommens von \tilde{X} in \mathbf{X}^* , also

$$X_{n_i}^* = X_{n_i+1}^* = \dots = X_{n_i+k-1}^*.$$

Dann ist $rg(X_i) = \frac{1}{k} \sum_{j=0}^{k-1} n_i + j$.

Definition 1. Sei $(X_1, Y_1), \dots, (X_n, Y_n) \in \mathbb{R}^2$ eine bivariate Stichprobe. Dann wird der Rangkorrelationskoeffizient nach *Spearman* $r_s(X, Y)$ definiert durch

$$r_s(X, Y) := 1 - \frac{6 \cdot \sum_{i=1}^n \left(rg(X_i) - rg(Y_i) \right)^2}{n \cdot (n^2 - 1)} \quad (8.1)$$

Zum Vergleich von zwei Belegungskarten werden bis zu einer vorgegebenen Entfernung R , aus n Strahlen m äquidistante Zellen paarweise gezogen. Somit resultiert eine bivariate Stichprobe:

$$(X_{11}, Y_{11}), (X_{12}, Y_{12}), \dots, (X_{1m}, Y_{1m}), (X_{21}, Y_{21}), (X_{22}, Y_{22}), \dots, (X_{2m}, Y_{2m}), \dots, (X_{nm}, Y_{nm}) \quad (8.2)$$

Für diese Stichprobe wird $r_s(X, Y)$ bestimmt.

Der Rangkorrelationskoeffizient liegt im Wertebereich $[-1; 1]$. Um die verschiedenen Gütemaße miteinander vergleichen zu können, wird eine Normierung auf das Intervall $[0; 1]$ durchgeführt. Dabei soll ein Wert nahe 1 sehr starke Abhängigkeit, und somit auch Ähnlichkeit der beiden Karten bedeuten. Ein Ergebnis nahe 0 hingegen deutet auf sehr große Unterschiede hin. Die folgende Umformung liefert das gewünschte Ergebnis.

$$\frac{1}{2}(r_s(X, Y) + 1) \quad (8.3)$$

Bewertung anhand des Mahalanobis Abstands

Die Mahalanobis Distanz wird dazu eingesetzt, eine Ähnlichkeit der Merkmalsvektoren entlang der extrahierten Strahlen aus beiden Karten zu ermitteln [5]. Hierzu werden mit Hilfe des Bresenham-Algorithmus alle n Strahlen beider Karten durchwandert und die Belegungsinformationen extrahiert. Dabei werden sowohl die Belegungswerte p , die größer als p_0 sind, und deren Entfernung r zum Kartenzentrum notiert. Sei $(r_{1,ij}, p_{1,ij})^T$ das Tupel der j -ten Zelle auf Strahl i , $1 \leq i \leq n$, von Karte 1, deren Belegungswert größer als p_0 ist. Da in beiden Karten unterschiedlich viele Zellen mit $p > p_0$ vorhanden sein können, erscheint ein direkter Vergleich mit dem j -ten Tupel aus der zweiten Karte nicht sinnvoll. Stattdessen muss zunächst eine Zuordnung stattfinden. Die Assoziation wird mit Hilfe der Entfernungen r durchgeführt. D.h. für jede Belegung mit dem Abstand $r_{1,ij}$ zum Karten-Zentrum aus der ersten Karte wird die Belegung aus der zweiten Karte genommen, deren Entfernung zum Karten-Zentrum die nächste zu $r_{1,ij}$ ist.

Sei nun $(r_{2,ij}, p_{2,ij})^T$ das Tupel, das $(r_{1,ij}, p_{1,ij})^T$ zugeordnet wurde. Der dazugehörige Mahalanobis Abstand lässt sich wie folgt berechnen:

$$d_{m,ij} := d_m \left(\begin{pmatrix} r_{1,ij} \\ p_{1,ij} \end{pmatrix}, \begin{pmatrix} r_{2,ij} \\ p_{2,ij} \end{pmatrix} \right) = \sqrt{ \begin{pmatrix} r_{1,ij} - r_{2,ij} \\ p_{1,ij} - p_{2,ij} \end{pmatrix}^T \mathbf{S}^{-1} \begin{pmatrix} r_{1,ij} - r_{2,ij} \\ p_{1,ij} - p_{2,ij} \end{pmatrix} } \quad (8.4)$$

Die Kovarianz-Matrix \mathbf{S} wird aus der gesamten Stichprobe geschätzt.

$$\mathbf{S} = \begin{pmatrix} S_r^2 & S_{rp}^2 \\ S_{rp}^2 & S_p^2 \end{pmatrix} \quad (8.5)$$

Der quadratische Mittelwert aus den Mahalanobis Distanzen aller Tupel liefert ein Hinweis für die Ähnlichkeiten beider Karten.

$$d := \sqrt{ \frac{1}{n} \sum_{i=1}^n \sum_{j=1}^{n_i} d_{m,ij}^2 } \quad (8.6)$$

Dabei ist n_i die Anzahl der Tupel im i -ten Strahl.

Mit Hilfe des maximalen Abstands $d_{m,max} = \sqrt{\begin{pmatrix} R \\ 1 \end{pmatrix}^T \mathbf{S}^{-1} \begin{pmatrix} R \\ 1 \end{pmatrix}}$ kann eine Normierung durchgeführt werden, so dass die Vergleichbarkeit mit anderen Gütemaßen gewährleistet wird.

$$1 - \frac{1}{d_{m,max}} d \quad (8.7)$$

8.3.4 ROI-basierter Vergleich zweier Belegungskarten

Eine weitere Idee zur Herstellung der Vergleichbarkeit zwischen zwei Belegungskarten mit unterschiedlichen Parametern besteht in der Definition eines Aufmerksamkeitsbereiches um das Fahrzeug in den beiden Karten und in der Extraktion der Belegungsinformation in diesem Bereich. Abbildung 8.5(a) verdeutlicht das Prinzip dieser Idee. Hier wird ein Rechteck der Länge l und Breite b um das Eigenfahrzeug betrachtet. Das Rechteck besitzt die gleiche Orientierung wie das Eigenfahrzeug auf dem Belegungsgitter und wird in einer Zellenstruktur aufgeteilt, die größer als die ursprüngliche Gitterstruktur ist. In jeder der resultierenden Zellen I_{ij} wird der Schwerpunkt $\mathbf{s}_{ij} \in \mathbb{R}^2$ der Belegung nach der folgenden Formel bestimmt.

$$\mathbf{s}_{ij} := \frac{1}{N_{ij}} \sum_{(x,y)^T \in I_{ij}} p_{xy} \begin{pmatrix} x \\ y \end{pmatrix} \quad (8.8)$$

p_{xy} bezeichnet hierbei die Belegungswahrscheinlichkeit der Zelle (x, y) und N_{ij} die Anzahl der Karten-Zellen in der ROI-Zelle I_{ij} . Damit die extrahierten Daten aus den zu vergleichenden Karten in Bezug zueinander gesetzt werden können, werden sie in das Fahrzeugkoordinatensystem transformiert. Die Assoziation der Belegungsschwerpunkte aus beiden Karten erfolgt implizit über die Zellen der ROI. Seien nun n und m respektive die Anzahl der Spalten und Zeilen in den ROIs und $\mathbf{s}_{1,ij} = (x_{1,ij}, y_{1,ij})^T$ und $\mathbf{s}_{2,ij} = (x_{2,ij}, y_{2,ij})^T$ die Schwerpunkte der Zelle I_{ij} aus beiden Karten, so liefert der quadratische Mittelwert der euklidischen Abstände zwischen den Schwerpunkten aus beiden ROIs ein Maß für die Differenz der beiden Belegungsgitter.

$$d_{roi} := \sqrt{\frac{1}{n \cdot m} \sum_{i=1}^n \sum_{j=1}^m \left((x_{1,ij} - x_{2,ij})^2 + (y_{1,ij} - y_{2,ij})^2 \right)} \quad (8.9)$$

Prinzipiell können andere Maße wie der Mahalanobis-Abstand verwendet werden. Außerdem können neben dem Schwerpunkt der Belegung weitere Merkmale wie z.B. die minimale und maximale Belegungswahrscheinlichkeit innerhalb der ROI-Zelle eingesetzt werden. Mit Hilfe des

maximalen möglichen Abstands $d_{roi,max} := \sqrt{\left(\frac{l}{n}\right)^2 + \left(\frac{b}{m}\right)^2}$ kann der Mittelwert normiert werden, so dass die Größe $1 - \frac{1}{d_{roi,max}} d_{roi}$ ein Maß für die Ähnlichkeit der beiden Belegungskarten wird.

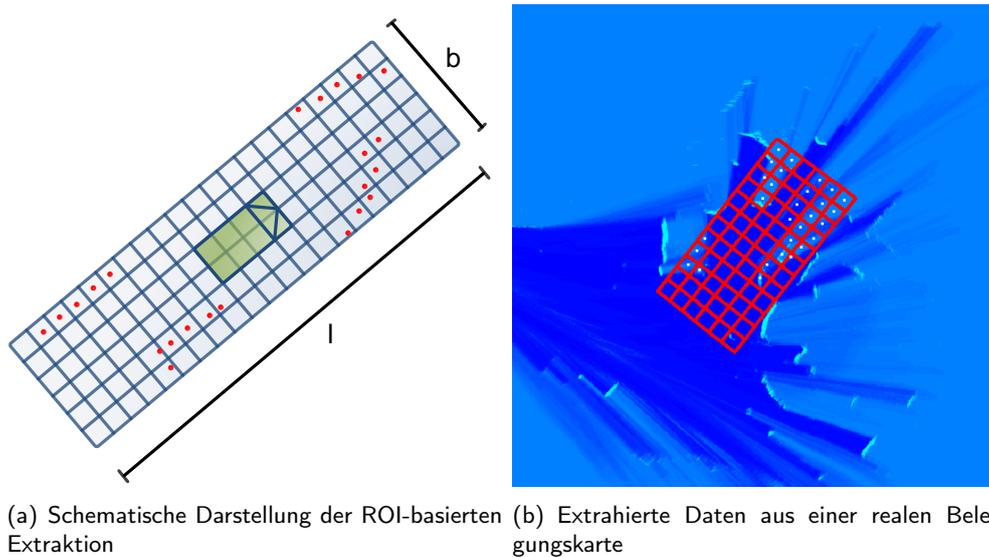


Abbildung 8.5: Prinzip der ROI-basierten Extraktion

8.3.5 Bewertung mit Hilfe von Referenz-Objekten

Eine weitere Möglichkeit zur Bewertung des Belegunggitters mit Hilfe der Referenzdaten besteht in der Generierung einer Erwartung an den Inhalt des Belegunggitters ausgehend von den Umrissen von im Vorfeld mit hoher Genauigkeit vermessenen Objekten (Leitplanken, Fahrzeuge, Leitpfosten, ...). Die Bewertung wird gemäß den folgenden Schritten durchgeführt:

- Aus der Liste der Referenz-Objekte werden die dem Fahrzeug zugewandten Seiten der Hindernisse, die in Sensor-Reichweite liegen, berechnet.
- Anschließend werden diese extrahierten Objekt-Daten durch zeitliche Prädiktion mit dem zu bewertenden Belegunggitter synchronisiert und in das Karten-Koordinatensystem transformiert.
- Im entscheidenden Schritt wird jede Objekt-Kante gemäß der Auflösung des Belegunggitters mit Hilfe des Bresenham-Algorithmus gerastert.

Es wird erwartet, dass die Zellen, durch die die Objekt-Kanten verlaufen, den Belegungswert 1 haben. Von den Zellen in direkter Umgebung der Objekt-Kanten wird erwartet, dass sie entweder die Wahrscheinlichkeit 0 oder 0.5 haben (d.h. frei oder unbekannt), sofern sie nicht zum Hindernis gehören. Aus diesem Grund wird die 8-ter Nachbarschaft der zu den Kanten zugehörigen Zellen in den Vergleich miteinbezogen. Um bereits besuchte Zellen nicht noch ein weiteres Mal in die Bewertung mit einfließen zu lassen, werden die bereits bewerteten umgebenden Zellen markiert. Sei nun $(x, y)^T$ die aktuelle vom Bresenham-Algorithmus erreichte Zelle mit der Wahrscheinlichkeit p_{xy} , und sei N_{xy} die Menge von Indizes der zu diesem Zeitpunkt bereits besuchten Pixel zusammen mit dem Index der Zelle, die als nächstes von der Linie erfasst wird. Dann ergibt sich für die aktuell untersuchte Position (x, y) folgende Fehler-Funktion, die die Abweichung zwischen

dem Belegungswert und der Erwartung beschreibt.

$$f_{xy} := (1 - p_{xy}) + \sum_{i=0; i \notin N_{xy}}^7 f(p_i) \quad (8.10)$$

p_i steht für die Belegungswahrscheinlichkeit der Zelle mit dem Index i . Die Fehlerfunktion $f(p)$ wird wie folgt definiert.

$$f(p) := \begin{cases} p & \text{für } p < 0.25 \\ 0.5 - p & \text{für } p \geq 0.25 \end{cases}, \quad (8.11)$$

wobei $n_{xy} = 1 + \sum_{i=0; i \notin N_{xy}}^7 1$ Pixel für diese Berechnung berücksichtigt wurden. Werden alle betroffenen Zellen auf dem Belegungsgitter betrachtet, so kann z.B. die Summe der Fehlerquadrate f_{xy}^2 als Maß für die Qualität des Belegungsgitters berechnet werden.

8.3.6 Ergebnisse

Für die Validierung der entwickelten Bewertungsmethoden und der generierten Qualitätsmaße wurde ein Fahrscenario aus der Funktion aktive Gefahrenbremsung ausgewählt. In diesem Szenario fährt das Eigenfahrzeug auf ein Stauende mit seitlichen Randbegrenzungen (Baken) zu. Das Fahrzeug führt kurz vor dem Stauende ein Vollbremsmanöver durch. Es wurde festgestellt, dass Fehler in der Geschwindigkeit und der Beschleunigung zu einer erheblichen Verschlechterung des Belegungsgitters führen. Somit eignet sich das Fahrscenario für die Bewertung der entwickelten Qualitätsmaße.

Um den Einfluss des Fehlers in der Eigenbewegung untersuchen zu können, wurde eine Referenzkarte festgelegt. Diese wurde mit Hilfe der Eigenbewegung aus den Referenzdaten und dem IDIS Laserscanner aufgebaut. Darüber hinaus wurden ein Belegungsgitter mit Hilfe von fehlerhaften Eigenbewegungsdaten und ein anderes Gitter mit verbesserten und Offset-kompensierten Eigenbewegungsdaten erzeugt. In beiden zu bewertenden Karten kommt der IDIS Laserscanner zum Einsatz. Der Unterschied in der Qualität zwischen den Karten ist auch visuell anhand Abbildung 8.9 zu erkennen.

Die Abbildungen 8.6, 8.7 und 8.8 zeigen die Ergebnisse der Qualitätsmaße aus dem strahlenbasierten Vergleich, aus dem ROI basierten Vergleich und aus der Bewertung anhand von Referenz-Objekten. Bei den drei Ansätzen ist zu erkennen, dass die generierten Qualitätsmaße sich verschlechtern, falls fehlerhafte Eigenbewegungsdaten eingesetzt werden.

Die entwickelten Ansätze ergänzen sich gut. Wird eine Bewertung der Belegungskarte auf Objekt-Ebene angestrebt, eignet sich am besten die Bewertung anhand von Referenz-Objekten. Wenn allgemein Belegungen in der Karte bewertet werden sollen, kann auf die ROI-basierte Methode zurückgegriffen werden. Der strahlenbasierte Ansatz ergänzt die beiden letzten Methoden, weil er die Bewertung von Freiräumen zusätzlich zulässt.

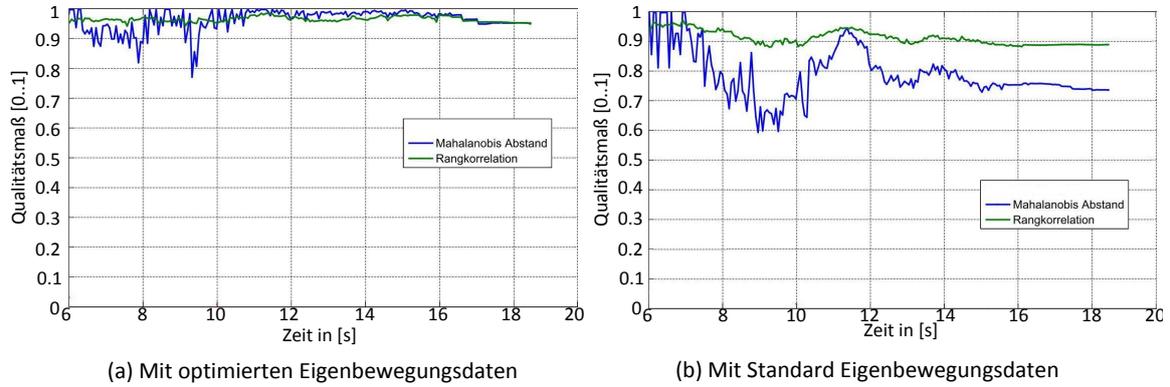


Abbildung 8.6: Ergebnisse aus dem strahlenbasierten Vergleich

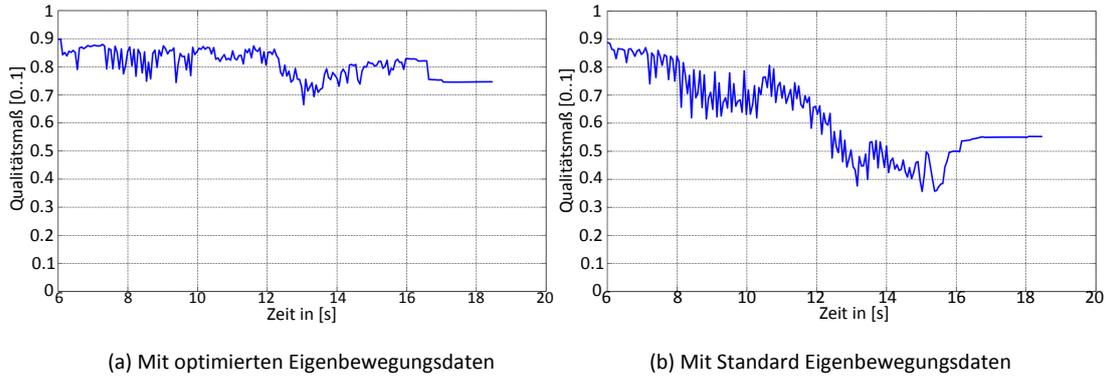


Abbildung 8.7: Ergebnisse aus dem ROI-basierten Vergleich

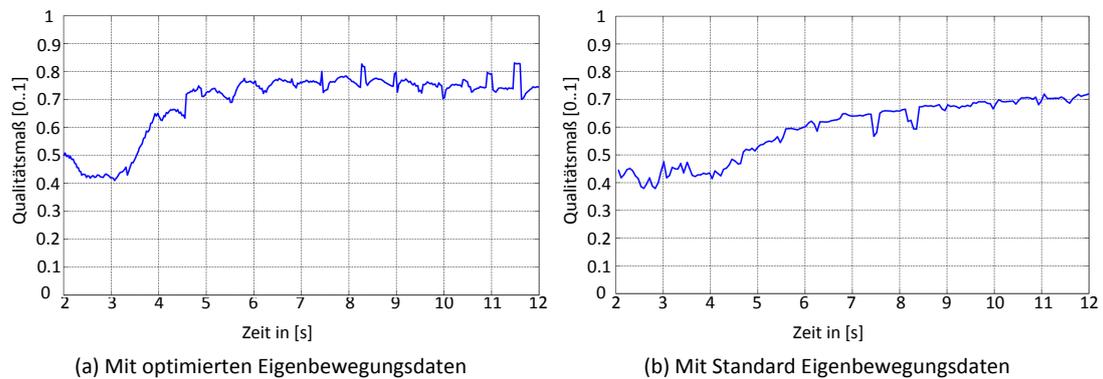


Abbildung 8.8: Bewertung mit Hilfe von Referenz-Objekten

8.4 Referenzierung des Belegungsgitters ohne ein Referenzsystem

Die Schätzung der eigenen Leistung stellt eine wichtige Fähigkeit für ein maschinelles Wahrnehmungssystem dar. Mit dieser Fähigkeit kann das hoch automatisierte Fahrerassistenzsystem während des Online-Betriebs seine Grenzen erkennen, falls seine Erfassungsleistung sich degradiert. Dieser Aspekt ist für die Gewährleistung der funktionalen Sicherheit und für die Auslegung des Systems von entscheidender Bedeutung. Der vorliegende Abschnitt beschäftigt sich mit der Fragestellung der Qualitätsschätzung der Daten eines Belegungsgitters ohne „*Ground-Truth*“. Für diesen Zweck werden zwei Methoden aufgeführt.

8.4.1 Bewertung anhand der Kantendicke

Die Ergebnisse der Simulation aus dem Abschnitt 8.2 haben gezeigt, dass eine ungenaue Karte meist durch unscharfe und breite Konturen charakterisiert ist. Diese Effekte entstehen durch Fehler in den Daten der Eigenbewegung und der Umfeldsensoren. Die Fehler verhindern die zeitliche Akkumulation der Belegungsinformationen. Die vorliegende Arbeit gereift diesen Effekt als Indikator für die Qualität eines Belegungsgitters auf. Hierbei wird versucht, die Unschärfe in den Umrissen der Hindernissen zu schätzen und diese als Qualitätsmerkmal für die Belegungskarte zu interpretieren. Die Idee ist besonders elegant, weil sie komplett auf eine *Ground-Truth* verzichtet.

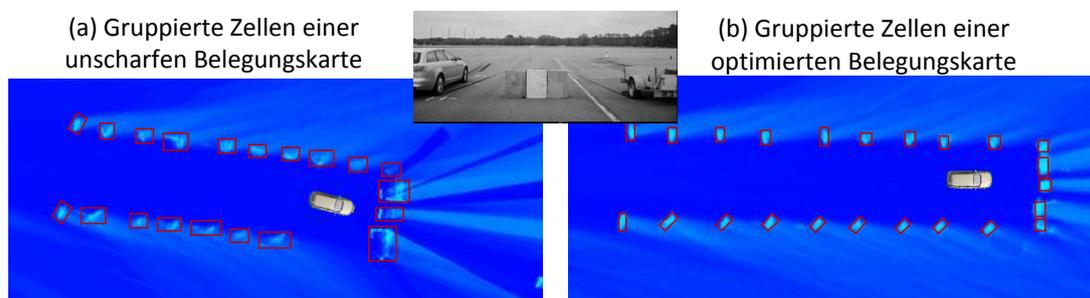


Abbildung 8.9: Gruppierete Zellen

Zur Umsetzung der Idee werden die Konturen bzw. Umrisse durch Polygonzüge ähnlich, wie bei der mehrfach erwähnten Segmentierung der Laserscanner-Daten approximiert. Aus der Streuung um eine Kante eines solchen Zuges wird auf dessen Schärfe und Erfassungsqualität geschlossen. Dazu werden zunächst die Koordinaten aller Zellen, deren Belegungswert größer als p_0 ist, extrahiert und derart gruppiert, sodass alle Punkte einer Kante in einer Gruppe liegen.

Bei der Extraktion der Koordinaten aus der Belegungskarte wird diese zeilenweise durchsucht. Die n gefundenen Zellen werden unter Berücksichtigung der Reihenfolge in der folgenden Matrix

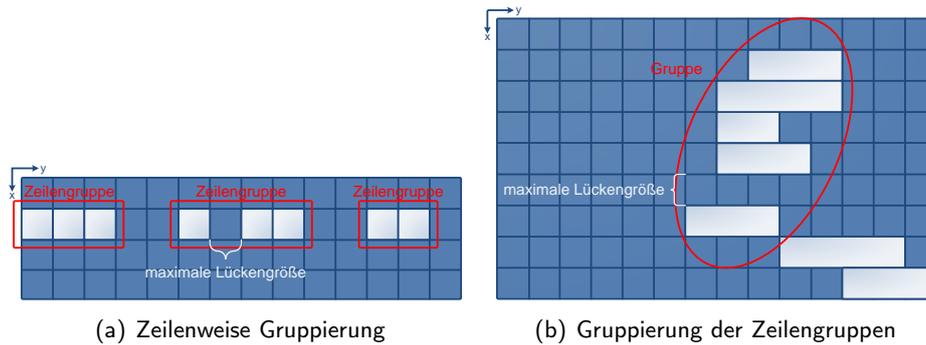


Abbildung 8.10: Regeln für die Gruppierung der Zellen

O notiert.

$$O = \begin{pmatrix} x_1 & y_1 \\ x_2 & y_2 \\ \vdots & \vdots \\ x_n & y_n \end{pmatrix} \in \mathbb{N}^{n \times 2} \quad (8.12)$$

In einem ersten Schritt werden nun die gefundenen Zellen zeilenweise gruppiert (Abbildung 8.10(a)), wobei auch hier die Reihenfolge wieder Beachtung findet. Die Elemente einer Zeilengruppe $R = (r_{ij}) \in \mathbb{N}^{p \times 2}$ besitzen alle die gleiche x -Koordinate, lassen in y -Richtung eine maximale Lücke der Breite d und sind aufsteigend sortiert:

$$\begin{aligned} r_{i1} &= r_{k1} && \text{für alle } i, k = 1, \dots, p, \\ r_{i2} &< r_{(i+1)2} && \text{für alle } i = 1, \dots, p, \text{ und} \\ r_{i2} - r_{(i+1)2} &\leq (d + 1) && \text{für alle } i = 1, \dots, p. \end{aligned}$$

Anschließend werden diese Zeilengruppen zusammengeführt, wobei außer einem maximalen Abstand von d nun auch die Ausrichtung der gesamten Gruppe beachtet wird (s. Abb 8.10(b)). Sei R_1, \dots, R_s eine Folge von s Zeilengruppen, $R_k \in \mathbb{N}^{p_k \times 2}$, $k = 1, \dots, s$, die zu einer Gruppe zusammengefasst werden, und deren x -Koordinate monoton steigt. Dann kann die Zeilengruppe R genau dann hinzugefügt werden, wenn folgende Kriterien erfüllt sind:

- Zwischen den Zeilen darf ein maximaler Abstand d liegen, also $(R)_{11} - (R_s)_{11} \leq (d + 1)$.
- Zwischen den Zeilengruppen darf ein maximaler Spalt d liegen, also $(R)_{12} - (R_s)_{p_s 2} \leq (d + 1)$ und $(R_s)_{12} - (R)_{p 2} \leq (d + 1)$.
- Ist $s > 2$, so darf der Winkel zwischen der Ausrichtung m_s der Gruppe und der Steigung m_R zwischen den Mittelpunkten der Zeilengruppen R_s und R nicht größer als $\Delta\varphi$ sein. Sei

m_s bekannt und sei

$$m_R := \frac{\frac{1}{2} \left((R)_{p2} + (R)_{12} - (R_s)_{ps2} - (R_s)_{12} \right)}{(R)_{11} - (R_s)_{11}}.$$

Dann muss $|\arctan(m) - \arctan(m_R)| \leq \Delta\varphi$ gelten.

Dabei wird m_s nach jedem Zusammenschluss mit einer neuen Zeilengruppe R berechnet als

$$m_{s+1} := \frac{n_s \cdot m_s + p \cdot m_R}{n_s + p}, \text{ mit } n_s = \sum_{k=1}^s p_k \text{ und } m_1 = 0. \quad (8.13)$$

Mit $\Delta\varphi$ wird die Feinheit der Approximation von Kurven durch Polygonzüge beeinflusst.

Der Vorteil dieser Vorgehensweise liegt darin, die Richtung der Iteration durch die Ausrichtung der Karte festzulegen, um möglichst effizient Punktmengen für die Kanten der Polygonzüge zu erhalten.

8.4.2 Überwachung des Akkumulationsverhaltens

Die Idee der Überwachung des Akkumulationsverhaltens beruht auf der einfachen Beobachtung, dass sich die Zellen eines genauen Belegungsgitters zeitlich bestätigen. Belegungsgitter mit niedriger Qualität hingegen weisen die Eigenschaft auf, dass die Belegungswerte ihrer Zellen widersprochen werden, d.h., die Belegungswerte konvergieren nicht Richtung „frei“ oder „belegt“. In diesem Abschnitt wird eine Methode zum Überwachen des Akkumulations- bzw. Konvergenzverhaltens der Zellen aufgeführt.

Dazu werden N Zellen zufällig ausgewählt. Der Auswahlprozess kann gesteuert werden, sodass eine bestimmte Zellen-Klasse (frei, unbekannt, belegt) eine höhere Wahrscheinlichkeit, gezogen zu werden, bekommt. Danach wird die zeitliche Entwicklung jeder dieses Pixels analysiert. Hierzu wird eine Art gleitendes Beobachtungsfenster eingeführt und die Anzahl der Bestätigungen bzw. Nicht-Bestätigungen innerhalb des Zeitfensters gezählt. Eine Bestätigung wird festgestellt, falls der Pixel belegt ist (Belegungswahrscheinlichkeit > 0.5) und sein Belegungswert steigt im neuen Zyklus, oder falls der Pixel frei ist und sein Belegungswert absinkt. Ein Konflikt wird hingegen registriert, falls der Belegungswert sich ändert aber invers zu einer Bestätigung. Die Länge des Zeitfensters kann entsprechend der Zielsetzung für die Beobachtung festgelegt werden. Ist es erforderlich schnell eine abrupte Verschlechterung der Belegungskarte zu erfassen, so kann ein kurzes Zeitfenster gewählt werden. Soll hingegen die Historie stärker in Betracht gezogen, ist ein längeres Zeitfenster geeignet. Bleibt der beobachtete Wert eines Pixels eine Zeit lang unverändert, wird der Pixel aus der Beobachtungsliste entfernt und ein neuer Punkt wird ermittelt. Als Maß für die Bestätigung bzw. Qualität eines Pixels wird das Verhältnis der Anzahl der Bestätigungen zu der Anzahl der gesamten Veränderungen innerhalb des Beobachtungszeitfensters genommen. Der Mittelwert dieses Quotienten über alle beobachtete Pixel liefert ein Maß für die Qualität des Belegungsgitters.

$$AccQuot = \frac{\sum_{k=1}^N \frac{n_{Best}}{n_{Ver}}}{N} \quad (8.14)$$

Selbstdiagnose

Neben der aktuellen Qualität des Belegungsgitters ist auch die maximale Zeit, in der eine gewisse Qualität bzw. Genauigkeit der Umfeldrepräsentation gehalten wird, für Fahrerassistenzsysteme mit hohem Automatisierungsgrad von großem Nutzen. Diese Zeit kann für das worst-case Szenario ermittelt werden, indem für jedes betrachtete Belegt-Pixel die Anzahl der notwendigen Zyklen ermittelt wird, damit der dazugehörige Belegungswert unterhalb eines kritischen Wertes sinkt. Unter der Annahme, dass sich der Belegungszustand auf der Bayes-Kennlinie bewegt, kann die übrige Zeitdauer ΔT_{krit} bis zum Erreichen eines kritischen Wertes p_{krit} ausgehend vom aktuellen Belegungswert p wie folgt berechnet werden. q und t_{zyk} bezeichnen dabei respektive die Update-Konstante in „LogOdds“ (siehe Kapitel 2.3.3) für den Zustand frei und die Zykluszeit der Aktualisierung des Belegungsgitters.

$$\Delta T_{krit} = \frac{(\text{LogOdds}(p) - \text{LogOdds}(p_{krit}))}{q} \cdot t_{zyk} \quad (8.15)$$

Die ermittelte Zeit ist eine wichtige Information für das System, um seine Aktionsstrategie in komplexen Umgebungen und schwierigen Situationen anzupassen. Abhängig von dieser Größe können die Zeitpunkte der Fahrerwarnungen bzw. die Fahrer-Übernahmeaufforderungen bei auftretenden Grenzsituationen (Verlassen der Funktionsdomänen, Verschlechterung der Wahrnehmungsleistung, ...) ausgelegt werden.

8.4.3 Ergebnisse

Für die Bewertung der vom Belegungsgitter selbst generierten Gütemaße wurde hier auf die bereits erwähnten Szenarien der aktiven Gefahrenbremsung zurückgegriffen. Abbildung 8.11 zeigt die detektierte Kantendicke bei zwei Belegungsgittern. Beim Ersten wurden Eigenbewegungsdaten aus den Referenzdaten eingesetzt. Beim Zweiten hingegen wurden die Standard-Eigenbewegungssensoren verwendet. In beiden Karten kam der IDIS Laserscanner zum Einsatz. Die Verwendung der fehlerbehafteten Eigenbewegungsdaten führt zu einer Verschlechterung der Akkumulation und resultiert in breite Umrisse der Hindernisse. Das mit Hilfe der Referenzdaten aufgebaute Belegungsgitter ist zwar qualitativ besser, die Umrisse sind trotzdem nicht sehr fein, da die Messdaten des Laserscanners Fehler enthalten.

In der Abbildung 8.12 sind die Verläufe des gemäß Gleichung 8.14 definierten Akkumulationsquotient aufgetragen. Auch hier ist der Unterschied in der Qualität der Belegungsgitter aufgrund der unterschiedlichen verwendeten Eigenbewegungsdaten zu erkennen. Falls die Referenzdaten eingesetzt werden, bewegt sich der Akkumulationsquotient zwischen 0.9 und 1.

Für die Validierung der Methode der Selbstdiagnose wurde eine Fehlfunktion des Laserscanners simuliert, indem das Belegungsgitter ab einem bestimmten Zeitpunkt nur durch Freirauminformationen aktualisiert wurde. Dadurch werden die detektierten Hindernisse mit der Freirauminformation überschrieben. Als Konsequenz sinkt die maximale Zeit bis zum Unterschreiten eines kritischen Akkumulationsmaßes und somit die Konfidenz des Belegungsgitters im Vergleich zum Nicht-Ausfall des Sensors dramatisch (s. Abbildung 8.13).

8. Methoden zur Bewertung von Belegungsgittern mit und ohne Hilfe eines Referenzsystems

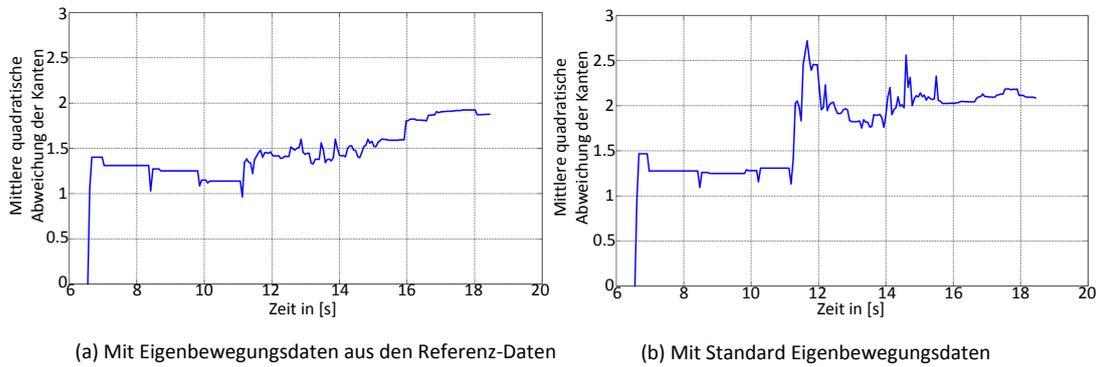


Abbildung 8.11: Ergebnisse aus der Bewertung anhand der Kantendicke

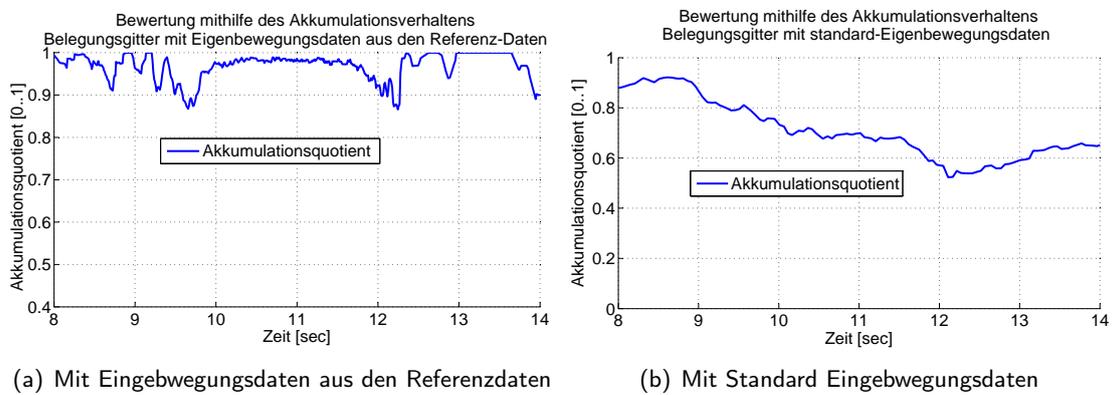


Abbildung 8.12: Bewertung anhand der Überwachung des Akkumulationsverhaltens

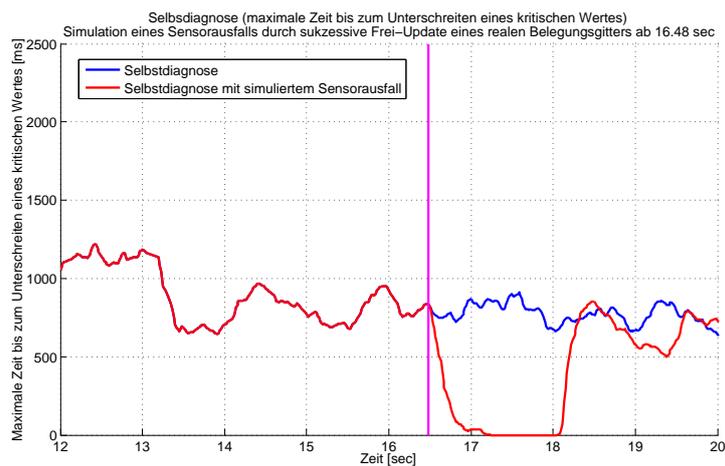


Abbildung 8.13: Validierung der Selbstdiagnose

9 Zusammenfassung und Ausblick

9.1 Zusammenfassung

Die genaue und vollständige Erfassung des Fahrzeugumfelds mithilfe von Umfoldsensoren ist eine entscheidende Voraussetzung für die Realisierung von Assistenzsystemen mit hohem Automatisierungsgrad bis hin zu autonomen Fahrzeugen. Die belegungskartenbasierte Umfeldrepräsentation stellt dabei einen wichtigen noch nicht vollständig erforschten Grundbaustein für die Umfeldwahrnehmung dar. Das Ziel der Arbeit bestand deswegen in der Entwicklung verschiedener belegungskartenbasierter Repräsentationen, deren Bewertung und Kombination mit den bestehenden objektbasierten Ansätzen, damit sie für Fahrerassistenzsysteme genutzt werden können.

Der Aufbau eines genauen und korrekten Bildes über die Umgebung des Fahrzeugs setzt eine möglichst präzise Interpretation der Sensordaten und die Berücksichtigung der Sensor-Unsicherheiten voraus. Die Arbeit stellt für diesen Zweck Methoden sowohl für die Analyse von Umfoldsensoren am Beispiel eines Laserscanners und eines Doppel-Radarsystems als auch für die Modellierung von Sensoreffekten zur Verfügung. Im nächsten Schritt hat sich die Arbeit mit dem Aufbau von verschiedenen belegungskartenbasierten Umfeldrepräsentationen mithilfe der Sensordaten und der Sensor-Interpretationsmodelle beschäftigt. Hierfür sind neben dem klassischen Belegungsgitter weitere kompakte Formen wie die intervallbasierte Freiraum-Repräsentation und neuartige Ansätze zur Berücksichtigung der Höhe entstanden.

Die in Kapitel 6 vorgestellte Strategie zur Kopplung der Belegungskarte mit der Objektverfolgung gewährleistet eine konsistente Beschreibung des Fahrzeugumfelds und erweitert die klassische Belegungskarte um die Beschreibung dynamischer Hindernisse. Mit dieser Erweiterung eröffnen sich neue Möglichkeiten für den Einsatz der Belegungskarte wie z.B. die Detektion von Freiräumen in hochdynamischen Szenen.

Aufgrund der Beschränkungen in der Bandbreite von Fahrzeug-Bussystemen und des niedrigen Abstraktionsniveaus der Daten aus dem Belegungsgitter wurde eine zusätzliche Informationsschicht eingeführt. Diese soll abhängig von der Assistenz-Funktion eine Verdichtung der Informationen und eine Vereinfachung ihrer Interpretierbarkeit erzielen. Hierzu wurden zwei Anwendungen dieser Extraktionsschicht aufgezeigt: zum einen eine Freiraum- und Belegungsextraktion, zum anderen eine Extraktion von Randbebauungsverläufen.

Eine weitere wissenschaftliche Lücke, die die Arbeit adressiert hat, besteht in der Entwicklung von Bewertungsmethoden für das Belegungsgitter. Die notwendigen Verarbeitungsschritte für die Nutzung der Referenz-Daten zum Bewerten eines Belegungsgitters und das Ausdrücken der Qualität in Form von Gütemaßen wurden im Rahmen der Arbeit aufgeführt. Außerdem sind

Ansätze für die Durchführung einer Selbstdiagnose zur Überwachung der eigenen Leistung ohne „Ground-Truth“ entstanden.

Der Nutzen der entwickelten Methoden und Ansätze wurde anhand zweier Fahrerassistenzsysteme aufgezeigt. Zum einen wurde im Rahmen des Förderprojekts AKTIV ein aktives Sicherheitssystem, das mithilfe der erweiterten Umfeldbeschreibung (Detektion von Randbebauung und Freiräumen) ein unfallvermeidendes Bremsmanöver in kritischen Situationen ohne Bevormunden des Fahrers durchführt, entwickelt. Zum anderen wurde im Rahmen eines weiteren Forschungsprojektes ein System zur Stauassistentz realisiert, das auf Basis der entwickelten belegungskartenbasierten Methoden ein automatisches Fahren in Stausituationen und komplexen Baustellen-Szenarien ermöglicht.

9.2 Ausblick

Die Arbeit stellt einige Grundlagen für die Weiterentwicklung der belegungskartenbasierten Umfeldrepräsentation und deren Einsatz bei Fahrerassistenzsystemen bereit. Einerseits können die in der Arbeit entwickelten Repräsentationen (2D-Belegungskitter, Intervall-Repräsentation, verschiedene 3D-Belegungskarten) kombiniert werden. Sowohl die Mechanismen für die Überführung der Repräsentationen ineinander als auch die intelligente Steuerung der Mechanismen abhängig von der Zielsetzung des Assistenzsystems und der zur Verfügung stehenden Ressourcen, sind zu entwickeln.

Andererseits lässt sich das präsentierte Konzept der Kopplung der Belegungskarte mit der modellbasierten Objektverfolgung für weitere Anwendungen wie Objekt-Klassifikation, Bewertung von Modell-Hypothesen und Herleitung von Objekt-Existenzwahrscheinlichkeiten weiterentwickeln und anpassen.

Abschließend können die aufgeführten Methoden zur Bewertung der Belegungskitter für ihre Anwendung auf andere Repräsentationen (intervallbasierte Repräsentation und 3D-Belegungskarten) weiterentwickelt und angepasst werden. Außerdem ist eine Gewichtung der generierten Qualitätsmaße abhängig vom jeweiligen Fahrerassistenzsystem denkbar, sodass die Interpretation der Bedeutung dieser Qualitätsmaße vereinfacht wird.

A Versuchsträger

Für die prototypische Umsetzung und Validierung der entwickelten Methoden wurden reale Sensordaten eingesetzt. Die Sensoren wurden in Versuchsträgern integriert. Für die zweidimensionalen Belegungskarten wurden ein Laserscanner mittig hinter dem Kühlerschutzgitter und ein Doppel-Radarsystem an den Ecken designverträglich verbaut. Abbildung A.1(a) zeigt den vorderen Bereich des Versuchsträgers.



(a) Versuchsträger mit integrierten Umfeldsensoren (b) Messtechnik im Kofferraum des Versuchsträgers

Abbildung A.1: Versuchsträger und Messtechnik

Für die Realisierung der dreidimensionalen Ansätze wurden ein 3D Laser-Sensor und der Ibeo Lux mit einer speziellen Saugknopfhalterung auf der Motorhaube eingebaut. Neben den Sensoren verfügt der Versuchsträger über ein Rechner-System und eine CAN/Flexray Vernetzung, die die Anbindung der Sensoren an den Rechner ermöglichen (siehe Abbildung A.1(b)). Mithilfe einer speziellen Software (ADTF, *Automotive Data And Time Triggered Framework*) können die Sensordaten unter Berücksichtigung ihrer Zeitstempel eingelesen und aufgenommen werden.

B Formeln und Definitionen aus der Wahrscheinlichkeitstheorie

Zufallsvariablen

Definition 2. Jede auf der Ereignismenge eines Zufallsexperimentes definierte reelle Funktion wird als **Zufallsvariable** definiert. Ist X das Symbol einer Zufallsvariable, so wird die reelle Zahl, die dem Ereignis ξ aus dem Ereignisraum Ω durch x zugeordnet wird, mit $X(\xi)$ bezeichnet.

Es gibt diskrete Zufallsvariablen, die bei Zufallsexperimenten mit abzählbaren Ereignissen auftreten (z.B. Werfen einer Münze). Bei diskreten Zufallsvariablen besitzt jedes Ereignis ξ_i eine Wahrscheinlichkeit $P(X = \xi_i)$. Kontinuierliche Zufallsvariablen sind immer mit Experimenten verbunden, bei denen die Ereignisse nicht abzählbar sind. Sie werden durch die Wahrscheinlichkeitsverteilung und die Wahrscheinlichkeitsdichte beschrieben, die im Folgenden beschrieben werden.

Definition 3. Die **Wahrscheinlichkeitsverteilung** $F_X(x) = P\{X \leq x\}$ einer Zufallsvariable X gibt die Wahrscheinlichkeit P an, mit der der Funktionswert von X kleiner oder höchstens gleich x ist.

Definition 4. Die **Wahrscheinlichkeitsdichte** einer Zufallsvariable X ist $f_X(x) = \frac{dF_X(x)}{dx}$. Die Wahrscheinlichkeitsdichte wird auch als $p(x)$ bezeichnet.

Für diskrete und kontinuierliche Zufallsvariablen gelten folgende Eigenschaften:

$$\begin{array}{ll} P(x) \geq 0 & p(x) \geq 0 \\ \sum_x P(x) = 1 & \int_{-\infty}^{+\infty} p(x) dx = 1 \end{array}$$

Im Folgenden werden kontinuierliche Zufallsvariablen betrachtet. Die aufgeführten Formeln sind übertragbar auf diskrete Zufallsvariablen.

$p(x|y) = \frac{p(x,y)}{p(y)}$ bezeichnet die Wahrscheinlichkeitsdichte der Zufallsvariable X unter der Bedingung, dass das Ereignis $Y = y$ eingetreten ist. $p(x, y)$ wird als gemeinsame Wahrscheinlichkeitsverteilung bezeichnet.

Satz der totalen Wahrscheinlichkeit

$$p(x) = \int p(x, y) dy \quad (\text{B.1})$$

$$= \int p(x|y) p(y) dy \quad (\text{B.2})$$

$$p(x|y) = \int p(x|y, z) p(z|y) dz \quad (\text{B.3})$$

Bayes Regel

$$p(x|y) = \frac{p(y|x) p(x)}{p(y)} \quad (\text{B.4})$$

$$= \eta \cdot p(y|x) p(x) \quad (\text{B.5})$$

$$= \frac{\textit{likelihood} \cdot \textit{prior}}{\textit{evidence}} \quad (\text{B.6})$$

$$\eta = p(y)^{-1} = \frac{1}{\int p(y|x) \cdot p(x) dx} \quad (\text{B.7})$$

Bayes Regel mit Hintergrundwissen

$$p(x|y, z) = \frac{p(x, y, z)}{p(y, z)} \quad (\text{B.8})$$

$$= \frac{p(y|x, z) p(x|z)}{p(y|z)} \quad (\text{B.9})$$

Statistische Unabhängigkeit

Falls die Zufallsvariablen X und Y statistisch unabhängig sind, gelten folgende Zusammenhänge:

$$p(x|y) = p(x) \quad (\text{B.10})$$

$$p(x, y) = p(x) p(y) \quad (\text{B.11})$$

$$p(x, y|z) = p(x|z) p(y|z) \quad (\text{B.12})$$

C Zustandsschätzung

In diesem Kapitel werden einige einführende Grundlagen zur Estimationstheorie präsentiert. Diese Grundlagen werden sowohl für den Aufbau der Belegungskarte als auch für die Objektverfolgung benötigt. Ein Zustand bezeichnet die Menge von Eigenschaften, die das betrachtete System charakterisieren und somit beschreiben. Beispiele hier sind die Position eines Objektes oder die Belegung einer Zelle. Zunächst wird in einem ersten Abschnitt auf die Zustandsraumdarstellung eingegangen, die die Basis einiger Zustandsschätzer wie das Kalman-Filter bildet. Für detaillierte Herleitungen sei auf die breite Fachliteratur zu diesem Themenbereich verwiesen [33], [61], [63].

C.1 Zustandsraumdarstellung

Basis einer Zustandsschätzung ist ein zeitdiskretes Zustandsraummodell, das in einer expliziten Form allgemein wie folgt dargestellt werden kann [25], [97].

$$\mathbf{x}(k+1) = \mathbf{f}(\mathbf{x}(k), \mathbf{v}(k)) \quad (\text{C.1})$$

$$\mathbf{y}(k+1) = \mathbf{h}(\mathbf{x}(k), \mathbf{n}(k)) \quad (\text{C.2})$$

$\mathbf{x}(k)$ bezeichnet den zu schätzenden mehrdimensionalen Zustandsvektor zum Zeitpunkt k . $\mathbf{y}(k)$ bezeichnet entsprechend den zum Zeitpunkt k eintreffenden mehrdimensionalen Messvektor. Gleichung C.1 definiert die Systemdynamik und beschreibt die diskreten Zustandsübergänge $\mathbf{x}(k) \rightarrow \mathbf{x}(k+1)$ unter dem zusätzlichen Einfluss des mehrdimensionalen Systemrauschens $\mathbf{v}(k)$. Gleichung C.2 definiert das Messmodell und modelliert den zum Zeitpunkt k bestehenden Zusammenhang zwischen der aktuellen Messungen $\mathbf{y}(k)$, dem aktuellen Zustandsvektor $\mathbf{x}(k)$ und dem mehrdimensionalen Messrauschen $\mathbf{n}(k)$. Das Messmodell wird im Kapitel 3 detaillierter behandelt. Die dabei verwendeten Funktionen \mathbf{f} und \mathbf{h} sind im allgemeinen Fall nichtlineare, zeitvariante Funktionen.

Die Modell- und Messunsicherheiten in den Gleichungen C.1 und C.2 werden jeweils durch die System- und Messrauschen berücksichtigt. Diese werden als unkorrelierte weiße Prozesse vorausgesetzt, die zu jedem diskreten Zeitpunkt k durch die vom aktuellen Zustand abhängigen Wahrscheinlichkeitsdichten $p(\mathbf{v}(k) | \mathbf{x}(k))$ und $p(\mathbf{n}(k) | \mathbf{x}(k))$ vollständig beschrieben werden. Die Annahme weißer Rauschprozesse hat den Vorteil, dass das Zustandsraummodell als ein Markov-Modell erster Ordnung aufgefasst werden kann. Dieses Modell ist dadurch gekennzeichnet, dass in dem Zustand $\mathbf{x}(k)$ alle statistische Informationen enthalten sind, d.h. der neue Zustand $\mathbf{x}(k+1)$ hängt nur vom Zustand $\mathbf{x}(k)$ ab. In den meisten Fällen gehen die Rauschvektoren $\mathbf{v}(k)$ und $\mathbf{n}(k)$ additiv in die System- und Messgleichung ein, so dass folgende vereinfachte Form der Systembeschreibung entsteht.

$$\mathbf{x}(k+1) = \mathbf{f}(\mathbf{x}(k)) + \mathbf{v}(k) \quad (\text{C.3})$$

$$\mathbf{y}(k+1) = \mathbf{h}(\mathbf{x}(k)) + \mathbf{n}(k) \quad (\text{C.4})$$

Werden die Funktionen f und h als linear angenommen, so resultiert die gewohnte lineare Zustandsraumbeschreibung.

$$\mathbf{x}(k+1) = \mathbf{A}(k) \cdot \mathbf{x}(k) + \mathbf{v}(k) \quad (\text{C.5})$$

$$\mathbf{y}(k+1) = \mathbf{H}(k) \cdot \mathbf{x}(k) + \mathbf{n}(k) \quad (\text{C.6})$$

Dabei stehen $\mathbf{A}(k)$ und $\mathbf{H}(k)$ für zeitvariante Matrizen.

Die Bestimmung der Systemgleichungen und deren Parameter geschieht klassischerweise in einem Modellbildungsschritt. Aufgrund der physikalischen Prinzipien der zu modellierenden Systeme, entstehen meistens zeitkontinuierliche Differentialgleichungen, die zunächst in ein System zeitdiskreter Differentialgleichungen überführt werden muss. Die zeitdiskrete Systembeschreibung ermöglicht die Verarbeitung auf einem Digitalrechner und ist daher wichtig. Prinzipiell gibt es für die Diskretisierung der Systembeschreibung zwei Vorgehensweisen:

- Analytisches Lösen der DGLs und Abtasten der Lösung zu zeitdiskreten Zeitpunkten.
- Numerische Integration der DGLs.

Im Falle linearer Zustandsdifferentialgleichungen kann eine analytische Lösung mit Hilfe der Laplace-Transformation bewerkstelligt werden. Ist die Systembeschreibung hingegen nichtlinear, ist eine analytische Lösung oftmals zu kompliziert und eine approximative Lösung daher notwendig. Weitere Details zu der Vorgehensweise bei der Bestimmung der zeitdiskreten Zustandssystembeschreibung finden sich in der Literatur [25].

C.2 Das Schätzproblem

Unabhängig von der gewählten Systembeschreibung besteht die Aufgabe der Zustandsschätzung darin, zum Zeitpunkt k unter Zuhilfenahme aller bis dahin zur Verfügung stehender Messvektoren $\mathbf{y}_{1:k} = \{\mathbf{y}(1), \mathbf{y}(2), \dots, \mathbf{y}(k)\}$ den Zustandsvektor $\mathbf{x}(k)$ und unter Voraussetzung der vollständigen Beobachtbarkeit des Zustandsvektors zu schätzen. Die dabei auftretende Schätzunsicherheit resultiert aus den Unsicherheiten in dem Anfangszustand $\mathbf{x}(0)$ und in der Systembeschreibung (System- und Messrauschen). Die Modellierung der Unsicherheiten als stochastische Größen impliziert die Auffassung des Zustandsvektors ebenfalls als Realisierung einer Zufallsvariable $\mathbf{X}(k)$. Die zu schätzenden Zustandsgrößen können folglich durch die bedingte Wahrscheinlichkeitsdichte $p_{\mathbf{X}|\mathbf{Y}}(\mathbf{x}(k)|\mathbf{y}_{1:k})$ vollständig beschrieben werden. Denn es lassen sich aus der Wahrscheinlichkeitsdichte alle Kenngrößen des Zustandsvektors berechnen, z.B. der bedingte Erwartungswert $E\{\mathbf{X}(k)|\mathbf{y}_{1:k}\}$, die Kovarianzmatrix $\mathbf{C}_{\mathbf{X}\mathbf{X}}(k)$ oder beliebige höhere Momente.

Wie in [49] auf Seite 86 gezeigt wird, impliziert z.B. der bedingte Erwartungswert das Minimum des mittleren quadratischen Schätzfehlers (MMSE, *Minimum Mean-Square Error*).

$$\mathbf{x}^{MMSE} = E\{\mathbf{X}(k)|\mathbf{y}_{1:k}\} = \int \mathbf{x} \cdot p_{\mathbf{X}|\mathbf{Y}}(\mathbf{x}|\mathbf{y}_{1:k}) d\mathbf{x} \quad (\text{C.7})$$

Neben dem Entwurf von Zustandsschätzern nach dem MMSE-Kriterium lassen sich prinzipiell aus der Wahrscheinlichkeitsdichte $p_{\mathbf{X}|\mathbf{Y}}(\mathbf{x}(k)|\mathbf{y}_{1:k})$ Schätzwerte beliebiger Optimalitätskriterien ableiten. Aus diesem Grund kann das Schätzproblem in einem ersten Schritt auf die Ermittlung der Wahrscheinlichkeitsdichte $p_{\mathbf{X}|\mathbf{Y}}(\mathbf{x}(k)|\mathbf{y}_{1:k})$ zurückgeführt werden.

C.3 Bayes Schätzer

Die Bayes'sche Wahrscheinlichkeitstheorie stellt die Grundlage von mehreren in dieser Arbeit eingesetzten probabilistischen Methoden. Der Bayes Schätzer ermöglicht die Berechnung der Zustandsdichte $p_{\mathbf{X}|\mathbf{Y}}(\mathbf{x}(k)|\mathbf{y}_{1:k})$ gegeben der alten *a posteriori* Wahrscheinlichkeitsdichte $p_{\mathbf{X}|\mathbf{Y}}(\mathbf{x}(k-1)|\mathbf{y}_{1:k-1})$ und eine neue Messung $\mathbf{y}(k)$ unter Berücksichtigung einer allgemeinen Systembeschreibung. Diese modelliert einerseits das zeitliche Verhalten des betrachteten Systems und beschreibt andererseits den Zusammenhang zwischen Schätzgröße und Messung. Mit Hilfe der Bayes-Regel (s. Anhang B) und der Berücksichtigung der Unabhängigkeit zwischen $\mathbf{y}(k)$ und alten Messungen lässt sich die gesuchte Wahrscheinlichkeitsdichte wie folgt berechnen.

$$p(\mathbf{x}(k)|\mathbf{y}_{1:k}) = \frac{p(\mathbf{y}_{1:k}|\mathbf{x}(k)) \cdot p(\mathbf{x}(k))}{p(\mathbf{y}_{1:k})} \quad (\text{C.8})$$

$$= \frac{p(\mathbf{y}(k)|\mathbf{x}(k)) \cdot p(\mathbf{y}_{1:k-1}|\mathbf{x}(k)) \cdot p(\mathbf{x}(k))}{p(\mathbf{y}(k)|\mathbf{y}_{1:k-1}) \cdot p(\mathbf{y}_{1:k-1})} \quad (\text{C.9})$$

$$= \frac{p(\mathbf{y}(k)|\mathbf{x}(k)) \cdot p(\mathbf{x}(k)|\mathbf{y}_{1:k-1})}{p(\mathbf{y}(k)|\mathbf{y}_{1:k-1})} \quad (\text{C.10})$$

Die Wahrscheinlichkeitsdichte $p(\mathbf{y}(k)|\mathbf{x}(k))$ in Gleichung C.10 definiert das Messmodell. Der Nenner in Gleichung C.9 stellt in jedem Zyklus eine Normierungskonstante dar, später η genannt, die sich durch Integration über den Zustand $\mathbf{x}(k)$ berechnen lässt.

$$p(\mathbf{y}(k)|\mathbf{y}_{1:k-1}) = \int p(\mathbf{y}(k)|\mathbf{x}(k), \mathbf{y}_{1:k-1}) \cdot p(\mathbf{x}(k)|\mathbf{y}_{1:k-1}) d\mathbf{x}(k) \quad (\text{C.11})$$

Die Wahrscheinlichkeitsdichte $p(\mathbf{x}(k)|\mathbf{y}_{1:k-1})$, die die Abhängigkeit des aktuellen Zustands $\mathbf{x}(k)$ von der Folge alter Messungen $\mathbf{y}_{1:k-1}$ beschreibt, muss noch bestimmt werden. Dies erfolgt über die *Chapman-Kolomogorov* Gleichung [64] unter Ausnutzung des Satzes der totalen Wahrscheinlichkeit (siehe Anhang B) und der Markov-Eigenschaft der Systembeschreibung gemäß

$$p(\mathbf{x}(k)|\mathbf{y}_{1:k-1}) = \int p(\mathbf{x}(k)|\mathbf{x}(k-1), \mathbf{y}_{1:k-1}) \cdot p(\mathbf{x}(k-1)|\mathbf{y}_{1:k-1}) d\mathbf{x}(k-1) \quad (\text{C.12})$$

$$= \int p(\mathbf{x}(k)|\mathbf{x}(k-1)) \cdot p(\mathbf{x}(k-1)|\mathbf{y}_{1:k-1}) d\mathbf{x}(k-1) \quad (\text{C.13})$$

Durch die Einführung von $\mathbf{x}(k-1)$ in Gleichung C.12 resultiert die Abhängigkeit von den alten Schätzgrößen, die durch die Dichte $p(\mathbf{x}(k)|\mathbf{x}(k-1))$ gegeben wird. Gleichung C.13 entspricht

deswegen einem Prädiktionsschritt, der die alten Schätzgrößen in der Zeit propagiert und mit Hilfe des alten Schätzergebnisses $p(\mathbf{x}(k-1) | \mathbf{y}_{1:k-1}) d\mathbf{x}(k-1)$ eine Integration über alle möglichen alten Schätzgrößen durchführt. Die Übertragungswahrscheinlichkeit $p(\mathbf{x}(k) | \mathbf{x}(k-1))$ im Englischen bekannt als *transition prior* resultiert aus der Modellierung des betrachteten Systems.

Ausgehend von der als bekannt vorausgesetzten Dichte des Anfangszustands $p(\mathbf{x}(0))$ basiert daher der Bayes-Schätzer auf der rekursiven Anwendung von Prädiktion (Gleichung C.13) und Korrektur (Gleichung C.10). Die bei der Herleitung des Bayes-Schätzers auftretenden Integrale (Gleichung C.13) sind i.d.R. nicht analytisch lösbar. Entscheidende Vereinfachungen verschaffen die linearen Systeme mit additiven Gauß'schen Rauschen. Die Schätzung der Zustände solcher Systeme kann beispielhaft durch das Kalman-Filter als eine explizite Form des Bayes Schätzers behandelt werden.

C.4 Kalman-Filter und Erweiterungen

Das Kalman-Filter ist ein weitverbreiteter Zustandsschätzer, der in dieser Arbeit seinen Einsatz in der modellbasierten Freiraumverfolgung (Kapitel 4.2), in der Höhenschätzung (5.3) und in der Objektverfolgung (Kapitel 6.3.3) findet.

Die Annahmen, auf die das Kalman-Filter beruht, bestehen aus einer linearen Systembeschreibung nach Gleichung C.6, sowie mittelwertfreien, unabhängigen Gauß'schen Rauschprozessen $\mathbf{V}(k)$ und $\mathbf{N}(k)$. Zudem muss die Wahrscheinlichkeitsdichte $p(\mathbf{x}(\mathbf{0}))$ bekannt und normalverteilt sein. Da die beiden Größen $E\{\mathbf{X}\}$ (Erwartungswert) und $\mathbf{C}_{\mathbf{X}\mathbf{X}}$ (Kovarianzmatrix) eine normalverteilte Zufallsvariable vollständig beschreiben, reduziert sich der Bayes-Schätzer auf eine rekursive Berechnung des Erwartungswertes und der Kovarianzmatrix. Das Kalman-Filter kann daher als eine spezielle Implementierung unter den aufgeführten Voraussetzungen des Bayes-Schätzers interpretiert werden. Aufgrund bestimmter Eigenschaften der Normalverteilung wie z.B. Symmetrie, fallen die Schätzwerte aller gebräuchlichen Optimalitätskriterien mit dem Erwartungswert zusammen, so dass dieser dem Schätzwert $\hat{\mathbf{x}}$ gleichgesetzt wird. Auf die Herleitung der Kalman Gleichungen wird an dieser Stelle verzichtet. Sie kann in der Fachliteratur z.B. in [63] und [61] nachgelesen werden.

Als Bayes-Schätzer basiert das Kalman-Filter auf zwei Verarbeitungsschritten, in denen die geschätzten Zustandsgrößen und ihre Schätzkovarianzmatrizen angepasst werden. In einem ersten Schritt wird die Prädiktion des Zustandsvektors über die Systemgleichung durchgeführt:

$$\hat{\mathbf{x}}^-(k) = \hat{\mathbf{x}}(k|k-1)(k) = E\{\mathbf{x}(\mathbf{k}) | \mathbf{y}_{1:k-1}\} = \mathbf{A}(k-1) \cdot \hat{\mathbf{x}}(k-1) \quad (\text{C.14})$$

$$\mathbf{C}_{\mathbf{X}\mathbf{X}}^-(k) = \mathbf{C}_{\mathbf{X}\mathbf{X}}(k|k-1) = \mathbf{A}(k-1) \cdot \mathbf{C}_{\mathbf{X}\mathbf{X}}(k-1) \cdot \mathbf{A}^T(k-1) + \mathbf{C}_{\mathbf{V}\mathbf{V}}(k-1) \quad (\text{C.15})$$

In einem zweiten Schritt erfolgt die Korrektur der Prädiktion mit Hilfe des neuen Messvektors:

$$\hat{\mathbf{x}}(k) = \hat{\mathbf{x}}^-(k) + \mathbf{K}(k) \cdot (\mathbf{y}(k) - \mathbf{H}(k) \cdot \hat{\mathbf{x}}^-(k)) \quad (\text{C.16})$$

$$\mathbf{C}_{\mathbf{X}\mathbf{X}}(k) = (\mathbf{I} - \mathbf{K}(k) \cdot \mathbf{H}(k)) \cdot \mathbf{C}_{\mathbf{X}\mathbf{X}}^-(k) \quad (\text{C.17})$$

Dabei bezeichnet \mathbf{I} die Einheitsmatrix und \mathbf{K} die Kalman-Verstärkungsmatrix, die wie folgt sich berechnen lässt:

$$\mathbf{K}(k) = \mathbf{C}_{\mathbf{XX}}^- \cdot \mathbf{H}^T \cdot (\mathbf{H}(k) \cdot \mathbf{C}_{\mathbf{XX}}^- \cdot \mathbf{H}^T + \mathbf{C}_{\mathbf{NN}}(k))^{-1} \quad (\text{C.18})$$

Aus Gleichung C.16 wird ersichtlich, dass die Kalman-Verstärkungsmatrix die Abweichung - auch *Residuum* genannt - zwischen der eintreffenden Messung $\mathbf{y}(k)$ und der erwarteten Messung $\mathbf{H}(k) \cdot \hat{\mathbf{x}}^-(k)$ gewichtet. Liegt z.B. eine Messung mit hoher Unsicherheit vor, so fällt das Gewicht entsprechend klein aus.

Weitere Formen des Kalman-Filters versuchen die einfach implementierbare Struktur des Filters in komplexeren Systemen anzuwenden. Das *Extended Kalman-Filter* z.B. behandelt nichtlineare Systeme mit additivem Gauß'schen Rauschen gemäß den Gleichungen C.3 und C.4. Die Idee besteht hier darin, die nicht linearen Modellanteile lokal um alten Schätzzustand $\hat{\mathbf{x}}(k-1)$ für das Systemmodell und um den prädizierten Zustand $\hat{\mathbf{x}}^-(k)$ für das Messmodell zu linearisieren. Mit Hilfe dieser Annäherung kann der klassische Kalman-Ansatz zur Schätzung der neuen Systemzustände verwendet werden. Dabei werden die aus der Linearisierung gewonnenen Jacobimatrizen der nichtlinearen Funktionen f und h nur für die approximative Berechnung der Kovarianzen eingesetzt. Zur Prädiktion des Zustands sowie zur Berechnung der erwarteten Messung werden üblicherweise die nichtlinearen Funktionen verwendet. Weitere Erweiterungen des Kalman-Filters können in der Literatur z.B. in [58] gefunden werden.

D Der Bresenham-Algorithmus

Der Bresenham-Algorithmus ist ein recheneffizientes Verfahren für die Zeichnung von Linien auf einer gerasterten Fläche [56] [35] (s. Abbildung D.1). Das Verfahren ist besonders effizient, weil es ausschließlich mit *Integer*-Operationen auskommt.

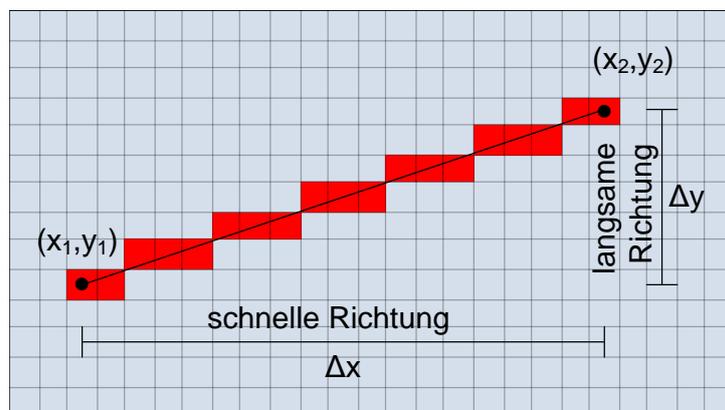


Abbildung D.1: Erstellung einer gerasterten Linie mit Hilfe des Bresenham-Algorithmus

Es wird die durch die Punkte (x_1, y_1) und (x_2, y_2) definierte Gerade betrachtet. Zur Veranschaulichung des Algorithmus genügt die Betrachtung des Falls mit $\Delta x > \Delta y > 0$. Die anderen Fälle können durch Fallunterschiedungen und Anpassungen in den Vorzeichen von Δx und Δy und in den Rollen von x und y abgedeckt werden.

Die betrachtete Gerade kann durch die Gleichung $y = y_1 + (x - x_1) \cdot \frac{\Delta y}{\Delta x}$ beschrieben werden. Die Abweichung in y -Richtung zwischen der Gerade und einem Punkt (x, y) kann anhand der folgenden Funktion ausgedrückt werden:

$$F(x, y) = y - y_1 - (x - x_1) \cdot \frac{\Delta y}{\Delta x} \quad (\text{D.1})$$

Die Grundidee des Bresenham-Algorithmus besteht im regelmäßigen Setzen eines Pixels in der schnellen Richtung und der Durchführung eines Schrittes in der langsamen Richtung, falls der Betrag der Fehler-Funktion eine Schwelle überschreitet. Konkret führt ein Schritt in die x -Richtung zu einer Verringerung des Fehlers in der Funktion $F(x, y)$ um $\frac{\Delta y}{\Delta x}$. Ein Schritt in die y -Richtung hingegen erhöht den Fehler um 1. Sollen nun die Pixel ausgewählt werden, deren Mittelpunkte möglichst nah an der Gerade sind, dann wird die Bewegung auf dem Raster so lange in x -Richtung fortgesetzt, bis die Fehler-Funktion $-1/2$ unterschreitet. Erst dann folgt ein Schritt in die y -Richtung. Um die Division durch Δx zu vermeiden, kann statt der Funktion $F(x, y)$,

$F(x, y) \cdot \Delta x$ betrachtet werden. In diesem Fall verringert sich die Fehler-Funktion um Δy bei einem Schritt in x -Richtung. Er erhöht sich um Δx bei einem Schritt in y -Richtung. Die Schwelle für einen Richtungswechsel beträgt dann $-\frac{\Delta x}{2}$.

E Die Funktionen Stauassistent und Aktive Gefahrenbremsung

E.1 Die Aktive Gefahrenbremsung

Das System zur Aktiven Gefahrenbremsung unterstützt den Fahrer zur Vermeidung von Unfällen und zur Reduzierung der Unfallschwere im Längsverkehr durch automatische Bremsung mit situationsangepasster Stärke. Das System baut auf den extrahierten Belegungsintervallen aus der Belegungskarte als Umfeldbeschreibung auf. Zur Beurteilung der Gefahr einer Situation wird eine Ausweichanalyse mehrmals mit unterschiedlichen Querbeschleunigungsparametern durchgeführt und dabei überprüft, ob das Eigenfahrzeug in der vorliegenden Situation noch mit der maximalen, bzw. mit einer komfortablen Querbeschleunigung ausweichen könnte oder in welcher Entfernung es ggf. jeweils zu einer Kollision kommen könnte. Sobald mit maximal möglicher Querbeschleunigung kein Ausweichen mehr möglich und die ermittelte Entfernung zur Kollision kleiner als der Bremsweg plus Sicherheitsabstand ist, löst das System eine Vollverzögerung aus. Die aus dem Stand der Technik bekannten Notbremsysteme [98] betrachten in der Regel nur ein relevantes Objekt, sodass die Ausweichmöglichkeit lange bestehen bleibt. Sie bremsen deswegen lediglich kollisionsfolgenmindernd. Die Aktive Gefahrenbremsung kann hingegen aufgrund des erweiterten Umfeldwissens durch die Belegungskarte in einer kritischen Situation (wie z.B. bei einem Stauende mit Leitplanken an der Seite) den Unfall durch autonomes Bremsen vermeiden, ohne den Fahrer zu bevormunden.

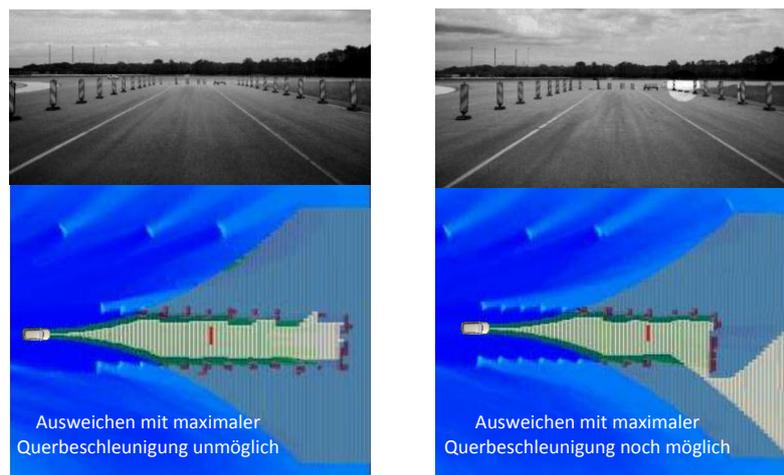


Abbildung E.1: Ein Nutzen-Szenario der Aktiven Gefahrenbremsung und die dazugehörigen Umfeldwahrnehmung und Situationsanalyse

E.2 Der Stauassistent

Der Stauassistent ist ein Assistenzsystem, das den Fahrer in der Quer- und Längsführung des Fahrzeugs in einer Stau-Situation unterstützt. Das System ist im Geschwindigkeitsbereich 0 bis 60 km/h und hauptsächlich auf Autobahnen verfügbar. Es versucht das Fahrzeug innerhalb des eigenen Fahrstreifens zu halten, führt aber keinen Fahrstreifen-Wechsel durch. Das System ist in der Lage, ein Ausweichmanöver innerhalb des eigenen Fahrstreifens auszuführen.

Es gibt verschiedene Ausprägung des Stauassistenten. In seiner einfachen Variante assistiert das System den Fahrer. D.h., der Fahrer muss aufmerksam bleiben und das System überwachen (z.B. die Hände des Fahrers bleiben am Lenkrad, während das System aktiv ist). In einer Variante mit hohem Automatisierungsgrad übernimmt das System die Quer- und Längsführung des Fahrzeugs, sofern die System-Bedingungen erfüllt sind. Der Fahrer kann die Zeit dann für andere Aktivitäten wie das Lesen von E-Mails oder das Surfen im Internet nutzen. Das impliziert auch, dass das System selbstständig seine Grenzen erkennt (Ausfall der Umfellsensorik, Verlassen der Funktionsdomäne, ...). In diesem Fall muss das System den Fahrer informieren und ihn auffordern, die Fahraufgabe zu übernehmen. Reagiert der Fahrer nicht, geht das System in einen sicheren Zustand, in dem es z.B. bis zum Stillstand bremst und die Warnblink-Anlage aktiviert.

Für die Umsetzung des Systems werden folgende Informationen über das Umfeld benötigt:

- Informationen über Objekte (Position, Geschwindigkeit, Ausdehnung) im eigenen und in den benachbarten Fahrstreifen.
- Informationen über Fahrstreifen-Markierungen (Position und Verlauf).
- Informationen über weitere Fahrbahn-Begrenzungen (Position und Verlauf) wie z.B. Baken, Pylonen, Leitplanken und Betonwände.
- Informationen über Frei- und Unbekannträume.

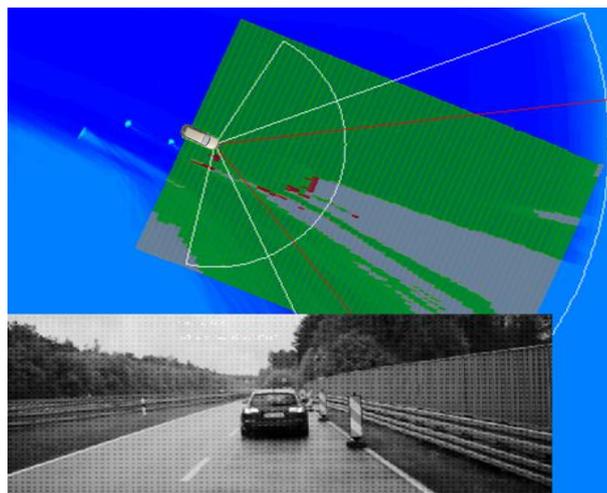


Abbildung E.2: Umfeldwahrnehmung für den Stauassistenten in einem Baustellenszenario

Literaturverzeichnis

- [1] BALLARD, D. H. und C. M. BROWN: *Computer Vision*. Prentice-Hall, Englewood Cliffs, NJ, 1982.
- [2] BAMBERG, GÜNTER, FRANZ BAUR und MICHAEL KRAPP: *Statistik*. Oldenbourg Wissenschaftsverlag, 2008.
- [3] BLAKE, ANDREW und MICHAEL ISARD: *Active Contours: The Application of Techniques from Graphics, Vision, Control Theory and Statistics to Visual Tracking of Shapes in Motion*. Springer, 1 Auflage, August 2000.
- [4] BORGES, G. A und M. J ALDON: *Line Extraction in 2D Range Images for Mobile Robotics*. Journal of Intelligent and Robotic Systems, 40(3):267 - 297, 2004.
- [5] BRACHINGER, WOLFGANG: *Multivariate statistische Verfahren*. Walter de Gruyter, 1996.
- [6] BRUHN, MATTHIAS und KAI-UWE HEMKEN: *Modernisierung des Sehens: Schweisen zwischen Künsten und Medien*. Transcript, 1., Aufl. Auflage, Mai 2008.
- [7] B.STRASSER, A. SIEGEL, K.-H. SIEDERSEBERGER und PROF.R.-ING. M. MAURER: *Vernetzung von Test- und Simulationen für die Entwicklung von Fahrerassistenzsystemen (FAS)*. München, 2010.
- [8] BÖTTIGER, HELMUT: *Die Mobilität des Menschen: Über Wege, Bahn und Grenzen hinaus*. Imhof, Petersberg; Auflage: 1, 2007.
- [9] BUNGARTZ, HANS-JOACHIM, MICHAEL GRIEBEL und CHRISTOPH ZENGER: *Einführung in die Computergraphik. Grundlagen, Geometrische Modellierung, Algorithmen*. Vieweg Verlagsgesellschaft, Oktober 2001.
- [10] BURGER, WILHELM und MARK JAMES BURGE: *Digitale Bildverarbeitung*. Springer, Mai 2006.
- [11] BURLET, JULIEN, TRUNG DUNG VU und NILS APPENRODT: *Grid-based Localization and Online Mapping with Moving Object Detection and Tracking*. Research Report RR-6276, INRIA, 2007.
- [12] BURLET, JULIEN, TRUNG DUNG VU und OLIVIER AYCARD: *Grid-based Localization and Online Mapping with Moving Object Detection and Tracking: new results*. In: *Proceedings of the 2008 IEEE Intelligent Vehicles Symposium*, Seiten 684–689, Eindhoven, June 2008. IEEE.

- [13] C. COUÉ, C. PRADALIER UND C. LAUGIER: *Bayesian Programming Multi-Target Tracking : an Automotive Application*. In: *International conference on Field and Service Robotics*, 2003.
- [14] C. Y. CHONG, S. MORI und K. C. CHANG: *Information Fusion in Distributed Sensor Networks*. In: *In proceedings American Control Conference*, Monterey CA, 1985.
- [15] CHEE-YEE CHONG, SHOZO MORI, KUO-CHU CHANG und WILLIAM H. BARKER: *Architectures and Algorithms for Track Association and Fusion*. IEEE Aerospace and Electronic Systems Magazine, 15:5 - 13, 2002.
- [16] CHIEH-CHIH WANG, CHUCK THROPE, MARTIAL HEBERT, SEBASTIAN THRUN und H. DURRANT-WHYTE: *Simultaneous Localization, Mapping and Moving Object Tracking*. The International Journal of Robotics Research, 26(6), 2007.
- [17] CHONG, C. Y.: *Hierarchical Estimation*. In: *Proceedings MIT/ONR Workshop on C3*, Monterey CA, 1979.
- [18] CHRISTOPHE COUÉ, CÉDRIC PRADALIER, CHRISTIAN LAUGIER, THIERRY FRAICHARD und PIERRE BESSIÈRE: *Bayesian Occupancy Filtering for Multitarget Tracking: An Automotive Application*. The International Journal of Robotics Research, 25(1):19–30, 2006.
- [19] DENZLER, J. und H. NIEMANN: *Active Rays: A New Approach to Contour Tracking*. International Journal of Computing and Information Technology, 4:9–16, 1996.
- [20] DRUMMOND, O. E.: *Feedback in Track Fusion without Process Noise*. In: *proceedings of SPIE, the international Society for Optical Engineering*, Monterey CA, 1996.
- [21] EBERLY, DAVID: *Intersection of Convex Objects: The Method of Separating Axes*, 2003. Magic Software Inc.
- [22] ELFES, A.: *Using occupancy grids for mobile robot perception and navigation*. Computer, 22(6):46–57, 1989.
- [23] ELFES, A.: *Occupancy Grids: A Stochastic Spatial Representation for Active Robot Perception*. In: *Proceedings of the Proceedings of the Sixth Conference Annual Conference on Uncertainty in Artificial Intelligence (UAI-90)*, Seiten 136–146, New York, NY, 1990. Elsevier Science.
- [24] FERGUSON, DAVID, MICHAEL DARMS, CHRISTOPHER URMSON und SASCHA KOLSKI: *Detection, Prediction, and Avoidance of Dynamic Obstacles in Urban Environments*. In: *Proceedings of the 2008 IEEE Intelligent Vehicles Symposium*, Seiten 1149–1154, Eindhoven, June 2008. IEEE.
- [25] FÖLLINGER, OTTO: *Regelungstechnik: Einführung in die Methoden und ihre Anwendung*. Hüthig, 10., durchgesehene Auflage. Auflage, Juni 2008.
- [26] FONG, E. H. L., W. ADAMS, F. L. CRABBE und A. C. SCHULTZ: *Representing a 3-D Environment with a 2 1/2 -D Map Structure*. In: *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems*, Band 3, Seiten 2986– 2991, 2003.

- [27] FORSCHUNGSINITIATIVE AKTIV: *AKTIV: Gemeinsam die Zukunft erleben*. <http://www.aktiv-online.org/deutsch/Downloads/Broschueren/aktiv%20image-deutsch.pdf>, 2006. Zuletzt geprüft am 18.06.2011.
- [28] FORSCHUNGSINITIATIVE AKTIV: *Aktive Sicherheit – AS: Sichterheitstechnologien aktivieren*. <http://www.aktiv-online.org/deutsch/Downloads/Broschueren/Aktiv%20AS-d.pdf>, 2006. Zuletzt geprüft am 18.06.2011.
- [29] FRANKEL, G.: *Flexible Architectures for Sensor Fusion in Theater Missile Defense*. IDA Paper P-2935, April 1994.
- [30] FRANKEL, G.: *Track Fusion for Intercept Support*. IDA Paper, April 1995.
- [31] FROMMBERGER, L.: *3D-Umweltmodellierung zur Navigationsunterstützung von Laufmaschinen im Gelände*. Diploma Thesis, Forschungszentrum Informatik / Universität Karlsruhe, 2002.
- [32] FÜRSTENBERG, KAY CH. und KLAUS C. J. DIETMAYER: *Fahrzeugumfelderfassung mit mehrzeiligen Laserscannern (The Use of Multi-Layer Laser Scanners for Monitoring the Environment of Driving Vehicles)*. tm - Technisches Messen, 71(3-2004):164–172, 2004.
- [33] GELB, ARTHUR: *Applied Optimal Estimation*. The MIT Press, Mai 1974.
- [34] GROSS, JÜRGEN: *Grundlegende Statistik mit R: Eine anwendungsorientierte Einführung in die Verwendung der Statistik Software R*. Vieweg+Teubner, 1 Auflage, April 2010.
- [35] GROUP, ISRD: *Computer Graphics*. Tata McGraw-Hill Education, Oktober 2005.
- [36] GUTMANN, J.-S., M. FUKUCHI und M. FUJITA: *A Floor and Obstacle Height Map for 3D Navigation of a Humanoid Robot*. In: *Proceedings of the 2005 IEEE International Conference on Robotics and Automation*, Seiten 1066 – 1071, 2005.
- [37] HAKE, GÜNTER, DIETMAR GRÜNREICH und LIQIU MENG: *Kartographie. Visualisierung raum-zeitlicher Informationen*. Gruyter, 7. A. Auflage, Dezember 1982.
- [38] HAKE, GÜNTER, DIETMAR GRÜNREICH und LIQIU MENG: *Kartographie. Visualisierung raum-zeitlicher Informationen*. Gruyter, 8., vollst. neu bearb. und erw. A. Auflage, Dezember 2001.
- [39] HAUG, ANDREAS: *Sierpinski-Kurven zur speichereffizienten numerischen Simulation auf adaptiven Tetraedergittern*. Doktorarbeit, Technische Universität München, München, 2006.
- [40] HESS, J. M.: *Characterizing Dynamic Objects in 3D Laser Range Data*. Diplomarbeit, Albert-Ludwigs-Universität Freiburg, Faculty of Applied Sciences, Department of Computer Science, Autonomous Intelligent Systems Laboratory, Nov. 2008.
- [41] HÄHNEL, D., D. SCHULZ und W. BURGARD: *Mobile Robot Mapping in Populated Environments*. *Advanced Robotics*, 17:579–597, 2003.
- [42] HÄHNEL, DIRK, WOLFRAM BURGARD, DIETER FOX und SEBASTIAN THRUN: *An efficient FastSLAM algorithm for generating maps of large-scale cyclic environments from raw laser*

- range measurements. In: *Proc. of the IEEE/RSJ Int. Conf. on Intelligent Robots and Systems (IROS)*, Seiten 206–211, 2003.
- [43] HONG, T., M. ABRAMS, T. CHANG und M. SHNEIER: *An Intelligent World Model for Autonomous Off-Road Driving*. Computer Vision and Image Understanding, Hook, S. ASTER Spectral Library, 2000.
- [44] HUDER, BERNHARD: *Einführung in die Radartechnik*, Kapitel 5, Seiten 77–83. Teubner Verlag, Stuttgart.Leipzig, 1999.
- [45] JÄHHNE, BERND: *Digitale Bildverarbeitung*. Springer, März 2005.
- [46] JOHO, D., C. STACHNISS, P. PFAFF und W. BURGARD: *Autonomous Exploration for 3D Map Learning*. In: BERNIS, KARSTEN und TOBIAS LUKSCH (Herausgeber): *Autonome Mobile Systeme (AMS)*, Seiten 22–28, Kaiserslautern, Germany, October 2007. Springer.
- [47] JONES, J. P.: *Real-Time Construction of Three-Dimensional Occupancy Maps*. In: *Proceedings of the IEEE International Conference on Robotics and Automation*, Band 1, Seiten 52–57, 1993.
- [48] KAMEL MEKHNACHA1, YONG MAO, DAVID RAULO1 und CHRISTIAN LAUGIER: *Bayesian occupancy filtering based „Fast Clustering-Tracking“ algorithm*. In: *International Conference on Intelligent Robots and Systems*, 2008.
- [49] KAMEN, EDWARD W. und JONATHAN SU: *Introduction to optimal estimation*. Springer, 1999.
- [50] KAYAMA, K., I. E. YAIRI und S. IGI: *Construction of Elevation Map for User-Carried Outdoor Mobile Robot Using Stereo Vision*. In: *IEEE International Conference on Systems, Man and Cybernetics*, Band 5, Seiten 4631 – 4636, 2003.
- [51] KELNHOFER, FRITZ: *25 Jahre Studienzweig Kartographie*. Universität Wien Institut für Geographie und Regionalforschung, 1999.
- [52] KÜHLMEYER, MANFRED: *Statistische Auswertungsmethoden für Ingenieure*. Springer, Januar 2001.
- [53] KIENCKE, UWE und RALF EGER: *Messtechnik: Systemtheorie für Elektrotechniker*. Springer, Berlin, 7. Auflage. Auflage, März 2008.
- [54] KLASING, K., D. WOLLHERR und M. BUSS: *A Clustering Method for Efficient Segmentation of 3D Laser Data*. In: *IEEE International Conference on Robotics and Automation, ICRA*, Seiten 4043–4048, Pasadena, CA, USA, 2008.
- [55] KONRAD, MARCUS, MAGDALENA SZCZOT und KLAUS DIETMAYER: *Road Course Estimation in Occupancy Grids*. In: *Proceedings of the IEEE Intelligent Vehicles Symposium (IV 2010)*, 2010.
- [56] KRISHNAMURTHY: *Introduction to computer graphics*. Tata McGraw-Hill Education, November 2001.

-
- [57] KÖRNER, M.: *Methoden zur 3D-Kartierung des Fahrzeugumfeldes mittels Echtzeit-Tiefensensorik*. Diplomarbeit, Lehrstuhl für Digitale Bildverarbeitung, Fakultät für Informatik, Friedrich-Schiller-Universität Jena, 2008.
- [58] LAGES, U.S.: *Untersuchungen zur aktiven Unfallvermeidung von Kraftfahrzeugen*. Fortschritt Berichte-VDI Reihe 12 Verkehrstechnik Fahrzeugtechnik, 2001.
- [59] LI, X. RONG und V.P. JILKOV: *Survey of maneuvering targettracking . part I: dynamic models*. IEEE Transactions on Aerospace and Electronic Systems, 39(4):1333–1364, 2003.
- [60] LIENKAMP, M. und A. BARTELS: *Automatisches Fahren: Logische Konsequenz der Assistenzsysteme oder Utopie?* In: *Proceedings des 1. Autobiltechnischen Kolloquiums*, 2009.
- [61] LOFFELD, OTMAR: *Estimationstheorie, Bd.1, Grundlagen und stochastische Konzepte*. Oldenbourg, 1990.
- [62] MATTHEWS, VOLKER und HANS VOLQUARDTS: *Vermessungskunde. Fuer die Fachgebiete Architektur, Bauingenieurwesen und Vermessungswesen: Vermessungskunde, Teil 2*. Vieweg+Teubner, 17., neubearb. A. Auflage, August 1997.
- [63] MAYBECK, PETER S.: *Stochastic models, estimation, and control*, Band 141 der Reihe *Mathematics in Science and Engineering*. 1979.
- [64] MAYBECK, PETER S.: *Stochastic models, estimation and control*. Academic Press, Juni 1982.
- [65] MÄHLISCH, MIRKO: *Filtersynthese zur simultanen Minimierung von Existenz-, Assoziations- und Zustandsunsicherheiten in der Fahrzeugumfelderfassung mit heterogenen Sensordaten*. Doktorarbeit, Universität Ulm, 2009.
- [66] MORAVEC, H. P.: *Sensor fusion in certainty grids for mobile robots*. AI Magazine, 1988.
- [67] MORAVEC, H. P.: *Robot Spatial Perception by Stereoscopic Vision and 3D Evidence Grids*. Technical Report CMU-RI-TR-96-34, CMU Robotics Institute, September 1996.
- [68] MORAVEC, H. P.: *Dense 3D Perception for Broad Mobile Robot Applications*. DARPA BAA0221 Proposal Abstract, 2003.
- [69] MORAVEC, H. P. und A. ELFES: *High Resolution Maps from Wide Angle Sonar*. In: *Proceedings of the 1985 IEEE International Conference on Robotics and Automation*, Seiten 116 – 121, March 1985.
- [70] NÜCHTER, A.: *Semantische dreidimensionale Karten für autonome mobile Roboter*. Doktorarbeit, Universität Bonn, 2006.
- [71] PAPULA, L.: *Mathematik für Ingenieure und Naturwissenschaftler 3: Vektoranalysis, Wahrscheinlichkeitsrechnung, mathematische Statistik, Fehler- und Ausgleichsrechnung*. Vieweg+Teubner Verlag, 2008.
- [72] PAVLINA KONSTATINOVA, ALEXANDER UDVAREV und TZVETAN SEMERDJIEV: *A Study of a target Tracking Algorithm Using Global Nearest Neighbor Approach*. In: *International Conference on Computer Systems and Technologies*, 2003.

- [73] PETROVSKAYA, A. und S. THRUN: *Model Based Vehicle Tracking in Urban Environments*. In: *Proceedings of the 2009 IEEE International Conference on Robotics and Automation*, Kobe, Japan, May 2009.
- [74] RAMER, U.: *An iterative procedure for the polygonal approximation of plane curves*. *Computer Graphics and Image Processing*, 1(3):244–256, 1972.
- [75] RATHI, YOGESH, NAMRATA VASWANI, ALLEN TANNENBAUM und ANTHONY YEZZI: *Particle Filtering for Geometric Active Contours with Application to Tracking*. In: *IEEE CVPR*, Seiten 2–9, 2005.
- [76] ROHLING, HERMANN: *Radartechnik- und signalverarbeitung*. Skriptum zur Vorlesung TU Hamburg-Harburg, 2007.
- [77] RUSSELL, STUART und PETER NORVIG: *Künstliche Intelligenz: Ein moderner Ansatz*. Pearson Studium, 2., überarb. A. Auflage, August 2004.
- [78] SALEM, MOHAMMED: *Grundlagen der Signalverarbeitung – Korrelation und Faltung*. 2007.
- [79] SCHMID, MATTHIAS R., MIRKO MAEHLISCH, JUERGEN DICKMANN und HANS-JOACHIM WUENSCH: *Dynamic Level of Detail 3D Occupancy Grids for Automotive Use*. In: *Proceedings of IEEE Intelligent Vehicles Symposium*, Seiten 269–274, San Diego, CA, USA, 2010.
- [80] SCHNIEDER, ECKEHARD (Herausgeber): *Verkehrsleittechnik*. Springer Berlin Heidelberg, Berlin, Heidelberg, 2007.
- [81] SCHREER, O.: *Stereoanalyse und Bildsynthese*. Springer, März 2005.
- [82] SESTER, MONIKA: *Lernen struktureller Modelle für die Bildanalyse*. Doktorarbeit, Universität Stuttgart, 1995.
- [83] SMITH, A., Y. KITAMURA und F. KISHINO: *Efficient Algorithms for Octree Motion*. In: *IAPR Workshop on Machine Vision Applications*, Seiten 172–177, 1994.
- [84] SPIES, M. und H. SPIES: *Automobile Lidar Sensorik: Stand, Trends und zukünftige Herausforderungen*. *Advances in Radio Science*, 4:99–104, 2006.
- [85] STEGER, CARSTEN, MARKUS ULRICH und CHRISTIAN WIEDEMANN: *Machine Vision Algorithms and Applications*. Wiley-VCH, Weinheim, 2007.
- [86] STILLER, C.: *Fahrerassistenzsysteme - Von realisierten Funktionen zum vernetzt wahrnehmenden, selbstorganisierenden Verkehr*. In: MAURER, M. und C. STILLER (Herausgeber): *Fahrerassistenzsysteme mit maschineller Wahrnehmung*, Seiten 1–20. Springer-Verlag Berlin Heidelberg, 2004.
- [87] STILLER, C., S. KAMMEL, I. LULCHEVA und J. ZIEGLER: *Probabilistische Methoden in der Umfeldwahrnehmung Kognitiver Automobile*. *Automatisierungstechnik - at*, (11):562–574, 2008.
- [88] TALUKDER, A., R. MANDUCHI, A. RANKIN und L. MATTHIES: *Fast and reliable obstacle detection and segmentation for cross-country navigation*. In: *Intelligent Vehicle Symposium, IEEE*, Band 2, Seiten 610–618, June 2002.

-
- [89] THRUN, SEBASTIAN. *Autonomous Robots*, 15:111–127, 2003.
- [90] TÖNNIES, KLAUS D.: *Grundlagen der Bildverarbeitung*. Pearson Studium, 1 Auflage, April 2005.
- [91] WALIA, A. und J. TEIZER: *Analysis of Spatial Data Structures for Proximity Detection*. Tsinghua Science & Technology, 13, Supplement 1:102–107, 2008.
- [92] WANG, C.-C. und C. THORPE: *Simultaneous Localization and Mapping with Detection and Tracking of Moving Objects*. In: *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA)*, Band 3, Seiten 2918–2924, 2002.
- [93] WANG, CHIEH-CHIH, CHARLES THORPE und ARNE SUPPE: *Ladar-Based Detection and Tracking of Moving Objects from a Ground Vehicle at High Speeds*. In: *Proceedings of the IEEE Intelligent Vehicles Symposium*, Columbus, OH, June 2003.
- [94] WANG, CHIEH-CHIH, CHARLES THORPE und SEBASTIAN THRUN: *Online Simultaneous Localization And Mapping with Detection And Tracking of Moving Objects: Theory and Results from a Ground Vehicle in Crowded Urban Areas*. In: *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA)*, Taipei, Taiwan, September 2003.
- [95] WEDEL, A., C. RABE, H. BADINO, H. LOOSE, U. FRANKE und D. CREMERS: *B-Spline Modeling of Road Surfaces with an Application to Free Space Estimation*. *Transactions on Intelligent Transportation Systems*, 10(4):572–583, 2009.
- [96] WEISS, T., B. SCHIELE und K. DIETMAYER: *Robust Driving Path Detection in Urban and Highway Scenarios Using a Laser Scanner and Online Occupancy Grids*. Seiten 184–189, June 2007.
- [97] WERNER, MARTIN: *Zustandsraumdarstellung*. In: *Signale und Systeme*, Seiten 354–372. Vieweg+Teubner, Wiesbaden, 2008.
- [98] WINNER, HERMANN, STEPHAN HAKULI und GABRIELE WOLF: *Handbuch Fahrerassistenzsysteme Grundlagen, Komponenten und Systeme fuer aktive Sicherheit und Komfort*. Vieweg+Teubner, 1 Auflage, juli 2009.
- [99] WOLF, DENIS und GAURAV S. SUKHATME: *Online simultaneous localization and mapping in dynamic environments*. In: *Proc. of ICRA*, Seiten 1301–1306, 2004.
- [100] ZACHMANN, G. und E. LANGETEPE: *Geometric Data Structures for Computer Graphics*. In: *Tutorials of EUROGRAPHICS*, 2002.

Eigene Publikationen und betreute Arbeiten

- [Bouzouraa 2010] Mohamed Essayed Bouzouraa, Ulrich Hofmann:
Fusion of occupancy grid mapping and model based object tracking for driver assistance systems using laser and radar sensors
IEEE Intelligent Vehicles Symposium, 2010, San Diego.
- [Bär 2009] Michael Bär, Mohamed Essayed Bouzouraa, C. Demiral, Ulrich Hofmann, U. Gies, K. Diepold:
EgoMaster: A central ego motion estimation for driver assist systems
IEEE International Conference on control and Automation, 2009, Christchurch.
- [Reichel 2010] Michael Reichel, Mohamed Essayed Bouzouraa, A. Siegel, K. H. Siedersberger, M. Maurer:
Erweiterte Umfelderkennung und Nutzung einer Ausweichanalyse als Grundlage einer aktiven Gefahrenbremsung
AAET 2010 Automatisierungssysteme, Assistenzsysteme und eingebettete Systeme für Transportmittel, 2010, Braunschweig.
- [Bouzouraa 2010] Mohamed Essayed Bouzouraa, Ulrich Hofmann:
Effiziente kartenbasierte Umfeldwahrnehmung mit Laserscanner-Sensoren für Fahrerassistenzsysteme
6. Workshop Fahrerassistenzsysteme, 2009, Löwenstein.
- [Bouzouraa 2011] Mohamed Essayed Bouzouraa, Ulrich Hofmann:
Fusion kartenbasierter Umfeldwahrnehmung mit modellbasierter Objektverfolgung für Fahrerassistenzsysteme
7. Workshop Fahrerassistenzsysteme, 2011, Walting.
- [Bouzouraa 2010] Mohamed Essayed Bouzouraa, Michael Reichel, M. Maurer, K. H. Siedersberger, U. Hofmann:
Grundlegende Architekturentscheidungen für hochautomatisierte Fahrerassistenzsysteme am Beispiel einer Aktiven Gefahrenbremsung
4. Tagung Sicherheit durch Fahrerassistenz, 2010, München.
- [Demiral 2010] Christopher Demiral:
Statistische Methoden zur Bewertung von Algorithmen der kartenbasierten Umfeldwahrnehmung
Diplomarbeit, 2010, Fakultät für Mathematik und Informatik Julius-Maximilians-Universität Würzburg.

- [Rauch 2009] Andreas Rauch:
3D Umfeldkartierung und Kompensation bewegter Objekte
Diplomarbeit, 2009, Lehrstuhl für Fahrzeugtechnik Technische Universität München.
- [Wind 2009] Adalbert Wind:
Fusion von Laser- und Radar-Sensoren zur kartenbasierten Umfeldwahrnehmung für Fahrerassistenzsysteme
Diplomarbeit, 2009, Lehrstuhl für Technische Elektronik Friedrich-Alexander-Universität Erlangen-Nürnberg.
- [Weiherer 2009] Tobias Weiherer:
Differenzbildung auf einer Belegungskarte zur Erkennung von dynamischen Hindernissen und Fehler in der Fahrzeugausrichtung
Semsterarbeit, 2009, Technische Universität München Fakultät für Informatik.
- [Schuster 2009] Martin Schuster:
Modellbasierte Freiraumverfolgung im Bereich vor dem Fahrzeug
Semsterarbeit, 2009, Technische Universität München Fakultät für Informatik.
- [Nyga 2009] Daniel Nyga:
Extraktion von Umgebungsinformationen aus Belegungskarten für Fahrerassistenzsysteme
Semesterarbeit, 2009, Technische Universität München Fakultät für Informatik.
- [Brahmi 2010] Mohamed Brahmi:
Entwicklung, Implementierung und Validierung eines Sensormodells für zukünftige Radarsensorik
Diplomarbeit, 2010, Technische Universität München Fakultät für Elektrotechnik und Informationstechnik.