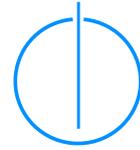




Technische Universität München
Fakultät für Informatik



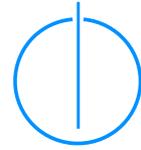
Modellgestützte Sensordatenfusion von Laserscanner und Radar zur Erfassung komplexer Fahrzeugumgebungen

Dissertation

Sylvia Pietzsch



Technische Universität München
Fakultät für Informatik



Informatik IX - Bildverstehen und wissensbasierte Systeme

Modellgestützte Sensordatenfusion von Laserscanner und Radar zur Erfassung komplexer Fahrzeugumgebungen

Sylvia Pietzsch

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

Doktors der Naturwissenschaften (Dr. rer. nat.)

genehmigten Dissertation.

Vorsitzender: Univ.-Prof. Dr. Helmut Seidl

Prüfer der Dissertation:

1. Univ.-Prof. Dr. Bernd Radig (i. R.)
2. Univ.-Prof. Gudrun J. Klinker, Ph. D.

Die Dissertation wurde am 18.12.2014 bei der Technischen Universität München eingereicht und durch die Fakultät für Informatik am 14.05.2015 angenommen.

Kurzfassung

Moderne Fahrerassistenzsysteme nutzen bordautonome Sensorik, um ihre Umgebung zu erfassen, andere Verkehrsteilnehmer oder Hindernisse zu erkennen und deren Positionen und Bewegungen abzuschätzen. Die Funktionalität solcher Systeme reicht dabei von der Information des Fahrers (beispielsweise über die momentan zulässige Höchstgeschwindigkeit) über das Warnen in einer potentiellen Gefahrensituation (geringer Abstand, Spurverlassen, Spurwechsel, etc.) bis hin zum aktiven Eingriff zur Unfallfolgenminderung oder sogar zur Vermeidung von Unfällen. Je stärker ein solcher Eingriff das Verkehrsgeschehen beeinflussen kann, desto höher sind die Anforderungen, die sich bezüglich Zuverlässigkeit und Robustheit an die Umgebungserfassung stellen. Bei einem Bremseneingriff etwa sind Falschalarme unbedingt zu vermeiden, da eine unvermittelte Bremsung in diesem Fall selbst eine Gefahrensituation verursachen könnte.

In dieser Arbeit werden Methoden zur Umgebungserfassung basierend auf zwei distanzbasierten Sensoriken - Laserscanner und Radar - untersucht, entwickelt und getestet. Das Ziel ist dabei eine robuste und genaue Erfassung und Verfolgung von Objekten in komplexen Umgebungen wie Kreuzungs- und Innenstadtbereichen, die mit einer Palette an unterschiedlichen Verkehrsteilnehmern, hoher Dynamik und teils komplexer Verkehrsführung ein eher unstrukturiertes Verkehrsgeschehen darstellen.

Durch eine Fusion der Daten werden die Vorteile beider Sensoren gezielt genutzt. Aus den Laserscannerdaten lassen sich Informationen über Ausdehnung und Orientierung von Objekten in der Fahrzeugumgebung extrahieren. Ein Vorteil des Radars besteht in der direkten Messung der (Doppler-)Geschwindigkeit, die jedoch bei der Objektverfolgung als Messgröße bisher selten betrachtet wird, da sie nur den radialen Anteil an der Objektgeschwindigkeit bestimmt. Mithilfe von Modellwissen über die Verteilung von Radarreflexionen an Fahrzeugen können gemessene Radarziele präziser ihrem Entstehungsort zugeordnet werden als dies bei einer Punktzielbeschreibung möglich ist. Die Kombination mit der Orientierungsinformation macht die Doppler-Geschwindigkeit auch in Szenarien auswertbar, in denen sich das beobachtete Fahrzeug nicht in Blickrichtung des Sensors bewegt. Mittels modellbasierter Fusion wird die Geschwindigkeitsschätzung bewegter Objekte präzisiert und eine schnellere Nachführung bei Änderungen der Dynamik erreicht.

Einen weiteren Aspekt, der in dieser Arbeit betrachtet wird, bildet der Umgang mit der Dynamik von Kreuzungsszenarien. Unterschiedliche Verkehrsteilnehmer bewegen sich unterschiedlich schnell und ändern dabei häufig ihre Richtung und Geschwindigkeit. Im Zusammenhang mit dem Kalman-Filter, dem „Standardwerkzeug“ zur Objektverfolgung in der Umfelderkennung,

existieren zwei Methoden zum Umgang mit Manövern, i. e. Abweichungen vom erwarteten Bewegungsmodell: 1) Inspektion der Residuen¹ und Anpassung der Prozessfehlerkovarianz (adaptiver Kalman-Filter), 2) Umschalten zwischen verschiedenen Bewegungsmodellen (Interacting Multiple Model Filter). In der Arbeit werden adaptive Methoden hinsichtlich ihrer Eignung für die Objektverfolgung im beschriebenen Kontext untersucht und bewertet.

Einen Gewinn an Robustheit und Genauigkeit der Parameterschätzung erhält man, wenn einzelne Objekte in der Fahrzeugumgebung nicht unabhängig voneinander sondern im situativen Kontext betrachtet werden. Fehlende Beobachtbarkeit bei (partiellen) Verdeckungen oder an Sichtbereichsgrenzen können zu falschen Geschwindigkeiten oder Objektverlust führen. Dieser Aspekt wird ebenfalls aufgegriffen und in einem kontextabhängigen Management von Objekt-hypothesen implementiert.

¹Abstand zwischen Messwert und prädiziertem Wert

Abstract

Modern driver assistance systems utilize on-board sensors for environmental perception to detect other traffic participants or obstacles and to estimate their positions and trajectories. The functionality of such systems reaches from informing the driver (e.g. about the currently allowed maximum speed) to warning in a potentially hazardous situation (low distance to vehicle in front, lane departure, lane change, etc.) and finally to an active intervention with the aim of collision mitigation or even collision avoidance. The higher the influence on a traffic situation introduced by such an intervention, the higher the requirements in terms of reliability and robustness of the environmental perception. Considering a brake intervention, false alarms are to be avoided in any case, since an unintended activation of the brakes could itself cause a hazardous situation.

In this thesis methods for environmental perception based on two distance-based sensor technologies - laserscanner and Radar - are investigated, developed and tested. Thereby the aim is a robust and accurate detection and tracking of objects in complex environments like crossings and urban areas that are characterized by a variety of different traffic participants, a lot of dynamics and partly complex traffic routing.

Data fusion utilizes the advantages of both sensor technologies in a systematic way. From laserscanner data information about dimension and orientation of objects can be derived. An advantage of Radar is the direct measurement of (Doppler-)speed that is so far hardly used as a measurement input in object tracking since it only gives the radial part of object velocity. With the help of modelling knowledge about the distribution of Radar reflections on cars measured Radar targets can be assigned more precisely to their originating location than it is possible by purely describing an object as a point target. A combination with orientation information makes it possible to utilize Doppler speed even in scenarios where the observed vehicle is moving in a different direction than the sensor looks into. With model-based fusion the velocity estimation of moving objects yields more precise results and tracking of motion changes adapts faster.

A further aspect in this thesis is handling of dynamics in crossing scenarios. Different traffic participants move slower or faster and often change their direction and speed. In the framework of the Kalman filter, the standard tool for object tracking in environmental perception, there exists two methods for maneuver handling, i. e. deviations from the expected motion model: 1) inspection of residuals¹ and adjustment of process noise covariance (adaptive Kalman filter), 2) switching between several motion models (Interacting Multiple Model Filter). In this thesis

¹Distance between measured and predicted value

adaptive methods are evaluated regarding their capability for object tracking in the specified context.

A gain in robustness and accuracy of parameter estimation is achieved when individual objects in the vicinity of a the vehicle are treated in a situational context rather than independently. Missing observability in the case of (partial) occlusion or at the edge of the field of view can lead to incorrect velocity estimations or object loss. This aspect is considered and implemented in the form of context-dependent management of object hypotheses.

Danksagung

Zunächst möchte ich an dieser Stelle die Gelegenheit nutzen, all denen zu danken, die mich beim Entstehen dieser Arbeit unterstützt und gefördert haben.

Allen voran gilt mein Dank Herrn Prof. Dr. Bernd Radig, der es mir ermöglichte, diese Doktorarbeit an seinem Lehrstuhl anzufertigen, meine Arbeit über die gesamte Zeit betreute und mir mit fachlichem Rat und Anregungen zur Seite stand.

Besonderen Dank aussprechen möchte ich Dr. Jürgen Dickmann und Nils Appenrodt vom Team „Aktive Sensoren“ in der Abteilung „Environmental Perception“ am Forschungszentrum der Daimler AG in Ulm, die mich bei meiner Arbeit immer unterstützt aber auch gefordert haben, so dass sich mir nicht nur theoretische Denkanstöße sondern auch viele praktische Einblicke in das automobiler Umfeld boten. Der Dank gilt ebenso den übrigen Mitgliedern des Teams sowie den Mitdoktoranden. Die Zusammenarbeit mit Euch hat wirklich Spaß gemacht.

Weiterhin möchte ich den Studenten und Praktikanten danken, die mit ihren Arbeiten wesentliche Beiträge zu dieser Doktorarbeit geleistet haben, insbesondere seien Matthias Schmid, Christoph Glöckler, Mirko Schmitt und Yiliang Xu genannt.

Furthermore, I would like to express my thanks to my colleagues in my current workplace who have encouraged me to carry on and finish my thesis beside a full time job, especially to Marc for his unconventional way to keep the motivation alive. It has helped a lot!

Mein Dank gilt ebenso meiner Familie, deren Rückhalt ich mich in meinem Leben immer gewiss sein konnte und kann.

Nichtzuletzt danke ich meinem langjährigen Lebensgefährten Toni, den ich in all den Jahren, in denen meine Arbeit im Vordergrund stand, auf eine ziemliche Geduldsprobe gestellt habe, für sein Durchhaltevermögen und sein Verständnis.

Nicht unerwähnt bleiben soll ein Dankeschön an meinen Laptop, der über die Jahre hinweg durchgehalten hat und nun seine Pflicht und Schuldigkeit getan hat.

Inhaltsverzeichnis

Symbolverzeichnis	xv
1 Einleitung	1
1.1 Umgebungserfassung im Kontext der Fahrerassistenz	1
1.2 Stand der Technik	4
1.3 Zielsetzung und wissenschaftlicher Beitrag	6
1.4 Aufbau der Arbeit	7
1.5 Koordinatensysteme	9
2 System-Architektur und Sensorik	11
2.1 Beschreibung der verwendeten Sensoren	11
2.1.1 Laserscanner	11
2.1.2 Nahbereichsradar	12
2.1.3 Fernbereichsradar	16
2.1.4 Vergleich der Sensoren	18
2.2 Versuchsträger	19
2.3 Logischer Systemaufbau	20
3 Generieren von Objekthypothesen aus Laserscannerdaten	21
3.1 Segmentierung	21
3.1.1 Segmentierverfahren im Überblick	21
3.1.2 Gitterbasierte Segmentierung	24
3.1.3 Bewertung von Segmentierverfahren	26
3.2 Merkmalsextraktion	29
3.2.1 Objektcharakterisierende Merkmale	29
3.2.2 Referenzpunkte	35
3.2.3 Szenenrelevante Merkmale	37
3.2.4 Klassifikation	38
3.2.5 Bewertung	40
4 Objektverfolgung für ausgedehnte Ziele	45
4.1 Grundlagen	45
4.1.1 Stationäre und instationäre Prozesse	47
4.1.2 Adaptiver Kalman-Filter (AKF)	47
4.1.3 Interacting Multiple Model Filter (IMM)	48
4.2 Verfolgung von Referenzpunkten	49
4.2.1 Prozess- und Messmodelle	49
4.2.2 Eigenbewegungskompensation	52

4.3	Umgang mit ausgedehnten Zielen	53
4.3.1	Anpassung des Referenzpunktes	53
4.3.2	Datenassoziation	54
4.3.3	Objektverwaltung	55
4.3.4	Integrierte Objektverfolgung und Klassifikation	57
5	Sensordatenfusion	67
5.1	Grundlagen	67
5.1.1	Ziele der Sensorfusion	67
5.1.2	Fusionsarchitekturen und -konzepte	68
5.1.3	Randbedingungen und Synchronisationsaspekte	69
5.2	Fusion von ausgedehnten Zielen mit Punktzielen	70
5.2.1	Vorbemerkungen zum Fusionskonzept	70
5.2.2	Radarreflexionsmodelle an Fahrzeugen	71
5.2.3	Umsetzung der modellgestützten Fusion	74
5.2.4	Nutzung der Doppler-Geschwindigkeit	77
5.3	Bewertung des Fusionsystems	79
5.3.1	Testverfahren und Testszenarien	79
5.3.2	Bewertungskriterien	80
5.3.3	Ergebnisse	81
5.3.4	Diskussion der Ergebnisse	91
6	Zusammenfassung und Ausblick	93
A	Szenenauswahl zur Auswertung der Segmentierverfahren	97
B	Definition objektcharakterisierender Merkmale	101
B.1	Konventionen	101
B.2	Anzahl der Punkte im Segment	101
B.3	Schwerpunkt	101
B.4	Bounding Box und Ausdehnung	102
B.4.1	Hauptkomponentenanalyse	102
B.4.2	Bounding Box	102
B.4.3	Ausdehnung	103
B.5	Länge der Konturlinie	103
B.6	Umfang	103
B.6.1	Konvexe Hülle	103
B.6.2	Berechnung des Umfangs	104
B.7	Fläche	104
B.8	Dichte	105
B.9	Seitenverhältnis	105
B.10	Kompaktheit	105
B.11	Konvexität	106
B.12	Relative Anzahl von Punkten pro Scanebene	106
C	Fahrmanöver-Katalog	107

Abbildungsverzeichnis	115
Tabellenverzeichnis	119
Betreute Diplomarbeiten	121
Liste der Publikationen	123
Literaturverzeichnis	125

Symbolverzeichnis

k	Zeitindex
x, y	Position in kartesischen Koordinaten
ψ	Orientierungswinkel
l	Länge
b	Breite
r	Distanz
\dot{r}	Entfernungsänderungsrate
φ	Ablagewinkel
ω	Winkeländerungsrate
θ	Fehlerschranke
A	Amplitude
τ_P	Pulsbreite
T_P	Pulsperiodendauer
t_S	Sendezeitpunkt
t_E	Empfangszeitpunkt
τ	Laufzeit
f_0	Trägerfrequenz
f_R	Frequenzhub
f_D	Dopplerfrequenz
T_R	Rampendauer
v_r	Relativgeschwindigkeit
\mathbf{z}_k	Messvektor zum Zeitpunkt k
\mathbf{x}_k	Zustandsvektor zum Zeitpunkt k

$\hat{\mathbf{x}}_k$	Prädiktion zum Zeitpunkt k
$\tilde{\mathbf{x}}$	in den Messraum projizierter Zustand
\mathbf{P}_k	Prozessfehlerkovarianzmatrix zum Zeitpunkt k
$\hat{\mathbf{P}}_k$	präzidierter Prozessfehler zum Zeitpunkt k
\mathbf{F}	Zustandsübergangsmatrix
\mathbf{H}	Messmatrix
$\mathbf{F}_J, \mathbf{H}_J$	Jacobi-Matrizen
\mathbf{R}	Messfehlerkovarianzmatrix
\mathbf{Q}	Modellfehler
\mathbf{S}	Innovationskovarianzmatrix
\mathbf{K}	Kalman-Gain
\mathbf{I}	Einheitsmatrix
T	Abtastintervall
ν	Messresiduum
w	Gewichtungsfaktor
f_{rc}^{vis}	Sichtbarkeitsfunktion von Reflektoren
\mathbf{p}_{rc}	Reflektorposition
i, j, l	Laufindices
c	Lichtgeschwindigkeit
m	Objektzustand (Kantensichtbarkeit)
M	Matrix der Zustandsübergangswahrscheinlichkeiten
p	Wahrscheinlichkeit

1 Einleitung

1.1 Umgebungserfassung im Kontext der Fahrerassistenz

Schaut man sich die Unfallstatistik der vergangenen 40 Jahre für Deutschland an (siehe Abbildung 1.1), so ist erfreulicherweise ein positiver Trend zu verzeichnen. Trotz der gestiegenen Fahrleistung stieg die Gesamtzahl der Unfälle nicht in gleichem Maße, in den letzten 20 Jahren ist sie nahezu konstant. Die Unfallzahlen mit Personenschäden und Todesopfern sind sogar leicht rückläufig. Dies geht zum einen auf verkehrstechnische Infrastrukturmaßnahmen zurück wie Verkehrsleitsysteme, Geschwindigkeitsbegrenzungen, Radwege etc., ist aber auch in starkem Maße der technischen Entwicklung der Fahrzeuge zu verdanken. Die Einführung der Gurtpflicht und des Airbags waren wichtige Meilensteine, um Fahrzeuginsassen zu schützen. In modernen Fahrzeugen befinden sich heute bis zu zehn verschiedene Airbags, die bei Frontal- und Seitenaufprällen Kopf, Becken und Knie des Fahrers und Beifahrers vor schweren Verletzungen bewahren und damit Leben retten. Auch Systeme, die die Fahrstabilität erhöhen und in kritischen Situationen den Fahrer dabei unterstützen, die Kontrolle über sein Fahrzeug zu behalten, haben wesentlich dazu beigetragen, die Sicherheit im Straßenverkehr zu erhöhen. Typische Beispiele hierfür sind das Anti-Blockier-System (ABS) sowie das Elektronische Stabilitätsprogramm (ESP), die heute Standard in modernen PKWs sind.

Darüber hinaus wurden über die vergangenen Jahre hinweg verschiedenste Fahrerassistenzsysteme im Markt eingeführt, die den Fahrer in unterschiedlichen Fahrsituationen unterstützen und damit den Komfort aber gleichzeitig auch die Sicherheit erhöhen. Beispiele hierfür sind der Spurhalteassistent, Spurwechselassistent, Bremsassistent, Stauassistent, Einparkhilfe, um nur einige zu nennen. Sensoren wie Nachtsichtkameras ergänzen die Augen des Fahrers, indem sie vorzeitig auf Gefahren wie Fußgänger oder Wild auf oder nahe der Fahrbahn aufmerksam machen. Eine Aufstellung bekannter Fahrerassistenzsysteme zeigt Abbildung 1.2. Die Grafik folgt mit kleineren Anpassungen der Autorin einer Darstellung des Gesamtverbandes der Deutschen Versicherungswirtschaft e. V. Die Einteilung erfolgt in zwei Dimensionen, auf der einen Seite wird unterschieden zwischen passiven bzw. warnenden Systemen, also solchen Systemen, die entweder Unfallfolgen abmildern oder die Aufmerksamkeit des Fahrers im Vorfeld auf potentielle Gefahren lenken, und Systemen, die aktiv bei der Fahraufgabe unterstützen. Die zweite Achse unterteilt die Assistenzsysteme nach ihrer Funktion als Sicherheits- oder den Fahrkomfort unterstützende Systeme. Während die grau eingefärbten Ovale schon auf dem Markt befindliche Systeme kennzeichnen, befinden sich die rosa-farbenen derzeit noch in der Entwicklung beziehungsweise stellen eine langfristige Vision dar wie die generelle Kollisionsvermeidung. Ähnliche Einteilungen von Fahrerassistenzsystemen nach Sicherheit und Komfort finden sich in [Naa04] und [Fre04].

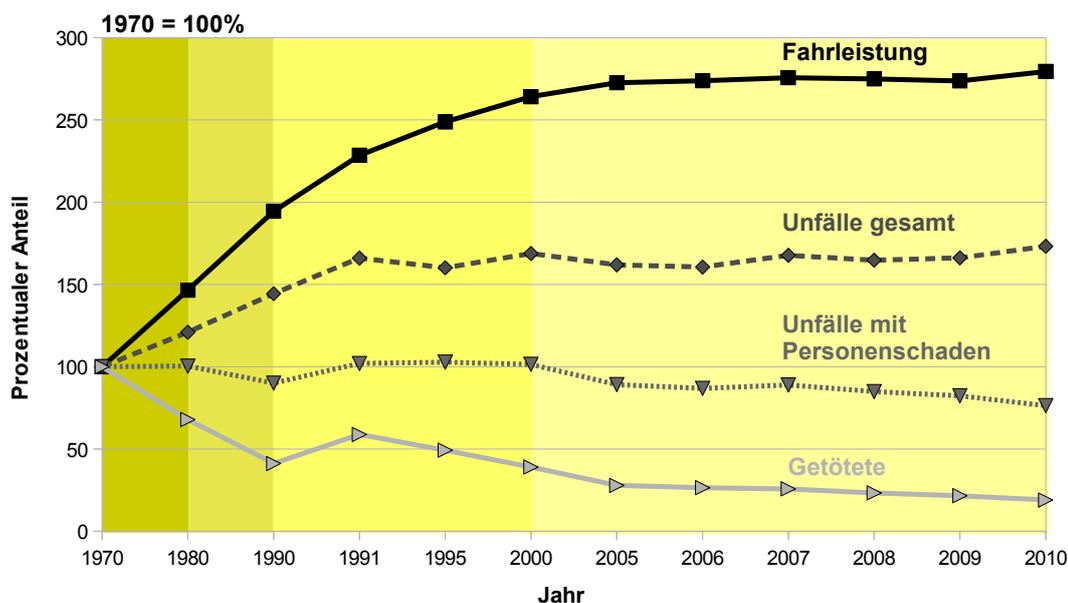


Abbildung 1.1: Unfallstatistik der vergangenen 40 Jahre für Deutschland, Quellen: Bundesanstalt für Straßenwesen [Bun10a], Statistisches Bundesamt [Sta11]

Trotz des positiven Trends für Deutschland, der in ähnlicher Weise auch auf die anderen Industrieländer der Welt zutrifft, beträgt die Zahl der durch die Folgen von Verkehrsunfällen Getöteten laut Schätzungen der WHO weltweit jährlich 1,2 Millionen [Wor], weitere 20 bis 50 Millionen Menschen werden bei Verkehrsunfällen verletzt. Länder mit mittlerem und niedrigem Einkommen weisen dabei die höchsten Raten auf. In einigen Ländern Asiens befinden sich die Zahlen in drastischem Aufwärtstrend. Setzt sich dieser Trend ungebremst fort, prognostiziert die WHO, dass Verkehrsunfälle von der derzeit neunthäufigsten Todesursache zur fünftthäufigsten bis zum Jahr 2030 aufsteigen werden. Neben dem menschlichen Leid aus den Folgen von Verkehrsunfällen entsteht auch ein nicht zu vernachlässigender volkswirtschaftlicher Schaden. Laut der Bundesanstalt für Straßenwesen beliefen sich die Kosten für Personen- und Sachschäden in Folge von Straßenverkehrsunfällen im Jahr 2008 in Deutschland auf 31 Milliarden Euro [Bun10b]. Angesichts dieser Zahlen und Entwicklungen ist das Thema Verkehrsunfälle und deren Folgen sowohl auf globaler als auch regionaler Ebene in den Fokus gerückt. Die UN-Hauptversammlung verabschiedete im März 2010 die Resolution 64/255, in der sie den Zeitraum von 2011 bis 2020 offiziell zur „Decade of Action for Road Safety“ ausrief. Das Ziel ist zunächst eine Stabilisierung und schließlich die Reduktion der Zahl der Verkehrstoten. Die Europäische Union orientiert sich an den nationalen Vorbildern von Schweden und der Schweiz, die langfristig das ambitionierte Ziel von null Verkehrstoten und Schwerverletzten verfolgen („Vision Zero“). In ihrem Weißbuch 2001 [Eur01] formulierte die Europäische Kommission als Teilziel auf diesem Weg die Halbierung der Zahl der Verkehrstoten bis 2010. Dieses Ziel wurde mit einer Verringerung um 36 % nicht erreicht, dennoch wird für die nächste Dekade bis 2020 erneut eine Verringerung um 50 % angestrebt [Eur11].

Aus den verfügbaren Unfallstatistiken geht hervor, dass Kreuzungen vor allem im innerstädtischen Bereich einen Unfallschwerpunkt darstellen, sowohl was die Häufigkeit als auch die Un-

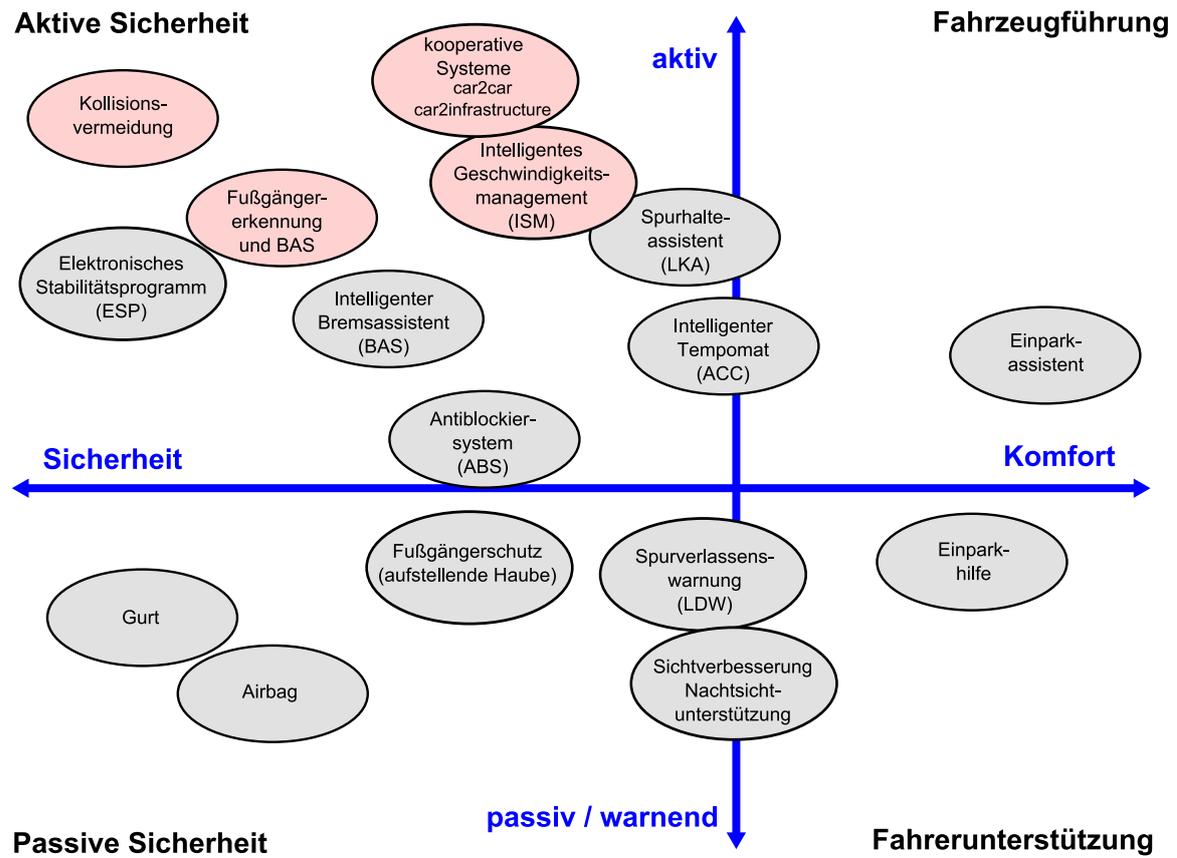


Abbildung 1.2: Einteilung von Fahrerassistenzsystemen nach ihrer Funktion (Komfort- oder Sicherheitsfunktion) und Wirkungsweise (passiv: warnend/schützend oder aktiv: eingreifend/verhindernd), Quelle: Gesamtverband der Deutschen Versicherungswirtschaft e. V. (GDV) [WWWb], grau hinterlegt: Systeme im Feld, rosa hinterlegt: Systeme in Entwicklung

fallschwere betrifft. Siehe dazu Abbildung 1.3, die die Verteilung von schweren Verkehrsunfällen nach Unfalltypen auf Basis der Daten für Deutschland 2010 darstellt [Sta11]. Das linke Diagramm zeigt, dass etwa zwei Drittel der schweren Unfälle (Unfälle mit Personenschäden oder schweren Sachschäden) innerorts passierten, diese werden im rechten Diagramm nochmals anteilig nach Typ unterschieden. Unfälle beim Kreuzen und Abbiegen bilden hier mit 29,3 % den größten Anteil. Ähnliche Betrachtungen für das Jahr 2006 finden sich bei Winner et al. [WHW09, S. 572]. Als Gründe werden hier Fehleinschätzungen der Verkehrssituation durch den Fahrer, Unaufmerksamkeit und eingeschränkte Sicht genannt, die sowohl durch Teile des Fahrzeugs, Bepflanzungen oder parkende Fahrzeuge als auch durch die Verkehrssituation selbst (z.B. abbiegende Fahrzeuge, die Verdeckung erzeugen) verursacht sein kann. Fahrerassistenz- und Sicherheitssysteme können in diesen komplexen Situationen den Fahrer bei seiner Fahraufgabe unterstützen und helfen, Unfälle zu vermeiden oder zumindest die Folgen abzumildern. Während Systeme wie ABS und ESP darauf ausgelegt sind, die Dynamik des eigenen Fahrzeugs zu regeln und für diese Aufgabe lediglich Bewegungsdaten des eigenen Fahrzeugs benötigen, ist für interagierende Systeme wie Bremsassistenten eine sensorielle Erfassung und Interpretation

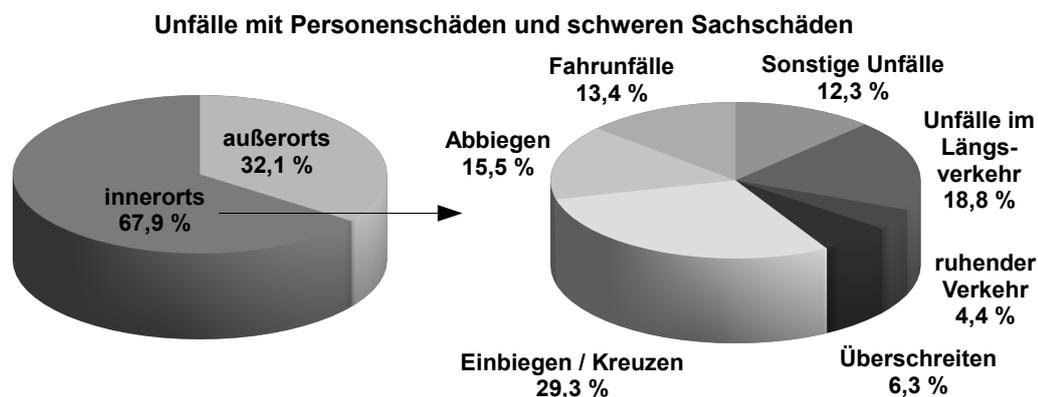


Abbildung 1.3: Unfälle mit Personenschäden und schweren Sachschäden 2010 aufgeschlüsselt nach dem Unfalltyp entsprechend [Sta11]

der Fahrzeugumgebung vonnöten. Je komplexer die Umgebung und die mit der Assistenzfunktion adressierte Fahrsituation ist, desto höher sind dabei die Anforderungen, die an die Umgebungserfassung gestellt werden. Mit dem weltweiten Trend zu immer größer werdenden Städten und Ballungsgebieten und der gleichzeitigen Zunahme des motorisierten Verkehrs ergeben sich neue Herausforderungen. Bei den auf dem Markt befindlichen Assistenzfunktionen spielt zudem die Verfügbarkeit und Verlässlichkeit eine Rolle. In gleichartigen Situationen sollte das System auch gleichartig reagieren, damit sich der Fahrer darauf verlassen kann. Andernfalls könnten durch das Assistenzsystem selbst zusätzliche Risiken entstehen. Im Idealfall soll die Situation natürlich immer korrekt erkannt und die entsprechende Reaktion, z. B. eine Bremsung mit der richtigen Intensität, eingeleitet werden. Gründl [Grü05] untersucht in seiner Dissertation Unfallursachen und Fahrerverhalten und geht dabei auf die Auslegung sowie die Potenziale und Risiken von Fahrerassistenz- und Sicherheitssystemen ein. Einen Überblick über aktuelle Entwicklungen im Bereich der Fahrerassistenzsysteme findet man bei Vollrath [VBS⁺06] sowie in den Büchern von Winner et al. [WHW09] sowie Maurer und Stiller [MS05], wo auf Sensoriken und Methoden zur Umgebungserfassung ausführlich eingegangen wird.

1.2 Stand der Technik

Maschinelle Perzeption der Umgebung ist ein klassisches Thema aus dem Gebiet der Robotik, insbesondere seit der Entwicklung mobiler Roboter. Hierbei kann prinzipiell unterschieden werden, ob sich ein Roboter in einer statischen oder dynamischen Umgebung bewegt. Entsprechend ergeben sich andere Aufgabenstellungen. Statische Umgebungen sind typischerweise innerhalb von Gebäuden zu finden. Während der Exploration seiner Umgebung erstellt der Roboter eine Karte, die er speichert und entsprechend aktualisiert, und anhand derer er sich orientiert und andere Objekte erkennt. Man kann bei dieser Art der Umgebungsmodellierung auch von der *Gridwelt* sprechen, denn eine verbreitete Methode bei der schrittweisen Erstellung solcher Karten ist es, ein sogenanntes Belegtheitsgitter zu verwenden (*engl. Occupancy Grid*).

Dabei wird die Umgebungskarte in ein Raster eingeteilt, deren Zellen jeweils entsprechend der von den Sensoren empfangenen Daten als belegt oder frei markiert werden. Die Belegtheit von Zellen kann dabei auch probabilistisch bestimmt werden [TBF98]. Typische Aufgaben, die sich in statischen Umgebungen stellen, sind (Selbst-)Lokalisierung, Hinderniserkennung sowie Pfadplanung.

In dynamischen Umgebungen geht es vorrangig um die Detektion statischer und fremdbewegter Objekte und um die Berechnung von Trajektorien und Bewegungsparametern. Die Umgebungserfassung im automobilen Umfeld zum Beispiel zur Realisierung von Pre-Crash-Systemen oder Notbremsassistentenfunktionen fällt in diesen Bereich. Die Modellierung der Umgebung geschieht meist in Form von Objektlisten mit verschiedenen Attributen, daher kann man hier auch von der *Objektwelt* sprechen.

Um komplexere Funktionen wie Kollisionsvermeidung durch Ausweichen oder zukünftig (teil-)automatisiertes Fahren zu ermöglichen, existieren Ansätze, die Grid- und Objektwelt für die Umgebungserfassung im automobilen Umfeld verbinden. Neben der Detektion von Objekten ist hierzu die Erkennung von Freiraum, der von einem Fahrzeug befahrbar ist, notwendig. Hierbei werden lokale Belegungskarten erzeugt, die jeweils auf temporäre globale Karten abgebildet werden. Zusätzlich werden Objekthypothesen bewegter Objekte gebildet und diese Information ebenfalls in die Karte eingetragen [Vu09] [Eff09]. Um den Aufwand für die Erzeugung und Speicherung der Karten zu verringern, wurden Ansätze entwickelt, die den Detaillierungsgrad der Karten dynamisch an die jeweilige Situation anpassen [Sch12].

Die vorliegende Arbeit beschäftigt sich vornehmlich mit einer robusten und akkuraten Trajektorien- und Bewegungsschätzung in dynamischen Szenarien und kann damit in den Bereich der Objektwelt eingeordnet werden. Was die Objektverfolgung (nicht nur im automobilen Umfeld) anbelangt, so hat sich der Kalman-Filter als Standard-Methode etabliert. Kalmans Veröffentlichung von 1960 ([Kal60]) verzeichnet laut Microsoft Academic Search 4366 Literaturzitate [Mica], die von Welch und Bishop 2001 veröffentlichte Einführung zum Kalman-Filter ([WB01]) 1395 [Micb]. Der ursprüngliche lineare Kalman-Filter löst zunächst das Problem der Einzelzielverfolgung (*engl. Single Target Tracking*), wobei die System- und Messmodelle linear sind bzw. linearisiert werden können. Im Laufe der Zeit wurde der Kalman-Filter erweitert, um mit Nichtlinearitäten umgehen zu können (Extended Kalman Filter [BSLK01] [May82] [Rib04] [LBS04], Unscented Kalman Filter [JU97b] [JU02] [JU04]) sowie Manöver von Objekten dynamisch zu verwalten und verfolgen zu können (Interacting Multiple Model [BSLK01] [BP99] [LJ05] [YKBS04] [KWSD04] [KH04] [CDB09], Adaptive Kalman Filter [Meh72]). Die Hinzunahme eines Assoziationsschritts, der die Zuordnung einzelner Messungen zu etablierten Tracks vornimmt, und Methoden zur Trackverwaltung ermöglichen es, auf Basis des Kalman-Filters eine Mehrzielverfolgung (*engl. Multiple Target Tracking*) zu realisieren [Bla04]. Neue Entwicklungen gehen über die reine Parameterschätzung hinaus und beziehen die Existenzschätzung in die Filteralgorithmen ein, um so Scheinziele robuster unterdrücken zu können und die Genauigkeit weiter zu erhöhen [Mäh09] [Mun11].

Das Thema des Objekttracking kommt ursprünglich aus dem militärischen Bereich, wo Ziele²

²Im militärischen Umfeld wörtlich zu nehmen, hat sich der Begriff des „Ziels“ im Fachjargon der Objektverfolgung zur Bezeichnung des relevanten Objektes eingebürgert.

über weite Distanzen zumeist mithilfe von Radarsensoren detektiert und verfolgt werden. Diese sind in Form von Punktzielen repräsentiert. Bei Anwendungen im Automobilbereich gilt es, räumlich ausgedehnte Objekte erkennen und verfolgen zu können, um Aussagen über möglicherweise bevorstehende Kollisionen treffen zu können. Dieses wird durch die Verwendung von Kameras oder Laserscanner realisiert. Zur Erhöhung der Robustheit und Genauigkeit werden oft mehrere Sensoren fusioniert [Sku06] [Kap07] [Käm07] [Lin09] [Wal08] [Wen08] [Stü03] [Dar07] [FC07].

Radarreflexionsmodelle wurden bisher meist im Bereich der Radarentwicklung aufgestellt und angewendet, um beispielsweise Antennenkonfigurationen zu verifizieren [Sch07]. Um diesen Zweck zu erfüllen, müssen sie die Streueigenschaften der betrachteten Objekte sehr genau abbilden und sind daher im Falle von PKWs durch die Komplexität der Oberfläche und deren Streueigenschaften aber auch durch die Komplexität des Verfahrens der Modellextraktion auf einzelne Fahrzeugmodelle beschränkt. Auf Seiten von Funktionsentwicklern wiederum besteht der Wunsch, Sensorausgaben für Fahrscenarien synthetisch zu generieren, um reale Testfahrten zu reduzieren und somit Entwicklungszeit und Testkosten zu sparen. Mit [WW07] und ausführlicher mit [Büh08] wurden zwei Ansätze vorgestellt, allgemein gültige und benutzbare Radarreflexionsmodelle zu entwickeln. Letzteres Modell wurde in [GSDB07] angewandt, um eine rein radarbasierte Fusion durchzuführen unter der Annahme eines zugrundeliegenden Fahrzeugs ohne Wissen über räumlich ausgedehnte Objekte.

1.3 Zielsetzung und wissenschaftlicher Beitrag

In der vorliegenden Arbeit wird eine Repräsentation der Fahrzeugumgebung in Form von Objektlisten gewählt. Das Ziel dabei ist eine präzise und robuste Erfassung der Position, Ausdehnung und Bewegungsparameter von Objekten insbesondere in Innenstadt- und Kreuzungsszenarien als Basis für erweiterte Fahrerassistenz- und Sicherheitsfunktionen. Im Vergleich zu Autobahnszenarien sind zwar die Relativgeschwindigkeiten in diesen Umgebungen geringer, jedoch stellen die Vielfältigkeit der Verkehrsteilnehmer (Fußgänger, Zweiradfahrer, PKW, LKW) mit ihrer unterschiedlichen und sich schnell ändernden Dynamik erweiterte Anforderungen an die Flexibilität und Leistungsfähigkeit der Umgebungserfassung. Für Frontapplikationen ohne Spurwechsel auf Autobahnen wie beispielsweise ACC (*engl. Adaptive Cruise Control*, Abstandsregeltempomat) genügt es im Allgemeinen, mit Fahrzeugrückfronten umgehen zu können und zudem nur die longitudinale Geschwindigkeit zu betrachten. Im Innenstadtbereich müssen der vollständige Geschwindigkeitsvektor sowie Perspektivänderungen der Objekte in der Fahrzeugumgebung in Betracht gezogen werden.

Erreicht wird dies durch die Fusion von Laserscannerdaten, die räumlich ausgedehnte Ziele darstellen, und Radardaten, die eine oder auch mehrere Reflexionen pro Objekt umfassen können. Die Fusion wird unter Nutzung von Modellwissen über die Verteilung von Radarzielen auf realen Objekten, hier Fahrzeugen, durchgeführt. Im Gegensatz zu bisher bekannten Ansätzen zur Fusion von ausgedehnten mit Punktzielen, die auf festen Bezugspunkten basieren, findet hier eine kontextadaptive bzw. situationsadaptive Modellierung für bewegte Objekte im Straßenverkehr statt. Durch diese selektive Anwendung von Modellwissen ergibt sich letztend-

lich eine Plausibilisierung und Stabilisierung für alle Umgebungsobjekte. Der Nutzen aus einer genaueren Modellierung ist eine schnellere Nachführung bei Dynamik-Änderungen und eine genauere Geschwindigkeitsschätzung durch die gezielte Nutzung der Doppler-Messwerte des Radars.

Ausschlaggebend für die Robustheit und Präzision des in dieser Arbeit eingeführten Datenfusionsansatzes ist zum einen eine robuste Vorverarbeitung der Laserscannerdaten zur Erzeugung valider Objekthypothesen und zum anderen der Umgang mit ausgedehnten Zielen in dynamischen Szenarien mit mehreren Objekten. Beides wird in dieser Arbeit umfassend untersucht und bewertet. Da die Generierung von Radarreflexionsmodellen nicht Teil der Arbeit ist, werden hier zunächst Fahrzeuge als relevante Objekte betrachtet, für die entsprechende Modelle in der Literatur existieren. Die konkrete Umsetzung der Fusion der Sensordaten und deren Evaluierung anhand eines Manöverkatalogs, der unterschiedliche Fahrszenen, wie sie an Kreuzungen vorkommen können, enthält, bildet den wesentlichen Beitrag und damit den Hauptteil dieser Arbeit.

Zur Veranschaulichung zeigt Abbildung 1.4 einen Ausschnitt aus einer realen Verkehrsszene mit den vom Laserscanner erfassten Daten dargestellt als farbige Punkte (zur Farbcodierung siehe Kapitel 2.1.1) sowie den in rot dargestellten berechneten Objekten mit ihrer Bewegungsinformation. Die ausgefüllten kleineren roten Quadrate kennzeichnen den Mittelpunkt der Objekte.

Ein weiterer Schwerpunkt der Arbeit liegt in der Modellierung des dynamischen Verhaltens der Verkehrsteilnehmer in Kreuzungssituationen. Im klassischen Kalman-Filter-Ansatz zur Objektverfolgung wird die Bewegung eines Objektes in der Umgebung durch ein festes Bewegungsmodell beschrieben. Abweichungen von diesem Prozessmodell werden durch das Prozessrauschen abgedeckt. In komplexen Verkehrssituationen wie beispielsweise an Kreuzungen kann diese Modellierung zu signifikanten Ungenauigkeiten in den geschätzten Trajektorien führen. Zudem ist die Voraussetzung von mittelwertfreiem, Gaußschem Rauschen für das Prozessmodell unter Umständen nicht erfüllt. In dieser Arbeit werden daher adaptive Modellierungsansätze wie IMM und Prozessfehlerkovarianzadaption für ihre Eignung in den benannten Situationen untersucht und verglichen.

1.4 Aufbau der Arbeit

In diesem Kapitel wurde zunächst der Kontext vorgestellt, in dem die vorliegende Arbeit steht (Kapitel 1.1) und der Nutzen motiviert. Der aktuelle Stand der Technik auf dem Gebiet der Umgebungserfassung für automobiler Anwendungen und der wissenschaftliche Beitrag dieser Arbeit wurden in den Kapiteln 1.2 und 1.3 beleuchtet. Die verwendeten Koordinatensysteme werden in Kapitel 1.5 definiert.

Kapitel 2 beschäftigt sich mit den verwendeten Sensortechnologien. Es werden die generelle Arbeitsweise der Sensoren beschrieben sowie die spezifischen Charakteristika der verwendeten Sensoren gezeigt und verglichen. Darüber hinaus werden die Hardwarearchitektur des zur

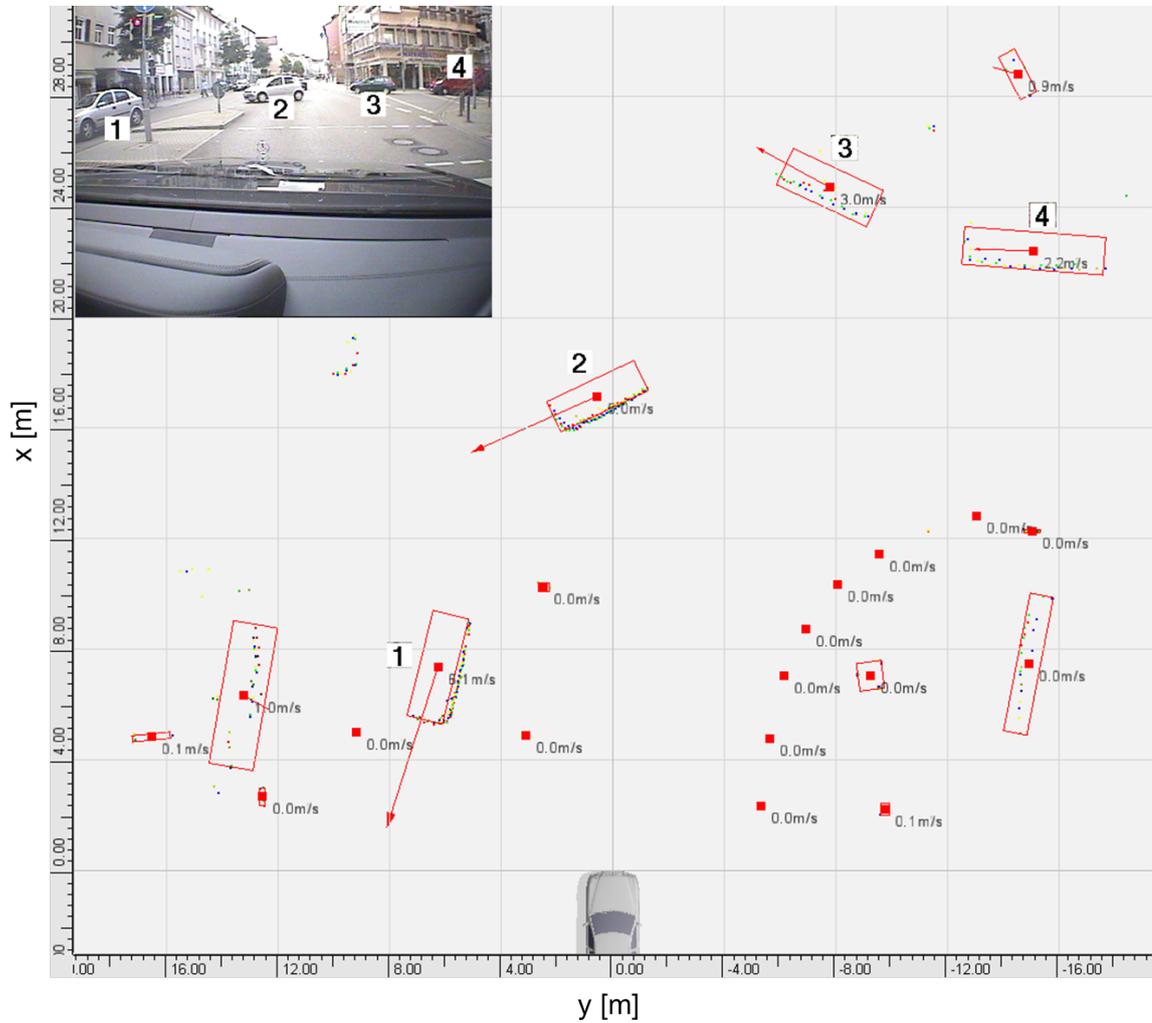


Abbildung 1.4: Messdaten des Laserscanners in einer realen Verkehrsszene und Objektdarstellung (rot). Größe und Ausrichtung von Objekten sind durch ein umgebendes Rechteck dargestellt. Wo anwendbar, repräsentieren Pfeile den (skalierten) Geschwindigkeitsvektor. Das Kamerabild zeigt die Sicht der Dokumentationskamera im Cockpit des Sensorfahrzeugs.

Datenaufzeichnung verwendeten Versuchsträgers vorgestellt und die Architektur des Fusionsystems aufgezeigt.

In Kapitel 3 werden die Methoden der Signalverarbeitung der Laserscannerdaten ausführlich beschrieben und bewertet. Verschiedene Verfahren zur Segmentierung der Rohdaten werden in Kapitel 3.1 analysiert. Anschließend wird auf die Extraktion objektcharakterisierender und szenenrelevanter Merkmale in Kapitel 3.2 eingegangen.

Kapitel 4 beleuchtet Aspekte der Objektverfolgung unter Verwendung des Kalman-Filters. Dabei steht die Verfolgung ausgedehnter Objekte im Vordergrund. In diesem Zusammenhang wird auf die Wahl des Objektreferenzpunktes, anhand dessen ein Objekt verfolgt wird, eingegangen, und es werden Methoden zur Verwendung mehrerer Referenzpunkte und deren Umrechnung diskutiert. Die verwendeten Mess- und Prozessmodelle werden vorgestellt, und zwei Ansätze zur adaptiven Modellierung von Objekten mit veränderlicher Dynamik - IMM und adaptive Prozessfehlerkovarianzen - werden untersucht und verglichen.

In Kapitel 5 wird die modellbasierte Fusion von Laserscanner- und Radardaten beschrieben. Dieses Kapitel bildet den Kern der vorliegenden Arbeit. Das Verfahren wird beschrieben und anhand von Messdaten evaluiert.

Kapitel 6 gibt eine Zusammenfassung der Arbeit und zeigt Ansätze für zukünftige Arbeiten auf.

1.5 Koordinatensysteme

Um eine gemeinsame Grundlage für die beschriebenen Verfahren der Signalvorverarbeitung, Objektverfolgung und Fusion zu schaffen, soll an dieser Stelle auf die verwendeten Koordinatensysteme eingegangen werden. Ein Großteil der Berechnungen sowie die Charakterisierung der Objekte wird im zweidimensionalen kartesischen Koordinatensystem nach ISO 8855/DIN 70000 durchgeführt wie in Abbildung 1.5 dargestellt. Sensordaten werden teilweise entsprechend dem Messprinzip in polaren Koordinaten angegeben wie ebenfalls in der Abbildung verzeichnet. Auf Umrechnungen und die sich daraus ergebenden zusätzlichen Unsicherheiten wird in Kapitel 4 eingegangen.

Hier angegeben sind das Fahrzeugkoordinatensystem, welches am vordersten Punkt des Ego-Fahrzeuges aufgehängt ist, sowie ein Objektkoordinatensystem, das im Referenzpunkt eines Objektfahrzeuges entspringt und zum Fahrzeugkoordinatensystem verschoben und um den Winkel ψ rotiert ist. Neben dem Fahrzeug- und dem Objektkoordinatensystem existieren Sensorkoordinatensysteme, die ihren Ursprung in der Anbauposition im Fahrzeug haben und ebenfalls relativ zum Fahrzeugkoordinatensystem gedreht sein können sowie das Weltkoordinatensystem als globaler Bezug. Angaben im Weltkoordinatensystem sind nur möglich und sinnvoll, wenn eine globale Lokalisierung möglich ist, z. B. mittels GPS. Transformationen zwischen den einzelnen Koordinatensystemen werden als Abfolge von Translationen und Rotationen angegeben.

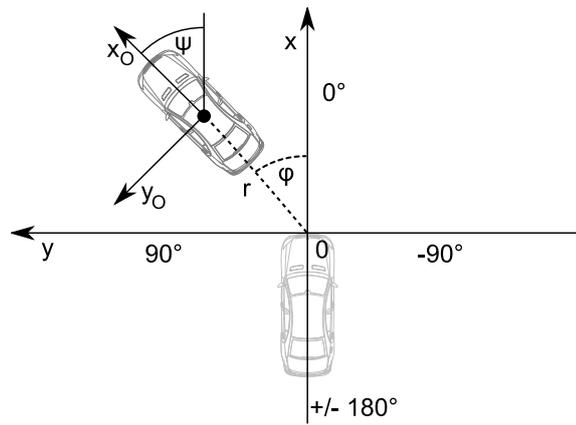


Abbildung 1.5: Koordinatensystem nach ISO 8855/DIN 70000

2 System-Architektur und Sensorik

2.1 Beschreibung der verwendeten Sensoren

2.1.1 Laserscanner

Laserscanner arbeiten mit einer dem Radar verwandten Methode zur Entfernungsmessung, dem Lidar-Prinzip (engl. **L**ight **D**etection and **R**anging). Abbildung 2.1 zeigt den prinzipiellen Aufbau eines Laserscanners mit Laserdiode, Spiegel und Photodiode.

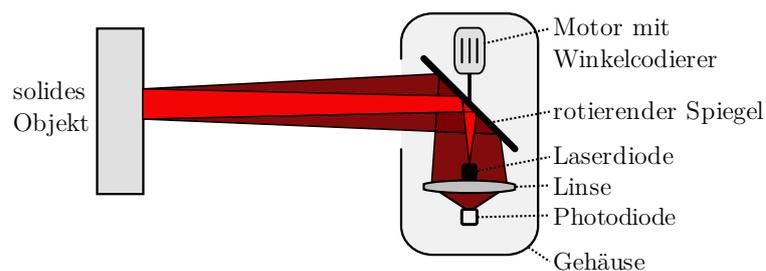


Abbildung 2.1: Prinzip des Laserscanners [1]

In eine definierte Richtung wird ein kurzer Laser-Puls gesendet. Mit Hilfe der Zeit, die vergeht, bis eine Reflexion (Echo) gemessen wird, kann nun der Abstand des reflektierenden Gegenstandes zum Scanner ermittelt werden. Damit liegt der gemessene Punkt in Polarkoordinaten vor. Anschließend dreht sich der Spiegel im Laserscanner um einen Winkelschritt und misst darauf den nächsten Abstand.

Durch Objekte, die von einem Laserstrahl nur teilweise getroffen werden, oder durch lichtdurchlässige Objekte wie Glasscheiben, können jedoch auch mehrere Echos pro ausgesendetem Laserpuls entstehen. Berücksichtigt der Laserscanner diese zusätzlichen Echos in seiner Auswertung, nennt man ihn mehrzielfähig.

Die Lidar-Technik macht sich die Laufzeit des Lichtes zunutze. Anhand der Lichtgeschwindigkeit c kann die Distanz zu einem Gegenstand ermittelt werden. Wenn zum Zeitpunkt t_0 ein Laserpuls ausgesendet wird und zum Zeitpunkt t_1 die erste Reflexion (Echo) am Scanner ein-

trifft, lässt sich die Distanz s des reflektierenden Objekts mit der Formel 2.1 berechnen.

$$s = \frac{(t_1 - t_0) \cdot c}{2} \quad (2.1)$$

Ist das reflektierende Objekt beispielsweise einen Meter entfernt, trifft das Echo bereits nach $1 \text{ m} = \frac{tc}{2} \Leftrightarrow t = 6,6713 \text{ ns}$ ein. Hier wurde vereinfachend mit der Lichtgeschwindigkeit im Vakuum gerechnet.

Aufgrund der immensen Geschwindigkeit des Lichtes sind aufwändige Schaltungen im Sensor erforderlich, um die kurze Zeitspanne bis zum Empfang des reflektierten Signals messen zu können, was hohe Kosten für Laserscanner verursacht. Die Forschung liefert jedoch jetzt schon wichtige Ergebnisse, die in der Praxis eingesetzt werden können, sobald die Geräte günstig verfügbar werden.

Der in dieser Arbeit verwendete Laserscanner vom Typ AlascaXT der Firma Ibeo ist ein mehrzielfähiges Gerät, das zusätzlich vier vertikale Scanebenen nutzt. Damit soll Objektverlust, der bei Nickbewegungen des Fahrzeuges entstehen kann, entgegengewirkt werden. Pro ausgesendetem Impuls werden bis zu vier Echos empfangen und ausgewertet. Die Winkelschrittweite ist nicht äquidistant sondern nimmt stufenweise zu den Rändern des Sichtbereichs hin zu, was gleichbedeutend mit einer Abnahme der horizontalen Winkelauflösung ist. Abbildung 2.2 verdeutlicht die vertikale und horizontale Winkelauflösung.

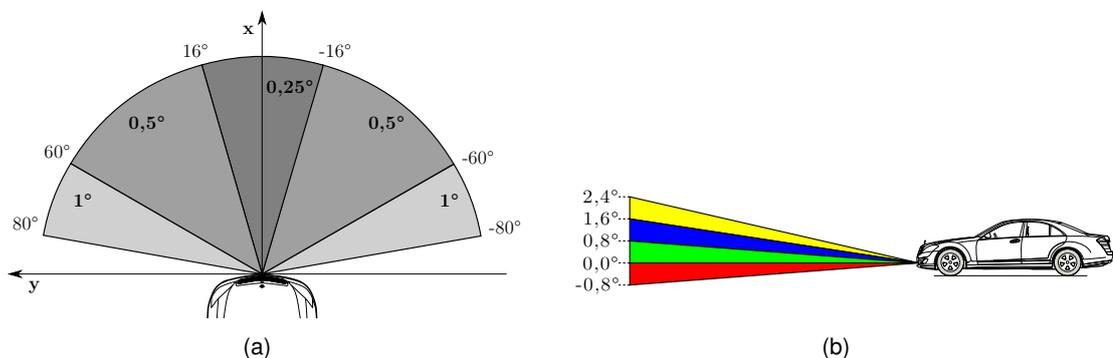


Abbildung 2.2: Winkelbereiche des Laserscanners: (a) horizontal, (b) vertikal

2.1.2 Nahbereichsradar

Das Prinzip des Radar (*engl. **R**adio **D**etection and **R**anging*) basiert auf dem Aussenden und dem Empfang elektromagnetischer Wellen, die von Objekten in der Umgebung des Senders reflektiert werden. Aus der Signallaufzeit wird die Entfernung des Objektes ermittelt, unter Ausnutzung des Dopplereffektes können Geschwindigkeiten relativ zum Radargerät gemessen werden. Entsprechend ihrer Arbeitsweise lassen sich Radarsensoren in zwei Kategorien einteilen, zum einen das Impulsradar, bei dem in festgelegtem zeitlichen Abstand immer wieder

kurze Pulse einer bestimmten Frequenz gesendet werden, zum anderen das Dauerstrichradar, bei dem sogenannte Chirps ausgesendet werden, also die Frequenz einer kontinuierlich ausgesendeten Welle im Sendeintervall verändert wird. Der für diese Arbeit verwendete Nah-

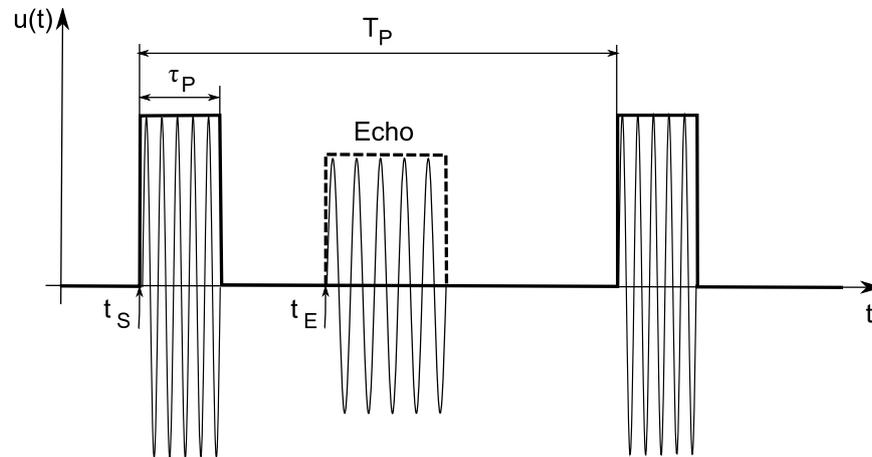


Abbildung 2.3: Signale beim Impulsradar

bereichsradarsensor ist ein Puls-Doppler-Radar. Das Prinzip ist in Abbildung 2.3 schematisch dargestellt. Kurze Pulse der Dauer τ_P werden mit der Pulswiederholungszeit T_P ausgesendet. Dies wird durch An- und Ausschalten des Senders realisiert. Die elektromagnetischen Wellen werden durch ein Objekt in der Umgebung zurückgeworfen und als Echo aufgefangen. Dabei ist die empfangene Leistung bedingt durch Dämpfungseffekte in der Atmosphäre sowie Absorption und Streuung am Objekt kleiner als die emittierte Leistung. Die einhüllenden Rechtecke stellen eine Idealisierung dar, da die Schaltzeiten der Hardwarebauteile endlich schnell sind. Die Entfernung r zum Ziel kann (theoretisch) aus der Signallaufzeit mittels Sende- und Empfangszeitpunkt t_S und t_E berechnet werden. Die Ausbreitungsgeschwindigkeit elektromagnetischer Wellen ist die Lichtgeschwindigkeit c .

$$r = \frac{(t_E - t_S) \cdot c}{2} \quad (2.2)$$

Das in Abbildung 2.3 dargestellte Echo stammt von einem sich vom Sender entfernenden Ziel. Durch die Bewegung wird die vom Beobachter wahrgenommene Frequenz verändert, im Fall der Wegbewegung ist sie verringert. Dies wird als Doppler-Effekt bezeichnet und erlaubt die Bestimmung der Geschwindigkeit des Objekts. Radargeräte, die neben der Laufzeit auch die Frequenzverschiebung auswerten, werden deshalb auch als Puls-Doppler-Radare bezeichnet. Die Dopplerfrequenz f_D steht in folgendem Zusammenhang mit der Relativgeschwindigkeit des Objektes v_r und der Trägerfrequenz f_0 :

$$f_D = -\frac{2v_r}{c} f_0 \quad (2.3)$$

In der Praxis werden t_S und t_E nicht direkt gemessen, sondern das Empfangssignal wird mit dem Sendesignal gemischt, gefiltert und mit der Empfangsfrequenz abgetastet. Zu jedem

Abtastzeitpunkt t_i wird ein Wertepaar bestehend aus Realteil I (In-phase) und Imaginärteil Q (Quadrature) erzeugt. Das In-phase-Signal entsteht durch Mischung mit dem Originalausgangssignal, das allgemein als harmonische Wellenfunktion mithilfe des Kosinus entsprechend Gleichung 2.4 beschrieben werden kann.

$$u_s(t) = A_s \cdot \cos(2\pi f_0 t + \phi_0) \quad (2.4)$$

Die Mischung von Signalen entspricht einer Multiplikation, unter Anwendung der Produktregel für trigonometrische Funktionen ergibt sich für das Sendesignal u_s und das Empfangssignal u_r :

$$u_s(t) \cdot u_r(t) = A_s \cos(2\pi f_0 t + \phi_0) \cdot A_r \cos(2\pi(f_0 + f_D)t + \phi_r) \quad (2.5)$$

$$= A_s \cos(2\pi f_0 t + \phi_0) \cdot A_r \cos(2\pi(f_0 - \frac{2v_r}{c} f_0)t + \phi_r) \quad (2.6)$$

$$= \frac{1}{2} A_s A_r \cdot (\cos(2\pi \frac{2v_r}{c} f_0 t + \phi_0 - \phi_r) + \cos(2\pi(2f_0 - \frac{2v_r}{c} f_0)t + \phi_0 + \phi_r)) \quad (2.7)$$

Das Empfangssignal eines relativ zum Sender bewegten Zieles erfährt nicht nur eine Verschiebung der Frequenz sondern auch der Phase. Der Signalanteil, der durch den zweiten Term in Gleichung 2.7 repräsentiert wird, ist zu hochfrequent, um im Empfangsteil ausgewertet zu werden, die Information über die Frequenzverschiebung findet sich daher im ersten Term.

Das Quadratursignal entsteht durch Mischung mit dem Sinus des Ausgangssignal, entspricht also einer Phasenverschiebung um 90° . Die Unterscheidung wird benötigt, um zu erkennen, ob sich ein Ziel auf den Sensor zu oder von ihm weg bewegt.

$$u_s(t) \cdot u_r(t) = A_s \sin(2\pi f_0 t + \phi_0) \cdot A_r \cos(2\pi(f_0 + f_D)t + \phi_r) \quad (2.8)$$

$$= A_s \sin(2\pi f_0 t + \phi_0) \cdot A_r \cos(2\pi(f_0 - \frac{2v_r}{c} f_0)t + \phi_r) \quad (2.9)$$

$$= \frac{1}{2} A_s A_r \cdot (\sin(2\pi \frac{2v_r}{c} f_0 t + \phi_0 - \phi_r) + \sin(2\pi(2f_0 - \frac{2v_r}{c} f_0)t + \phi_0 + \phi_r)) \quad (2.10)$$

Die Wertepaare, die zu jedem Abtastzeitpunkt t_i ermittelt werden, können als Vektor in der komplexen Q-I-Ebene dargestellt werden. Zum nächsten Messzeitpunkt t_{i+1} ist der Vektor entsprechend der Doppler-Geschwindigkeit um den Winkel $2\pi \frac{2v_r}{c} f_0 t_{i+1}$ weitergedreht. Der Abstand zum Ziel kann über die Signallaufzeit ähnlich Gleichung 2.2 berechnet werden, wobei der Sendezeitpunkt auf die Pulsmitte bezogen wird und der Empfangszeitpunkt nun mit dem aktuellen Abtastzeitpunkt gleichgesetzt wird. Damit definieren die Abtastzeitpunkte sogenannte „Range Gates“. In der Praxis werden zudem Pulsfolgen ausgesendet und ausgewertet, was zum einen die Robustheit erhöht, zum anderen auch geringere Anforderungen an die Pulsleistung bewirkt.

Durch die Parameter τ_P und T_P wird die Leistungsfähigkeit des Radargerätes bestimmt. Eine der dabei betrachteten Größen ist die Entfernungsauflösung Δr , die den minimalen Abstand bezeichnet, ab dem zwei Ziele als getrennte Ziele wahrgenommen werden. Die erreichbare

Auflösung wird durch die Pulsbreite τ_P determiniert.

$$\Delta r = \frac{c}{2} \cdot \tau_P \quad (2.11)$$

Für eine Entfernungsauflösung von 30 cm ergibt sich eine maximale Pulsbreite von ca. 3 ns. Die untere Grenze für die Pulsbreite wird theoretisch durch die Sendefrequenz bestimmt, jedoch sollte in der Praxis ein Impuls zumindest einige vollständige Schwingungen beinhalten. Die Wahl der Sendefrequenz ist wiederum beschränkt durch Kosten und Realisierungsaufwand der Hardware sowie durch gesetzliche Frequenzregulierungen.

Die Eindeutigkeit der Entfernungsbestimmung wird durch die Pulsperiodendauer T_P determiniert. Innerhalb einer Pulsperiode können empfangene Echos eindeutig dem aktuellen Sendintervall zugeordnet werden. Dadurch ergibt sich die maximale eindeutige Reichweite r_{max} zu:

$$r_{max} = \frac{c}{2} \cdot T_P \quad (2.12)$$

Für die Auflösung der Relativgeschwindigkeit gilt:

$$\Delta v_r = \frac{c}{2f_0 T_M} \quad (2.13)$$

wobei f_0 die Trägerfrequenz bezeichnet und T_M die Gesamtlänge der Pulsfolgen ist.

Die beschriebene Arbeitsweise eines Radars mit einer Antenne erlaubt die Messung von Distanz und Relativgeschwindigkeit. Für Anwendungen im Automobilbereich ist zusätzlich der Betrachtungswinkel wichtig. Dieser kann bei Verwendung mehrerer Antennenelemente aus dem Amplitudenverhältnis gewonnen werden. Bei zwei Antennenkeulen, die leicht versetzt ausgerichtet sind, erscheint ein Ziel abhängig vom Winkel, in dem es sich befindet, in der einen mit Amplitude A_1 und in der anderen mit Amplitude A_2 . Die Winkelschätzung erfolgt mithilfe des Amplitudenverhältnisses, dies ist der Quotient aus der Differenz von A_1 und A_2 und deren Summe. Beim Antennendesign der dieser Arbeit zugrunde liegenden Sensoren verläuft das Amplitudenverhältnis über einen großen Winkelbereich nahezu linear. Bei den hier verwendeten Nahbereichsradarsensoren werden die Antennendiagramme durch zwei Empfangselemente realisiert, die einmal phasengleich und einmal um 90° phasenverschoben betrieben werden. Dieses Verfahren wird als sequentielle Strahlformung (*engl. Sequential Lobing*) bezeichnet. Ein Nachteil dieses Verfahrens besteht darin, dass zwei Ziele in gleicher Entfernung und mit gleicher Geschwindigkeit ein Scheinziel bilden, wenn sie nicht aufgelöst werden können. Dieses erscheint als einzelnes Ziel mit falscher Winkelinformation.

Die Funktionsweise sowie die Betrachtung der Systemparameter wurden hier nur in der Zusammenfassung dargestellt. Ebenso wurde auf Hardwareaspekte nicht näher eingegangen. Dies kann in [Men99] und [HKF05] nachgelesen werden. Detailliertere Ausführungen zur Radartechnologie finden sich ebenfalls in [Sko08], [VHW09, S. 123 ff.] und [Büh08, Kap. 2.4].

2.1.3 Fernbereichsradar

Der Radarsensor für den Fernbereich arbeitet nach dem Prinzip des frequenzmodulierten Dauerstrichradars (*engl. Frequency Modulated Continuous Wave, FMCW*). Hierbei wird der Sender nicht an- und ausgeschaltet, sondern arbeitet kontinuierlich und sendet dabei ein frequenzmoduliertes Signal aus.

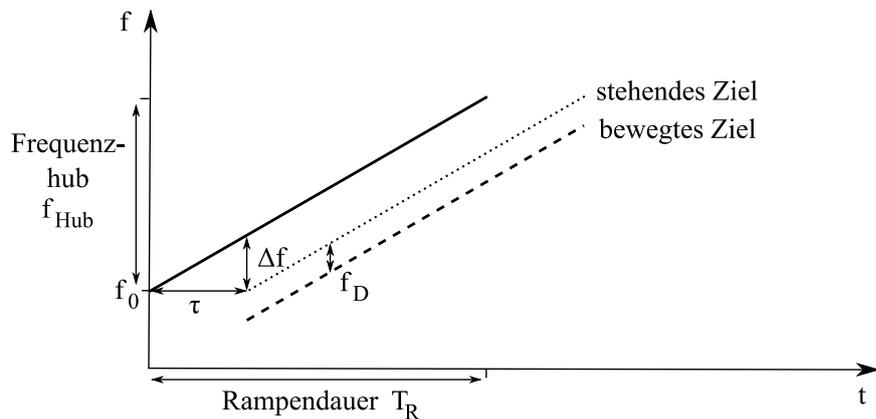


Abbildung 2.4: Sende- und Empfangssignal bei linearer Frequenzmodulation

In Abbildung 2.4 ist beispielhaft der zeitliche Verlauf eines Einzelsignals mit linearem Frequenzanstieg gezeigt. Die durchgezogene Linie stellt das ausgesandte Signal dar. Ein durch ein Objekt zurückgestreutes Signal trifft mit der Verzögerung τ beim Empfänger ein, was sich als Frequenzverschiebung bemerkbar macht (gepunktete Linie). Da beide Geraden die gleiche Steigung besitzen, gilt

$$\frac{f_{Hub}}{T_R} = \frac{\Delta f}{\tau} \quad (2.14)$$

wobei die Laufzeit τ proportional zur Entfernung r ist.

$$r = \frac{c}{2} \cdot \tau \quad (2.15)$$

Aus der Überlagerungsfrequenz, die durch Mischen der Signale, wie in Kapitel 2.1.2 beschrieben, entsteht, kann durch Frequenzanalyse direkt der Abstand (genauer gesagt die Abstandszelle) des reflektierenden Objektes bestimmt werden. Dies gilt zunächst für stehende Ziele. Bewegt sich das Objekt, bewirkt dies eine zusätzliche Frequenzverschiebung um die Dopplereffrequenz f_D (dargestellt durch die gestrichelte Linie in Abbildung 2.4, die ein sich entfernendes Ziel repräsentiert). Die resultierende Frequenzverschiebung Δf_{ges} beträgt somit

$$\Delta f_{ges} = \Delta f - f_D = \frac{2}{c} \left(\frac{f_{Hub}}{T_R} \cdot r + f_0 \cdot v_r \right) \quad (2.16)$$

wobei die Dopplereffrequenz f_D nach Gleichung 2.3 aufgelöst wurde und Δf durch die Gleichungen 2.14 und 2.15 substituiert wurde. Wie ersichtlich wird, ist die Differenzfrequenz sowohl von der Entfernung als auch von der Relativgeschwindigkeit abhängig. Da es mehrere Kombinationen aus Distanz und Relativgeschwindigkeit geben kann, die auf dieselbe Differenzfrequenz

abbilden, sind diese nicht eindeutig bestimmbar. Abhilfe schafft die Verwendung eines zweiten Signalanteils mit modifizierter Modulation. In der Praxis finden verschiedene Signalformen Anwendung, z. B. die Verwendung mehrerer Rampen mit unterschiedlicher Steigung (mit steigender und fallender Frequenz) oder die schrittweise Frequenzumtastung (*engl. Frequency Shift Keying, FSK*), bei der kurze Pulse jeweils konstanter Frequenz ausgesendet werden und danach die Frequenz verändert wird. Eine Beschreibung der Verfahren mit Beispielen verschiedener Hersteller findet sich in [WHW09].

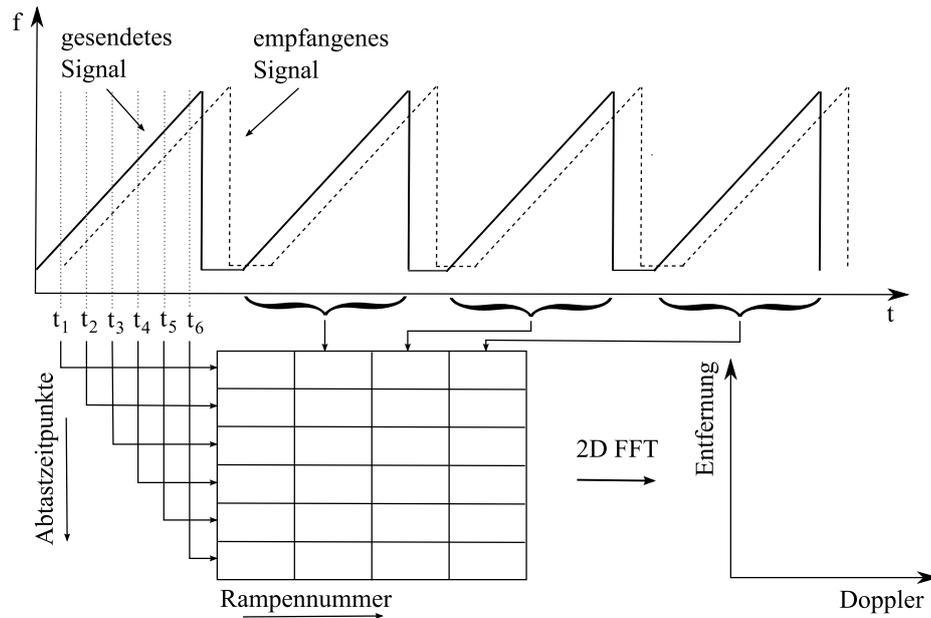


Abbildung 2.5: Frequenzverlauf beim FMCW mit schnellen Rampen und Prinzip der Signalverarbeitung

Bei dem hier verwendeten Sensor werden schnelle Rampen (*engl. Fast Chirps*) als Signalform verwendet. Abbildung 2.5 veranschaulicht das Prinzip. Die durchgezogene Linie im Frequenz-Zeit-Diagramm stellt wiederum das ausgesandte Signal dar, die gestrichelte Linie ist das Empfangssignal. Das Verfahren erlaubt die gleichzeitige Auswertung der Abstands- und Dopplerverinformation. Aufgrund der kurzen Rampendauer wird die Dopplerverschiebung innerhalb einer Rampe nicht relevant, sodass eine direkte Zuordnung zwischen Abstand und Frequenz getroffen werden kann. Die auftretenden Überlagerungsfrequenzen werden durch die Fouriertransformation ermittelt. Die Abtastzeitpunkte t_i können somit in Abstandszellen übersetzt werden. Eine weitere Fouriertransformation einer Abstandszelle über die Rampenfolge hinweg liefert direkt die entsprechenden Dopplerfrequenzen.

Die Entfernungsauflösung ist von der Auflösung der Frequenzen abhängig, die über die FFT ausgewertet werden. Das heißt, um eine hohe Entfernungsauflösung zu erhalten ist ein entsprechend hoher Frequenzhub, also die entsprechende Bandbreite nötig. Die Auflösung der Relativgeschwindigkeit hängt von der Grundfrequenz f_0 und der Gesamtmesszeit T ab.

$$\Delta r = \frac{c}{2} \cdot \frac{1}{f_{Hub}}, \quad \Delta v_r = \frac{c}{2} \cdot \frac{1}{f_0 T} \quad (2.17)$$

2.1.4 Vergleich der Sensoren

Bedingt durch die technischen Messprinzipien und die verwendeten Wellenlängen ergeben sich für die Sensoren unterschiedliche Vor- und Nachteile. Laserscanner besitzen einen großen Sichtbereich und können präzise Entfernungen vermessen. Zudem liegt ihr Vorteil in der hohen Winkelauflösung. Die Bestimmung des Winkels, unter dem ein Objekt beobachtet wird, ist bei Radarsensoren zwar im Prinzip möglich, stellt aber höhere Anforderungen an Hardware und Rechenzeit. Ein Vorteil der Radartechnik besteht darin, dass Geschwindigkeiten von Objekten relativ zum Sensor unter Ausnutzung des Doppler-Effektes direkt gemessen werden können. Tabelle 2.1 gibt einen Überblick über die wichtigsten Größen aller für diese Arbeit verwendeten Sensoren.

Tabelle 2.1: Spezifikationen der verwendeten Sensoren

Merkmal	LRR		SRR	Laserscanner
	Nahmodus	Fernmodus		
Winkelbereich	56°	18°	80°	160°
Winkelauflösung	4°	1°	–	0.25..1°
Winkelgenauigkeit	±1..2°	±0.1°	±5..10°	0.25..1°
Entfernungsbereich	60 m	200 m	30 m	200 m
Entfernungsauflösung	2 m	2 m	30 cm	1 cm
Entfernungsgenauigkeit	±25 cm	±25 cm	±5..7.5 cm	±5 cm
Geschwindigkeitsauflösung	5.5 km/h	5.5 km/h	k.A.	–
Geschwindigkeitsgenauigkeit	±0.5 km/h	±0.5 km/h	±5 km/h	–
Zykluszeit	66 ms	66 ms	40 ms	40 ms

Neben Messbereichen, Genauigkeiten und Auflösungen spielen weitere Faktoren wie der Einfluss von Umgebungsparametern (z. B. Wetter, Umgebungslicht, Partikel in der Luft) auf die Sensorperformance, die Variabilität beim Verbau im Fahrzeug und nicht zuletzt die Kosten eine Rolle bei der Wahl der Sensoren zur Umsetzung von Assistenz- und Sicherheitsfunktionen im Automobil. Weitere Punkte sind die Erfassung von räumlichen Abmessungen in den verschiedenen Dimensionen und die Fähigkeit zur Objektklassifikation. In Tabelle 2.2 werden unterschiedliche im Automotivbereich einsetzbare Sensortechnologien, nicht nur die in dieser Arbeit verwendeten, anhand wesentlicher Kriterien verglichen. Die Daten stützen sich auf [Wal08, S. 19] und [RG05, S. 208] sowie auf die Erfahrungen der Autorin.

Der Vergleich zeigt, dass Stärken und Schwächen einzelner Technologien teilweise komplementär sind, so dass eine Fusion dieser Sensoren einen Leistungssteigerung für das Gesamtsystem bedeuten würde.

Die Vorteile der einzelnen Sensortechnologien stellen sich wie folgt dar: Radarsysteme sind in hohem Grade wetterunabhängig und besitzen sehr gute longitudinale Eigenschaften. Laserscanner sind eher wetterabhängig, besitzen im Gegenzug aber sehr gute longitudinale sowie gute laterale Eigenschaften. Kamerasysteme sind ebenfalls zum Teil wetterabhängig. Sie zeichnen sich wiederum durch gute laterale Eigenschaften aus. Für Stereosysteme gilt dies auch in longitudinaler Richtung. Zudem besteht hier die Möglichkeit der Klassifikation, die anderer-

Tabelle 2.2: Vergleich automotiver Sensortechnologien, Bewertung der Güte: ++ sehr gut, + gut, ◦ befriedigend, – ausreichend, – – mangelhaft

	Radar	Laser-scanner	Mono-kamera	Stereo-kamera	IR-Kamera	Ultra-schall
maximale Reichweite	200 m*	200 m	100 m	80 m	>300 m	4 m
Funktionsweise	aktiv	aktiv	passiv	passiv	aktiv/passiv**	aktiv
Genauigkeit longitudinal	++	++	◦	+	–	+
Genauigkeit lateral	◦ [◇]	+	+	+	+	–
Geschwindigkeitsinformation	++	--	--	--	--	◦
Objektanmessungen	–	+	++	++	++	--
Klassifikation	–	◦	++	++	+	--
Schlechtwetterverhalten	++	–	–	–	–	+
Verhalten bei Verschmutzung	++	◦	--	--	--	++
Verhalten bei Nacht	++	++	–	–	++	++
Verbaubarkeit	++	◦	+	◦	◦ / +**	++
Kosten	◦	–	++	–	◦ / –**	++

* Fernbereichsradar

** Nah-Infrarot/Fern-Infrarot

◇ für Fernbereichsradar sehr gut wegen hoher Winkelauflösung, dann jedoch eingeschränktes FoV, vgl. Tabelle 2.2

seits aber auch nach mehr Ressourcen (Rechenzeit und Speicher) verlangt. Im Gegensatz zu Radar-, Laser- und Ultraschallsensoren senden Kameras (mit Ausnahme einiger Infrarotsysteme) keine elektromagnetische Strahlung aus, sondern arbeiten passiv, was das Thema gegenseitiger Störung mehrerer Sender und Interferenzen von vornherein ausschließt. Andererseits sind diese Sensoren von natürlichen „Störfaktoren“ beeinflusst, z. B. Blendung durch die Sonne, Schattenbildung, etc.

2.2 Versuchsträger

Als Versuchsfahrzeug kommt ein Fahrzeug der Marke Mercedes-Benz S-Klasse zum Einsatz, welches mit den in Kapitel 2.1 beschriebenen Sensoren ausgestattet wurde. Im Kofferraum wurde ein automotive-taugliches Rechnersystem verbaut, auf dem ein Software-Framework zur Aufzeichnung der Sensordaten sowie die im Rahmen dieser Arbeit entwickelte Software zur Sensordatenverarbeitung implementiert wurde. Damit ist es zum einen möglich, reale Sensordaten aufzuzeichnen, um sie später im Labor zur Entwicklung und Validierung der Algorithmen zur Umgebungserfassung zu benutzen, und zum anderen kann die Performance und Echtzeitfähigkeit der entwickelten Algorithmen direkt im Fahrzeug getestet werden. Den Versuchsträger mit den Verbaupositionen der Sensoren zeigt Abbildung 2.6.



Abbildung 2.6: Verbaupositionen der Sensoren im Versuchsträger

2.3 Logischer Systemaufbau

Abbildung 2.7 zeigt den Ablauf der einzelnen Verarbeitungsschritte innerhalb des Umgebungserfassungssystems in stark vereinfachter Form. Die Eingabe bilden die von Laserscanner und Radarsensoren erzeugten Sensorrohdaten. Die Vorverarbeitungsstufe erzeugt aus den Laserscanner-Rohdaten abstrahierte Objekthypothesen in Form von ausgerichteten Rechtecken. Basierend auf deren Abmessungen findet eine Einteilung in potentielle Fahrzeuge und andere Zielklassen statt. Für die in die Klasse der Fahrzeuge eingeteilten Ziele wird eine neu entwickelte Methode zur Fusion von ausgedehnten Zielen mit Radarzielen angewandt, die auf Radarreflexionsmodellen von Fahrzeugen basiert. Für die anderen Ziele wird eine Fusion anhand der Referenzpunkte vorgenommen. Die detektierten Ziele werden im Tracking über die Zeit verfolgt und gefiltert und bilden schließlich eine Beschreibung der Fahrzeugumgebung in Form einer Objektliste.

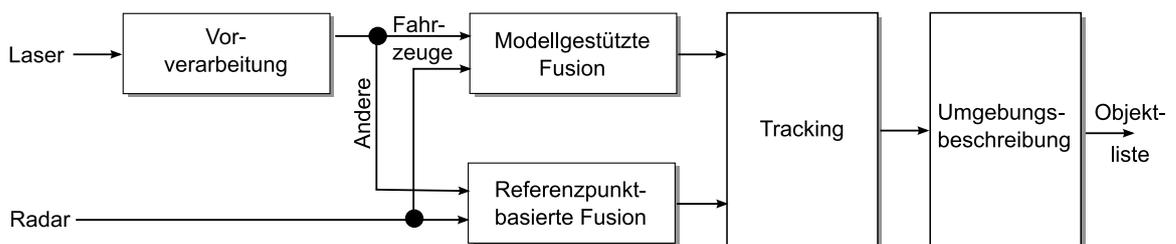


Abbildung 2.7: Flussdiagramm der Datenverarbeitungsschritte

3 Generieren von Objekthypothesen aus Laserscannerdaten

Dieses Kapitel behandelt die Vorverarbeitungsschritte, die auf den Rohdaten des Laserscanners vorgenommen werden. Diese beinhalten die Gruppierung der Rohdatenpunkte sowie die Extraktion von Merkmalen innerhalb der gruppierten Punktwolken. Ausgehend von der Verarbeitungskette bezeichnet in dieser Arbeit ein *Segment* eine Gruppe von Messpunkten des Laserscanners, ein *Objekt* stellt die Abstraktion von realen Objekten in der Fahrzeugumgebung dar. Objekte entstehen durch räumliche und zeitliche Verfolgung der Segmente. Neben Positions- und Bewegungsinformationen sind sie mit weiteren Attributen wie Länge, Breite und Orientierung versehen, die aus den Merkmalen der Segmente abgeleitet werden.

Da die Leistungsfähigkeit der modellbasierten Fusion in entscheidendem Maße von der Güte der gebildeten Objekthypothesen abhängt, wird in diesem Kapitel vertieft auf die verwendeten Methoden bei der Verarbeitung der Laserscannerdaten und dessen Evaluierung eingegangen.

3.1 Segmentierung

Unter Segmentierung versteht man eine Partitionierung des vom Laserscanner gelieferten Umgebungsscans. Das Ziel dabei ist es, die Datenpunkte so zu gruppieren, dass sie realen Objekten in der Fahrzeugumgebung entsprechen. Die Gruppierung von Laserscannerrohdaten erfolgt im Wesentlichen über deren Abstand zueinander, wobei verschiedene Verfahren zum Einsatz kommen können, die im Folgenden beschrieben und bewertet werden.

3.1.1 Segmentierverfahren im Überblick

Verfahren zur Segmentierung von Laserscannerdaten lassen sich in drei Kategorien einteilen. Bei der *abstandsbasierten Segmentierung* wird anhand des euklidischen Abstands zweier Punkte entschieden, ob sie zum selben Segment gehören. Die *gitterbasierte Segmentierung* bedient sich eines Rasters, in das die Punkte einsortiert und anschließend zu Segmenten verbunden werden. Unter dem Begriff *Clusterverfahren* werden alle übrigen Verfahren zur Gruppierung von Daten zusammengefasst, die mit einem (nicht notwendigerweise metrischen) Distanzmaß arbeiten.

Abstands-basierte Segmentierung

Der abstands-basierte Segmentieralgorithmus verarbeitet die nach ihrem Ablagewinkel sortierten Laserdatenpunkte sequentiell und entscheidet jeweils anhand eines einfachen Abstandskriteriums, ob ein begonnenes Segment fortgesetzt wird oder, wenn der Abstand größer als der eingestellte Schwellwert ist, ein neues Segment begonnen wird. Für den Abstand d_{PQ} zweier Punkte P und Q gilt:

$$d_{PQ} = \sqrt{r_P^2 + r_Q^2 - 2r_P r_Q \cos \alpha} \quad (3.1)$$

wobei r_P, r_Q die gemessene Distanz der Punkte zum Ursprung ist und α den von r_P und r_Q eingeschlossenen Winkel bezeichnet (siehe Abbildung 3.1). Der Schwellwert d_{th} kann wie in

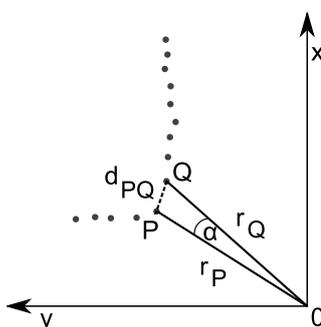


Abbildung 3.1: Abstands-basierte Segmentierung: geometrische Grundlagen

[DSS01] beschrieben berechnet werden:

$$d_{th} = \min(r_P, r_Q) \sqrt{2 - 2 \cos \alpha} + C \quad (3.2)$$

wobei C eine Konstante bezeichnet, die addiert wird, um die Robustheit im Nahbereich zu erhöhen.

Wird ein mehrzeiliger oder mehrzielfähiger Laserscanner verwendet, kann die beschriebene einfache Implementierung zu Problemen bei der Segmentierung führen, wenn Laserscannerpunkte von räumlich getrennten Zielen in einen Winkelauf Lösungsbereich fallen, wie Abbildung 3.2(a) zeigt. Die sequentielle Verarbeitung der winkelsortierten Scanpunkte würde hier zu einem Zerfall der Segmente führen. Eine Lösung wäre die getrennte Verarbeitung der einzelnen Ebenen, was allerdings komplexe Logik erfordert, um die Ergebnisse anschließend wieder zu kombinieren. Eine weitere Lösung besteht in einer Implementierung mit Warteschlangen. Wird nach Überschreiten des Abstandsschwellwertes ein neues Segment begonnen, wird das alte Segment nicht abgeschlossen, sondern zunächst in eine Warteschlange eingereiht, so dass es später fortgesetzt werden kann. Für Punkte, die Startpunkt eines neuen Segments würden, wird zunächst geprüft, ob Segmente in der Warteschlange fortgesetzt werden können. Um die Warteschlange zu begrenzen, werden Segmente, deren Differenz zum aktuellen Ablagewinkel einen einzustellenden Parameterwert übersteigt, abgeschlossen. Das Ergebnis der Implementierung mit Warteschlangen im Vergleich zur klassischen Implementierung ist in Abbildung 3.2(b) aufgezeigt.

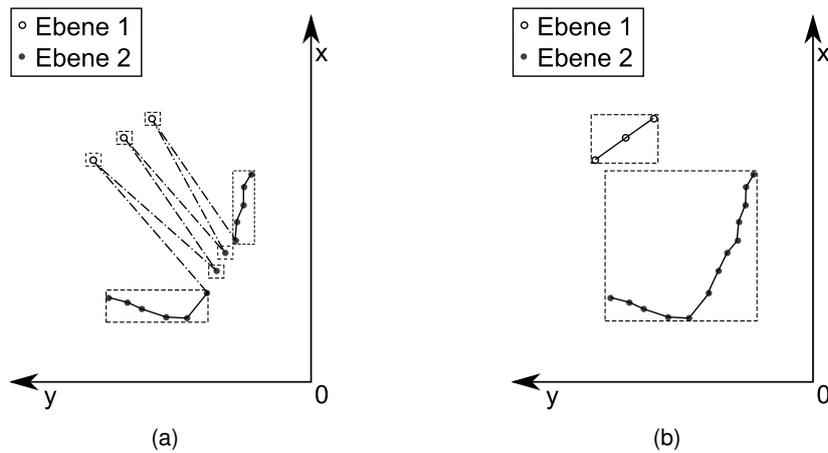


Abbildung 3.2: Abstandsbasierte Segmentierung angewendet auf Daten eines mehrzeiligen Laserscanners: (a) klassische Implementierung, (b) Implementierung mit Warteschlange

Gitterbasierte Segmentierung

Bedingt durch schnelle Ausführungszeiten und eine gute Parametrierbarkeit wurde dieses Verfahren im Rahmen der für diese Arbeit verwendeten Algorithmen gewählt. In Kapitel 3.1.2 wird auf die Arbeitsweise, Parameter und Besonderheiten eingegangen.

Clusterverfahren

Clustering, also das Gruppieren von Datenpunkten oder Merkmalsvektoren, findet in unterschiedlichen Kontexten Anwendung, etwa bei der Auswertung biologischer Daten oder in der Bildverarbeitung. Ziel ist es dabei, Muster innerhalb der Daten zu finden. Clusteralgorithmen arbeiten entweder agglomerativ, das heißt, sie beginnen mit Clustern bestehend aus Einzel-elementen und erweitern diese, oder divisiv, in diesem Fall findet die Initialisierung mit einem Cluster statt, der alle Datenpunkte enthält. Dieser wird schrittweise in kleinere Cluster zerteilt. Bekannte Clusterverfahren sind z. B. der K-Means-Algorithmus oder das hierarchische Clustering.

Der K-Means-Algorithmus startet mit einer zufälligen Wahl von k Clusterzentren. Die Datenpunkte werden den Clustern anhand der kürzesten Distanz zu deren Zentrum zugeordnet. Anschließend werden die Zentren neu berechnet und die Daten erneut den Clustern zugeordnet. Der Algorithmus bricht ab, wenn sich die Clusterzuordnung nicht mehr ändert. K-Means ist ein einfach zu implementierender Algorithmus, für die Verarbeitung der Laserscans allerdings nicht geeignet, da die Clusteranzahl von vornherein bekannt sein muss.

Das hierarchische Clustering gibt eine Baumstruktur der Datenmenge aus, bei der kleinere Cluster jeweils in größeren Clustern enthalten sind. Die Gruppierung kann agglomerativ oder

divisiv erfolgen. Agglomerative Algorithmen beginnen mit n Clustern C_n , wobei n die Anzahl der Datenpunkte ist, und berechnen schrittweise Vereinigungsmengen $C_i \cup C_j$ unter Minimierung einer Kostenfunktion, bis alle Teilmengen zu einem Cluster zusammengefasst sind. Unterschiede bestehen in der Wahl der Kostenfunktion. Zur Berechnung kann beispielsweise der kürzeste Abstand innerhalb eines schon vorhandenen Clusters herangezogen werden, aber auch der längste oder der mittlere Abstand. In jedem dieser Fälle ergibt sich die Tendenz zu einer gewissen Form der Cluster, eher länglich für den kürzesten Abstand, sphärisch für die anderen zwei Varianten. Da die Distanzmatrix die Größe $n \times n$ hat und jede Ebene in der Baumstruktur berechnet wird, ist das Verfahren vom Speicherplatz- und Rechenzeitbedarf her eher ungeeignet für die Laserdatenverarbeitung. Zudem müsste in einem weiteren Schritt die Ebene innerhalb des Baumes und damit der Level der Clusterung bestimmt werden, der als tatsächliches Ergebnis der Gruppierung weiterverwendet wird.

In diesem Kapitel wurde kurz auf zwei bekannte Vertreter klassischer Clusterverfahren eingegangen. Für einen weiter greifenden Überblick sei auf [JMF99] und [XI05] verwiesen. Generell lässt sich sagen, dass Clusterverfahren im klassischen Sinne tendenziell aufwendiger bezüglich Speicherplatzbedarf und Rechenzeit sind. Zusätzlich erschwert Rekursion die Abschätzung der benötigten Rechenzeit. Ein weiteres Problem stellt Determinismus dar wie im Fall von K-Means, wo die initiale Verteilung der Clusterzentren zufällig erfolgt, was bei unabhängiger Wiederholung auf demselben Datensatz zu unterschiedlichen Ergebnissen führen kann, und damit die Auswertbarkeit erschwert.

3.1.2 Gitterbasierte Segmentierung

Das Prinzip der gitterbasierten Segmentierung von Laserscannerdaten wurde von Michael Skutek [Sku06] eingeführt. Die Parameter des Gitters wurden in dieser Arbeit verändert, um es an eine geänderte Hardware aber auch an variable Zielszenarien zu adaptieren. Das Verfahren basiert auf einem radialen Gitter, auf welches die Laserdatenpunkte projiziert werden, siehe Abbildung 3.3(a).

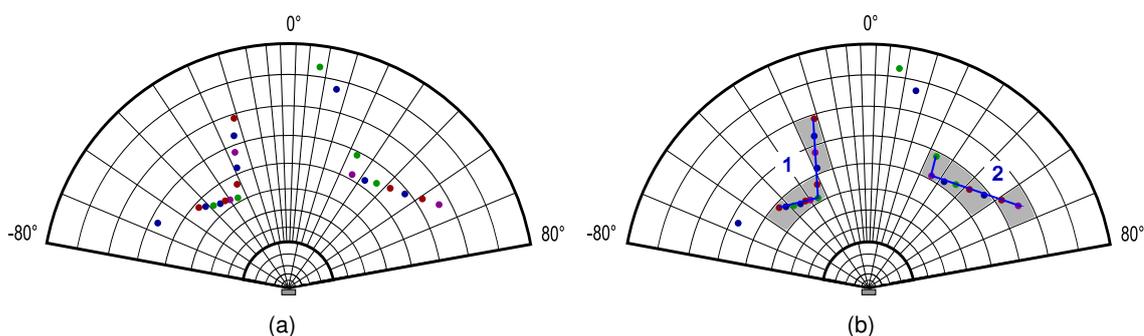


Abbildung 3.3: Segmentierungsgitter (nicht maßstabsgetreu) und Segmentierungsprozedur: (a) Projektion der Datenpunkte auf das Gitter, (b) Markieren belegter Gitterzellen (Anzahl Punkte > Schwellwert), Verbinden benachbarter Zellen und Nummerierung

Gitterzellen, die eine größere Anzahl an Punkten enthalten, als ein vorgegebener Mindestwert, werden als belegt markiert. Somit arbeitet das Gitter gleichzeitig als Filter für Ausreißer. Anschließend werden benachbarte als belegt markierte Zellen zu einem Segment verbunden und mit einer fortlaufenden Nummer gekennzeichnet. Berücksichtigt werden Zellen in Achternachbarschaft. Diese Arbeitsweise entspricht im Wesentlichen dem CCL-Algorithmus (*engl. Connected Component Labeling*) [DST92]. Ein Beispiel zeigt Abbildung 3.3(b).

Die Größe der Gitterzellen kann über Parameter an das Messverfahren sowie an zu erwartende Objektgrößen angepasst werden. Insbesondere kann die Größe der Gitterzellen variabel gestaltet werden. So bietet es sich an, die Zellen mit zunehmendem Winkelbetrag und zunehmender Distanz zum Scanner aufzuweiten, um Objekte zu erfassen, bei denen durch Geometrie oder mangelnde Reflexivität hervorgerufen Messpunkte fehlen. Analog zu den verschiedenen Winkelauf Lösungsbereichen des verwendeten Scanners (siehe Abbildung 2.2(a)) wird das Segmentierungsgitter mit jeweils eigenen Parametern zur Winkelschrittweite für diese Bereiche parametrisiert. Da im Nahbereich die Winkelschritte sehr klein werden können, bietet es sich an, für diesen Bereich eine andere Winkelaufweitung der Zellen zu wählen. Dies ist schematisch in Abbildung 3.3 dargestellt. Dem Parameter zur Entfernungsaufweitung liegen Überlegungen zugrunde, die Santos et. al. [SFS⁺03] im Zusammenhang mit dem abstandsbaasierten Segmentieralgorithmus veröffentlicht haben. Dabei geht es um die Anpassung des Abstandsschwellwerts an die Größe der erwarteten Objekte unter Berücksichtigung ihres Winkels zueinander und zum Beobachter. Der dort vorgeschlagene Parameter β wurde hier übernommen, um die Entfernungsaufweitung r_{cell} der Gitterzellen in Abhängigkeit der Entfernung r und der Winkelschrittweite α zu bestimmen, siehe Abbildung 3.4.

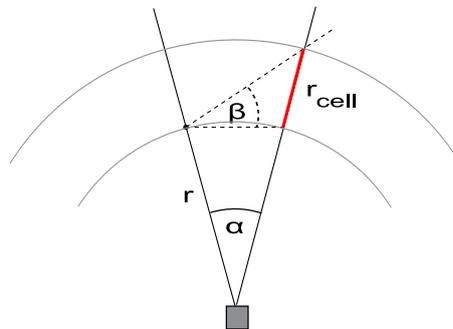


Abbildung 3.4: Die longitudinale Aufweitung der Gitterzellen wird über den Parameter β bestimmt.

Die Entfernungsaufweitung r_{cell} wird wie folgt berechnet:

$$r_{cell} = r \cdot \frac{\sin \beta \sqrt{2 - 2 \cos \alpha}}{\sin(\pi/2 - \beta - \alpha/2)} \quad (3.3)$$

Der Parameter β sollte so gewählt werden, dass Objekte entsprechend dem adressierten Szenario noch getrennt werden können. Sollen z. B. zwei Fahrzeuge, die sich in 20 m Entfernung befinden und einen Abstand von 0,5 m zueinander haben, bei der Segmentierung getrennt werden, ist bei einer angenommenen Winkelauf Lösung von $\alpha = 1^\circ$ der Winkel β mindestens 30° zu wählen.

Trotz sorgfältiger Wahl der Parameter ist es nicht möglich, in allen Fällen ein ideales Ergebnis zu erreichen. Beispielsweise möchte man ein Fahrzeug von Randbebauung separieren, während man bei Randbepflanzung gleichzeitig zu starken Objektzerfall vermeiden möchte. Eine Möglichkeit zur weiteren Optimierung bietet ein zweistufiges Verfahren. Im ersten Schritt wird das Gitter so parametrisiert, dass Objekte eher zusammengefasst als getrennt werden. In einem Nachsegmentierungsschritt werden dann kleinere lokale Gitter über Segmente, die eine gewisse Ausdehnung aufweisen, gelegt, und der Segmentieralgorithmus wird hier nochmals angewandt. Die Parameter für die lokalen Gitter sind adaptiv, d.h. sie können abhängig von der Entfernung und Ausdehnung der Segmente gewählt werden. Abbildung 3.5 zeigt eine Parkplatzszene. Die dicht geparkten Fahrzeuge stellen eine Herausforderung für ein globales Verfahren dar (Ergebnis in der mittleren Reihe). Eine Überanpassung mit zu kleinen Zellgrößen würde in anderen Szenarien zu Objektzerfall führen. Die untere Reihe zeigt das Ergebnis mit lokaler Nachsegmentierung. Die einzelnen Fahrzeuge werden hier deutlich besser separiert, was eine bessere Grundlage für das Objekttracking bildet.

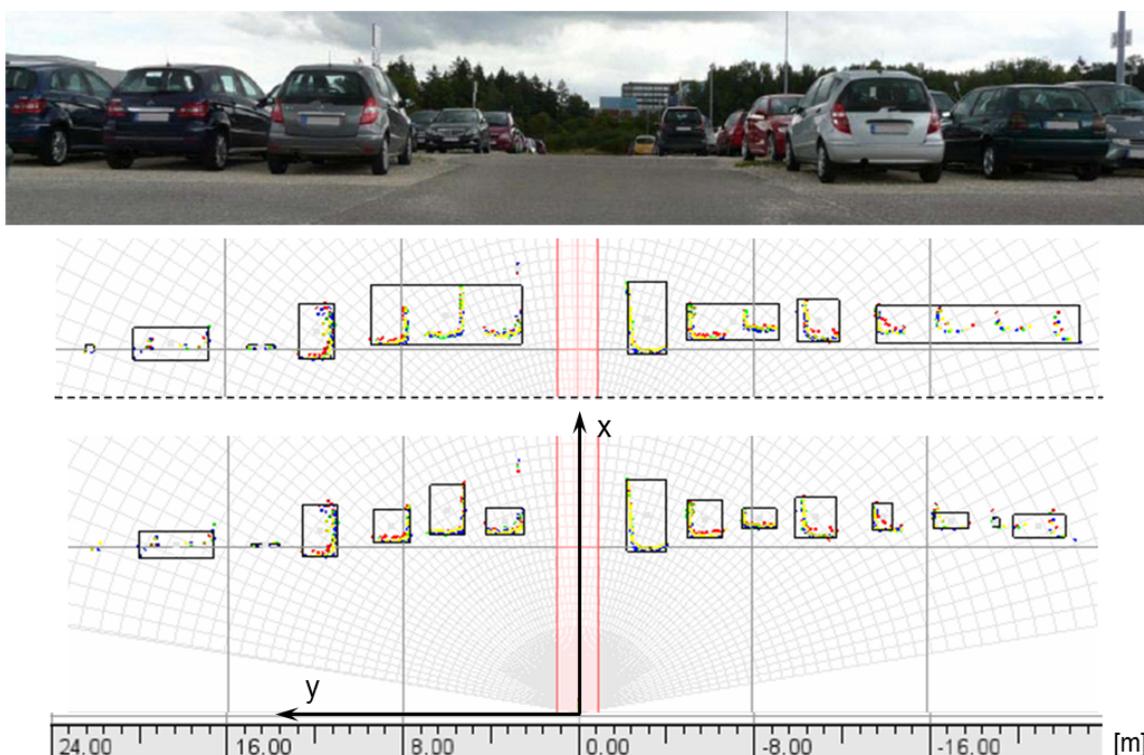


Abbildung 3.5: Zweistufige Segmentierung, oben: Kamerabild der Szene, Mitte: Ergebnis der einstufigen Segmentierung, unten: Ergebnis mit lokaler Nachsegmentierung

3.1.3 Bewertung von Segmentierverfahren

Das ideale Ergebnis der Segmentierung stellt eine 1:1-Abbildung von realen Objekten zu Segmenten dar. Bei einer Einzelbildverarbeitung, die lediglich auf geometrischen Abstandskriterien

basiert, wird dieses Ideal in der Praxis nicht erreicht. Rauschen sowie mangelnde Reflektivität erschweren die Segmentierung zusätzlich. Fehler, die dabei entstehen, sind

- 1) Mehrere reale Objekte werden zu einem Segment zusammengefasst (*Untersegmentierung*).
- 2) Ein reales Objekt wird in mehrere Segmente aufgespalten (*Übersegmentierung*).
- 3) Ein reales Objekt wird durch kein Segment abgebildet.

Unter- und Übersegmentierung können auch in Kombination auftreten. In jedem Fall können Fehler bei der Segmentierung zu falschen Annahmen über Objektgrößen führen und die Objektverfolgung erschweren. Das optimale Ergebnis stellt einen Kompromiss dar, um einerseits eine gute Separierung von in der Realität getrennten Objekten zu ermöglichen und andererseits zu starken Objektzerfall zu vermeiden. Beispielsweise möchte man ein Fahrzeug von Randbebauung separieren, während man bei Randbepflanzung gleichzeitig ein Aufspalten in viele kleine Segmente vermeiden möchte. Die Optimierung der Parameter für das eingesetzte Segmentierverfahren und die Kriterien zur Bewertung dessen Güte sind anwendungsbezogen, im Fokus dieser Arbeit steht die korrekte Segmentierung von Fahrzeugen im Längs- und Querverkehr.

Um die optimalen Parameter für das Segmentierungsgitter zu finden, wurde ein semiautomatisiertes Verfahren eingesetzt. Dazu wurden Laserscans verschiedener Verkehrsszenen mit dem gewünschten Ergebnis (Ground Truth) markiert. Anschließend wurde der Algorithmus mehrfach durchlaufen, wobei die Parameterwerte iterativ erhöht wurden. Als Startparameter wurde die physikalische Auflösung des Scanners gewählt (siehe Abbildung 2.2(a)). Nach jedem Durchlauf wurde die Anzahl an Überdeckungen mit der Ground Truth sowie die Segmentierfehler gezählt. Kombinationen aus Unter- und Übersegmentierung, mehrfaches Zusammenfassen in einem Segment oder mehrfaches Aufspalten eines Objekts wurden jeweils als separate Fehler gezählt. Als Kriterium gilt die Minimierung der Gesamtfehlerzahl. In Abbildung 3.6 sind die Bewertungen vor und nach der automatisierten Parameteroptimierung als prozentuale Überdeckung mit der Ground Truth gegenübergestellt. Die Szenenauswahl erfolgte so, dass unterschiedliche Umgebungen (Landstraße, Innenstadt), unterschiedliche Szenarien (Parken, Kreuzungen, Hinterherfahren) sowie unterschiedliche Verkehrsteilnehmer (Pkw, Lkw) vorkommen. Die Objekte bewegten sich zudem in bzw. durch die verschiedenen Auflösungsbereiche des Scanners. Eine Auflistung und Veranschaulichung der einzelnen Szenen kann in Anhang A nachgeschlagen werden.

Tabelle 3.1: Segmentierparameter vor und nach Optimierung

Winkelbereich	vor Optimierung	nach Optimierung
Bereich 1	1,55°	0,95°
Bereich 2	1,20°	1,60°
Bereich 3	2,40°	2,40°

Vor der automatischen Optimierung wurden die Parameter empirisch gewählt und an einigen ausgewählten Situationen geprüft. Mit dem semiautomatisierten Verfahren sollte ein weitestgehend szenenunabhängiges Optimum der Parameter gefunden werden. Tabelle 3.1 zeigt die

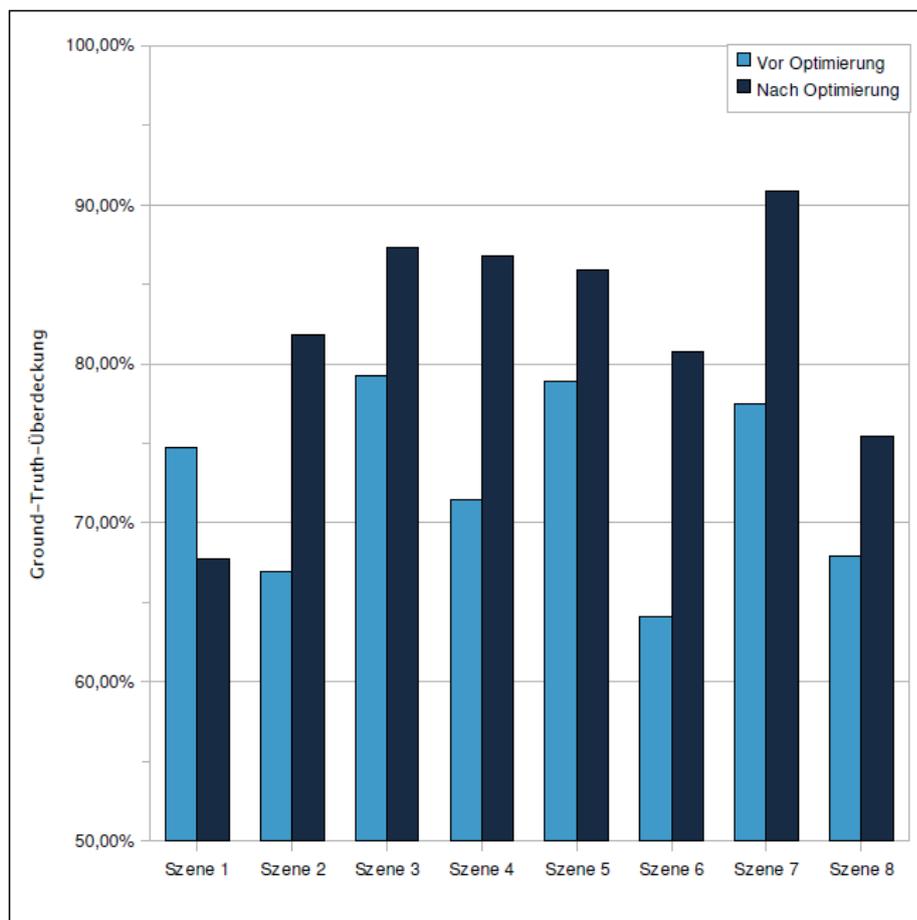


Abbildung 3.6: Vergleich der gitterbasierten Segmentierung vor und nach semiautomatisierter Parameteroptimierung

gefundenen Werte für den Parameter α , der für die Winkelaufweitung der Gitterzellen steht. Dieser unterscheidet sich für die jeweiligen Winkelbereiche des Laserscanners entsprechend Abbildung 2.2(a). Wie in Abbildung 3.6 gezeigt, ergibt sich in der Mehrheit der betrachteten Szenen eine Verbesserung. Einzig in Szene 1 führen die anfangs gewählten Parameter zu einem besseren Ergebnis. Bei dieser Szene handelt es sich um eine Parkplatzsituation mit dicht beieinander stehenden Fahrzeugen vor allem im Bereich 2.

Um die Ground-Truth-Überdeckung zu bestimmen, wurden mittels Toolunterstützung die Informationen über die Datenpunkte in den Ground-Truth-Segmenten mit denen der Ausgabe des Algorithmus verglichen, und somit der Überdeckungsgrad bestimmt [2]. Die Auswertung bezieht sich dabei auf relevante Objekte, d. h. es wurden nur Fahrzeuge markiert. Jede der acht Szenen in der Datenbank ist ungefähr 15 Sekunden lang, so dass sich bei einer Update-Rate von 40 ms rund 375 Frames pro Szene und damit insgesamt 3000 Frames ergeben. Pro Frame wurden jeweils zwei bis fünf Fahrzeuge als relevant markiert.

3.2 Merkmalsextraktion

Ziel der Merkmalsextraktion ist es, eine von den segmentierten Laserscannerdaten abstrahierende Zielbeschreibung von Objekten der realen Welt zu liefern. Eine abstrakte Segmentbeschreibung ersetzt die Rohdaten als Eingabe für folgende Verarbeitungsschritte und kann dadurch deren Laufzeit deutlich reduzieren. Sie erleichtert ebenso die spätere Zuordnung der extrahierten Segmente des laufenden Zeitschritts zu bereits vorhandenen Objekten. Als Merkmale gelten in diesem Zusammenhang geometrische Eigenschaften der Segmente, ihre Form, Referenzpunktkandidaten sowie Attribute, die eine Einteilung der Segmente in unterschiedliche Klassen erlauben. Weiterhin wird unterschieden zwischen Merkmalen, die isoliert aus einzelnen Segmenten abgeleitet werden, hier bezeichnet als objektcharakterisierende Merkmale, und solchen, die erst im Kontext der sie umgebenden Segmente berechnet werden können, hier bezeichnet als szenenrelevante Merkmale.

3.2.1 Objektcharakterisierende Merkmale

Zu den Merkmalen, die aus dem einzelnen Segment abgeleitet werden, gehören einfache Merkmale wie die Seitenlängen des es umgebenden Rechtecks, dessen Orientierung sowie der Mittelpunkt. Aus der Punktmenge und dessen Verteilung in einem Segment können Merkmale wie der Schwerpunkt, die Punktdichte und die Konvexität berechnet werden. Eine Definition aller einfachen geometrischen Merkmale wird in Anhang B gegeben.

Linieneinpassung

Die Kontur von Fahrzeugen kann durch ein umgebendes Rechteck approximiert werden. Daher zielt die Merkmalsextraktion darauf ab, das optimale umgebende Rechteck zu einer Punktmenge innerhalb eines Segmentes zu finden, um aus diesem die Orientierung und die Dimensionen des Segmentes abzuleiten.

Abhängig vom Betrachtungswinkel sind eine oder zwei Seiten eines Fahrzeuges vom Laserscanner beobachtbar. Entsprechend werden für jedes Segment ein oder zwei Linien in seine Punktmenge P eingepasst. Um zwei Linien einzupassen, muss die Punktmenge in zwei Teilmengen partitioniert werden. Der Punkt $P_s = (x_s, y_s)$, an dem die Menge aufgeteilt wird, ist festgelegt als der Punkt, der die größte Distanz zu der Gerade aufweist, die den am weitesten links liegenden mit dem am weitesten rechts liegenden Punkt im Segment verbindet. Die Punkte innerhalb des Segmentes sind dabei nach Winkel sortiert. Die Linieneinpassung wird mit der Methode der kleinsten Fehlerquadrate mit Randbedingungen (*engl. Constraint Least Squares*) durchgeführt [GH04]. Im zweidimensionalen Raum kann eine Gerade durch die Gleichung

$$n_1x + n_2y + c = 0 \quad (3.4)$$

angegeben werden. Dabei ist $[n_1 \ n_2]^T$ der Normalenvektor der Gerade. Eine orthogonale Ge-

rade hat den Normalenvektor $[-n_2 \ n_1]^T$. Dies ergibt das lineare System

$$\begin{bmatrix} 1 & 0 & x_1 & y_1 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & x_s & y_s \\ 0 & 1 & y_{s+1} & -x_{s+1} \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 1 & y_m & -x_m \end{bmatrix} \begin{bmatrix} c_1 \\ c_2 \\ n_1 \\ n_2 \end{bmatrix} = \begin{bmatrix} d_1 \\ d_2 \\ \vdots \\ d_m \end{bmatrix} \quad (3.5)$$

wobei die Punkte $\{P_1 \dots P_s\}$ aus der ersten Teilmenge stammen, $\{P_{s+1} \dots P_m\}$ gehören zur zweiten Teilmenge, m ist die Gesamtzahl der Punkte im Segment, c_1, c_2, n_1, n_2 sind die gesuchten Parameter der Geraden und $d_1 \dots d_m$ sind die Abstände zur Linie, die minimiert werden unter der Beschränkung

$$n_1^2 + n_2^2 = 1 \quad (3.6)$$

im Sinne kleinster Quadrate unter Verwendung von Matrizenberechnungen. Die Einpassung einer Linie erfolgt mit derselben Prozedur, wobei nur eine Punktmenge eingesetzt und c_2 entsprechend weggelassen wird. Indem die Residuen verglichen werden, die beim Einpassen von einer Linie und beim Einpassen von zwei Linien entstehen, wird entschieden, ob ein Segment besser durch zwei Linien oder durch eine Linie repräsentiert wird. Darüber hinaus liefert der mittlere Abstand zur eingepassten Linie bzw. zu den eingepassten Linien ein Maß, um Segmente zu erkennen, die nicht der Bedingung einer rechteckigen Form genügen.

Der Anstieg der (längeren) eingepassten Linie gibt die Orientierung des Segments. Dabei ist anzumerken, dass die Orientierung in dieser Verarbeitungsstufe nicht eindeutig ist. Die absolute Orientierung kann erst bestimmt werden, wenn die Bewegungsrichtung des zugrunde liegenden Objektes bekannt ist. Die Dimensionen des Segments werden aus den Seitenlängen des Rechtecks abgeleitet, welches durch die Punkte mit den minimalen und maximalen Koordinaten aufgespannt wird und um die berechnete Orientierung rotiert ist.

Es ist ebenso möglich, Linien durch Regression zu finden ohne Randbedingungen. Die Punktmenge wird wiederum am Punkt P_s aufgeteilt. In jede der Untermengen werden unabhängig Geraden eingepasst. Die Entscheidung, ob zwei Linien oder nur eine Linie eingepasst werden, also ob die Punktmenge aufgeteilt wird oder nicht, wird im Voraus getroffen. Übersteigt der Abstand vom Punkt P_s zur Geraden, die durch die Punkte P_1 und P_m gebildet wird, einen vorgegebenen Schwellwert, wird die Menge aufgeteilt. Die Gerade wird durch orthogonale Regression ermittelt, da die Messpunkte sowohl in y als auch in x fehlerbehaftet sind und nicht etwa die eine Koordinate als Funktion der anderen aufgefasst werden kann, siehe Abbildung 3.7.

Eine weitere Alternative zur Linieneinpassung ist die Verwendung von RANSAC (**R**andom **S**ample **C**onsensus) [FB81]. Der RANSAC-Algorithmus ist ein Algorithmus, um eine parametrisierbare Figur optimal in eine Punktmenge einzupassen, wobei Ausreißer ignoriert werden. Als Parameter werden die Anzahl der Iterationen i und die Fehlerschranke θ benötigt. Da in dieser Anwendung eine Regressionsgerade bestimmt werden soll, genügen zwei Punkte als Geradenmodell.

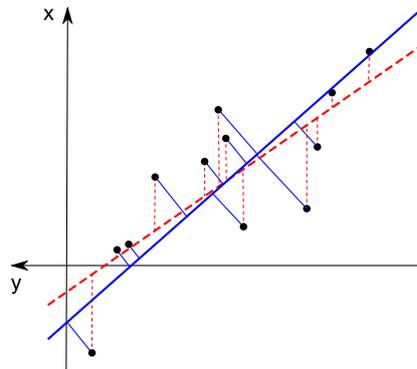


Abbildung 3.7: Vergleich zwischen linearer (rote, gestrichelte Linie) und orthogonaler Regression (blaue, durchgezogene Linie)

Die Vorgehensweise ist wie folgt:

1. Es werden zufällig zwei unterschiedliche Punkte aus einem Segment bestimmt.
2. Die Gleichung der durch diese beiden Punkte definierten Geraden wird berechnet.
3. Alle Punkte, die in dem Fehlerschlauch um diese Gerade liegen, das heißt, alle Punkte mit einem Abstand $\leq \theta$ zu dieser Geraden, werden bestimmt. Diese Punktmenge nennt sich *Consensus Set*.
4. Wiederhole die Schritte eins bis drei i -fach.
5. Das *Consensus Set* mit den meisten Punkten wird ausgewählt. Es enthält die Punkte, die das Modell einer Geraden am besten unterstützen.
6. Die Regressionsgerade, die durch die Punkte des besten *Consensus Set* gelegt wird, wird nur selten durch Ausreißer verfälscht.

Die benötigten Parameter i und θ sind applikationsspezifisch und können empirisch bestimmt werden. Wie bereits bei den Regressionsverfahren beschrieben, wird die Punktmenge gegebenenfalls aufgeteilt und der RANSAC-Algorithmus auf jede Teilmenge getrennt angewendet.

Abbildung 3.8 zeigt das Laufzeitverhalten der drei vorgestellten Verfahren zur Linieneinpassung im Vergleich. Gemessen wurde die Zeit in ms, die jeweils ein kompletter Durchlauf der Algorithmen für jeweils ein Segment benötigte in Abhängigkeit der Anzahl der Rohdatenpunkte im Segment. Die orthogonale Regression liegt in etwa konstant bei 0,1 ms. Bei Verwendung des RANSAC ergibt sich eine leichte Steigung mit der Erhöhung der Anzahl der Punkte. Parametriert wurde hier mit $i = 50$ und $\theta = 15cm$. Die beiden Parallelen ergeben sich durch das Einpassen von einer oder zwei Linien. Bei der *Constraint Least Squares* - Methode wächst der Aufwand kubisch mit der Anzahl der Punkte. Die Auswertung wurde auf einem Rechner mit Intel® Core™2 Extreme CPU X9650 mit 3 GHz, 6 MB Cache und 4 GB Arbeitsspeicher durchgeführt.

Die orthogonale Regression hat sehr kurze Laufzeiten, das Ergebnis wird jedoch durch Ausreißer beeinflusst. Bei Verwendung des RANSAC-Algorithmus werden Ausreißer verfahrensbedingt ausgefiltert. Die Constraint-Least-Squares-Methode hat den Vorteil, dass die eingepasste

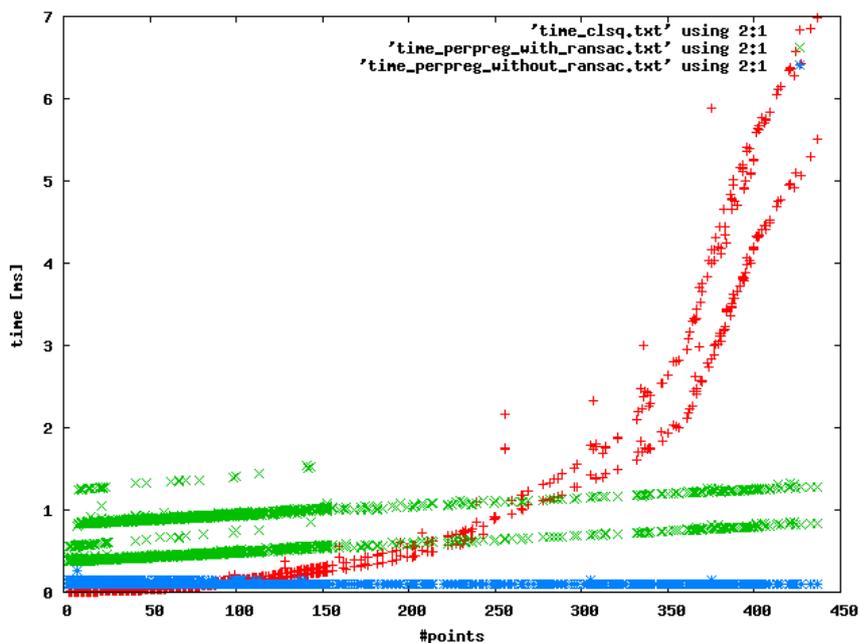


Abbildung 3.8: Laufzeit der unterschiedlichen Methoden zur Linieneinpassung für ein einzelnes Segment in Abhängigkeit der Punktzahl, rot: Constraint Least Squares, grün: RANSAC, blau: orthogonale Regression

Rechteckform direkt die gesuchte Fahrzeugform repräsentiert, sodass eine nachträgliche Überprüfung des Winkels zwischen zwei eingepassten Geraden auf Plausibilität entfällt. Der mittlere Abstand der einzelnen Punkte zum eingepassten Linienpaar kann als Gütemaß für das Fitting benutzt werden. Für Rückfronten und Fahrzeugseiten war dieses Verfahren in der Praxis gut geeignet, bei entgegenkommenden Fahrzeugen erwies es sich als weniger geeignet, da durch die eher runde Form die Einpassung mit Randbedingung tendenziell falsche Ergebnisse lieferte. Zudem treten gerade im Nahbereich durchaus Segmente mit hoher Anzahl an Punkten auf, sodass in Szenen mit hoher Segmentdichte die hohen Laufzeiten problematisch werden.

Probleme bei der Linieneinpassung

Die Segmente auf der linken Seite in Abbildung 3.9 sind Beispielsegmente, in die jeweils Linien eingepasst werden sollen. Auf der rechten Seite wird dargestellt, wie die zugehörigen eingepassten Linien aussehen, wenn keine weiteren Maßnahmen getroffen werden. Der ermittelte Trennpunkt wird durch einen Stern dargestellt. Alle Punkte, die links davon liegen werden der linken Geraden zugeordnet (rechteckige beziehungsweise rote Punkte). Die Punkte, die rechts davon liegen werden der rechten Geraden zugeordnet (runde beziehungsweise blaue Punkte).

Abbildung 3.9(a) zeigt ein Segment, bei dem optimale Voraussetzungen für eine Linieneinpassung herrschen. In Abbildung 3.9(b) wird dargestellt, wie die eingepassten Linien aussehen würden.

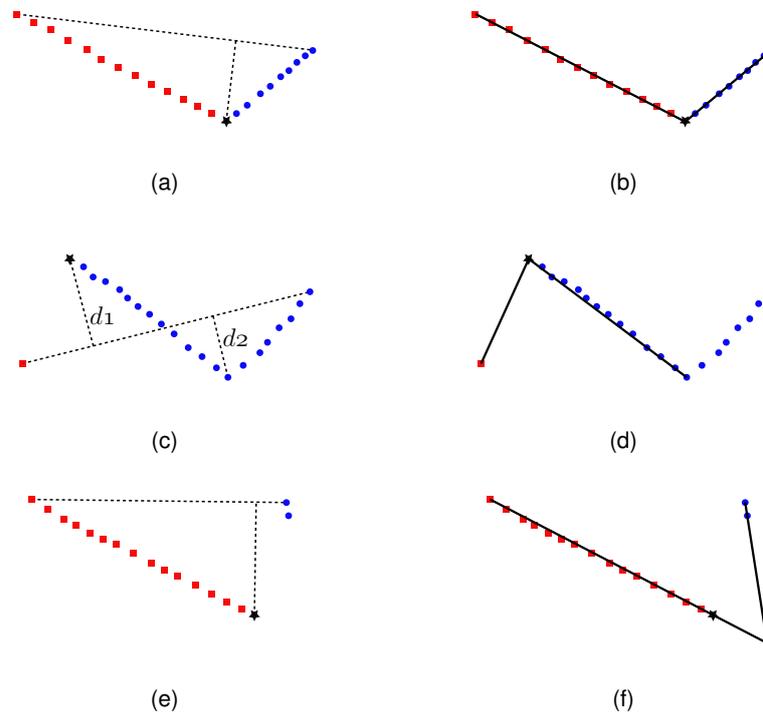


Abbildung 3.9: Beispiele für Probleme bei der Linienanpassung

Im zweiten Segment 3.9(c) ist ein Ausreißer enthalten. Da Abstand d_1 größer als Abstand d_2 ist, wird der Punkt bei d_1 als Trennpunkt gewählt. In Abbildung 3.9(d) wird die falsche Wahl des Trennpunktes deutlich sichtbar. Dieser Problemfall wird effektiv vermieden, wenn vor der Linienanpassung Ausreißer ausgefiltert werden. Dies kann z. B. durch Anwendung des Median-Filters geschehen oder auch durch Weglassen von Punkten, die einen zu großen Abstand zur übrigen Punktmenge besitzen.

Beim dritten Segment 3.9(e) fehlen Rohdatenpunkte. In Abbildung 3.9(f) wird dargestellt, dass dadurch unrealistische Linien eingepasst werden. Dieser Fall kann durch Plausibilisierung der Schnittpunkte vermieden werden. Nach Berechnung der Bounding Box würde erkannt werden, dass der Schnittpunkt zu weit von den Rohdatenpunkten entfernt liegt. Alternativ würde eine einzelne Linie eingepasst werden. Dieser Fall tritt nur bei der Linienanpassung ohne Randbedingungen auf.

Die dargestellten Problemfälle werden ebenfalls vermieden, indem Linien, die durch lediglich zwei Punkte gestützt werden, die zudem nahe beieinander aber mit Abstand zur übrigen Punktmenge liegen, unterbunden werden. In diesem Fall sollten diese Punkte beim Einpassen einer Linien nicht beachtet werden, um das Ergebnis nicht zu verfälschen.

Orientierungswinkel

Der Orientierungswinkel ψ ist definiert durch den Winkel zwischen x-Achse (Fahrtrichtung) und der Längsachse eines Segmentes. Gilt $|\psi| \geq 45^\circ$, ist das Objekt quer ausgerichtet. Ist $|\psi| < 45^\circ$, ist das Objekt längs ausgerichtet. Der Orientierungswinkel ψ liege dabei im Bereich $[-90^\circ, 90^\circ]$, da aus der Einzelbildverarbeitung nicht auf die Fahrtrichtung geschlossen werden kann.

Es gibt mehrere Möglichkeiten, den Orientierungswinkel aus Segmentmerkmalen zu berechnen, zum Beispiel mittels der Drei-Punkt-Methode [Sku06], aus der Hauptkomponentenanalyse oder abgeleitet aus der Linieneinpassung.

Bei der Drei-Punkt-Methode werden zunächst der Punkt mit dem geringsten Ablagewinkel $P_{\phi_{min}}$, der Punkt mit dem geringsten Abstand zum Ursprung $P_{r_{min}}$ sowie der Punkt mit dem größten Ablagewinkel $P_{\phi_{max}}$ in einem Segment bestimmt. Danach werden die zwei Strecken $\overline{P_{\phi_{min}}P_{r_{min}}}$ und $\overline{P_{r_{min}}P_{\phi_{max}}}$ berechnet. Die längere der beiden Strecken wird zur Bestimmung des Orientierungswinkels herangezogen. Seien P_1 und P_2 die zugehörigen Endpunkte, dann errechnet sich der Betrag des Winkels über

$$|\psi_{3pt}| = \arctan \frac{|y_1 - y_2|}{|x_1 - x_2|} \quad (3.7)$$

Das Vorzeichen wird als Steigung der Geraden über P_1 und P_2 gewählt.

Mittels der Hauptkomponentenanalyse erhält man die Achse, auf der die Punkte eines Segmentes maximale Streuung haben. Diese Achse kann man als Hauptausrichtung der Punktmenge interpretieren. Für alle I-förmigen Segmente, das heißt für in etwa linienartig angeordnete Punktmengen, ist diese Annäherung sehr gut. Auch für die meisten L-förmigen Segmente liefert die Hauptkomponentenanalyse gute Ergebnisse. Lediglich bei L-förmigen Segmenten, bei denen beide Schenkel in etwa gleich lang sind, entspricht die Achse mit der höchsten Varianz nicht mehr der Ausrichtung des realen Objekts. Der Orientierungswinkel ψ_{pca} wird über den Eigenvektor e_1 mit Hilfe des Arcustangens wie in Formel 3.8 angegeben bestimmt.

$$\psi_{pca} = \arctan \left(\frac{y_{e_1}}{x_{e_1}} \right) \cdot \frac{180^\circ}{\pi} \quad (3.8)$$

Nach der Linieneinpassung liegen entweder keine, eine oder zwei Linien vor. Wenn keine Linie eingepasst wird, also ein punktförmiges Segment vorliegt, wird der Orientierungswinkel als 0° definiert. Erhält man genau eine Linie, so berechnet sich der Orientierungswinkel ψ_{line} aus der Steigung der Linie. Erhält man zwei Linien, so entspricht der Orientierungswinkel per Definition der Steigung der längeren Linie.

3.2.2 Referenzpunkte

Um Positionsangaben für ausgedehnte Objekte machen zu können, muss vereinbart werden, worauf sich diese beziehen, beispielsweise auf einen Referenzpunkt, der das Objekt repräsentiert. Anhand ihres Referenzpunktes werden Segmente in jedem Zeitschritt den ihnen zugehörigen Objekten zugeordnet, was ihre räumlich-zeitliche Verfolgung ermöglicht. Der Referenzpunkt ist ein aus den einzelnen Datenpunkten innerhalb eines Segmentes bzw. aus bereits berechneten Merkmalen extrahierter virtueller Messpunkt, der die Bewegung des zugrundeliegenden Objektes nachvollzieht. Gleichzeitig sollte er stabil gegenüber Scheinbewegungen sein, die aus schwankenden Segmentausdehnungen oder allgemein aus verrauschten Rohdaten resultieren. Das Finden geeigneter, stabiler Referenzpunkte stellt eine Herausforderung dar, da Laserscannersegmente bedingt durch Perspektivenwechsel, Verdeckungen sowie durch physikalische Effekte verursacht fehlende Messpunkte ihre Form und Größe ändern und somit zu verfälschten Geschwindigkeitsschätzungen führen können. Abbildung 3.10 illustriert diesen Effekt am Beispiel des Segmentenschwerpunktes bei einem querenden Fahrzeug. Abhängig vom

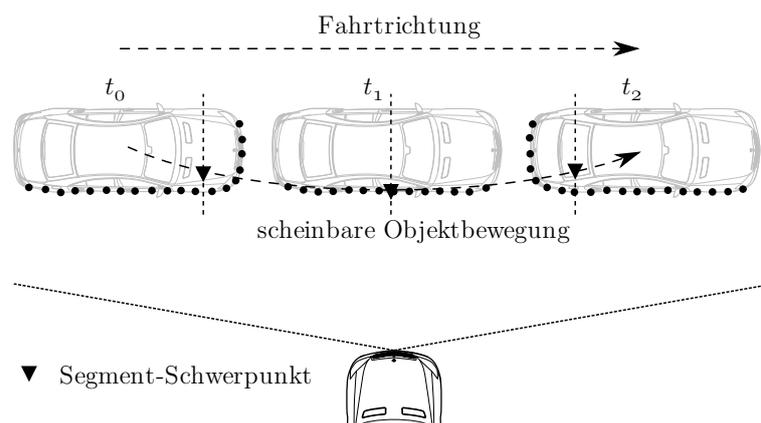


Abbildung 3.10: Verschiebung des Schwerpunktes bei unterschiedlichen Betrachtungswinkeln

Betrachtungswinkel werden jeweils Front und Seite, nur die zugewandte Längsseite oder Heck und Seite des Fahrzeugs vom Laserscanner erfasst. Der Schwerpunkt der Messpunkte bewegt sich in x-Richtung zuerst auf den Laserscanner zu und entfernt sich dann wieder. Das reale Objekt jedoch bewegt sich geradlinig von links nach rechts. Zudem befindet sich der Schwerpunkt zuerst im Frontbereich des realen Objektes und wandert von dort aus über die Fahrzeugmitte bis zum Heck. Das bedeutet, dass das Objekt sich in y-Richtung scheinbar langsamer bewegt, als es das tatsächlich tut.

Im Folgenden werden verschiedene Referenzpunktkandidaten beschrieben und diskutiert. Der Schwerpunkt, der aus allen Messpunkten innerhalb eines Segmentes gebildet wird, wurde bereits oben angesprochen. Sein Vorteil liegt in der einfachen Berechnung, zudem ist er robust gegen vereinzelte Ausreißer in den Messpunkten. Der Schwerpunkt unterliegt jedoch den oben beschriebenen Schwankungen bei Perspektivenwechsel. Die Berechnung erfolgt gemäß For-

mel 3.9, wobei N die Anzahl der Punkte in einem Segment bezeichnet.

$$p_{cog} = \frac{1}{N} \sum_{i=1}^N p_i(x, y) \quad (3.9)$$

Der Mittelpunkt der Segmentbox ist ebenfalls als Referenzpunkt denkbar. Er unterliegt jedoch ebenso den geometrischen Einflüssen des Messverfahrens. Vorteilhaft ist, dass die Lage des Mittelpunktes mit der Lage der Eckpunkte des Segmentes in Beziehung steht. Für den Schwerpunkt muss die Lage relativ zur Segmentbox separat bestimmt werden.

Die Problematik des Referenzpunktes wurde bereits in einigen Arbeiten aufgegriffen [Sku06] [FLD03] [SFS⁺03]. Santos et al. [SFS⁺03] schlagen einen virtuellen Referenzpunkt vor, der aus dem Punkt mit dem geringsten Abstand zum Scanner und dem Median der Ablagewinkel konstruiert wird. Sei P die Menge aller Punkte eines Segmentes in Polarkoordinaten, sei p_{\min} der Punkt mit minimalem Abstand zum Ursprung und p_{med} der Punkt mit medianem Winkel.

$$p_{\min} = (r_{\min}, \phi_{\min}) := \min_P(r) \quad (3.10)$$

$$p_{\text{med}} = (r_{\text{med}}, \phi_{\text{med}}) := \text{median}_P(\phi) \quad (3.11)$$

Dann wird der Referenzpunkt p_{ref} entsprechend Formel 3.12 definiert.

$$p_{\text{ref}} = (r_{\min} \cdot \cos(\phi_{\min}), r_{\text{med}} \cdot \sin(\phi_{\text{med}})) \quad (3.12)$$

Angewandt auf das in Abbildung 3.10 gezeigte Beispiel der Querfahrt liefert p_{ref} tatsächliche robustere Ergebnisse. Nachteile ergeben sich jedoch, wenn das beobachtete Fahrzeug seine Orientierung ändert, beispielsweise abbiegt. Der Referenzpunkt zeigt dann große Abweichungen, wie Abbildung 3.11 aufzeigt.

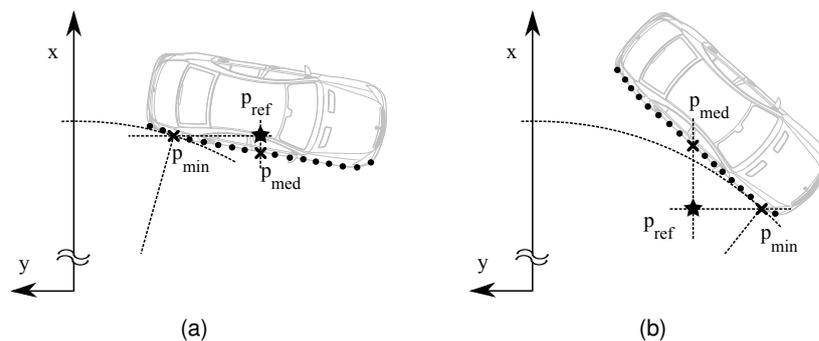


Abbildung 3.11: Zwei Beispiele für den virtuellen Referenzpunkt nach Santos et al. [SFS⁺03]

Wie aus der Diskussion hervorgeht, gibt es keinen einzelnen Referenzpunkt, der sich optimal in allen Situationen verhält. Eine Möglichkeit, dieses Problem zu adressieren, besteht in der Verwendung mehrerer Referenzpunkte. Kandidaten hierfür sind die End- und Schnittpunkte

der in die Punkte eingepassten Linien. Diese verhalten sich phasenweise stabil, solange die gleiche Anzahl an Linien sichtbar ist und keine Verdeckungen auftreten. Für die Übergänge braucht es Modelle, die szenarioabhängig den Referenzpunkt auf die jeweils geeignete Ecke umrechnen.

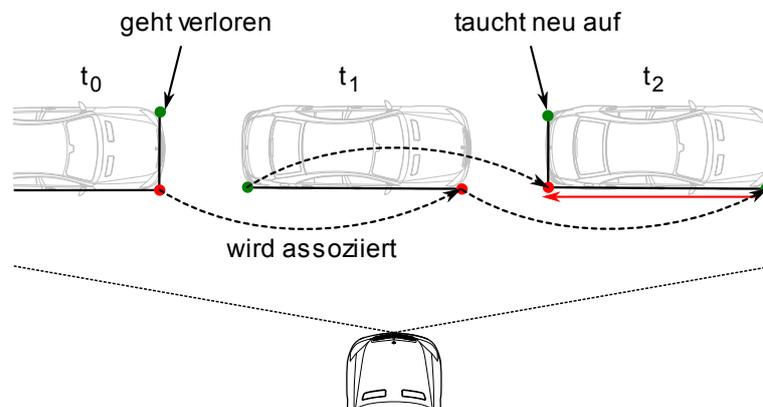


Abbildung 3.12: Szenarioabhängige Verlagerung des Referenzpunktes

Abbildung 3.12 zeigt ein Beispiel. Im Zeitschritt t_0 wurde der rot gekennzeichnete Schnittpunkt zweier Geraden als robuster Referenzpunkt ausgewählt. Er bezeichnet die rechte vordere Ecke des betrachteten Fahrzeugs. Im nächsten Zeitschritt t_1 wird diese Fahrzeugecke durch einen der Linienendpunkte repräsentiert. Als neuer Referenzpunktkandidat kommt die rechte hintere Fahrzeugecke hinzu. Im Zeitschritt t_2 gibt es erneut einen Schnittpunkt zwischen Geraden. Bewertet man diesen als robusteren Kandidaten als die Linienendpunkte, muss eine Kompensation erfolgen, hier dargestellt durch den roten Pfeil.

3.2.3 Szenenrelevante Merkmale

Die von einem Laserscanner erfassten Punkte sind von der Perspektive des Sensors abhängig. Das bedeutet insbesondere, dass Objekte im Hintergrund von im Vordergrund befindlichen Objekten ganz oder teilweise verdeckt werden können und dadurch nicht vollständig in den Rohdaten sichtbar werden. Diese Fluktuation wirkt sich auf die Stabilität der Referenzpunkte aus, die in die Rohdaten eingepasst werden. Wird nur ein Referenzpunkt, zum Beispiel der Schwerpunkt des Segmentes verwendet, ist der resultierende Effekt, dass der Schwerpunkt innerhalb des Segmentes wandert. Bei eingepassten Eckpunkten entsteht die Illusion, dass einzelne Eckpunkte still zu stehen scheinen oder sich viel zu schnell bewegen. Dem kann dadurch begegnet werden, dass man Punkte, die sich am Rand von Verdeckungen befinden, explizit als solche kennzeichnet und für die Assoziation nicht weiter beachtet ähnlich wie in [Mac05] vorgeschlagen. Abbildung 3.13 zeigt eine komplette Szene mit markierten Referenzpunkten.

Referenzpunkte, die auf dem Rand des Sichtbereiches liegen, sind ebenfalls unzuverlässig. Aus den Rohdaten geht nicht hervor, ob ein Objekt dort tatsächlich zu Ende ist oder lediglich nicht ganz eingesehen werden kann. Das resultiert darin, dass Eckpunkte am Rand des

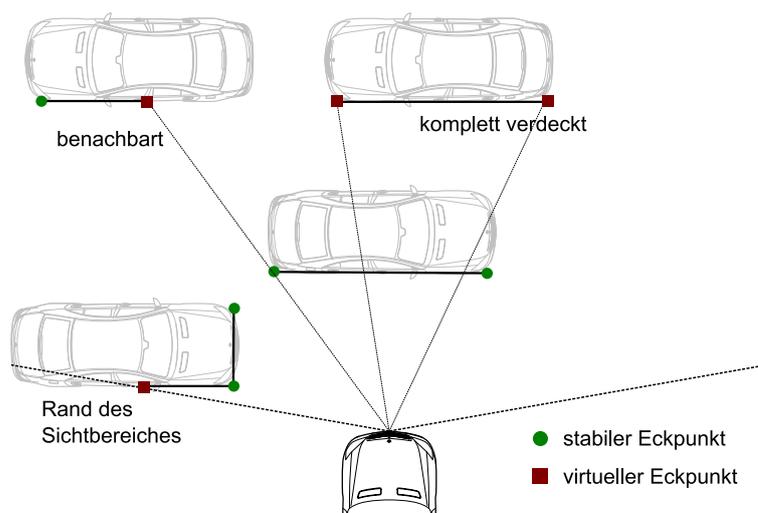


Abbildung 3.13: Verdeckung und daraus resultierende unzuverlässige Referenzpunkte

Sichtbereiches stehen zu bleiben scheinen, obwohl sich das dazugehörige Objekt bewegt. Referenzpunkte am Rand des Sichtbereiches werden daher ebenfalls markiert.

3.2.4 Klassifikation

Die Klassifikation auf Segment- bzw. Merkmalsebene dient vor allem dazu, unerwünschte Objekte frühzeitig auszufiltern und sie somit der Tracking-Stufe zu entziehen. Dies spart zum einen Rechenzeit und erhöht zum anderen die Robustheit, da weniger unrelevante Objekte entstehen und somit das Problem fehlerhafter Assoziation reduziert wird. Unrelevante Objekte entstehen, wenn der Laserscanner Messpunkte liefert, die von nicht kompakten Objekten wie Gras, Buschwerk etc. stammen. Anders als bei anderen Verkehrsteilnehmern oder Gebäuden erwartet man in diesem Fall eine eher zufällige Verteilung der Messpunkte innerhalb eines Segments. Die Klassifikation von Segmenten ist ebenfalls notwendig, um eine Vorauswahl von Objekten zu treffen, die potentiell Fahrzeuge darstellen, da die modellbasierte Fusion mit Fahrzeugmodellen arbeitet. Anhand der Größe und Punktverteilung im Segment werden drei Klassen strukturierter Objekte unterschieden: *L-förmig*, *I-förmig* und *punktförmig* (siehe Abbildung 3.14). Eine vierte Klasse *Unbestimmt* wird für alle anderen Objekte verwendet.

Aus der Literatur sind Ansätze bekannt, die direkt nach Objekten wie Personen oder Fahrzeugen klassifizieren. Premebida et. al. [PLN09] detektieren Fußgänger ausschließlich basierend auf Laserscannerdaten. Dazu werden verschiedene Merkmale aus von Hand segmentierten Laserscans extrahiert, hinsichtlich ihrer Relevanz für die Klassifikationsaufgabe bewertet und zum Training von Klassifikatoren verwendet. Die Veröffentlichung vergleicht die Leistungsfähigkeit unterschiedlicher Klassifikationsmethoden (Bayes-Klassifikator, Gaussian Mixture Models, Neuronale Netze, Support Vector Machines) bezogen auf die Erkennung von Fußgängern. Zhao et al. [ZZC⁺09] benutzen aus Segmenten extrahierte Merkmale in Kombination mit Bewegungsinformationen, um bewegte Objekte als Person, Gruppe, Fahrrad oder Fahrzeug

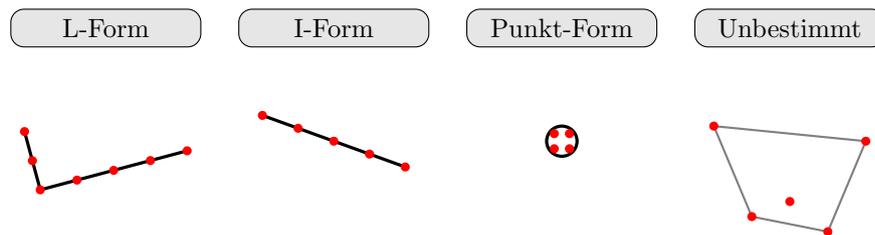


Abbildung 3.14: Segmentklassen

zu klassifizieren. Thoma [Tho05] verwendet die durch Fourieranalyse gefundene Pendelbewegung der Beine in Laserscannerdaten als Merkmal, um Fußgänger zu klassifizieren, und fusioniert diese mit Merkmalen aus Ferninfrarotbildern.

Im Folgenden bezeichnet *Instanz* ein Segment in der Ausprägung einer der definierten Klassen. Als Klassifikationsverfahren wurden Entscheidungsbäume gewählt, da diese effizient zu implementieren sind. Bei einem Entscheidungsbaum handelt es sich um ein statisches Klassifikationsverfahren. Der Baum wird anfangs einmal „gelernt“ und kann anschließend effizient genutzt werden, da in der Regel wenige Fallunterscheidungen ausreichen, um eine Instanz zu klassifizieren. In dieser Arbeit wurde der von J. Ross Quinlan entwickelte C4.5-Algorithmus verwendet, um den Entscheidungsbaum zu erzeugen [Qui93]. Dieser arbeitet nach dem Prinzip des höchsten Informationsgewinns, um die Menge der Instanzen rekursiv in Teilmengen aufzuspalten, bis sie einer konkreten Klasse zugeordnet werden können. Instanzen werden anhand ihrer Merkmale unterschieden. Zur Entscheidungsfindung soll das Merkmal ermittelt werden, welches den maximalen Informationsgewinn verspricht. Dazu betrachtet man die Entropie, also die Unordnung, der Instanzen in einem Knoten. Maximaler Informationsgewinn liegt vor, wenn die Differenz der Entropien nach einer Aufteilung der Instanzen maximal ist.

Die Entropie E einer Menge S von Instanzen bei C möglichen Klassen ist definiert durch Formel 3.13. Dabei sei S_c/S das Verhältnis der Instanzen mit Klassifikation c zu der Gesamtzahl der Instanzen.

$$E(S) = \sum_{i=1}^C -\frac{S_c}{S} \log_2 \frac{S_c}{S} \quad (3.13)$$

Der Informationsgewinn IG ist wie in Formel 3.14 definiert, wobei $IG(A)$ den Informationsgewinn durch das Merkmal A angibt.

$$IG(A) = E(S) - \sum_{v \in \text{Werte}(A)} \frac{|S_v|}{|S|} E(S_v) \quad (3.14)$$

Die Auswahl der für die Klassifikation aussagefähigsten Attribute wird also durch das Verfahren inhärent getroffen. Um eine Überanpassung an die für die Erstellung des Entscheidungsbaukes benutzten Trainingsdaten zu verhindern, kann eine minimale Menge von Instanzen pro Kindknoten vorgegeben und damit die Rekursionstiefe beschränkt werden. Tabelle 3.2 listet die Attribute auf, die als Eingabe für den Klassifikator benutzt werden. Die Merkmale sind in Anhang B einzeln erläutert.

Tabelle 3.2: Merkmale für die Klassifikation

Merkmal	Bezeichnung
Winkel des Schwerpunktes	ϕ_{cog}
Länge	$length$
Breite	$width$
Höhe	$height$
Anzahl Punkte	n
Orientierungswinkel über Drei-Punkt-Methode	ψ_{3PT}
Orientierungswinkel über Hauptkomponentenanalyse	ψ_{PCA}
Länge der Konturlinie	CL
Umfang der konvexen Hülle	U_{CH}
Umfang der Bounding Box	U_{BB}
Fläche der konvexen Hülle	A_{CH}
Fläche der Bounding Box	A_{BB}
Dichte über konvexe Hülle	ρ_{CH}
Dichte über Bounding Box	ρ_{BB}
Seitenverhältnis	$aspectratio$
Kompaktheit über konvexe Hülle	$compactness_{CH}$
Kompaktheit über Konturlinie	$compactness_{CL}$
Konvexität	$convexity$

3.2.5 Bewertung

In diesem Kapitel werden Betrachtungen zur Performance bei unterschiedlichen Alternativen zur Bestimmung von Merkmalen getroffen sowie die Klassifikation von Segmenten bewertet.

Merkmalsextraktion

Zur Bewertung der Merkmalsextraktion wurden die Daten verschiedener Fahrscenarien aufgenommen. Um die Evaluierung auf die Verfahren der Merkmalsextraktion zu konzentrieren, wurden von Hand ideale Segmentierparameter gewählt. Das erste Szenario ist ein im Abstand von 5 Metern querendes Fahrzeug. Das zweite Szenario ist eine Kreisfahrt mit Radius 20 m um das Sensorfahrzeug. Im dritten Szenario fährt ein Fahrzeug parallel zum Sensorfahrzeug im Abstand von 6,3 m vorbei. Das Sensorfahrzeug steht jeweils still. Die Ergebnisse der unterschiedlichen Alternativen für die Bestimmung des Orientierungswinkels sind in Abbildung 3.15 aufgezeigt. Die durchgezogene Linie stellt den tatsächlichen Wert dar. Mit einem roten Pluszeichen gekennzeichnet sind die Werte für die Winkelbestimmung über die Hauptkomponentenanalyse, mit der blauen Raute sind die Werte für die Winkelbestimmung über die Drei-Punkte-Methode dargestellt, die grünen Kreuze stehen für die Winkelbestimmung aus eingepassten Linien. Im ersten Szenario (Querfahrt) ist zunächst nur die Front sichtbar, der erwartete Orientierungswinkel ist 0. Fährt das Fahrzeug weiter in den Sichtbereich ein, wird die Längsseite

erfasst, der Orientierungswinkel ist dann 90. Umgekehrt verhält es sich beim Verlassen des Sichtbereichs. Die Winkelbestimmung aus eingepassten Linien liefert im Bereich vollständiger Sichtbarkeit (Zeitschritte 80 bis 180) die besten Ergebnisse. Beim Verlassen des Sichtbereichs liefern alle Methoden aufgrund verrauschter Rohdaten fehlerhafte Ergebnisse. Im zweiten Szenario (Kreisfahrt) tritt das Fahrzeug von rechts in den Sichtbereich ein. Der Orientierungswinkel steigt kontinuierlich von 0 auf 90, erfährt laut Definition einen Sprung auf -90 und steigt dann wieder auf 0 an. Die Methode der Winkelbestimmung aus eingepassten Linien wie auch die Bestimmung über die Hauptkomponentenanalyse sind in der Lage, dem Verlauf gut zu folgen. Die Drei-Punkte-Methode liefert zuweilen größere Fehler. Im dritten Szenario (Parallelfahrt) liefert die Winkelbestimmung aus eingepassten Linien bis zum Zeitschritt 180 sehr gute Ergebnisse. Danach wird nur noch die Rückfront erkannt, und die Rohdaten sind stärker verrauscht. Insgesamt lässt sich sagen, dass die Winkelbestimmung aus eingepassten Linien die besten Ergebnisse über alle Szenarien liefert. Die Bestimmung über die Drei-Punkte-Methode erzeugt große Abweichungen selbst bei optimaler Segmentierung.

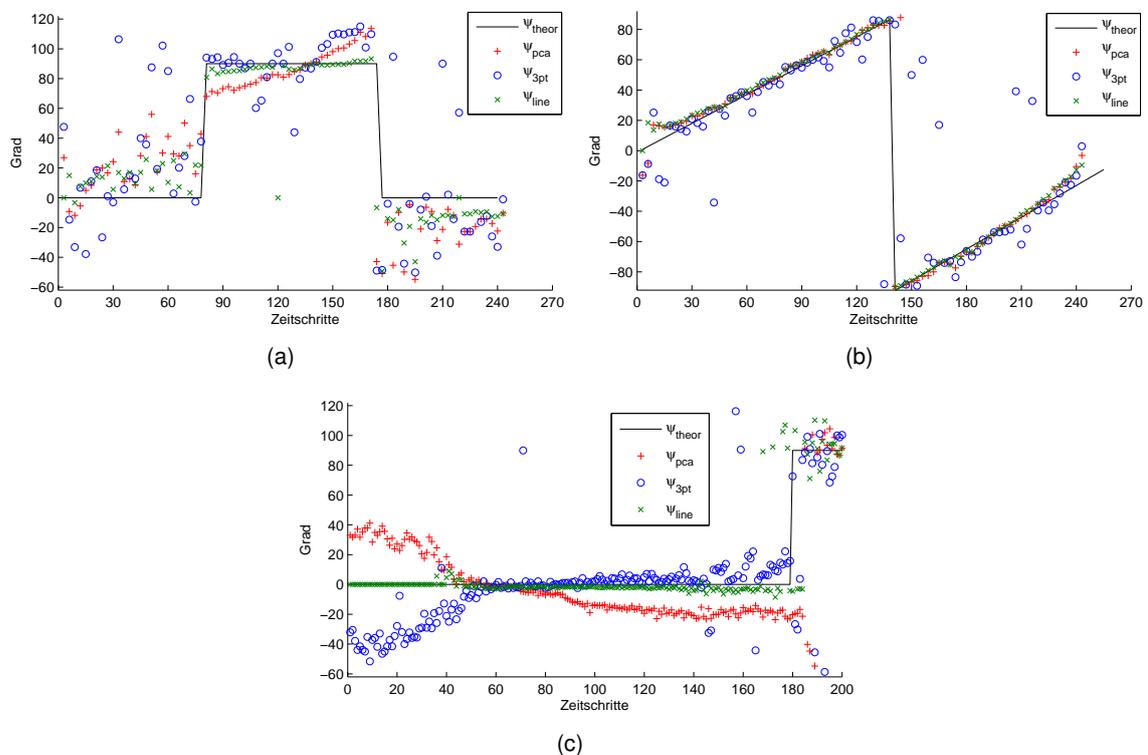


Abbildung 3.15: Vergleich der Alternativen zur Berechnung des Orientierungswinkels in unterschiedlichen Szenarien: (a) querendes Fahrzeug, (b) Kreisfahrt, (c) Parallelvorbeifahrt

Klassifikation

Der Entscheidungsbaum wurde mit vorklassifizierten Test- und Trainingsdaten trainiert. Dazu wurden die Laserscannerdaten unterschiedlicher Szenen aus Stadt-, Überland- und Autobahn-

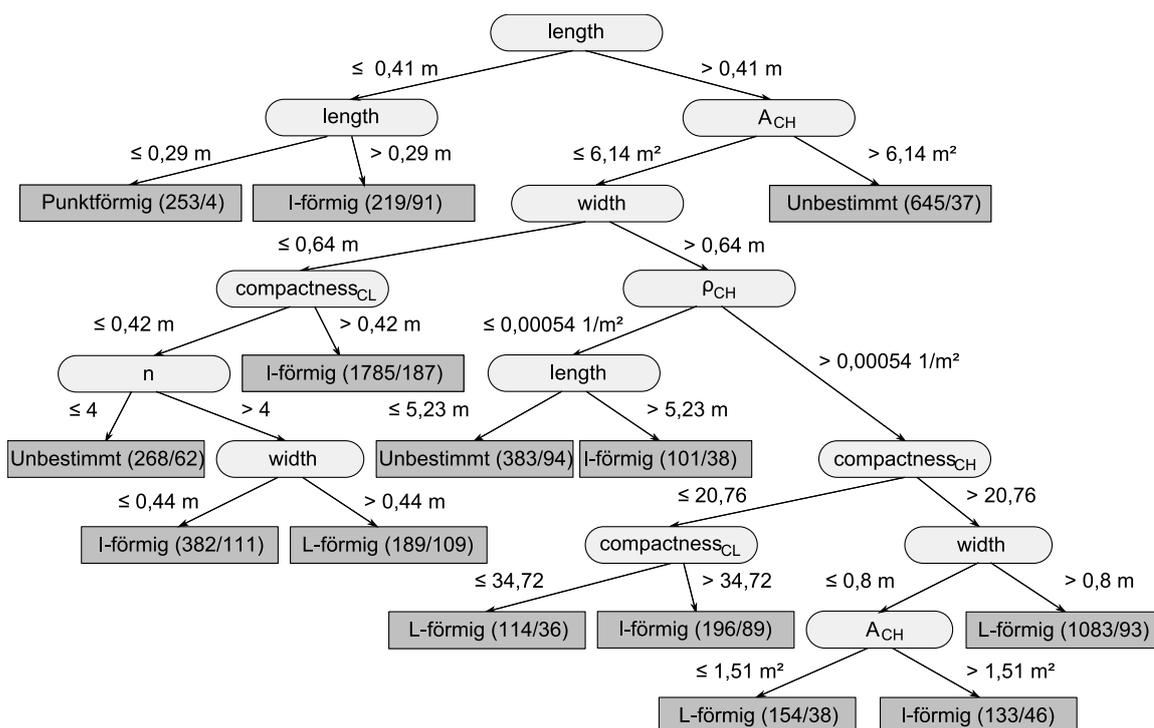


Abbildung 3.16: Entscheidungsbaum zur Klassifikation von Segmenten

fahrten mit dem Versuchsträger aufgezeichnet. Aus den aufgezeichneten Daten wurden 5802 Segmente extrahiert und manuell gelabelt, das heißt, zu den in Abschnitt 3.2.4 definierten Klassen zugeordnet. Der Vorhersagefehler des Klassifikators wurde mittels zehnfacher Kreuzvalidierung bestimmt [HTF09, S. 241].

Abbildung 3.16 zeigt den Entscheidungsbaum, der aus den angegebenen Daten erstellt wurde. Die Knoten enthalten jeweils das Attribut, das zur Entscheidung herangezogen wird, die Pfade sind mit dem entsprechenden Schwellwert für das Attribut versehen. Die Blätter zeigen die Klasse an, in die die jeweilige Instanz sortiert wird. Die Werte in den Klammern geben an, wieviele Instanzen in diesem Blatt terminierten und wieviele dabei der falschen Klasse zugeordnet wurden.

Die Wirksamkeit eines Klassifikators besagt, wieviele Instanzen der richtigen Klasse zugeordnet wurden. Die Werte zu ihrer Ermittlung können der Konfusionsmatrix entnommen werden. Diese enthält die Häufigkeiten in der Testmenge für alle Kombinationen der vom Klassifikator ermittelten Klasse und des wahren Wertes. Bei einer zu groß festgelegten Mindestanzahl an Instanzen pro Blatt ist eine schlechte Wirksamkeit des Entscheidungsbaumes zu erwarten, da eine feine Differenzierung anhand mehrerer Merkmale nicht möglich ist. Bei einer zu geringen Anzahl an Instanzen besteht die Gefahr, dass der Entscheidungsbaum überangepasst ist auf die Trainingsdatenmenge. Deshalb wurde die Mindestanzahl an Instanzen pro Blattknoten kontinuierlich erhöht und dabei die resultierende Wirksamkeit und die Konfusionsmatrix beobachtet. Der Wert, bei dem die Konfusionsmatrix nach einer zehnfachen Kreuzvalidierung noch

das beste Ergebnis lieferte, bevor durch eine Überanpassung eine ungerechtfertigt hohe Wirksamkeit einsetzte, lag bei 100 Instanzen. Die Wirksamkeit des Klassifikators liegt bei 81,7 %, das heißt 81,7 % aller Segmente wurden der richtigen Klasse zugeordnet.

Tabelle 3.3 zeigt die Genauigkeit des Entscheidungsbaumes, aufgeschlüsselt nach Klassen. Aus der Tabelle lässt sich entnehmen, dass das Klassifikationsverfahren punktförmige Segmente gut von den anderen Segmenten trennt. Entscheidend ist hier nicht die Rate der *korrekt positiv* Instanzen, die aussagt, wie viele punktförmige Segmente als solche erkannt werden, sondern die *falsch positiv*-Rate. Diese sagt aus, wieviele der anderen Segmente als punktförmig klassifiziert werden. Da für punktförmige Segmente eine vereinfachte Bearbeitung genügen soll, ist es wichtig, dass keine I- oder L-förmigen Segmente fälschlicherweise als punktförmig klassifiziert werden. Dies ist bei einer Rate von 0,1 % gegeben, diese kann auch aus Ungenauigkeiten beim Labeln von Hand resultieren.

Ein differenzierteres Bild ergibt sich für die Klassen I-förmig und L-förmig. Zwar liegen die *richtig positiv*-Raten mit 90,3 % und 81,0 % relativ hoch, gleichzeitig sind jedoch auch die *falsch positiv*-Raten hoch. Problematisch sind hier die falsch klassifizierten Instanzen, die eigentlich der Klasse Unbestimmt angehören. Auf diese würden im weiteren Verlauf der Verarbeitung fälschlicherweise Fahrzeugmodelle angewandt werden, was zu Schätzfehlern führen kann. Umgekehrt können auch die unbestimmten Segmente nicht ausgefiltert werden, da 4,4 % strukturierter Segmente ansonsten nicht weiterverarbeitet würden.

Tabelle 3.3: Güte des Entscheidungsbaumes, aufgeschlüsselt nach Klasse

Klasse	richtig positiv	falsch positiv
Punktförmig	75,7%	0,1%
I-förmig	90,3%	17,5%
L-förmig	81,0%	6,6%
Unbestimmt	69,4%	4,4%

Tabelle 3.4 zeigt die Konfusionsmatrix mit den absoluten Häufigkeiten, die der Gütebewertung in Tabelle 3.3 zugrunde liegen.

Wie aus der Auswertung hervorgeht, ist die Trennung in I-förmige/L-förmige Segmente und Segmente unbestimmter Form anhand der hier verwendeten Merkmale zu unscharf, um als Filter für die nächste Verarbeitungsstufe zu dienen. Daher ist es sinnvoll, eine Klassifikation

Tabelle 3.4: Konfusionsmatrix nach zehnfacher Kreuzvalidierung

Klasse	klassifiziert als			
	Punktförmig	I-förmig	L-förmig	Unbestimmt
Punktförmig	246	75	0	4
I-förmig	4	2220	153	81
L-förmig	0	186	1242	105
Unbestimmt	0	324	130	1032

im späteren Verlauf der Verarbeitung in Verbindung mit Bewegungsparametern vorzunehmen. Dieses Thema wird in Kapitel 4.3.4 nochmals aufgegriffen.

4 Objektverfolgung für ausgedehnte Ziele

4.1 Grundlagen

Aufgabe von Algorithmen zur Objektverfolgung ist es, aus den von der bordinternen Sensorik gelieferten Messdaten zu diskreten Zeitpunkten auf die Position, Bewegungszustände und Trajektorien von Objekten im Umfeld zu schließen. Rudolf E. Kalman veröffentlichte 1960 ein Verfahren zur dynamischen Zustandsschätzung [Kal60], das nach ihm als Kalman-Filter benannt wurde und bis heute - mit verschiedenen Abwandlungen und Anpassungen - als ein Standardverfahren zur Zustandsschätzung bewegter Objekte angesehen werden kann.

In der ursprünglichen Veröffentlichung wird der lineare Kalman-Filter beschrieben, das bedeutet, sowohl die Zustandsübergänge als auch die Abbildungen vom Zustands- in den Messraum sind linear. Für diesen Fall stellt der Kalman-Filter den optimalen Schätzer dar, vorausgesetzt die Prozess- und Messfehler lassen sich durch weißes, mittelwertfreies Rauschen beschreiben. Betrachtet man die Realität, so kommen hier oft Nichtlinearitäten vor, beispielsweise bei der Zustandsmodellierung in kartesischen Koordinaten mit gleichlaufender Messung in polaren Koordinaten oder bei nichtlinearen Bewegungsmustern, die gerade im Kreuzungs- und Innenstadtbereich häufig auftreten (Abbiegen, Wenden, etc.). In diesen Fällen kann der erweiterte Kalman-Filter benutzt werden.

Auf theoretische Betrachtungen zum Kalman-Filter soll an dieser Stelle nur insoweit eingegangen werden, wie es zum Verständnis der in dieser Arbeit vorgestellten Verfahren notwendig ist. Für eine tiefgreifende Beschäftigung mit dem Thema sei auf [LJ00, LJ01a, LJ01b, LJ02, LJ04, LJ05, May82, Rib04, WB01] verwiesen.

Ein Filterzyklus besteht aus Prädiktion und Update, diese werden in jedem Zeitschritt iterativ ausgeführt. Im Prädiktionsschritt wird aus dem Zustand \mathbf{x}_{k-1} zum Zeitpunkt $k-1$ mithilfe des hinterlegten Bewegungsmodells der neue Zustand $\hat{\mathbf{x}}_k$ zum aktuellen Zeitpunkt k berechnet sowie dessen Kovarianz prädiziert.

$$\hat{\mathbf{x}}_k = \mathbf{F}\mathbf{x}_{k-1} \quad (4.1)$$

$$\hat{\mathbf{P}}_k = \mathbf{F}\mathbf{P}_{k-1}\mathbf{F}^T + \mathbf{Q} \quad (4.2)$$

\mathbf{F} bezeichnet die diskrete Zustandsübergangsmatrix, \mathbf{P}_{k-1} und $\hat{\mathbf{P}}_k$ beinhalten die Prozessfehlerkovarianzmatrizen vor und nach der Prädiktion, \mathbf{Q} bildet den Modellfehler ab, der als Rauschterm in jedem Prädiktionsschritt addiert wird.

In der Innovationsphase werden der prädizierte Zustand und seine Kovarianzmatrix mit der

aktuellen Messung z_k korrigiert.

$$\mathbf{x}_k = \hat{\mathbf{x}}_k + \mathbf{K}(z_k - \mathbf{H}\hat{\mathbf{x}}_k) \quad (4.3)$$

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}\mathbf{H})\hat{\mathbf{P}}_k \quad (4.4)$$

\mathbf{I} bezeichnet die Einheitsmatrix, \mathbf{H} bildet die Zusammenhänge zwischen Mess- und Zustandsgrößen ab und \mathbf{K} ist der sogenannte Kalman-Gain, der wie folgt berechnet wird.

$$\mathbf{K} = \hat{\mathbf{P}}_k \mathbf{H}^T (\mathbf{H}\hat{\mathbf{P}}_k \mathbf{H}^T + \mathbf{R})^{-1} \quad (4.5)$$

Über den Kalman-Gain erfolgt die Gewichtung zwischen Prädiktion und Messung anhand der erwarteten Fehler, die als Messfehlerkovarianzmatrix \mathbf{R} direkt in Gleichung 4.5 bzw. als Modellfehlerkovarianzmatrix \mathbf{Q} über die Prädiktion des Prozessfehlers (Gleichung 4.2) eingehen. Gemäß den Voraussetzungen für den Kalman-Filter werden sowohl Mess- als auch Prozessrauschen als gegenseitig unkorreliertes, normalverteiltes, mittelwertfreies weißes Rauschen angenommen.

Um den Kalman-Filter auch auf nichtlineare Probleme anwenden zu können wurde mit dem Extended Kalman Filter (EKF) eine Erweiterung geschaffen. Der EKF basiert auf der Linearisierung der Mess- bzw. Zustandsgleichungen durch eine Entwicklung in eine Taylorreihe um den letzten Schätzwert. Üblicherweise wird die Reihenentwicklung nach dem ersten Glied abgebrochen, und man erhält ein linearisiertes System. Es gelten weiterhin die Gleichungen 4.1 und 4.2 für den Prädiktionsschritt sowie die Gleichungen 4.3 und 4.4 für den Innovationsschritt, anstelle der Zustandsübergangsmatrix \mathbf{F} und der Messmatrix \mathbf{H} werden die Jacobi-Matrizen \mathbf{F}_J und \mathbf{H}_J benutzt.

$$\mathbf{F}_J = \left. \frac{\partial f}{\partial \mathbf{x}} \right|_{\mathbf{x}=\mathbf{x}_{k-1}} \quad (4.6)$$

$$\mathbf{H}_J = \left. \frac{\partial h}{\partial \mathbf{x}} \right|_{\mathbf{x}=\hat{\mathbf{x}}_k} \quad (4.7)$$

Hierin stehen f und h für die jeweiligen Zustandsübergangs- und Messgleichungen.

Für die Anwendung des Kalman-Filters so wie hier beschrieben, muß zunächst von der Verfolgung eines Einzelziels ausgegangen werden. Bei automotiven Anwendungen befinden sich jedoch mehrere Objekte im Sensierungsbereich, die gleichzeitig verfolgt werden sollen. Es stellt sich daher das Problem der Datenassoziation, d. h. der Zuordnung von Messungen zu bereits vorhandenen Tracks. Die Zuordnung findet nach dem Prädiktionsschritt statt. Es gibt Verfahren, die Messungen zu Tracks fest zuordnen sowie probabilistische Verfahren, bei der Messungen mit einer bestimmten Wahrscheinlichkeit zu einem Track gehören. Auf die Datenassoziation wird in Kapitel 4.3.2 eingegangen.

4.1.1 Stationäre und instationäre Prozesse

Eine der Voraussetzungen für den Kalman-Filter ist die, dass es sich bei dem Schätzproblem um einen stationären Prozess handelt, das ist gleichbedeutend damit, dass sich die durch \mathbf{R} und \mathbf{Q} beschriebenen Mess- und Modellfehler während des Schätzvorgangs nicht ändern. Sie werden bei der Filterinitialisierung einmalig belegt und bleiben dann erhalten. In der Praxis kann es, gerade bei längerer Betrachtung, durchaus vorkommen, dass sich diese Größen ändern und der Prozess somit instationär wird. Dies kann sowohl für den Messprozess als auch für den Zustandsübergang zutreffen.

Bei Sensoren kann es beispielsweise vorkommen, dass sich durch Änderungen der Umgebungstemperatur oder Alterung das Messrauschen erhöht. Aber auch abhängig vom Szenario kann das Messrauschen differieren, beispielsweise in Abhängigkeit von der Distanz, in der ein Objekt detektiert wird oder wie nahe es sich an der Sichtbereichsgrenze befindet.

Für den Bewegungsprozess des Objekts werden bestimmte Annahmen getroffen, beispielsweise, dass es sich mit annähernd konstanter Geschwindigkeit in Richtung seiner Längsachse weiterbewegt. Diese Annahme ist sicherlich für einen Großteil von Objekten im Verkehrsgeschehen die meiste Zeit über gültig. Abweichungen dieser Annahme werden im Prozessrauschen mit beachtet, sodass auch bei leichtem Abbremsen oder Beschleunigen das Objekt nicht verloren wird, sondern mit ausreichender Genauigkeit weiter verfolgt werden kann. Nun kommt es aber vor, dass von der Modellannahme stärker abgewichen wird, etwa durch starkes Beschleunigen, starkes Bremsen oder Abbiegen. Der Prozess ist instationär, man spricht hier von einem Manöver. Theoretisch können auch diese Abweichungen vom Modell im Rauschen erfasst werden, jedoch müsste man dann das Prozessrauschen sehr groß wählen, was unter Umständen zu ungenauen Schätzungen und Konsistenzproblemen im Tracker führt. In den Kapiteln 4.1.2 und 4.1.3 werden mit dem adaptiven Kalman-Filter und dem Interacting Multiple Model Filter zwei Verfahren benannt, die den Umgang mit Manövern unter Verwendung des Kalman-Filters auf bessere Weise lösen.

4.1.2 Adaptiver Kalman-Filter (AKF)

Der Kalman-Filter ist der optimale Filter für lineare dynamische Systeme, falls die vollständige a priori Information des Prozess- und Messrauschens bekannt ist. In der Praxis können beide Rauschanteile instationär sein. Für einen Sensor könnte sich das Rauschen beispielsweise in Abhängigkeit von Umweltbedingungen mit der Zeit vergrößern oder verringern. Im Prozessrauschen werden alle Abweichungen vom hinterlegten Bewegungsmodell als allgemeines Rauschen erfasst. Sollen starke Dynamikschwankungen verfolgt werden können, muss das Modellrauschen von vornherein entsprechend groß gewählt werden, was unter Umständen eine Unterschätzung des prädierten Wertes und eine zu starke Gewichtung hin zum Messwert zur Folge hat.

Der adaptive Kalman-Filter (AKF) ist eine Lösung für instationäre Prozesse. Die im System gespeicherten Informationen des stochastischen Prozesses werden für die Schätzung des

Prozess- und Messrauschens und die Berechnung des optimalen Kalman-Gains im instationären Fall gebraucht. Abweichungen von den aktuellen Parametern werden online detektiert und die Rauschterme adaptiv angepasst [3].

Für die Manöverdetektion wurden in dieser Arbeit zwei Verfahren untersucht: Residuenanalyse und *Recursive Least Square*. Bei der Residuenanalyse wird die Mahalanobis-Distanz d_M zwischen der prädizierten Position $\hat{\mathbf{x}}_k$ und der im aktuellen Zeitschritt k gemessenen Position \mathbf{z}_k betrachtet.

$$d_M = \sqrt{(\hat{\mathbf{x}}_k - \mathbf{z}_k) \mathbf{S}_k^{-1} (\hat{\mathbf{x}}_k - \mathbf{z}_k)} \quad (4.8)$$

\mathbf{S}_k ist die Innovationskovarianzmatrix, sie wird wie folgt berechnet:

$$\mathbf{S}_k = \mathbf{H} \hat{\mathbf{P}}_k \mathbf{H}^T + \mathbf{R} \quad (4.9)$$

Weichen die Residuen zu stark ab, wird von einem Manöver ausgegangen und das Prozessrauschen angepasst.

Bei der Recursive-Least-Squares-Methode werden die korrigierten Zustände zwischengespeichert und daraus die Prozessunsicherheit geschätzt. Diese sollte mit dem erwarteten Wert für das Prozessrauschen übereinstimmen, ansonsten liegt ein Manöver vor. Bei dieser Methode ergibt sich eine Verzögerung der Schätzung, die von der Fenstergröße für die Speicherung der Daten abhängt. Je größer das Fenster, desto größer die Verzögerung. Andererseits verringert sich die Falschalarmrate für die Detektion mit steigender Fenstergröße.

Abbildung 4.1 zeigt ein Beispiel für die Geschwindigkeitsschätzung mittels Standard-Kalman-Filter (mit CV-Modell) im Vergleich zum Kalman-Filter mit Online-Identifikation des Prozesses und adaptivem Prozessrauschen. Das Szenario ist eine Realfahrt, wobei das Zielfahrzeug längs am Sensorfahrzeug vorbeifährt und dabei von 20 km/h auf 40 km/h in 2 s beschleunigt. Die rote Linie zeigt die tatsächliche Geschwindigkeit, die blaue Linie repräsentiert das Ergebnis mit dem Standard-Kalman-Filter, die schwarze Linie ist das Ergebnis mit dem adaptiven Kalman-Filter. Als Detektor wurde das Recursive-Least-Square-Verfahren benutzt. Mit dem AKF kann der Geschwindigkeit genauer gefolgt werden.

4.1.3 Interacting Multiple Model Filter (IMM)

Der Interacting Multiple Model Filter (IMM) ist eine weitere Möglichkeit, mit instationären Prozessen umzugehen. Während beim adaptiven Kalman-Filter ein Bewegungsmodell beibehalten wird und Abweichungen durch Veränderungen im Rauschen abgebildet werden, wird beim IMM mit mehreren Bewegungsmodellen gearbeitet. Für jedes dieser Modelle existieren quasi einzelne Filter, die parallel durchlaufen werden. Das Gesamtergebnis in jedem Zeitschritt ist eine gewichtete Kombination der Einzelergebnisse. Die Wichtung erfolgt anhand von Übergangswahrscheinlichkeiten von einem Bewegungsmodell zum anderen. Der Übergangsprozess wird dabei als Markov-Kette modelliert. Neben den Zustandsgrößen und der Prozesskovarianz sind die Modellübergangswahrscheinlichkeiten beim IMM eine in die Berechnungen jedes Zeitschritts einzubeziehende Größe.

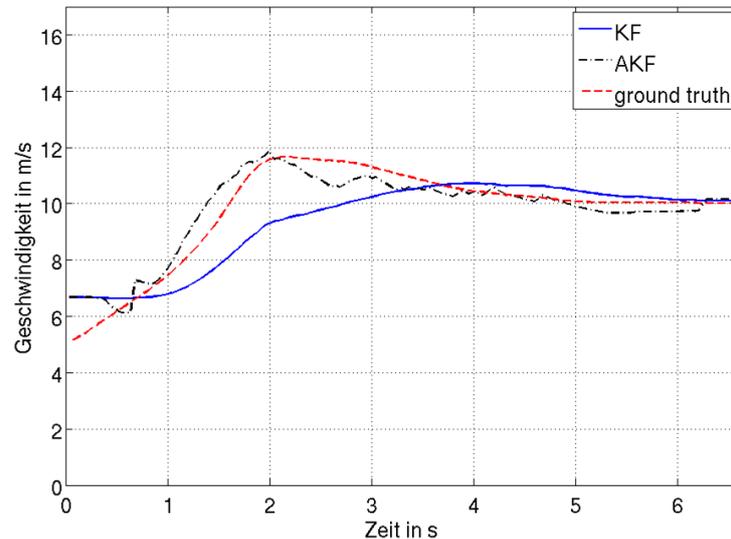


Abbildung 4.1: Geschwindigkeitsschätzung mit adaptivem Prozessrauschen

Der Algorithmus besteht aus vier Schritten [KD04]:

- **Interaktion:** Gewichtung der Einzelschätzungen entsprechend der prädierten Modellwahrscheinlichkeiten
- **Modell-spezifische Filterung:** Filterzyklus (Prädiktion/Innovation) jedes Einzelfilters entsprechend seiner Modellparameter
- **Update der Modell-Wahrscheinlichkeiten:** Modell-Wahrscheinlichkeiten werden anhand der Innovationsfehler aktualisiert.
- **Kombination:** Ein kombinierter Ausgabewert wird anhand der gewichteten Einzelzustände berechnet.

4.2 Verfolgung von Referenzpunkten

4.2.1 Prozess- und Messmodelle

Die Messvektoren \mathbf{z} für Laser- und Radarmessungen sind definiert als

$$\mathbf{z}_{laser} = [x_z \ y_z]^T \quad (4.10)$$

$$\mathbf{z}_{radar} = [x_z \ y_z \ \dot{r}_z]^T \quad (4.11)$$

wobei x und y die Positionen in kartesischen Koordinaten sind und \dot{r} die radiale Geschwindigkeit angibt. Dem Messprinzip zufolge sind die Positionsmessungen des Radars ursprünglich in polaren Koordinaten gegeben. Um Laserscanner- und Radardaten innerhalb desselben

Tracking-Systems zu benutzen, werden die Positionsdaten, die das Radar liefert, zunächst in kartesische Koordinaten konvertiert und dann mithilfe des Kalman-Filters mit gemischten Koordinaten (*engl. Mixed Coordinates Kalman Filter*) verarbeitet [Bla86, BSLK01]. Zur Reduktion von Verzerrungseffekten, die bei der Linearisierung von Messwerten mit korrelierten Fehlern entstehen, wird eine als *Debiased Consistent Measurement Conversion* bezeichnete Konvertierungsmethode verwendet [LBS93]. Die Komponenten des Messvektors werden zu

$$x_{z,radar} = r_z \cos(\varphi_z)(1 - e^{-\sigma_\varphi^2} + e^{-\sigma_\varphi^2/2}) \quad (4.12)$$

$$y_{z,radar} = r_z \sin(\varphi_z)(1 - e^{-\sigma_\varphi^2} + e^{-\sigma_\varphi^2/2}) \quad (4.13)$$

mit dem Ablagewinkel φ und der dazugehörigen Varianz σ_φ^2 . Die Konvertierung muss ebenso für die entsprechenden Einträge in der Messkovarianzmatrix \mathbf{R} vorgenommen werden:

$$\mathbf{R}_{xx} = e^{-2\sigma_\varphi^2}(r_z^2(c_1 \cos^2(\varphi_z) + c_2 \sin^2(\varphi_z)) + \sigma_r^2(c_3 \cos^2(\varphi_z) + c_4 \sin^2(\varphi_z))) \quad (4.14)$$

$$\mathbf{R}_{yy} = e^{-2\sigma_\varphi^2}(r_z^2(c_1 \sin^2(\varphi_z) + c_2 \cos^2(\varphi_z)) + \sigma_r^2(c_3 \sin^2(\varphi_z) + c_4 \cos^2(\varphi_z))) \quad (4.15)$$

$$\mathbf{R}_{xy} = e^{-4\sigma_\varphi^2} \sin(\varphi_z) \cos(\varphi_z)(\sigma_r^2 + (r^2 + \sigma_r^2)(1 - e^{\sigma_\varphi^2})) \quad (4.16)$$

mit

$$c_1 = \cosh(2\sigma_\varphi^2) - \cosh(\sigma_\varphi^2) \quad (4.17)$$

$$c_2 = \sinh(2\sigma_\varphi^2) - \sinh(\sigma_\varphi^2) \quad (4.18)$$

$$c_3 = 2 \cosh(2\sigma_\varphi^2) - \cosh(\sigma_\varphi^2) \quad (4.19)$$

$$c_4 = 2 \sinh(2\sigma_\varphi^2) - \sinh(\sigma_\varphi^2) \quad (4.20)$$

Modell konstanter Geschwindigkeit (*engl. Constant Velocity Model*)

Als Prozessmodell kann ein einfaches Modell konstanter Geschwindigkeit verwendet werden. Der Zustandsvektor

$$\mathbf{x} = [x \quad y \quad \dot{x} \quad \dot{y}]^T \quad (4.21)$$

beinhaltet Position und Positionsänderung der Koordinaten. Die Verknüpfung zwischen der Messung der Entfernungsänderung und dem Zustandsvektor ist nichtlinear, was den Einsatz des erweiterten Kalman-Filters (EKF) nötig macht. Die Messgleichung lautet

$$\dot{r}_z = \frac{x\dot{x} + y\dot{y}}{\sqrt{x^2 + y^2}} \quad (4.22)$$

Mittels Reihenentwicklung erster Ordnung zur Linearisierung der Messgleichungen kann die Messmatrix \mathbf{H} folgendermaßen geschrieben werden

$$\mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ \frac{\partial \dot{r}}{\partial x} & \frac{\partial \dot{r}}{\partial y} & \frac{\partial \dot{r}}{\partial \dot{x}} & \frac{\partial \dot{r}}{\partial \dot{y}} \end{bmatrix} \quad (4.23)$$

mit den partiellen Ableitungen

$$\frac{\partial \dot{r}}{\partial x} = \frac{\dot{x}}{\sqrt{x^2 + y^2}} - \frac{x(x\dot{x} + y\dot{y})}{\sqrt{(x^2 + y^2)^3}} \quad (4.24)$$

$$\frac{\partial \dot{r}}{\partial y} = \frac{\dot{y}}{\sqrt{x^2 + y^2}} - \frac{y(x\dot{x} + y\dot{y})}{\sqrt{(x^2 + y^2)^3}} \quad (4.25)$$

$$\frac{\partial \dot{r}}{\partial \dot{x}} = \frac{x}{\sqrt{x^2 + y^2}} \quad (4.26)$$

$$\frac{\partial \dot{r}}{\partial \dot{y}} = \frac{y}{\sqrt{x^2 + y^2}} \quad (4.27)$$

Nach Bizup und Brown [BB03] ist \mathbf{H} in dieser Form überbestimmt, da die Summe der Ableitungen von \dot{r} nach den Positionen multipliziert mit den Komponenten aus dem Zustandsvektor Null ergibt.

$$x \frac{\partial \dot{r}}{\partial x} + y \frac{\partial \dot{r}}{\partial y} = 0 \quad (4.28)$$

Daher lässt sich die Messmatrix \mathbf{H} aus Gleichung 4.23 vereinfachen zu

$$\mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & \frac{\partial \dot{r}}{\partial \dot{x}} & \frac{\partial \dot{r}}{\partial \dot{y}} \end{bmatrix} \quad (4.29)$$

Die diskrete Zustandsmatrix \mathbf{F} für das Modell konstanter Geschwindigkeit mit dem in Formel 4.21 definierten Zustandsvektor lautet

$$\mathbf{F} = \begin{bmatrix} 1 & 0 & T & 0 \\ 0 & 1 & 0 & T \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (4.30)$$

wobei T für die Dauer des Abtastintervalls steht.

Modell konstanter Beschleunigung (engl. *Constant Acceleration Model*)

Beim Modell konstanter Beschleunigung werden Abweichungen vom Modell, also Beschleunigungen, im Prozessrauschen erfasst.

$$\mathbf{x} = [x \quad y \quad \dot{x} \quad \dot{y} \quad \ddot{x} \quad \ddot{y}]^T \quad (4.31)$$

$$\mathbf{F} = \begin{bmatrix} 1 & 0 & T & 0 & T^2/2 & 0 \\ 0 & 1 & 0 & T & 0 & T^2/2 \\ 0 & 0 & 1 & 0 & T & 0 \\ 0 & 0 & 0 & 1 & 0 & T \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (4.32)$$

Modell konstanter Kreisfahrt (engl. *Constant Turn Model*)

Für die konstante Kreisfahrt lassen sich Modellierungen in polaren Koordinaten als auch in kartesischen Koordinaten angeben [GI96]. Zu beachten ist, dass die Zustandsgleichungen nichtlinear sind.

$$\mathbf{x}^{kar} = [x \ y \ \dot{x} \ \dot{y} \ \omega]^T, \quad \mathbf{x}^{pol} = [x \ y \ v \ \psi \ \omega]^T \quad (4.33)$$

Für kartesische Koordinaten lauten die Systemgleichungen wie folgt:

$$x_{k+1} = x_k + \frac{\dot{x}}{\omega} \sin(\omega T) + \frac{\dot{y}}{\omega} (\cos(\omega T) - 1) \quad (4.34)$$

$$y_{k+1} = y_k + \frac{\dot{x}}{\omega} (1 - \cos(\omega T)) + \frac{\dot{y}}{\omega} \sin(\omega T) \quad (4.35)$$

$$\dot{x}_{k+1} = \dot{x}_k \cos(\omega T) - \dot{y}_k \sin(\omega T) \quad (4.36)$$

$$\dot{y}_{k+1} = \dot{x}_k \sin(\omega T) + \dot{y}_k \cos(\omega T) \quad (4.37)$$

$$\omega_{k+1} = \omega_k \quad (4.38)$$

Für die Modellierung in polaren Koordinaten ergeben sich folgende Bewegungsgleichungen:

$$x_{k+1} = x_k + \frac{v}{\omega} (\sin(\psi + \omega T) - \sin(\psi)) \quad (4.39)$$

$$y_{k+1} = y_k - \frac{v}{\omega} (\cos(\psi + \omega T) - \cos(\psi)) \quad (4.40)$$

$$v_{k+1} = v_k \quad (4.41)$$

$$\psi_{k+1} = \psi + \omega T \quad (4.42)$$

$$\omega_{k+1} = \omega_k \quad (4.43)$$

4.2.2 Eigenbewegungskompensation

Die Schätzung der Objektparameter erfolgt im Fahrzeugkoordinatensystem, Positionen und Bewegungen werden also relativ zur eigenen Bewegung des Sensorfahrzeugs angegeben. Um absolute Angaben zu erhalten, muss eine Kompensation der Fahrzeugbewegung erfolgen. Dies kann unter Verwendung des Einspurmodells mit den Dynamik-Daten erfolgen, die über den Fahrzeugbus zur Verfügung gestellt werden: Geschwindigkeit in Fahrtrichtung v_{veh} und Gierra-

te ω_{veh} . Die aktuelle Orientierung ψ_{veh} wird unter Annahme konstanter Gierrate bestimmt.

$$\psi_{veh} = \omega_{veh}T \quad (4.44)$$

Diese Approximation ist zulässig, da die Abtastzeit T klein ist. Die Systemmatrix F aus dem Beispiel für das Modell konstanter Geschwindigkeit (siehe Formel 4.30) wird zu

$$\mathbf{F} = \begin{bmatrix} \cos(\psi_{veh}) & -\sin(\psi_{veh}) & \cos(\psi_{veh})T & -\sin(\psi_{veh})T \\ \sin(\psi_{veh}) & \cos(\psi_{veh}) & \sin(\psi_{veh})T & \cos(\psi_{veh})T \\ 0 & 0 & \cos(\psi_{veh}) & -\sin(\psi_{veh}) \\ 0 & 0 & \sin(\psi_{veh}) & \cos(\psi_{veh}) \end{bmatrix} \quad (4.45)$$

und beinhaltet die Rotation. Zusätzlich muss noch die Translation berücksichtigt werden, damit ergibt sich für den Prädiktionsschritt

$$\hat{\mathbf{x}}_k = \mathbf{F}\mathbf{x}_{k-1} - [\Delta x \ \Delta y]^T \quad (4.46)$$

mit

$$\Delta x = \frac{v_{veh}}{\omega_{veh}} \sin(\omega_{veh}T) \quad (4.47)$$

$$\Delta y = \frac{v_{veh}}{\omega_{veh}} (1 - \cos(\omega_{veh}T)) \quad (4.48)$$

bzw. für $\omega_{veh} \rightarrow 0$

$$\Delta x = v_{veh} \cdot T \cdot \cos(\omega_{veh}T) \quad (4.49)$$

$$\Delta y = v_{veh} \cdot T \cdot \sin(\omega_{veh}T) \quad (4.50)$$

4.3 Umgang mit ausgedehnten Zielen

4.3.1 Anpassung des Referenzpunktes

In Kapitel 3.2.2 wurde bereits auf die Problematik bei der Wahl geeigneter Referenzpunkte für das Tracking ausgedehnter Objekte eingegangen. Dort wurde skizziert, wie Eckpunkte von Segmenten als Referenzpunktkandidaten für Objekte benutzt werden können (siehe Abbildung 3.12). Referenzpunkte sollen möglichst robust gegen Scheinbewegungen durch Größenänderungen bei Objekten sein. Ist die Merkmalsextraktion, speziell die Linieneinpassung von ausreichender Güte, verhalten sich die extrahierten Eckpunkte der Segmente zumindest phasenweise stabil. Bei Änderung der beobachtbaren Länge oder Breite des Objekts müssen die Referenzpunkte jedoch umgesetzt werden. Bei einer Querfahrt wie in Abbildung 3.12 dargestellt, wird zunächst die rechte vordere Fahrzeugecke verfolgt, beim Verlassen des Sichtbereichs wird der Referenzpunkt auf die rechte hintere Fahrzeugecke umgesetzt und diese weiterverfolgt.

Die Umsetzung des Referenzpunktes erfolgt szenarioabhängig. Zur Realisierung muss bekannt sein, wo sich das Objekt relativ zum Sensor befindet und wohin es sich bewegt, das heißt die

Anwendung der Eckpunkte als Referenzpunkte kann erst nach Initialisierung des Objektes erfolgen. Entsprechend der Bewegungsform können dann Modelle der Beobachtbarkeit der einzelnen Eckpunkte angewendet werden, um den aktuellen Referenzpunkt zu bestimmen. Wenn nach der Initialisierung bekannt ist, dass sich das Objekt senkrecht zum eigenen Fahrzeug von links nach rechts bewegt wie im Beispiel gezeigt, wird als Referenzpunkt zunächst der Schnittpunkt der Linien gewählt sobald zwei Linien extrahiert wurden. Dieser Referenzpunkt wird beibehalten. Quert das Objekt die Mittelachse des eigenen Fahrzeugs, kann auf den linken der beiden Linienendpunkte umgeschaltet werden, der von da ab weiterverfolgt wird. In dieser Position ist nur eine Linie sichtbar. Im weiteren Verlauf werden wieder zwei Linien extrahiert, der Schnittpunkt beider Linien bildet nun den Referenzpunkt.

In einem Längsszenario, bei dem das verfolgte Objekt dem Sensorfahrzeug entgegenkommt, ist zunächst nur die Front in Form einer Linie sichtbar. Hier wird der nächstgelegene Linienendpunkt als Referenzpunkt weiterverfolgt. Werden beim Näherkommen zwei Fahrzeugkanten sichtbar, wird aus dem nächstgelegenen Endpunkt der Schnittpunkt beider Linien. Beim Verlassen des Sichtbereichs muss hier auf den entfernteren Linienendpunkt in Längsrichtung umgerechnet werden, um die Bewegung weiter richtig verfolgen zu können.

Dieses Verfahren kompensiert das Problem der Scheinbewegungen, setzt jedoch eine robuste Linienextraktion mit entsprechend stabilen End- und Schnittpunkten gemäß der Sichtbarkeitsmodelle der jeweiligen Fahrzeugkanten voraus.

4.3.2 Datenassoziation

Datenassoziation wird bei der Mehrzielverfolgung als zusätzlicher Prozessschritt nach der Prädiktion benötigt, um Messungen zu vorhandenen Tracks zuzuordnen, sodass das Update der Tracks mit der korrekten Messung erfolgen kann. Als Assoziationskriterium dient zumeist der Abstand zwischen den Messungen und den Tracks, wobei als Abstand im einfachsten Fall der geometrische Abstand definiert sein kann, gebräuchlicher ist allerdings die Mahalanobis-Distanz [Mah36] zwischen den Komponenten des Zustandsraums und ihrer Abbildung im Messraum. Zur Auflösung von Mehrdeutigkeiten bei der Assoziation wird eine Gütefunktion, die den Abstand berechnet, minimiert. Die Minimierung kann lokal erfolgen wie beim *Single Nearest Neighbour (SNN)*-Verfahren, oder es wird nach der global optimalen Variante der Zuordnungen gesucht wie beim *Global Nearest Neighbour (GNN)*-Verfahren. Um die Komplexität zu verringern und Rechenzeit zu sparen, werden nicht alle Kombinationen möglicher Zuordnungen von Messungen zu Tracks ausgewertet, sondern es werden nur potentielle Kandidaten betrachtet, die sich in einem Suchfenster um den Track befinden, dies wird als *Gating* bezeichnet. Das Suchfenster wird entsprechend der Varianzen von Track und Messungen so gewählt, dass ein bestimmter Anteil relevanter Messungen in das Gate fallen, beispielsweise $99,73\% \cong 3\sigma$ bei normalverteilten Zustands- und Messgrößen.

Sowohl SNN als auch GNN bilden eine 1:1-Zuordnung von Messungen zu Tracks. Probabilistische Assoziationsverfahren heben die starre Zuordnung auf, indem sie gewichtete Zuordnungen bilden. Messungen werden den Tracks mit einer gewissen Wahrscheinlichkeit zugeordnet, damit werden Mehrfachzuordnungen vom Typ $m:n$ möglich. Vertreter dieser Verfahren

sind *Probabilistic Data Association* (PDA) und *Joint Probabilistic Data Association* (JPDA). Gemeinsam ist beiden Verfahren, dass für jeden Track eine Detektionswahrscheinlichkeit existiert, anhand derer die Gewichte für die Zuordnung berechnet werden können. Zusätzlich wird von Hintergrundrauschen ausgegangen, sodass Messungen als solches interpretiert und keinem Track zugeordnet werden können, obwohl sie im Gate eines Tracks liegen. Die Unterschiede zwischen PDA und JPDA liegen in der Bildung der Hypothesen und deren Gewichtung. Sind Mehrfachzuordnungen erlaubt, wird der Kalman-Filter angepasst, sodass der Innovationsschritt mit mehreren Messungen möglich ist. Sarholz [Sar08] befasst sich in seiner Diplomarbeit ausführlich mit den hier angesprochenen Datenassoziationverfahren und deren Auswertung in automotiven Anwendungen.

Prinzipiell können die vorgestellten Verfahren auch auf ausgedehnte Objekte angewendet werden, die durch einen Referenzpunkt im Tracker repräsentiert sind. Ausgehend von diesem können die Abstandsmaße für das Gating und die Gütefunktion berechnet werden. Allerdings sollte zusätzlich die Ausdehnung berücksichtigt werden. Insbesondere bei der Zuordnung von Radarzielen zu Tracks, die räumlich ausgedehnte Objekte repräsentieren, muss die Beobachtbarkeit des Referenzpunktes berücksichtigt werden. In der Praxis wird der Referenzpunkt vor dem Assoziationsschritt zu einem Ort wahrscheinlicher Sichtbarkeit auf der Kante des Objekts verschoben, danach werden Assoziation der Messung sowie Innovationsschritt im Tracker vollzogen, und anschließend wird der Referenzpunkt des Objekts wieder rücktransformiert. Im Kapitel zur Datenfusion 5 wird dieses Thema nochmals aufgegriffen.

Bei räumlich ausgedehnten Objekten sind die über mehrere Zyklen ermittelten Längen- und Breiteninformationen ein mögliches Kriterium für die Zuordnung von Lasersegmenten zu vorhandenen Tracks. In Kapitel 4.3.4 wird ein Verfahren beschrieben, das diese Information explizit nutzt, um Objekthypothesen beim Tracking zu stabilisieren.

4.3.3 Objektverwaltung

In Kapitel 4.2.1 wurde bereits auf das Prozessmodell und die Komponenten des Zustandsvektors eingegangen. Dabei handelt es sich um Größen, die die Lage des Objektes im Raum und deren Änderungen erfassen. Weitere wichtige Attribute zur Charakterisierung von Objekten stellen deren Dimensionen, im Zweidimensionalen die Länge und Breite, dar. Es ist theoretisch möglich, diese Attribute in den Zustandsvektor aufzunehmen und mithilfe von entsprechend hinterlegten Prozess- und Messmodellen im Kalman-Filter zu tracken. Die Modelle hierfür sind simpel, Länge und Breite sind aus Prozesssicht unveränderlich und werden direkt gemessen, daher lauten die Zustands- und Messgleichungen (am Beispiel der Länge):

$$f(l_k) = l_{k-1} + Q \quad (4.51)$$

$$h(l) = l + R \quad (4.52)$$

Folgt man der Theorie, so ist der Modellfehler Q gegen Null gehend anzunehmen, die Dimension ist vom Wesen her eigentlich keine stochastische Größe. Die Messungen sind, bedingt durch Fehler bei der Segmentierung und Linieneinpassung, mit größerer Unsicherheit behaftet. Für das Schätzergebnis bedeutet das eine eher langsame Anpassung an die Messungen,

was bei der vorliegenden Anwendung eher unpraktikabel sein kann. Ein weiteres Problem ergibt sich daraus, das aus der Messung allein Länge und Breite nicht voneinander zu trennen sind, was eine falsche Belegung des Messvektors und somit eine Verfälschung des Ergebnisses zur Folge hätte. Die Autorin hat sich daher entschieden, die Schätzung der Objektgröße aus dem Kalman-Filter auszukoppeln und in einer nachgeschalteten Verarbeitungsstufe zur Objektverwaltung vorzunehmen.

Bevor ein Update der Objektgröße stattfinden kann, wird zunächst überprüft, wie sich der Winkel ψ_{obj} , der aus der Schätzung des Geschwindigkeitsvektors abgeleitet werden kann, zu dem Winkel ψ_{seg} verhält, den die dem Objekt im aktuellen Zeitschritt zugeordnete Messung aufweist. Basierend darauf können die aus dem Segment extrahierten Linien entweder der Länge oder der Breite des Objekts zugeordnet werden. Ist $(\psi_{obj} - \psi_{seg}) \bmod 180^\circ = 0^\circ \pm \theta$, wird die längere der eingepassten Linien der Objektlänge zugeordnet, stehen die Winkel orthogonal aufeinander, ist also $(\psi_{obj} - \psi_{seg}) \bmod 180^\circ = 90^\circ \pm \theta$, entspricht die längere der eingepassten Linien (oder die eingepasste Linie, wenn es nur eine gibt) der Objektbreite, denn wie in Kapitel 3.2.1 beschrieben, wird der Orientierungswinkel des Segmentes anhand der längeren Linie bestimmt. „Entgegengesetzte Richtungen“, die ebenfalls durch die Winkelbestimmung im Segment entstehen können, werden durch den Modulus aufgelöst. θ ist ein Parameter für den Akzeptanzbereich, in dem Richtungen als gleich angesehen werden. Die Schätzung von Länge und Breite erfolgt mittels *Fixed Gain Filter*:

$$l_k = w \cdot l_{seg} + (1 - w) \cdot l_{obj} \quad (4.53)$$

dabei bezeichnet l_{seg} die Länge des Segmentes und l_{obj} die Länge des getrackten Objektes. Die Gewichtung w ist ein konfigurierbarer Parameter, für die praktische Anwendung haben sich Werte von etwa 0.3 bewährt.

In Kapitel 4.3.4 wird ein alternatives Verfahren zum Umgang mit Längen- und Breiteninformationen beschrieben, das diese Informationen über ein Zustandsmodell in den Tracker integriert.

Neben den Dimensionen wird der Zustand und das Lebensalter jedes Objekts verwaltet. Dies ermöglicht Aussagen über die Verlässlichkeit der Attribute. Abbildung 4.2 stellt das Zustandsmodell dar. Wird ein Objekt neu aufgesetzt, befindet es sich zunächst im Zustand „initialized“. Wird es im nächsten Zeitschritt durch eine Messung gestützt, wird es in den Zustand „tentative“ versetzt. In diesem Zustand gilt ein Objekt noch als relativ unsicher, da es von wenigen Messungen gestützt ist, und auch die Schätzung der dynamischen Parameter bedingt durch das Einschwingen des Trackers noch ungenau ist. Nach einer konfigurierbaren Anzahl von Zeitschritten geht das Objekt in den Zustand „confirmed“ über. Objekte, die den Zustand „confirmed“ erreicht haben, werden als stabil angesehen. Kann einem Objekt im Zustand „confirmed“ im aktuellen Zeitschritt keine Messung zugeordnet werden, geht es in den Zustand „messed“ über. Dort kann es ohne Zuordnungen weiterer Messungen für eine konfigurierbare Dauer verbleiben. Wird erneut eine Messung zugeordnet, wird es wieder in den Zustand „confirmed“ versetzt. Somit bleiben auch Objekte, die zeitweilig verdeckt werden, erhalten. Kann nach Ablauf des Zählers für den „messed“-Zustand keine Messung zugeordnet werden, wird das Objekt in den Zustand „dead“ versetzt und gelöscht. Objekte, die nicht den Zustand „confirmed“ erreicht haben, gehen sofort in den Zustand „dead“ über, wenn im aktuellen Zyklus kein Messupdate erfolgt. Die

Zustände bilden eine Hierarchie, die den Status von Objekten bestimmt: confirmed → missed → tentative → initialized → dead. Objekte im Zustand „confirmed“ haben den höchsten Status.

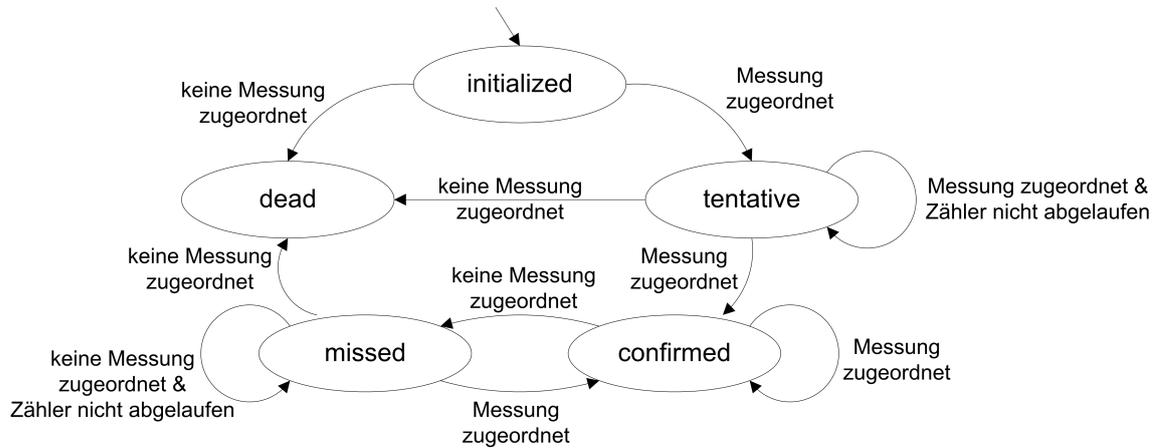


Abbildung 4.2: Zustandsmodell des Objektmanagements

Besonders bei querenden Objekten ist häufig zu beobachten, dass Objekte aufgrund formbedingten Wegreflektierens der einfallenden Wellen zerfallen. Verfolgt man die getrennten Objekte über einen gewissen Zeitraum und stellt fest, dass sie sich mit gleicher Geschwindigkeit in die gleiche Richtung bewegen, kann man die Hypothese aufstellen, dass es sich eigentlich um ein größeres zusammengehöriges Objekt handelt. Eine solche Zusammenführung von Objekten wird ebenfalls in der Objektverwaltung durchgeführt, zur Illustration siehe Abbildung 4.3. Beim Vergleich von Geschwindigkeiten und Bewegungsrichtungen wird wiederum mit einem Akzeptanzbereich gearbeitet. Da ein Tracking bereits stattgefunden hat, erhält das zusammengefasste Objekt die dynamischen Parameter des Objektes mit dem höheren Status entsprechend dem oben beschriebenen Zustandsmodell oder bei gleichem Status des Objektes mit der längeren Lebensdauer. Fusioniert werden nur Objekte im Zustand „confirmed“ oder „missed“. Der Referenzpunkt wird für das zusammengefasste Objekt neu berechnet, in der Abbildung wurde der Einfachheit der Darstellung halber der Mittelpunkt gewählt.



Abbildung 4.3: Zusammenfassen von Objekten, links: getrennte Objekte nach dem Tracking, rechts: zusammengefasstes Objekt

4.3.4 Integrierte Objektverfolgung und Klassifikation

Eine Erweiterung des in Kapitel 4.3.3 vorgestellten Umgangs mit Längen- und Breiteninformationen aus den Segmenten bildet die integrierte Objektverfolgung und Klassifikation. Hierbei werden die Informationen über die Ausdehnung nicht separat verwaltet sondern mitverfolgt. Grundlage dafür bildet ein Zustandsmodell der für den Laserscanner sichtbaren Kanten auf

bewegten Objekten. Das hier verwendete Verfahren orientiert sich an der von Zhao et al. publizierten Methode des „Joint tracking and classification“ [ZSKS06].

Da in dieser Arbeit der Fokus auf Fahrzeugen liegt, ist der Algorithmus auf rechteckige konvexe Objekte ausgelegt. Das Rechteckobjekt wird wie in Abbildung 4.4 richtungsabhängig modelliert. Entsprechend ergeben sich acht Möglichkeiten der Kantensichtbarkeit für den Sensor, die in den Zuständen $\{m_1..m_8\}$ erfasst werden. Die möglichen Zustandsübergänge sind in der Abbildung durch die Pfeile aufgezeigt. Liegt beispielsweise momentan der Zustand m_4 vor, d. h. die rechte Seite ist sichtbar, so kann im nächsten Zeitschritt die rechte und die vordere Seite sichtbar sein oder aber die rechte und die hintere Seite, oder es bleibt weiterhin nur die rechte Seite sichtbar. Dies tritt bei der Quervorbeifahrt eines Fahrzeugs auf.

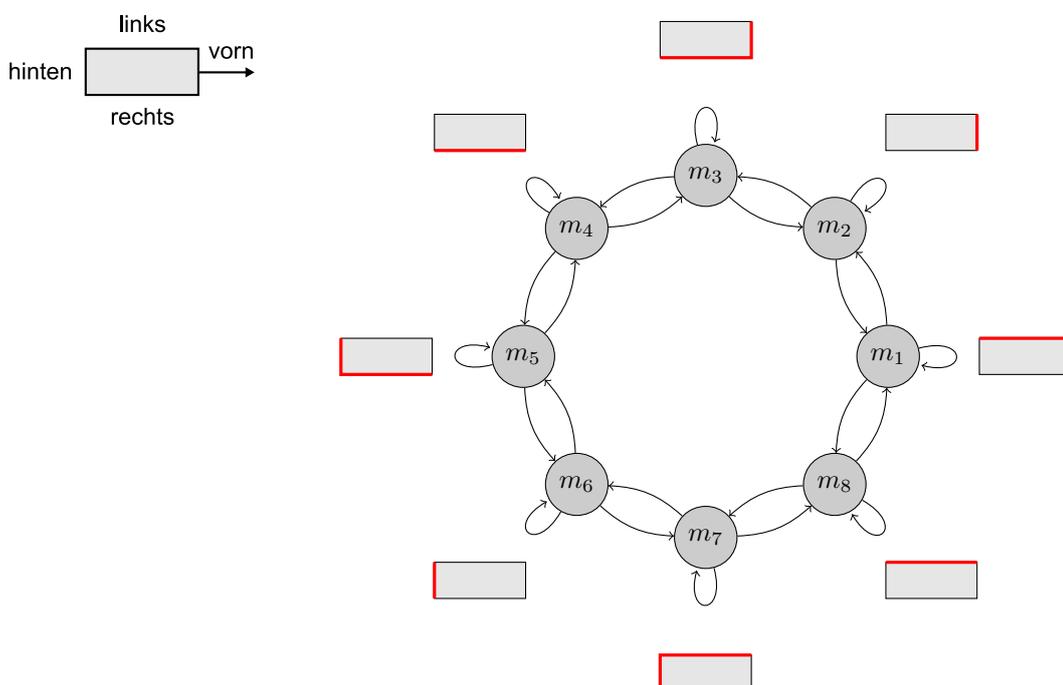


Abbildung 4.4: Die Zustände m_1 bis m_8 bilden alle möglichen Segmentkonfigurationen, die unter verschiedenen Sichtwinkeln auftreten können, ab. In rot sind die jeweils sichtbaren Kanten markiert. Das Objektmodell (links) ist richtungsorientiert, daher unterscheiden sich z. B. die Zustände m_2 und m_6 voneinander, da einmal die vordere Kante und einmal die hintere Kante gesehen wird.

Allgemein beschreibt die Wahrscheinlichkeit p_{ij} den Übergang von einem Zustand m_i in den Zustand m_j . Die Wahrscheinlichkeiten werden in der Übergangsmatrix M zusammengefasst:

$$M = \begin{pmatrix} p_{11} & \cdots & p_{18} \\ \vdots & \ddots & \vdots \\ p_{81} & \cdots & p_{88} \end{pmatrix} \quad (4.54)$$

In der Arbeit von Zhao et al. [ZSKS06] wird bei der Bestimmung von M unterschieden, ob

sich das Fahrzeug im Uhrzeigersinn oder gegen den Uhrzeigersinn bewegt. Je nachdem ist der Übergang zum nächsten Kantenzustand höher zu gewichten als zum vorherigen. Dies soll hier allgemeiner gehandhabt werden, um theoretisch auch Rückwärtsfahren abzubilden. Bewegt sich das Fahrzeug von links nach rechts (im Uhrzeigersinn) wird ein Zustandswechsel von $m_3 \rightarrow m_4 \rightarrow m_5$ erwartet. Mit hoher Wahrscheinlichkeit sind also Übergänge in den gleichen Zustand oder den nächsten Zustand zu bewerten:

$$p_{stay} = p_{ii} \gg 0 \quad (4.55)$$

$$p_{next} = p_{i(i+1)} \gg 0 \quad (4.56)$$

Es wird außerdem das Zurückspringen zum vorherigen Zustand zugelassen:

$$p_{prev} = p_{i(i-1)} > 0 \quad (4.57)$$

Alle anderen Wechsel werden ausgeschlossen. Die Übergangsmatrix lautet dann:

$$M = \begin{pmatrix} p_{stay} & p_{next} & 0 & 0 & 0 & 0 & 0 & p_{prev} \\ p_{prev} & p_{stay} & p_{next} & 0 & 0 & 0 & 0 & 0 \\ 0 & p_{prev} & p_{stay} & p_{next} & 0 & 0 & 0 & 0 \\ \vdots & \vdots \\ p_{next} & 0 & 0 & 0 & 0 & 0 & p_{prev} & p_{stay} \end{pmatrix} \quad (4.58)$$

Gemäß der Definition von M gilt:

$$p_{stay} + p_{next} + p_{prev} = 1 \quad (4.59)$$

Für die Bewertung der Zustandswechsel untereinander soll gelten:

$$1 > p_{stay} > p_{next} > p_{prev} > 0 \quad (4.60)$$

Um das Verfahren vorteilhaft einsetzen zu können, sind Anpassungen in der Assoziationsstufe notwendig. Insbesondere soll eine Mehrfachassoziation, also die Zuordnung mehrerer Segmente zu einem Objekt, erlaubt sein, um den Zerfall von Objekten zu adressieren. Dieses kann über einen Kantenabgleich realisiert werden. Abbildung 4.5 zeigt ein Beispiel. Hier wurden drei Segmente, jeweils bestehend aus den roten, blauen und grünen Punkten, in unmittelbarer Umgebung des durch das Rechteck dargestellten Objekts extrahiert. Dem Objekt ist der Zustand m_5 zugeordnet, d. h. bisher waren die rechte und die hintere Kante sichtbar. Die Zuordnung des grünen und des blauen Segments unterstützt den Verbleib im Zustand m_5 , was plausibel erscheint. Ebenfalls plausibel ist der Zustandsübergang $m_5 \rightarrow m_4$, also nur die rechte Seite ist sichtbar. Unwahrscheinlich ist der Zustandsübergang $m_5 \rightarrow m_7$, der durch Zuordnung von blauem und rotem Segment gestützt würde. Man könnte argumentieren, dass bei einem in Schlangenlinien vorausfahrendem Fahrzeug abwechselnd die hintere und linke Seite und die hintere und rechte Seite sichtbar wäre. Dies ist allerdings ein eher konstruierter Fall. Zudem würde bedingt durch die zeitliche Auflösung und den Toleranzbereich für die Linieneinpassung zwischendurch der Zustand m_6 , also nur die hintere Seite ist sichtbar, auftreten.

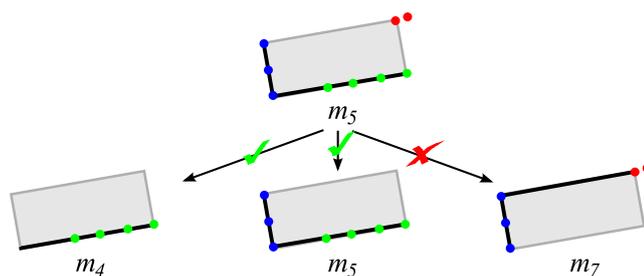


Abbildung 4.5: Beispiel für mögliche Kantenzuordnungen. Ein Objekt befindet sich im Zustand m_5 . Für die Assoziation kommen drei Segmente in Frage (grün, blau, rot). Die Übergänge $m_5 \rightarrow m_4$ und $m_5 \rightarrow m_5$ sind gültige Zustandsübergänge und werden durch die Zuordnung des grünen Segments bzw. durch die Kombination aus grünen und blauem Segment unterstützt. Der Übergang $m_5 \rightarrow m_7$ wird zwar durch die Kombination aus rotem und blauem Segment gestützt, ist jedoch kein gültiger Zustandsübergang (siehe Abbildung 4.4).

Die Kostenfunktion wird entsprechend modifiziert, um die Segmentform zu berücksichtigen. Dabei wird die Übergangsmatrix entsprechend Formel 4.58 zur Grundlage genommen. Die Übergangswahrscheinlichkeit ist ein Maß dafür, wie gut die Segmentform zu einem existierenden Objekt passt. Für alle Segmente, die in der Nähe des Objekts liegen, wird der Kantenzustand bestimmt und die daraus resultierende Kostenfunktion ermittelt. Zusätzlich werden aus den Segmenten alle möglichen Kombinationen gebildet, klassifiziert und die Kostenfunktion anhand der sichtbaren Kanten ermittelt. Es wird dann das Segment oder die Kombination mit der geringsten Kostenfunktion gewählt. Dadurch werden alle Segmente zugeordnet, die am besten die Objektform unterstützen. Bei n Segmenten in der Nähe eines Objektes gibt es unter Berücksichtigung aller Kombinationen $\sum_{i=1}^n \binom{n}{i}$ Möglichkeiten der Zuordnung. Hier steht i für die Anzahl kombinierter Segmente in der Mehrfachassoziation. Um nicht alle Kombinationen bewerten zu müssen, liegt es nahe, die Anzahl der Segmente, die pro Objekt zugeordnet werden können, zu beschränken. Dies ergibt auch praktisch einen Sinn, da eine Rekonstruktion von für die Anwendung relevanten Objekten, die bei der Segmentierung in mehr als 2 bis 3 Segmente zerfallen, eher zufällig wäre. Trotz plausibler Kantenzuordnungen können Fehler bei der Assoziation auftreten, wie Abbildung 4.6 zeigt.

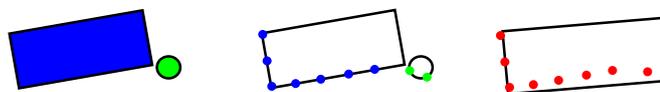


Abbildung 4.6: Fehler bei der Mehrfachassoziation durch plausible Segmentkombinationen

Dies kann vermieden werden, indem man das *Global-Nearest-Neighbour*-Verfahren einsetzt. Dazu wird in der ersten Auktionsrunde jedem Objekt ein Segment zugeordnet. Die nicht assoziierten Segmente werden in einem zweiten Schritt neu zugeordnet. Anschließend werden die Kombinationen gebildet und neu bewertet. Ergibt sich dabei eine Verbesserung, wird die Kombination bevorzugt.

Die Kostenfunktion κ_{ij} für die Zuordnung von Segment S_j zu Objekt O_i setzt sich aus zwei

Komponenten zusammen. $edge(O_i, S_j)$ liefert die Wahrscheinlichkeit für den Kantenübergang bei einem Messupdate von O_i mit S_j . Da es passieren kann, dass zwei Segmente den gleichen Zustandsübergang ermöglichen, wird zusätzlich der prozentuale Segmentanteil ζ berücksichtigt. Dieser gibt den Anteil n_U aller n Rohdatenpunkte eines Segmentes an, der in der Umgebung U eines Objektes liegt.

$$\zeta = \frac{n_U}{n} \quad (4.61)$$

Die Kostenfunktion für das Objekt O_i und das Segment S_j lautet:

$$\kappa_{ij} := \omega_1 edge(O_i, S_j) + \omega_2 \zeta_{ij} \quad (4.62)$$

wobei ω_1 und ω_2 zur Gewichtung der beiden Anteile dienen. ζ soll in erster Linie nur bei Gleichheit entscheiden oder aber wenn der Anteil in der Umgebung deutlich größer ist.

Abbildung 4.7 zeigt das Objektmodell mit den aus einem L-förmigen Segment extrahierten Merkmalen. Die Ausdehnungen len_1 und len_2 werden im Tracker in gleicher Weise gefiltert wie in Kapitel 4.3.3 beschrieben.

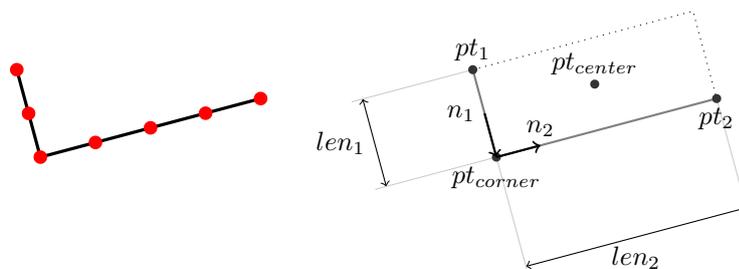


Abbildung 4.7: Objektattribute für ein L-förmiges Segment

Für die Objektverwaltung werden zwei Klassen - *Seeds* und *Trajectories* - eingeführt, die die Qualität der Objekte kategorisieren. Die Gütekriterien für die Zuordnung sind der Vergleich des Geschwindigkeitsvektors mit der Orientierung des Objektes wie bereits in Kapitel 4.3.3 beschrieben und die Stabilität der Klassenzugehörigkeit (I- bzw. L-förmig). Eine *Trajectory* wird dann als *Seed* zurückgestuft, wenn drei Messungen hintereinander ausfallen. Eine Messung fällt dann aus, wenn ein Segment einer falschen Klasse zugeordnet wurde oder ein unwahrscheinlicher Kantenübergang erfolgt ist.

Das Verfahren wurde anhand zweier Kreuzungsszenarien evaluiert, die unterschiedliche Problemfelder für die Verfolgung ausgedehnter Objekte beinhalten. Die Szenen wurden in der Simulation modelliert und in der Realität nachgefahren. Untersucht wurde die Genauigkeit der Positions- und Geschwindigkeitsschätzung des erweiterten Trackingsystems mit integrierter Objektverfolgung und Klassifikation (im Folgenden als System 2 referenziert) im Vergleich zum einfachen Trackingsystem ohne integrierter Klassifikation (als System 1 bezeichnet).

Das erste Testszenario wird durch Abbildung 4.8 illustriert. Zwei Fahrzeuge queren eine Kreuzung. Die Position des Messfahrzeugs ist durch den roten Punkt gekennzeichnet. Beim Passieren verdeckt das vordere Fahrzeug (grau) das Hintere (blau). Betrachtungsgegenstand ist

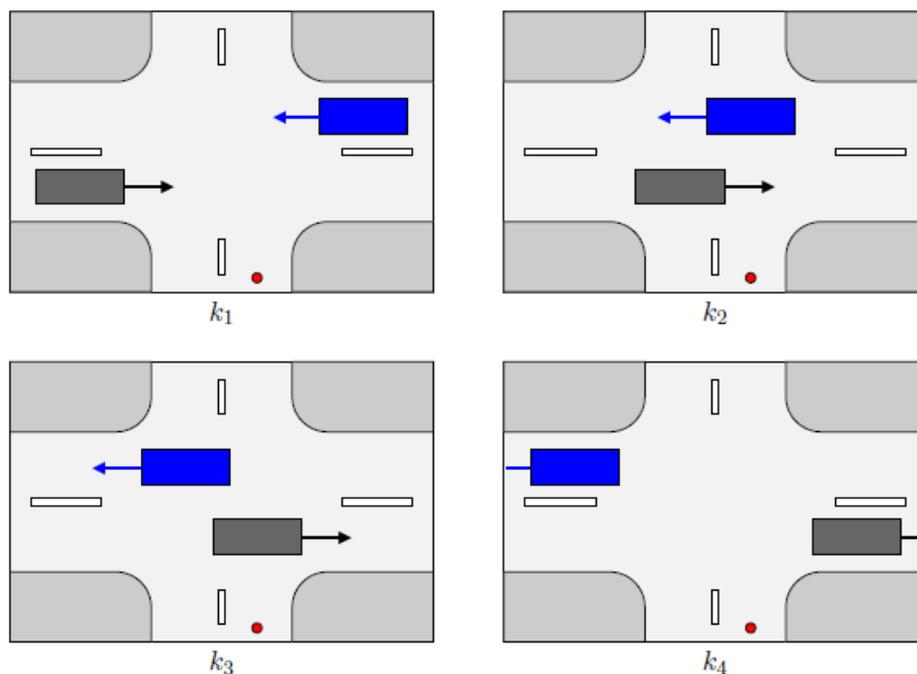


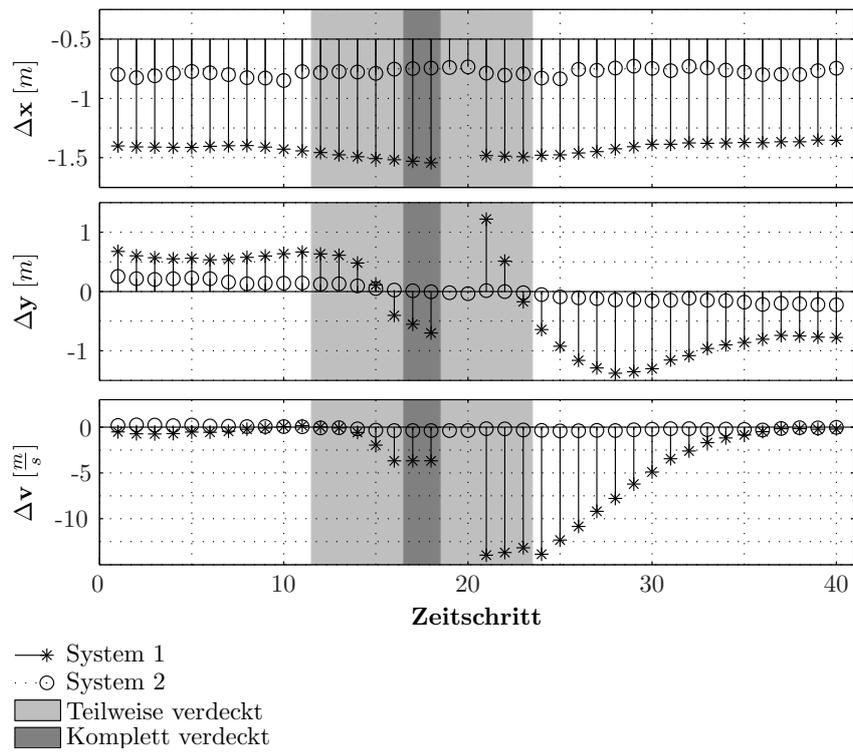
Abbildung 4.8: Szenario 1 mit zwei querenden Fahrzeugen

das hintere Objekt. Die auftretenden kritischen Situationen sind Perspektivwechsel und Verdeckung. Die Geschwindigkeiten der Fahrzeuge betragen zwischen $8 \frac{m}{s}$ und $14 \frac{m}{s}$, der Mittelpunkt der Kreuzung ist in etwa $15 m$ vom Sensor entfernt.

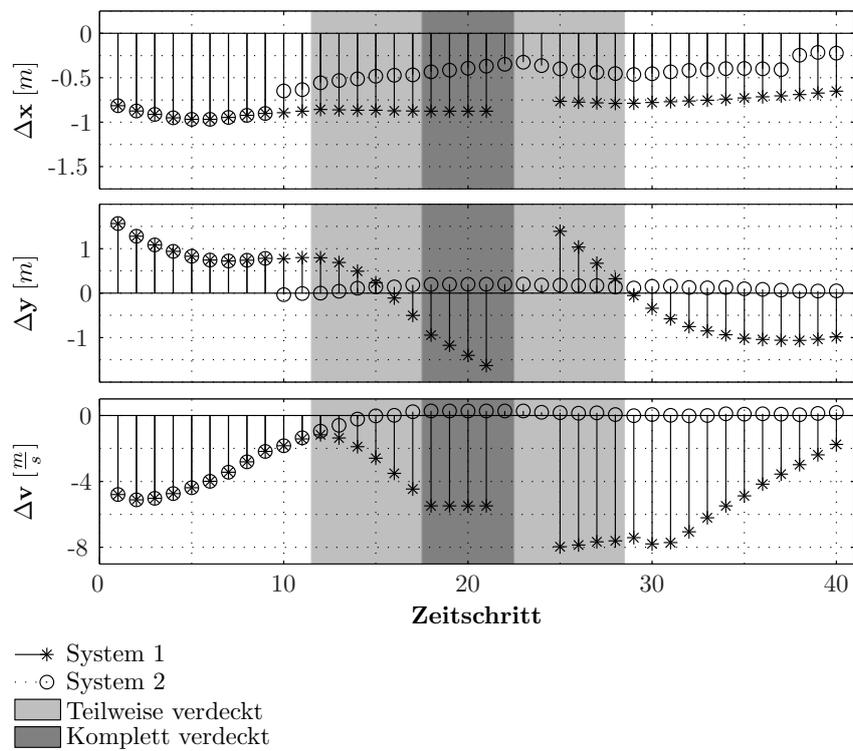
Abbildung 4.9 stellt die Ergebnisse für Szenario 1 in Form von Abweichungen vom wahren Wert dar. In Abbildung 4.9(a) sind die Werte für die simulierten Daten aufgetragen. Beide Fahrzeuge fahren mit $14 \frac{m}{s}$ über die Kreuzung. Während der Verdeckung verliert System 1 das Objekt im 19. Zeitschritt. Danach wird ein neuer Track aufgesetzt, wobei durch die Verschiebung des Referenzpunktes nach hinten aus der Verdeckung heraus die Geschwindigkeit mit $0 \frac{m}{s}$ initialisiert und erst langsam korrigiert wird. System 2 kompensiert die Verdeckung und erreicht durch eine gute Positionsbestimmung eine nahezu exakte Geschwindigkeitsschätzung. Da die Breite des Fahrzeugs nicht komplett erfasst wird, entsteht ein Offset in x-Richtung bezogen auf den tatsächlichen Fahrzeugmittelpunkt.

In der Realität wurde das Szenario mit $8 \frac{m}{s}$ nachgefahren (Abbildung 4.9(b)). Die Zeitdauer der Verdeckung dauert somit länger als im simulierten Fall. Auch hier schafft das Trackingsystem nicht, das Fahrzeug durch die Verdeckung zu tracken, es entstehen die gleichen Fehler wie mit simulierten Daten. Erst zum Zeitschritt 10 wird der Track von System 2 als hinreichend gut klassifiziert, so dass die Ausdehnung geschätzt und in die Berechnung eingebracht werden darf. Ab diesem Zeitpunkt wird die Position genauer bestimmt und die Geschwindigkeit nahezu zum wahren Wert korrigiert.

Abbildung 4.10 zeigt ein zweites Szenario zur Evaluierung der integrierten Objektverfolgung und Klassifikation. Ein Fahrzeug fährt über eine Kreuzung. Bei der Segmentierung kommt es



(a)



(b)

Abbildung 4.9: Szenario 1 - Differenz zum wahren Wert, (a) simulierte Daten, (b) Realdaten

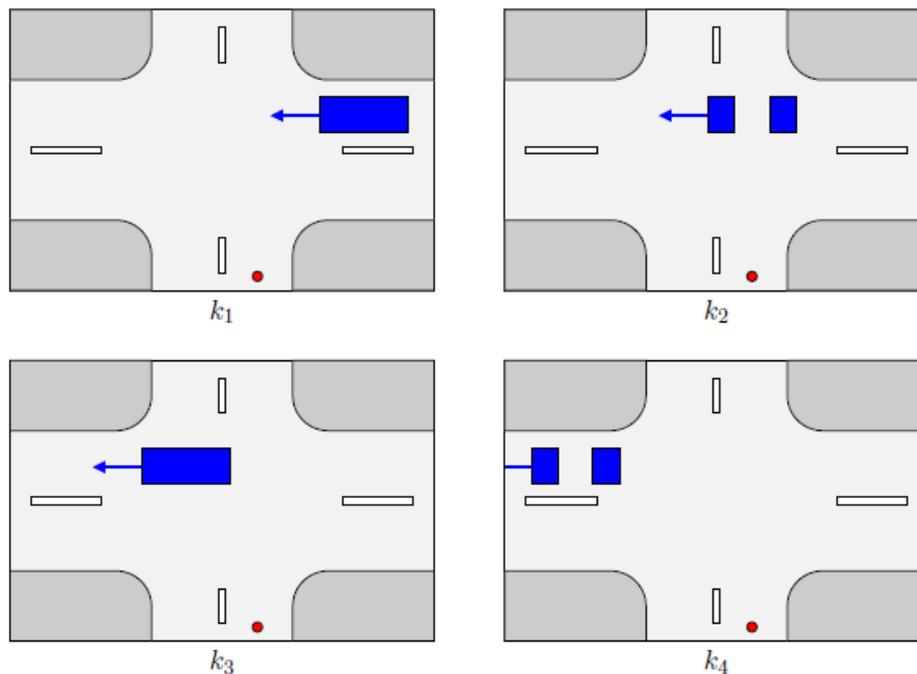
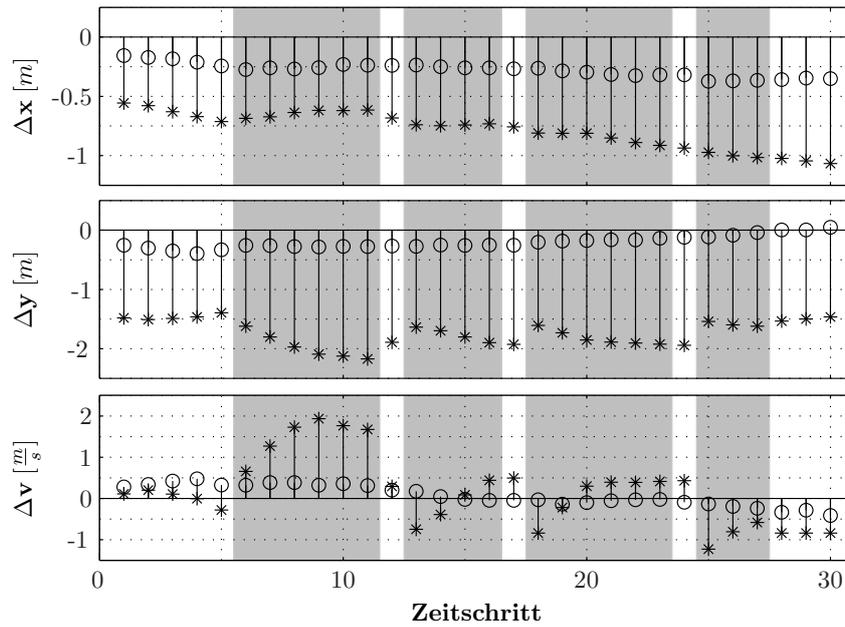


Abbildung 4.10: Szenario 2 mit zeitweise zerfallenem Segment

zu einem Zerfall in zwei Segmente. Die Position des Messfahrzeugs ist wiederum durch den roten Punkt gekennzeichnet. Objektzerfall stellt hier die zu evaluierende kritische Situation dar. Die Geschwindigkeit des Zielfahrzeugs beträgt zwischen $8 \frac{m}{s}$ und $14 \frac{m}{s}$, der Mittelpunkt der Kreuzung ist in etwa $15 m$ vom Sensor entfernt.

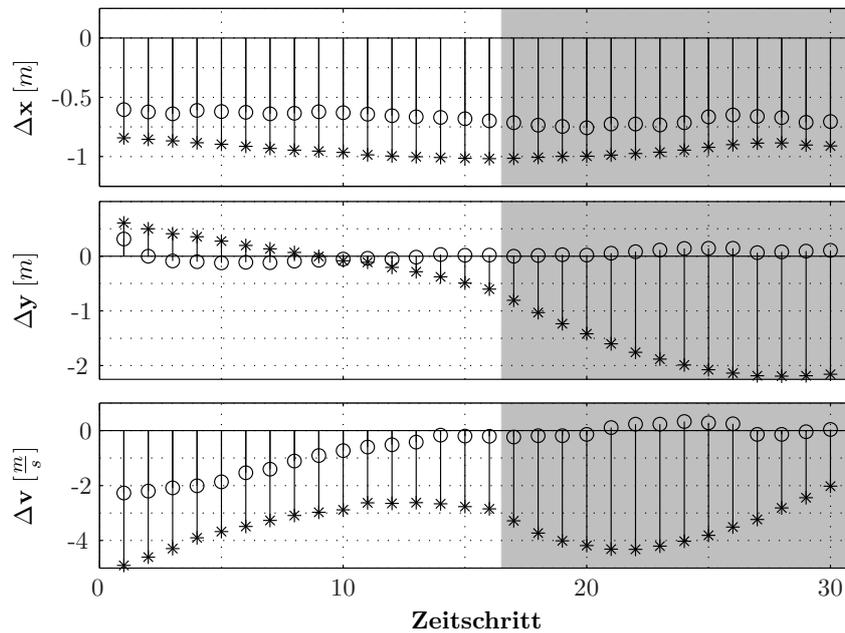
Die Ergebnisse auf der Basis von Szenario 2 für Simulation und reale Daten zeigt Abbildung 4.11. In der Simulation fährt das Zielfahrzeug mit $14 \frac{m}{s}$ über die Kreuzung. Über einen durch die Simulation gesteuerten Zufallsprozess zerfällt das Fahrzeug in zwei Segmente. System 1 setzt in der Zeit einen weiteren Track auf. Die Ergebnisse, die in Abbildung 4.11(a) aufgezeichnet sind, beziehen sich nur auf einen Track, der dem vorderen Teil des Fahrzeugs zugeordnet ist. Durch die sprungartige Änderung der Position kann keine stabile Geschwindigkeitsschätzung erfolgen. System 2 erkennt, dass beide Segmente zum selben Objekt gehören und fügt beide nach der Assoziation zusammen. Da die Breite des Fahrzeugs nicht vollständig erfasst wird, entsteht ein Offset in x-Richtung, der sich jedoch nicht negativ auf die Bestimmung der Geschwindigkeit auswirkt.

Das Szenario wurde in der Realität mit $8 \frac{m}{s}$ nachgefahren. Die Ergebnisse sind in Abbildung 4.11(b) aufgetragen. Wie zu erwarten ist, schafft es System 1 nicht, den Objektzerfall zu erkennen. Es entstehen die gleichen Fehler wie mit simulierten Daten. Da der Objektzerfall in der Realität nicht kontrolliert werden kann, tritt der Übergang nur einmal auf. Trotzdem ist zu erkennen, dass System 2 auch bei Realdaten mit dem Objektzerfall umgehen kann und dadurch ein stabiles Tracking erfolgt.



- * System 1
- System 2
- Cluster zerfallen

(a)



- * System 1
- System 2
- Cluster zerfallen

(b)

Abbildung 4.11: Szenario 2 - Differenz zum wahren Wert, (a) simulierte Daten, (b) Realdaten

5 Sensordatenfusion

In Kapitel 2.1 wurden die Stärken und Schwächen unterschiedlicher Sensoren zur Umgebungserfassung beleuchtet. Um unterschiedliche Stärken einzelner Sensoren zum Erzielen eines optimalen Ergebnisses zu nutzen, bietet es sich an, Sensordaten miteinander zu fusionieren. Dieses Kapitel beschreibt zunächst die theoretischen Konzepte der Sensordatenfusion und behandelt anschließend das Kernthema dieser Arbeit, die modellbasierte Fusion von Laserscanner- und Radardaten.

5.1 Grundlagen

5.1.1 Ziele der Sensorfusion

Sensorfusion bedeutet im Automobilbereich zunächst den Verbau mehrerer Sensoren im Fahrzeug und führt dadurch einerseits zu höheren Kosten und andererseits zu zusätzlichem Rechenaufwand. Demgegenüber stehen folgende Vorteile, die sich aus der Kombination mehrerer/unterschiedlicher Sensoren ergeben:

Gewinn an Genauigkeit bei der Schätzung von Objektparametern: Oftmals messen Sensoren die Parameter von Objekten mit unterschiedlicher Genauigkeit. Ein Beispiel hierfür ist die Monokamera, die die laterale Ablage von Objekten präzise bestimmen kann, während der Abstand zum Sensor mit größerer Unsicherheit belegt ist. Im Gegensatz dazu misst ein Radarsensor den Abstand sehr genau, während die Winkelbestimmung eher ungenau erfolgt. Unter der Voraussetzung einer idealen Zuordnung beider Messungen wird für das fusionierte Objekt eine hohe Genauigkeit in longitudinaler und lateraler Richtung erreicht.

Gewinn an Sicherheit/Konfidenz bezüglich Objekthypothesen: Bisher wurde nur die Aufenthaltswahrscheinlichkeit von Objekten betrachtet. Bedingt durch physikalische Phänomene kann es zur Detektion von Scheinzielen kommen, beispielsweise werden Abgase von Fahrzeugen oder Rauchsäulen aus Gullies bei niedriger Umgebungstemperatur von einem Laserscanner als Ziele ausgegeben. Neben der Aufenthaltswahrscheinlichkeit spielt daher die Auftrittswahrscheinlichkeit eine große Rolle für eine robuste Umgebungserfassung. Beim Objekttracking werden daher Absicherungsmaßnahmen gegen die Verfolgung von Scheinzielen vorgenommen. Dabei geht man meist davon aus, dass Scheinziele im Gegensatz zu echten Zielen sporadisch detektiert werden. Bei der Objektverwaltung innerhalb des Objekttrackings werden Objekte verworfen, die keine Messupdates

vom Sensor erhalten. Die Verwendung mehrerer Sensoren, die zu den Messupdates beitragen, erhöht hier die Robustheit.

Erweiterung des Messraums durch unterschiedliche Sensorprinzipien: Eine Erweiterung des Messraums erreicht man beispielsweise durch Kombination von rein entfernungs-messenden mit rein winkelmessenden Sensoren. Hier besteht die Herausforderung in der richtigen Zuordnung der Ziele zueinander bzw. zu den Objekten.

Erweiterung des Sichtbereiches: Ein weiteres Ziel der Kombination unterschiedlicher Sensoren besteht darin, den Detektionsbereich zu vergrößern, indem man Sensoren räumlich getrennt verbaut oder Sensoren mit unterschiedlichen Entfernungsbereichen und Öffnungswinkeln kombiniert.

Erhöhung der Zuverlässigkeit durch Redundanz: Einen wichtigen und hier bisher nicht betrachteten Punkt im automotiven Umfeld stellen Anforderungen bezüglich funktionaler Sicherheit dar. Sicherheitsapplikationen im Fahrzeug, die das Ziel haben, Insassen oder andere Verkehrsteilnehmer zu schützen, stellen nicht nur Anforderungen an die Genauigkeit sondern auch an die Zuverlässigkeit solcher Systeme und ihrer Komponenten. Durch Verwendung mehrerer Sensoren können Ausfälle einzelner Sensoren kompensiert oder zumindest ein gewisses Maß an Funktionalität sichergestellt werden.

5.1.2 Fusionsarchitekturen und -konzepte

In der Literatur werden unterschiedliche Einteilungen von Fusionssystemen getroffen, basierend auf den betrachteten Aspekten der beteiligten Sensoren und Verarbeitungsmodule [HL97, BI98, Das97, DW88, RL07, ESW⁺05]. Mögliche Einteilungen sind dabei:

Einteilung nach Abstraktionsebene der Datenverarbeitung:

- **Fusion auf Signalebene:** Hierbei werden Rohdaten bzw. minimal vorverarbeitete Daten miteinander verknüpft. Die Vorverarbeitung könnte beispielsweise ein Filter zur Rauschunterdrückung sein. Die Fusion findet zu einem frühen Zeitpunkt in der Verarbeitungskette statt.
- **Fusion auf Merkmalebene:** Hier werden aus den Rohdaten extrahierte Merkmale im Fusionsmodul miteinander kombiniert. Die Fusion findet also bereits auf einer höheren Abstraktionsebene statt und erlaubt es, Daten von Sensoren, die unterschiedliche physikalische Effekte messen, im Messvektor zusammenzuführen. Ein Beispiel hierfür wäre eine Fusion von Laserscannersegmenten mit extrahierten Kanten aus Videobildern.
- **Fusion auf Objektebene:** Bei dieser Fusionsart durchlaufen die jeweiligen Eingangsdaten zunächst getrennt die gesamte Verarbeitungskette und werden dann auf Objektebene einem zentralen Entscheidungsmodul zugeführt. Man findet daher auch den Begriff *Fusion auf Entscheidungsebene* für diese späte Fusion. Eine mögliche Implementierung ist die sogenannte *Track-to-Track-Fusion*, bei der die Trajektorien von Objekten, die von unterschiedlichen Sensoren stammen, miteinander verknüpft werden.

Einteilung hinsichtlich Interaktion der Sensoren:

- **komplementäre Fusion:** Bei der komplementären Fusion werden Daten verknüpft, die von unabhängigen Sensoren stammen, die jeweils disjunkte räumliche oder zeitliche Bereiche erfassen, um so die Information zu vervollständigen. Beispiele sind Sensoren, die unterschiedliche Sichtbereiche abdecken oder zu unterschiedlichen Zeitpunkten messen.
- **konkurrierende Fusion:** Bei der Abdeckung gleicher Sichtbereiche und Perzeption derselben Umfeldinformationen durch mehrere Sensoren können die Messwerte kongruieren oder divergieren und stehen damit in Konkurrenz. Durch eine geeignete Verknüpfung der Einzelwerte wird eine Vereinheitlichung erreicht, die dem wahren Wert am nächsten kommt.
- **kooperative Fusion:** Bei der kooperativen Fusion wird die Information aus dem Zusammenschluss mehrerer Einzelsensoren generiert, die jeder für sich genommen nur einen Teilaspekt messen, vergleichbar mit einem Puzzle, das aus mehreren Einzelteilen besteht und zusammengesetzt ein Bild ergibt. Anders als bei der konkurrierenden Fusion besteht hier keine Redundanz, sodass sich Einzelfehler stärker auf das Gesamtergebnis auswirken

Je nach Anzahl und Art der Sensoren und der Plattform für die Implementierung können Mischformen der hier aufgezeigten Fusionsmethoden vorkommen. Die Wahl des optimalen Fusionskonzeptes hängt von einer Reihe von Faktoren ab wie der zu erzielenden Systemperformance, Anforderungen an redundante Systemauslegung oder dem Ressourcenbedarf. Eine frühe Fusion auf Signal- oder Merkmalsebene stellt eine effektivere Nutzung der Information dar, braucht jedoch mehr Ressourcen für Berechnung und Datenübertragung. Eine späte Fusion erleichtert die Implementierung eines generischen Fusionsmoduls, das eine flexible Anbindung unterschiedlicher Sensoren erlaubt. Die Informationen werden hier über eine definierte Objektschnittstelle übertragen, die Objektbildung kann durch entsprechende Hardware im Sensor selbst oder durch dem Fusionsmodul vorgeschaltete Verarbeitungsmodule realisiert werden.

5.1.3 Randbedingungen und Synchronisationsaspekte

Bei der Verwendung mehrerer Sensoren können unterschiedliche Zykluszeiten sowie unterschiedliche Latenzen auftreten. Zusätzlich zu den Messtoleranzen der einzelnen Sensoren müssen also auch zeitliche Aspekte berücksichtigt werden. Dies sind zum einen Asynchronität, das heißt Sensoren senden ihre Daten mit unterschiedlichen Raten, die zudem nicht notwendigerweise Vielfache voneinander sein müssen, und zum anderen Nichtsequentialität (*engl. Out-of-sequence*), die beispielsweise durch unterschiedliche Zeitdauern für die sensorinterne Signalverarbeitung entstehen kann. Angenommen zwei Sensoren senden ihre Ziellisten mit einer Updaterate von 40 ms, Sensor 1 braucht für die interne Signalverarbeitung einen Zyklus an Verarbeitungszeit, Sensor 2 benötigt zwei Zyklen. Selbst wenn die Messdaten synchron am Fusionsmodul ankommen, ist die Beobachtung von Sensor 2 bereits einen Messzeitpunkt älter als die von Sensor 1.

Konzepte zum Umgang mit asynchronen und nichtsequentiell eintreffenden Messdaten sind Pufferung, Reprocessing sowie Retrodiktion. *Pufferung* stellt die algorithmisch einfachste Lö-

sung dar. Hierbei werden die eintreffenden Daten zunächst mit einem (gegebenenfalls korrigierten) Zeitstempel versehen in eine Warteschlange eingereiht, um anschließend in der richtigen Reihenfolge verarbeitet zu werden. Der Nachteil dieses Verfahrens liegt in der Verzögerung, die dabei entsteht, dass jeweils auf den Sensor mit der längsten Zykluszeit gewartet wird, während von anderen Sensoren eventuell schon aktuellere Daten zur Verfügung stünden. Die Verzögerung wird noch größer, wenn der langsamste Sensor zusätzlich eine große Latenz aufweist. Beim *Reprocessing* wird jeweils die aktuell eintreffende Messung sofort verarbeitet. Zusätzlich findet auch hier eine Pufferung der Messdaten statt. Ist die zeitliche Reihenfolge nicht korrekt, das heißt wäre die aktuell eintreffende Messung bereits zu einem früheren Zeitpunkt zu verarbeiten gewesen, kehrt man zu diesem Punkt zurück und führt die Berechnungen nochmals in der korrekten zeitlichen Reihenfolge aus. Der Vorteil dieses Verfahrens liegt in der Aktualität der Ausgabe zu jedem Zeitpunkt jeweils auf Basis aller bis dahin verfügbaren Daten. Er wird erkauft durch einen höheren Aufwand für (Neu-)Berechnung und Speicherung. *Retrodiktion* ist das komplexeste der drei Verfahren. Auch hier werden die Messungen jeweils aktuell zur Zeit des Eintreffens verarbeitet. Anstatt einer kompletten Neuberechnung wird hier allerdings eine „Prädiktion“ des aktuellen Zustands in die Vergangenheit, also eine Retrodiktion, vorgenommen. Die Messung wird so zum korrekten Zeitpunkt verarbeitet unter Beibehaltung aller bisher durchgeführten Messungen und Messupdates. Zur Theorie der Redrodiktion sei auf [BS02] verwiesen. Zur Vereinfachung wurde hier mit einer Pufferung der Daten gearbeitet, umfassende Untersuchungen zu allen drei Verfahren basierend auf demselben Sensor-Setup wie in dieser Arbeit beschrieben, wurden in [MSZD09] dokumentiert.

5.2 Fusion von ausgedehnten Zielen mit Punktziele

5.2.1 Vorbemerkungen zum Fusionskonzept

Wie in Kapitel 5.1.2 beschrieben, existieren verschiedene Möglichkeiten, um die Daten von Sensoren mit überlappenden Sichtbereichen zu fusionieren. Für die in dieser Arbeit verwendeten Radar- und Lasersensoren käme prinzipiell eine Fusion auf Merkmalsebene als auch auf Objektebene in Frage. Eine Fusion auf Signalebene scheidet aufgrund der unterschiedlichen Sensorprinzipien und der damit verbundenen Inhomogenität der Rohdaten aus. Die Fusion auf Merkmalsebene ist besonders geeignet, die Vorteile der einzelnen Sensoren bereits in der Trackingstufe zu nutzen.

Bei der Fusion auf Merkmalsebene werden vorverarbeitete Daten miteinander kombiniert. Die Kombination kann dabei am Trackereingang in Form einer *Messvektorfusion* stattfinden oder innerhalb des Trackers als *sequentielles Update* ausgeführt werden. Bei der Messvektorfusion werden die Einzelmessungen $\mathbf{z}_{k,i}$ der n Sensoren zum Zeitpunkt k gewichtet zu einer Messung \mathbf{z}_k aufaddiert, bevor sie Eingang in den Tracker finden. Die Gewichte werden anhand der zugeordneten Messunsicherheiten \mathbf{R}_i gewählt.

$$\mathbf{z}_k = \sum_{i=1}^n \frac{\mathbf{R}_i}{\sum^n \mathbf{R}_n} \cdot \mathbf{z}_{k,i} \quad (5.1)$$

Die kombinierte Messfehlerkovarianz ergibt sich zu:

$$\mathbf{R} = \frac{\prod^n \mathbf{R}_n}{\sum^n \mathbf{R}_n} \quad (5.2)$$

Das Verfahren ist nur bei gleichartigen Messvektoren anwendbar. Eine andere Möglichkeit besteht darin, die vorverarbeiteten Messdaten innerhalb des Kalman-Filters zu fusionieren. Diese Methode eignet sich vor allem bei asynchron eintreffenden Messungen der einzelnen Sensoren oder bei unterschiedlichen Messgleichungen. Treffen Messungen zu unterschiedlichen Zeitpunkten ein, wird der Kalman-Filter-Zyklus sequentiell zu jedem Messzeitpunkt durchlaufen. Auch für gleichzeitig eintreffende Messungen ist eine sequentielle Verarbeitung möglich. Hierbei wird der Prädiktionsschritt nur einmal ausgeführt. Datenassoziation und Messupdate werden nacheinander für jeden Sensor vollzogen. Im Ergebnis der a-posteriori-Schätzung des Zustandes und der Unsicherheiten unterscheiden sich Messvektorfusion und sequentielles Update im mathematischen Sinn nicht. In der Praxis muss auf eine numerisch stabile Implementierung geachtet werden, da beim sequentiellen Update das Messupdate, welches Matrixdivisionen beinhaltet, mehrfach aufgerufen wird. Die sequentielle Verarbeitung im Kalman-Filter erfordert einen etwas höheren Rechenaufwand als die Kombination der Messungen im Vorfeld. Da sich bei der in dieser Arbeit entwickelten Fusionsmethode die Bezugspunkte eines Objektes unter Anwendung des Reflexionsmodells ändern, ist es einfacher, mit dem sequentiellen Messupdate zu arbeiten. Im Weiteren stützen sich die vorgestellten Verfahren daher auf diesen Ansatz.

5.2.2 Radarreflexionsmodelle an Fahrzeugen

Eine etablierte Methode, Punktziele und ausgedehnte Ziele miteinander zu fusionieren, basiert auf der Annahme, dass der das Punktziel erzeugende Sensor höchstens ein Streuzentrum auf jeweils einem ausgedehnten Objekt besitzt, und dieses an der dem Sensor nächsten Stelle auf dem Objekt lokalisiert ist. Die Realisierung einer Messvektorfusion beinhaltet dann die Verschiebung des Referenzpunktes des ausgedehnten Objektes auf das errechnete Streuzentrum, die Verknüpfung der Messungen der verschiedenen Sensoren zu einem kombinierten Messwert bzw. Messvektor und die anschließende Rückverschiebung um den anfänglich benutzten Verschiebungsvektor. Das Prinzip ist in Abbildung 5.1 anhand von Laserscanner- und Radardaten illustriert.

Das Laserscanner-Ziel ist hier durch das die Messpunkte umgebende Rechteck sowie dessen Mittelpunkt (schwarz umrandetes Rechteck) repräsentiert. Das Radar-Reflexionszentrum wird auf dem nächsten Eckpunkt zum Scanner (ausgefülltes schwarzes Rechteck) angenommen. Der Mittelpunkt des Laserzieles wird zunächst auf den Eckpunkt verschoben (durchgezogener

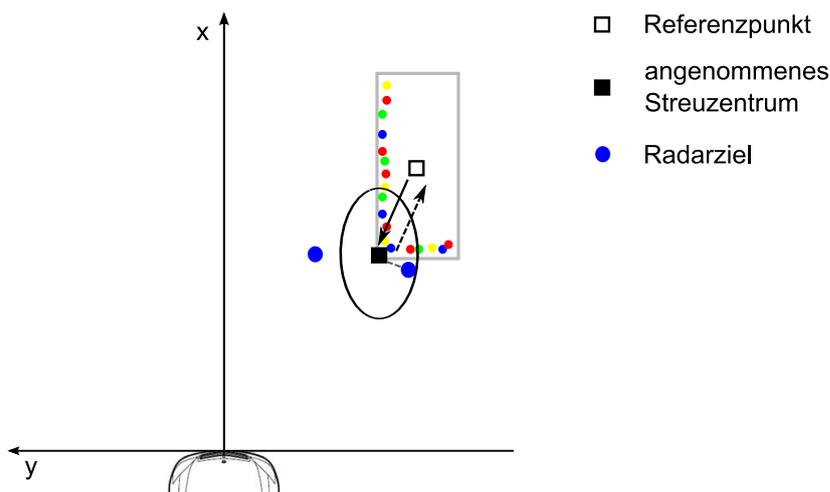


Abbildung 5.1: Fusion von Punkt- und ausgedehnten Zielen unter Annahme eines einzelnen Streuzentrums

Pfeil), wo eine Assoziation von Radarziel(en) zum Laserziel stattfindet (schematisch dargestellt durch den elliptischen Suchbereich). Die einander zugeordneten Messwerte werden anschließend zu einer Positionsmessung fusioniert und rücktransformiert (gestrichelter Pfeil). Der fusionierte Messvektor bildet die Eingabe für den Tracker. Anwendungen der beschriebenen Methode finden sich zum Beispiel in [WDC⁺08] und [SLAW05].

Diese stark vereinfachende Annahme ist zumeist ausreichend für die Verfolgung vorausfahrender Fahrzeuge insbesondere auf Autobahnen, wo Objekte in größerer Distanz erfasst werden. Für den Kreuzungsbereich mit querenden und abbiegenden Fahrzeugen, die sich eher im Nahbereich bewegen, ist diese Modellierung nicht zweckmäßig, wie Abbildung 5.2 verdeutlicht. Abhängig vom Auflösungsvermögen des Radarsensors können mehrere Ziele für ein reales Fahrzeug geliefert werden. Diese müssen zudem nicht notwendigerweise durch Reflexion an den Fahrzeugecken entstanden sein. Gute Reflektoren sind beispielsweise auch Radkästen oder Teile der Karosserie. Im hier gezeigten Beispiel des querenden Fahrzeugs führt die Annahme, die Radarreflexion stamme von der nächstgelegenen Fahrzeugecke zu einer Verschiebung des Referenzpunktes entgegen der Fahrtrichtung und damit zu einer verminderten Geschwindigkeitsschätzung. Das Ziel dieser Arbeit ist es, die vereinfachende Annahme über Streuzentren durch die Anwendung realistischer Modelle des tatsächlichen Reflexionsverhaltens zu ersetzen, um ein gutes Schätzergebnis unabhängig von der konkreten Fahrsituation zu erhalten.

Die Arbeiten von Karin Schuler [Sch07] und Markus Bühren [Büh08] beinhalten komplexe Analysen und realistische Modellierungen des Reflexionsverhaltens von Radarwellen an Fahrzeugen. Die Motivation zur Erstellung solcher Modelle liegt darin, eine Grundlage für realitätsnahe Simulationen zu Evaluierungszwecken zu schaffen. Bei Schuler ist der Hintergrund die Evaluierung eines Sensors bzw. einer Antennenkonfiguration, Bühren generiert mit Hilfe des Reflexionsmodells synthetische Ziellisten zum Testen von Tracking-Algorithmen.

Abbildung 5.3 zeigt die beiden Radarreflexionsmodelle. Das Modell 1 von Schuler (Abb. 5.3(a))

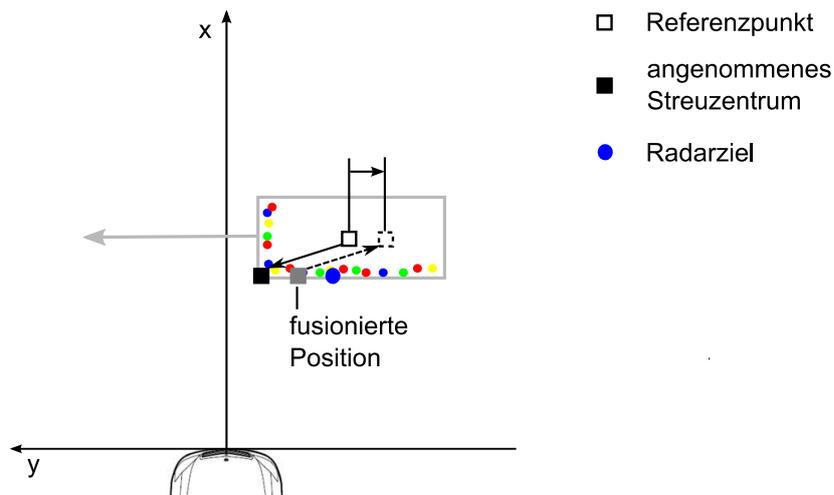
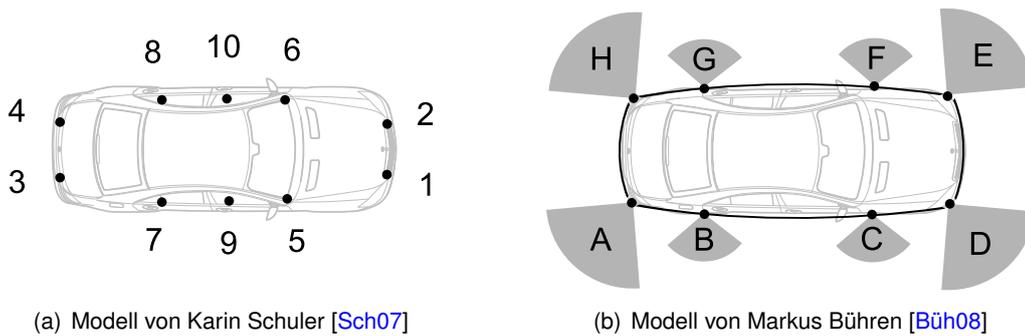


Abbildung 5.2: Verfälschung der Schätzung für querende Fahrzeuge durch unzureichende Modellierung der Radar-Reflexionszentren



(a) Modell von Karin Schuler [Sch07]

(b) Modell von Markus Bühren [Büh08]

Abbildung 5.3: Radarreflexionsmodelle an Fahrzeugen

beinhaltet zehn virtuelle Streuzentren, die mit Hilfe einer Ray-Tracing-Simulation anhand eines konkreten Fahrzeugmodells mit anschließender Clusterung der einzelnen Streuzentren aus den betrachteten Strahlen erzeugt wurden. Bei der Ray-Tracing-Simulation wurden Kombinationen aus Mehrfachreflexion, Beugung und Streuung berücksichtigt. Modell 2 von Bühren (Abb. 5.3(b)) besteht aus acht Punktreflektoren, die jeweils an den Fahrzeugecken und in Höhe der Radkästen lokalisiert sind, und vier konvexen Flächenreflektoren, die die Fahrzeugseiten sowie Front und Heck umspannen. Diese Aufteilung basiert auf der Analyse realer Ziellisten, die mithilfe von Automobilradaren in verschiedenen Konstellationen von Sensor- und Zielfahrzeug aufgenommen wurden. Für die modellbasierte Datenfusion in der vorliegenden Arbeit wird Modell 2 benutzt, da es ein allgemeines Fahrzeugmodell beschreibt und nicht aus einem bestimmten Fahrzeugtyp abgeleitet wurde, wie dies bei Modell 1 der Fall ist. Zudem ist das Modell skalierbar, was eine Anpassung auf die aus den Laserdaten erzeugten Objekthypothesen ermöglicht.

Die Reflektoren, aus denen das Modell zusammengesetzt ist, werden durch drei Parameter beschrieben: ihre Position innerhalb des Objektmodells, den Sichtbereich, in dem sie detektierbar

sind, und den relativen Rückstreuquerschnitt (ERCS, engl. *Equivalent Radar Cross Section*), der als Maß für die zu erwartende rückgestreute Energie dient. Die Fahrzeugecken sind dabei stärkere Reflektoren als die Radkästen, was durch das Größenverhältnis der Sichtbereiche um die Reflektoren {A,D,E,H} und {B,C,F,G} in Abbildung 5.3(b) ausgedrückt wird (schematisch, nicht maßstabsgetreu). In [Büh08] werden Belegungen der ERCS-Werte für zwei konkrete Fahrzeuge, einen Opel Vectra und einen VW Golf, angegeben. Um unabhängig von einem speziellen Fahrzeug zu sein, wird in dieser Arbeit die allgemeine Belegung der relativen Rückstreuquerschnitte nach Bühren und Yang [BY06] verwendet. Der relative Rückstreuquerschnitt stellt eine Abstraktion vom (absoluten) Radarrückstreuquerschnitt dar, der als Flächenmaß die von einem Radarziel zurückgestreute Leistung zur einfallenden Leistungsdichte in Beziehung setzt. Er ist abhängig von der Größe und Beschaffenheit (Form und Material) des Zieles, dem Aspektwinkel sowie der verwendeten Wellenlänge. Die Sichtbereiche der Punktreflektoren sind jeweils als Kreissegmente um den Haupteinfallswinkel modelliert. Die Flächenreflektoren werden durch Kreisbögen repräsentiert, die an den Fahrzeugecken durch die Punktstreuer begrenzt werden. Der Reflexionspunkt, sofern er existiert, ergibt sich aus dem Schnittpunkt der Sichtlinie vom Sensor zum Kreismittelpunkt mit dem Kreisbogen, und ist damit nicht fix bezogen auf das zugrundeliegende Fahrzeugmodell, sondern kann über mehrere Zeitschritte betrachtet auf der Fahrzeugkontur „wandern“, was dem realen Verhalten bei einer Quervorbeifahrt entspricht.

5.2.3 Umsetzung der modellgestützten Fusion

Da sich die Streuzentren des Radarreflexionsmodells auf die Ausmaße des erfassten Fahrzeuges beziehen, müssen diese initial bekannt sein. Die aus den Laserrohdaten berechneten Segmente dienen hier als Vorsteuerung. Anhand der ermittelten Ausdehnung und Orientierung wird die Lage der für den Radarsensor sichtbaren Streuzentren ermittelt, wie in Abbildung 5.4 zu sehen. Für Segmente, deren Ausdehnung zu klein ist, wird kein Fahrzeugmodell angewendet, sondern nur ein einzelner Punktreфлектор angenommen. Umgekehrt werden Segmente, deren Ausmaße die eines Fahrzeuges übersteigen, ebenfalls nicht durch das Reflexionsmodell abgebildet, sondern nach der in Kapitel 5.2.2 beschriebenen Methode fusioniert. In Zukunft könnten hier weitere Reflexionsmodelle beispielsweise für Busse oder LKWs entwickelt werden.

Das Reflexionsmodell ist, wie in Abbildung 5.3(b) gezeigt, symmetrisch, das bedeutet, die Abstände zwischen Front und Vorderachse sowie zwischen Hinterachse und Heck werden als identisch angenommen, was eine Approximation realer Fahrzeuggeometrien darstellt. Nimmt man die Bewegungsrichtung der Laserobjekte hinzu, um Vorder- und Rückseite zu unterscheiden, können auch nichtsymmetrische Modelle betrachtet werden. Stünden in einem Sensorfusionssystem bildgebende Sensoren zur Verfügung, könnte das Modell sogar individuell für das jeweils detektierte Objekt angepasst werden. Durch eine Raddetektion im Videobild könnten beispielsweise die Reflektoren der Radkästen direkt positioniert werden.

Neben der Position in Fahrzeugkoordinaten wird für jedes sichtbare Streuzentrum ein Gewichtungsfaktor bestimmt, der sich aus dem ERCS-Wert des Reflektors und einem Sichtbarkeitsmaß zusammensetzt. Wie in [Büh08] beschrieben, werden die Sichtbereiche der Punktstreu-

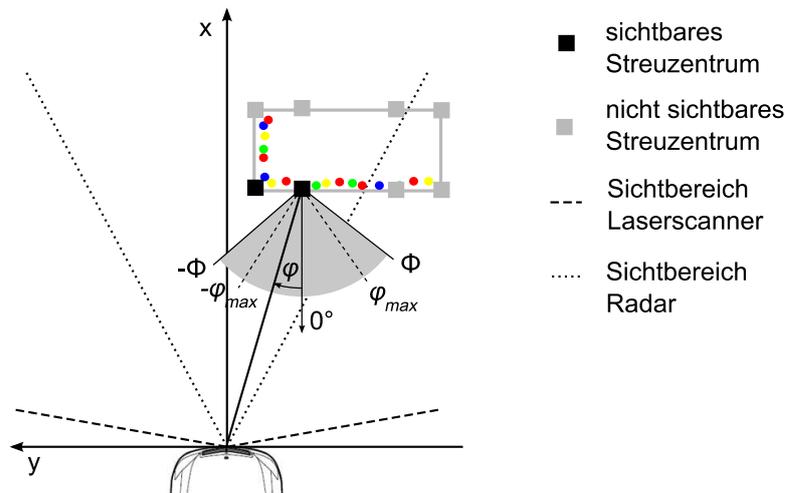


Abbildung 5.4: Anwendung des erweiterten Radarreflexionsmodells

zentren nicht als scharf abgegrenzt modelliert, sondern durch eine zu den Rändern hin cosinusförmig abfallende Funktion des Einfallswinkels ausgedrückt. Der Gewichtungsfaktor w_{rc} eines Streuzentrums rc berechnet sich abhängig vom Einfallswinkel φ zu

$$w_{rc}(\varphi) = ERCS_{rc} \cdot \begin{cases} 1 & \text{für } rc \in \text{Flächenreflektoren} \\ f_{rc}^{vis}(\varphi) & \text{für } rc \in \text{Punktreflektoren} \end{cases} \quad (5.3)$$

wobei f_{rc}^{vis} für die Sichtbarkeitsfunktion steht, die wie folgt definiert ist:

$$f_{rc}^{vis}(\varphi) = \begin{cases} 1 & \text{für } |\varphi| < \frac{1}{2}\varphi_{max} \\ 0 & \text{für } |\varphi| > \frac{1}{2}\Phi \\ \frac{1}{2} \left(1 + \cos \left(2\pi \frac{|\varphi| - \frac{1}{2}\varphi_{max}}{\Phi - \varphi_{max}} \right) \right) & \text{sonst.} \end{cases} \quad (5.4)$$

Hierbei bezeichnet Φ die Grenze des Detektionsbereichs, φ_{max} begrenzt den Bereich, in dem der relative Rückstreuquerschnitt sein Maximum annimmt. Zur Vereinfachung wurde φ aus Sicht des Reflektors dargestellt. Eine Umrechnung in Objektkoordinaten ist leicht möglich. In Abbildung 5.4 sind die Größen exemplarisch für ein Reflektionszentrum gezeigt.

Die Fusion mit den Radardaten kann unimodal oder multimodal erfolgen. Bei der unimodalen Fusion wird ein virtuelles Streuzentrum aus der Summe der als sichtbar erkannten Streuzentren unter Einbeziehung ihrer jeweiligen Gewichtung gebildet, und dieses wie in Kapitel 5.2.2 beschrieben zur Fusion im Filter benutzt. Bei der multimodalen Fusion werden die sichtbaren Streuzentren getrennt betrachtet, das bedeutet, jedem sichtbaren Streuzentrum können zum aktuellen Messzeitpunkt entsprechende Radarziele zugeordnet werden. Für die weitere Verarbeitung ergeben sich zwei Möglichkeiten:

- (sequentielle) Verarbeitung der Informationen aller Streuzentren mit zugeordneten Radarmessungen

- Verwendung der Radarmessung des am höchsten gewichteten Streuzentrums

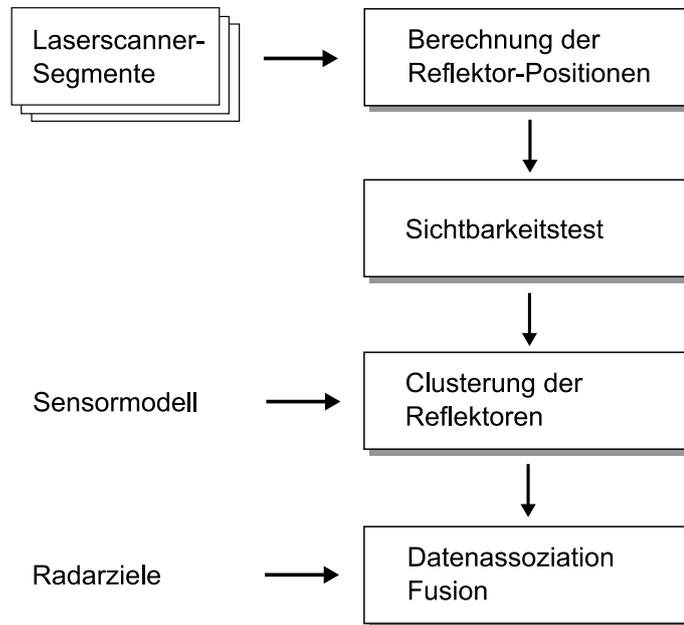


Abbildung 5.5: Flussdiagramm zur modellbasierten Fusion von Laserscanner- und Radarzielen

Eine Zuordnung zu getrennten Streuzentren sollte allerdings nur erfolgen, wenn dies die Auflösung des Sensors erlaubt. Entsprechend der vom Radar gemessenen Dimensionen Entfernung r , Azimut φ und Radialgeschwindigkeit \dot{r} ergeben sich Auflösungszellen $(\Delta r, \Delta \varphi, \Delta \dot{r})$ gemäß dem Auflösungsvermögen des Sensors in der jeweiligen Dimension. Fallen zwei Streuzentren in dieselbe Auflösungszelle, d.h. können sie in keiner Dimension getrennt werden, werden sie zu einem Streuzentrum kombiniert. Ob zwei Streuzentren dieselbe Zelle $(\Delta r, \Delta \varphi, \infty)$ teilen, kann direkt über ihre Positionen und das Sensormodell bestimmt werden. Ob sie darüber hinaus in der Geschwindigkeitskomponente getrennt werden können, hängt zusätzlich von der Geschwindigkeit und der Bewegungsrichtung des Zielobjekts ab. Betrachtungen zur Dopplergeschwindigkeit werden in Kapitel 5.2.4 gemacht. Der Algorithmus zur Clustering von Reflektoren lautet wie folgt:

1. Finde den stärksten Reflektor aus der Menge der Reflektoren
2. Suche nach benachbarten Reflektoren, die in die gleiche Auflösungszelle fallen, bilde ein Cluster und entferne geclusterte Reflektoren aus der Menge verbleibender Reflektoren
3. Wiederhole Schritt 1 und 2, bis keine weiteren Reflektoren übrig sind

Innerhalb eines Clusters l werden die n Reflektorpositionen $\mathbf{p}_{rc,i}$ gewichtet zu einem gemeinsamen Streuzentrum \mathbf{p}_{rc}^c addiert. die Gewichte $w_{rc,i}$ werden anhand der Intensität der Reflexion bestimmt.

$$\mathbf{p}_{rc}^c = \sum_{i=1}^n w_{rc,i} \mathbf{p}_{rc,i}, \quad w_{rc,i} = \frac{ERCS_{rc,i}}{\sum_{j=1}^n ERCS_{rc,j}} \quad (5.5)$$

Die einzelnen Schritte der modellbasierten Fusion fasst Abbildung 5.5 zusammen.

5.2.4 Nutzung der Doppler-Geschwindigkeit

Die vom Radarsensor gelieferten Messwerte umfassen neben Entfernung und Winkel eines Zieles zum Sensor auch dessen radiale Geschwindigkeit, das heißt, die Geschwindigkeitskomponente in Blickrichtung des Sensors. Abbildung 5.6(a) verdeutlicht die Zusammenhänge. Zur Vereinfachung ist das vom Sensor erfasste Ziel als Punktziel dargestellt. Es befindet sich an der Position x_{obj}, y_{obj} und bewegt sich in Richtung des Vektors \vec{v}_{obj} mit der Geschwindigkeit $|\vec{v}_{obj}|$. Die Doppler-Geschwindigkeit, dargestellt in cyan, wird wie folgt berechnet:

$$v_{doppler} = |\vec{v}_{obj}| \cdot \cos(\beta) \quad (5.6)$$

Dabei bezeichnet β den zwischen dem Beobachtungswinkel des Sensors und der Bewegungsrichtung des Objekts eingeschlossenen Winkel. Eine eindeutige Zuordnung zwischen Doppler- und Objektgeschwindigkeit kann nur getroffen werden, wenn die Bewegungsrichtung des Objektes bekannt und damit β geschätzt werden kann. Abbildung 5.6(b) illustriert die Mehrdeutigkeit anhand beispielhafter Geschwindigkeitsvektoren, also Kombinationen aus Objektgeschwindigkeit und Bewegungsrichtung, die auf dieselbe Doppler-Geschwindigkeit abbilden.

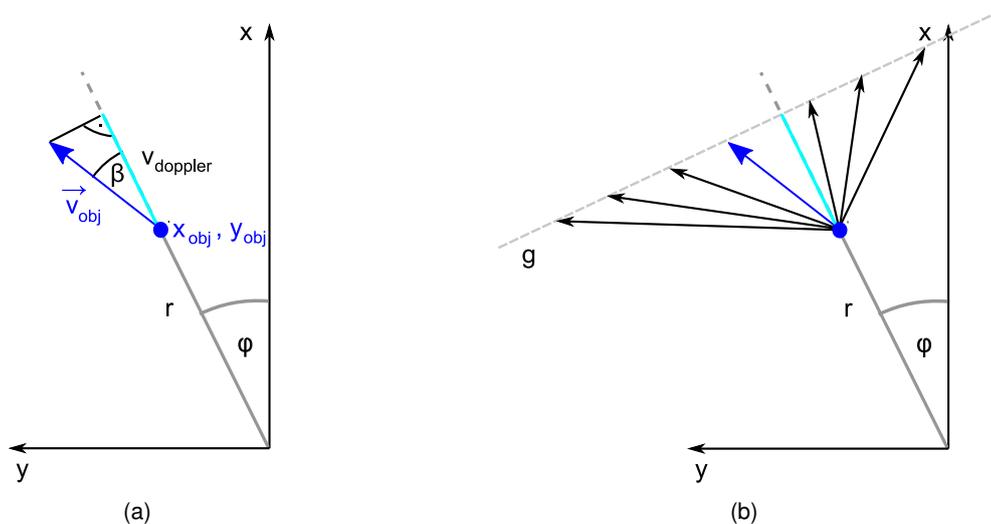


Abbildung 5.6: Zusammenhang zwischen radialer Geschwindigkeit und Objekt-Geschwindigkeit (a), Mehrdeutigkeit der Doppler-Geschwindigkeit (b)

Aufgrund dieser Zusammenhänge und der sich ergebenden Nichtlinearität der Messgleichung wird die Doppler-Geschwindigkeit häufig nicht als direkte Messgröße im Tracker benutzt, sondern zur Initialisierung der Geschwindigkeit herangezogen, um ein schnelleres Einschwingen des Trackers zu erreichen [MZD09] [YKBS04]. Eine weitere Anwendung findet sich bei der Manövererkennung [RCLC05] [BB04].

Integration der Radialgeschwindigkeit in den Kalman-Filter

In Kapitel 4.2.1 wurde im Zusammenhang mit dem Bewegungsmodell konstanter Geschwindigkeit ein Messmodell vorgestellt, das die Objektgeschwindigkeit als Eingabe beinhaltet. Dieses berücksichtigt jedoch nicht die Orientierung des Zieles sondern nur den Aspektwinkel, wie aus folgender Umformung von Gleichung 4.22 hervorgeht:

$$\dot{r}_z = \frac{x\dot{x} + y\dot{y}}{\sqrt{x^2 + y^2}} \quad (5.7)$$

$$= \frac{x\dot{x}}{\sqrt{x^2 + y^2}} + \frac{y\dot{y}}{\sqrt{x^2 + y^2}} \quad (5.8)$$

$$= \cos(\varphi)\dot{x} + \sin(\varphi)\dot{y} \quad (5.9)$$

Um ausgehend von der Doppler-Geschwindigkeit auf die Geschwindigkeit des Objekts schließen zu können, bedarf es also der Information über den Aspektwinkel φ , die direkt aus der Radarmessung zu beziehen ist sowie der Objektorientierung ψ , die aus dem Laserscannersegment bestimmt werden kann. Aus diesen beiden Größen kann der Winkel β zwischen Blickrichtung des Sensors und Bewegungsrichtung des Objekts bestimmt werden.

$$v_{obj} = \frac{v_{doppler}}{\cos(\varphi + \psi)} \quad (5.10)$$

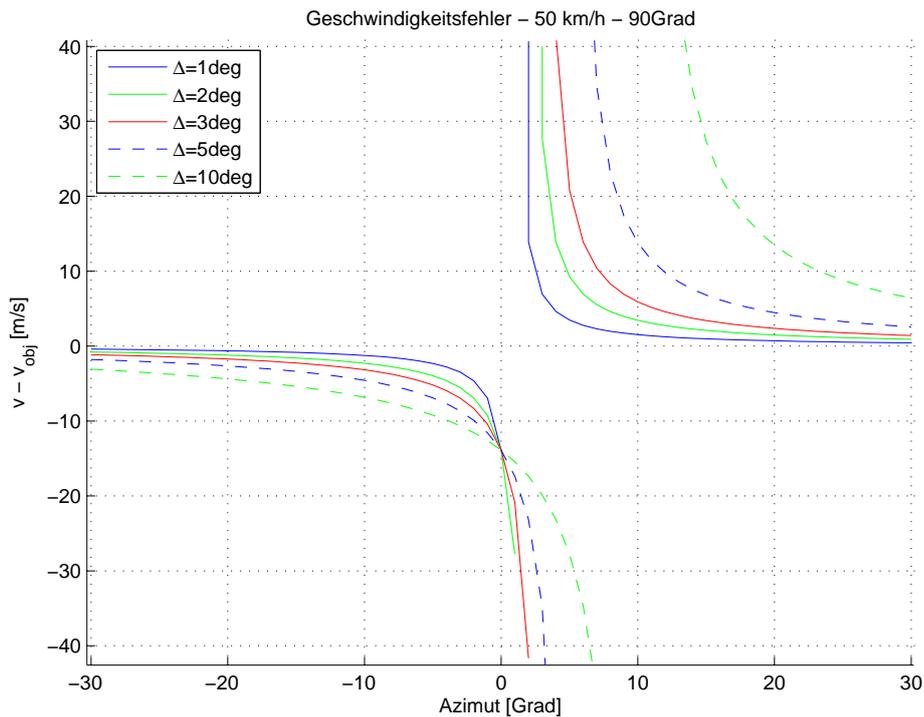
Punkte nichtvorhandener Beobachtbarkeit

Wie dem Nenner in Gleichung 5.10 zu entnehmen ist, entstehen Unstetigkeitsstellen, wenn der Aspektwinkel und die Objektorientierung senkrecht zueinander stehen. Die tatsächliche Geschwindigkeit des Zieles wird an diesen Punkten auf eine Radialgeschwindigkeit von $0 \frac{m}{s}$ abgebildet. Umgekehrt ist es nicht möglich, bei einer solchen Konstellation auf die Geschwindigkeit des Objektes rückzuschließen.

Bei der Umsetzung im Tracker kann das Problem abgemildert werden, indem adaptiv das Messrauschen für die Doppler-Komponente erhöht wird, wenn eine solche Situation eintritt. Bei einer geraden Fahrt des Zieles in einem bestimmten Winkel zum Sensorfahrzeug betrifft das nur eine kurze Zeitdauer. Anders verhält es sich, wenn sich das Ziel auf einer Kreisbahn um das Sensorfahrzeug bewegt. In diesem Fall entspricht der Bewegungsvektor des Objektes in jedem Zeitschritt einer Tangente an den Kreis, die immer normal zur Sensorblickrichtung verläuft. Damit ist die radiale Geschwindigkeitskomponente konstant $0 \frac{m}{s}$.

Unsicherheit von β und Fehlerabschätzung

Wie schon beschrieben, gilt Gleichung 5.10 nur für $\varphi + \psi \neq n\frac{\pi}{2}$. Was bei links- und rechtsseitiger Annäherung passiert, illustriert Abbildung 5.7

Abbildung 5.7: Geschwindigkeitsabweichungen bei Offset-Fehlern in β

5.3 Bewertung des Fusionssystems

5.3.1 Testverfahren und Testszenarien

Die Güte des entwickelten Fusionsansatzes wird anhand von Daten aus real gefahrenen Fahrmanövern bewertet. Der Manöverkatalog enthält sowohl Szenarien, die auch im realen Straßenverkehr vorkommen (z.B. verschiedene Kreuzungsszenen), als auch Szenarien, die dafür vorgesehen sind, spezielle Aspekte der Objektverfolgung und Fusion zu betrachten (z.B. Objektverlust bei einer schleifenförmigen Trajektorie). Bei den Kreuzungsszenen wurde darauf geachtet, dass sich die geometrischen Verhältnisse an denen orientieren, die an realen Kreuzungen existieren. Der gesamte Manöverkatalog ist in Anhang C zu finden.

Die Manöver wurden mit zwei Fahrzeugen gefahren, einem mit umgebungserfassender Sensorik ausgestatteten *Sensorfahrzeug* (siehe Kapitel 2.2) und einem beobachteten *Zielfahrzeug*. Die Sensorrohdaten wurden mittels Messtechnik aufgezeichnet und können später offline reproduziert werden. Beide Fahrzeuge waren mit DGPS-Empängern (*Differential Global Positioning System*) und Inertialsensorik (engl.: *Inertial Measurement Unit (IMU)*) ausgestattet, die eine genaue räumliche und zeitliche Referenz der gefahrenen Trajektorien zur Verfügung stellen. Diese Referenztrajektorien sind eine wichtige Voraussetzung, um die Leistungsfähigkeit der Fusionsalgorithmen objektiv bewerten zu können. Weiterhin wurden beide Fahrzeuge für die Tests mit Systemen zur automatisch gesteuerten Lenkung sowie Beschleunigung/Bremmung

ausgestattet, so dass die Szenarien automatisiert gefahren wurden. Die Vorteile des automatisierten Testens sind zum einen in der Reproduzierbarkeit der abgefahrenen Trajektorien zu sehen, zum anderen aber auch in der besseren Koordination zwischen zwei Fahrzeugen sowie darin, sehr knappe Manöver unter Beteiligung beider Fahrzeuge sicher fahren zu können. Abbildung 5.8 zeigt ein Versuchsfahrzeug für das automatisierte Fahren [WWWa].

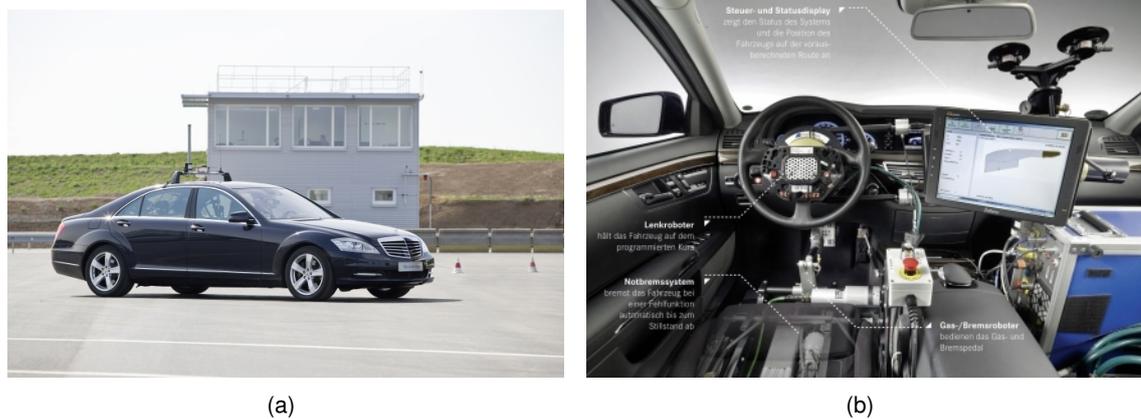


Abbildung 5.8: Mit Lenk- und Bremsroboter sowie DGPS und IMU ausgestattetes Versuchsfahrzeug: (a) Außenansicht, (b) Innenansicht

5.3.2 Bewertungskriterien

Um Aussagen über die Güte der Fusionsalgorithmen zu treffen, werden die geschätzten Zustandsgrößen mit den während der Versuchsfahrten aufgezeichneten Trajektorien und Bewegungsparameter verglichen. Als Kriterium dient der mittlere quadratische Fehler (*engl. Root Mean Squared, RMS*) der einzelnen Zustandsvariablen Position, Geschwindigkeit und Orientierungswinkel. Zusätzlich wird ausgewertet, wie gut die Ausdehnung des Zielfahrzeugs geschätzt werden kann. In Szenarien mit hoher Dynamik ist neben der Genauigkeit der Schätzung ebenfalls wichtig, wie gut das Trackingsystem in der Lage ist, schnelle Änderungen zu verfolgen. Ein weiteres Kriterium ist daher die zeitliche Genauigkeit.

Der mittlere quadratische Fehler wird wie folgt berechnet. Die Laufvariable n läuft dabei über die Anzahl der Zeitschritte, in denen das Objekt verfolgt wird.

$$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n \varepsilon^2} \quad (5.11)$$

Der Skalar ε bezeichnet die Abweichung vom wahren Wert, im Falle der Position ergibt sich

$$\varepsilon^2 = (x_s - x_{GT})^2 + (y_s - y_{GT})^2 \quad (5.12)$$

mit der Position (x_s, y_s) aus der aktuellen Schätzung und der tatsächlichen Position (x_{GT}, y_{GT}) . Analog wird der Fehler für die Geschwindigkeit aus dem Vektor $[\dot{x} \ \dot{y}]$ berechnet.

Verglichen werden dabei das nur auf Laserdaten basierende Tracking, die Fusion mit Radardaten nach dem klassischen Ansatz (Methode des nächstgelegenen Punktes) und die in dieser Arbeit entwickelte Fusion nach dem modellbasierten Ansatz.

5.3.3 Ergebnisse

Nachfolgend sind die Ergebnisse einiger Beispiele aus dem Testkatalog ausführlicher aufgezeigt. Im ersten Beispiel wird eine Querfahrt untersucht, bei der das Zielfahrzeug von rechts kommend mit 30 km/h am stehenden Sensorfahrzeug vorbeifährt. Abbildung 5.9 zeigt die Trajektorien sowie die Geschwindigkeiten aufgeschlüsselt nach x- und y-Geschwindigkeit jeweils für die zum Objekt gehörenden Tracks. In Abbildung 5.10 sind der Orientierungswinkel sowie die Abmessungen aus den Schätzungen aufgetragen. Rot markiert sind Werte für das rein auf Laserdaten basierte Tracking, in blau sind die Ergebnisse für den klassischen Fusionsansatz dargestellt (bezeichnet mit „Fusion NP“ für „Fusion nächster Punkt“), grün steht für die modellbasierte Fusion („Fusion MB“ für „Fusion modellbasiert“). In schwarz ist jeweils die Referenz aus den GPS-Daten aufgetragen (*engl. Ground Truth, GT*). Trajektorien und Geschwindigkeiten sind in Sensorkoordinaten dargestellt. Die Positionen sowohl für die Referenz als auch für die Schätzung beziehen sich immer auf den Mittelpunkt des Objekts.

Zu Beginn sind alle drei Trajektorien deckungsgleich bis ca. $y = -5\text{ m}$, da das Ziel noch nicht von den Radarsensoren erfasst wird. Werden Radarziele zugeordnet, ergibt sich in diesem Beispiel zunächst eine Abweichung von der Referenztrajektorie, die aber wieder ausgeglichen wird für beide Arten der Fusion. Im weiteren Verlauf zeigt sich, dass die modellbasierte Fusion der Referenztrajektorie besser folgen kann als der klassische Ansatz. Zwischen $y = 0$ und $y = 5\text{ m}$ kommt es bei der klassischen Fusion zu einer Verzögerung, die zu falschen Parametern führt und schließlich den Track abreißen lässt. Die y-Komponente der Geschwindigkeit wird zu niedrig geschätzt. Die modellbasierte Fusion kann der Trajektorie gut folgen, auch die Geschwindigkeitsschätzung ist am genauesten, vergleicht man alle drei Methoden. Nichtsdestotrotz kommt es auch hier zu einem kurzzeitigen Trackverlust, der allerdings in diesem Fall der in Kapitel 3.2.2 besprochenen Referenzpunktproblematik geschuldet ist. Man sieht dies in der Neuinitialisierung der Geschwindigkeit in Zeitschritt 135. Anders als bei der Fusion unter Verwendung der nächstgelegenen Ecke kann dieser Track wiederum der wahren Geschwindigkeit folgen. Das laserbasierte Tracking folgt der Referenztrajektorie ohne das Objekt zu verlieren, jedoch ist der Fehler in der Position höher und vor allem ist der Fehler in der y-Geschwindigkeit viel höher wie aus Tabelle 5.1 ersichtlich wird.

Orientierungswinkel und Abmessungen werden bei allen drei Verfahren ungefähr mit gleicher Performance geschätzt, da die Schätzungen vor allem auf den Objekthypothesen aus den Laserscannerdaten beruhen. Unterschiede ergeben sich beim Abriss und Neuauftreten von Tracks sowie durch den Abgleich mit Bewegungsparametern bei der Assoziation von Lasersegmenten zu vorhandenen Tracks. Auffallend ist dabei, dass, obwohl die Länge des Fahrzeugs generell stark unterschätzt wurde, trotzdem eine Zuordnung von Radarzielen nicht nur an der nächstgelegenen Fahrzeugecke den Effekt der Verzögerung vermindert.

Tabelle 5.1 listet den mittleren quadratischen Fehler für die betrachteten Parameter auf. Für Po-

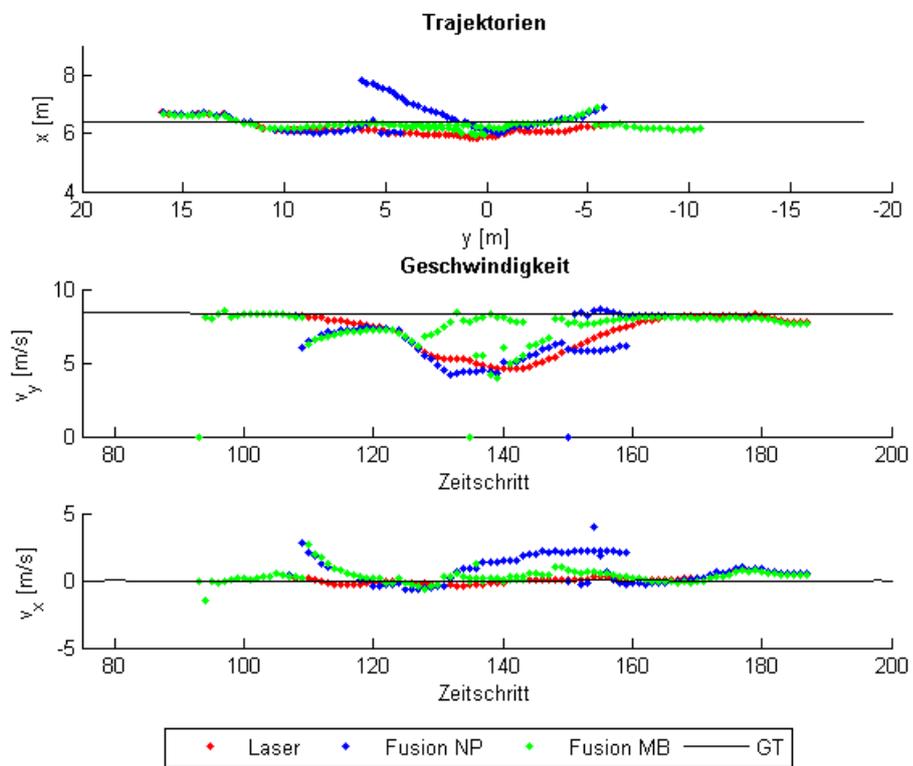


Abbildung 5.9: Geschätzte Trajektorien und Geschwindigkeiten bei einem Querfahrt-Szenario mit stehendem Sensorfahrzeug

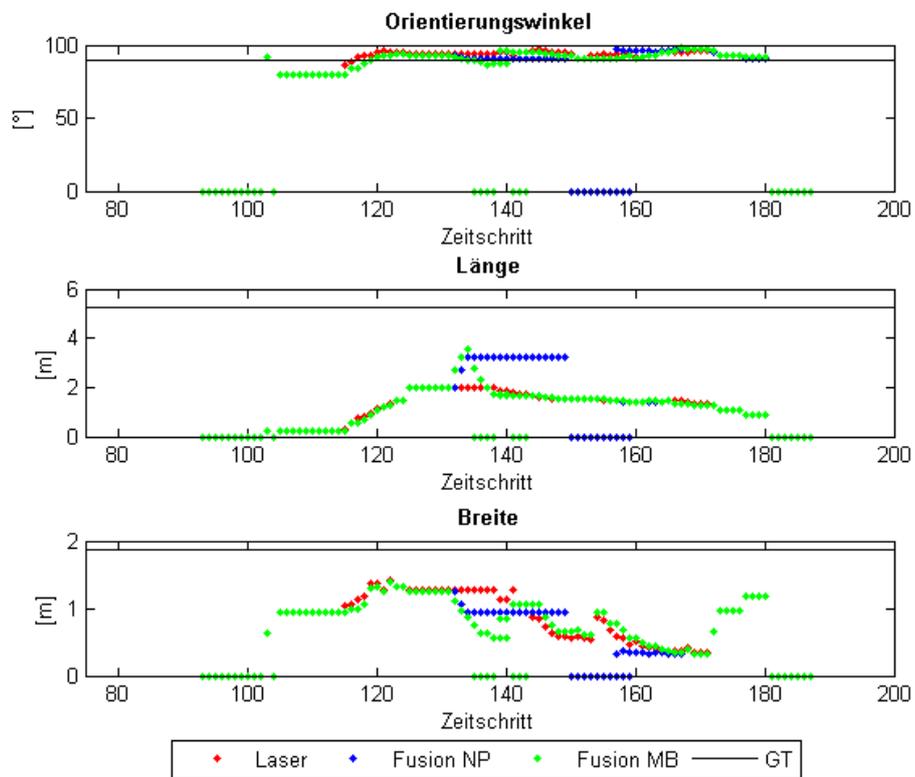


Abbildung 5.10: Schätzergebnisse der Orientierung und Abmessungen bei einem Querfahrt Szenario mit stehendem Sensorfahrzeug

sition und Geschwindigkeit ist jeweils auch der Fehler in x und y getrennt angegeben. Die relativ hohen Werte für den Orientierungswinkel sowie Länge und Breite kommen dadurch zustande, dass bei fehlender Beobachtbarkeit die Werte zunächst auf Null gesetzt werden sowie durch die Latenz, die vorhanden ist, da die richtige Zuordnung von Orientierungswinkel, Länge und Breite von der Bewegungsrichtung abhängt. Für diese wird zunächst eine angemessene Konfidenz gefordert, bevor Orientierungswinkel und Abmessungen belegt werden. Die Berechnung des quadratischen Fehlers beginnt erst, wenn der Track sich im Zustand „confirmed“ befindet (zur Objektverwaltung siehe Kapitel 4.3.3). Die in den Plots dargestellten Ergebnisse zeigen jeweils die vollständigen Trackinformationen inklusive der Initialisierungsphase. In der Tabelle ist zusätzlich die Anzahl der Tracks angegeben, die insgesamt für das Objekt gebildet wurden.

Tabelle 5.1: RMS - Querfahrt, Sensorfahrzeug statisch

	x [m]	y [m]	Pos. [m]	v_x [m/s]	v_y [m/s]	v [m/s]	ψ [°]	Länge [m]	Breite [m]	Tracks #
Laser	0,35	2,02	2,05	0,34	1,78	1,81	32,19	4,15	1,16	1
Fusion NP	0,40	2,04	2,09	0,94	1,35	1,67	43,39	4,19	1,32	2
Fusion MB	0,19	1,73	1,74	0,58	1,12	1,27	35,29	4,16	1,20	2

Das zweite Beispiel stellt ein Kreuzungsszenario dar. Das Zielfahrzeug quert von rechts kommend und beschleunigt dabei von 30 km/h auf 50 km/h. Das Sensorfahrzeug fährt an die Kreuzung heran und bremst aus einer Geschwindigkeit von 30 km/h mit 3 m/s^2 bis zum Stillstand. Die geschätzten Parameter für das Zielfahrzeug zeigen die Abbildungen 5.11 (Trajektorien und Geschwindigkeiten) und 5.12 (Orientierungswinkel und Abmessungen). Die Farbkodierung ist, wie im ersten Beispiel angegeben, rot für das laserbasierte Tracking, blau für die Fusion am nächstgelegenen Eckpunkt und grün für die modellbasierte Fusion. Eine Aufstellung der quadratischen Fehler für dieses Testszenario wird in Tabelle 5.2 gegeben.

Auch in diesem Szenario weist die modellbasierte Fusion einen geringeren Fehler zur Referenztrajektorie auf und liegt sowohl in der x - als auch in der y -Komponente der Geschwindigkeit im quadratischen Mittel näher am wahren Wert als die Fusion an der nächstgelegenen Ecke. Beim Orientierungswinkel liegen die Kurven mit Ausnahme von Phasen der Initialisierung annähernd deckungsgleich. Die Länge des Zielfahrzeugs wurde ab dem Zeitschritt 480 präzise geschätzt, das Fahrzeug befand sich zu diesem Zeitpunkt bei $y = -5,7 \text{ m}$. Betrachtet man die Trajektorien ab dieser Distanz, ist zu erkennen, dass die modellbasierte Fusion von da an „wirksam“ ist und der Referenztrajektorie genauer folgt als die anderen beiden Methoden.

Tabelle 5.2: RMS - Querfahrt, Sensorfahrzeug bewegt

	x [m]	y [m]	Pos. [m]	v_x [m/s]	v_y [m/s]	v [m/s]	ψ [°]	Länge [m]	Breite [m]	Tracks #
Laser	1,29	2,28	2,62	0,63	0,79	1,01	34,18	3,62	0,63	3
Fusion NP	1,28	2,18	2,53	1,11	2,10	2,38	35,72	3,68	0,65	3
Fusion MB	1,19	2,18	2,48	1,02	1,50	1,82	34,44	3,59	0,67	2

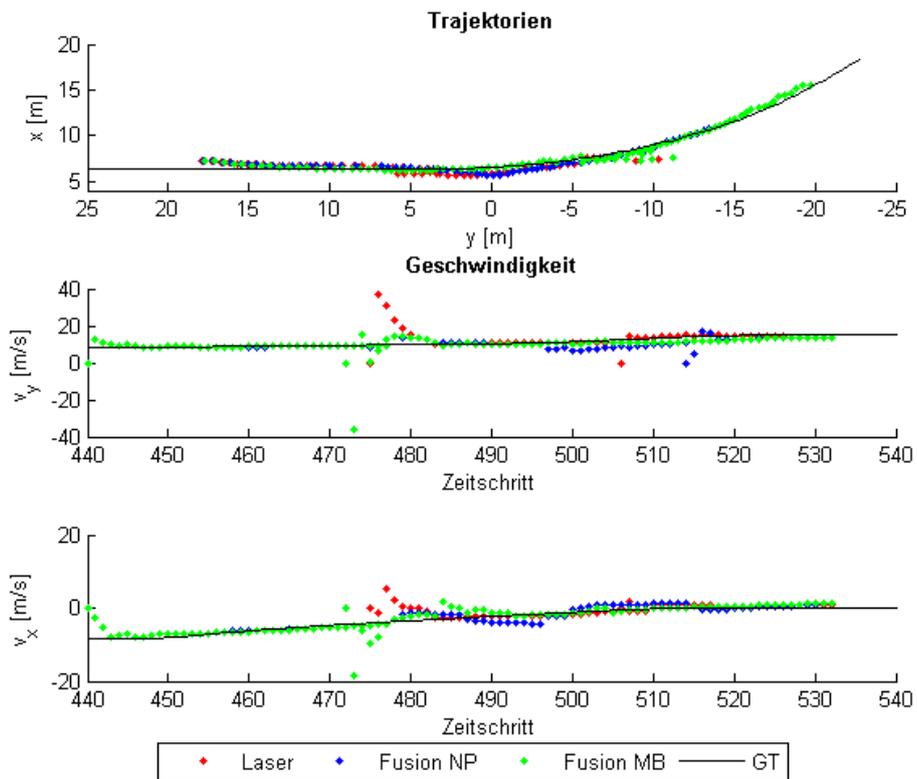


Abbildung 5.11: Geschätzte Trajektorien und Geschwindigkeiten bei einem Querfahrt-Szenario mit bewegtem Sensorfahrzeug

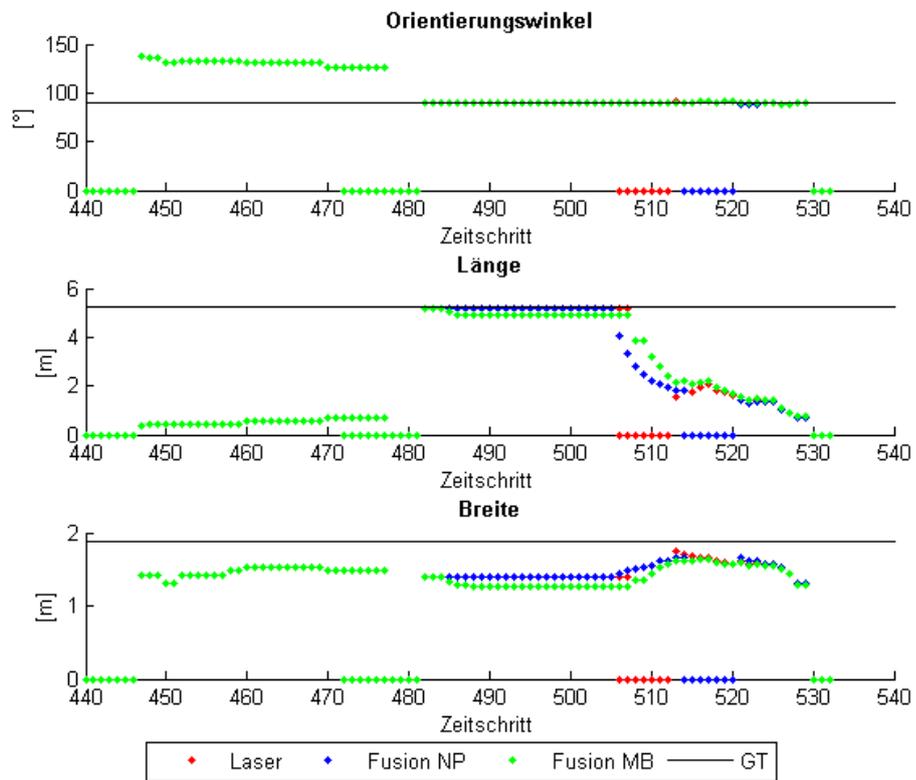


Abbildung 5.12: Schätzergebnisse der Orientierung und Abmessungen bei einem Querfahrt-Szenario mit bewegtem Sensorfahrzeug

Im nächsten Beispiel wird ein Längsszenario untersucht. Das Zielfahrzeug kommt dem Sensorfahrzeug auf der Gegensepur entgegen und beschleunigt dabei von 30 km/h auf 50 km/h. Das Sensorfahrzeug fährt konstant geradeaus mit 50 km/h. Die Ergebnisse sind in den Abbildungen 5.13 und 5.14 sowie in Tabelle 5.3 dargestellt. Im Längsszenario wird nach der Theorie nicht unbedingt eine Verbesserung zur klassischen Fusion erwartet. Die Trajektorien beider Fusionsansätze unterscheiden sich kaum. Bei der klassischen Fusion beginnt der Track früher als bei der modellbasierten Fusion und beim laserbasierten Tracking, da hier der Track allein auf Radardaten basiert aufgesetzt wird. Der mittlere quadratische Fehler für die modellbasierte Fusion ist geringer, da die Trajektorie bei der klassischen Fusion noch stark von der Referenz abweicht. Leichte Verbesserungen in der Geschwindigkeitsschätzung sind aber auch in diesem Szenario auszumachen.

Eine gute Längenschätzung findet erst relativ spät statt, da unter dem steilen Winkel das Fahrzeug erst sehr spät als vollständiges Objekt vom Laserscanner detektiert werden kann.

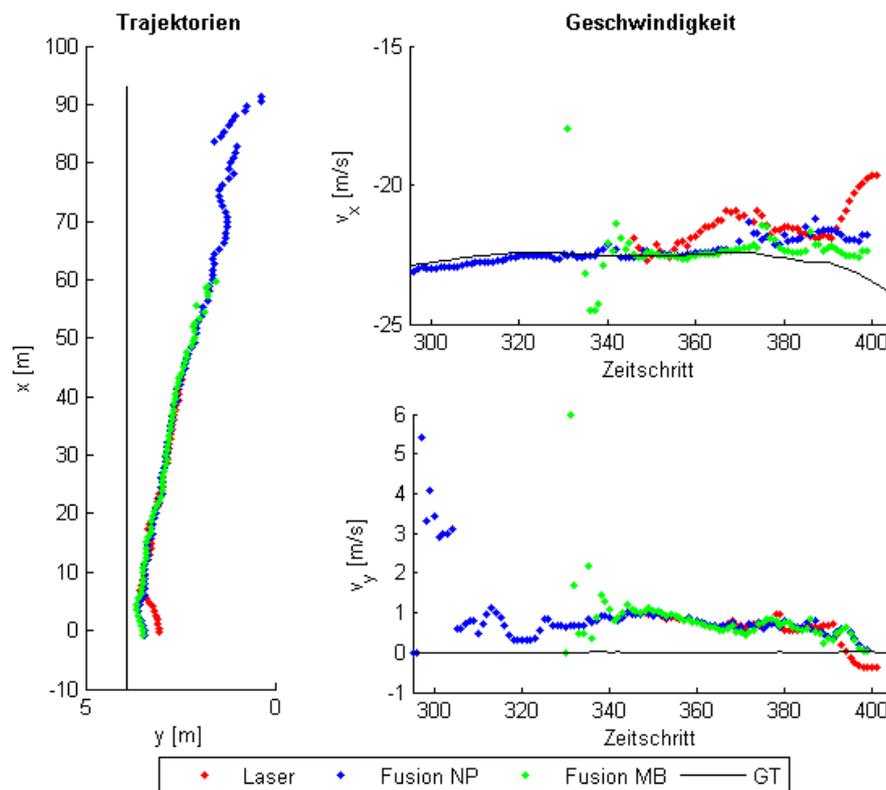


Abbildung 5.13: Geschätzte Trajektorien und Geschwindigkeiten bei einem Längsfahrt-Szenario mit bewegtem Sensorfahrzeug

Tabelle 5.4 zeigt eine Gesamtübersicht der quadratischen Fehler in Position und Geschwindigkeit aller Testfahrten, die durchgeführt und ausgewertet wurden. Eine Übersicht über alle Testszene findet sich im Fahrmanöverkatalog in Anhang C. Verglichen wurde die Fusion an der nächstgelegenen Fahrzeugecke mit der modellbasierten Fusion. Der jeweils bessere Wert für die Position sowie die Gesamtgeschwindigkeit ist durch Fettdruck hervorgehoben. Die in

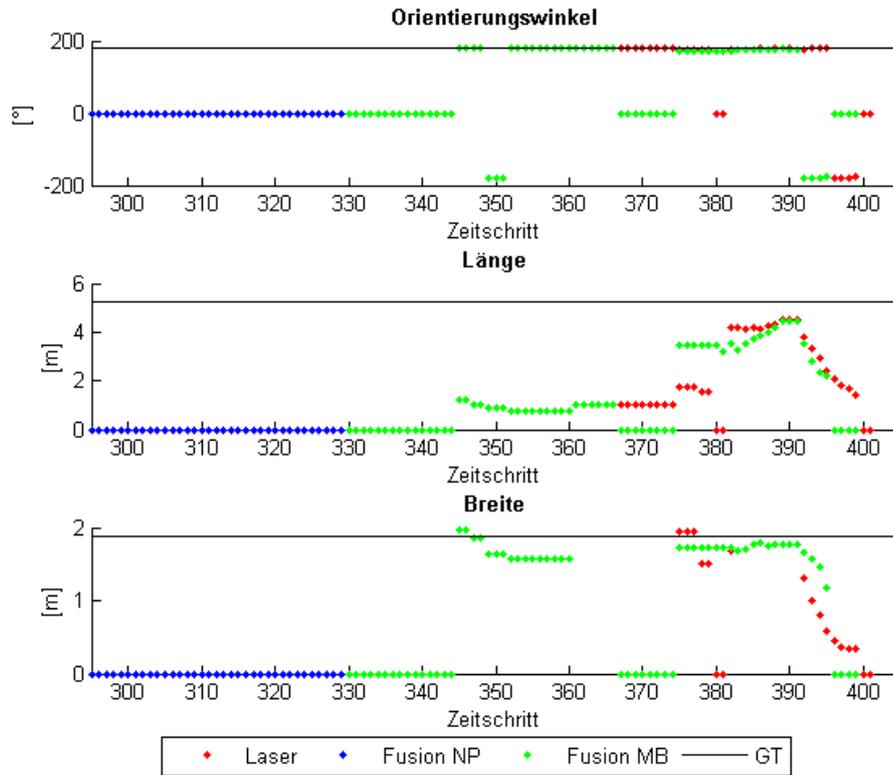


Abbildung 5.14: Schätzergebnisse der Orientierung und Abmessungen bei einem Längsfahrt-Szenario mit bewegtem Sensorfahrzeug

Tabelle 5.3: RMS - Längsfahrt, Sensorfahrzeug bewegt

	x [m]	y [m]	Pos. [m]	v_x [m/s]	v_y [m/s]	v [m/s]	ψ [°]	Länge [m]	Breite [m]	Tracks #
Laser	1,01	1,08	1,48	1,44	0,76	1,63	140,27	3,94	0,91	1
Fusion NP	1,02	1,74	2,02	0,56	0,98	1,13	165,86	4,51	1,42	1
Fusion MB	0,66	1,04	1,23	0,50	0,77	0,92	156,57	4,01	1,05	1

diesem Kapitel bereits genauer beleuchteten Ergebnisse sind in der Tabelle nochmals mit verzeichnet (Tests 1, 12 und 19). Im Durchschnitt über alle Tests ist die modellbasierte Fusion in der Positionsschätzung um 3 % und in der Geschwindigkeitsschätzung um 14 % genauer als die Fusion am nächstgelegenen Eckpunkt des Objekts.

Tabelle 5.4: RMS - Manöverkatalog

Test Nr.	Fusion NP						Fusion MB					
	x [m]	y [m]	Pos. [m]	v_x [m/s]	v_y [m/s]	v [m/s]	x [m]	y [m]	Pos. [m]	v_x [m/s]	v_y [m/s]	v [m/s]
1	0,40	2,04	2,09	0,94	1,35	1,67	0,19	1,73	1,74	0,58	1,12	1,27
2	0,33	1,74	1,77	1,56	2,79	3,19	0,55	1,85	1,93	2,02	2,85	3,49
3	1,10	2,33	2,58	2,12	2,02	2,93	1,07	2,60	2,81	0,84	2,32	2,46
4	0,52	5,10	5,13	1,31	3,79	4,01	0,41	5,02	5,04	0,59	3,73	3,78
5	0,82	1,46	1,68	0,64	1,93	2,04	0,81	1,28	1,52	0,58	2,11	2,18
6	0,88	2,72	2,86	3,02	1,70	3,46	0,75	2,25	2,37	0,64	3,40	3,46
7	0,50	1,63	1,70	1,24	0,81	1,49	0,49	1,69	1,76	0,61	2,50	2,58
8	1,13	2,72	2,95	1,19	0,90	1,49	1,20	2,72	2,98	0,48	0,39	0,62
9	0,38	1,69	1,74	1,49	3,11	3,45	0,55	1,26	1,38	2,11	1,64	2,67
10	1,78	5,07	5,37	1,07	2,92	3,10	1,65	5,08	5,35	1,11	2,91	3,12
11	0,54	2,30	2,36	1,29	3,40	3,64	0,34	1,77	1,80	0,88	1,59	1,82
12	1,28	2,18	2,53	1,11	2,10	2,38	1,19	2,18	2,48	1,02	1,50	1,82
13	0,51	1,35	1,45	4,70	7,73	9,05	0,36	1,90	1,93	1,18	5,55	5,67
14	1,03	2,11	2,34	1,00	2,54	2,73	0,93	2,00	2,20	0,55	2,94	2,99
15	0,41	1,78	1,83	0,95	2,22	2,41	0,33	1,70	1,73	0,92	2,27	2,45
16	1,02	1,14	1,53	1,32	2,00	2,40	0,79	2,04	2,19	1,25	1,84	2,23
17	0,65	3,57	3,63	1,47	1,87	2,38	0,63	3,53	3,59	1,42	1,87	2,35
18	0,88	1,36	1,62	2,75	1,19	3,00	0,84	1,10	1,39	1,11	3,30	3,49
19	1,02	1,74	2,02	0,56	0,98	1,13	0,66	1,04	1,23	0,50	0,77	0,92
20	0,99	1,26	1,60	1,43	0,75	1,62	1,28	1,26	1,80	1,48	0,60	1,60
21	1,73	0,90	1,95	1,54	0,68	1,68	1,80	0,91	2,01	1,12	0,62	1,28
22	2,44	1,47	2,85	2,17	4,34	4,85	2,76	0,86	2,89	2,60	1,93	3,24
23	2,24	0,61	2,33	7,12	0,54	7,14	1,86	0,64	1,97	1,00	0,67	1,20
24	1,50	0,84	1,72	4,21	0,97	4,32	1,75	0,71	1,89	3,02	1,01	3,19
25	1,08	1,16	1,59	1,40	4,39	4,60	1,06	1,07	1,51	1,65	4,11	4,42

Bei den untersuchten Beispielen wurde vor allem der Vergleich der verschiedenen Fusionsansätze betrachtet. Das nur auf Laserdaten basierte Tracking wurde zum Vergleich immer mit aufgezeigt. In der Mehrheit der Szenarien ergibt sich ein Vorteil generell für die Fusion in der Geschwindigkeitsschätzung. Die Geschwindigkeitskomponente entsprechend der Bewegungsrichtung ist tendenziell beim laserbasierten Tracking ungenauer als bei der Fusion, da die Geschwindigkeit hier als Positionsänderung abgeleitet werden muss, während sie beim Radar als Messgröße eingeht.

Ein weiterer Aspekt, der damit einhergeht, ist die zeitliche Genauigkeit der Geschwindigkeits-

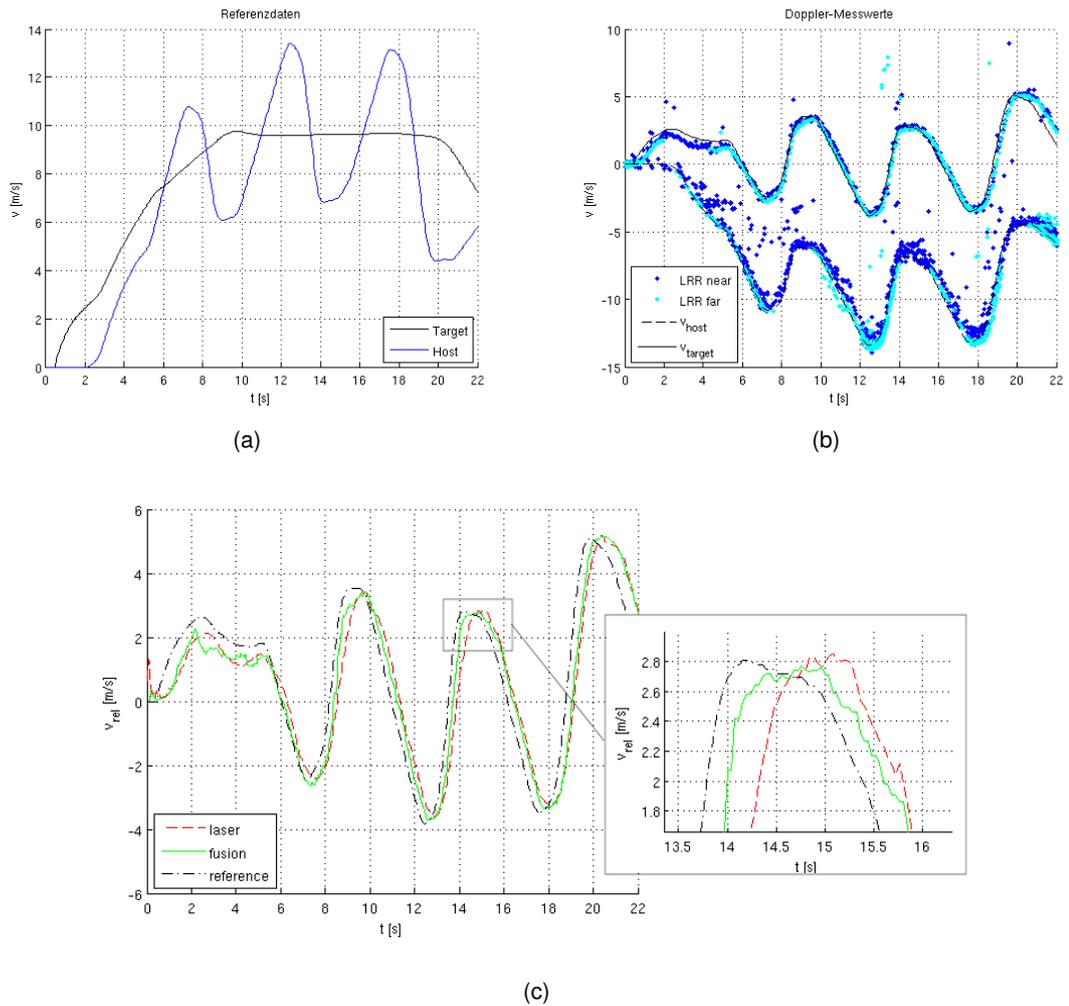


Abbildung 5.15: Folgefahrt-Szenario: (a) Referenz-Geschwindigkeiten, (b) Doppler-Messwerte Fernradar, (c) geschätzte Relativgeschwindigkeit

schätzung. Um dies zu illustrieren, wird eine Folgefahrt untersucht. Das Zielfahrzeug fährt mit ca. 30 km/h voraus, während das dahinter fahrende Sensorfahrzeug mehrere Male zuerst beschleunigt und dann wieder abbremst. Die Abbildungen 5.15(a) und 5.15(b) zeigen zur Veranschaulichung die Absolutgeschwindigkeit der beiden Fahrzeuge und die Doppler-Messwerte des Fernradarsensors. Zur Orientierung sind die Eigengeschwindigkeit des Sensorfahrzeugs und die Geschwindigkeit des Zielfahrzeugs relativ zum Sensorfahrzeug aufgetragen. Die Messpunkte auf der unteren Kurve entsprechen den Messungen auf dem Zielfahrzeug, Messpunkte auf der oberen Kurve stammen von statischen Objekten in der Umgebung. Da die Dopplergeschwindigkeit relativ gemessen wird, erhalten sie die Geschwindigkeit des Sensorfahrzeuges mit umgekehrtem Vorzeichen. Die von beiden Kurven abweichenden Messpunkte entstehen entweder durch Rauschen oder durch andere fremdbewegte Objekte in der Umgebung.

Abbildung 5.15(c) zeigt die geschätzten Relativgeschwindigkeiten für das Zielfahrzeug. Die rote gestrichelte Kurve gibt das Ergebnis für das rein auf Laserdaten basierte Tracking wieder, die grüne durchgezogene Kurve ist das Ergebnis des Trackings mit fusionierten Daten.³ Die Kurven zeigen, dass das fusionierte Tracking zeitlich näher an der Referenzkurve liegt als das laserbasierte. Dies wird besonders deutlich, wenn man sich den vergrößerten Ausschnitt ansieht. Änderungen in der Fahrzeugdynamik können mit der Fusion deutlich schneller verfolgt werden.

5.3.4 Diskussion der Ergebnisse

Ziel der Arbeit war es, eine genaue und robuste Schätzung von Positions- und Bewegungsparametern von Objekten durch eine Kombination von Laserscanner- und Radardaten zu erreichen, wobei Modellwissen über die Radarreflexionseigenschaften von Fahrzeugen eingesetzt wurde. Dieses wurde genutzt, um die Assoziation von Radarzielen zu korrespondierenden Reflexionszentren am ausgedehnten Objekt und letztendlich die Parameterschätzung zu verbessern. Im Fokus standen dabei Szenarien mit querenden Fahrzeugen, da hier eine ungenaue Positionszuordnung zu merklichen Abweichungen in der Positions- und Geschwindigkeitsschätzung führt.

Die in Kapitel 5.3.3 betrachteten Beispiele zeigen, dass durch die modellbasierte Fusion von Laserscanner- und Radardaten ein Gewinn an Genauigkeit sowohl in der Schätzung der Geschwindigkeit als auch der Position gegenüber der Fusion bei Verwendung der nächstgelegenen Ecke an einem ausgedehnten Objekt erzielt werden kann. Dieses konnte im Mittel über alle Querfahrten belegt werden (Szenarien 1-18). Da der Ansatz generisch sein soll, sollte jedoch auch in Längsszenarien keine Verschlechterung eintreten. Im Gegenteil wurde auch bei diesen Szenarien eine Verbesserung durch die modellbasierte Fusion erreicht (Szenarien 19-25). Neben der Genauigkeit der geschätzten Parameter spielt für automotiv Anwendungen auch die Robustheit, mit der ein relevantes Objekt verfolgt wird, eine Rolle. Werden Tracks zeitweilig verloren und wieder neu aufgesetzt, ändert sich deren ID und ihre Historie, die unter Umständen vom Situationsbewertungsmodul für weitere Auswertungen benutzt wird - beispielsweise

³Für das Folgefahrt-Szenario wurden der modellbasierte Ansatz und der klassische Ansatz nicht gesondert untersucht.

um zu einer Bremsentscheidung zu gelangen - geht verloren. In der Praxis ist hier zumeist ein Kompromiss zu finden zwischen der geforderten Genauigkeit und der benötigten Robustheit. In den detailliert betrachteten Fällen in Kapitel 5.3.3 wurde die Anzahl an aufgesetzten Tracks für das relevante Objekt angegeben. Die modellbasierte Fusion verursacht tendenziell weniger Trackabrisse. Dies kann damit erklärt werden, dass eine falsche Annahme über den Reflexionspunkt zu einer inkorrekten Zuordnung von Radarzielen zum Objekt führt, die dieses dann sozusagen „in die falsche Richtung ziehen“ bzw. verzögern, bis schließlich die Messungen dem Track nicht mehr folgen, und ein neuer Track aufgesetzt werden muss.

Gegenüber dem rein auf Laserdaten basierten Tracking sind die Vorteile eher in der Genauigkeit der Geschwindigkeitsschätzung, weniger in der Positionsschätzung zu sehen. Vor allem kann durch die Fusion mit Radardaten ein zeitlicher Gewinn erzielt werden, das heißt Dynamikänderungen können bei vergleichbarer Genauigkeit schneller nachvollzogen werden.

Die Leistungsfähigkeit der modellbasierten Fusion ist in starkem Maße von der Güte der Objekthypothesen bezüglich Ausdehnung und Orientierung abhängig. In den vorangegangenen Kapiteln wurde daher großes Augenmerk auf die Entwicklung, Auswahl und Auswertung von Methoden zur Extraktion der Objekthypothesen basierend auf Laserscannerdaten gelegt. Nichtsdestotrotz bleiben die Möglichkeiten von rein distanzbasierten Messverfahren auch bei guter räumlicher Auflösung beschränkt, da eine Klassifikation nur eingeschränkt möglich ist (siehe Kapitel 3.2.5). Die Benutzung von Kamera- anstelle von Laserscannerdaten oder eine zusätzliche Fusion mit Kameradaten könnten helfen, die Ergebnisse der modellbasierten Fusion weiter zu verbessern, da eine bessere Selektion der Objekthypothesen zur Anwendung der Radarreflexionsmodelle ermöglicht würde. Zudem könnten bestimmte Reflexionszentren wie beispielsweise die Radkästen direkt lokalisiert werden, was Ungenauigkeiten durch Skalierungseffekte weiter minimiert.

Weitere Optimierungsmöglichkeiten bietet die Hinzunahme von Kontextinformation. Bei der Separierung von Objekten, die potentiell Fahrzeuge darstellen, von anderen Objekten in der Fahrzeugumgebung könnten Informationen über den Straßenverlauf bzw. die Lokalisierung des Straßenrands helfen. Die Falschanwendung von Radarreflexionsmodellen für Fahrzeuge auf andere Objekte wird damit weiter eingeschränkt, was zum einen zu einer Verringerung von falschen Zielen führt, die zur Auslösung von Falschalarmen in der jeweiligen Anwendung führen könnten, und zum anderen Rechenzeit spart. Ein möglicher Ansatz zur Straßenverlaufsschätzung mit Radar kann in [SMK⁺11] nachgelesen werden.

6 Zusammenfassung und Ausblick

Um die Sicherheit im Straßenverkehr und den Komfort für den Fahrer zu erhöhen, wird kontinuierlich an neuen und verbesserten Fahrerassistenz- und Sicherheitssystemen gearbeitet. Diese Systeme benutzen Sensoren, die im Fahrzeug verbaut sind, um die Umgebung, in der sich das Fahrzeug bewegt, zu erfassen. Aus den erfassten Daten wird eine digitale Abbildung der Umgebung erstellt, die Objekte wie Fahrzeuge, andere Verkehrsteilnehmer oder Hindernisse und deren Bewegung relativ zum eigenen Fahrzeug beinhaltet. Da die Sensoren nicht rauschfrei arbeiten und manche der gewünschten Parameter nicht direkt messbar sind, wird der Objektzustand mithilfe von Zustandsübergangsmodellen aus den Messdaten geschätzt und über mehrere Zeitschritte hinweg verfolgt. Eine zuverlässige und genaue Schätzung des Objektzustandes, der die Position, Ausdehnung, Orientierung und Geschwindigkeit umfasst, ist die Voraussetzung, um die aktuelle Situation analysieren zu können, mögliche Gefährdungen zu erkennen und die richtigen Maßnahmen wie zum Beispiel eine Warnung an den Fahrer, Bremsen oder Lenken einzuleiten.

Die in dieser Arbeit vorgestellten und untersuchten Methoden und Verfahren befassen sich mit der Datenverarbeitung von Einzelsensoren und deren Fusion zur Erstellung von Objektlisten als Repräsentation der Umgebung. Dabei geht es im Speziellen um die Kombination von Sensoren, die die räumliche Ausdehnung von Objekten erfassen, mit Sensoren, die Objekte nur in Form einzelner oder einiger weniger Reflexionen detektieren. Konkret wurde für diese Arbeit ein Laserscanner verwendet, der die sichtbare Kontur von Objekten und damit die Position mit hoher Genauigkeit vermisst sowie Radarsensoren, die zusätzlich zur Position auch die Dopplergeschwindigkeit als Messgröße ausgeben. Die Information über Objektdimensionen wurde hier benutzt, um Hypothesen darüber zu generieren, ob Objekte vom Typ „Fahrzeug“ sind. Ist dies der Fall, wird ein bereits existierendes Modell von Reflexionszentren am Fahrzeug angewendet, um Radarziele präziser dem Entstehungsort ihrer Reflexion zuzuordnen. Diese modellbasierte Fusion bildet reales Reflexionsverhalten am Fahrzeug genauer nach als ein generalisierter Ansatz, der nur mit einem Reflexionszentrum für ein Objekt arbeitet und dieses pauschal z. B. auf die zum Sensor nächstgelegene Fahrzeugecke legt.

Im Rahmen dieser Arbeit wurden existierende Radarreflexionsmodelle an Fahrzeugen recherchiert und für die Implementierung dasjenige ausgewählt, welches zum einen das Verhalten der eingesetzten Radarsensoren gut abbildet und zum anderen skalierbar ist. Algorithmen zur Vorverarbeitung und Fusion der Sensordaten unter Verwendung dieses Modells wurden entwickelt und sowohl auf einem Laborrechner zur Offline-Analyse wie auch auf einem Rechner im Fahrzeug zur Evaluierung und Präsentation in Echtzeit implementiert. Das Verfahren zur Fusion von ausgedehnten Objekten in Form von Laserscannersegmenten mit Radarzielen, das bei der Datenassoziation verschiedene Reflexionszentren am Objekt differenziert und dabei deren aktuelle Sichtbarkeit und Auflösungsvermögen durch den Sensor einbezieht, wurde

nach Kenntnisstand der Autorin im Rahmen dieser Arbeit erstmals publiziert. Mit diesem Ansatz wurde eine Methode gefunden, die vor allem bei querenden Fahrzeugen die Fusion mit Radardaten befördert, sodass deren Vorteile der direkten Geschwindigkeitsmessung und der Positionsgenauigkeit auch in solchen Anwendungsfällen genutzt werden können. Die in dieser Arbeit vorgestellten Ergebnisse aus realen Testfahrten zeigen, dass sich dadurch eine genauere Schätzung von Position und Geschwindigkeit erreichen lässt. Die präsentierten Ergebnisse sind bewusst nicht auf eine bestimmte Anwendung bzw. ein bestimmtes Szenario bezogen, sondern es wurde allgemein die Güte der Parameterschätzung von Zielfahrzeugen in unterschiedlichen Szenarios bezogen jeweils auf den wahren Wert evaluiert.

Um die Vorteile der modellbasierten Fusion nutzen zu können, stellen sich Anforderungen an die Güte der Objekthypothesen, die aus den Laserscannerdaten gewonnen werden. Diese stellen die Eingabe für die Anwendung des Fahrzeugmodells bezüglich der Reflexionszentren dar. Besonderes Augenmerk wurde daher in dieser Arbeit auf die Vorverarbeitung der Laserdaten gelegt. Unterschiedliche Methoden der Segmentierung und Merkmalsextraktion wurden verglichen, bewertet und optimiert. Als Erweiterung zur Einzelschrittverarbeitung wurde das Verfahren der integrierten Objektverfolgung und Klassifikation implementiert und analysiert, welches die Extraktion von Linien aus Laserscannerdaten und die Objektverfolgung koppelt und so zur Stabilisierung der Objekthypothesen beiträgt.

Zur Objektverfolgung und Zustandsschätzung wurde der Kalman-Filter benutzt. Da die verwendeten Mess- und Prozessmodelle teilweise nichtlinear sind, wurde die Variante des Extended Kalman Filter verwendet. Die Referenzpunktproblematik bei räumlich ausgedehnten Objekten wurde ebenfalls diskutiert und Methoden aufgezeigt, die helfen, Scheinbewegungen zu minimieren. Ein weiterer Aspekt bei der Fusion von Laserscanner- und Radardaten ist die Integration der vom Radar gemessenen Geschwindigkeit in die Mess- und Prozessmodelle, da vom Radar nur die radiale Komponente der Geschwindigkeit erfasst wird.

In dieser Arbeit wurden die Vorteile einer modellgestützten Fusion basierend auf dem Reflexionsmodell für PKWs aufgezeigt. In Zukunft könnte die Menge der Modelle erweitert werden, um andere Fahrzeuge abzudecken. Denkbar wären beispielsweise Modelle für Busse, LKWs oder Zweiräder. Dafür müssten entsprechende allgemeine Reflexionsmodelle für diese Fahrzeugklassen neu erstellt und evaluiert werden. Bei der Bildung von Objekthypothesen müssen dann wiederum diese Klassen unterschieden werden. Generell kann das Verfahren auch in anderen Bereichen als dem automotiven Umfeld eingesetzt werden, beispielsweise zur Hinderniserkennung in der Robotik. Für dynamische Umgebungen als Einsatzgebiet des Roboters könnten zumindest geometrische Grundformen der vorkommenden Objekte abstrahiert werden und für diese generische Reflexionsmodelle generiert werden.

Eine für die Zukunft denkbare Erweiterung ist die Hinzunahme der dritten Dimension. Die hier verwendeten Sensoren sind nicht geeignet, die Höhe von Objekten zu vermessen bzw. aufzulösen, daher wurden Positionen und Ausdehnungen nur im Zweidimensionalen betrachtet. Das verwendete Radarreflexionsmodell ist ebenfalls zweidimensional. Mit fortschreitender Entwicklung von Sensoren, die die Höhe von Objekten erfassen können wie 3D-Laserscanner aber auch Radarsensoren mit entsprechender Hardware und Signalverarbeitung kann die Sensordatenverarbeitung und -fusion um die z -Komponente ergänzt werden. Das Radarreflexions-

modell muss dann ebenfalls entsprechend erweitert werden. Aktuelle Arbeiten, die sich mit 3D-Modellierungen bzw. Höhenschätzungen für Einzelsensoren beschäftigen sind [SKD⁺12], was Laserscanner betrifft und [Die13] bezüglich Radar.

Generell könnte eine genauere Klassifikation der Objekte basierend auf Kamerabildern zu einer weiteren Verbesserung des Verfahrens eingesetzt werden. Momentan ist das Reflexionsmodell des PKWs symmetrisch und unterscheidet nicht zwischen Front und Heck. Mit dem Einsatz von Kameras kann diese Unterscheidung getroffen werden, und so die Lokalisierung von Reflexionszentren weiter präzisiert werden. Ein weiterer Aspekt, der damit adressiert werden kann, ist die genaue Lokalisierung der Räder. Bisweilen stammen Radarreflexionen nicht nur von den Radkästen sondern von den Rädern selbst. Durch die Eigenbewegung der Räder führt die gemessene Dopplergeschwindigkeit jedoch nicht auf die Fahrzeuggeschwindigkeit, was zu Ungenauigkeiten in der Zustandsschätzung führen kann. Die Erkennung dieser Situation kann helfen, solche Fehler zu eliminieren.

A Szenenauswahl zur Auswertung der Segmentierverfahren

Für die Auswertung der Segmentierverfahren wurden folgende Szenen ausgewählt, die unterschiedliche Verkehrsszenarien und Umgebungen beinhalten. Links ist jeweils das Kamerabild, rechts ein Ausschnitt aus den Laserscannerrohdaten eines Frames der jeweiligen Szene abgebildet.



Abbildung A.1: Szene 1: Parkplatzsituation



Abbildung A.2: Szene 2: Innenstadtszene mit Fahrzeugen im Längsverkehr



Abbildung A.3: Szene 3: Querverkehr



Abbildung A.4: Szene 4: Kreuzung mit querenden und abbiegenden Fahrzeugen, Fußgängern, Ampeln und Randbebauung

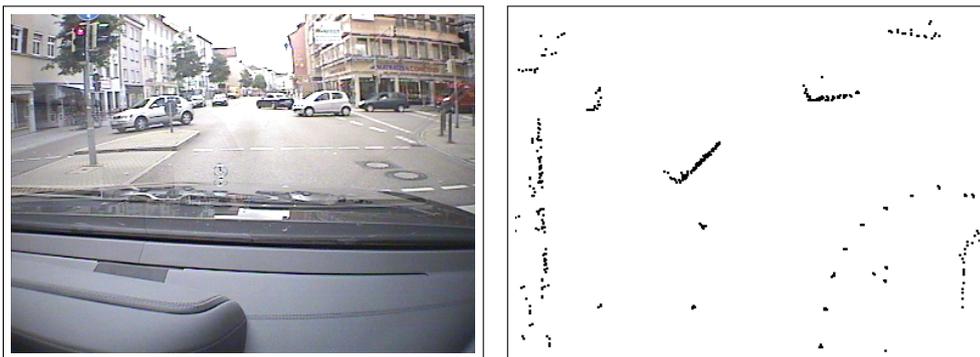


Abbildung A.5: Szene 5: Kreuzung ähnlich Szene 4 jedoch mit umgekehrter Abbiegerichtung und auf engerem Raum

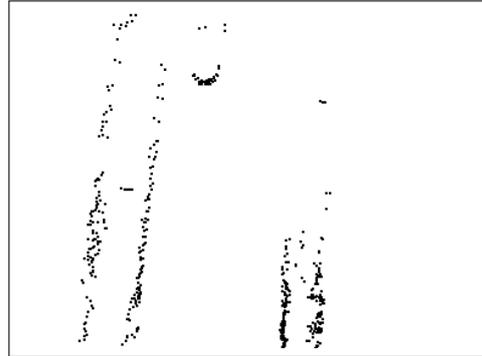


Abbildung A.6: Szene 6: Landstraße mit Entgegenkommern und dichter Vegetation am Straßenrand

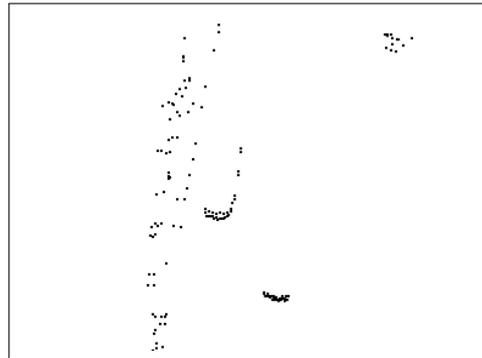


Abbildung A.7: Szene 7: Landstraße mit Vorfahrer und Einmündung

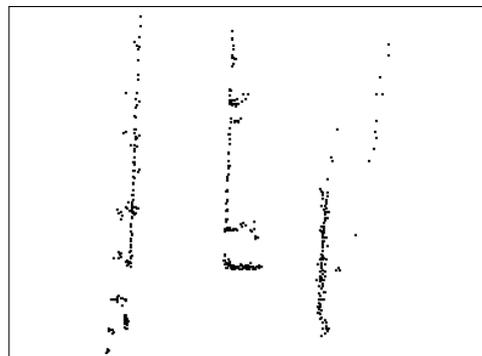


Abbildung A.8: Szene 8: Zweispurige Autobahn mit LKW auf der rechten Spur

B Definition objektcharakterisierender Merkmale

B.1 Konventionen

Im Folgenden sei S die Menge der durch die Segmentierung gegebenen Segmente. Dabei bezeichnet $|S|$ die Anzahl aller Segmente und S_i das i -te Segment. Weiterhin bezeichne $P(S_i)$ die Menge aller Punkte im Segment S_i und $|P(S_i)|$ die Anzahl der Punkte im Segment S_i . Punkte aus unterschiedlichen Scanebenen werden mit $P(S_i, k)$ unterschieden, wobei $P(S_i, k)$ alle Punkte des i -ten Segmentes aus der Ebene k bezeichnet. $p_j(S_i)$ bezeichne den j -ten Punkt im Segment i , $x_j(S_i)$ die x -Koordinate und $y_j(S_i)$ die y -Koordinate im kartesischen Koordinatensystem.

B.2 Anzahl der Punkte im Segment

$$n := |P| \tag{B.1}$$

Die Anzahl der Punkte pro Segment alleine ist noch kein gutes Merkmal, um Aussagen über die Eigenschaften von Segmenten machen, da die Anzahl der Punkte je nach Abstand vom Laserscanner und Lage in einem bestimmten Auflösungsbereich variiert.

B.3 Schwerpunkt

Der Schwerpunkt $p_{cog} = (x_{cog}, y_{cog})$ eines Segmentes entspricht dem arithmetischen Mittel der x - und y -Koordinaten aller Punkte.

$$p_{cog} := \left(\frac{\sum_{i=1}^n x_i}{n}, \frac{\sum_{i=1}^n y_i}{n} \right) \tag{B.2}$$

B.4 Bounding Box und Ausdehnung

Die Bounding Box ist definiert als kleinstes umschließendes Rechteck eines Segmentes. Die Hauptkomponentenanalyse liefert die Richtung, in der eine Punktmenge die größte Streuung besitzt. Diese Richtung kann als Orientierung des Segmentes aufgefasst werden. Diese wiederum lässt die Definition einer Bounding Box zu.

B.4.1 Hauptkomponentenanalyse

Die Hauptkomponentenanalyse (PCA¹) ist ein statistisches Verfahren, um die Eigenschaften der Verteilung einer Punktmenge zu bestimmen. Dazu wird die Kovarianzmatrix K eines Segmentes wie in Gleichung B.3 aufgestellt. Dabei bezeichne n die Anzahl der Punkte in einem Segment, x_{cog} den Mittelwert der x -Werte und y_{cog} den Mittelwert der y -Werte aller Punkte im Segment.

$$K = \frac{1}{n-1} \sum_{i=1}^n \begin{pmatrix} x_i - x_{cog} \\ y_i - y_{cog} \end{pmatrix} \begin{pmatrix} x_i - x_{cog} & y_i - y_{cog} \end{pmatrix} \quad (\text{B.3})$$

Die Eigenwerte λ_1 und λ_2 der Matrix K repräsentieren die Varianz der Daten in die Richtung der entsprechenden Eigenvektoren e_1 und e_2 , wobei gilt: $\lambda_1 \geq \lambda_2$. e_1 liegt dabei orthogonal zu e_2 . Da e_1 die Richtung der größten Varianz der Punktmenge eines Segmentes festlegt, kann man diese als Ausrichtung des Segmentes auffassen.

B.4.2 Bounding Box

Der durch die Hauptkomponentenanalyse bestimmte Eigenvektor e_1 zeigt in die Richtung mit der größten Varianz eines Segmentes. Damit ist er geeignet, eine Bounding Box zu definieren. Die Punktmenge P wird so weit um einen Winkel β gedreht, bis e_1 parallel zur x -Achse liegt. Nun werden folgende Punkte bestimmt:

$$\begin{aligned} p_a &= (x_a, y_a) := \max_P x & p_b &= (x_b, y_b) := \min_P x \\ p_c &= (x_c, y_c) := \max_P y & p_d &= (x_d, y_d) := \min_P y \end{aligned}$$

Anschließend werden die Punkte p_a, p_b, p_c und p_d wieder um $-\beta$ in die Ausgangslage zurückgedreht, die resultierenden Punkte werden als p'_a, p'_b, p'_c und p'_d bezeichnet. Die Bounding Box entspricht dann dem Rechteck, das durch die Punkte (x'_a, y'_c) und (x'_b, y'_d) aufgespannt wird.

¹engl. principle component analysis

B.4.3 Ausdehnung

Die Ausdehnung eines Segmentes mit Länge und Breite lässt sich durch die im vorigen Abschnitt definierten Punkte nach den Formeln B.4 und B.5 bestimmen.

$$length := x_a - x_b \quad (B.4)$$

$$width := y_c - y_d \quad (B.5)$$

Die Ausdehnung eines Segmentes entspricht nicht notwendigerweise der Ausdehnung des zugehörigen realen Objektes, da für den Laserscanner im Allgemeinen nur ein Teil der Konturen eines Objektes sichtbar ist. Trotzdem lässt sich die reale Ausdehnung schätzen, wenn Segmente über die Zeit verfolgt werden.

Eine alternative Berechnungsmethode für die Segmentausdehnung und -orientierung kann anhand von eingepassten Linien angewendet werden. Verfahren zur Linieneinpassung werden in Kapitel 3.2.1 ausgeführt.

B.5 Länge der Konturlinie

Die Bestimmung der Länge der Konturlinie CL , die der Summe der Abstände zwischen benachbarten Punkten entspricht, setzt voraus, dass die Punkte P mit $p_i = (r, \phi)$ im Segment aufsteigend nach Winkel ϕ sortiert sind. Sei $dist$ dabei der euklidische Abstand zwischen zwei Punkten p_i und p_j entsprechend Formel B.7.

$$CL := \sum_{i=0}^n dist(p_i, p_{i+1 \bmod n}) \quad (B.6)$$

$$dist(p_i, p_j) = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (B.7)$$

B.6 Umfang

Der Umfang wird entweder über die Konturlinienlänge oder über die Länge der konvexen Hülle bestimmt.

B.6.1 Konvexe Hülle

Mit der Berechnung der konvexen Hülle entsteht aus einer Punktmenge ein konvexes Polygon. Dieses ist dadurch charakterisiert, dass alle Innenwinkel im Polygon $\leq 180^\circ$ sind. Die Berechnung der konvexen Hülle geschieht aus Effizienzgründen mit Hilfe des Graham Scan

Algorithmus [O'R98, S. 72ff]. Für den Graham Scan Algorithmus sind keine trigonometrischen Funktionen notwendig, die Komplexität beträgt $O(n \log n)$.

Das prinzipielle Vorgehen beim Bilden der konvexen Hülle einer Punktmenge $P = \{p_i : i = 0 \dots n - 1\}$ ist wie folgt:

1. Verschiebe P so, dass der Punkt mit der minimalen x-Koordinate im Ursprung liegt. Dieser Punkt wird mit Index 0 versehen.
2. Sortiere die Punkte $p_1 \dots p_{n-1}$ aufsteigend nach dem Winkel ϕ .
3. Verschiebe die Punkte zurück an ihre ursprünglichen Koordinaten.
4. Betrachte das Kreuzprodukt von jeweils drei Punkten beginnend mit p_0, p_1 und p_2 .
 - Ist das Kreuzprodukt größer als 0, das heißt p_1 liegt innerhalb der konvexen Hülle, so wird p_1 gelöscht. Im nächsten Schritt wird das Kreuzprodukt aus p_0, p_2 und p_3 betrachtet.
 - Ist das Kreuzprodukt jedoch kleiner als 0, sind die drei Punkte bereits konvex, und der Index der betrachteten Punkte wird um eins erhöht. Als nächstes wird das Kreuzprodukt von p_1, p_2 und p_3 überprüft.
5. Führe so lange Schritt 4 durch, bis alle Punkte abgearbeitet sind.
6. Übrig bleiben die Punkte, welche die konvexe Hülle von P bilden.

B.6.2 Berechnung des Umfangs

Mit der Definition der konvexen Hülle lässt sich nun der Umfang der konvexen Hülle U_{CH} nach Formel B.8 definieren. Dabei bezeichne H die Menge der Punkte der konvexen Hülle über P und h_i den i -ten Punkt der nach Winkeln aufsteigend sortierten Punktmenge H .

$$U_{CH} := \sum_{i=0}^{|H|} dist(h_i, h_{i+1 \bmod |H|}) \quad (\text{B.8})$$

Alternativ dazu könnte man den Umfang der Bounding Box U_{BB} verwenden. Dieser wird in Formel B.9 definiert. Da die rechteckige Bounding Box die tatsächliche Segmentform aber nur selten genau annähert, wird die Berechnungsmethode über die konvexe Hülle vorgezogen.

$$U_{BB} := 2 \cdot (length + width) \quad (\text{B.9})$$

B.7 Fläche

Analog zum Umfang wird die Berechnung der Fläche zum einen über die Bounding Box (A_{BB}) und zum anderen unter Zuhilfenahme der konvexen Hülle (A_{CH}) definiert. Zu beachten ist, dass die Fläche, die über ein Segment berechnet wird, nicht der Fläche des zugehörigen realen

Objektes entspricht, da für den Laserscanner lediglich eine Seite des Objektes sichtbar ist.

$$A_{BB} := length \cdot width \quad (\text{B.10})$$

$$A_{CH} = \frac{1}{2} \sum_{i=1}^{|H|} x_i \cdot (y_{i+1} - y_{i-1}) \quad (\text{B.11})$$

B.8 Dichte

Die Dichte ρ eines Segmentes wird berechnet als Quotient aus der Anzahl n der Punkte im Segment und der Fläche A . Dabei kann A als A_{BB} oder als A_{CH} gewählt werden, siehe Kapitel B.7.

$$\rho := \frac{n}{A} \quad (\text{B.12})$$

B.9 Seitenverhältnis

Das Seitenverhältnis *aspectratio* wird durch das Verhältnis der Eigenwerte λ_1 und λ_2 aus der Hauptkomponentenanalyse definiert. Dabei gelte $\lambda_1 \geq \lambda_2$.

$$aspectratio := \frac{\lambda_1}{\lambda_2} \quad (\text{B.13})$$

B.10 Kompaktheit

Die Kompaktheit drückt aus, wie stark ein Segment von der Kreisform abweicht. Bei kreisrunden Segmenten ist sie maximal und wird geringer, je mehr das Segment von der idealen Form abweicht. Für die Berechnung werden die beiden Merkmale Umfang und Fläche des Segmentes verwendet.

$$compactness := \frac{U^2}{A} \quad (\text{B.14})$$

Durch die unterschiedlichen Berechnungsmethoden der Merkmale U und A entstehen mehrere Möglichkeiten, die Kompaktheit zu berechnen. In dieser Arbeit werden die folgenden beiden Merkmale verwendet:

$$compactness_{CH} := \frac{U_{CH}^2}{A_{CH}} \quad compactness_{BB} := \frac{CL^2}{A_{CH}}$$

B.11 Konvexität

Die Konvexität ist ein Maß für die „Rundheit“ von Segmenten. Bei kreisrunden oder ovalen Segmenten beträgt die sie 1. Je mehr konkave, also nach innen gewölbte Kanten enthalten sind, desto geringer ist die Konvexität. Zur Berechnung wird der konvexe Umfang ins Verhältnis zur Länge der Konturlinie gesetzt.

$$convexity = \frac{U_{CH}}{CL} \quad (\text{B.15})$$

B.12 Relative Anzahl von Punkten pro Scanebene

Die relative Anzahl von Punkten pro Scanebene wird in Formel B.16 definiert. Das Merkmal $relpoints_i$ gibt an, welcher Prozentsatz aller Punkte eines Segmentes aus Scanebene i stammt. l bezeichne die Anzahl der Scanebenen. Damit lassen sich beispielsweise Segmente erkennen, die ausschließlich Punkte aus der untersten Scanebene enthalten. Solch ein Segment könnte durch die Reflexionen einer Bordsteinkante entstehen.

$$relpoints_k := \frac{|P(k)|}{n}, k \in [1..l] \quad (\text{B.16})$$

C Fahrmanöver-Katalog

In den Grafiken werden folgende Symbole benutzt:



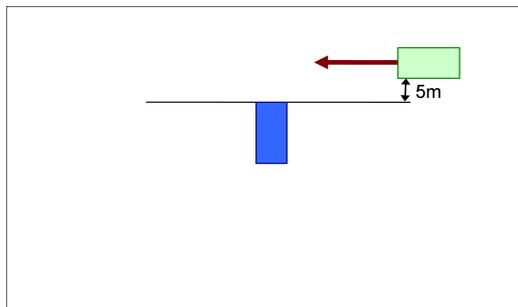
Sensorfahrzeug



Zielfahrzeug



feststehendes Hindernis

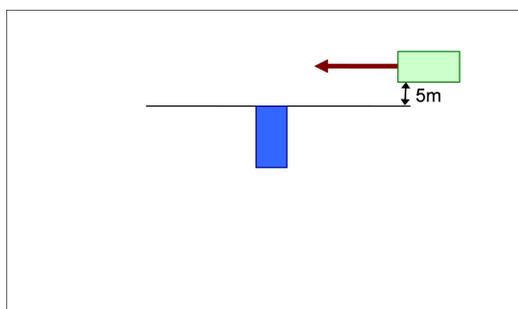


Test 1

Sensorfahrzeug steht, Zielfahrzeug quert mit konstanter Geschwindigkeit

$$v_{ego} = 0 \text{ km/h}$$

$$v_{target} = 30 \text{ km/h}$$

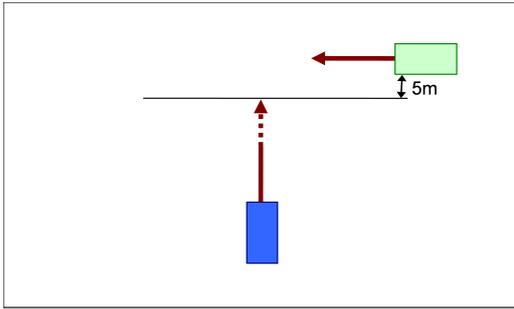


Test 2

Sensorfahrzeug steht, Zielfahrzeug quert mit konstanter Geschwindigkeit

$$v_{ego} = 0 \text{ km/h}$$

$$v_{target} = 50 \text{ km/h}$$

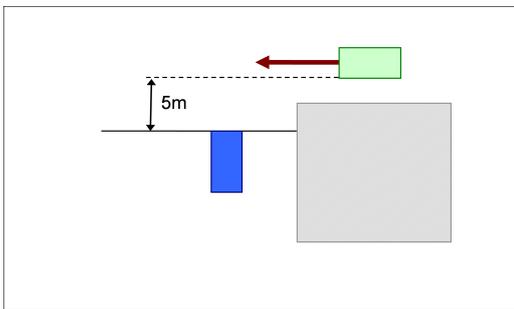


Test 3

Sensorfahrzeug fährt auf Kreuzung zu und bremst, Zielfahrzeug quert mit konstanter Geschwindigkeit

$$v_{ego} = 30.0 \text{ km/h}$$

$$v_{target} = 50 \text{ km/h}$$

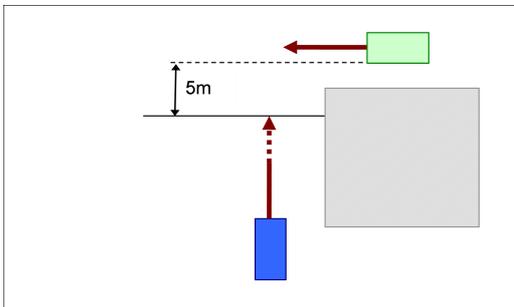


Test 4

Sensorfahrzeug steht, Zielfahrzeug quert mit konstanter Geschwindigkeit aus Sichtverdeckung heraus

$$v_{ego} = 0 \text{ km/h}$$

$$v_{target} = 50 \text{ km/h}$$

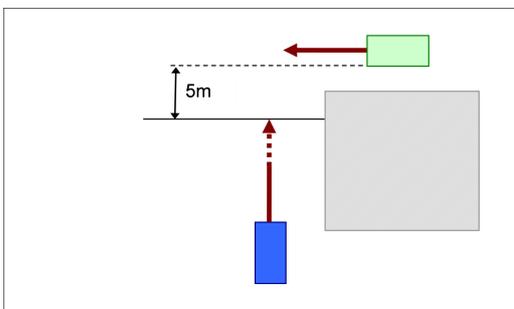


Test 5

Sensorfahrzeug fährt auf Kreuzung zu und bremst, Zielfahrzeug quert mit konstanter Geschwindigkeit aus Sichtverdeckung heraus

$$v_{ego} = 30.0 \text{ km/h}$$

$$v_{target} = 30 \text{ km/h}$$

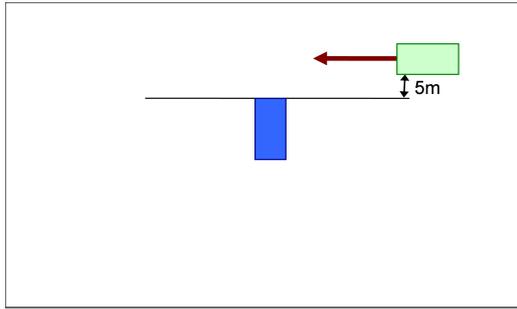


Test 6

Sensorfahrzeug fährt auf Kreuzung zu und bremst, Zielfahrzeug quert mit konstanter Geschwindigkeit aus Sichtverdeckung heraus

$$v_{ego} = 30.0 \text{ km/h}$$

$$v_{target} = 50 \text{ km/h}$$

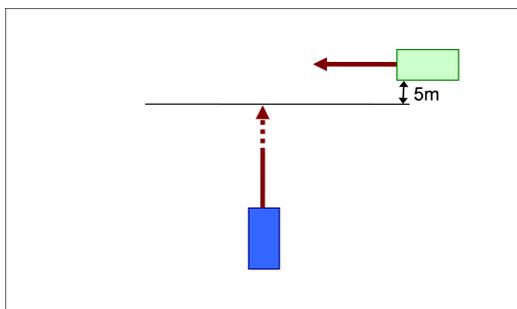


Test 7

Sensorfahrzeug steht, Zielfahrzeug quert und bremst dabei ab

$$v_{ego} = 0 \text{ km/h}$$

$$v_{target} = 50..30 \text{ km/h}$$

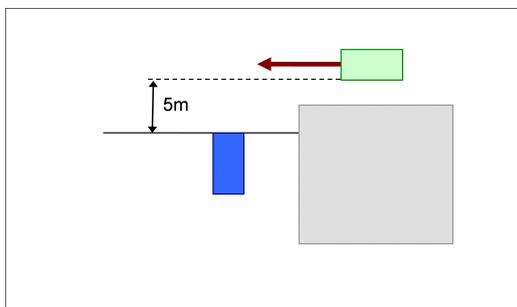


Test 8

Sensorfahrzeug fährt auf Kreuzung zu und bremst, Zielfahrzeug quert und bremst dabei ab

$$v_{ego} = 30..0 \text{ km/h}$$

$$v_{target} = 50..30 \text{ km/h}$$

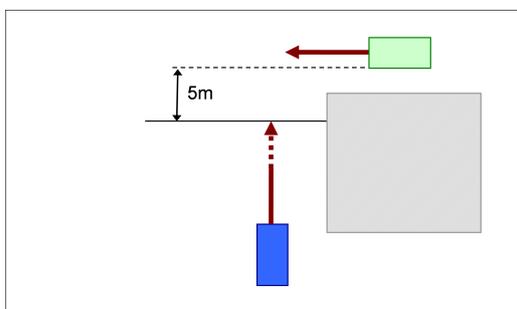


Test 9

Sensorfahrzeug steht, Zielfahrzeug quert aus Sichtverdeckung heraus und bremst dabei ab

$$v_{ego} = 0 \text{ km/h}$$

$$v_{target} = 50..30 \text{ km/h}$$

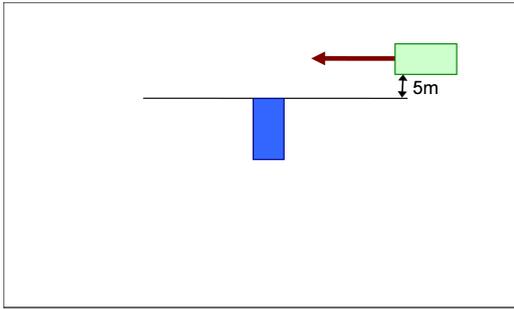


Test 10

Sensorfahrzeug fährt auf Kreuzung zu und bremst, Zielfahrzeug quert aus Sichtverdeckung heraus und bremst dabei ab

$$v_{ego} = 30..0 \text{ km/h}$$

$$v_{target} = 50..30 \text{ km/h}$$

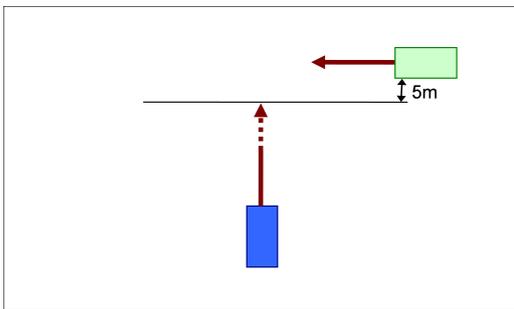


Test 11

Sensorfahrzeug steht, Zielfahrzeug quert und beschleunigt dabei

$$v_{ego} = 0 \text{ km/h}$$

$$v_{target} = 30..50 \text{ km/h}$$

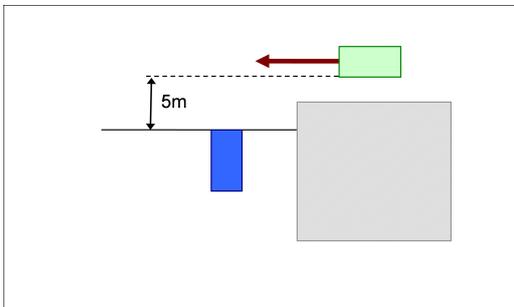


Test 12

Sensorfahrzeug fährt auf Kreuzung zu und bremst, Zielfahrzeug quert und beschleunigt dabei

$$v_{ego} = 30..0 \text{ km/h}$$

$$v_{target} = 30..50 \text{ km/h}$$

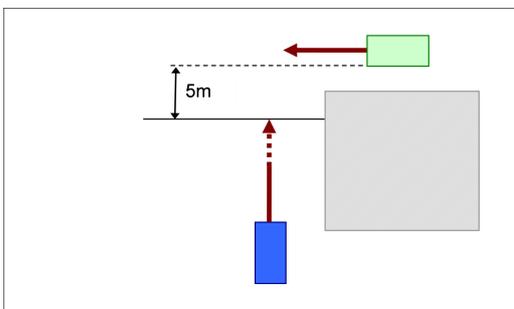


Test 13

Sensorfahrzeug steht, Zielfahrzeug quert aus Sichtverdeckung heraus und beschleunigt dabei

$$v_{ego} = 0 \text{ km/h}$$

$$v_{target} = 30..50 \text{ km/h}$$

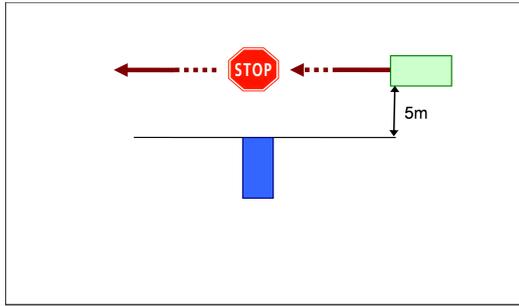


Test 14

Sensorfahrzeug fährt auf Kreuzung zu und bremst, Zielfahrzeug quert aus Sichtverdeckung heraus und beschleunigt dabei

$$v_{ego} = 30..0 \text{ km/h}$$

$$v_{target} = 30..50 \text{ km/h}$$

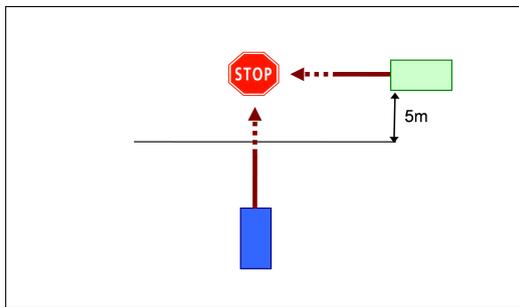


Test 15

Sensorfahrzeug steht, Zielfahrzeug quert, macht eine Vollbremsung und fährt wieder los

$$v_{ego} = 0 \text{ km/h}$$

$$v_{target} = 50..0..50 \text{ km/h}$$

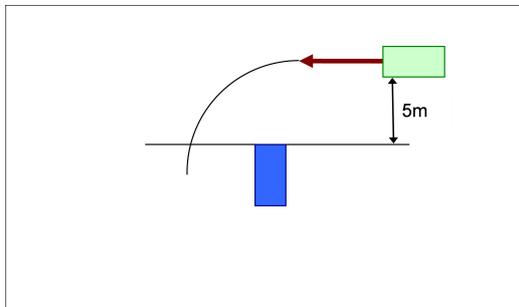


Test 16

Sensorfahrzeug und Zielfahrzeug fahren auf die Kreuzung zu und machen jeweils eine Vollbremsung

$$v_{ego} = 50..0 \text{ km/h}$$

$$v_{target} = 50..0 \text{ km/h}$$

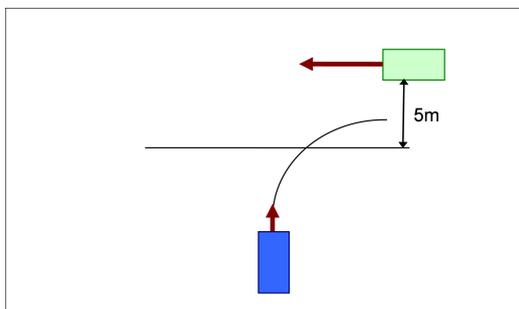


Test 17

Sensorfahrzeug steht, Zielfahrzeug kommt von rechts und biegt seinerseits nach links ab

$$v_{ego} = 0 \text{ km/h}$$

$$v_{target} = 50..20 \text{ km/h}$$

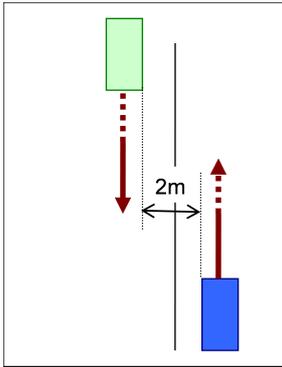


Test 18

Sensorfahrzeug fährt auf die Kreuzung zu und biegt nach rechts ab, Zielfahrzeug kommt von rechts und biegt seinerseits links ab

$$v_{ego} = 30..20 \text{ km/h}$$

$$v_{target} = 50..20 \text{ km/h}$$

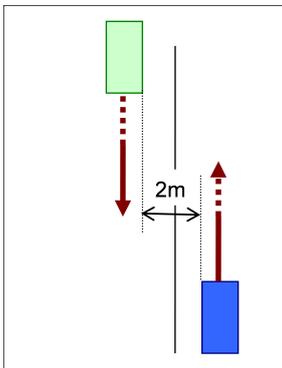


Test 19

Sensorfahrzeug fährt mit konstanter Geschwindigkeit, Zielfahrzeug kommt auf der Gegenspur entgegen und beschleunigt dabei

$$v_{ego} = 50 \text{ km/h}$$

$$v_{target} = 30..50 \text{ km/h}$$

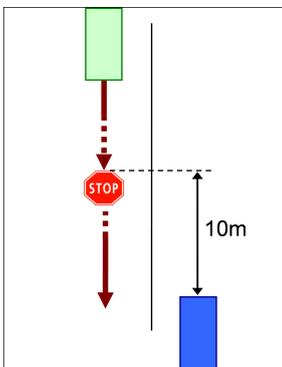


Test 20

Sensorfahrzeug beschleunigt, Zielfahrzeug kommt auf der Gegenspur entgegen und beschleunigt dabei

$$v_{ego} = 30..50 \text{ km/h}$$

$$v_{target} = 30..50 \text{ km/h}$$

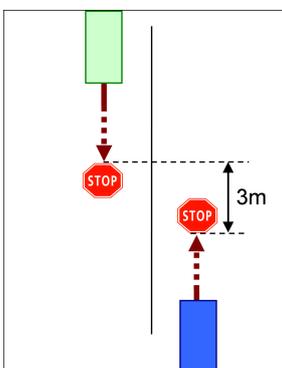


Test 21

Sensorfahrzeug steht, Zielfahrzeug kommt auf der Gegenspur entgegen, bremst bis zum Stillstand und fährt anschließend wieder los

$$v_{ego} = 0 \text{ km/h}$$

$$v_{target} = 50..0..50 \text{ km/h}$$

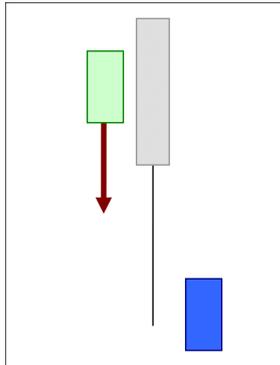


Test 22

Sensorfahrzeug und Zielfahrzeug kommen sich entgegen und machen beide eine Vollbremsung

$$v_{ego} = 50..0 \text{ km/h}$$

$$v_{target} = 50..0 \text{ km/h}$$

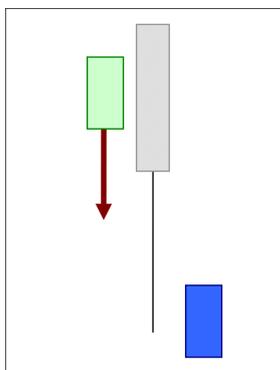


Test 23

Sensorfahrzeug steht, Zielfahrzeug kommt auf der Gegenseite aus Verdeckung heraus mit konstanter Geschwindigkeit entgegen

$$v_{ego} = 0 \text{ km/h}$$

$$v_{target} = 50 \text{ km/h}$$

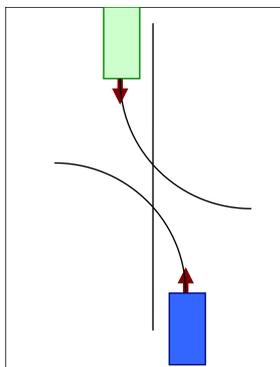


Test 24

Sensorfahrzeug steht, Zielfahrzeug kommt auf der Gegenseite aus Verdeckung heraus entgegen und bremst dabei

$$v_{ego} = 0 \text{ km/h}$$

$$v_{target} = 50..30 \text{ km/h}$$



Test 25

Sensorfahrzeug und Zielfahrzeug kommen sich entgegen und biegen voreinander links ab

$$v_{ego} = 50..20 \text{ km/h}$$

$$v_{target} = 50..20 \text{ km/h}$$

Abbildungsverzeichnis

1.1	Unfallstatistik der vergangenen 40 Jahre für Deutschland	2
1.2	Einteilung von Fahrerassistenzsystemen nach ihrer Funktion und Wirkungsweise	3
1.3	Unfälle mit Personenschäden und schweren Sachschäden 2010 aufgeschlüsselt nach dem Unfalltyp entsprechend [Sta11]	4
1.4	Messdaten des Laserscanners in einer realen Verkehrsszene und Objektdarstellung (rot). Größe und Ausrichtung von Objekten sind durch ein umgebendes Rechteck dargestellt. Wo anwendbar, repräsentieren Pfeile den (skalierten) Geschwindigkeitsvektor. Das Kamerabild zeigt die Sicht der Dokumentationskamera im Cockpit des Sensorfahrzeugs.	8
1.5	Koordinatensystem nach ISO 8855/DIN 70000	10
2.1	Prinzip des Laserscanners [1]	11
2.2	Winkelbereiche des Laserscanners: (a) horizontal, (b) vertikal	12
2.3	Signale beim Impulsradar	13
2.4	Sende- und Empfangssignal bei linearer Frequenzmodulation	16
2.5	Frequenzverlauf beim FMCW mit schnellen Rampen und Prinzip der Signalverarbeitung	17
2.6	Verbaupositionen der Sensoren im Versuchsträger	20
2.7	Flussdiagramm der Datenverarbeitungsschritte	20
3.1	Abstands-basierte Segmentierung: geometrische Grundlagen	22
3.2	Abstands-basierte Segmentierung angewendet auf Daten eines mehrzeiligen Laserscanners: (a) klassische Implementierung, (b) Implementierung mit Warteschlange	23
3.3	Segmentierungsgitter (nicht maßstabsgetreu) und Segmentierungsprozedur: (a) Projektion der Datenpunkte auf das Gitter, (b) Markieren belegter Gitterzellen (Anzahl Punkte > Schwellwert), Verbinden benachbarter Zellen und Nummerierung	24
3.4	Die longitudinale Aufweitung der Gitterzellen wird über den Parameter β bestimmt.	25
3.5	Zweistufige Segmentierung, oben: Kamerabild der Szene, Mitte: Ergebnis der einstufigen Segmentierung, unten: Ergebnis mit lokaler Nachsegmentierung	26
3.6	Vergleich der gitterbasierten Segmentierung vor und nach semiautomatisierter Parameteroptimierung	28
3.7	Vergleich zwischen linearer (rote, gestrichelte Linie) und orthogonaler Regression (blaue, durchgezogene Linie)	31
3.8	Laufzeit der unterschiedlichen Methoden zur Linieneinpassung für ein einzelnes Segment in Abhängigkeit der Punktzahl, rot: Constraint Least Squares, grün: RANSAC, blau: orthogonale Regression	32

3.9	Beispiele für Probleme bei der Linieneinpassung	33
3.10	Verschiebung des Schwerpunktes bei unterschiedlichen Betrachtungswinkeln	35
3.11	Zwei Beispiele für den virtuellen Referenzpunkt nach Santos et al. [SFS ⁺ 03]	36
3.12	Szenarioabhängige Verlagerung des Referenzpunktes	37
3.13	Verdeckung und daraus resultierende unzuverlässige Referenzpunkte	38
3.14	Segmentklassen	39
3.15	Vergleich der Alternativen zur Berechnung des Orientierungswinkels in unterschiedlichen Szenarien: (a) querendes Fahrzeug, (b) Kreisfahrt, (c) Parallelvorbeifahrt	41
3.16	Entscheidungsbaum zur Klassifikation von Segmenten	42
4.1	Geschwindigkeitsschätzung mit adaptivem Prozessrauschen	49
4.2	Zustandsmodell des Objektmanagements	57
4.3	Zusammenfassen von Objekten, links: getrennte Objekte nach dem Tracking, rechts: zusammengefasstes Objekt	57
4.4	Segmentkonfigurationen unter verschiedenen Sichtwinkeln als Zustände modelliert	58
4.5	Beispiel für mögliche Kantenzuordnungen	60
4.6	Fehler bei der Mehrfachassoziation durch plausible Segmentkombinationen	60
4.7	Objektattribute für ein L-förmiges Segment	61
4.8	Szenario 1 mit zwei querenden Fahrzeugen	62
4.9	Szenario 1 - Differenz zum wahren Wert, (a) simulierte Daten, (b) Realdaten	63
4.10	Szenario 2 mit zeitweise zerfallenem Segment	64
4.11	Szenario 2 - Differenz zum wahren Wert, (a) simulierte Daten, (b) Realdaten	65
5.1	Fusion von Punkt- und ausgedehnten Zielen unter Annahme eines einzelnen Streuzentrums	72
5.2	Verfälschung der Schätzung für querende Fahrzeuge durch unzureichende Modellierung der Radar-Reflexionszentren	73
5.3	Radarreflexionsmodelle an Fahrzeugen	73
5.4	Anwendung des erweiterten Radarreflexionsmodells	75
5.5	Flussdiagramm zur modellbasierten Fusion von Laserscanner- und Radarzielen	76
5.6	Zusammenhang zwischen radialer Geschwindigkeit und Objekt-Geschwindigkeit (a), Mehrdeutigkeit der Doppler-Geschwindigkeit (b)	77
5.7	Geschwindigkeitsabweichungen bei Offset-Fehlern in β	79
5.8	Mit Lenk- und Bremsroboter sowie DGPS und IMU ausgestattetes Versuchsfahrzeug: (a) Außenansicht, (b) Innenansicht	80
5.9	Geschätzte Trajektorien und Geschwindigkeiten bei einem Querfahrt-Szenario mit stehendem Sensorfahrzeug	82
5.10	Schätzergebnisse der Orientierung und Abmessungen bei einem Querfahrt Szenario mit stehendem Sensorfahrzeug	83
5.11	Geschätzte Trajektorien und Geschwindigkeiten bei einem Querfahrt-Szenario mit bewegtem Sensorfahrzeug	85
5.12	Schätzergebnisse der Orientierung und Abmessungen bei einem Querfahrt-Szenario mit bewegtem Sensorfahrzeug	86
5.13	Geschätzte Trajektorien und Geschwindigkeiten bei einem Längsfahrt-Szenario mit bewegtem Sensorfahrzeug	87

5.14	Schätzergebnisse der Orientierung und Abmessungen bei einem Längsfahrt-Szenario mit bewegtem Sensorfahrzeug	88
5.15	Folgefahrt-Szenario: (a) Referenz-Geschwindigkeiten, (b) Doppler-Messwerte Fernradar, (c) geschätzte Relativgeschwindigkeit	90
A.1	Szene 1: Parkplatzsituation	97
A.2	Szene 2: Innenstadtszene mit Fahrzeugen im Längsverkehr	97
A.3	Szene 3: Querverkehr	98
A.4	Szene 4: Kreuzung mit querenden und abbiegenden Fahrzeugen, Fußgängern, Ampeln und Randbebauung	98
A.5	Szene 5: Kreuzung ähnlich Szene 4 jedoch mit umgekehrter Abbiegerichtung und auf engerem Raum	98
A.6	Szene 6: Landstraße mit Entgegenkommern und dichter Vegetation am Straßenrand	99
A.7	Szene 7: Landstraße mit Vorfahrer und Einmündung	99
A.8	Szene 8: Zweispurige Autobahn mit LKW auf der rechten Spur	99

Tabellenverzeichnis

2.1	Spezifikationen der verwendeten Sensoren	18
2.2	Vergleich automotiver Sensortechnologien, Bewertung der Güte: ++ sehr gut, + gut, o befriedigend, – ausreichend, -- mangelhaft	19
3.1	Segmentierparameter vor und nach Optimierung	27
3.2	Merkmale für die Klassifikation	40
3.3	Güte des Entscheidungsbaumes, aufgeschlüsselt nach Klasse	43
3.4	Konfusionsmatrix nach zehnfacher Kreuzvalidierung	43
5.1	RMS - Querfahrt, Sensorfahrzeug statisch	84
5.2	RMS - Querfahrt, Sensorfahrzeug bewegt	84
5.3	RMS - Längsfahrt, Sensorfahrzeug bewegt	88
5.4	RMS - Manöverkatalog	89

Betreute Diplomarbeiten

- [1] Christoph Glöckler: *Sensorsignalverarbeitung für die lidarbasierte Fahrzeugumfelderfassung*. Diplomarbeit, Fachhochschule Würzburg-Schweinfurt, 2010.
- [2] Mirko Schmitt: *Entwicklung eines Test- und Analysetools für Segmentierverfahren auf Laserscannerdaten*. Diplomarbeit, Hochschule Bremen, 2009.
- [3] Yiliang Xu: *Adaptive Zustandsschätzung mit Laserscanner im automobilen Umfeld*. Diplomarbeit, Technische Universität Dresden, 2009.
- [4] David Kaimer: *Optimale Verfahren zur Segmentierung von Laserscannerdaten*. Diplomarbeit, Fachhochschule Münster, 2008.
- [5] Matthias Schmid: *Merkmalsextraktion aus Laserscannerdaten im automobilen Umfeld*. Diplomarbeit, Universität Ulm, 2008.

Liste der Publikationen

- [6] Sylvia Pietzsch, Olivier Aycard, Julien Burlet, Trung Dung Vu, Thomas Hackbarth, Nils Appenrodt, Jürgen Dickmann, and Bernd Radig: *Results of a precrash application based on laserscanner and short range radars*. In *Proceedings of the IEEE Intelligent Vehicles Symposium*, pages 367–372, Eindhoven, The Netherlands, June 4-6 2008.
- [7] Sylvia Pietzsch, Trung Dung Vu, Julien Burlet, Olivier Aycard, Thomas Hackbarth, Nils Appenrodt, Jürgen Dickmann, and Bernd Radig: *Results of a precrash application based on laser scanner and short-range radars*. *IEEE Transactions on Intelligent Transportation Systems*, 10(4):584–593, 2009.
- [8] J. Dickmann, F. Diewald, M. Mählich, J. Klappstein, S. Zuther, S. Pietzsch, S. Hahn, and M. Munz: *Environmental perception for future integrated safety systems*. In *International Technical Conference on the Enhanced Safety of Vehicles*, Stuttgart, Germany, June 15-18 2009.
- [9] Sylvia Pietzsch, Nils Appenrodt, Jürgen Dickmann, and Bernd Radig: *Model-based fusion of laser scanner and radar data for target tracking*. In *Proceedings of the 8th Intern. Workshop on Intelligent Transportation*, pages 11–16, 2011.

Literaturverzeichnis

- [Ale04] Alempijevic, Alen: *High-speed feature extraction in sensor coordinates for laser rangefinders*. In *Australasian Conference on Robotics and Automation*, 2004.
- [AMB07] Arras, Kai. O., Oscar Martinez Mozos, and Wolfram Burgard: *Using boosted features for the detection of people in 2d range data*. In *Proceedings of the IEEE International Conference on Robotics and Automation (IROS 2007)*, pages 3402–3407, April 10–14 2007.
- [BB03] Bizup, David F. and Donald E. Brown: *The over-extended kalman filter - don't use it!* In *Proceedings of the Sixth International Conference of Information Fusion*, volume 1, pages 40–46, 2003.
- [BB04] Bizup, D. F. and D. E. Brown: *Maneuver detection using the radar range rate measurement*. *IEEE Transactions on Aerospace and Electronic Systems*, 40(1):330–336, 2004.
- [BCG⁺08] Broggi, Alberto, Pietro Cerri, Stefano Ghidoni, Paolo Grisleri, and Ho Gi Jung: *Localization and analysis of critical areas in urban scenarios*. In *Proceedings of the IEEE Intelligent Vehicles Symposium*, pages 1074–1079, Eindhoven, The Netherlands, June 4-6 2008.
- [BI98] Brooks, Richard R. and Sundararaja S. Iyengar: *Multi-Sensor Fusion: Fundamentals and Applications with Software*. Prentice Hall, 1998.
- [Bla86] Blackman, Samuel S.: *Multiple-Target Tracking with Radar Applications*. Artech House, 1986.
- [Bla04] Blackman, Samuel S.: *Multiple hypothesis tracking for multiple target tracking*. *IEEE Aerospace and Electronic Systems Magazine*, 19(1):5–18, 2004.
- [BN93] Basseville, Michèle and Igor V. Nikiforov: *Detection of Abrupt Changes - Theory and Application*. Prentice-Hall, Upper Saddle River, N.J., USA, 1993.
- [BP99] Blackman, Samuel and Robert Popoli: *Design and Analysis of Modern Tracking Systems*. Artech House, 1999.
- [BS02] Bar-Shalom, Y.: *Update with out-of-sequence measurements in tracking: exact solution*. *IEEE Transactions on Aerospace and Electronic Systems*, 38(3):769–777, July 2002.
- [BSLK01] Bar-Shalom, Y., X. R. Li, and T. Kirubarajan: *Estimation with Applications to Tracking and Navigation: Theory, Algorithms, and Software*. Wiley, New York, 2001.
- [Büh08] Bühren, Markus: *Simulation und Verarbeitung von Radarziellisten im Automobil*. Dissertation, Universität Stuttgart, 2008.

- [Bun10a] Bundesanstalt für Straßenwesen: *Verkehrs- und Unfalldaten, Kurzzusammenstellung der Entwicklung in Deutschland*, 2010.
- [Bun10b] Bundesanstalt für Straßenwesen: *Volkswirtschaftliche Kosten durch Straßenverkehrsunfälle in Deutschland 2008*. *Forschung kompakt*, 17(10), 2010.
- [BY06] Bühren, Markus and Bin Yang: *Simulation of automotive radar target lists using a novel approach of object representation*. In *IEEE Intelligent Vehicles Symposium*, pages 314–319, Tokyo, Japan, June 2006.
- [CDB09] Chen, Yixin, Manohar Das, and Devendra Bajpai: *Improving time-to-collision estimation by imm based kalman filter*. SAE World Congress & Exhibition, April 2009.
- [CNR04] Castro, Daniel, Urbano Nunes, and António Ruano: *Feature extraction for moving objects tracking system in indoor environments*. Proc. 5th IFAC/euron Symposium on Intelligent Autonomous Vehicles, pages 5–7, July 2004.
- [Dar07] Darms, Michael: *Eine Basis-Systemarchitektur zur Sensordatenfusion von Umfeldsensoren für Fahrerassistenzsysteme*. Dissertation, Technische Universität Darmstadt, 2007.
- [Das97] Dasarathy, Belur V.: *Sensor fusion potential exploitation-innovative architectures and illustrative applications*. *Proceedings of the IEEE*, 85(1):24–38, January 1997.
- [Die13] Diewald, Fabian: *Objektklassifikation und Freiraumdetektion auf Basis bildgebender Radarsensorik für die Fahrzeugumfelderfassung*. Dissertation, Universität Ulm, 2013.
- [DSS01] Dietmayer, Klaus, Daniel Streller, and Jan Sparbert: *Model based object classification and object tracking in traffic scenes from range images*. In *Proceedings of IEEE Intelligent Vehicles Symposium*, 2001.
- [DST92] Dillencourt, Michael B., Hannan Samet, and Markku Tamminen: *A general approach to connected-component labeling for arbitrary image representations*. *Journal of the Association for Computer Machinery*, 39(2):253–280, April 1992.
- [DW88] Durrant-Whyte, H. F.: *Sensor models and multisensor integration*. *International Journal of Robotics Research - Special Issue on Sensor Data Fusion*, 7(6):97–113, December 1988.
- [Eff09] Effertz, Jan: *Autonome Fahrzeugführung in urbaner Umgebung durch Kombination objekt- und kartenbasierter Umfeldmodelle*. Dissertation, Fakultät für Elektrotechnik, Informationstechnik, Physik der Technischen Universität Carolo-Wilhelmina zu Braunschweig, Februar 2009.
- [ESW⁺05] Esteban, Jaime, Andrew Starr, Robert Willetts, Paul Hannah, and Peter Bryanston-Cross: *A review of data fusion models and architectures: towards engineering guidelines*. *Neural Computing and Applications*, 14(4):273–281, December 2005.
- [Eur01] Europäische Kommission: *Weißbuch-Die europäische Verkehrspolitik bis 2010: Weichenstellungen für die Zukunft*. Amt für amtliche Veröffentlichungen der europäischen Gemeinschaften, 2001.
- [Eur11] Europäisches Parlament-Ausschuss für Verkehr und Fremdenverkehr: *Bericht über die europäische Straßenverkehrssicherheit 2011–2020*. Plenarsitzungsdokument, July 2011.

-
- [FB81] Fischler, Martin A. and Robert C. Bolles: *Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography*. Communications of the ACM, 24(6):381–395, Juni 1981.
- [FC07] Fayad, Fadi and Veronique Cherfaoui: *Tracking objects using a laser scanner in driving situation based on modeling target shape*. In *Proceedings of the IEEE Intelligent Vehicles Symposium*, pages 44–49, June 13-15 2007.
- [FLD03] Fürstenberg, K., D. Linzmeier, and K. Dietmayer: *Pedestrian recognition and tracking of vehicles using a vehicle based multilayer laserscanner*. In *Proceedings of 10th World Congress on Intelligent Transport Systems (ITS 2003)*, Madrid, Spain, 2003.
- [Föl06] Fölster, Florian: *Erfassung ausgedehnter Objekte durch ein Automobil-Radar*. Dissertation, Technische Universität Hamburg-Harburg, Dezember 2006.
- [Frä07] Fränken, Dietrich: *Consistent unbiased linear filtering with polar measurements*. In *Proceedings of the 10th International Conference on Information Fusion*, pages 1–8, Quebec, July 2007.
- [Fre04] Freymann, Raymond: *Möglichkeiten und Grenzen von Fahrerassistenz- und Aktiven Sicherheitssystemen*. Tagung Aktive Sicherheit durch Fahrerassistenz, 2004.
- [FSSJ09] Fathabadi, Vahid, Mehdi Shahbazian, Karim Salahshour, and Lotfollah Jargani: *Comparison of adaptive kalman filter methods in state estimation of a nonlinear system using asynchronous measurements*. In *Proceedings of the World Congress on Engineering and Computer Science (WCECS)*, volume 2, San Francisco, USA, October 20–22 2009.
- [GH04] Gander, Walter and Jiri Hrebicek: *Solving Problems in Scientific Computing Using Maple and MATLAB®*. Springer, fourth edition, 2004.
- [GI96] Gustafsson, Fredrik and Alf J. Isaksson: *Best choice of coordinate system for tracking coordinated turns*. In *Proc. 35th IEEE Conf. Decision and Control*, pages 3145–3150, 1996.
- [Grü05] Gründl, Martin: *Fehler und Fehlverhalten als Ursache von Verkehrsunfällen und Konsequenzen für das Unfallvermeidungspotenzial und die Gestaltung von Fahrerassistenzsystemen*. Dissertation, Universität Regensburg, July 2005.
- [GSDB07] Gunnarsson, Joakim, Lennart Svensson, L. Danielsson, and Fredrik Bengtsson: *Tracking vehicles using radar detections*. In *Proceedings of the IEEE Intelligent Vehicles Symposium*, pages 296–302, Istanbul, Turkey, June 13–15 2007.
- [Gus00] Gustafsson, Fredrik: *Adaptive Filtering and Change Detection*. John Wiley & Sons, 2000.
- [HKF05] Henftling, Hermann, Dirk Klotzbücher, and Christian Frank: *Ultra wide band 24 ghz sequential lobing radar for automotive applications*. Proceedings of International Radar Symposium (IRS), pages 79–82, 2005.
- [HL97] Hall, David L. and James Llinas: *An introduction to multisensor data fusion*. Proceedings of the IEEE, 85(1):6–23, January 1997.
- [HTF09] Hastie, Trevor, Robert Tibshirani, and Jerome Friedman: *The Elements of Statistical Learning*. Springer, Heidelberg, 2nd edition, 2009.

- [JMF99] Jain, A. K., M. N. Murty, and P. J. Flynn: *Data clustering: A review*. ACM Computing Surveys (CSUR), 31(3):264–323, September 1999.
- [JU97a] Julier, Simon J. and Jeffrey K. Uhlmann: *A consistent, unbiased method for converting between polar and cartesian coordinate systems*. In *The Proceedings of AeroSense: The 11th International Symposium on Aerospace/Defense Sensing, Simulation and Controls*, pages 110–121, 1997.
- [JU97b] Julier, Simon J. and Jeffrey K. Uhlmann: *A new extension of the kalman filter to nonlinear systems*. Proc. SPIE Signal Processing, Sensor Fusion, and Target Recognition VI, 3068:182–193, 1997.
- [JU02] Julier, Simon J. and Jeffrey K. Uhlmann: *Reduced sigma point filters for the propagation of means and covariances through nonlinear transformations*. In *Proceedings of the American Control Conference*, volume 2, pages 887–892, Anchorage, May 8-10 2002.
- [JU04] Julier, Simon J. and Jeffrey K. Uhlmann: *Unscented filtering and nonlinear estimation*. Proceedings of IEEE, 92(3):401–422, 2004.
- [Kal60] Kalman, R. E.: *A new approach to linear filtering and prediction problems*. Transactions of the ASME—Journal of Basic Engineering, 82 (Series D):35–45, 1960.
- [Käm07] Kämpchen, Nico: *Feature-Level Fusion of Laser Scanner and Video Data for Advanced Driver Assistance Systems*. PhD thesis, Universität Ulm, Juni 2007.
- [Kap07] Kapp, Andreas: *Ein Beitrag zur Verbesserung und Erweiterung der Lidarsignalverarbeitung für Fahrzeuge*. Dissertation, Uni Karlsruhe, August 2007.
- [KD04] Kämpchen, N. and K. Dietmayer: *Imm vehicle tracking for traffic jam situations on highways*. In *Proceedings of 7th International Conference on Information Fusion*, Stockholm, Sweden, 2004.
- [KH04] Kim, Yong Shik and Keum Shik Hong: *An imm algorithm for tracking maneuvering vehicles in an adaptive cruise control environment*. International Journal of Control, Automation, and Systems, 2(3):310–318, September 2004.
- [KWSD04] Kämpchen, N., T. Weiss, M. Schaefer, and K. Dietmayer: *Imm object tracking for high dynamic driving maneuvers*. In *Proceedings of IEEE Intelligent Vehicles Symposium 2004 (IV 2004)*, Parma, Italy, 2004.
- [LBS93] Lerro, Don and Yaakov Bar-Shalom: *Tracking with unbiased consistent converted measurements versus ekf*. IEEE Transactions on Aerospace and Electronic Systems, 29(3):1015–1022, 1993.
- [LBS04] Lefebvre, Tine, Herman Bruyninckx, and Joris De Schutter: *Kalman filters for nonlinear systems: a comparison of performance*. International Journal of Control, 77(7):639–653, May 10 2004.
- [Lin09] Lindl, Rudi: *Tracking von Verkehrsteilnehmern im Kontext von Multisensorsystemen*. Dissertation, Technische Universität München, 2009.
- [LJ00] Li, X. Rong and Vesselin P. Jilkov: *A survey of maneuvering target tracking: Dynamic models*. In Drummond, Oliver E. (editor): *Proceedings of SPIE Conference on Signal and Data Processing of Small Targets*, volume 4048(22), pages 212–235, Orlando, FL, USA, April 2000.

- [LJ01a] Li, X. Rong and Vesselin P. Jilkov: *A survey of maneuvering target tracking: Ballistic target models*. In *Proceedings of SPIE Conference on Signal and Data Processing of Small Targets*, volume 4473, pages 559–581, San Diego, CA, USA, July 30–August 2 2001.
- [LJ01b] Li, X. Rong and Vesselin P. Jilkov: *A survey of maneuvering target tracking-part iii: Measurement models*. In *Proceedings of SPIE Conference on Signal and Data Processing of Small Targets*, volume 4473, pages 423–446, San Diego, CA, USA, July 30–August 2 2001.
- [LJ02] Li, X. Rong and Vesselin P. Jilkov: *A survey of maneuvering target tracking-part iv: Decision-based methods*. In *Proceedings of SPIE Conference on Signal and Data Processing of Small Targets*, volume 4728, pages 511–534, Orlando, FL, USA, April 2–4 2002.
- [LJ04] Li, X. Rong and Vesselin P. Jilkov: *A survey of maneuvering target tracking: Approximation techniques for nonlinear filtering*. In *Proc. 2004 SPIE Conf. Signal and Data Processing of Small Targets*, pages 537–550, San Diego, CA, USA, 2004.
- [LJ05] Li, X. Rong and Vesselin P. Jilkov: *A survey of maneuvering target tracking-part v: Multiple-model methods*. In *IEEE Transactions on Aerospace and Electronic Systems*, volume 41, pages 1255–1321. IEEE, October 2005.
- [Mac05] MacLachlan, Robert: *Tracking moving objects from a moving vehicle using a laser scanner*. Technical Report CMU-RI-TR-05-07, The Robotics Institute, Carnegie Mellon University, Pittsburgh, PA, Juni 2005.
- [Mah36] Mahalanobis, P. C.: *On the generalized distance in statistics*. *Proceedings National Institute of Science, India*, 2(1):49–55, 1936.
- [Mäh09] Mählich, Mirko: *Filtersynthese zur simultanen Minimierung von Existenz-, Assoziations- und Zustandsunsicherheiten in der Fahrzeugumfelderfassung mit heterogenen Sensordaten*. Dissertation, Universität Ulm, August 2009.
- [May82] Maybeck, Peter S.: *Stochastic models, estimation, and control*, volume 2. Academic Press, 1982.
- [Meh72] Mehra, R.: *Approaches to adaptive filtering*. *IEEE Transactions on Automatic Control*, 17(5):693–698, 1972.
- [Men99] Mende, Ralph: *Radarsysteme zur automatischen Abstandsregelung in Automobilen*. Dissertation, Universität Carolo-Wilhelmina zu Braunschweig, January 1999.
- [Mica] Microsoft Academic Search. <http://academic.research.microsoft.com/Publication/2122363/a-new-approach-to-linear-filtering-and-prediction-problems>. Zuletzt abgerufen am 04.08.2013.
- [Micb] Microsoft Academic Search. <http://academic.research.microsoft.com/Publication/1364468/an-introduction-to-the-kalman-filter>. Zuletzt abgerufen am 04.08.2013.
- [MN04] Mendes, Abel and Urbano Nunes: *Situation-based multi-target detection and tracking with laserscanner in outdoor semi-structured environment*. In *Proceedings of the IEEE International Conference on Intelligent Robots and Systems (IROS 2004)*, volume 1, pages 88–93, Sendai, Japan, September 28–October 2 2004.

- [MS05] Maurer, Markus und Christoph Stiller: *Fahrerassistenzsysteme mit maschineller Wahrnehmung*. Springer Verlag, 2005.
- [MSZD09] Muntzinger, M. M., F. Schroder, S. Zuther, and K. Dietmayer: *Out-of-sequence measurement processing for an automotive pre-crash application*. In *Intelligent Transportation Systems, 2009. ITSC '09. 12th International IEEE Conference on*, pages 1–6, 2009.
- [Mun11] Munz, Michael: *Generisches Sensorfusionsframework zur gleichzeitigen Zustands- und Existenzschätzung für die Fahrzeugumfeldererkennung*. Dissertation, Universität Ulm, 2011.
- [MZD09] Muntzinger, Marc M., Sebastian Zuther, and Klaus Dietmayer: *Probability estimation for an automotive pre-crash application with short filter settling times*. In *Proceedings of the IEEE Intelligent Vehicles Symposium*, pages 411–416, Xi'an, China, June 3-5 2009.
- [Naa04] Naab, Karl: *Sensoren und Signalverarbeitungsarchitekturen für Fahrerassistenz und Aktive Sicherheit*. Tagung Aktive Sicherheit durch Fahrerassistenz, 2004.
- [O'R98] O'Rourke, Joseph: *Computational Geometry in C*. Cambridge University Press, Cambridge, 2nd edition, 1998.
- [PLN09] Premebida, Cristiano, Oswaldo Ludwig, and Urbano Nunes: *Exploiting lidar-based features on pedestrian detection in urban scenarios*. In *Proceedings of the 12th International IEEE Conference on Intelligent Transportation Systems*, pages 18–23, St. Louis, MO, USA, October 3–7 2009.
- [Qui93] Quinlan, J. Ross: *C4.5: Programs for Machine Learning*. Morgan Kaufmann, San Mateo, California, 1st edition, January 1993.
- [RBL04] Ru, Jifeng, Anwer Bashi, and X. Rong Li: *Performance comparison of target maneuver onset detection algorithms*. In *In Proc. 2004 SPIE Conf. on Signal and Data Processing of Small Targets*, 2004.
- [RCLC05] Ru, Jifeng, Huimin Chen, X. Rong Li, and Genshe Chen: *A range rate based detection technique for tracking a maneuvering target*. In *SPIE Proceedings of Signal and data processing of small targets Conference*, volume 5913, pages 1–13, 2005.
- [RG05] Rasshofer, R. H. and K. Gresser: *Automotive radar and lidar systems for next generation driver assistance functions*. *Advances in Radio Science*, 3:205–209, 2005.
- [Rib04] Ribeiro, Maria Isabel: *Kalman and extended kalman filters: Concept, derivation and properties*. Technical report, Institute for Systems and Robotics, Lisboa, Portugal, February 2004.
- [RL07] Ruser, Heinrich und Fernando Puente León: *Informationfusion - Eine Übersicht*. *Technisches Messen*, 74(3):93–102, January 2007.
- [SA10] Spitzmiller, John N. and Reza R. Adhami: *Tracking with estimate-conditioned debiased 2-d converted measurements*. *Intelligent Information Management*, 2:286–294, April 2010.
- [Sar08] Sarholz, Frederik: *Konzeption und Realisierung einer Daten-Assoziation*. Diplomarbeit, Universität Ulm, 2008.

- [Sch05] Schröter, Derik: *Region & Gateway Mapping: Acquiring Structured and Object-Oriented Representations of Indoor Environments*. PhD thesis, Technische Universität München, Fakultät für Informatik, November 2005.
- [Sch07] Schuler, Karin: *Intelligente Antennensysteme für Kraftfahrzeug-Nahbereichs-Radar-Sensorik*. Dissertation, Universität Karlsruhe, Institut für Hochfrequenztechnik und Elektronik, November 2007.
- [Sch12] Schmid, Matthias: *Umgebungserfassung für Fahrerassistenzsysteme mit hierarchischen Belegungskarten*. Dissertation, Universität der Bundeswehr München, 2012.
- [SD04] Streller, D. and K. Dietmayer: *Multiple hypothesis classification with laser range finders*. In *Intelligent Transportation Systems, 2004. Proceedings. The 7th International IEEE Conference on*, pages 195–200, 3-6 Oct. 2004.
- [SFS⁺03] Santos, Sérgio, José Eduardo Faria, Fernando Soares, Rui Araújo, and Urbano Nunes: *Tracking of multi-obstacles with laser range data for autonomous vehicles*. In *3rd National Festival of Robotics Scientific Meeting (ROBOTICA 2003)*, pages 59–65, Lissabon, Portugal, Mai 2003.
- [SKD⁺12] Steinemann, Philipp, Jens Klappstein, Jürgen Dickmann, Hans Joachim Wünsche, and Felix von Hundelshausen: *3d outline contours of vehicles in 3d-lidar-measurements for tracking extended targets*. In *Proceedings of IEEE Intelligent Vehicles Symposium*, pages 432–437, Alcalá de Henares, Spain, June 2012.
- [Sko08] Skolnik, Merrill: *Radar Handbook*. Mc Graw Hill, 3rd edition, 2008.
- [Sku06] Skutek, Michael: *Ein PreCrash-System auf Basis multisensorieller Umgebungserfassung*. Dissertation, TU Chemnitz, Januar 2006.
- [SLAW05] Skutek, M., D. Linzmeier, N. Appenrodt, and G. Wanielik: *A precrash system based on sensor data fusion of laser scanner and short range radars*. In *8th International Conference on Information Fusion*, volume 2, Philadelphia, USA, July 2005.
- [SMK⁺11] Sarholz, F., J. Mehnert, J. Klappstein, J. Dickmann, and B. Radig: *Evaluation of different approaches for road course estimation using imaging radar*. In *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 4587–4592, 25-30 Sept. 2011.
- [Sta11] Statistisches Bundesamt: *Verkehrsunfälle 2010*. Verkehr, 8(7), July 2011.
- [Stü03] Stüker, Dirk: *Heterogene Sensordatenfusion zur robusten Objektverfolgung im automobilen Straßenverkehr*. Dissertation, Carl von Ossietzky–Universität Oldenburg, November 2003.
- [TBF98] Thrun, Sebastian, Wolfram Burgard, and Dieter Fox: *A probabilistic approach to concurrent mapping and localization for mobile robots*. *Machine Learning and Autonomous Robots*, 31(5):1–25, 1998.
- [Tho05] Thoma, Stephan: *Fusion von Infrarotvideo- und Laserscanner-Daten zur Fußgängererkennung*. Diplomarbeit, Technische Universität München, Dezember 2005.
- [VBS⁺06] Vollrath, Mark, Susanne Briest, Caroline Schießl, Jörn Drewes und Uwe Becker: *Anforderungen an Fahrerassistenzsysteme aus Sicht der Verkehrssicherheit*. Berichte der Bundesanstalt für Straßenwesen, Fahrzeugtechnik Heft F 60, 2006.

- [Vu09] Vu, Trung Dung: *Vehicle Perception: Localization, Mapping with Detection, Classification and Tracking of Moving Objects*. PhD thesis, Institut National Polytechnique de Grenoble, September 2009.
- [Wal08] Walchshäusl, Leonhard: *Maschinelle Erkennung von Verkehrsteilnehmern mittels heterogener Sensorik*. Dissertation, Technische Universität München, Fakultät für Informatik, 2008.
- [WB01] Welch, Greg and Gary Bishop: *An introduction to the kalman filter*. In *SIGGRAPH*, 2001.
- [WDC⁺08] Wu, Shunguan, Stephen Decker, Peng Chang, Theodore Camus, and Jayan Eldath: *Collision sensing by stereo vision and radar sensor fusion*. In *Proceedings of IEEE Intelligent Vehicles Symposium*, pages 404–409, June 4–6 2008.
- [Wen08] Wender, Stefan: *Multisensorsystem zur erweiterten Fahrzeugumfelderfassung*. Dissertation, Universität Ulm, Fakultät für Ingenieurwissenschaften und Informatik, Oktober 2008.
- [WHW09] Winner, Hermann, Stephan Hakuli und Gabriele Wolf (Herausgeber): *Handbuch Fahrerassistenzsysteme*. Vieweg+Teubner, GWV Fachverlage GmbH, Wiesbaden, 2009.
- [Wor] World Health Organization: *Road safety*. http://www.who.int/gho/road_safety/en/index.html. Zuletzt abgerufen am 02.10.2012.
- [WW07] Wahl, Rene and Gerd Wölfle: *Using a 3d ray tracing model with radar cross sections for the prediction of spatial channel impulse responses in time variant scenarios*. In *Proceedings of the 4th International Workshop on Intelligent Transportation (WIT2007)*, Hamburg, March 2007.
- [WWWa] „Automatisiertes Fahren“ präzisiert Prüfmethodik. <http://www.daimler-technicity.de/af/>. Zuletzt abgerufen am 23.06.2011.
- [WWWb] *Fahrerassistenzsysteme*. http://www.versicherung-und-verkehr.de/uploads/media/GDV_Fahrerassistenzsysteme.pdf. Zuletzt abgerufen am 30.09.2012.
- [XI05] Xu, Rui and Donald Wunsch II: *Survey of clustering algorithms*. *IEEE Transactions on Neural Networks*, 16(3):645–678, May 2005.
- [XPC⁺05] Xavier, Joao, Marco Pacheco, Daniel Castro, Antonio Ruano, and Urbano Nunes: *Fast line, arc/circle and leg detection from laser scan data in a player driver*. In *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA 2005)*, pages 3930–3935, April 2005.
- [YKBS04] Yeom, S. W., T. Kirubarajan, and Y. Bar-Shalom: *Track segment association, fine-step imm and initialization with doppler for improved track performance*. *IEEE Transactions on Aerospace and Electronic Systems*, 40(1):293–309, January 2004.
- [ZSKS06] Zhao, H., X. W. Shao, K. Katabira, and R. Shibasaki: *Joint tracking and classification of moving objects at intersection using a single-row laser range scanner*. In *Proceedings of the IEEE Intelligent Transportation Systems Conference*, pages 287–294, Toronto, Canada, September 17-20 2006.

- [ZZC⁺09] Zhao, Huijing, Quanshi Zhang, Masaki Chiba, Ryosuke Shibasaki, Jinshi Cui, and Hongbin Zha: *Moving object classification using horizontal laser scan data*. In *Proceedings of the IEEE International Conference on Robotics and Automation*, pages 2424–2430, Kobe, Japan, May 12–17 2009.