


# Modellierung der Sensorabdeckung autonomer Fahrzeuge zur Berechnung optimaler Annäherungspfade

Sensor coverage modeling of autonomous vehicles to calculate optimal approach paths



Wissenschaftliche Arbeit zur Erlangung des Grades

Master of Science (M.Sc.)

an der Fakultät für Maschinenwesen der Technischen Universität München

**Betreut von** Univ.-Prof. Dr.-Ing. Markus Lienkamp  
Thomas Ponn, M.Sc.  
Lehrstuhl für Fahrzeugtechnik

**Eingereicht von** Fabian Müller, B.Sc.  
Josef-Wirth-Weg 21  
80939 München

**Eingereicht am** 15.11.2018



## Aufgabenstellung

### Modellierung der Sensorabdeckung autonomer Fahrzeuge zur Berechnung optimaler Annäherungspfade

Hochautomatisierte und autonome Fahrzeuge können in ihrem Einsatz einer unendlichen Zahl an verschiedenen Verkehrsszenarien ausgesetzt sein. Um die Sicherheit dieser Systeme gewährleisten zu können, müssten daher alle theoretisch möglichen Szenarien getestet werden, was in der Realität nicht praktikabel ist. Für eine wirtschaftliche Überprüfung müssen aus der unbegrenzten Anzahl möglichst relevante Szenarien gewählt werden. Ein solches Szenario kann beispielsweise sein, dass sich ein Objekt aus einer bestimmten Richtung annähert, aus der es die Fahrzeugsensorik möglichst schlecht erfassen und tracken kann. Dazu muss zuerst die Sensorabdeckung des Fahrzeugs modelliert und visualisiert werden. Dies kann zusätzlich unter Berücksichtigung der Änderungen durch die Fahrbahneigung, etc. dargestellt werden. Anschließend kann daraus ein optimaler Annäherungspfad berechnet werden.

In einer theoretischen Masterarbeit soll die Sensorabdeckung autonomer Fahrzeuge visualisiert und anschließend ein optimaler Annäherungspfad ermittelt werden. Folgende Punkte sind durch Herrn Fabian Müller zu bearbeiten:

- Einarbeitung in die Absicherung von autonomen Fahrzeugen und in die Sensortechnologie
- Visualisierung der Sensorabdeckung auf Basis der verwendeten Sensoren, deren Einbaulage, Reichweite und weiteren Eigenschaften
- Berücksichtigung der Änderungen durch Fahrbahneigung, Fahrbahnverlauf, etc.
- Implementierung eines Verfahrens zur Wahl eines optimalen Annäherungspfads. Optimal bedeutet hierbei, dass die Fahrzeugsensorik das Objekt möglichst schlecht / spät erkennen kann.
- Dokumentation der Ergebnisse

Die Ausarbeitung soll die einzelnen Arbeitsschritte in übersichtlicher Form dokumentieren. Der Kandidat/Die Kandidatin verpflichtet sich, die Masterarbeit selbstständig durchzuführen und die von ihm verwendeten wissenschaftlichen Hilfsmittel anzugeben.

Die eingereichte Arbeit verbleibt als Prüfungsunterlage im Eigentum des Lehrstuhls.

Ausgabe: 15.05.2018

Abgabe: 15.11.2018

---

Prof. Dr.-Ing. M. Lienkamp

---

Betreuer: Thomas Ponn, M. Sc.



# Geheimhaltungsverpflichtung

Herr/Frau: **Müller, Fabian**

Gegenstand der Geheimhaltungsverpflichtung sind alle mündlichen, schriftlichen und digitalen Informationen und Materialien die der Unterzeichner vom Lehrstuhl oder von Dritten im Rahmen seiner Tätigkeit am Lehrstuhl erhält. Dazu zählen vor allem Daten, Simulationswerkzeuge und Programmcode sowie Informationen zu Projekten, Prototypen und Produkten.

Der Unterzeichner verpflichtet sich, alle derartigen Informationen und Unterlagen, die ihm während seiner Tätigkeit am Lehrstuhl für Fahrzeugtechnik zugänglich werden, strikt vertraulich zu behandeln.

Er verpflichtet sich insbesondere:

- derartige Informationen betriebsintern zum Zwecke der Diskussion nur dann zu verwenden, wenn ein ihm erteilter Auftrag dies erfordert,
- keine derartigen Informationen ohne die vorherige schriftliche Zustimmung des Betreuers an Dritte weiterzuleiten,
- ohne Zustimmung eines Mitarbeiters keine Fotografien, Zeichnungen oder sonstige Darstellungen von Prototypen oder technischen Unterlagen hierzu anzufertigen,
- auf Anforderung des Lehrstuhls für Fahrzeugtechnik oder unaufgefordert spätestens bei seinem Ausscheiden aus dem Lehrstuhl für Fahrzeugtechnik alle Dokumente und Datenträger, die derartige Informationen enthalten, an den Lehrstuhl für Fahrzeugtechnik zurückzugeben.

Besondere Sorgfalt gilt im Umgang mit digitalen Daten:

- Für den Dateiaustausch dürfen keine Dienste verwendet werden, bei denen die Daten über einen Server im Ausland geleitet oder gespeichert werden (Es dürfen nur Dienste des LRZ genutzt werden (Lehrstuhlaufwerke, Sync&Share, GigaMove).
- Vertrauliche Informationen dürfen nur in verschlüsselter Form per E-Mail versendet werden.
- Nachrichten des geschäftlichen E-Mail Kontos, die vertrauliche Informationen enthalten, dürfen nicht an einen externen E-Mail Anbieter weitergeleitet werden.
- Die Kommunikation sollte nach Möglichkeit über die (my)TUM-Mailadresse erfolgen.

Die Verpflichtung zur Geheimhaltung endet nicht mit dem Ausscheiden aus dem Lehrstuhl für Fahrzeugtechnik, sondern bleibt 5 Jahre nach dem Zeitpunkt des Ausscheidens in vollem Umfang bestehen. Die eingereichte schriftliche Ausarbeitung darf der Unterzeichner nach Bekanntgabe der Note frei veröffentlichen.

Der Unterzeichner willigt ein, dass die Inhalte seiner Studienarbeit in darauf aufbauenden Studienarbeiten und Dissertationen mit der nötigen Kennzeichnung verwendet werden dürfen.

Datum: 15.05.2018

Unterschrift: \_\_\_\_\_



## Erklärung

Ich versichere hiermit, dass ich die von mir eingereichte Abschlussarbeit selbstständig verfasst und keine anderen als die angegebenen Quellen und Hilfsmittel benutzt habe.

Garching, den 15.11.2018

---

Fabian Müller, B. Sc.





# Inhaltsverzeichnis

<b>Abkürzungsverzeichnis .....</b>	<b>III</b>
<b>Formelzeichen.....</b>	<b>V</b>
<b>1 Einleitung .....</b>	<b>1</b>
<b>1.1 Motivation.....</b>	<b>1</b>
<b>1.2 Ziel der Arbeit .....</b>	<b>2</b>
<b>1.3 Aufbau der Arbeit .....</b>	<b>3</b>
<b>2 Stand der Technik .....</b>	<b>5</b>
<b>2.1 Automatisierung von Fahrzeugen .....</b>	<b>5</b>
<b>2.2 Absicherung autonomer Fahrzeuge.....</b>	<b>7</b>
<b>2.3 Umfelderkennung .....</b>	<b>8</b>
2.3.1 Radarsensor .....	8
2.3.2 Ultraschallsensoren .....	15
2.3.3 Lidarsensoren .....	16
2.3.4 Kamerasensoren .....	18
2.3.5 Vergleich der Sensoren .....	21
2.3.6 Sensorfusion.....	23
<b>2.4 Sensormodellierung.....</b>	<b>25</b>
2.4.1 Idealisierte Modelle .....	25
2.4.2 Phänomenologische Modelle.....	26
2.4.3 Physikalische Modelle.....	26
2.4.4 Sensorabdeckungsmodelle .....	27
<b>2.5 Optimierung .....</b>	<b>29</b>
2.5.1 Mathematische Optimierung.....	29
2.5.2 Optimierung mit MATLAB .....	31
<b>3 Methoden.....</b>	<b>33</b>
<b>3.1 Modellanforderungen.....</b>	<b>33</b>
<b>3.2 Modellannahmen .....</b>	<b>34</b>
3.2.1 Sensortopologie .....	34

3.2.2	Sensoreigenschaften .....	36
3.2.3	Antennencharakteristik .....	39
3.2.4	Rückstreuquerschnitte .....	41
3.2.5	Wetterbedingungen .....	43
3.2.6	Receiver Operating Characteristics .....	44
<b>3.3</b>	<b>Modellaufbau .....</b>	<b>45</b>
<b>4</b>	<b>Ergebnisse und Diskussion .....</b>	<b>51</b>
4.1	Fernfelduntersuchung .....	51
4.2	Nahfelduntersuchung .....	63
4.3	Pfadoptimierung .....	69
4.4	Diskussion der Ergebnisse .....	77
<b>5</b>	<b>Zusammenfassung und Ausblick .....</b>	<b>81</b>
5.1	Zusammenfassung .....	81
5.2	Ausblick .....	82
	<b>Abbildungsverzeichnis .....</b>	<b>i</b>
	<b>Tabellenverzeichnis .....</b>	<b>v</b>
	<b>Literaturverzeichnis .....</b>	<b>vii</b>
	<b>Anhang .....</b>	<b>xiii</b>

# Abkürzungsverzeichnis

BASt	Bundesanstalt für Straßenwesen
EIRP	Äquivalente Isotrope Strahlungsleistung (engl. Equivalent Isotropically Radiated Power)
FMCW	Frequency Modulated Continuous Wave
IEEE	Institute of Electrical and Electronics Engineers
Lidar	Light Detection and Ranging
LRR	Fernbereichsradar (engl. Long Range Radar)
MRR	Mittelbereichsradar (engl. Mid Range Radar)
Radar	Radio Detection and Ranging
RCS	Rückstreuquerschnitt (engl. Radar Cross Section)
ROC	Receiver Operating Characteristics
SAE	Society of Automotive Engineers
SNR	Signal-Rausch-Verhältnis (engl. Signal-Noise-Ratio)
SRR	Nahbereichsradar (engl. Short Range Radar)
TOF	Laufzeit (engl. Time of Flight)



# Formelzeichen

Formelzeichen	Einheit	Beschreibung
$A$	-	Amplitude des Sende- und Empfangssignals
$A_r$	m <sup>2</sup>	Empfängerfläche
$B_n$	1/s	Rauschbandbreite
$D_r$	m	Empfängerdurchmesser
$E_{sun}$	W/m <sup>2</sup>	Strahlungsdichte der Sonnenstrahlung
$f$	-	Brennweite des Kamerasensors
$f_0$	1/s	Trägerfrequenz
$f_D$	1/s	Dopplerfrequenz
$f_{Hub}$	1/s	Frequenzintervall
$G_r$	dB	Antennengewinn im Empfänger
$G_t$	dB	Antennengewinn im Sender
$h_o$	-	Objekthöhe im Bild
$H$	m	Objekthöhe
$l_N$	m	Nahfeldlänge
$L_{ges}$	dB	Dämpfungsfaktor
$m_{sp}$	-	Glaubensfunktion
$N$	-	Anzahl an Abtastwerten
$N_e$	-	Anzahl an Elektronen
$N_{e,n}$	-	Anzahl an Rauschelektronen
$N_{e,n,shot}$	-	Anzahl an Rauschelektronen durch Schrotrauschen
$N_{pix,image}$	-	Auflösung des Kamerasensors
$N_{pix,o}$	-	Objektgröße im Bild
$p_D$	-	Detektionswahrscheinlichkeit
$p_{D,value,path}$	-	Kostenfunktion der Optimierung

## Formelzeichen

---

$p_{FA}$	-	Fehlalarmquote
$P_n$	W	Rauschleistung
$P_o$	W	Vom Objekt aufgenommene Strahlungsleistung
$P_r$	W	Empfangene Strahlungsleistung
$P_{r,ideal}$	W	Empfangene ideale Strahlungsleistung
$P_{r,image}$	W	Empfangene Strahlungsleistung des Kamerasensors
$P_t$	W	Ausgesendete Strahlungsleistung
$QE$	-	Quanteneffizienz
$R$	m	Entfernung
$R_o$	m	Entfernung zum Objekt
$R_s$	m	Maximale Sensorreichweite
$S_{iso}$	W/m <sup>2</sup>	Isotrope Strahlungsdichte
$S_r$	W/m <sup>2</sup>	Empfangene Strahlungsdichte
$S_t$	W/m <sup>2</sup>	Ausgesendete Strahlungsdichte
$SNR$	-	Signal-Rausch-Verhältnis
$t_E$	s	Empfangszeitpunkt des reflektierten Impulses
$t_S$	s	Sendezeitpunkt des Impulses
$T_{int}$	s	Integrationszeit des Kamerasensors
$T_P$	1/s	Pulswiederholffrequenz
$T_R$	s	Rampendauer
$T_{sys}$	K	Systemrauschtemperatur
$v_{rel}$	m/s	Relativgeschwindigkeit
$w_o$	-	Objektbreite im Bild
$W$	m	Objektbreite
$dx_i$	m	Abstand zwischen zwei Berechnungspunkten
$x_{sp}$	-	Gewichtete Wahrscheinlichkeit der Gkaubensfunktion
$\theta$	°	Keulenbreite
$\theta_0$	-	Objektzustand (nicht abgedeckt)
$\theta_1$	-	Objektzustand (abgedeckt)
$\lambda$	m	Wellenlänge der Strahlung
$\nu$	1/s	Frequenz der Strahlung

---

$\sigma$	m <sup>2</sup>	Rückstreuquerschnitt
$\tau$	s	Pulsdauer
$\tau_p$	s	Impulsdauer
$\phi$	°	Azimuth
$\psi$	°	Elevation
$\Theta$	-	Raum der Unterscheidung





# 1 Einleitung

Nach [1] steht die Automobilindustrie derzeit vor drei großen Herausforderungen, die die Zukunft dieser Industrie und der modernen Gesellschaft prägen werden. Die erste Herausforderung ist die Energieproblematik, ausgelöst durch Nachhaltigkeitssorgen und Umweltprobleme, die die Industrie zur Entwicklung alternativer Antriebe veranlasst. Die zweite Herausforderung ist der Wandel von individueller Mobilität zu gemeinsam genutzter Mobilität, der die Konzeption neuer Mobilitätsstrategien erfordert. Die dritte Herausforderung ist das autonome Fahren, das dem Wunsch entspringt die Anzahl und Schwere von Unfällen zu reduzieren, die Mobilität der Menschen zu erhöhen, Emissionen zu reduzieren und die Infrastruktur effizienter zu nutzen.

Eine der Hauptmotivationen des autonomen Fahrens ist die Unempfindlichkeit gegenüber menschlicher Fehler wie Ablenkung, Unachtsamkeit oder Fehleinschätzungen, die für 94% aller entstandenen Verkehrsunfälle verantwortlich sind [2, S. 1], [3, S. 384]. Autonome Fahrzeuge bieten hier ein großes Potential zur Reduzierung der Anzahl an Unfällen, weil Computer den Menschen als Fahrer ersetzen und dessen Fahraufgabe übernehmen. Der eigentliche Fahrer wird zum Passagier, der sich während der Fahrt anderen Dingen, wie beispielsweise E-Mails checken, im Internet surfen oder in einem Buch lesen, widmen kann. Durch eine zunehmende Automatisierung der Fahrzeuge entstehen aber gleichzeitig neue Unsicherheiten, weil auch Computer und Software nicht frei von Fehlern sind [4, S. 70]. Für die Homologierung von autonomen Fahrzeugen bedarf es aus diesem Grund einer zwangsweisen Absicherung der Hardware und Software. Im Automobilbereich existieren bis auf die Zertifizierung von ESP keinerlei Erfahrungswerte bei der Zertifizierung von sicherheitskritischer Software, weshalb es aktuell noch keine passenden Absicherungskonzepte für autonome Fahrzeuge gibt.

## 1.1 Motivation

Aktuell wird bei der Homologierung von Fahrzeugen nur der in (Abbildung 1.1) blau hinterlegte Bereich berücksichtigt, wobei es sich bis auf die Prüfung des ESP ausschließlich um Tests der Hardware handelt. Bei autonomen Fahrzeugen muss zusätzlich der in (Abbildung 1.1) grau hinterlegte Bereich zertifiziert werden, der von Software übernommen wird. Der Mensch als Fahrer führt die Fahraufgabe bestehend aus Navigation, Bahnführung und Stabilisierung auf Basis von wissensbasiertem, regelbasiertem und fertigkeitbasiertem Verhalten aus und besitzt die Fähigkeit dieses Verhalten auch auf ähnliche Situationen übertragen zu können [5, S. 258]. Dies ist die Grundlage der Führerscheiprüfung, die in einer begrenzten Zeit nur einige wenige Situationen des Verkehrsgeschehens abprüft. Besteht ein Mensch die Führerscheiprüfung, wird angenommen, dass er sich auch in anderen Situation des Verkehrsgeschehens richtig verhalten kann. Software weist die drei Verhaltensweisen des Menschen nicht auf, wodurch ein Übertrag auf die Ausführung vergleichbarer Situationen derzeit nicht gegeben ist. Eine Führerscheiprüfung für autonome Fahrzeuge im bisherigen Maße

ist dementsprechend nicht ausreichend. Folglich muss bei der Absicherung und Freigabe von autonomen Fahrzeugen eine hohe Anzahl an Testfällen berücksichtigt werden, die mit zunehmender Automatisierung exponentiell ansteigt und in einem ökonomisch nicht vertretbaren Testaufwand resultiert [6, S. 14]. Die theoretisch unendliche Anzahl an Testfällen ergibt sich aus der Kombination der unterschiedlichen Verkehrsszenarien mit variierenden Umgebungsbedingungen, Umweltbedingungen und dem nicht deterministischen Verhalten der anderen Verkehrsteilnehmer. Aufgrund der Anzahl an Parametern, die die Testfälle beeinflussen, lässt sich der resultierende Testraum unmöglich vollständig definieren und ist selbst durch den Einsatz gängiger Simulationsmethoden nicht beherrschbar.

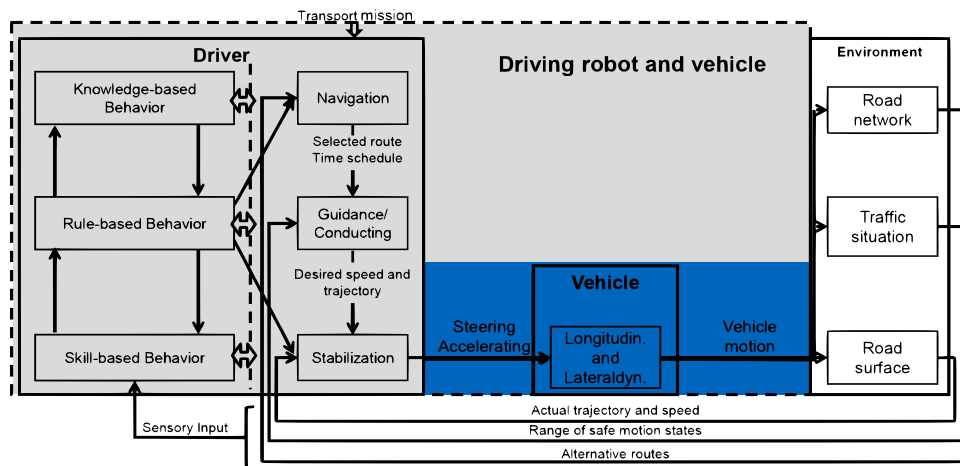


Abbildung 1.1: Unterschied zwischen konventionellen und autonomen Fahrzeugen (nach Rasmussen und Donges) [5], [7]

Aus diesem Grund muss die Auswahl der wichtigsten und vor allem auch relevanten Testfälle im Fokus zukünftiger Absicherungskonzepte stehen [8, S. 24]. Die Herausforderung hierbei besteht in der Definition der relevanten Testfälle, um einerseits alle Aspekte der Anforderungen abzutesten und andererseits die Anzahl der benötigten Testfälle möglichst gering zu halten [9, S. 139].

## 1.2 Ziel der Arbeit

Durch den Einsatz von Simulationsmethoden kann der Zeitaufwand für die Absicherung und Freigabe von autonomen Fahrzeugen deutlich reduziert werden. Der Testraum, bestehend aus einer theoretisch unendlichen Anzahl an Testfällen, kann auch mit Hilfe der Simulation nicht vollständig abgedeckt werden. Eine Möglichkeit zur Einschränkung des Testraums und Reduzierung des Testaufwands bietet die Definition von komplexen Szenarien bzw. Worst-Case Szenarien, weil diese eine Vielzahl einfacherer Szenarien enthalten bzw. Szenarien mit geringerer Auswirkung beinhalten [9, S. 143].

Wie solche Szenarien definiert und ausgewählt werden können und welche Aspekte dabei berücksichtigt werden müssen stellt eine große Herausforderung dar und ist Gegenstand aktueller Untersuchungen. Einen Ansatz zur Definition von Worst-Case Szenarien soll im Rahmen der vorliegenden Arbeit anhand der Berechnung optimaler Annäherungspfade aufgezeigt werden.

Dafür soll eine Methodik entwickelt werden, die die Optimierung von Annäherungspfaden an autonome Fahrzeuge auf Basis der Modellierung derer Sensorabdeckung ermöglicht. Das Ergebnis der Modellierung der Sensorabdeckung soll eine Aussage bezüglich der Detektionswahrscheinlichkeit von Objekten im Erfassungsbereich der Sensoren liefern. Das konkrete Ziel der vorliegenden Arbeit ist somit der Aufbau eines entsprechenden Berechnungsmodells, das neben der Berechnung optimaler Annäherungspfade auch eine Visualisierung der Sensorabdeckung autonomer Fahrzeuge ermöglicht. Die im Berechnungsmodell zu implementierenden Sensormodelle sollen neben geometrischen Informationen auch Umwelteinflüsse, Objekteigenschaften und spezifische Sensorcharakteristiken berücksichtigen und durch Funktionen definiert werden, die einem Objekt, das sich innerhalb des Detektionsbereichs eines Sensors befindet, einen Wert für dessen Detektionswahrscheinlichkeit zuordnen, abhängig von dessen Eigenschaften, Position und den Umgebungsbedingungen. Durch die Verknüpfung der Einzelwerte für verschiedene Positionen, sollen Gesamtwerte für die Detektionswahrscheinlichkeit möglicher Annäherungspfade berechnet werden. Unter Verwendung dieser Gesamtwerte sollen die möglichen Annäherungspfade durch ein Optimierungsverfahren optimiert werden (d.h. ein möglichst kleiner Gesamtwert).

Die nach diesem Verfahren bestimmten optimalen Annäherungspfade beschreiben somit die Trajektorie eines Objekts mit der geringsten Detektionswahrscheinlichkeit an ein autonomes Fahrzeug und sollen als Basis zur Definition von Worst-Case Szenarien dienen.

## 1.3 Aufbau der Arbeit

Die vorliegende Arbeit gliedert sich in fünf Kapitel, die in (Abbildung 1.2) dargestellt sind. Nach der Einleitung wird im zweiten Kapitel der Stand der Technik dargelegt. Zu Beginn wird die Automatisierung von Fahrzeugen beschrieben und die verschiedenen Stufen der Automatisierung definiert. Es werden aktuelle Methoden und Ansätze zur Absicherung autonomer Fahrzeuge vorgestellt und die Vor- und Nachteile dieser diskutiert. Weiter werden die zur Umfelderkennung verwendeten Sensoren vorgestellt, ihre grundlegende Funktionsweise beschrieben und ihre Umsetzung in Modellen aufgezeigt. Zum Abschluss des Kapitels werden die Grundlagen der mathematischen Optimierung erläutert und die Umsetzung einer Optimierung in MATLAB vorgestellt.

Im dritten Kapitel wird die Methodik präsentiert, die dem im Rahmen dieser Arbeit entwickelten Berechnungsmodell zugrunde liegt. Dazu werden die getroffenen Modellannahmen aufgezeigt und deren Verwendung gerechtfertigt. Im letzten Teil des Kapitels wird der Aufbau des Berechnungsmodells beschrieben und der zugrundeliegende Pseudocode dargelegt.

Nach der Erläuterung der Methodik, fasst Kapitel vier die Ergebnisse des Berechnungsmodells zusammen. Die Ergebnisse werden für drei verschiedene Untersuchungen analysiert. Zum Abschluss des Kapitels werden die Ergebnisse diskutiert und deren Einschränkungen erläutert.

Abschließend wird im fünften Kapitel die Arbeit zusammengefasst, weiterführende Aspekte dargestellt und Möglichkeiten für ein weiteres Vorgehen aufgezeigt.




Abbildung 1.2: Aufbau der vorliegenden Arbeit

## 2 Stand der Technik

Nach der Erläuterung der Aufgabenstellung und der Motivation der vorliegenden Arbeit, befasst sich das folgende Kapitel mit dem aktuellen Stand der Technik. Zu Beginn werden die Automatisierungsgrade von Fahrzeugen definiert und aktuelle Methoden und Ansätze für deren Absicherung diskutiert. In Kapitel 2.3 werden die zur Umfelderkennung autonomer Fahrzeuge verwendeten Sensoren vorgestellt und deren Funktionsweise erläutert. Kapitel 2.4 zeigt Ansätze für die Modellierung der Sensoren auf und diskutiert deren Vor- und Nachteile. Zum Abschluss werden in Kapitel 2.5 die Grundlagen der mathematischen Optimierung besprochen.

### 2.1 Automatisierung von Fahrzeugen

Assistiertes und automatisiertes Fahren gehören heute zu den mit am intensivsten erforschten Gebieten der Automobilindustrie. Fast alle Automobilhersteller und namenhaften Akteure der Elektronik- und Kommunikationsbranche treiben ihr Know-how im Bereich autonomer Fahrzeuge voran [10, S. 501]. Das IEEE prognostiziert in diesem Zusammenhang, dass bis zum Jahr 2040 ca. 75% der Fahrzeuge auf der Straße autonom fahren werden [4, S. 69].

Um die Möglichkeiten des autonomen Fahrens zu beschreiben werden verschiedene Begriffe (assistiert, automatisiert, hochautomatisiert, ...) verwendet, die in der Gesellschaft oft fälschlicherweise mit autonomen Fahren gleichgesetzt werden (z.B. „Autopilot“ von Tesla). Zur Entwirrung der Vielfalt an Begriffen haben verschiedene Arbeitsgruppen Automatisierungsstufen eingeführt, die den Grad der Automatisierung eines Fahrzeugs beschreiben [11, S. 100]. Die gängigsten Definitionen sind die der BASt und der SAE, die in (Tabelle 2.1) zusammengefasst sind.

Beim assistierten Fahren (Stufe 1) führt der Fahrer dauerhaft entweder die Quer- oder Längsführung aus. Die jeweils andere Fahraufgabe wird in gewissen Grenzen vom System ausgeführt. Dabei muss der Fahrer das System dauerhaft überwachen und muss zu jeder Zeit zur vollständigen Übernahme der Fahrzeugführung bereit sein. Beim teilautomatisierten Fahren (Stufe 2) übernimmt das System die Quer- und Längsführung für spezifische Situationen und einen gewissen Zeitraum. Der Fahrer muss dabei das System dauerhaft überwachen und muss zu jeder Zeit zur vollständigen Übernahme der Fahrzeugführung bereit sein. Beim hochautomatisierten Fahren (Stufe 3) übernimmt das System die Quer- und Längsführung für spezifische Situationen in einem gewissen Zeitraum. Der Fahrer muss das System dabei nicht überwachen, muss nach Aufforderung mit ausreichender Zeitreserve durch das System aber zur Übernahme der Fahrzeugführung bereit sein. Beim vollautomatisierten Fahren (Level 4) übernimmt das System die Quer- und Längsführung in einem spezifischen Anwendungsfall. Der Fahrer muss das System dabei nicht überwachen, wird vor Verlassen des Anwendungsfalls mit ausreichender Zeitreserve aber durch das System zur Übernahme der Fahrzeugführung aufgefordert. Wird die Aufforderung der Fahrzeugübernahme nicht erfüllt, wird das System in einen risikominimalen

Systemzustand versetzt [12]. Im Vergleich zur BASt unterteilt die SAE die höchste Stufe der Automation weiter. Die SAE konzentriert sich bei der Automatisierung der Stufe 5 auf die Fähigkeit universelle Fahraufträge vollautomatisch und ohne eine zeitliche und anwendungsspezifische Beschränkung zu bewältigen, unabhängig davon, ob ein Fahrer verfügbar ist [11, S. 100]. Die Quer- und Längsführung wird dabei vollständig vom System übernommen und muss nicht durch den Fahrer überwacht werden.

Tabelle 2.1: Definition der Automatisierungsgrade (nach BASt und SAE) [12], [13]

#	Automatisierungsgrad nach BASt	Automatisierungsgrad nach SAE	Fahraufgabe	Überwachung	Rückfallebene	Systemausprägung
0	Nur Fahrer	No Automation	Fahrer	Fahrer	Fahrer	Nicht vorhanden
1	Assistiert	Driver Assistance	Fahrer / System	Fahrer	Fahrer	Einige Fahraufgaben
2	Teilautomatisiert	Partial Automation	System	Fahrer	Fahrer	Einige Fahraufgaben
3	Hochautomatisiert	Conditional Automation	System	System	Fahrer (übernahmefähig)	Einige Fahraufgaben
4	Vollautomatisiert	High Automation	System	System	System / Fahrer	Einige Fahraufgaben
5		Full Automation	System	System	System	Alle Fahraufgaben

Vom Begriff der autonomen Fahrzeuge lässt sich auf Basis der dargelegten Definitionen ab Stufe 3 (hochautomatisiertes Fahren) sprechen, weil ab dieser Stufe der menschliche Fahrer das System nicht mehr dauerhaft überwachen muss. Die Überwachung des Systems ist der entscheidende Unterschied zu derzeitigen Fahrzeugen, die aufgrund der Beschränkungen und hohen Kosten der erforderlichen Sensoren meist nur die Stufen 1-2 umfassen [3, S. 385]. Diese Fahrzeuge sind zwar bereits heute in der Lage die Fahrzeugführung vollständig zu übernehmen, der Fahrer muss das System allerdings dauerhaft überwachen, darf keinen anderen Tätigkeiten nachgehen und muss die Hände stets am Lenkrad halten, um bei einem fehlerhaften Verhalten des Systems sofort eingreifen zu können. Der Übergang von Stufe 2 zu Stufe 3 stellt für die Automobilhersteller eine große Herausforderung dar, weil die Verantwortung des Fahrers in spezifischen Situationen auf das System übergeht und der Automobilhersteller für entstandene Schäden zur Haftung herangezogen werden kann. Entsprechende Gesetze, die die Schuldfrage bei einem Versagen des Systems regeln, sind in der Diskussion. Aktuell behält grundsätzlich der Mensch die letzte Verantwortung [14]. Eine zunehmende Automatisierung erfordert dementsprechend eine redundante Auslegung aller Teilsysteme, von den Sensoren über die Hard- und Software der Steuergeräte bis hin zu den Aktuatoren wie Bremse und Lenkung [15, S. 32]. Der 2018 neu vorgestellte AUDI A8 geht diesen Schritt und soll, sobald es die rechtlichen Rahmenbedingungen erlauben, als erstes Fahrzeug Fahrfunktionen der Stufe 3 aufweisen [15, S. 32].

## 2.2 Absicherung autonomer Fahrzeuge

Mit zunehmender Automatisierung und jeder höheren Automatisierungsstufe steigt die Verantwortung der Automobilhersteller und Entwickler autonomer Fahrfunktionen bezüglich der Gewährleistung der allgemeinen Sicherheit des Verkehrsgeschehens und seiner Verkehrsteilnehmer. Aus diesem Grund bedarf es zuverlässiger Absicherungsstrategien autonomer Fahrzeuge, die anstelle eines menschlichen Fahrers das Verkehrsgeschehen beobachten, es analysieren und die Fahraufgabe übernehmen [16, S. 32]. Für die Homologierung von autonomen Fahrzeugen existieren aktuell noch keine passenden Absicherungskonzepte. Die bisherigen Absicherungsstrategien stoßen an ihre Grenzen.

Die ISO 26262 beispielsweise definiert Anforderungen an die Entwicklung und Produktion von sicherheitsrelevanten Systemen in Kraftfahrzeugen zur Gewährleistung der funktionalen Sicherheit [9, S. 139]. Dabei orientiert sich die Norm im beschriebenen Vorgehen am V-Modell, das in (Abbildung 2.1) dargestellt ist [17, S. 2]. Beim V-Modell handelt es sich um ein Stufenmodell, in dem zuerst die Anforderungen an das zu entwickelnde System gemäß dem Lastenheft festgelegt werden. Anschließend erfolgt die Spezifikation der Systemarchitektur, die in Form des Pflichtenhefts festgehalten wird. Für den Systementwurf werden einzelne Module abgeleitet und implementiert, die anschließend auf System- und Gesamtfahrzeugebene validiert werden [18, S. 9]. Erweitert wird das V-Modell um die virtuelle Validierung der Anforderungen zur Absicherung des funktionalen Konzepts, bevor das entwickelte System im realen Versuch getestet wird [19, S. 73]. Für autonome Fahrzeuge genügt es nicht die Systeme auf den Fall eines Versagens auf funktionaler Ebene vorzubereiten, sondern vielmehr gilt es die Systeme gegen situative Fehlinterpretationen abzusichern [16, S. 33]. Weil sich im Rahmen einer vorab erstellten Systemspezifikation nicht alle Eventualitäten des realen Verkehrsgeschehens erfassen lassen, ist anhand des V-Modells keine vollständige Beschreibung der Funktionsspezifikation möglich [16, S. 33].

Ein alternativer Ansatz zur Absicherung autonomer Fahrzeuge stellt der in [20] beschriebene Dauerlauf dar. Beim Dauerlauf wird das System auf ausgesuchten Strecken unter realen Bedingungen getestet. Um anhand dieser Strategie fundierte Aussagen über die Fähigkeiten des Systems treffen zu können bedarf es mehrerer Milliarden Testkilometer [21, S. 50-51].

In [20] wird das Trojanische Pferd als eine weitere alternative Absicherungsmethode vorgestellt. Dabei ist ein neues System bereits im Hintergrund tätig, das noch keinen Einfluss auf die Fahrzeugführung hat. Während Testfahrten oder im Serienbetrieb wird dokumentiert wann und wie das System reagiert hätte. Voraussetzung hierfür ist die Erfassung des Umfelds und der Verkehrssituation. Die Aussagekraft dieser Strategie ist beschränkt, weil der Situationsverlauf nicht der Zielfunktion entspricht, d.h. es kann nur beobachtet werden wie das System in einer Situation reagiert hätte, ohne zu wissen, ob sich das System selbst in diese Situation manövriert hätte. Aus diesem Grund kann keine Aussage über das Systemverhalten in komplexen Situationen getroffen werden.

Die dargelegten Beispiele zeigen, dass eine ökonomische Absicherung und Freigabe von autonomen Fahrzeugen mit gängigen Methoden aktuell nicht möglich ist. Eine Möglichkeit zur effizienten Absicherung und Freigabe autonomer Fahrzeuge ist der szenariobasierte Ansatz, der aktuell im vom Bundesministerium für Wirtschaft und Energie (BMWi) geförderten Projekt PE-GASUS [22] erarbeitet wird. Der bei der Absicherung und Freigabe autonomer Fahrzeuge entstehende Testraum repräsentiert das reale Verkehrsgeschehen, das durch die Kombinationen der Vielzahl von Einflussfaktoren eine theoretisch unendlich hohe Anzahl an Testfällen

generiert. Weil in der Praxis nur eine endliche Anzahl an Testfällen überprüft werden kann, bedarf es der Identifikation einer begrenzten Anzahl von repräsentativen, fehlersensitiven und redundanzarmen Testfällen [23, S. 3], deren Ziel eine möglichst hohe Testabdeckung ist [8, S. 25]. Der szenariobasierte Ansatz versucht genau diese Einschränkung des Testraums, indem nur die interessantesten und relevantesten Szenarien berücksichtigt werden. Die Definition dieser sog. Worst-Case Szenarien stellt jedoch eine der großen Herausforderungen dar und ist Gegenstand aktueller Untersuchungen.

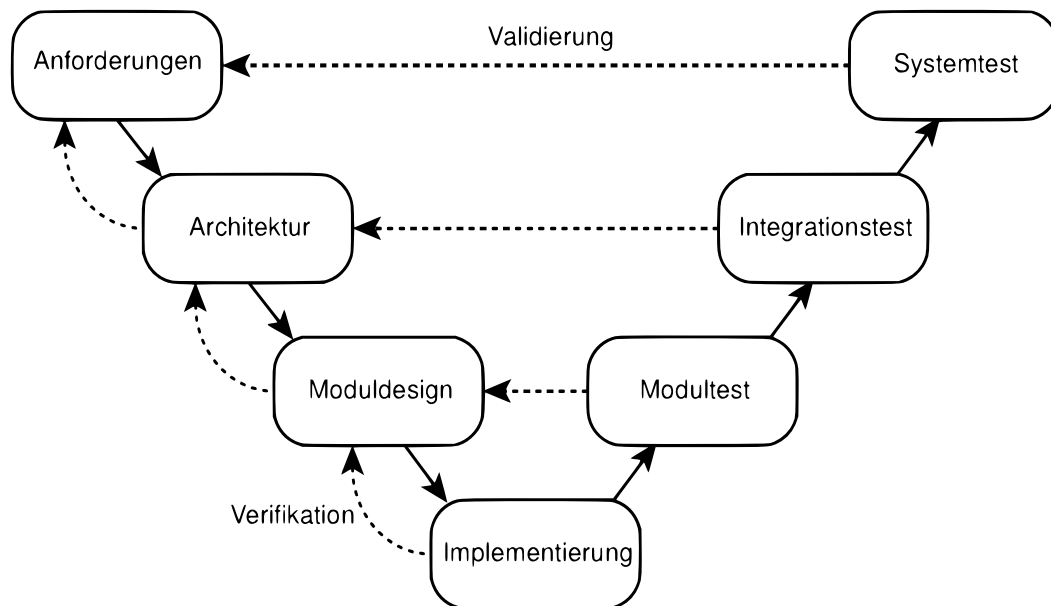


Abbildung 2.1: Entwicklung von sicherheitsrelevanten Systemen anhand des V-Modells [18, S. 10]

## 2.3 Umfelderfassung

Die große Herausforderung des autonomen Fahrens besteht in der fahrerlosen Führung des Fahrzeugs im realen Verkehrsgeschehen. Grundvoraussetzung ist eine zuverlässige Umfelderfassung, um die Umgebung und alle anderen Verkehrsteilnehmer rund um das Fahrzeug zu erkennen [24, S. 6]. Hierfür kommen fahrzeugintegrierte Radar-, Ultraschall-, Lidar- und Kamerasensoren zur Anwendung [15, S. 34], [25, S. 1]. Weil die Theorien dieser Sensoren sehr umfangreich sind, kann im Rahmen der vorliegenden Arbeit nur auf die für die Arbeit grundlegenden Aspekte eingegangen werden. Für eine ausführliche Einführung in die Theorien der umfelderfassenden Sensoren wird auf [26] verwiesen.

### 2.3.1 Radarsensor

Radarsensoren (**R**adio **D**etection and **R**anging) senden und empfangen hochfrequente elektromagnetischer Wellen, um die Entfernung und Relativgeschwindigkeit zu Objekten zu messen. Es existieren zwei verschiedene Radartechnologien. Impulsradare senden innerhalb eines zeitlich festgelegten Abstands kurze Impulse einer bestimmten Frequenz aus. Dauerstrichradare hingegen übertragen frequenzmodulierte Signale, d.h. kontinuierliche Signale mit veränderten Frequenzen innerhalb des Sendeintervalls [27, S. 6-7], [28, S. 12-13]. Im Automobilbereich werden dafür die Frequenzbereiche 24 GHz und 76-77 GHz verwendet. Radarsensoren im 24 GHz



Frequenzbereich sind billiger und bieten eine hohe Auflösung [29]. Sie sind in der Sendeleistung stark limitiert und anfälliger für Interferenzen, weil der 24 GHz Frequenzbereich ebenfalls von mehreren anderen Funkdiensten verwendet wird [25, S. 2]. 24 GHz Radarsensoren werden aus diesen Gründen für die Erfassung des Nahbereichs verwendet (engl. Short Range Radar). Radarsensoren im 76-77 GHz Frequenzbereich bieten eine höhere Genauigkeit in der Distanz- und Relativgeschwindigkeitsmessung, weil sie kleinere Wellenlängen besitzen [30]. Diese ermöglichen zusätzlich höhere Sendeleistungen, wodurch sich der Einsatz für größere Entfernungen realisieren lässt [31, S. 6]. 76-77 GHz Radarsensoren werden aus diesen Gründen für die Erfassung des Mittel- und Fernbereichs verwendet (engl. Mid Range Radar und Long Range Radar).

Impulsradare sind meist als sog. Puls-Doppler-Radare ausgeführt, deren Sendepinzip in (Abbildung 2.2) dargestellt ist. Durch An- und Ausschalten des Senders werden kurze Impulse der Dauer  $\tau_P$  mit der Pulswiederholfrequenz  $T_P$  ausgesendet. Die in (Abbildung 2.2) dargestellten einhüllenden Rechtecke stellen eine Idealisierung der endlichen Schaltzeiten der Hardwarebauteile dar.




Abbildung 2.2: Sende- und Empfangssignal beim Impulsradar [28, S. 13]

Die ausgesendeten Impulse werden in der Umgebung durch ein Objekt reflektiert und vom Radarsensor als Echo empfangen. Aus der Signallaufzeit kann die Entfernung  $R$  zu einem Objekt mittels

$$R = \frac{t_E - t_S}{2} * c \quad (2.1)$$

berechnet werden. Die Ausbreitungsgeschwindigkeit elektromagnetischer Wellen ist dabei die Lichtgeschwindigkeit  $c$  [28, S. 13]. Bewegen sich Sensor und Objekt relativ zueinander, ergibt sich aufgrund des Doppler-Effekts eine Frequenzverschiebung im empfangenen Signal, durch deren Messung die Relativgeschwindigkeit des Objekts direkt bestimmt werden kann [32, S. 10-11]. Die als Dopplerfrequenz  $f_D$  bezeichnete Frequenzverschiebung steht in folgenden Zusammenhang mit der Trägerfrequenz  $f_0$  und der Relativgeschwindigkeit des Objekts  $v_{rel}$ :

$$f_D = -\frac{2 * v_{rel}}{c} * f_0 . \quad (2.2)$$

Fahrzeugintegrierte Radarsensoren sind heutzutage hauptsächlich als Dauerstrichradare ausgeführt und werden mit dem sog. Frequency Modulated Continuous Wave (FMCW)-Verfahren betrieben [18, S. 41], das in (Abbildung 2.3) dargestellt ist.

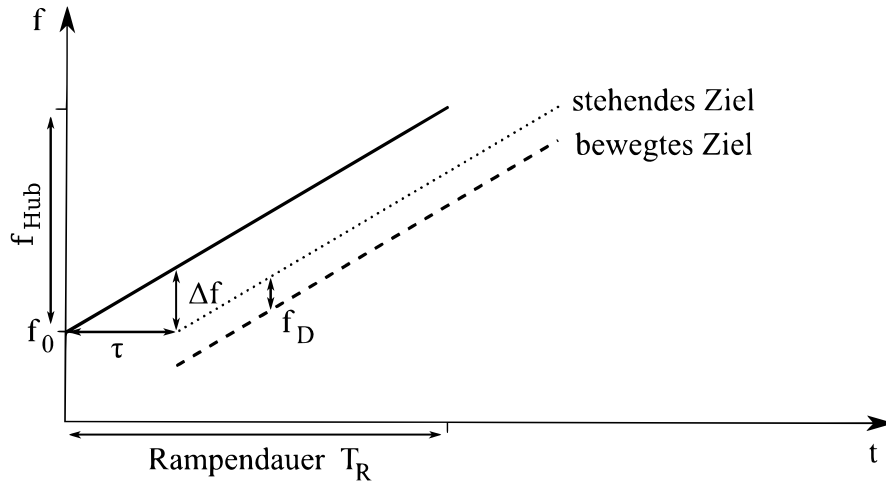


Abbildung 2.3: Sende- und Empfangssignal beim FMCW-Radar [28, S. 16]

Beim FMCW-Verfahren wird die Frequenz eines kontinuierlichen Signals innerhalb der Rampendauer  $T_R$  und des Frequenzintervalls  $f_{Hub}$  verändert. Das durch ein Objekt reflektierte Echo wird mit der Verzögerung  $\tau$  vom Radarsensor empfangen, was sich als Frequenzverschiebung bemerkbar macht. Die Frequenzverschiebung  $\Delta f$  wird durch

$$\frac{f_{Hub}}{T_R} = \frac{\Delta f}{\tau} \quad (2.3)$$

beschrieben, wobei gilt

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

Aus der Überlagerungsfrequenz der Signale kann durch eine Frequenzanalyse direkt die Entfernung eines Objekts bestimmt werden [28, S. 16-17]. Bewegen sich Sensor und Objekt relativ zueinander, ergibt sich eine zusätzliche Frequenzverschiebung um die Dopplerverschiebung  $f_D$ . Die resultierende Gesamtfrequenzverschiebung beträgt

$$f_{ges} = \Delta f - f_D = \frac{2}{c} \left( \frac{f_{Hub}}{T_R} * R + f_0 * v_{rel} \right) . \quad (2.5)$$

Es ist ersichtlich, dass die Gesamtfrequenzverschiebung sowohl von der Entfernung als auch von der Relativgeschwindigkeit abhängt. Dadurch ist sie nicht eindeutig bestimmbar, weil es mehrere Kombinationen aus Entfernung und Relativgeschwindigkeit gibt, die die selbe Gesamtfrequenzverschiebung abbilden. Abhilfe schafft die Verwendung eines zweiten Signalteils mit modifizierter Modulation [28, S. 16-17]. In der Praxis finden verschiedene Signalformen Anwendung, deren Verfahren in [26] beschrieben werden.

Für Anwendungen im Automobilbereich ist neben der Bestimmung der Entfernung und Relativgeschwindigkeit eines Objekts auch der Betrachtungswinkel relevant. Dieser kann durch die Verwendung mehrerer Strahler (Sender und Empfänger) innerhalb des Radarsensors bestimmt werden. Dabei wird das von einem Objekt reflektierte Echo abhängig vom Winkel des Objekts

in einem Empfänger mit der Amplitude  $A_1$  und in einem anderen Empfänger mit der Amplitude  $A_2$  gemessen. Die Winkelschätzung erfolgt anhand des Amplitudenverhältnisses [28, S. 15]. In der Praxis werden üblicherweise planare Antennenarrays verwendet, die aus mehreren Einzelstrahlern mit überlappender Antennencharakteristik bestehen und für deren Einsatz eine starke Strahlbündelung der Einzelstrahler erforderlich ist [33, S. 10]. Hierfür werden Antennen verwendet, die durch eine spezielle Geometrie der Strahlung eine Richtcharakteristik geben, wodurch mehr Strahlungsleistung in eine bevorzugte Richtung abgegeben wird. Das Verhältnis von gerichteter zu ungerichteter Strahlungsleistung wird als Antennengewinn  $G$  bezeichnet und ist abhängig von Azimuth  $\phi$  und Elevation  $\psi$  [34, S. 17-18]. (Abbildung 2.4) zeigt beispielhaft die Richtcharakteristik einer solchen Antenne.

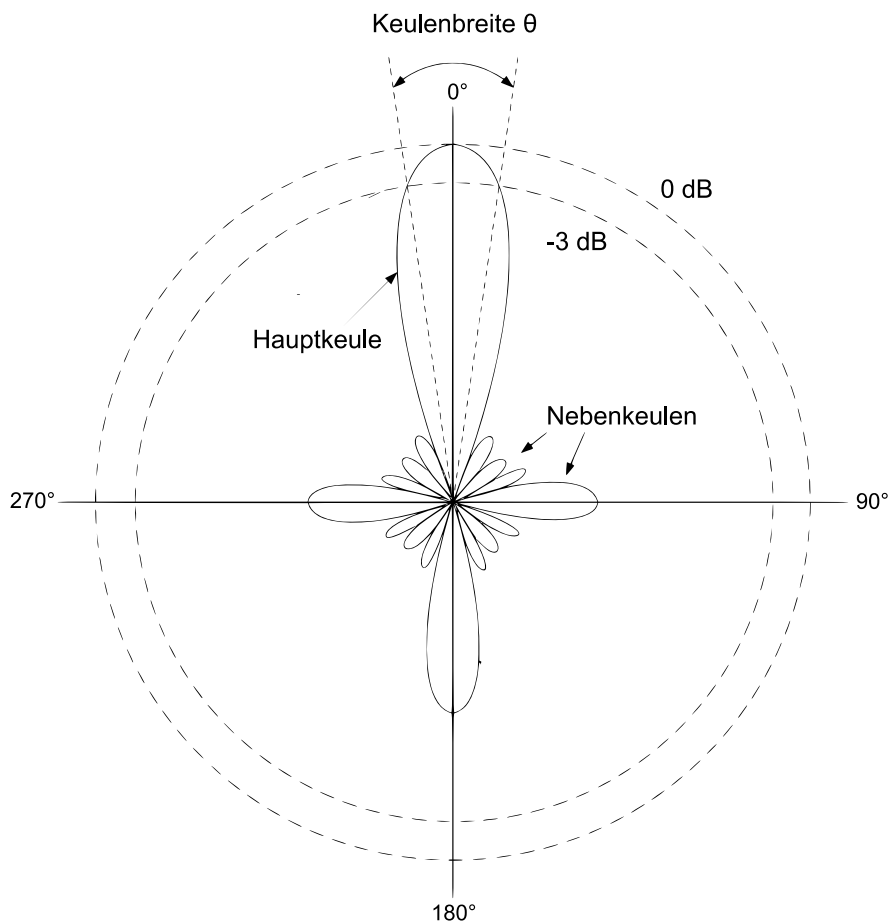


Abbildung 2.4: Richtcharakteristik einer Radarantenne [34, S. 17]

Das Gebiet um die maximale Strahlungsleistung wird als Hauptkeule bezeichnet und ist durch die -3 dB Keulbreite  $\theta$  definiert, d.h. die Grenzlinien des Öffnungswinkels, bei dem die Strahlungsleistung auf 50% abfällt [34, S. 18-19]. Die Einzelstrahler eines Radarsensors werden folglich nur durch die Hauptkeulen charakterisiert, weil die geringen Intensitäten der auftretenden Nebenkeulen für die Erfassung von Objekten nicht relevant sind. Aus der Überlagerung der Einzelstrahler ergibt sich das in (Abbildung 2.5) dargestellte Antennendiagramm, das die Strahlungsleistung eines Radarsensors in Abhängigkeit des Abstrahlungswinkels darstellt [18, S. 38-39].

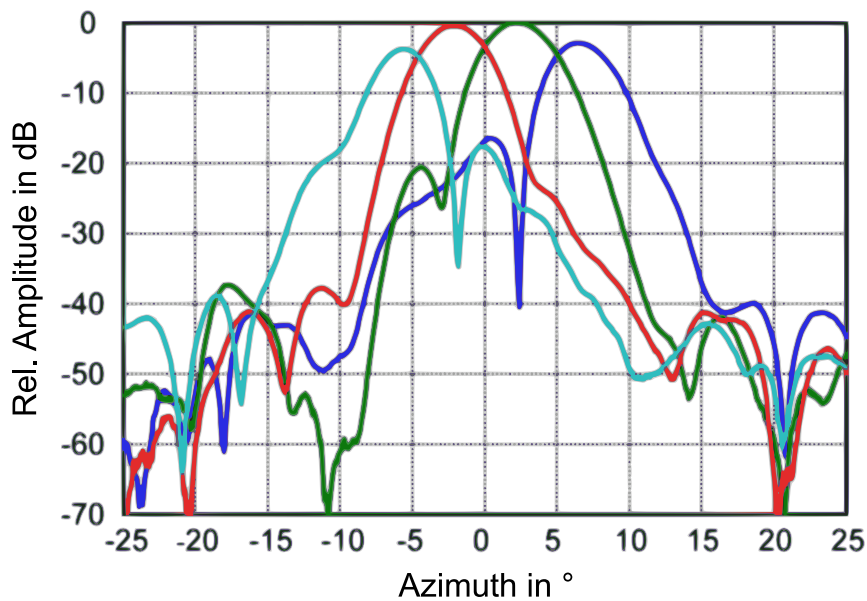


Abbildung 2.5: Antennendiagramm des Bosch LRR 3 [35, S. 2378]

Die Umfelderkennung und Objektdetektion ist stark von der Sende- und Empfangscharakteristik der verwendeten Sensoren abhängig. Zur Charakterisierung des Sende- und Empfangsverhaltens von Radarsensoren kann die Radargleichung verwendet werden, für deren Herleitung folgende Vereinfachungen angenommen werden [36, S. 16]:

- Es wird Freiraumausbreitung der Radarwellen in der Atmosphäre angenommen, d.h. der Raum ist außer dem Radar und seinen Zielen leer
- Wellenausbreitung zwischen Sende- und Empfangsantenne erfolgt bei gleicher Polarisation, d.h. die Reflexion an Objekten verursacht keine Polarisationsänderung
- Radarziele befinden sich im Fernfeld der Antennen
- Radarziele stellen Punktziele dar, die die gemäß ihres Rückstreuquerschnitts eingesammelte Leistung isotrop wieder abstrahlen
- Radarantennen sind optimal auf das Ziel ausgerichtet

Elektromagnetische Wellen die von einer isotropen Punktquelle ausgestrahlt werden, breiten sich in alle Raumrichtungen gleichförmig aus, wodurch die Wellenfronten eine Kugeloberfläche bilden. Die isotrope Leistungsdichte  $S_{iso}$  auf der Kugeloberfläche in einer Entfernung  $R$  ist in Abhängigkeit der ausgesendeten Strahlungsleistung  $P_t$  durch

$$S_{iso} = \frac{P_t}{4\pi R^2} \quad (2.6)$$

definiert. Durch die Antennen des Radarsensors wird eine starke directionale Abstrahlung der Wellen in eine gewünschte Raumrichtung erreicht, die durch den Antennengewinn  $G$  ausgedrückt werden kann. Unter Einbezug des Gewinns der Sendeantenne  $G_t$  ergibt sich die directionale ausgestrahlte Leistungsdichte  $S_t$  zu

$$S_t = \frac{P_t \cdot G_t}{4\pi R^2} \quad (2.7)$$

Ein Radarziel in der Entfernung  $R$  nimmt proportional zu seinem Rückstreuquerschnitt  $\sigma$  (engl. Radar Cross Section, RCS) die Leistung  $P_o$  nach

$$P_o = S_t * \sigma \quad (2.8)$$

auf und reflektiert die Strahlung isotrop. An den Empfangsantennen des Radarsensors ergibt sich die zurückgestrahlte Leistungsdichte  $S_r$  gemäß

$$S_r = \frac{P_o}{4\pi * R^2}. \quad (2.9)$$

Aus der Leistungsdichte  $S_r$  ergibt sich die reflektierte und empfangene Strahlungsleistung  $P_{r,ideal}$  durch Multiplikation mit der Antennenwirkfläche  $A_r$ , die durch den Antennengewinn  $G_r$  und die Wellenlänge der Strahlung  $\lambda$  ausgedrückt werden kann:

$$P_{r,ideal} = S_r * A_r = S_r * \frac{G_r * \lambda^2}{4\pi}. \quad (2.10)$$

Setzt man die Gleichungen Gl. (2.7) – Gl. (2.10) ineinander ein, erhält man die ideale Radargleichung:

$$P_{r,ideal} = \frac{P_t * G_t * G_r * \sigma * \lambda^2}{(4\pi)^3 * R^4}. \quad (2.11)$$

Bei Verwendung der idealen Radargleichung ist zu beachten, dass die Parameter voneinander abhängig sind. Beispielsweise suggeriert Gl. (2.11) eine quadratische Abhängigkeit der empfangenen Leistung  $P_{r,ideal}$  von der Wellenlänge  $\lambda$ . Allerdings sind weitere Parameter ( $P_t$ ,  $G_t/r$ ,  $\sigma$ ) von der Wellenlänge abhängig, so dass eine Analyse der Frequenzabhängigkeit mit der einfachsten Form der Radargleichung nicht möglich ist. Eine Verallgemeinerung der Radargleichung gelingt durch die Einführung sog. Verlustfaktoren [36, S. 16-17]. Durch diese gelingt es Fehler, die durch die Vereinfachungen gemacht werden, zu kompensieren und die Realität besser abzubilden. Es wurde bisher davon ausgegangen, dass die Radarantennen optimal auf die Objekte ausgerichtet sind. Eine optimale Antennenausrichtung liegt nur für die Hauptstrahlrichtung der einzelnen Radarkeulen vor. Für Objekte, die sich nicht in der Hauptstrahlrichtung der Antennen befinden, muss eine Reduktion des Antennengewinns abhängig von Azimuth  $\phi$  und Elevation  $\psi$  berücksichtigt werden [36, S. 19-20]. Für die Ausbreitung der Radarwellen wurde bisher Freiraumausbreitung angenommen. In der Realität unterliegen die Radarwellen einer atmosphärischen Dämpfung, die sich durch schlechte Witterungsverhältnisse zusätzlich erhöht [36, S. 18]. Des Weiteren müssen Systemverluste, wie beispielsweise ohmsche Verluste, innerhalb eines Radarsensors berücksichtigt werden [34, S. 12-13]. Die auftretenden Verluste werden dazu im Dämpfungsfaktor  $L_{ges}$  als Produkt aller Einzelverluste zusammengefasst [33, S. 8]. Die allgemeine Form der Radargleichung ergibt sich zu

$$P_r = \frac{P_t * G_t(\phi, \psi) * G_r(\phi, \psi) * \sigma * \lambda^2}{(4\pi)^3 * R^4 * L_{ges}}. \quad (2.12)$$

Aus Gl. (2.12) wird ersichtlich, dass der Rückstreuquerschnitt  $\sigma$  die empfangene Strahlungsleistung in gleichem Maße beeinflusst wie die ausgesendete Strahlungsleistung  $P_t$  oder der Antennengewinn  $G$ . Aus diesem Grund ist eine exakte Bestimmung des Rückstreuquerschnitts wünschenswert, was für reale Objekte mit erheblichen Schwierigkeiten verbunden ist, weil dieser von einer Vielzahl an Parametern abhängt [34, S. 20-21]:

- Objektgeometrie
- Elektrische Eigenschaften des Objekts
- Betrachtungswinkel bzw. Einstrahlwinkel
- Sender- und Empfängerpolarisation
- Entfernung
- Frequenz und Wellenlänge der Strahlung

Aufgrund der komplexen Oberflächenstrukturen der Objekte, ergeben sich so richtungsabhängige Rückstreuquerschnitte, die die Reflexionseigenschaften der Objekte charakterisieren [18, S. 36]. Um in der Praxis dennoch aussagekräftige und vergleichbare Wert für die Rückstreuquerschnitte von Objekten zu erhalten, werden die Objekte als Standardziele in Form einfacher Geometrien (Kugel, Zylinder, Quader, ...) definiert, für die mathematische Herleitungen des Rückstreuquerschnitts existieren [36, S. 20-21].

Mit der allgemeinen Form der Radargleichung gelingt es das Leistungsverhältnis von Sendee- und Empfangssignal darzustellen. Zur genaueren Charakterisierung der Sensorperformance bedarf es zusätzlich dem Signal-Rausch-Verhältnis (engl. Signal-to-Noise Ratio, SNR), das durch

$$SNR = \frac{P_r}{P_n} \quad (2.13)$$

definiert ist und die von einem Objekt reflektierte und vom Radarsensor empfangene Strahlungsleistung  $P_r$  mit der aufgenommenen Rauschleistung  $P_n$  ins Verhältnis setzt. Die vom Radarsensor aufgenommene Rauschleistung setzt sich aus mehreren Komponenten zusammen [36, S. 21-23]:

- Elektromagnetische Temperaturstrahlung aus der Atmosphäre, dem Weltraum (galaktisches Rauschen) und der Erdoberfläche
- Rauschen des Sendesignals, das am Objekt reflektiert und von der Empfangsantenne aufgenommen wird
- Zielrauschen, gegliedert in Amplitudenrauschen, Winkelrauschen, Entfernungrauschen, sowie Rauschen, das Polarisation und Dopplerfrequenz beeinflusst

Die Rauschleistung, die in Form elektromagnetischer Temperaturstrahlung aufgenommen wird, ist für Radarsensoren im Automobilbereich primär durch das atmosphärische Rauschen dominiert [37, S. 92] und kann unter der Berücksichtigung internen Systemverluste durch die Systemrauschtemperatur  $T_{sys}$  dargestellt werden, die einen Wert von 300 K nicht überschreitet [38, S. 17], [39]. Das Signal-Rausch-Verhältnis eines Radarsensors lässt sich aus

$$SNR = \frac{P_r}{k * B_n * T_{sys}} \quad (2.14)$$

berechnen, wobei  $k$  die Boltzmann Konstante und  $B_n$  die Rauschbandbreite beschreiben. Die Rauschbandbreite  $B_n$  ergibt sich aus der Pulsdauer  $\tau$  des Sendesignals nach

$$B_n = \frac{1}{\tau} \quad (2.15)$$

bei Verwendung eines angepassten Filters [38, S. 42-43].

### 2.3.2 Ultraschallsensoren

Ultraschallsensoren senden und empfangen akustische Ultraschallimpulse auf einer Frequenz von ca. 40 KHz, um die Entfernung zu Objekten zu bestimmen. Ihre Reichweite ist prinzipbedingt auf wenige Meter begrenzt [18, S. 7]. Die Charakteristik von Ultraschallsensoren ist der von Radarsensoren sehr ähnlich und unterscheidet sich primär durch die verschiedenen Frequenzbereiche der ausgesendeten Signale.

Ultraschallsensoren arbeiten nach dem Puls-Echo-Prinzip [40, S. 581]. Dabei werden ausgesendete Impulse in der Umgebung durch ein Objekt reflektiert und vom Ultraschallsensor als Echo empfangen. Durch eine Laufzeitmessung kann aus der Laufzeit  $\Delta t$  und der Schallgeschwindigkeit  $c_L$  die Entfernung zu einem Objekt nach

$$R = \frac{\Delta t}{2} * c_L \quad (2.16)$$

berechnet werden. Unter Ausnutzung des Doppler-Effekts lässt sich mit Ultraschallsensoren auch die Relativgeschwindigkeit von Objekten bestimmen [40, S. 582-584]. Aufgrund der prinzipbedingten geringen Reichweite ist dies für den Einsatz im Automobil jedoch nicht relevant. Zur Verbesserung der Umfelderkennung werden meist mehrere Ultraschallsensoren eingesetzt, die durch Verwendung des Triangulationsverfahrens eine robustere Entfernungsmessung ermöglichen [18, S. 47].

Durch Antennen mit spezieller Geometrie wird den ausgesendeten Ultraschallimpulsen eine Richtcharakteristik gegeben, um eine directionale Abstrahlung zu erzeugen. Dabei bilden Ultraschallsensoren ein Feld aus, das sich in Nah- und Fernfeld unterteilt und in (Abbildung 2.6) dargestellt ist.




Abbildung 2.6: Nah- und Fernfeld eines Ultraschallsensors [18, S. 46]

Im Nahfeld kommt es durch die Nähe zur Schwingungsquelle zu Interferenzen, was eine stark schwankende Intensitätsverteilung zur Folge hat. Dieser Bereich kann aus diesem Grund nicht zur Objektdetektion genutzt werden kann. Das Nahfeld ist durch die Nahfeldlänge  $l_n$  nach

$$l_n = \frac{D_r^2}{4\lambda} \quad (2.17)$$

definiert, wobei  $D_r$  den Sensordurchmesser und  $\lambda$  die Wellenlänge der ausgesendeten Ultraschallimpulse darstellen [18, S. 46]. Im Fernfeld bildet sich die Hauptkeule aus, d.h. das Gebiet

der maximalen Strahlungsleistung. Die Hauptkeule kann weitere Nebenkeulen aufweisen, die für die Erfassung von Objekten jedoch nicht relevant sind [18, S. 47].

Zur Charakterisierung des Sende- und Empfangsverhaltens von Ultraschallsensoren, sowie deren Sensorperformance können die in Kapitel 2.3.1 hergeleitete Radargleichung, sowie das Signal-Rausch-Verhältnis verwendet werden [41, S. 127]. Die abgeleitete Ultraschallgleichung ergibt sich zu

$$P_r = \frac{P_t * G_t(\phi, \psi) * G_r(\phi, \psi) * \sigma * \lambda^2}{(4\pi)^3 * R^4 * L_{ges}}, \quad (2.18)$$

das Signal-Rausch-Verhältnis zu

$$SNR = \frac{P_r}{k * B_n * T_{sys}}. \quad (2.19)$$

### 2.3.3 Lidarsensoren

Lidarsensoren (**L**ight **D**etection and **R**anging) sind laserbasierte Messsysteme, die Laserstrahlen im nahen Infrarotbereich des elektromagnetischen Spektrums bei 905 nm senden und empfangen. Ähnlich wie Radarsensoren basieren sie auf dem Prinzip der Laufzeitmessung, um die Entfernung und Relativgeschwindigkeit zu Objekten zu messen. Die Sendeleistung ist durch die Einhaltung der Augensicherheitsvorschriften beschränkt, wodurch die Reichweite von Lidarsensoren praktisch begrenzt ist [27, S. 8].

Es existieren hauptsächlich zwei verschiedene Lidartechnologien. Mehrstrahl-Lidarsensoren verwenden eine Anordnung von mehreren Sendern und Empfängern, die separate Abschnitte in einer festgelegten Richtung betrachten [42, S. 207], [43, S. 2]. Laserscanner hingegen besitzen meist nur einen Sender und Empfänger. Die ausgesendeten Lichtsignale werden durch bewegliche Spiegel abgelenkt, die sich periodisch von links nach rechts bewegen [44, S. 148]. In 3D-Laserscannern bewegen sich die Spiegel zusätzlich periodisch von oben nach unten, wodurch ein 3D-Scan der Umgebung möglich ist. Aufgrund ihres Funktionsprinzips besitzen Laserscanner eine besser Winkelauflösung als Mehrstrahl-Lidarsensoren, weil der Betrachtungswinkel eines Objekts direkt aus dem des Winkel des rotierenden Spiegels bestimmt werden kann [43, S. 2]. Bei der Anwendung im Automobil werden meist 2D-Laserscanner eingesetzt, die eine Ebene in Azimuth  $\phi$  abscannen. Eine Erweiterung des Erfassungsbereichs in Elevation  $\psi$  wird durch die Verwendung mehrerer 2-D Laserscanner in einem Lidarsensor realisiert [32, S. 8-9], wie (Abbildung 2.7) beispielhaft darstellt.

Lidarsensoren senden und empfangen gepulste Laserstrahlen, die stark gebündelt werden können und eine konstante Leistungsverteilung aufweisen, d.h. keine Abhängigkeit der Strahlungsleistung in Azimuth  $\phi$  und Elevation  $\psi$ . Dadurch eignen sich Lidarsensoren für die Entfernungsmessung von selbst kleinen Objekten [18, S. 29-30]. Die ausgesendeten Laserstrahlen werden in der Umgebung von einem Objekt reflektiert und wieder vom Lidarsensor empfangen. Anhand der Laufzeit  $\Delta t$  wird die Entfernung  $R$  zu einem Objekt nach

$$R = \frac{\Delta t}{2} * c \quad (2.20)$$

berechnet, wobei  $c$  die Lichtgeschwindigkeit darstellt [45, S. 65]. Eine direkte Messung der Relativgeschwindigkeit von Objekten anhand des Doppler-Effekts ist mit Lasersensoren nicht



möglich. Durch Differenzierung der Entfernung zu einem Objekt in zwei aufeinander folgenden Scans kann die relative Geschwindigkeit indirekt bestimmt werden [43, S. 2], [46].




Abbildung 2.7: Verwendung mehrerer Laserscanner in einem Lidarsensor [47, S. 613]

Die Sende- und Empfangscharakteristik von Lidarsensoren kann aus der in Kapitel 2.3.1 hergeleiteten Radargleichung abgeleitet werden und hängt von einer Reihe von Einflussfaktoren ab [48, S. 229]:

- Der ausgesendeten Strahlungsleistung  $P_s$
- Der Strahlenbreite  $\phi$  und  $\psi$
- Dem Rückstreuquerschnitt des Objekts  $\sigma$
- Der Fläche des Empfängers  $A_r$

Unter der Annahme, dass die Strahlungsleistung  $P_t$  der ausgesendeten Laserstrahlen in einem kreisförmigen Raumwinkel gebündelt wird, ergibt sich die ausgestrahlte Leistungsdichte  $S_t$  in einer Entfernung  $R$  zu

$$S_t = \frac{4 \cdot P_t}{\pi \cdot R^2 \cdot \phi \cdot \psi}, \quad (2.21)$$

wobei  $\frac{\pi \cdot R^2 \cdot \phi \cdot \psi}{4}$  die von Laserstrahl beleuchtete Fläche darstellt. Gl. (2.21) berücksichtigt somit, dass der Laserstrahl mit zunehmender Entfernung auseinander läuft. Ein Lidarziel in der Entfernung  $R$  nimmt proportional zu seinem Rückstreuquerschnitt  $\sigma$  die Leistung  $P_o$  nach

$$P_o = S_t \cdot \sigma \quad (2.22)$$

auf und reflektiert die Strahlung isotrop. An den Empfängern des Lidarsensors ergibt sich die zurückgestrahlte Leistungsdichte  $S_r$  gemäß

$$S_r = \frac{P_o}{4 \cdot \pi \cdot R^2}. \quad (2.23)$$

Aus der Leistungsdichte  $S_r$  ergibt sich die reflektierte und empfangene Strahlungsleistung  $P_{r,ideal}$  durch Multiplikation mit der Empfängerfläche  $A_r$  zu

$$P_{r,ideal} = S_r \cdot A_r. \quad (2.24)$$

Setzt man die Gleichungen Gl. (2.21) – Gl. (2.24) ineinander ein, erhält man die Lidargleichung

$$P_r = \frac{P_t \cdot \sigma \cdot A_r}{\pi^2 \cdot R^4 \cdot \phi \cdot \psi \cdot L_{ges}}, \quad (2.25)$$

in der die atmosphärische Dämpfung und die Systemverluste des Lidarsensors im Dämpfungsfaktor  $L_{ges}$  zusammengefasst sind [48, S. 229-230].

Zur Charakterisierung der Sensorperformance wird das Signal-Rausch-Verhältnis verwendet. Die vom Lidarsensor aufgenommene Rauschleistung  $P_n$  setzt sich aus mehreren Komponenten zusammen [49, S. 15]:

- Schrotrauschen, das das zufällige Eintreffen von Photonen durch eine Poisson-Verteilung beschreibt
- Granulares Rauschen, das durch Interferenzen kohärenter Lichtstrahlen verursacht wird
- Thermisches Rauschen, das durch Temperaturstrahlung von Objekten mit einer Temperatur  $> 0$  K verursacht wird
- Hintergrundrauschen, das durch Lichtstrahlung aus der Atmosphäre und von anderen Objekten verursacht wird

Die Rauschleistung ist für Lidarsensoren im Automobilbereich primär durch das Schrotrauschen dominiert [50, S. 3], [51, S. 2]. Thermisches Rauschen und Hintergrundrauschen, das in Form von Temperaturstrahlung aufgenommen wird, kann unter der Berücksichtigung interner Systemverluste durch die Systemrauschtemperatur  $T_{sys}$  dargestellt werden. Das Signal-Rausch-Verhältnis eines Lidarsensors lässt sich aus

$$SNR = \frac{P_r}{P_n} = \frac{P_r}{2 \cdot h \cdot \nu \cdot B_n + k \cdot B_n \cdot T_{sys}} \quad (2.26)$$

berechnen, wobei  $h$  die Planck'sche Wirkungskonstante,  $k$  die Boltzmann Konstante,  $\nu$  die Frequenz des Laserstrahls und  $B_n$  die Rauschbandbreite beschreiben. Die Rauschbandbreite  $B_n$  ergibt sich aus der Pulsdauer  $\tau$  des Sendesignals nach

$$B_n = \frac{1}{\tau} \quad (2.27)$$

bei Verwendung eines angepassten Filters [52, S. 1274].

### 2.3.4 Kamerasensoren

Im Gegensatz zu den bisher vorgestellten Sensoren sind Kamerasensoren passive Sensoren, d.h. sie senden selbst keine Signale aus, sondern empfangen Signale aus der Umgebung [3, S. 392]. Eine Ausnahme stellen sog. TOF-Kameras (engl. Time of Flight) dar, die die Umgebung mit Lichtpulsen ausleuchten und die Laufzeit des ausgesendeten und empfangenen Signals durch Vergleich der Phase des Lichtpulses messen [27, S. 8-9], [53]. Im Rahmen der vorliegenden Arbeit werden TOF-Kameras nicht weiter betrachtet.

Kamerasensoren empfangen Lichtstrahlen im für den Menschen sichtbaren Bereich des elektromagnetischen Spektrums und wandeln diese in Kontrast- und Bildinformationen um. Techniken des maschinellen Sehens und die Verwendung spezieller Algorithmen ermöglichen die Verarbeitung der aufgenommenen Bilder [31, S. 6]. Kamerasensoren sind somit in der Lage Objekte zu erkennen, zu lokalisieren und zu klassifizieren. Die Analyse einzelner Pixel liefert zusätzlich wertvolle Informationen über die Umgebung, wodurch sich beispielsweise die Interpretation von Verkehrszeichen ermöglichen lässt [27, S. 9]. Durch die Verarbeitung der aufgenommenen Bilder, die das Abbild der gesamten Szenerie darstellen, kann der

Betrachtungswinkel eines Objekts direkt bestimmt werden. Entfernung und Relativgeschwindigkeit zu einem Objekt hingegen können nicht direkt gemessen werden, weil die aufgenommenen Bilder keine Tiefeninformation besitzen. Durch Differenzierung der Bildinformationen an zwei unterschiedlichen Zeitpunkten können Entfernung und Relativgeschwindigkeit indirekt geschätzt werden [54, S. 4].

Im Gegensatz zu monokularen Kamerasystemen arbeiten stereobasierte Kamerasysteme mit zwei Kameras und sind in der Lage Bilder mit Tiefeninformation aufzunehmen. Dadurch lassen sich die 3D Koordinaten von Objekten direkt bestimmen und die Messung der Entfernung und Relativgeschwindigkeit ist in gewissen Grenzen möglich [27, S. 9].

Für die Schätzung der Entfernung und Relativgeschwindigkeit werden verschiedene Bildinformationen verwendet: die Größe des Objekts im Bild (Anzahl an Pixeln) und die Position des Objektbodens im Bild. Weil die Größe eines Objekts selbst innerhalb einer Objektklasse (z.B. Fußgänger, Motorrad, PKW, LKW) variiert, beträgt eine auf Objektgröße basierende Schätzung der Entfernung nur eine Genauigkeit von ca. 30% [54, S. 2]. Eine bessere Schätzung der Entfernung und Relativgeschwindigkeit zu Objekten kann durch die Verwendung der Straßengeometrie und des Kontaktpunkts des Objekts mit der Straße erreicht werden [54, S. 2].

Die Größe eines Objekts im Bild hat zusätzlich Einfluss auf die Objektdetektion und kann unter Berücksichtigung der Entfernung  $R$ , der Objekthöhe  $H$ , der Objektbreite  $W$  und der Brennweite  $f$  der Kameraoptik nach

$$h_o = \frac{f \cdot H}{R} ; w_o = \frac{f \cdot W}{R} \quad (2.28)$$

berechnet werden [44, S. 149]. Abhängig von der Objektklasse, müssen Objekte eine Mindestgröße im Bild aufweisen, um vom Bildverarbeitungsalgorithmus erkannt werden zu können. Diese Mindestgröße wiederum ist abhängig vom Bildverarbeitungsalgorithmus, der somit einen maßgeblichen Einfluss auf die Sensorperformance hat.

Einfluss auf die Genauigkeit der aufgenommenen Bildinformationen hat die Auflösung der Kamerasensoren. Die Auflösung beschreibt die Fähigkeit des Sensors Objekte eindeutig und mit deutlichen Grenzen zu erkennen. Sie bezieht sich auf die Anzahl an Pixeln durch die ein Objekt im Bild dargestellt wird und ist ein Maß für die Detailtiefe der aufgenommenen Bilder [44, S. 150], wie (Abbildung 2.8) zeigt.




Abbildung 2.8: Einfluss der Auflösung eines Kamerasensors [44, S. 150]

Für die Umfelderkennung und Objektdetektion mit Kamerasensoren ist neben der Objektgröße im Bild, der Auflösung und dem Kontrast auch deren Empfangscharakteristik wichtig. Diese kann aus der in Kapitel 2.3.3 hergeleiteten Lidargleichung abgeleitet werden.

Ein Objekt in der Entfernung  $R$  nimmt durch die Sonnenstrahlung proportional zu seinem Rückstreuquerschnitt  $\sigma$  die Leistung  $P_o$  nach

$$P_o = E_{sun} * \sigma \quad (2.29)$$

auf und reflektiert die Strahlung isotrop, wobei  $E_{sun}$  die Strahlungsdichte der Sonnenstrahlung darstellt. An der Linse des Kamerasensors ergibt sich die zurückgestrahlte Leistungsdichte  $S_r$  gemäß

$$S_r = \frac{P_o}{4 * \pi * R^2} . \quad (2.30)$$

Aus der Leistungsdichte  $S_r$  ergibt sich die empfangene Strahlungsleistung  $P_{r,ideal}$  unter Berücksichtigung des Linsendurchmessers  $D_r$  zu

$$P_{r,ideal} = S_r * A_r = S_r * \frac{\pi * D_r^2}{4} . \quad (2.31)$$

Setzt man die Gleichungen Gl. (2.29) – Gl. (2.31) ineinander ein, erhält man unter Berücksichtigung der Kameraauflösung  $N_{pix,image}$ , und der Objektgröße im Bild  $N_{pix,o} = h_o * w_o$  die Kameragleichung

$$P_{r,image} = \frac{E_{sun} * \sigma * D_r^2 * N_{pix,o}(R)}{R^2 * 16 * L_{ges} * N_{pix,image}} , \quad (2.32)$$

in der die atmosphärische Dämpfung und die Systemverluste des Kamerasensors im Dämpfungsfaktor  $L_{ges}$  zusammengefasst sind [55, S. 85-86]. Die im Kamerasensor vom Objekt erzeugten Elektronen lassen sich nach

$$N_e = \frac{P_{r,image} * T_{int} * QE}{h * \nu} \quad (2.33)$$

berechnen, wobei  $h$  die Planck'sche Wirkungskonstante,  $\nu$  die Frequenz der Lichtstrahlen,  $T_{int}$  die Integrationszeit des Kamerasensors und  $QE$  die Quanteneffizienz bei der Umwandlung von Photonen darstellen [55, S. 87].

Zur Charakterisierung der Sensorperformance wird das Signal-Rausch-Verhältnis verwendet, das durch

$$SNR = \frac{N_e}{N_{e,n}} \quad (2.34)$$

definiert ist und die Anzahl der vom Objekt erzeugten Elektronen  $N_e$  mit der Anzahl an Rauschelektronen  $N_{e,n}$  ins Verhältnis setzt. Die Rauschelektronen in Kamerasensoren im Automobilbereich werden primär durch Schrotrauschen erzeugt [55, S. 69] und berechnen sich nach

$$N_{e,n,shot} = \sqrt{N_e} . \quad (2.35)$$

Schrotrauschen kann nicht unterdrückt werden und steigt mit der Anzahl an empfangenen Photonen an [55, S. 71]. Die durch thermisches Rauschen, das in Form von Temperaturstrahlung aufgenommen wird, erzeugten Rauschelektronen können durch die Systemrauschtemperatur  $T_{sys}$  dargestellt werden. Das Signal-Rausch-Verhältnis eines Kamerasensors lässt sich nach

$$SNR = \frac{N_e}{\sqrt{N_e + \frac{k * B_n * T_{sys} * QE * T_{int}}{h * \nu}}} \quad (2.36)$$

berechnen, wobei  $h$  die Planck'sche Wirkungskonstante,  $k$  die Boltzmann Konstante,  $\nu$  die Frequenz der Lichtstrahlen,  $T_{int}$  die Integrationszeit des Kamerasensors,  $QE$  die Quanteneffizienz und  $B_n$  die Rauschbandbreite beschreiben.

Im Vergleich zu den anderen Sensoren haben Kamerasensoren große Probleme bei direkter Sonneneinstrahlung, weil sie, wie das menschliche Auge, geblendet werden [56, S. 40]. Durch die auf die Empfängerfläche eintreffende Sonneneinstrahlung werden im Kamerasensor weitere Elektronen erzeugt. Diese Elektronen stellen Rauschelektronen dar, wodurch sich das Signal-Rausch-Verhältnis bei direkter Sonneneinstrahlung zu

$$SNR = \frac{N_e}{N_{e,n} + N_{e,sun}} = \frac{N_e}{N_{e,n} + \frac{E_{sun} * N_{pix,image} * QE * T_{int}}{h * \nu}} \quad (2.37)$$

ergibt.

### 2.3.5 Vergleich der Sensoren

Alle Sensoren zur Umfelderkennung interagieren basierend auf ihrem Funktionsprinzip über einen bestimmten Sensorkanal mit der Fahrzeugumgebung. Echoeffekte von elektromagnetischen Wellen bzw. Ultraschallwellen stellen den Sensorkanal von Radarsensoren bzw. Ultraschallsensoren dar. Lidarsensoren basieren auf dem Prinzip der Laufzeitmessung von optischen Laserstrahlen. Bei Kamerasensoren repräsentiert die Ausbreitung von optischem Licht den Sensorkanal [57, S. 3]. Jede Sensortechnologie besitzt prinzipbedingte Vor- und Nachteile, die in (Abbildung 2.9) dargestellt sind.

	Kamera	Laserscanner	Radar	Ultraschall	Fusion
Blickfeld	↑	↑	↗	→	↑
Messbereich, Reichweite	↗	↑	↑	↘	↑
Geschwindigkeitsauflösung	→	↗	↑	↘	↑
Radiale Auflösung	↑	↗	→	↘	↑
Betrieb unter schlechten Witterungsbedingungen	→	↗	↗	→	↑
Betrieb bei Nacht, Störung durch Umgebungslicht	↗	↑	↑	↑	↑
Objektklassifizierung, semantische Informationen	↑	↗	→	↘	↑

Abbildung 2.9: Gegenüberstellung verschiedener Sensortechnologien [15, S. 34]

Radarsensoren erfassen ein großes Blickfeld bzw. haben eine große Reichweite, abhängig von ihrem Einsatz als Mittelbereichsradar (MRR) bzw. Fernbereichsradar (LRR). Ein Vorteil von Radarsensoren besteht darin, dass die Relativgeschwindigkeit zu Objekten unter Ausnutzung des Doppler-Effekts direkt gemessen werden kann. Radarsensoren besitzen eine hohe longitudinale Auflösung bei der Bestimmung der Entfernung zu Objekten. Ihre radiale Auflösung hingegen ist ungenauer. Die Bestimmung des Betrachtungswinkels eines Objekts ist mit Radarsensoren prinzipiell möglich, stellt aber hohe Anforderungen an die Hardware und Rechenzeit [28, S. 18]. Ein weiterer Vorteil von Radarsensoren ist die weitestgehende Unabhängigkeit von Witterungsbedingungen und Lichtverhältnissen. Lediglich bei starkem Regen ist die Leistungsfähigkeit von Radarsensoren beeinflusst [25, S. 1], [58, S. 1]. Als Output liefern Radarsensoren zweidimensionale Daten in Form der Position und Geschwindigkeit eines Objekts, wodurch eine Objektklassifizierung nur eingeschränkt möglich ist [59, S. 1838-1839].

Ultraschallsensoren erfassen ein großes Blickfeld, besitzen aber eine begrenzte Reichweite von wenigen Metern. Eine Messung der Relativgeschwindigkeit zu Objekten ist mit Ultraschallsensoren unter Ausnutzung des Doppler-Effekts prinzipiell möglich, findet aufgrund der eingeschränkten Reichweite jedoch keine Anwendung. Die longitudinale und radiale Auflösung von Ultraschallsensoren ist ungenau. Durch die Verwendung mehrerer Ultraschallsensoren kann diese verbessert werden. Ein Vorteil von Ultraschallsensoren besteht in der weitestgehend unabhängigen Leistungsfähigkeit bei verschiedenen Witterungsbedingungen und Lichtverhältnissen.

Lidarsensoren erfassen ein großes Blickfeld und haben eine große Reichweite, die durch die Einhaltung der Augensicherheitsvorschriften begrenzt ist. Die Relativgeschwindigkeit zu Objekten lässt sich mit Lidarsensoren nur indirekt durch Differenzierung zweier aufeinander folgender Scans bestimmen. Ein Vorteil von Lidarsensoren ist die hohe longitudinale Auflösung bei der Bestimmung der Entfernung zu Objekten [44, S. 147], sowie die hohe radiale Auflösung im Vergleich zu Radarsensoren [43, S. 1]. Durch den Einsatz in Form von Laserscannern kann der Betrachtungswinkel eines Objekt mit Lidarsensoren direkt gemessen werden. Ein weiterer Vorteil von Lidarsensoren ist die weitestgehende Unabhängigkeit von Lichtverhältnissen [10, S. 506]. Bei schlechten Witterungsverhältnissen und besonders bei Nebel ist die Sensorperformance beeinflusst [58, S. 1]. Als Output liefern Lidarsensoren 3D- Punktwolken, bei denen die Messpunkte dicht genug aneinander liegen um eine Objektklassifizierung zu ermöglichen [59, S. 1838-1839].

Kamerasensoren erfassen ein großes Blickfeld und haben eine große Reichweite. Die Relativgeschwindigkeit zu Objekten lässt sich mit Kamerasensoren nur indirekt durch Differenzierung zweier nacheinander aufgenommener Bilder bestimmen. Bei Verwendung von monokularen Kamerasystemen kann ebenso die Entfernung zu Objekten nur indirekt bestimmt werden. Bei der Verwendung von Stereokameras kann die Entfernung zu Objekten geschätzt werden. Die Reichweite von Stereokameras ist jedoch begrenzt [3, S. 392], [27, S. 18]. Ein Vorteil von Kamerasensoren ist die hohe radiale Auflösung durch Verarbeitung der aufgenommenen Bilder. Bei schlechten Witterungsverhältnissen und ungenügenden Lichtverhältnissen entstehen Einbußen in der Leistungsfähigkeit [3, S. 394]. Diese ist besonders bei Dunkelheit oder direkter Sonneneinstrahlung beeinflusst, bei der die Kamerasensoren geblendet werden. Ein weiterer Vorteil von Kamerasensoren ist die Ausgabe hochauflösender Bilder der Szenerie, wodurch eine hervorragende Objekterkennung und -klassifizierung möglich ist [59, S. 1838-1839].

Die Eigenschaften der einzelnen Sensortechnologien lassen sich wie folgt zusammenfassen und sind in (Abbildung 2.10) nochmals grafisch dargestellt. Die abgebildeten Werte stützen sich auf den Aussagen der verwendeten Literatur, sowie den Erfahrungen des Autors. Radarsensoren sind weitestgehend wetterunabhängig und besitzen sehr gute longitudinale Eigenschaften. Lidarsensoren sind eher wetterabhängig, besitzen aber sehr gute longitudinale und gute radiale Eigenschaften. Kamerasensoren sind ebenfalls wetterabhängig und besitzen sehr gute radiale Eigenschaften. Zusätzlich bieten Kamerasensoren die Möglichkeit einer genauen Objektklassifizierung. Im Gegensatz zu Radar-, Ultraschall- und Lidarsensoren sind Kamerasensoren passive Sensoren, wodurch sie Interferenzen und Störungen mehrerer Sender ausschließen. Andererseits sind Kamerasensoren von natürlichen Störeinflüssen beeinflusst, wie z.B. Blendung durch die Sonne [28, S. 18-19].

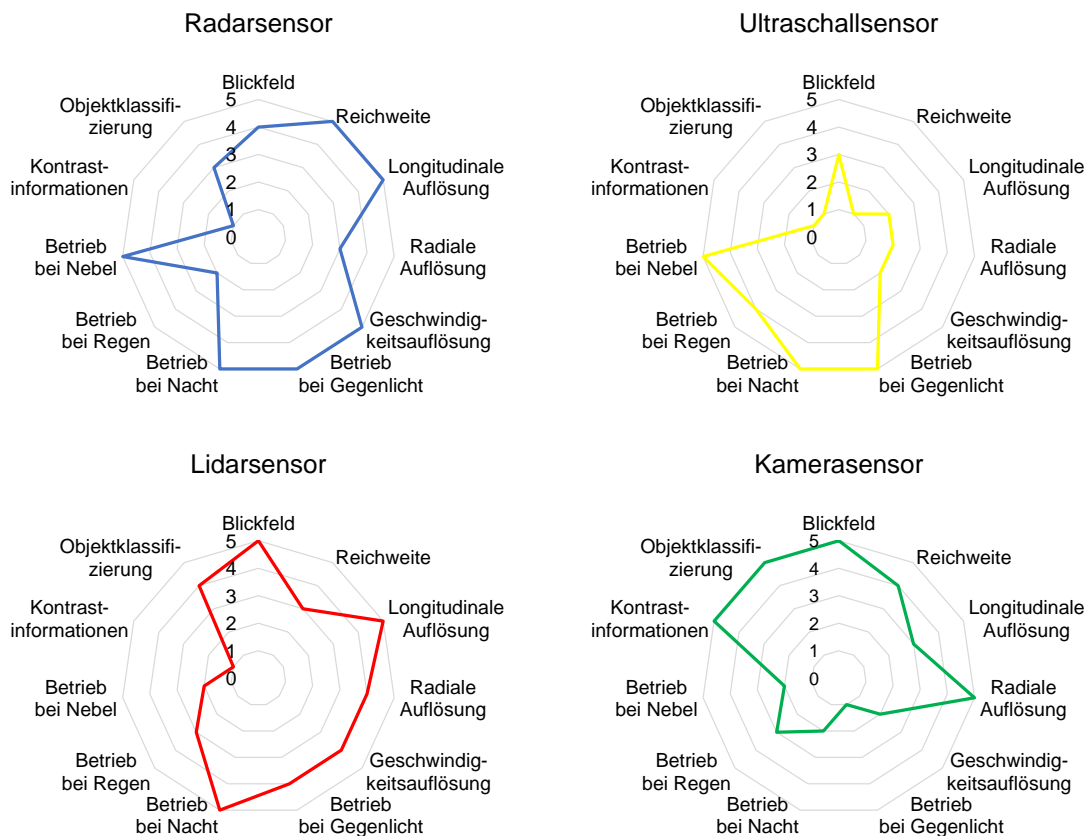


Abbildung 2.10: Vergleich der Eigenschaften verschiedener Sensortechnologien

### 2.3.6 Sensorfusion

Zur Umfelderfassung autonomer Fahrzeuge kommen die in Kapitel 2.3.1 bis Kapitel 2.3.4 beschriebenen Sensoren (Radar, Ultraschall, Lidar, Kamera) zum Einsatz. Keiner dieser Sensoren allein ist aktuell in der Lage hinreichend zuverlässige und detaillierte Umgebungsinformationen für die gewünschten autonomen Fahr- und Sicherheitsfunktionen von autonomen Fahrzeugen zu liefern [60, S. 59]. Aus diesem Grund müssen mehrere Sensoren unterschiedlicher Technologien kombiniert werden, um Redundanz und Diversität zu erreichen und die Nachteile der Einzelsensoren zu kompensieren. Die Einzelsensoren arbeiten unabhängig voneinander, sodass deren Messwerte asynchron erzeugt werden [25, S. 4] und im Sensorfusion-System zu einem robusten und gesamtheitlichen Modell der Fahrzeugumfelds fusioniert werden müssen.

Sensorfusion-Systeme lassen sich abhängig von der Interaktion mit anderen Sensoren und der Abstraktionsebene der Datenverarbeitung unterscheiden. Im Allgemeinen gibt es drei Arten Sensoren zu kombinieren. Es wird zwischen komplementärer, konkurrierender und kooperativer Fusion unterschieden, die in (Abbildung 2.11) dargestellt sind.

Bei der komplementären Fusion werden die Daten mehrerer unabhängiger Sensoren verknüpft. Motivation ist die Erfassung einer größeren Datenmenge zur Vervollständigung der benötigten Informationen. Die Sensoren können sich sowohl bei den Erfassungsbereichen als auch bei den Messgrößen ergänzen [32, S. 54-55]. Ein Beispiel hierfür ist die Kombination mehrerer Kameras zur Darstellung eines 360° Bilds. Bei der konkurrierenden Fusion werden identische Informationen von mehreren unabhängigen Sensoren gemessen. Durch eine Verknüpfung der Einzelwerte kann die Messgenauigkeit erhöht werden. Zusätzlich reduziert sich durch das

redundante Messprinzip die Ausfallwahrscheinlichkeit bei Sensorausfällen und Übertragungsfehlern [32, S. 54-55]. Ein Beispiel hierfür ist die Kombination eines Front-Lidars und eines Front-Radars. Bei der kooperativen Fusion werden die benötigten Informationen aus dem Zusammenschluss mehrerer unabhängiger Sensoren generiert, die einzeln jeweils nur einen Teilaspekt messen können. Im Gegensatz zur konkurrierenden Fusion besteht keine Redundanz [28, S. 69]. Ein Beispiel hierfür ist die Stereokamera, die die Daten von zwei Kameras verwendet, um die Entfernung eines Objekts zu bestimmen.




Abbildung 2.11: Vergleich verschiedener Fusionsmethoden [60, S. 62]

Die Vorteile der Sensorfusion-Systeme liegen in einer Verbesserung der Messgenauigkeit und Detektionssicherheit bei redundanten Daten, in einer Erweiterung des Erfassungsbereichs und der Datenmenge bei komplementären Daten, wodurch sich ein fehlertolerantes und konsistentes Modell des Fahrzeugumfelds generieren lässt [60, S. 63]. Bei der Verwendung mehrerer Sensoren können unterschiedliche Zykluszeiten und Latenzzeiten auftreten, wodurch zusätzlich auch zeitliche Aspekte bei der Sensorfusion berücksichtigt werden müssen. Dies sind zum einen Asynchronitäten (z.B. unterschiedliche Datenübertragungsraten der Sensoren) und zum anderen Nichtsequenzialitäten (z.B. unterschiedliche Zeitdauern der sensorinternen Signalverarbeitung) [28, S. 69-70]. Konzepte zum Umgang mit den zeitlichen Aspekten bei der Sensorfusion werden in [28] beschrieben.

Hinsichtlich der eigentlichen Fusion der Messdaten verschiedener Sensoren ergeben sich zwei unterschiedliche Vorgehensweisen. Bei der ersten werden die Messdaten asynchron in unabhängigen Verarbeitungszyklen eingebracht. Es ergibt sich eine implizite Fusion, weil die Messdaten nicht direkt vereinigt werden, sondern indirekt über das sequentielle Update der Informationen. Bei der zweiten Vorgehensweise werden die Messdaten synchron in einem gemeinsamen Assoziationsschritt verarbeitet. Es ergibt sich eine explizite Fusion, weil die Messdaten direkt vereinigt werden [60, S. 64]. Als wesentlicher Unterschied zwischen beiden Vorgehensweisen zeigt sich, dass bei der impliziten Fusion für jeden Sensor eine individuelle Abstraktionsebene gewählt werden kann, auf dem die Messdaten in den Fusionsprozess eingebracht werden. Bei der expliziten Fusion hingegen muss eine gemeinsame Abstraktionsebene der Messdaten existieren, damit diese in einem Assoziationsschritt vereint werden können [60, S. 66].



Voraussetzung für eine Sensorfusion ist die Existenz von Objektmodellen, wie beispielsweise Fußgänger, Motorräder, PKW und LKW, die trotz individueller Unterschiede ein identisches dynamisches Verhalten innerhalb ihrer Klasse aufweisen und durch identische Zustandsgrößen beschrieben werden können [60, S. 60]. Die Objektmodelle können auf unterschiedlichen Abstraktionsebenen formuliert werden, wodurch auch die Sensorfusion auf unterschiedlichen Abstraktionsebenen erfolgen kann. Der Abstraktionsgrad der Datenverarbeitung muss hierbei zum Abstraktionsgrad der Objektmodelle passen [60, S. 67].

Bei der Fusion auf Signalebene werden Rohdaten bzw. minimal vorverarbeitete Daten miteinander verknüpft. Die Fusion findet zu einem frühen Zeitpunkt der Verarbeitungskette statt, an dem noch kein Informationsverlust auftritt. Die Verarbeitung ist aufgrund des geringen Abstraktionsgrads und der großen Datenmenge am aufwendigsten und benötigt synchrone Daten [32, S. 55-56]. Bei der Fusion auf Merkmalebene werden die Daten der einzelnen Sensoren unabhängig voneinander vorverarbeitet. Die dadurch extrahierten Merkmale werden anschließend in einem höheren Abstraktionsgrad fusioniert, was die Zusammenführung unterschiedlicher Messgrößen erlaubt und die Datenmenge reduziert [28, S. 68]. Bei der Fusion auf Objektebene werden die Daten der einzelnen Sensoren unabhängig voneinander entlang der gesamten Verarbeitungskette verarbeitet und anschließend die extrahierten Objekte im höchsten Abstraktionsgrad fusioniert. Dadurch ist die zu verarbeitende Datenmenge am geringsten, es kommt allerdings zu Informationsverlusten [32, S. 55-56].

Die Wahl der optimalen Fusionsmethode hängt von einer Vielzahl an Faktoren ab, wie beispielsweise der gewünschten Sensorperformance, Anforderungen an die redundante Systemauslegung oder den verfügbaren Ressourcen. Aus diesem Grund existieren je nach Anzahl der Sensoren und Plattform für die Implementierung hybride Formen der dargestellten Fusionsmethoden [28, S. 69].

## 2.4 Sensormodellierung

Die Aussagekraft simulationsbasierter Auswertungen ist stark von der Qualität der Simulationen abhängig, d.h. von der Wahrscheinlichkeit, dass reale und simulierte Systeme ein ähnliches Verhalten aufweisen [61, S. 27]. Die Modellierung der umfelderfassenden Sensoren und ihrer Eigenschaften hat somit großen Einfluss auf die Güte der Simulation autonomer Fahrzeuge. Aktuell ist noch unklar welche Anforderungen an die Sensormodelle definiert werden müssen. Ebenso gibt es aktuell noch keine Methodik oder Richtlinie, welches Ausmaß an physikalischen Effekten oder stochastischem Verhalten bei der Modellierung der Sensoren berücksichtigt werden sollte [47, S. 1]. Aus diesem Grund gibt es verschiedene Ansätze zur Modellierung der Sensoren, die sich in ihrem Abstraktionsgrad unterscheiden.

### 2.4.1 Idealisierte Modelle

Kommerziell verfügbare Simulationspakete bieten heute bereits umfelderfassende Sensormodelle an, wobei es sich hierbei meist um idealisierte Sensormodelle handelt [19, S. 73]. Idealisierte Sensormodelle bilden den geometrischen Raum der Sensorabdeckung ab und machen keine Messfehler, d.h. sie detektieren Objekte zu jedem Zeitpunkt, wenn sich diese im Sensorbereich befinden [19, S. 76]. Reale Effekte, wie Abschattung, Dämpfung oder Rauschen werden nicht berücksichtigt. Idealisierte Sensormodelle stellen sog. Ground-Truth-Modelle dar,

die die wahren, ungestörten Werte der simulierten Größen (z.B. Position eines Objekts) liefern. Die Motivation hinter solchen Modellen ist die Folgerung, dass ein System, das anhand idealisierter Daten scheitert, die Anforderungen in realistischen Szenarien sicherlich nicht erfüllen kann [61, S. 27].

Aufgrund ihres hohen Abstraktionsgrads sind idealisierte Sensormodelle einfach zu parametrieren, echtzeitfähig und benötigen nur einen geringen Rechenaufwand. Der Nachteil ist, dass sie Sensorstörungen vollständig vernachlässigen, wodurch ihre Aussagekraft stark beschränkt ist [61, S. 27].

### 2.4.2 Phänomenologische Modelle

Phänomenologische Sensormodelle versuchen die Eigenschaften der Sensoren und reale Effekte nachzubilden. Auftretende Effekte werden phänomenologisch modelliert, d.h. das Resultat der Effekte wird nachgebildet [22]. So werden beispielsweise ideale Sensorsignale mit Effekten überlagert, die durch Umwelteinflüsse und Eigenschaften der zu detektierenden Objekte erzeugt werden [19, S. 74]. Bei phänomenologischen Sensormodelle werden die Beziehungen zwischen Eingaben und Ausgaben der Sensoren und der im Umfeld befindlichen Systeme modelliert, ohne die genauen inneren Vorgänge und Effekte zu kennen [62, S. 23].

Phänomenologische Sensormodelle können reale Sensoreigenschaften nicht exakt darstellen, besitzen aber dennoch eine hohe Aussagekraft, bei geringem Parametrierungsaufwand und guter Anpassungsmöglichkeit. Ihr Rechenaufwand ist im Vergleich zu idealisierten Sensormodellen höher, sie sind aber dennoch echtzeitfähig. Phänomenologische Sensormodelle stellen somit einen vielversprechenden Kompromiss zwischen Aussagekraft und Rechenaufwand dar [18] und sind aus diesem Grund Gegenstand aktueller Forschungs- und Entwicklungsarbeiten [19].

### 2.4.3 Physikalische Modelle

Physikalische Sensormodelle versuchen die Charakteristik der Sensoren, das physikalische Messprinzip und reale Effekte korrekt abzubilden [61, S. 27]. So werden beispielsweise die Reflexionseigenschaften eines Objekts physikalisch modelliert, wofür Materialeigenschaften, Geometrie und Lage der Streuzentren bekannt sein müssen. Die modellierten Sensoren werden durch Sender und Empfänger beschrieben, die so modifiziert werden, dass sie die realen Sensorcharakteristiken abbilden. Die Sender werden durch Punkt-Lichtquellen dargestellt, die Empfänger durch Kameras [63, S. 11]. Ein physikalischer Modellierungsansatz für Radar-, Ultraschall-, Lidar- und Kamerasensoren sind sog. Ray-Tracing-Modelle, die den Ansatz der Strahlverfolgung verwenden [57, S. 6]. Dabei wird angenommen, dass sich die ausgesendeten und empfangenen Signale entlang von Strahlen ausbreiten, die an Objekten auf Grundlage der Reflexions- und Brechungsgesetze reflektiert und gebrochen werden. Die Richtung der Strahlen ist reversibel und es treten keine Interferenzen zwischen den Strahlen auf [57, S. 8].

Physikalische Sensormodelle besitzen die höchste Aussagekraft und maximieren den Realismus der simulierten Größen. Nachteilig ist ihr hoher Rechenaufwand und ihre begrenzte Anpassungsmöglichkeit [61, S. 27]. Eine Anpassung der Simulation an verschiedene Sensortypen erfordert ein völlig neues physikalisches Sensormodell, wodurch der Einsatz physikalischer Sensormodelle in der Konzeptphase nicht sinnvoll ist [19, S. 73], [57, S. 5].

## 2.4.4 Sensorabdeckungsmodelle

Sensorabdeckungsmodelle sind Abstraktionsmodelle, die versuchen zu quantifizieren, wie gut Sensoren physikalische Phänomene an bestimmten Orten wahrnehmen können oder mit anderen Worten, wie gut Sensoren bestimmte Orte abdecken. Sensorabdeckungsmodelle werden verwendet, um die Eigenschaften und Performance von Sensoren darzustellen. Dazu bestimmen sie die Detektionsfähigkeit und -qualität, indem sie die geometrische Beziehung zwischen einem Raumpunkt und dem Sensor erfassen. In fast allen Fällen können Sensorabdeckungsmodelle mathematisch als eine Abdeckungsfunktion von Entfernungen und Winkeln formuliert werden. Die Eingaben solcher Abdeckungsfunktionen sind die Abstände zwischen bestimmten Raumpunkten und dem Sensor. Die Ausgaben sind positive reelle Zahlen, die die Detektionsfähigkeit und -qualität beschreiben und als Abdeckungsmaß bezeichnet werden [64, S. 21]. Sensorabdeckungsmodelle können in zwei Arten unterteilt werden, abhängig von den Abdeckungsfunktionen. Zum einen in boolesche Sensorabdeckungsmodelle, deren Abdeckungsmaß entweder 0 oder 1 ist. Zum anderen in allgemeine Sensorabdeckungsmodelle, deren Abdeckungsmaß verschiedene positive reelle Zahlen annehmen kann [64, S. 22]. In der Literatur werden verschiedene Sensorabdeckungsmodelle vorgeschlagen, von denen im Rahmen der vorliegenden Arbeit nur einige vorgestellt werden. Für die Darstellung der verschiedenen Sensorabdeckungsmodelle und eine ausführliche Einführung wird auf [64] und [65] verwiesen.

Das am weitesten verbreitete Sensorabdeckungsmodell ist das Binary Disk Model, das annimmt, dass Objekte die sich innerhalb des Erfassungsbereichs des Sensors  $R_s$  befinden immer erkannt werden, während Objekte die sich außerhalb des Erfassungsbereichs des Sensors  $R_s$  befinden nicht erkannt werden [66, S. 1462]:

$$p_D = \begin{cases} 1, & R_o < R_s \\ 0, & R_o \geq R_s \end{cases} \quad (2.38)$$

Das Binary Disk Model gehört zur Art der booleschen Sensorabdeckungsmodelle, die auch deterministische Sensorabdeckungsmodelle genannt werden [65, S. 2].

Eine Erweiterung des Binary Disk Model stellt das Truncated Attenuated Disk Model dar. Das Truncated Attenuated Disk Model nimmt an, dass Objekte die sich innerhalb einer gewissen Entfernung  $R_1$  im Erfassungsbereich des Sensors  $R_s$  befinden immer erkannt werden, während Objekte die sich außerhalb des Erfassungsbereichs des Sensors  $R_s$  befinden nicht erkannt werden. Objekte die sich in einer Entfernung  $> R_1$  im Erfassungsbereich des Sensors  $R_s$  befinden werden mit einer gewissen Detektionswahrscheinlichkeit  $p_D \in ]0,1[$  erkannt, die mit zunehmender Entfernung abnimmt [67, S. 833]:

$$p_D = \begin{cases} 1, & R_o < R_1 \\ f(R_o), & R_1 < R_o < R_s \\ 0, & R_o \geq R_s \end{cases} \quad (2.39)$$

Die Abnahme der Detektionswahrscheinlichkeit in Abhängigkeit der Entfernung stellt die realen Eigenschaften umfelderfassender Sensoren dar und kann durch verschiedene Funktionen modelliert werden [65, S. 3].

Obwohl diese probabilistischen Sensorabdeckungsmodelle die realen Sensoreigenschaften deutlich besser abbilden als deterministische Sensorabdeckungsmodelle, liefern sie keinen geeigneten Formalismus um Unzuverlässigkeiten einzelner Sensoren und Unzuverlässigkeiten bei der Fusion mehrerer Sensoren zu berücksichtigen. Zum Beispiel können die Messungen von Sensoren variieren, weil die Zuverlässigkeit einiger Sensoren bei schlechten Wetter-

bedingungen stärker beeinflusst ist als die Zuverlässigkeit anderer Sensoren [66, S. 1462], [68, S. 782]. Daher wurden verschiedene Theorien entwickelt, um die Sensorzuverlässigkeit bewerten zu können [69, S. 136]. Eine dieser Theorien ist die Theorie der Glaubensfunktionen, die die Zuverlässigkeit eines Sensors durch einen Gewichtungsfaktor darstellt, d.h. einen Koeffizienten, der die dem Sensor zugeordnete Detektionswahrscheinlichkeitsfunktion gewichtet [68, S. 782-783]. Das daraus abgeleitete Evidence-Based Sensor Coverage Model ist in (Abbildung 2.12) dargestellt.

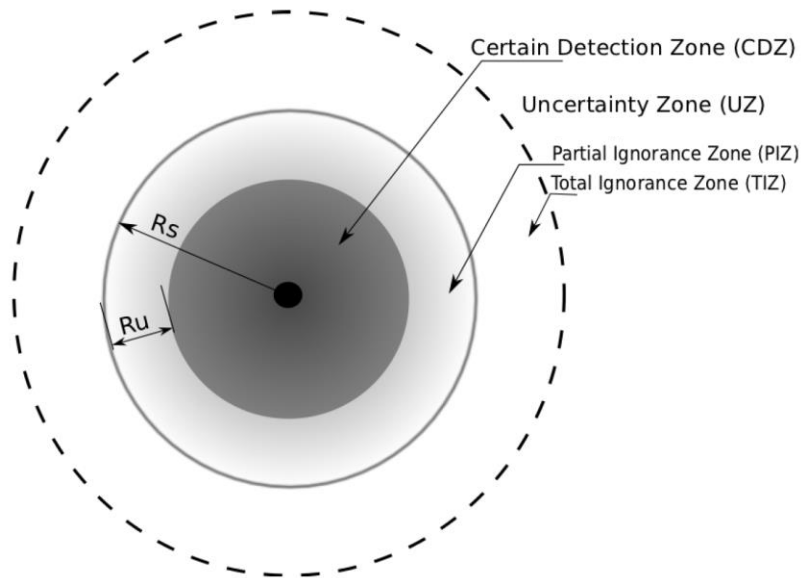


Abbildung 2.12: Evidence Based Sensor Coverage Model [66, S. 1463]

Das Evidence-Based Sensor Coverage Model benötigt zwei Zustände, um anzugeben, ob ein Raumpunkt abgedeckt ist:  $\theta_0$  (nicht abgedeckt) und  $\theta_1$  (abgedeckt). Dadurch ergibt sich der Rahmen der Unterscheidung  $\Theta = \{\theta_0, \theta_1\}$  (engl. Frame of Discernment). Es wird angenommen, dass jeder Sensor Informationen über die Abdeckung eines Raumpunkts mit einer Annahme  $x_{s,p}$  (gewichtete Wahrscheinlichkeit) liefert. Die komplementäre Information  $1 - x_{s,p}$  stellt die Unzuverlässigkeit des Sensors dar und wird dem Rahmen der Unterscheidung  $\Theta$  zugeordnet. Die Ausgabe eines Sensors für einen Raumpunkt kann als Glaubensfunktion  $m_{s,p}$  mit zwei fokalen Sätzen dargestellt werden: dem Singleton  $\{\theta_1\}$  und dem Rahmen der Unterscheidung  $\Theta$ . In der Certain Detection Zone (CDZ) ergibt sich die Glaubensfunktion zu

$$\begin{aligned} m_{s,p}(\{\theta_1\}) &= 1 \\ m_{s,p}(\Theta) &= 0 \end{aligned} \quad (2.40)$$

in der Partial Ignorance Zone (PIZ) zu

$$\begin{aligned} m_{s,p}(\{\theta_1\}) &= x_{s,p}, \quad x_{s,p} \in ]0,1[ \\ m_{s,p}(\Theta) &= 1 - x_{s,p} \end{aligned} \quad (2.41)$$

und in der Total Ignorance Zone zu

$$\begin{aligned} m_{s,p}(\{\theta_1\}) &= 0 \\ m_{s,p}(\Theta) &= 1 \end{aligned} \quad (2.42)$$

[66, S. 1463]. Die Glaubensfunktion  $m_{s,p}$  eines Sensors stellt die Detektionswahrscheinlichkeitsfunktion eines Objekts in Abhängigkeit der Entfernung und der Unzuverlässigkeit des Sensors

dar. Bei der Fusion mehrerer Sensoren kann die Gesamtdetektionswahrscheinlichkeit eines Objekts aus den Detektionswahrscheinlichkeiten der einzelnen Sensoren nach

$$p_D = 1 - \prod_{i=1}^N (1 - x_{i,s,p}) \quad (2.43)$$

berechnet werden [66, S. 1465].

## 2.5 Optimierung

Bei Problemstellungen in der Technik, Natur- und Wirtschaftswissenschaft werden häufig maximale Ergebnisse bei minimalen Aufwand gesucht. Die Optimierung im mathematischen Sinn beschreibt das Vorgehen zum Auffinden dieses Optimums, d.h. dem Auffinden mehr als einer bloßen Verbesserung, sondern der bestmöglichen Lösung [70, S. 1]. Weil die Theorie der mathematischen Optimierung sehr umfangreich ist, kann im Rahmen der vorliegenden Arbeit nur auf die für die Arbeit grundlegenden Aspekte eingegangen werden. Für eine ausführliche Einführung in die mathematische Optimierung wird auf [71] verwiesen.

### 2.5.1 Mathematische Optimierung

Die allgemeine Aufgabenstellung der Optimierung besteht darin, zu einer gegebenen Menge  $X \subseteq \mathbb{R}^n, n \in \mathbb{N} \setminus \{0\}$  und einer Funktion  $f: X \rightarrow \mathbb{R}$  ein  $\vec{x}^* \in Z \subseteq \mathbb{R}^n$  zu finden, so dass gilt:  $f(\vec{x}^*) \leq f(\vec{x})$  für alle  $\vec{x} \in Z$ . Hierbei ist die Kurzschreibweise

$$\min_{\vec{x} \in Z} f(\vec{x}) \quad (2.44)$$

üblich. Im Fall von  $Z \subset X \subseteq \mathbb{R}^n$  spricht man von restringierter Optimierung, während man für  $Z = \mathbb{R}^n$  von unrestringierter Optimierung spricht [72, S. 1]. In der Optimierungstheorie werden üblicherweise nur Minimierungsprobleme betrachtet, die durch Multiplikation mit -1 in Maximierungsprobleme überführt werden können [70, S. 12].

$$\max_{\vec{x} \in Z} f(\vec{x}) = \min_{\vec{x} \in Z} -f(\vec{x}) \quad (2.45)$$

Die Funktion  $f$  wird Zielfunktion genannt und stellt das Optimierungskriterium dar. Zielfunktionen gilt es zu minimieren oder maximieren, d.h. kleinste oder größte Werte (Minima oder Maxima) zu berechnen, die allgemein als Optima bezeichnet werden. Die Werte der Variablen, für die die Zielfunktion ein Optimum annimmt, werden Optimalwerte (Minimal- oder Maximalwerte) genannt. Der zulässige Bereich  $Z$  wird durch Nebenbedingungen definiert und liefert Restriktionen für die Werte der Variablen. Die Nebenbedingungen werden durch Gleichungen und Ungleichungen beschrieben. Abhängig von der Form der Zielfunktion und den Nebenbedingungen ergeben sich verschiedene Theorien der Optimierung [73, S. 213]. Ist die Zielfunktion linear und werden die Nebenbedingungen durch ein System linearer Gleichungen und Ungleichungen definiert, spricht man von linearer Optimierung. Ist die Zielfunktion nichtlinear oder werden die Nebenbedingungen durch nichtlineare Gleichungen und Ungleichungen definiert, spricht man von nichtlinearer Optimierung [72, S. 1]. Die Berechnung eines Optimierungsproblems vollzieht sich in zwei Schritten. Zuerst muss ein mathematisches Optimierungsmodell aufgestellt werden, das die Zielfunktion, Nebenbedingungen und Variablen festlegt. Liegt das mathematische Optimierungsmodell vor, wird im Zuge der mathematischen Optimierung das Optimum berechnet, wofür im Allgemeinen der Einsatz von Computern erforderlich ist [73, S. 213].

Notwendige Kriterien zum Auffinden eines Optimums stellen die Ableitungen der Zielfunktion dar. Hat  $f$  an der Stelle  $\vec{x}^* \in Z$  ein Optimum und ist dort differenzierbar, so gilt

$$f'(\vec{x}^*) = 0 . \quad (2.46)$$

Ist  $f$  zweimal differenzierbar und gilt neben Gl. (2.46) auch

$$f''(\vec{x}^*) \neq 0 , \quad (2.47)$$

so hat  $f$  an der Stelle  $\vec{x}^*$  ein Optimum. Ist Gl. (2.47)  $> 0$ , handelt es sich um ein Minimum, ist Gl. (2.47)  $< 0$  handelt es sich dagegen um ein Maximum.

In der mathematischen Optimierung werden lokale (relative) und globale (absolute) Optima unterschieden, wie (Abbildung 2.13) darstellt. An der Stelle  $\vec{x}^* \in Z$  liegt ein globales Optimum vor, wenn

$$f(\vec{x}^*) \leq f(\vec{x}) \text{ für alle } \vec{x} \in Z . \quad (2.48)$$

An der Stelle  $\vec{x}^* \in Z$  liegt ein lokales Optimum vor, wenn in einer gewissen, kleinen Umgebung  $U_{\vec{x}^*}$  von  $\vec{x}^*$  gilt

$$f(\vec{x}^*) \leq f(\vec{x}) \text{ für alle } \vec{x} \in U_{\vec{x}^*} . \quad (2.49)$$

Aus Gl. (2.48) und Gl. (2.49) wird ersichtlich, dass globale Optima gleichzeitig immer auch lokale Optima sind, die Umkehrung im Allgemeinen aber nicht gilt [70, S. 14]. Bei linearen Optimierungsproblemen existieren nur globale Minima bzw. Maxima, die auf dem Rand des durch die Nebenbedingungen definierten zulässigen Bereichs  $Z$  liegen. Bei nichtlinearen Optimierungsproblemen können neben globalen auch lokale Minima bzw. Maxima auftreten. Allerdings existiert kein direktes Kriterium, um globale Optima zu identifizieren [70, S. 14]. Aus diesem Grund ist bei nichtlinearen Optimierungsproblemen oft nur die Berechnung lokaler Optima möglich.

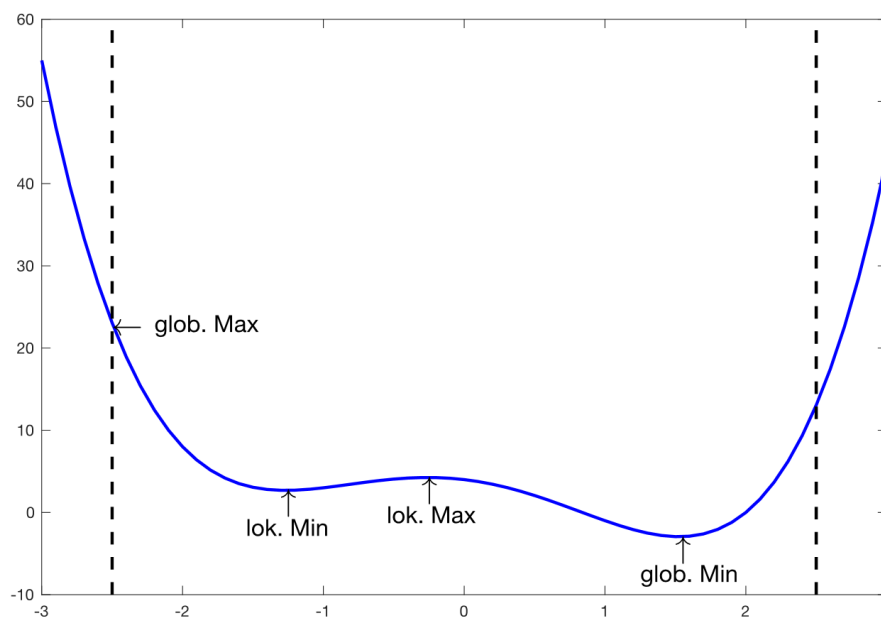


Abbildung 2.13: Unterscheidung globaler und lokaler Optima innerhalb festgelegter Restriktionen

## 2.5.2 Optimierung mit MATLAB

Weil sich praktische Optimierungsprobleme im Allgemeinen nicht exakt berechnen lassen, werden für deren Lösung numerische Verfahren eingesetzt. MATLAB, beispielsweise, bietet hierfür in der Toolbox Optimization vordefinierte Funktionen, abhängig von der Form der Zielfunktion und den Nebenbedingungen. Einige dieser Funktionen werden im Folgenden vorgestellt. Für ausführliche Informationen zur Toolbox Optimization wird auf die MATLAB-Hilfe verwiesen.

Für die Berechnung von Optimierungsproblemen ohne Nebenbedingungen bietet MATLAB die Funktionen `fminsearch` und `fminunc`. Die Funktion `fminsearch` verwendet den Nelder-Mead-Simplex Algorithmus, für den die Differenzierbarkeit der Zielfunktion nicht erforderlich ist. Die Funktion `fminunc` verwendet als numerischen Algorithmus einen BFGS Quasi-Newton Algorithmus, für den die Differenzierbarkeit der Zielfunktion erforderlich ist.

Die Berechnung von Optimierungsproblemen mit Nebenbedingungen kann mit der Funktion `fmincon` durchgeführt werden. Als Standardalgorithmus wird der Innere-Punkte-Algorithmus verwendet. Weiterhin können der SQP-, der Vertrauensbereich- und der Aktive-Mengen-Algorithmus angewendet werden. Die zu definierenden Nebenbedingungen müssen die Form

$$\begin{aligned} c_{ineq}(x) &\leq 0 \\ c_{eq}(x) &= 0 \\ A_{ineq} * x &\leq b_{ineq} \\ A_{eq} * x &= b_{eq} \\ lb &\leq x \leq ub \end{aligned} \quad (2.50)$$

aufweisen.  $x$ ,  $b_{eq}$ ,  $b_{ineq}$  sind Vektoren.  $A_{eq}$ ,  $A_{ineq}$  sind Matrizen.  $c_{eq}$ ,  $c_{ineq}$  sind Funktionen, die Vektoren liefern und nichtlinear sein dürfen. Die Funktion `fmincon` wird folgendermaßen im Kommandofenster aufgerufen:

```
[x, f] = fmincon(f(x), x0, A, b, Aeq, beq, lb, ub, [c, ceq], options);
```

und zeigt das Ergebnis im Vektor  $[x, f]$  an, in dem  $x$  die berechneten Optimalpunkte und  $f$  den zugehörigen Optimalwert bezeichnet.

Die verwendeten numerischen Algorithmen konvergieren bei der Berechnung von Optimierungsproblemen nicht immer, d.h. sie liefern kein Ergebnis bzw. kein optimales Ergebnis [73, S. 219]. Aus diesem Grund empfiehlt sich die Berechnung anhand mehrerer Startwerte durchzuführen, sowie eine sorgfältige Überprüfung der Ergebnisse.





# 3 Methoden

Nach der Darstellung des aktuellen Stands der Technik, befasst sich das folgende Kapitel mit der konkreten Umsetzung eines Berechnungsmodells zur Modellierung der Sensorabdeckung autonomer Fahrzeuge und Berechnung optimaler Annäherungspfade. In Kapitel 3.1 werden die entsprechenden Anforderungen an das Berechnungsmodell definiert. In Kapitel 3.2 werden die getroffenen Annahmen für die phänomenologische Sensormodellierung dargelegt und deren Verwendung gerechtfertigt. Zum Abschluss des Kapitels wird der Aufbau des Berechnungsmodells erläutert und dessen Umsetzung in MATLAB aufgezeigt.

## 3.1 Modellanforderungen

Wie in Kapitel 2.4 bereits erwähnt, hängt die Aussagekraft und Güte simulationsbasierter Auswertungen stark von der Qualität der Simulation und den zugrundeliegenden Modellen ab. Gemäß dem Ziel der vorliegenden Arbeit ergeben sich für die Berechnung optimaler Annäherungspfade auf Basis der Modellierung der Sensorabdeckung autonomer Fahrzeuge eine Reihe an Anforderungen an das Berechnungsmodell:

- Berücksichtigung verschiedener umfelderfassender Sensortechnologien: Radar, Ultraschall, Lidar, Kamera
- Berücksichtigung der Sende- und Empfangscharakteristik der Sensortechnologien
- Berücksichtigung der Leistungsfähigkeit der Sensortechnologien bei verschiedenen Objekten und Wetterbedingungen
- Berücksichtigung der Sensorfusion und Überlagerung mehrerer Sensoren
- Berücksichtigung verschiedener Einschränkungen und Bedingungen bei der Optimierung
- Einfache Anpassungsmöglichkeit im Hinblick auf die Sensortopologie und den Einsatz verschiedener Sensortypen
- Einfache Parametrierungsmöglichkeit der Sensormodelle und der Optimierung
- Berechnung und Visualisierung der Erfassungsbereiche der Sensoren und der Detektionswahrscheinlichkeit von Objekten in diesen
- Berechnung und Visualisierung optimaler Annäherungspfade an autonome Fahrzeuge

Anhand der Anforderungen an das Berechnungsmodell und dem in Kapitel 2 dargelegten Stand der Technik ergeben sich die Rahmenbedingungen für die Modellierung der Sensorabdeckung und die Berechnung optimaler Annäherungspfade.

Kapitel 2.4.2 zeigt, dass phänomenologische Modelle einen guten Kompromiss zwischen Aussagekraft und Parametrierungsaufwand darstellen, weil sie die Resultate physikalischer Effekte nachbilden. Aus diesem Grund werden im Rahmen der vorliegenden Arbeit die in autonomen Fahrzeugen zur Umfelderkennung eingesetzten Sensoren durch phänomenologische Modelle modelliert. Dazu werden Modellannahmen getroffen, die in Kapitel 3.2 aufgezeigt werden. Die Ausgabewerte der phänomenologischen Sensormodelle stellen die in Kapitel 2.3.1 bis Kapitel 2.3.4 hergeleiteten Signal-Rausch-Verhältnisse dar, um neben den Charakteristiken der Sensoren auch deren Unzuverlässigkeit und Abhängigkeit von Wetterbedingungen zu berücksichtigen. Die berechneten SNR-Werte werden durch sog. ROC-Kurven (engl. Receiver Operating Characteristics) in Detektionswahrscheinlichkeiten überführt und stellen die Gewichtungsfaktoren innerhalb der Theorie der Glaubensfunktionen dar (Kapitel 2.4.4). Die Sensorabdeckung autonomer Fahrzeuge wird somit durch ein Evidence Based Sensor Coverage Model modelliert, das die Fusion mehrerer Sensoren ermöglicht, eine einfache Anpassung an verschiedene Sensortopologien gewährleistet und als Grundlage für die Berechnung optimaler Annäherungspfade dient. Eine ausführliche Beschreibung des Modellaufbaus und der Modellumsetzung wird in Kapitel 3.3 gegeben.

## 3.2 Modellannahmen

Um die grundlegenden Sensorcharakteristiken und physikalischen Effekte phänomenologisch zu modellieren, werden die hergeleiteten Sensorgleichungen und Signal-Rausch-Verhältnisse verwendet. Diese hängen von einer Reihe von Parametern ab, weshalb für deren Berechnung einige Annahmen getroffen werden müssen. Ebenso müssen Annahmen bezüglich der Sensortopologie autonomer Fahrzeuge getroffen werden, um die Modellierung der Sensorabdeckung zu realisieren.

### 3.2.1 Sensortopologie

Die Sensortopologie, d.h. die Art, Anzahl und Anordnung der Sensoren bestimmt die Sensorabdeckung rund um ein autonomes Fahrzeug und beeinflusst maßgeblich die Qualität der Umfelderkennung. Der 2018 vorgestellte Audi A8 soll, sobald es die rechtlichen Rahmenbedingungen erlauben, als erstes Fahrzeug Fahrfunktionen der Stufe 3 aufweisen [15, S. 32] und dient aus diesem Grund im Rahmen der vorliegenden Arbeit als Referenzfahrzeug. Bei Vollausstattung besitzt der Audi A8 24 Sensoren [74, S. 67], die in (Abbildung 3.1) dargestellt sind:

- Zwölf Ultraschallsensoren an Front, Heck und den Fahrzeugflanken
- Vier Umgebungskameras an Front, Heck und den Außenspiegeln
- Vier Mittelbereichsradare an den Fahrzeugflanken
- Eine Frontkamera am oberen Rand der Windschutzscheibe
- Einen Fernbereichsradar an der Front
- Einen Laserscanner an der Front
- Eine Infrarotkamera an der Front




Abbildung 3.1: Sensortopologie des Audi A8 [75]

Welche Sensortypen im Audi A8 zum Einsatz kommen ist in der Literatur nicht beschrieben. Ebenso finden sich keine Aussagen hinsichtlich der Einbaupositionen der einzelnen Sensoren. Aus diesem Grund müssen Annahmen bezüglich der Sensortopologie getroffen werden. Für die Modellierung der Sensorabdeckung wird das Ego-Fahrzeug vereinfachend durch einen Quader mit den Maßen 5300x2000x1500 mm beschrieben und die Einbaupositionen der Sensoren anhand der Abmessungen des Audi A8 geschätzt, die in (Abbildung 3.2) dargestellt sind.




Abbildung 3.2: Abmessungen des Audi A8 [76]

Die geschätzten Einbaupositionen sind in (Tabelle 3.1) zusammengefasst und beziehen sich auf ein festgelegtes Koordinatensystem, dessen Ursprung sich an der Fahrzeugfront auf der Fahrzeuglängsachse auf Höhe der Fahrbahn befindet. Die X-Achse zeigt in Fahrtrichtung, die Y-Achse zeigt in Fahrtrichtung nach links und die Z-Achse zeigt in Fahrtrichtung nach oben. Die Infrarotkamera wird im Rahmen der vorliegenden Arbeit nicht betrachtet.

Tabelle 3.1: Positionen der Sensoren des Audi A8

#	Sensor-technologie	Position	Position in X (in m)	Position in Y (in m)	Position in Z (in m)
1	LRR	Front	0	-0.7	0.5
2	Lidar	Front	0	0	0.3
3	(Front-)Kamera	Obere Windschutzscheibe	-2.0	0	1.3
4	Kamera	Front	0	0	0.6
5	Kamera	Heck	-5.3	0	0.9
6	Kamera	Außenspiegel rechts	-1.9	-1.1	1.0
7	Kamera	Außenspiegel links	-1.9	1.1	1.0
8	MRR	Frontflanke rechts	-0.4	-1.0	0.6
9	MRR	Frontflanke links	-0.4	1.0	0.6
10	MRR	Heckflanke rechts	-5.2	-1.0	0.6
11	MRR	Heckflanke links	-5.2	1.0	0.6
12	Ultraschall	Frontflanke rechts	-0.6	-1.0	0.6
13	Ultraschall	Frontflanke links	-0.6	1.0	0.6
14	Ultraschall	Heckflanke rechts	-4.5	-1.0	0.6
15	Ultraschall	Heckflanke links	-4.5	1.0	0.6
16	Ultraschall	Front	0	-0.2	0.4
17	Ultraschall	Front	0	0.2	0.4
18	Ultraschall	Frontecke rechts	0	-1.0	0.6
19	Ultraschall	Frontecke links	0	1.0	0.6
20	Ultraschall	Heck	-5.3	-0.2	0.6
21	Ultraschall	Heck	-5.3	0.2	0.6
22	Ultraschall	Heckecke rechts	-5.3	-1.0	0.6
23	Ultraschall	Heckecke links	-5.3	1.0	0.6

### 3.2.2 Sensoreigenschaften

Für den Einsatz im Fahrzeug existiert eine Vielzahl umgebungserfassender Sensortypen mehrerer Hersteller. In (Tabelle 3.2) sind einige Ausführungsbeispiele für Mittelbereichs- und Fernbereichsradarsensoren dargestellt. (Tabelle 3.3) zeigt einige Ausführungsbeispiele für Ultraschall-, Lidar- und Kamerasensoren. In den Tabellen werden nur die für diese Arbeit relevanten Sensoreigenschaften dargestellt, die auf [26] und den jeweiligen Produktdatenblättern basieren.

Bei den Radarsensoren wird die ausgesendete Leistung meist als sog. EIRP angegeben. Diese bezeichnet die äquivalente isotrope Strahlungsleistung (engl. Equivalent Isotropically Radiated Power) und multipliziert die in die Sendeantenne eingespeiste Leistung  $P_t$  mit deren Antennengewinn  $G_t$ :

$$EIRP = P_t * G_t . \quad (3.1)$$

Tabelle 3.2: Ausführungsbeispiele für Mittel- und Fernbereichsradarsensoren

	Bosch LRR 4	Bosch LRR 3	Continental ASR 300	Bosch MRR Rear	Continental SRR 200
	2015	2009	2009	2014	2012
Signaleigenschaften					
Frequenz	76-77 GHz	76-77 GHz	76-77GHz	76-77GHz	24 GHz
Zyklusdauer	60 ms	80 ms	66 ms	60 ms	38 ms
Pulsdauer			16 $\mu$ s		9 $\mu$ s
Ausgesendete Leistung	<29 dBm (EIRP)	33 dBm (EIRP)	3 mW (Avg.)	<18 dBm (EIRP)	12.7 dBm (EIRP)
Detektionseigenschaften					
Entfernungsbereich	0.36-250 m	0.5-250 m	0.25-200 m	0.36-80 m	0.3-100 m
Messbereich Azimuth	12° (200 m) 20° (100 m) 30° (30 m)	12° (200 m) 20° (100 m) 30° (30 m)	17° (200 m) 56° (60 m)	150°	80° (100 m) 150° (50 m)
Messbereich Elevation	5°	4.5°	4.3°	13°	12°
Quellen	[26], [77]	[26], [78]	[26], [79]	[26], [80]	[26], [81]

Tabelle 3.3: Ausführungsbeispiele für Ultraschall-, Lidar- und Kamerasensoren

	Bosch Ultra- schallsensor	Valeo Scala Laserscanner	Continental Lidar AIS 200	Bosch Nahkamera	Bosch Multikamera
	2018	2017		2017	2017
Signaleigenschaften					
Frequenz/ Wellenlänge	40 kHz	905 nm	905 nm		
Zyklusdauer					
Pulsdauer					
Ausgesendete Leistung		75 W (Peak) 6 W (Avg.)	40 W (Peak) 4 mW (Avg.)		

Detektionseigenschaften					
Entfernungsbereich	0.15-5.5 m	0.3–150 m	1-180 m		120 m
Auflösung				1600x1280	1280x960
Bilder pro s					30
Messbereich Azimuth	70°	145°	30°	137°	50°
Messbereich Elevation	35°	3.2°	6.5°	94°	28°
Quellen	[82]	[26], [83]	[26]	[84]	[85]

Wie in Kapitel 3.2.1 bereits erwähnt, wird in der Literatur nicht beschrieben welche Sensortypen im Audi A8 verwendet werden. Für die Modellierung der Sensoren müssen aus diesem Grund Annahmen bezüglich der Sensoreigenschaften der jeweiligen Sensortechnologie getroffen werden. Die festgelegten Sensoreigenschaften sind in (Tabelle 3.4) zusammengefasst.

Der Fernbereichsradar basiert auf dem Bosch LRR 3, der Mittelbereichsradar auf dem Continental SRR 200, weil für diese Radarsensoren die entsprechenden Antennendiagramme aus der Literatur vorliegen. Der Antennengewinn der Radarsensoren wird auf Basis der Untersuchungen in [86] auf 20 dB festgelegt.

Der Ultraschallsensor basiert auf dem Bosch Ultraschallsensor. Dessen Antennengewinn wird auf Basis von [41, S. 127] auf 10 dB festgelegt. Die ausgesendete Leistung und die Pulsdauer des Ultraschallsensors werden auf die Werte des Mittelbereichsradars festgelegt.

Der Lidarsensor basiert auf dem von Valeo entwickelten Scala-Laserscanner, weil dieser im Audi A8 zum Einsatz kommt [15, S. 34]. Die Pulsdauer des Lidarsensors wird auf Basis von [43, S. 4] auf 10 ns festgelegt. Die Empfängerfläche des Lidarsensors wird ausgehend von den Abmessungen des Valeo Laserscanners abgeschätzt.

Tabelle 3.4: Sensoreigenschaften der Sensormodelle

	LRR	MRR	Ultraschall	Lidar	Kamera Nah	Kamera Fern
Signaleigenschaften						
Frequenz/ Wellenlänge	76.5e9 Hz 3.9e-3 m	24e9 Hz 1.2e-2 m	40 e3 Hz 8.6e-3 m	3.3e14 Hz 905e-9 m	5.5e14 Hz 550e-9 m	5.5e14 Hz 550e-9 m
Pulsdauer	16 µs	9 µs	10 µs	10 ns		
Ausgesendete Leistung	0.02 W	0.0002 W	0.0002 W	75 W		
Antennengewinn	20 dB	20 dB	10 dB			

Detektionseigenschaften						
Entfernungsbereich	0.5-250 m	0.3-100 m	0.15-5.5 m	0.3-150 m	60 m	120 m
Messbereich Azimuth	30°	150°	70°	145°	137°	50°
Messbereich Elevation	5°	12°	35°	3.2°	94°	28°
Empfängereigenschaften						
Integrationszeit					0.01 s	0.01 s
Empfängerfläche/ -durchmesser				0.002 m <sup>2</sup>	0.01m	0.01m

Die Kamerasensoren basieren auf den Bosch Kamerasensoren. Deren Wellenlänge wird auf den Mittelwert des sichtbaren elektromagnetischen Spektrums von 550 nm festgelegt [58, S. 2]. Die Reichweite des Nahbereichskamerasensors wird auf Basis der von Tesla verwendeten Weitwinkelkamerasensoren auf 60 m festgelegt [87]. Der Linsendurchmesser der Empfangsoptik der Kamera-sensoren wird ausgehend von den Abmessungen der Bosch Kamerasensoren abgeschätzt. Die Integrationszeit der Kamerasensoren wird unter Berücksichtigung mechanischer Verschlusszeiten aus der Bildrate der Bosch Kamerasensoren abgeleitet.

### 3.2.3 Antennencharakteristik

Die Antennencharakteristik beschreibt die Abhängigkeit des Antennengewinns der in Radar- und Ultraschallsensoren zum Einsatz kommenden Antennen von Azimuth  $\phi$  und Elevation  $\psi$ . Die Abhängigkeit bezieht sich auf einzelne Strahlenkeulen. Weil in Radar- und Ultraschallsensoren mehrere überlappende Einzelstrahler verwendet werden, ergibt sich deren Strahlungsleistung über den gesamten Detektionsbereich aus den entsprechenden Antennendiagrammen. (Abbildung 3.3) zeigt das zugrundeliegende Antennendiagramm für den Fernbereichsradar, (Abbildung 3.4) das zugrundeliegende Antennendiagramm für den Mittelbereichsradar. Für den Bosch Ultraschallsensor liegt kein Antennendiagramm vor, weshalb für den Ultraschallsensor alternativ das Antennendiagramm des ProWave 400PT160 angenommen wird [88].

Für die Modellierung der Antennencharakteristik der Sensoren werden nur die Hauptkeulen betrachtet, weil die geringe Intensität der Nebenkeulen für die Erfassung von Objekten nicht relevant ist [18, S. 39]. Zur Vereinfachung wird die Leistungsverteilung durch die in (Abbildung 3.3) und (Abbildung 3.4) eingezeichneten Polynome angenähert, die in (Tabelle 3.5) dargelegt sind. Für die Abhängigkeit der Sensorstrahlenkeulen in Elevation finden sich in der Literatur keine Angaben, weshalb diese im Rahmen der vorliegenden Arbeit nicht berücksichtigt wird. Weil die Messbereiche der Sensoren in Elevation kleiner ausfallen ist diese Annahme zulässig.

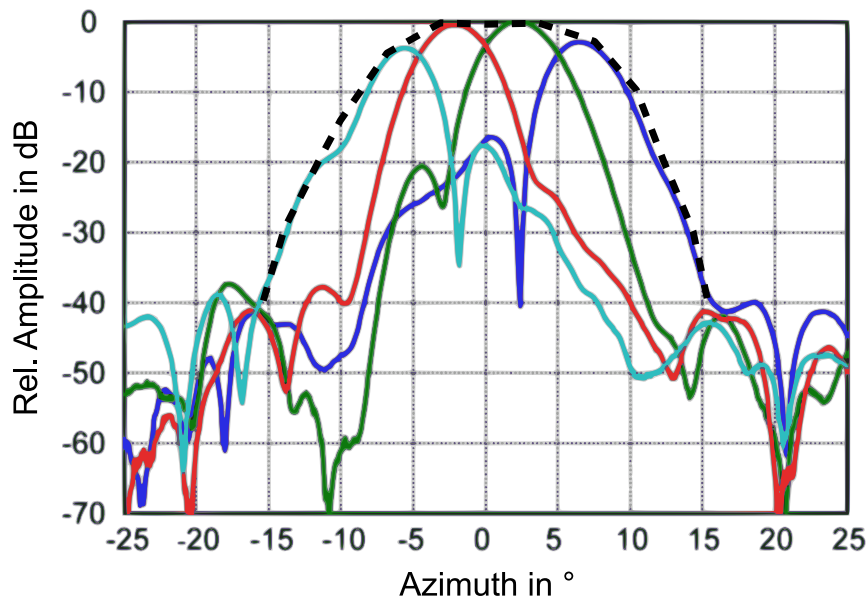


Abbildung 3.3: Antennendiagramm des Bosch LRR 3 [35, S. 2378]

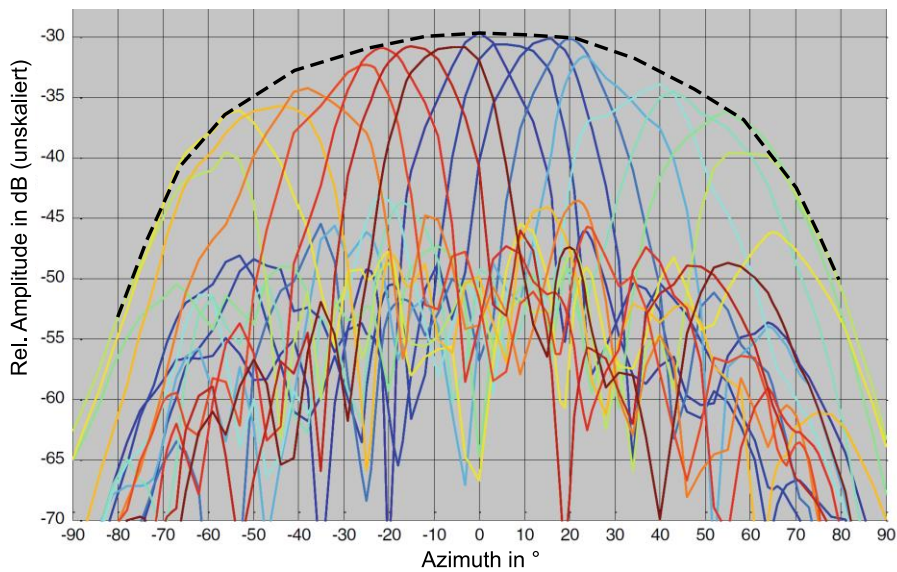


Abbildung 3.4: Antennendiagramm des Continental SRR 200 [26, S. 307]

Tabelle 3.5: Polynome der angenäherten Leistungsverteilung

	LRR	MRR	Ultraschall
Abh. Antennengewinn in Azimuth	-1.277e-04*x^4 -1.634e-19*x^3 -0.02702*x^2 +5.569e-17*x +0.1166	-4.062e-07*x^4 -1.228e-21*x^3 -0.001023*x^2 +1.893e-17*x -0.5339	-1.613e-06*x^4 -9.812e-20*x^3 -0.01031*x^2 +9.757e-17*x -0.09812
Abh. Antennengewinn in Elevation	nicht berücksichtigt	nicht berücksichtigt	nicht berücksichtigt



Die von Lidarsensoren ausgesendeten Laserstrahlen sind stark gebündelt, so dass diese eine konstante Leistungsverteilung aufweisen, d.h. keine Abhängigkeit von Azimuth  $\phi$  und Elevation  $\psi$ . Durch die Verwendung von Laserscannern mit kurzen Zykluszeiten kann aus diesem Grund eine konstante Leistungsverteilung über den gesamten Detektionsbereich des Lidarsensors angenommen werden.

### 3.2.4 Rückstreuquerschnitte

Maßgeblichen Einfluss auf die Umfelderfassung haben die sich im Fahrzeugumfeld befindlichen Objekte. Ihre Eigenschaften bestimmen welcher Anteil an ausgesendeter Strahlungsleistung vom Objekt reflektiert wird, welcher Anteil vom Objekt absorbiert wird und welcher Anteil vom Objekt durchgelassen wird. Nur der reflektierte Anteil an ausgesendeter Strahlungsleistung kann vom Sensor wieder empfangen werden [47, S. 2]. Die ausgesendeten Signale können auf unterschiedliche Weise reflektiert werden, abhängig von den Signaleigenschaften und dem Reflexionsfaktor der Objektoberfläche [18, S. 24-25]. (Abbildung 3.5) zeigt die verschiedenen Arten der Reflexion.




Abbildung 3.5: Vergleich verschiedener Reflexionsarten

Die diffuse Reflexion wird durch das Lambert'sche Gesetz beschrieben, d.h. die Wellenlänge des ausgesendeten Signals ist viel kleiner als die Rauigkeit der Objektoberfläche und das ausgesendete Signal wird gleichmäßig kreisförmig reflektiert. Die gestreute gerichtete Reflexion stellt eine Form der diffusen Reflexion dar, bei der das Objekt hinreichend viele Streuzentren aufweist und das ausgesendete Signal unabhängig vom Einstrahlwinkel hauptsächlich senkrecht zur Objektoberfläche reflektiert wird [18, S. 25]. Im Gegensatz zur diffusen Reflexion wird ein ausgesendetes Signal an einer spiegelnden Oberfläche gerichtet reflektiert. Die gerichtete Reflexion wird durch das Reflexionsgesetz beschrieben, d.h. das ausgesendete Signal wird unter gleichem Winkel reflektiert [18, S. 27]. Eine besondere Variante spiegelnder Oberflächen sind Retroreflektoren, die durch eine spezielle Oberflächenstruktur ein ausgesendetes Signal immer in die gleiche Richtung reflektieren [18, S. 28].

Im realen Reflexionsvorgang treten alle Arten der Reflexion auf, abhängig von den Signaleigenschaften, von der Geometrie der Objekte und von den Materialeigenschaften der Objekte. Aus diesem Grund müssen Annahmen getroffen werden, um den Reflexionsvorgang einheitlich beschreiben zu können. Bei der Herleitung der Sensorgleichungen wird vereinfachend angenommen, dass die ausgesendete Strahlungsleistung von den Objekten aufgenommen wird und wieder isotrop reflektiert wird. Um innerhalb dieser Vereinfachung die realen Reflexionsvorgänge zu berücksichtigen, müssen Rückstreuquerschnitte verschiedener Objekte festgelegt werden, die die Objektfläche unter Berücksichtigung des Reflexionsfaktors der Objektoberfläche beschreiben. Objekte werden durch mehr als einen Rückstreuquerschnitt charakterisiert,

abhängig von deren Orientierung und der Lage derer Streuzentren [89, S. 848]. (Abbildung 3.6) zeigt beispielhaft die Radar-Rückstreuquerschnitte eines PKW. In der Literatur finden sich für verschiedene Objekte des Verkehrsgeschehens Werte für deren Radar-Rückstreuquerschnitte. Weil die Sende- und Empfangscharakteristiken von Radar- und Ultraschallsensoren sehr ähnlich sind, können die Werte der Radar-Rückstreuquerschnitte ebenfalls für Ultraschallsensoren angenommen werden [41, S. 127]. Weil die hergeleiteten Sensorgleichungen der anderen Sensortechnologien auf den Annahmen der Radargleichung beruhen, werden für diese ebenfalls die Werte der Radar-Rückstreuquerschnitte angenommen. Diese Annahme ist nicht ganz korrekt, wie folgendes Beispiel zeigt: Bei schwarzen Objekten werden Laserstrahlen stärker absorbiert als bei anders farbigen Objekten, wodurch die Rückstreuquerschnitte von schwarzen Objekten für Lidarsensoren im Verhältnis zu den Rückstreuquerschnitten von schwarzen Objekten für Radarsensoren kleiner sind. Im Rahmen der vorliegenden Arbeit werden solche Effekte nicht berücksichtigt, wodurch die getroffene Annahme zulässig ist.




Abbildung 3.6: Rückstreuquerschnitte eines PKW [89, S. 848]

Zur Vereinfachung werden Objekte im Rahmen der vorliegenden Arbeit durch Quader beschrieben und deren Orientierung vernachlässigt, d.h. es wird ein konstanter Rückstreuquerschnitt angenommen. Die festgelegten Rückstreuquerschnitte für verschiedene Objekte sind in (Tabelle 3.6) zusammengefasst.

Tabelle 3.6: Rückstreuquerschnitte von Objekten im Straßenverkehr

	Mensch	Motorrad	PKW	LKW
Abmessungen	0.5x0.5x1.8 m	2.2x0.9x1.5 m	4.7x1.8x1.5 m	13.6x2.5x2.7 m
Rückstreuquerschnitt	0 dBsm 1 m <sup>2</sup>	10 dBsm 10 m <sup>2</sup>	20 dBsm 100 m <sup>2</sup>	23 dBsm 200 m <sup>2</sup>
Quellen	[90], [91]	[90], [91], [92],	[90], [91], [92]	[90], [91]

### 3.2.5 Wetterbedingungen

Die von umfelderfassenden Sensoren ausgesendeten Signale interagieren mit atmosphärischen Gasen wie H<sub>2</sub>O, CO<sub>2</sub>, O<sub>2</sub> und O<sub>3</sub>, sowie mit Partikeln in der Luft. In regnerischen oder nebligen Bedingungen werden die Signale zusätzlich an Wassertropfen gestreut [58, S. 1]. Dabei wird der Strahlung Energie entzogen, was zu einer Verringerung der Sensorzuverlässigkeit führt [58, S. 2]. Aus diesem Grund müssen Annahmen zur Modellierung der atmosphärischen Dämpfung bei verschiedenen Witterungsbedingungen getroffen werden. In [58] werden dazu Berechnungen durchgeführt, um die atmosphärische Dämpfung als Funktion der Signalfrequenz darzustellen. (Abbildung 3.7) zeigt die Funktionen für verschiedene Witterungsbedingungen.

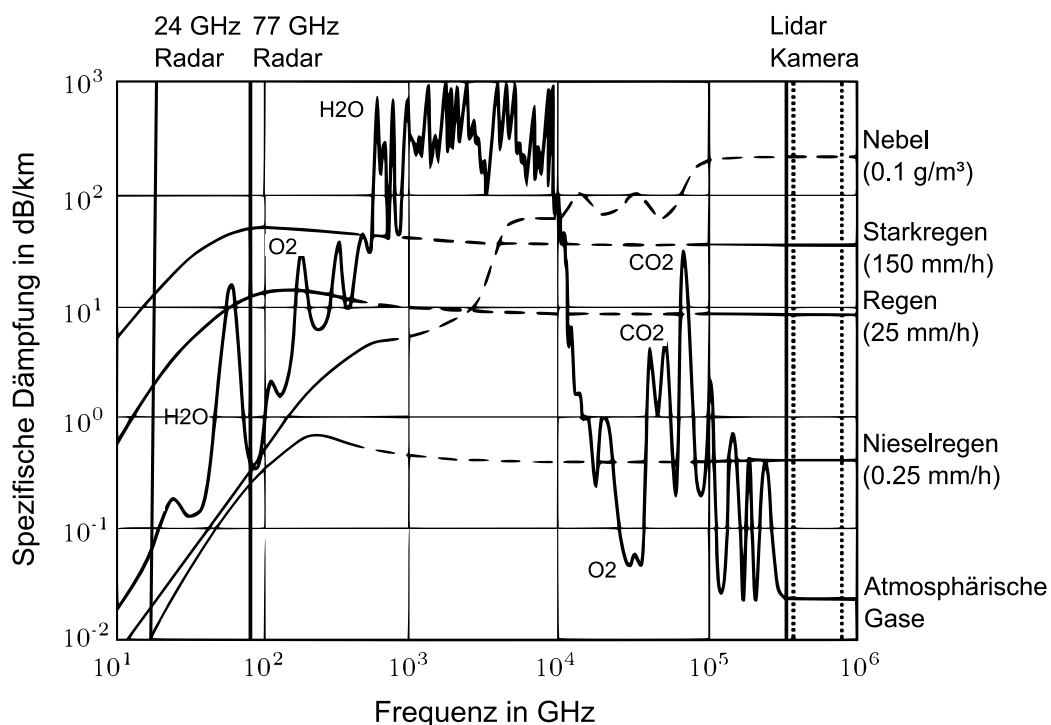


Abbildung 3.7: Spezifische Dämpfung für verschiedene Frequenzen bei unterschiedlichen Witterungsbedingungen [58, S. 6]

Die Bestimmung der spezifischen Dämpfung basiert auf drei Annahmen [58, S. 5]:

- Der Beitrag jedes Tropfens ist additiv und unabhängig von anderen Tropfen
- Die Tropfen sind kugelförmige Wassertropfen, die die ausgesendete Strahlung absorbieren und streuen
- Die Intensität der ausgesendeten Strahlung nimmt exponentiell ab, wenn sie sich durch das Volumen des Regens oder Nebels ausbreitet

Die spezifische Dämpfung durch atmosphärische Gase hängt stark von der Frequenz der ausgesendeten Signale ab. Bei regnerischen Bedingungen steigt die spezifische Dämpfung bis zu einer Frequenz von ca. 100 GHz an und bleibt dann nahezu konstant. Bei nebligen Bedingungen steigt die spezifische Dämpfung mit zunehmender Frequenz an und erreicht im nahen Infrarot und optischen Bereich Werte von über 100 dB/km. Die spezifische Dämpfung von Ultraschall hängt stark von der Luftfeuchtigkeit ab und liegt im Bereich zwischen 0.46 dB/m bis 1.3 dB/m [41, S. 128]. Die spezifische Dämpfung für Ultraschall ist deutlich größer als für Signale höherer Frequenzen und wird auf 1 dB/m festgelegt [93, S. 14]. Diese Vereinfachung bedeutet eine

Wetterunabhängigkeit der Ultraschallsensoren, die aufgrund ihrer geringen Reichweite zulässig ist. Für die spezifische Dämpfung der jeweiligen Sensortechnologien bei verschiedenen Witterungsbedingungen ergeben sich die in (Tabelle 3.7) festgelegten Werte.

Tabelle 3.7: Spezifische Dämpfung verschiedener Sensoren bei unterschiedlichen Witterungsbedingungen

	LRR	MRR	Ultraschall	Lidar	Kamera
Sonne/Nacht	0.4 dB/km	0.1 dB/km	1000 dB/km	0.03 dB/km	0.03 dB/km
Regen	30.4 dB/km	10.1 dB/km	1000 dB/km	20.03 dB/km	20.03 dB/km
Starkregen	70.4 dB/km	50.1 dB/km	1000 dB/km	50.03 dB/km	50.03 dB/km
Nebel	0.7 dB/km	0.13 dB/km	1000 dB/km	140.03 dB/km	140.03 dB/km

Die spezifische Dämpfung muss bei der Modellierung der Sensoren doppelt berücksichtigt werden, weil das ausgesendete, reflektierte und empfangene Signal die Entfernung zum Objekt zweimal zurücklegen muss. Bei Kamerasensoren werden nur die von Objekten ausgesendeten Lichtstrahlen empfangen. Welche Strahlungsleistung von den Objekten ausgesendet wird hängt von der Intensität der Sonnenstrahlung ab, die je nach Witterungsbedingung variiert [94]. Die angenommenen Werte der Leistungsdichte der Sonnenstrahlung sind in (Tabelle 3.8) zusammengefasst. Bei Nacht liegt der eigentliche Wert der Leistungsdichte der Sonnenstrahlung bei 0 W/m<sup>2</sup>. Durch den angenommenen Wert von 50 W/m<sup>2</sup> wird die Ausleuchtung des Umfelds durch andere Lichtquellen beachtet. Die direkte Beleuchtung der Objekte durch die Fahrzeugscheinwerfer wird im Rahmen der vorliegenden Arbeit nicht berücksichtigt.

Tabelle 3.8: Leistungsdichte der Sonnenstrahlung bei verschiedenen Witterungsbedingungen

	Sonne	Nacht	Regen	Starkregen	Nebel
Leistungsdichte der Sonnenstrahlung	1000 W/m <sup>2</sup>	50 W/m <sup>2</sup>	300 W/m <sup>2</sup>	100 W/m <sup>2</sup>	100 W/m <sup>2</sup>

### 3.2.6 Receiver Operating Characteristics

Anhand der getroffenen Annahmen lassen sich unter Verwendung der in Kapitel 2.3 hergeleiteten Signal-Rausch-Verhältnisse SNR-Werte der modellierten Sensoren in Abhängigkeit der Objektposition für verschiedene Objekte und Wetterbedingungen berechnen. Ein hoher SNR-Wert deutet auf eine vertrauenswürdige Messung hin, während ein niedriger SNR-Wert die Messung fragwürdig macht [42, S. 208]. Bezieht man diese Aussage auf die Detektionswahrscheinlichkeit von Objekten, so bedeutet ein höherer SNR-Wert innerhalb gewisser Grenzen eine höhere Detektionswahrscheinlichkeit. Die Grenzen werden durch einen unteren Schwellwert und einen oberen Grenzwert festgelegt [19, S. 74]. Unterhalb des Schwellwerts werden Objekte nicht erkannt, oberhalb des Grenzwerts werden Objekte immer erkannt. Um bei der Modellierung der Sensorabdeckung eine genaue Aussage treffen zu können welcher SNR-Wert für welche Detektionswahrscheinlichkeit steht, müssen Annahmen getroffen werden.

Einen Ansatz liefert die Albersheimgleichung, die den benötigten SNR-Wert berechnet, der erforderlich ist, um eine festgelegte Detektionswahrscheinlichkeit  $p_D$  bei einer gewissen Fehlalarmquote  $p_{FA}$  zu erreichen. Die Albersheimgleichung gilt für einen linearen Detektor und

kann auf die Integration von  $N$  Abtastwerten erweitert werden. Die Albersheimgleichung berechnet sich nach

$$\text{SNR} = -5 * \log_{10} * N + \left( \frac{6.2 + 4.54}{\sqrt{N + 0.44}} \right) * \log_{10}(A + 0.12 * A * B + 1.7 * B) \quad (3.2)$$

, wobei  $A = \ln \frac{0.62}{p_{FA}}$  und  $B = \ln \frac{p_D}{1-p_D}$  [95].

Sog. ROC-Kurven (engl. Receiver Operating Characteristics) fassen die Leistung eines Detektors grafisch zusammen [96]. Anhand der Albersheimgleichung ergeben sich ROC-Kurven, die die Detektionswahrscheinlichkeit über dem erforderlichen SNR-Wert darstellen, wie (Abbildung 3.8) zeigt.

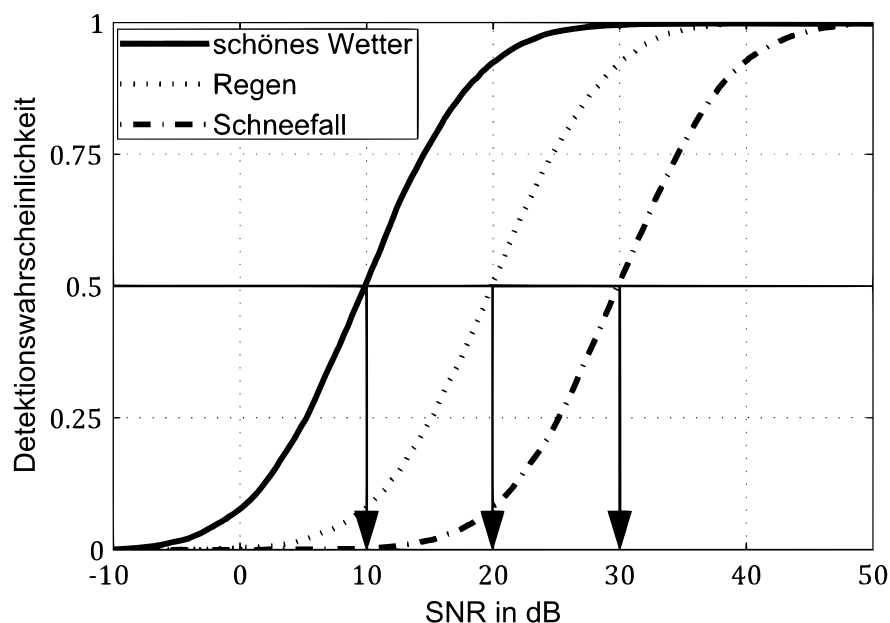


Abbildung 3.8: Erforderliche SNR-Werte bei unterschiedlichen Witterungsbedingungen [97, S. 7]

Für eine Detektionswahrscheinlichkeit von 50% bei einer niedrigen Fehlalarmquote wird in der Literatur ein erforderlicher SNR-Wert von 10 dB angegeben [89, S. 848], der in realen Sensoren adaptiv an die aktuelle Rauschsituation angepasst wird [97, S. 6]. Weil im Rahmen der vorliegenden Arbeit die Methodik zur Definition von Worst-Case Szenarien erarbeitet wird, wird diese Anpassung zur Vereinfachung nicht berücksichtigt und die in (Abbildung 3.8) dargestellte ROC-Kurve für Regen zum Übertrag der SNR-Werte auf die Detektionswahrscheinlichkeiten verwendet.

### 3.3 Modellaufbau

Die Modellierung der Sensorabdeckung autonomer Fahrzeuge, sowie die Berechnung optimaler Annäherungspfade an diese wird im Rahmen der vorliegenden Arbeit in MATLAB umgesetzt, wofür ein Berechnungsmodell entwickelt wurde. Das Berechnungsmodell gliedert sich in vier wesentliche Teile: die Definition der Randbedingungen, die Modellierung der Sensorabdeckung, die Berechnung optimaler Annäherungspfade und die Visualisierung der Ergebnisse. (Abbildung 3.9) zeigt schematisch den Aufbau des entwickelten Berechnungsmodells.




Abbildung 3.9: Schematischer Aufbau des Berechnungsmodells

Die in (Abbildung 3.9) grau dargestellten Blöcke stellen die Randbedingungen dar und sind in MATLAB durch verschiedene Klassen definiert. `EnvironmentCondition` enthält alle festgelegten Annahmen bezüglich der Wetterbedingungen. Hierbei sind verschiedene Witterungsbedingungen berücksichtigt: Sonne, Nacht, Regen, Starkregen und Nebel. `DetectionObject` enthält alle festgelegten Annahmen bezüglich der Rückstreuquerschnitte und Abmessungen der Objekte. Als Objekte sind hierbei definiert: Mensch, Motorrad, PKW und LKW. Zusätzlich können Faktoren für die Rückstreuquerschnitte definiert werden, die Besonderheiten bei der Interaktion zwischen Sensor und Objekt berücksichtigen. Dies sind beispielsweise die verminderte reflektierte Strahlungsleistung von Lidarsensoren, durch die höhere Absorption der Laserstrahlen bei schwarzen Objekten oder die verminderte Detektionswahrscheinlichkeit von Kamerasensoren bei geringen Kontrastunterschieden zwischen Objekt und Umgebung. Weil diese Besonderheiten stark von den Objekteigenschaften und Wetterbedingungen abhängen, sind nur vage Aussagen möglich. Aus diesem Grund werden die Faktoren der Rückstreuquerschnitte im Rahmen der vorliegenden Arbeit nicht berücksichtigt. `RadarSensorModelLRR`, `RadarSensorModelMRR`, `LidarSensorModel`, `CameraSensorModel` und `SonicSensorModel` enthalten alle festgelegten Annahmen bezüglich der Sensoreigenschaften und

Antennencharakteristik der entsprechenden Sensortechnologie. Ebenso kann die Lage der Sensoren definiert werden, wodurch die Sensortopologie festgelegt wird. `CameraSensorModel` ermöglicht zusätzlich die Definition von direkter Sonneneinstrahlung in den Kamerasensor, um eine Blendung dessen berücksichtigen zu können.

```
Object = DetectionObject('Type', 'Human');
Condition = EnvironmentCondition('Condition', 'Sunny');

Sensor{1} = RadarSensorModelLRR('Type', 'LRR', 'xLoc', 0, 'yLoc', 0.7, 'zLoc', 0.5,
    'Roll', 0, 'Pitch', 0, 'Yaw', 0);
Sensor{2} = LidarSensorModel('Type', 'Lidar', 'xLoc', 0, 'yLoc', 0, 'zLoc', 0.3,
    'Roll', 0, 'Pitch', 0, 'Yaw', 0);
Sensor{3} = CameraSensorModel('Type', 'Camera', 'Blinding', 'no', 'MaxRange', 120,
    'xImageSize', 960, 'yImageSize', 1280,
    'Azimuth', 50, 'Elevation', 28,
    'xLoc', -2.0, 'yLoc', 0, 'zLoc', 1.3,
    'Roll', 0, 'Pitch', 0, 'Yaw', 0);
Sensor{4} = RadarSensorModelMRR('Type', 'MRR', 'xLoc', -0.4, 'yLoc', -1.0, 'zLoc', 0.6,
    'Roll', 0, 'Pitch', 0, 'Yaw', -75);
Sensor{5} = SonicSensorModel('Type', 'Sonic', 'xLoc', -0.6, 'yLoc', 1.0, 'zLoc', 0.6,
    'Roll', 0, 'Pitch', 0, 'Yaw', -90);
```

Pseudocode zur Definition der Randbedingungen

Die in (Abbildung 3.9) blau dargestellten Blöcke stellen die Modellierung der Sensorabdeckung dar, die in MATLAB durch verschiedene Funktionen umgesetzt ist. Die definierten Randbedingungen dienen als Eingabewerte. In `calculateSNRradar`, `calculateSNRlidar`, `calculateSNRcamera`, und `calculateSNRsonic` werden die SNR-Werte der entsprechenden Sensoren anhand der hergeleiteten Signal-Rausch-Verhältnisse berechnet (Gl. (2.14), Gl. (2.19), Gl. (2.26), Gl. (2.36)). Dazu werden zunächst die in Kugelkoordinaten angegebenen Erfassungsbereiche der Sensoren (Reichweite, Azimuth und Elevation) in Abhängigkeit ihrer definierten Lage in kartesische Koordinaten ( $x$ ,  $y$  und  $z$ ) umgewandelt, wodurch für jeden Sensor drei mehrdimensionale  $m \times n \times p$  Matrizen für  $x$ ,  $y$  und  $z$  entstehen, die zusammen dessen Detektionsbereich beschreiben. Die Größe der Matrizen ist abhängig von den Erfassungsbereichen der Sensoren und den festzulegenden Schrittweiten für Reichweite, Azimuth und Elevation. Gleichzeitig werden entsprechend der Sensortechnologie der Sensoren und den festgelegten Randbedingungen die SNR-Werte anhand der hergeleiteten Signal-Rausch-Verhältnisse berechnet. In Abhängigkeit der festzulegenden Schrittweiten ergibt sich für jeden Sensor wiederum eine  $m \times n \times p$  Matrix, die dessen Signal-Rausch-Verhältnis in Abhängigkeit von Reichweite, Azimuth und Elevation beschreibt.

```
for n = 1:length(Sensor)
    [LookUP(n).x, LookUP(n).y, LookUP(n).z] = transformSensorCoordinates(Sensor,
        Increment, n);
    if strcmp(Sensor{n}.Type, 'LRR') == 1
        LookUP(n).SNR = calculateSNRradar(Sensor, Object, Condition, Increment, n);
    elseif strcmp(Sensor{n}.Type, 'MRR') == 1
        LookUP(n).SNR = calculateSNRradar(Sensor, Object, Condition, Increment, n);
    elseif strcmp(Sensor{n}.Type, 'Lidar') == 1
        LookUP(n).SNR = calculateSNRlidar(Sensor, Object, Condition, Increment, n);
    elseif strcmp(Sensor{n}.Type, 'Camera') == 1
        LookUP(n).SNR = calculateSNRcamera(Sensor, Object, Condition, Increment, n);
    elseif strcmp(Sensor{n}.Type, 'Sonic') == 1
        LookUP(n).SNR = calculateSNRsonic(Sensor, Object, Condition, Increment, n);
    end
end
```

Pseudocode zur Berechnung der Signal-Rausch-Verhältnisse

Im nächsten Schritt wird ein Gitter mit einer festzulegenden Schrittweite in der  $xy$ -Ebene definiert, das eine Schnittebene in der Höhe  $z$  darstellt und die Genauigkeit der Modellierung der Sensorabdeckung, sowie den betrachteten Bereich des Fahrzeugumfelds festlegt. Auf dieses Gitter werden die berechneten SNR-Werte anhand der Matrizen der kartesischen Koordinaten interpoliert. Dadurch ergibt sich für jeden Sensor eine  $m \times n$  Matrix, die dessen Signal-Rausch-Verhältnis in Abhängigkeit von  $x$  und  $y$  in einer bestimmten Höhe  $z$  beschreibt. Dieses Vorgehen ist notwendig, um die SNR-Werte in kartesischen Koordinaten darstellen zu können und die Fusion mehrerer überlappender Sensoren zu ermöglichen. Für die Berechnung der SNR-Werte in Abhängigkeit von  $x$ ,  $y$  und  $z$  kann ein 3D-Gitter definiert werden. Im Rahmen der vorliegenden Arbeit werden die SNR-Werte nur in Abhängigkeit von  $x$  und  $y$  für eine bestimmte Höhe  $z$  berechnet, um die benötigte Rechenzeit gering zu halten. Außerdem wird die Strahlungsleistung der Sensoren in Elevation als konstant angenommen (Kapitel 0), d.h. die SNR-Werte sind in Richtung der  $z$ -Achse konstant. Abhängig von der Höhe  $z$  der Schnittebene ändert sich nur der vom Sensor abgedeckte Bereich in der  $xy$ -Ebene. Die Höhe  $z$  kann entsprechend der durchzuführenden Untersuchung angepasst werden. In `calculatePDsensor` ist die angenommene ROC-Kurve hinterlegt, d.h. jeder berechnete SNR-Wert eines Sensors wird in eine Detektionswahrscheinlichkeit übertragen. Dadurch ergibt sich für jeden Sensor eine  $m \times n$  Matrix, die die Detektionswahrscheinlichkeit eines Objekts bei bestimmten Wetterbedingungen in Abhängigkeit von  $x$  und  $y$  in einer bestimmten Höhe  $z$  beschreibt. In `calculatePDFusion` werden schließlich die Detektionswahrscheinlichkeiten der einzelnen Sensoren nach Gl. (2.43) fusioniert. Dadurch ergibt sich eine  $m \times n$  Matrix, die die fusionierte Detektionswahrscheinlichkeit eines Objekts aller Sensoren bei bestimmten Wetterbedingungen in Abhängigkeit von  $x$  und  $y$  in einer bestimmten Höhe  $z$  beschreibt. Diese Matrix stellt das Ergebnis der Modellierung der Sensorabdeckung autonomer Fahrzeuge dar und dient als Grundlage für die Berechnung optimaler Annäherungspfade.

```
[xq, yq, zq] = meshgrid(FieldX(1):Increment:FieldX(2), FieldY(1):Increment:FieldY(2),
    Plane);
for n = 1:length(Sensor)
    LookUP(n).SNRq = griddata(LookUP(n).x, LookUP(n).y, LookUP(n).z, LookUP(n).SNR,
        xq, yq, zq, 'linear');

    LookUP(n).PD = calculatePDsensor(Sensor, LookUP, xq, yq, zq);
End
PDFusion = calculatePDFusion(Sensor, LookUP, xq, yq, zq);
```

Pseudocode zur Berechnung der fusionierten Detektionswahrscheinlichkeiten

Die in (Abbildung 3.9) orange dargestellten Blöcke stellen die Berechnung optimaler Annäherungspfade dar, die in MATLAB durch verschiedene Funktionen umgesetzt ist. Zu definierende Startbedingungen und die berechneten fusionierten Detektionswahrscheinlichkeiten dienen als Eingabewerte. Die fusionierten Detektionswahrscheinlichkeiten liegen als  $m \times n$  Matrix in einer bestimmten Höhe  $z$  vor. Die Berechnung optimaler Annäherungspfade findet somit zweidimensional auf einer  $xy$  Ebene statt. Auf dieser Ebene werden die Startbedingungen in Form von einem Startpunkt, einem Endpunkt und einer Anzahl an Pfadpunkten festgelegt. Der Startpunkt kann frei gewählt werden, der Endpunkt wird auf das Ego-Fahrzeug gelegt. Die festgelegte Anzahl an Pfadpunkten wird zunächst gleichmäßig entlang einer geraden Linie zwischen Start- und Endpunkt verteilt. In `PointsToCurve` werden die Pfadpunkte zu einem Annäherungspfad verbunden. Dazu wird jeweils zwischen zwei Pfadpunkten linear interpoliert und eine gewisse Anzahl an Berechnungspunkten zwischen die Pfadpunkte gelegt. Die Anzahl an Berechnungspunkten wird adaptiv angepasst, so dass sich alle 0,5 m entlang des Pfads ein Berechnungspunkt befindet. Die 0,5 m sind deshalb gewählt, weil sie der kleinsten Abmessung der definierten



Objekte (Mensch) entsprechen. Jeder Berechnungspunkt besitzt eine entsprechende und eindeutige Position in  $x$  und  $y$ . In `calculatePathValue` wird jedem Berechnungspunkt die entsprechende fusionierte Detektionswahrscheinlichkeit zugeordnet und ein „Gesamtwert für die Bewertung eines Annäherungspfads“ anhand einer Kostenfunktion  $p_{D,value,path}$  berechnet. Die Kostenfunktion  $p_{D,value,path}$  ist folgendermaßen definiert:

$$p_{D,value,path} = \sum(p_{D,i} * dx_i) + \frac{\sum dx_i}{50}. \quad (3.3)$$

$p_{D,i}$  beschreibt hierbei die zugeordnete fusionierte Detektionswahrscheinlichkeit eines Berechnungspunkts,  $dx_i$  beschreibt den Abstand zwischen zwei Berechnungspunkten. Würde die Länge des Annäherungspfads nicht berücksichtigt werden, ergeben sich bei der Optimierung unrealistische Annäherungspfade, die beispielsweise zick-zack verlaufen. Um dies zu vermeiden berücksichtigt der erste Term von Gl. (3.3) die Länge des Annäherungspfads im Produkt  $p_{D,i} * dx_i$  im Erfassungsbereich der Sensoren. Außerhalb des Erfassungsbereichs der Sensoren, d.h. die fusionierte Detektionswahrscheinlichkeit ist gleich 0, kann der Annäherungspfad weiterhin zick-zack verlaufen, weil hier das Produkt  $p_{D,i} * dx_i$  ebenfalls gleich 0 ist. Um dies zu vermeiden wird der zweite Term von Gl. (3.3) additiv hinzugefügt. Bei der Optimierung der Annäherungspfade wird versucht die Kostenfunktion  $p_{D,value,path}$  zu minimieren. Dazu werden die Positionen der Pfadpunkte iterativ variiert, wodurch sich auch die Positionen der Berechnungspunkte ändern und sich anhand der Kostenfunktion  $p_{D,value,path}$  ein neuer Gesamtwert für den Annäherungspfad berechnet. Ebenso ändert sich die Anzahl an Berechnungspunkten, weil zwischen zwei Pfadpunkten immer so viele Berechnungspunkte liegen müssen, dass sich alle 0,5 m entlang des Pfads ein Berechnungspunkt befindet. Dies ist notwendig, um die Länge des Annäherungspfads in der Optimierung berücksichtigt zu können. Die Positionen der Pfadpunkte werden so lange iterativ variiert bis sich anhand der Kostenfunktion  $p_{D,value,path}$  ein minimaler Gesamtwert für den Annäherungspfad einstellt. Dieser Annäherungspfad repräsentiert den optimalen Annäherungspfad eines Objekts an ein autonomes Fahrzeug bei bestimmten Wetterbedingungen und für einen festgelegten Startpunkt.

```
NumPathPoints = 15;
StartPoint = [300 50];
EndPoint = [0 0];

objectiveFun = @(P) calculatePathValue(P,PDFusion,StartPoint,EndPoint,FieldX,
    FieldY,'linear');
nonlcon = @egocarcon;

xWayPoints = linspace(StartPoint(1),EndPoint(1),NumPoints+2)';
yWayPoints = linspace(StartPoint(2),EndPoint(2), NumPoints +2)';
InitialPoints = [xWayPoints(2:end)';yWayPoints(2:end)'];

OptPathPoints = fmincon(objectiveFun,InitialPoints,[],[],[],[],lb,ub,nonlcon,
    options);
OptPath = PointsToCurve(OptPathPoints,'linear',FieldX,FieldY);
PDValuePath = calculatePathValue(OptPath,PDFusion,StartPoint,EndPoint,FieldX,
    FieldY,'linear');
```

Pseudocode zur Berechnung optimaler Annäherungspfade

Wie in Kapitel 2.5 beschrieben konvergieren die in MATLAB verwendeten Algorithmen nicht immer und es können nur lokale Optima gefunden werden. Aus diesem Grund empfiehlt sich eine sorgfältige Überprüfung der Ergebnisse. Im Berechnungsmodell wird für die Optimierung die in MATLAB vordefinierte Funktion `fmincon` verwendet, weil diese die Definition von nichtlinearen

Nebenbedingungen ermöglicht. Im Berechnungsmodell sind nach Gl. (2.50) Nebenbedingungen für den Endpunkt der Annäherungspfade definiert. Diese ermöglichen einen variablen Endpunkt, der sich auf der Außenfläche des Ego-Fahrzeugs befindet. Der Startpunkt hingegen kann zu Beginn frei gewählt werden, bleibt bei der Optimierung jedoch fix.

```
function [c,ceq] = egocarcon(P)
xlb = -5.3;
xub = 0;
y1b = -1;
yub = 1;

% c = [];
c1 = P(end-1)-xub;
c2 = -P(end-1)+xlb;
c3 = P(end)-yub;
c4 = -P(end)+y1b;
ceq = [];
% ceq1 = [];
% ceq2 = [];
c = [c1;c2;c3;c4];
% ceq = [ceq1;ceq2];
end
```

Nebenbedingungen bei der Berechnung optimaler Annäherungspfade

Die in (Abbildung 3.9) grün dargestellten Blöcke stellen die Visualisierung der Ergebnisse dar, die in MATLAB durch verschiedene Funktionen umgesetzt ist. Die Visualisierung der Ergebnisse unterteilt sich in zwei Darstellungen: die Darstellung der Sensorabdeckung und die Darstellung der Detektionswahrscheinlichkeit von Objekten und deren optimaler Annäherungspfade an autonome Fahrzeuge. Für die Darstellung der Sensorabdeckung werden die transformierten  $m \times n \times x \times p$  Matrizen für  $x$ ,  $y$  und  $z$  verwendet, um die eine konvexe Hülle gelegt wird. Diese konvexe Hülle beschreibt den theoretischen, dreidimensionalen Erfassungsbereich eines Sensors ohne Berücksichtigung seiner Charakteristiken, des Detektionsobjekts oder den Wetterbedingungen. Für die Darstellung der Detektionswahrscheinlichkeit von Objekten und deren optimaler Annäherungspfade wird die  $m \times n$  Matrix für die fusionierte Detektionswahrscheinlichkeit verwendet, um eine Heatmap zu erzeugen. Diese Heatmap beschreibt eine  $xy$  Ebene in einer bestimmten Höhe  $z$ , die die Detektionswahrscheinlichkeit eines Objekts in dieser Ebene in Abhängigkeit der Sensortopologie, der Sensorcharakteristiken, des Detektionsobjekts und der Wetterbedingungen darstellt und auf der optimale Annäherungspfade an autonome Fahrzeuge visualisiert werden können.

# 4 Ergebnisse und Diskussion

Das folgende Kapitel fasst die Ergebnisse des entwickelten Berechnungsmodells zusammen. In Kapitel 4.1 werden die Ergebnisse im Fernfeld untersucht und Auswirkungen des Detektionsobjekts und der Wetterbedingungen analysiert. In Kapitel 4.2 werden die Ergebnisse im Nahfeld untersucht. Kapitel 4.3 zeigt die Ergebnisse der Berechnung optimaler Annäherungspfade und erklärt den Einfluss des Optimierungsverfahrens. Zum Abschluss werden die Ergebnisse in Kapitel 4.4 diskutiert und Einschränkungen des Berechnungsmodells erläutert.

## 4.1 Fernfelduntersuchung

Für die Untersuchung des Fernfelds autonomer Fahrzeuge werden einige Rahmenbedingungen definiert. Das untersuchte Feld bzw. die Schnittebene wird in  $x$  auf  $-250$  m bis  $+350$  m, in  $y$  auf  $-200$  m bis  $+200$  m festgelegt, um alle Erfassungsbereiche der einzelnen Sensoren abbilden zu können. Die Schrittweiten für Reichweite, Azimuth und Elevation werden auf  $1$  m bzw.  $1^\circ$  festgelegt. Die Genauigkeit des Gitters in der  $xy$  Ebene (Schnittebene) wird in  $x$  auf  $0,5$  m und in  $y$  auf  $0,5$  m festgelegt. Die  $0,5$  m sind deshalb gewählt, weil sie der kleinsten Abmessung der definierten Objekte (Mensch) in Länge und in Breite entsprechen.

Basierend auf der in Kapitel 3.2.1 angenommenen Sensortopologie und den in Kapitel 3.2.2 angenommenen Sensoreigenschaften ergibt sich der gesamte theoretische Erfassungsbereich des Ego-Fahrzeugs. Der theoretische Erfassungsbereich berücksichtigt nur die geometrischen Eigenschaften der Sensoren, d.h. deren Reichweite und deren Öffnungswinkel in Azimuth und in Elevation. Der theoretische Erfassungsbereich ist in (Abbildung 4.1) dreidimensional dargestellt und in (Abbildung 4.2) bei Betrachtung aus der Vogelperspektive. Radarsensoren sind in Blau, Lidarsensoren in Rot, Kamerasensoren in Grün und Ultraschallsensoren in Gelb dargestellt.

Für die Untersuchung der Detektionswahrscheinlichkeit eines Objekts in Abhängigkeit seiner Eigenschaften, der Sensorcharakteristiken und der Wetterbedingungen wird der theoretische Erfassungsbereich, wie in Kapitel 3.3 beschrieben, in der  $xy$  Ebene in einer bestimmten Höhe  $z$  geschnitten und für die entstehende Schnittebene die fusionierte Detektionswahrscheinlichkeit berechnet. Die Höhe  $z$  der Schnittebene beeinflusst nur die von den Sensoren abgedeckten Bereiche in der  $xy$  Ebene, weil die Strahlungsleistung der Sensoren in Elevation als konstant angenommen wird. Die resultierende Heatmap beschreibt die Detektionswahrscheinlichkeit eines Objekts in Abhängigkeit von  $x$  und  $y$ , sowie den tatsächlichen Erfassungsbereich des Ego-Fahrzeugs in der Höhe  $z$ . Liegt die Höhe  $z$  der Schnittebene auf der Einbauhöhe eines Sensors, so wird dessen Erfassungsbereich entlang seiner Mittelachse geschnitten und beschreibt die maximalen Dimensionen in der  $xy$  Ebene. Ist dies nicht der Fall, ergibt sich durch die Öffnungswinkel des Erfassungsbereichs des Sensors ein eingeschränkter abgedeckter Bereich in der  $xy$  Ebene.

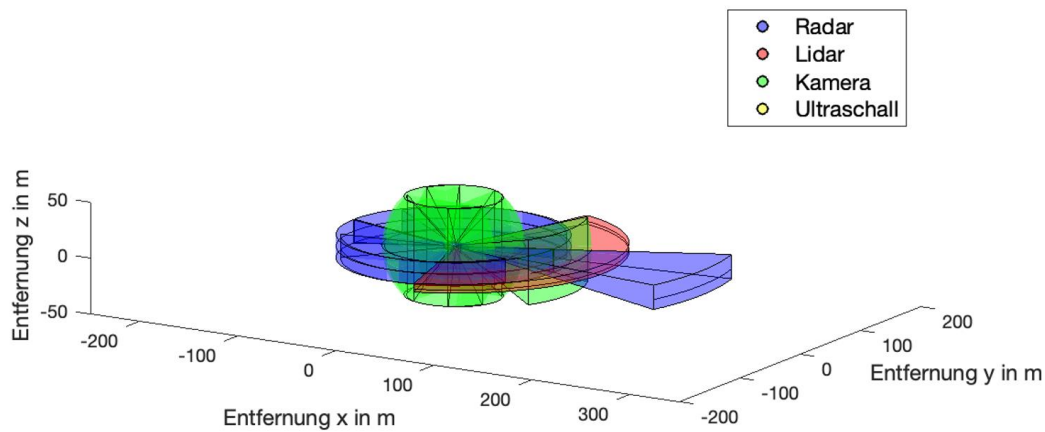


Abbildung 4.1: Dreidimensionale Darstellung des theoretischen Erfassungsbereichs

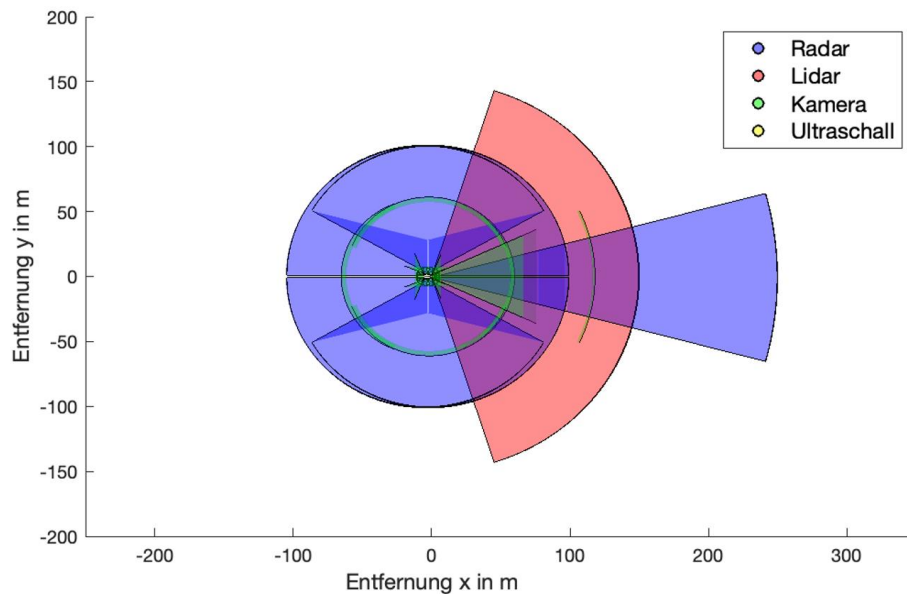


Abbildung 4.2: Theoretischer Erfassungsbereich des Ego-Fahrzeugs aus der Vogelperspektive

Für die folgende Untersuchung wird der theoretische Erfassungsbereich in vier verschiedenen Höhen (0,30 m, 0,60 m, 1,00 m und 1,30 m) geschnitten, die die Einbauhöhen der unterschiedlichen Sensoren beschreiben. (Abbildung 4.3) zeigt die Darstellung der Detektionswahrscheinlichkeit eines Objekts für die verschiedenen Schnittebenen. Es ist ersichtlich, dass die Höhe  $z$  der Schnittebene für die Untersuchung des Fernfelds kaum einen Einfluss auf den tatsächlichen Erfassungsbereich des Ego-Fahrzeugs hat. Für die weiteren Untersuchungen wird die Schnitthöhe  $z$  aus diesem Grund auf 0,75 m festgelegt. Die 0,75 m sind deshalb gewählt, weil sie der halben Höhe eines PKW entsprechen und alle definierten Objekte in dieser Höhe geschnitten werden.

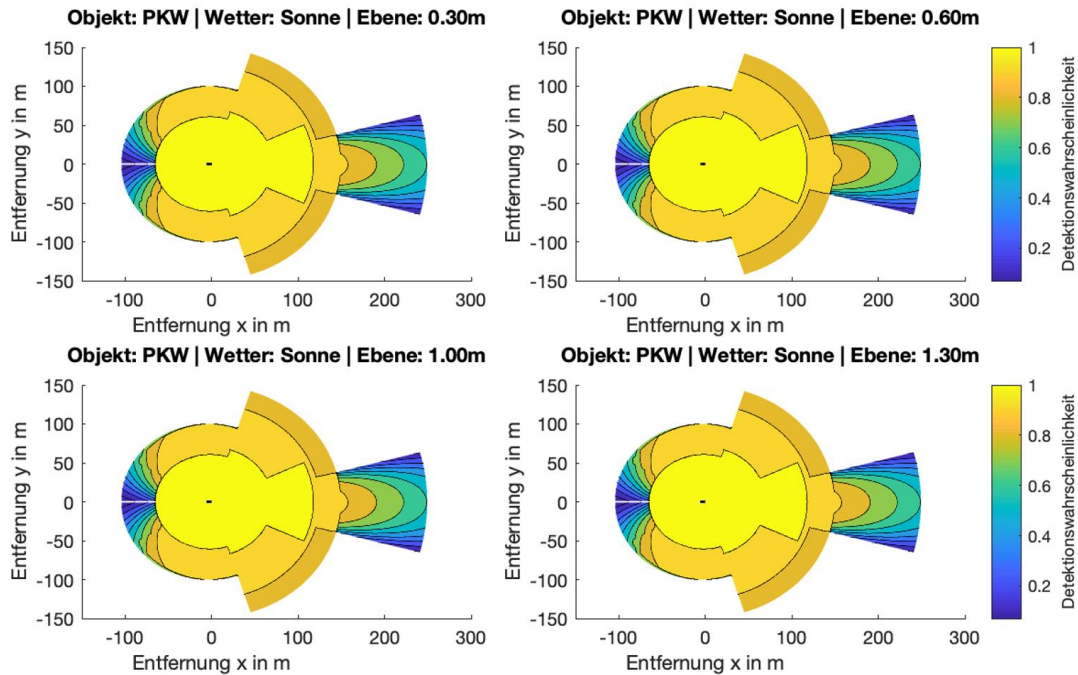


Abbildung 4.3: Einfluss der Schnittebene auf den tatsächlichen Erfassungsbereich im Fernfeld

Großen Einfluss auf die Detektionswahrscheinlichkeit und den tatsächlichen Erfassungsbereich hat das Detektionsobjekt, wie (Abbildung 4.4) bis (Abbildung 4.7) zeigen. Das Detektionsobjekt wird im Rahmen der vorliegenden Arbeit durch seinen Rückstreuquerschnitt beschrieben, der beeinflusst, welche vom Objekt aufgenommene Strahlungsleistung an den umfelderfassenden Sensor reflektiert wird. (Tabelle 4.1) fasst die Entfernungen einer frühesten möglichen Objektdetektion bei zentraler Annäherung für die verschiedenen definierten Objekte und für unterschiedliche Detektionswahrscheinlichkeiten  $p_D$  bei sonnigen Bedingungen zusammen. Die Entfernungen beziehen sich auf die entsprechend nächste Außenfläche des Ego-Fahrzeugs und nicht auf den Ursprung des festgelegten Koordinatensystems.

Tabelle 4.1: Auswertung der frühesten möglichen Objektdetektion bei sonnigen Bedingungen

	Mensch	Motorrad	PKW	LKW
Früheste mögliche Detektion mit $p_D > 0.5$ bei zentraler Annäherung an die Fahrzeugfront	118 m	158 m	250 m	250 m
Früheste mögliche Detektion mit $p_D = 1$ bei zentraler Annäherung an die Fahrzeugfront	40 m	67 m	118 m	118 m
Früheste mögliche Detektion mit $p_D > 0.5$ bei zentraler Annäherung an das Fahrzeugheck	58 m	60 m	60 m	60 m
Früheste mögliche Detektion mit $p_D = 1$ bei zentraler Annäherung an das Fahrzeugheck	15 m	29 m	60 m	60 m
Früheste mögliche Detektion mit $p_D > 0.5$ bei zentraler Annäherung an die Fahrzeugseite	60 m	96 m	100 m	100 m
Früheste mögliche Detektion mit $p_D = 1$ bei zentraler Annäherung an die Fahrzeugseite	17 m	33 m	60 m	60 m

(Abbildung 4.4) zeigt die Detektionswahrscheinlichkeit eines Menschen bei sonnigen Bedingungen. Es ist ersichtlich, dass der tatsächliche Erfassungsbereich eingeschränkt ist. Dies ist in den Randbereichen der Radarsensoren der Fall, weil deren Antennengewinn nach Tabelle 3.5 in Azimuth abnimmt und die ausgesendete Leistung nicht mehr ausreicht um einen Mensch zu detektieren. Besonders in Bereichen in denen sich keine Sensoren überlappen ist die Detektion eines Menschen daher schwierig. Ebenso zeigt sich die Abhängigkeit der Detektionswahrscheinlichkeit von der Entfernung des Objekts. Ein Mensch wird mit einer Detektionswahrscheinlichkeit  $p_D > 0.5$  frühestens in einer Entfernung von 118 m bei zentraler Annäherung an die Fahrzeugfront, frühestens in einer Entfernung von 58 m bei zentraler Annäherung an das Fahrzeugheck und frühestens in einer Entfernung von 60 m bei zentraler Annäherung an die Fahrzeugseite erfasst. Mit einer Detektionswahrscheinlichkeit  $p_D = 1$  wird ein Mensch frühestens in einer Entfernung von 40 m bei zentraler Annäherung an die Fahrzeugfront, frühestens in einer Entfernung von 15 m bei zentraler Annäherung an das Fahrzeugheck und frühestens in einer Entfernung von 17 m bei zentraler Annäherung an die Fahrzeugseite erkannt.

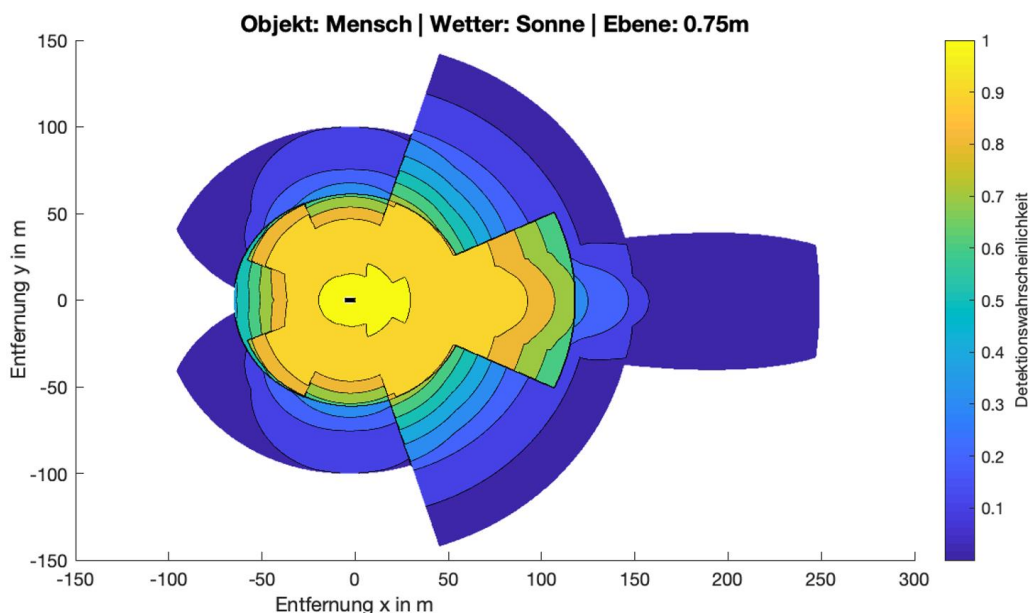


Abbildung 4.4: Detektionswahrscheinlichkeit eines Menschen bei sonnigen Bedingungen im Fernfeld

(Abbildung 4.5) zeigt die Detektionswahrscheinlichkeit eines Motorrads bei sonnigen Bedingungen. Der tatsächliche Erfassungsbereich ist in den Randbereichen der Radarsensoren minimal eingeschränkt. Ein Motorrad wird mit einer Detektionswahrscheinlichkeit  $p_D > 0.5$  frühestens in einer Entfernung von 158 m bei zentraler Annäherung an die Fahrzeugfront, frühestens in einer Entfernung von 60 m bei zentraler Annäherung an das Fahrzeugheck und frühestens in einer Entfernung von 96 m bei zentraler Annäherung an die Fahrzeugseite erfasst. Mit einer Detektionswahrscheinlichkeit  $p_D = 1$  wird ein Motorrad frühestens in einer Entfernung von 67 m bei zentraler Annäherung an die Fahrzeugfront, frühestens in einer Entfernung von 29 m bei zentraler Annäherung an das Fahrzeugheck und frühestens in einer Entfernung von 33 m bei zentraler Annäherung an die Fahrzeugseite erkannt.




Abbildung 4.5: Detektionswahrscheinlichkeit eines Motorrads bei sonnigen Bedingungen im Fernfeld

(Abbildung 4.6) zeigt die Detektionswahrscheinlichkeit eines PKW bei sonnigen Bedingungen. Der tatsächliche Erfassungsbereich ist nicht eingeschränkt. Ein PKW wird mit einer Detektionswahrscheinlichkeit  $p_D > 0.5$  frühestens in einer Entfernung von 250 m bei zentraler Annäherung an die Fahrzeugfront, frühestens in einer Entfernung von 60 m bei zentraler Annäherung an das Fahrzeugheck und frühestens in einer Entfernung von 100 m bei zentraler Annäherung an die Fahrzeugseite erfasst. Mit einer Detektionswahrscheinlichkeit  $p_D = 1$  wird ein PKW frühestens in einer Entfernung von 118 m bei zentraler Annäherung an die Fahrzeugfront, frühestens in einer Entfernung von 60 m bei zentraler Annäherung an das Fahrzeugheck und frühestens in einer Entfernung von 60 m bei zentraler Annäherung an die Fahrzeugseite erkannt.




Abbildung 4.6: Detektionswahrscheinlichkeit eines PKW bei sonnigen Bedingungen im Fernfeld

(Abbildung 4.7) zeigt die Detektionswahrscheinlichkeit eines LKW bei sonnigen Bedingungen. Der tatsächliche Erfassungsbereich ist nicht eingeschränkt. Ein LKW wird mit einer Detektionswahrscheinlichkeit  $p_D > 0.5$  frühestens in einer Entfernung von 250 m bei zentraler Annäherung an die Fahrzeugfront, frühestens in einer Entfernung von 60 m bei zentraler Annäherung an das Fahrzeugheck und frühestens in einer Entfernung von 100 m bei zentraler Annäherung an die Fahrzeugseite erfasst. Mit einer Detektionswahrscheinlichkeit  $p_D = 1$  wird ein LKW frühestens in einer Entfernung von 118 m bei zentraler Annäherung an die Fahrzeugfront, frühestens in einer Entfernung von 60 m bei zentraler Annäherung an das Fahrzeugheck und frühestens in einer Entfernung von 60 m bei zentraler Annäherung an die Fahrzeugseite erkannt. Im Vergleich zur Detektionswahrscheinlichkeit eines PKW ist die Detektionswahrscheinlichkeit eines LKW bei großen Entfernungen höher und liegt fast im gesamten Erfassungsbereich bei über 0,75.

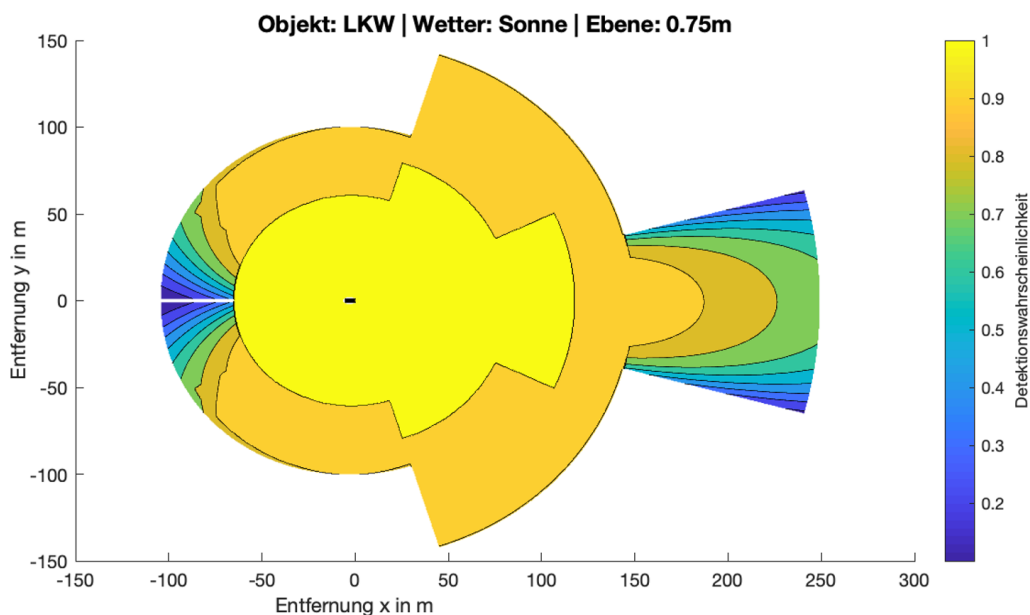


Abbildung 4.7: Detektionswahrscheinlichkeit eines LKW bei sonnigen Bedingungen im Fernfeld

Ebenfalls großen Einfluss auf die Detektionswahrscheinlichkeit eines Objekts und den tatsächlichen Erfassungsbereich haben die Wetterbedingungen, wie (Abbildung 4.9) bis (Abbildung 4.14) zeigen. Für die Untersuchung der Einflüsse der Wetterbedingungen wird im Folgenden ein konkretes Verkehrsszenario analysiert. Dabei befindet sich das Ego-Fahrzeug auf dem linken Fahrstreifen einer 4-spurigen Autobahn, die bei x gleich 0 m eine Rechtskurve mit dem Radius 500 m beschreibt. Als Detektionsobjekt wird ein PKW definiert, der sich auf dem rechten Fahrstreifen der Autobahn befindet und überholt wird. Der Überholvorgang wird durch den in den Abbildungen Violett dargestellten Pfad nachgebildet. Die Breite der jeweiligen Fahrstreifen ist aus [98] entnommen und entspricht der Richtlinie für die Anlage von Autobahnen. (Abbildung 4.8) stellt die Breite der Autobahn und der jeweiligen Fahrstreifen dar.




Abbildung 4.8: Breite der Fahrstreifen einer 4-spurigen Autobahn [98]



Die Auswertung des Überholvorgangs bei verschiedenen Wetterbedingungen wird anhand von sechs Werten durchgeführt. Zum einen wird der Gesamtwert des Pfads anhand der Kostenfunktion  $p_{D,value,path}$  (Gl. (3.3)) berechnet. Ein niedrigerer Gesamtwert drückt eine insgesamt niedrigere Detektionswahrscheinlichkeit aus. Zum anderen werden die Distanzen berechnet, in denen sich das andere Fahrzeug in Bereichen mit einer gewissen Detektionswahrscheinlichkeit  $p_D$  bewegt:  $p_D = 0$ ,  $0 < p_D < 0.5$ ,  $0.5 < p_D < 0.75$  und  $0.75 < p_D < 1$ ,  $p_D = 1$ . Der Bereich  $p_D = 0$  beschreibt den Bereich, in dem ein Objekt nicht erkannt wird. In der Literatur gilt eine Detektionswahrscheinlichkeit von 50% als gut [89, S. 848]. Der Bereich  $0 < p_D < 0.5$  beschreibt somit eine ungenügende Detektionswahrscheinlichkeit. Der Bereich  $p_D > 0.5$  wird im Rahmen der vorliegenden Arbeit weiter unterteilt, um eine gute Detektionswahrscheinlichkeit ( $0.5 < p_D < 0.75$ ) und eine sehr gute Detektionswahrscheinlichkeit ( $0.75 < p_D < 1$ ) zu definieren. Der Bereich  $p_D = 1$  beschreibt den Bereich, in dem ein Objekt immer erkannt wird. (Tabelle 4.2) fasst die Ergebnisse bei verschiedenen Wetterbedingungen zusammen. Die Distanzen werden als kumulierte Summe der jeweiligen Detektionswahrscheinlichkeit  $p_D$  ausgedrückt.

Tabelle 4.2: Auswertung des Überholmanövers eines PKW bei verschiedenen Wetterbedingungen

	$p_{D,value,path}$	Kum. Distanz $p_D = 1$	Kum. Distanz $p_D > 0.75$	Kum. Distanz $p_D > 0.5$	Kum. Distanz $p_D > 0$	Gesamt- distanz
Sonne	258.59	181.06 m	211.94 m	238.86 m	313.70 m	502.36 m
Sonne + Blendung	258.40	133.24 m	211.94m	238.86m	313.70 m	502.36 m
Nacht	258.23	101.24 m	211.94 m	238.86 m	313.70 m	502.36 m
Regen	231.38	131.18 m	201.98 m	214.94 m	312.71 m	502.36 m
Starkregen	204.60	92.28 m	181.06 m	184.04 m	260.90 m	502.36 m
Nebel	250.66	78.33	201.99 m	237.87 m	312.71 m	502.36 m
Nebel + Nickwinkel +2°	250.45	78.33 m	201.99 m	237.87 m	312.71 m	502.36m
Nebel + Nickwinkel -2°	250.49	78.33 m	201.99 m	237.87 m	312.71 m	502.36m
Nebel + Wankwinkel +2°	250.78	78.33 m	201.99 m	237.87 m	314.70 m	502.36 m
Nebel + Wankwinkel -2°	250.64	78.33 m	201.99 m	237.87 m	314.70 m	502.36 m
Nebel + Nickwinkel/ Wankwinkel +2°	245.92	78.33 m	202.98 m	238.86 m	298.76 m	502.36 m

(Abbildung 4.9) beschreibt das Szenario bei sonnigen Bedingungen und dient als Referenz für den Vergleich bei den verschiedenen Wetterbedingungen. Bei sonnigen Bedingungen wird das andere Fahrzeug beim Überholvorgang für 181 m immer durch das Ego-Fahrzeug erkannt. Für 189 m wird das andere Fahrzeug während des Überholvorgangs nicht erkannt.




Abbildung 4.9: Detektionswahrscheinlichkeit eines PKW beim Überholvorgang bei sonnigen Bedingungen

(Abbildung 4.10) zeigt das Szenario bei sonnigen Bedingungen und tiefstehender Sonne. Durch die tiefstehende Sonne werden die Kamerasensoren an der Front, hinter der Windschutzscheibe und am rechten Außenspiegel des Ego-Fahrzeugs geblendet und ermöglichen keine Objektdetektion mehr. Dies wird durch den eingeschränkten Bereich mit einer Detektionswahrscheinlichkeit  $p_D = 1$  an der Front und der rechten Seite des Ego-Fahrzeugs ersichtlich. Die Radarsensoren und der Lidarsensor sind durch die tiefstehende Sonne nicht beeinträchtigt. Weil sich die Erfassungsbereiche der ausfallenden Kamerasensoren in Bereichen mehrerer überlappender Sensoren befinden, ist durch die redundante Sensorauslegung auch beim Ausfall der Kamerasensoren bei tiefstehender Sonne weiterhin eine sehr gute Objektdetektion möglich.




Abbildung 4.10: Detektionswahrscheinlichkeit eines PKW beim Überholvorgang bei tiefstehender Sonne

(Abbildung 4.11) zeigt das Szenario bei Nacht, bei dem sich ein ähnliches Ergebnis ergibt. Durch die Dunkelheit verschlechtert sich die Leistungsfähigkeit der Kamerasensoren, was durch den eingeschränkten Bereich mit einer Detektionswahrscheinlichkeit  $p_D = 1$  rund um das Ego-Fahrzeug ersichtlich wird. Die Leistungsfähigkeit der Frontkameras ist durch die direkte Beleuchtung von Objekten durch die Fahrzeugscheinwerfer prinzipiell weniger beeinträchtigt. Dies wird im Rahmen der vorliegenden Arbeit nicht berücksichtigt. Die Radarsensoren und der Lidarsensor sind bei Nacht nicht beeinträchtigt und ermöglichen weiterhin eine sehr gute Objektdetektion. Bei Nacht wird das andere Fahrzeug beim Überholvorgang für 101 m immer und für 189 m nicht durch das Ego-Fahrzeug erkannt.




Abbildung 4.11: Detektionswahrscheinlichkeit eines PKW beim Überholvorgang bei Nacht

(Abbildung 4.12) zeigt das Szenario bei Regen. Bei Regen ist die Leistungsfähigkeit aller Sensoren beeinträchtigt, was sich im eingeschränkten tatsächlichen Erfassungsbereich des Ego-Fahrzeugs und dem eingeschränkten Erfassungsbereich mit einer Detektionswahrscheinlichkeit  $p_D > 0.75$  zeigt. Bei Regen wird das andere Fahrzeug beim Überholvorgang für 131 m immer und für 190 m nicht durch das Ego-Fahrzeug erkannt.




Abbildung 4.12: Detektionswahrscheinlichkeit eines PKW beim Überholvorgang bei Regen

(Abbildung 4.13) zeigt das Szenario bei Starkregen. Starkregen und Regen unterschieden sich durch die Größe der einzelnen Regentropfen und durch die Niederschlagsmenge ( Regen: 25 mm/h, Starkregen: 150 mm/h). Bei Starkregen ist die Leistungsfähigkeit aller Sensoren stark beeinträchtigt, wodurch der tatsächliche Erfassungsbereich des Ego-Fahrzeugs und der Erfassungsbereich mit einer Detektionswahrscheinlichkeit  $p_D > 0.75$  noch stärker eingeschränkt sind als bei Regen. Am deutlichsten zeigt sich die Einschränkung im Erfassungsbereich des LRR an der Fahrzeugfront. Bei Starkregen wird das andere Fahrzeug beim Überholvorgang für 92 m immer durch das Ego-Fahrzeug erkannt. Für 241 m wird das andere Fahrzeug während des Überholvorgangs nicht erkannt.




Abbildung 4.13: Detektionswahrscheinlichkeit eines PKW beim Überholvorgang bei Starkregen

(Abbildung 4.14) zeigt das Szenario bei Nebel. Bei Nebel verschlechtert sich die Leistungsfähigkeit des Lidarsensors und der Kamerasensoren. Die Radarsensoren sind bei Nebel kaum beeinflusst. Durch die redundante Sensorauslegung ist auch bei Leistungseinbußen der Sensoren bei nebligen Bedingungen weiterhin eine gute Objektdetektion möglich. Bei Nebel wird das andere Fahrzeug beim Überholvorgang für 78 m immer durch das Ego-Fahrzeug erkannt. Für 189 m wird das andere Fahrzeug während des Überholvorgangs nicht erkannt.

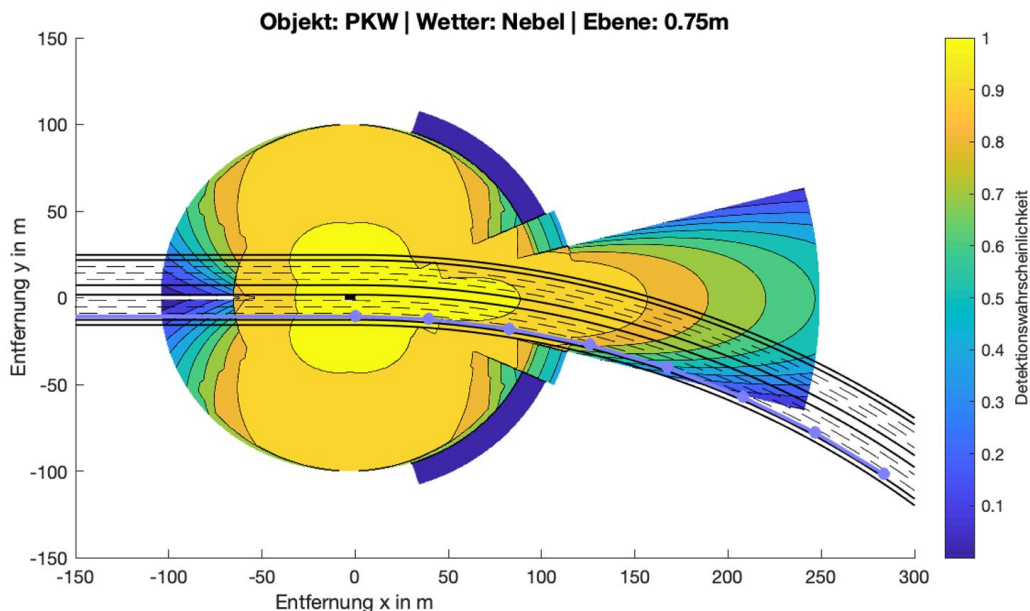


Abbildung 4.14: Detektionswahrscheinlichkeit eines PKW beim Überholvorgang bei Nebel

Weiteren Einfluss auf den tatsächlichen Erfassungsbereich hat der dynamische Zustand des Ego-Fahrzeugs. Der Nickwinkel des Ego-Fahrzeugs ändert sich beispielsweise in dynamischen Situationen wie Beschleunigungs- oder Bremsvorgängen, der Wankwinkel des Ego-Fahrzeugs ändert sich beispielsweise während der Kurvenfahrt. Ebenso können der Nick- und Wankwinkel des Ego-Fahrzeugs permanent verändert werden, beispielsweise durch eine hecklastige oder einseitige Zuladung. Durch die Änderung des Fahrzeugzustands ändert sich gleichzeitig die Orientierung aller Sensoren, weil im Rahmen der vorliegenden Arbeit die adaptive Anpassung der Sensoren an Nick- und Wankwinkeländerungen nicht berücksichtigt wird, d.h. es wird eine feste Orientierung der Sensoren angenommen. Weil sich die Orientierung aller Sensoren ändert, hat die Höhe  $z$  der Schnittebene einen Einfluss auf den tatsächlichen Erfassungsbereich des Ego-Fahrzeugs. Für die folgende Untersuchung wird nur die festgelegte Schnitthöhe  $z$  von 0,75 m betrachtet.

(Abbildung 4.15) zeigt den Einfluss des Fahrzeugzustands auf den tatsächlichen Erfassungsbereich des Ego-Fahrzeugs bei nebligen Bedingungen. Es ist ersichtlich, dass besonders der tatsächliche Erfassungsbereich des Lidarsensors beeinflusst ist. Dies liegt daran, dass der Lidarsensor im Vergleich zu den anderen verbauten Sensoren nur einen kleinen Erfassungsbereich in Elevation aufweist ( $3,2^\circ$ ).




Abbildung 4.15: Einfluss des Fahrzeugzustands auf die Detektionswahrscheinlichkeit eines PKW beim Überholmanöver

(Abbildung 4.16) zeigt das Überholmanöver bei Nebel und einem permanenten Nickwinkel von +2° und einem permanenten Wankwinkel von +2° des Ego-Fahrzeugs. Es ist ersichtlich, dass der Erfassungsbereich des Lidarsensors auf der rechten Fahrzeugseite eingeschränkt ist. Die Radarsensoren und Kamerasensoren weisen große Erfassungsbereiche in Elevation auf, wodurch deren tatsächliche Erfassungsbereiche durch die Änderung des Fahrzeugzustands nicht beeinträchtigt sind.




Abbildung 4.16: Detektionswahrscheinlichkeit eines PKW beim Überholvorgang bei Nebel und verändertem Fahrzeugzustand

Die Werte für das in (Abbildung 4.16) dargestellte Szenario ändern sich im Vergleich zum Szenario bei Nebel und einem neutralen Fahrzeugzustand nur geringfügig, weil sich der Erfassungsbereich des Lidarsensors in Bereichen mehrerer überlappender Sensoren befinden, wodurch weiterhin eine gute Objektdetektion möglich ist.

## 4.2 Nahfelduntersuchung

Für die Untersuchung des Nahfelds autonomer Fahrzeuge werden einige Rahmenbedingungen definiert. Das untersuchte Feld bzw. die Schnittebene wird in x auf -10 m bis +5 m, in y auf -6 m bis +6 m festgelegt. Die Schrittweite für die Reichweite wird auf 0,1 m festgelegt. Die Schrittweiten für Azimuth und Elevation werden auf  $1^\circ$  festgelegt. Die Genauigkeit des Gitters in der xy Ebene (Schnittebene) wird in x auf 0,05 m und in y auf 0,05 m festgelegt, um eine ausreichende Genauigkeit für die Darstellung der tatsächlichen Erfassungsbereiche der einzelnen Sensoren und für die Identifizierung blinder Stellen (engl. Blind Spots) rund um das autonome Fahrzeug zu ermöglichen.

In Kapitel 4.1 wird durch die Fernfelduntersuchung gezeigt, dass das Detektionsobjekt und die Wetterbedingungen großen Einfluss auf die Detektionswahrscheinlichkeit und den tatsächlichen Erfassungsbereich haben. Im Nahfeld rund um das Ego-Fahrzeug ergeben sich für verschiedene Detektionsobjekte und Wetterbedingungen keine Einschränkungen, wie (Abbildung 4.17) und (Abbildung 4.18) zeigen. Alle definierten Objekte werden im Nahfeld des Ego-Fahrzeugs auch bei schlechten Witterungs- und Lichtverhältnissen mit einer Detektionswahrscheinlichkeit  $p_D = 1$  erkannt. Folglich konzentriert sich die Nahfelduntersuchung auf die Identifizierung von blinden Stellen rund um das Ego-Fahrzeug. Die blinden Stellen sind abhängig von der Sensortopologie, den Sensoreigenschaften und der gewählten Schnittebene.

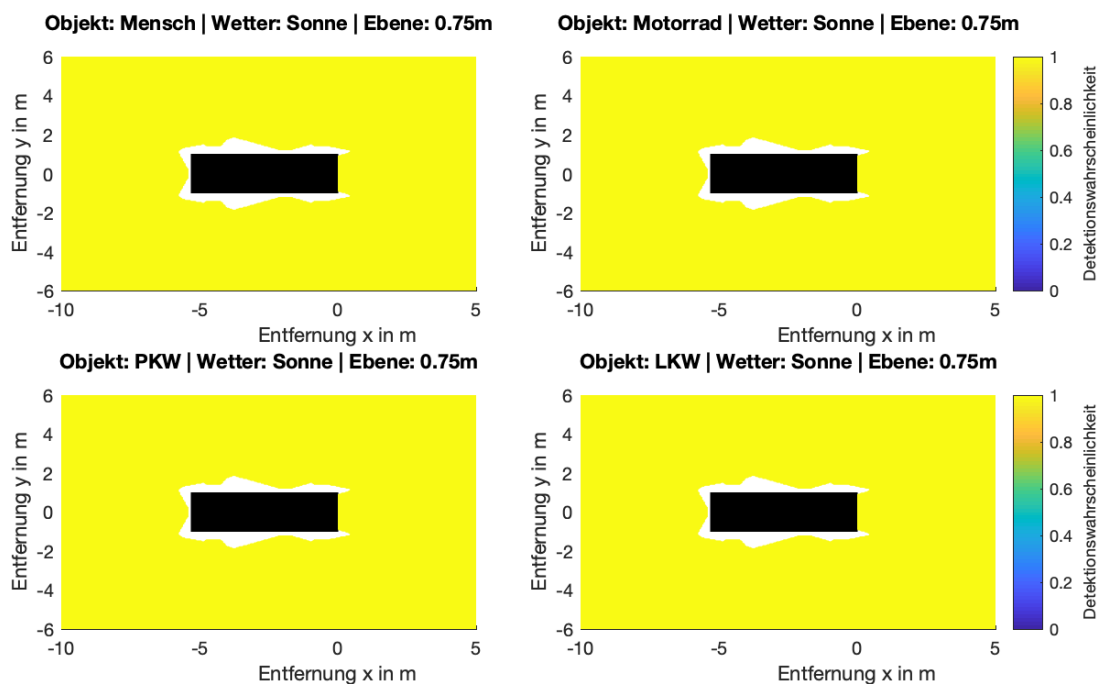


Abbildung 4.17: Einfluss des Detektionsobjekts auf die Detektionswahrscheinlichkeit im Nahfeld




Abbildung 4.18: Einfluss der Wetterbedingungen auf die Detektionswahrscheinlichkeit im Nahfeld

Der gesamte theoretische Erfassungsbereich für das Nahfeld des Ego-Fahrzeugs ist in (Abbildung 4.19)Abbildung 4.19 bei Betrachtung aus der Vogelperspektive dargestellt und bildet die blinden Stellen rund um das Ego-Fahrzeug ab. Insgesamt zeigt sich eine sehr gute 360° Abdeckung mit mehreren redundanten Erfassungsbereichen verschiedener Sensoren. Die größten blinden Stellen ohne Sensorabdeckung befinden sich an den Seiten des Ego-Fahrzeugs bei  $x = -4$  m.




Abbildung 4.19: Theoretischer Erfassungsbereich im Nahfeld des Ego-Fahrzeugs aus der Vogelperspektive

Wie in Kapitel 4.1 beschrieben wird für die Untersuchung der Detektionswahrscheinlichkeit eines Objekts der theoretische Erfassungsbereich in der xy Ebene in einer bestimmten Höhe z



geschnitten und für die entstehende Schnittebene die fusionierte Detektionswahrscheinlichkeit berechnet. Die Höhe  $z$  der Schnittebene beeinflusst die von den Sensoren abgedeckten Bereiche in der  $xy$  Ebene. Liegt die Höhe  $z$  der Schnittebene auf der Einbauhöhe eines Sensors, so wird dessen Erfassungsbereich entlang seiner Mittelachse geschnitten und beschreibt die maximalen Dimensionen in der  $xy$  Ebene. Ist dies nicht der Fall, ergibt sich durch die Öffnungswinkel des Erfassungsbereichs des Sensors ein eingeschränkter abgedeckter Bereich in der  $xy$  Ebene. In Kapitel 4.1 wird gezeigt, dass diese Einschränkung bei der Betrachtung des Fernfelds keinen Einfluss hat. Bei der Betrachtung des Nahfeld ist diese Einschränkung nicht zu vernachlässigen, weil sie die Lage und die Größe der blinden Stellen rund um das Ego-Fahrzeug beeinflusst, wie (Abbildung 4.20) bis (Abbildung 4.24) zeigen.

Radar-, Ultraschall- und Lidarsensoren können erst ab einer gewissen Mindestentfernung von einigen Zentimetern Objekte detektieren. Bei kleineren Entfernungen, im sogenannten Nahfeld der Sensoren, kommt es durch die Nähe des Objekts zum Sender und durch die Sendecharakteristik der aktiven Sensoren zu Interferenzen, weshalb diese Bereiche nicht zur Objektdetektion genutzt werden können. Für die Nahfelduntersuchung sind dementsprechend die Detektionsbereiche der Sensoren (Tabelle 3.4) von Interesse, weil sie die blinden Stellen rund um das Ego-Fahrzeug ebenfalls beeinflussen.

(Abbildung 4.20) zeigt die Detektionswahrscheinlichkeit eines Menschen bei sonnigen Bedingungen für eine Höhe der Schnittebene  $z = 0.00$  m. Auf dieser Höhe liegen die Fahrbahn und der Ursprung des festgelegten Koordinatensystems. Die blinden Stellen fallen an den seitlichen Heckbereichen des Fahrzeugs am größten aus und reichen bis zu einer Entfernung von 3 m.




Abbildung 4.20: Detektionswahrscheinlichkeit eines Menschen im Nahfeld in der Schnittebene 0.00 m

(Abbildung 4.21) zeigt die Detektionswahrscheinlichkeit eines Menschen bei sonnigen Bedingungen für eine Höhe der Schnittebene  $z = 0.30$  m. Auf dieser Höhe liegt die Einbauhöhe des Lidarsensors. Es zeigt sich eine insgesamt sehr gute 360° Abdeckung mit den größten blinden Stellen an den seitlichen Heckbereichen des Ego-Fahrzeugs.




Abbildung 4.21: Detektionswahrscheinlichkeit eines Menschen im Nahfeld in der Schnittebene 0.30 m

(Abbildung 4.22) zeigt die Detektionswahrscheinlichkeit eines Menschen bei sonnigen Bedingungen für eine Höhe der Schnittebene  $z = 0.60$  m. Auf dieser Höhe liegen die Einbauhöhen der Radarsensoren, der Ultraschallsensoren und der Frontkamera, wodurch die blinden Stellen rund um das Ego-Fahrzeug kleiner ausfallen und sich eine nahezu perfekte 360 ° Abdeckung ergibt.




Abbildung 4.22: Detektionswahrscheinlichkeit eines Menschen im Nahfeld in der Schnittebene 0.60 m

(Abbildung 4.23) zeigt die Detektionswahrscheinlichkeit eines Menschen bei sonnigen Bedingungen für eine Höhe der Schnittebene  $z = 1.00$  m. Auf dieser Höhe liegt die Einbauhöhe der Kamerasensoren in den Außenspiegeln, wie bei  $x = -2$  m ersichtlich wird. Die größten blinden Stellen befinden sich an den seitlichen Heckbereichen des Fahrzeugs und reichen bis zu einer Entfernung von 2 m.




Abbildung 4.23: Detektionswahrscheinlichkeit eines Menschen im Nahfeld in der Schnittebene 1.00 m

(Abbildung 4.24) zeigt die Detektionswahrscheinlichkeit eines Menschen bei sonnigen Bedingungen für eine Höhe der Schnittebene  $z = 1.30$  m. Auf dieser Höhe liegt die Einbauhöhe des Kamerasensors hinter der Windschutzscheibe. Die blinden Stellen an den seitlichen Heckbereichen des Fahrzeugs fallen in dieser Schnittebene größer aus und reichen bis zu einer Entfernung von 3 m.




Abbildung 4.24: Detektionswahrscheinlichkeit eines Menschen im Nahfeld in der Schnittebene 1.30 m

(Abbildung 4.20) bis (Abbildung 4.24) zeigen, dass die Höhe  $z$  der Schnittebene Einfluss auf die Lage und die Größe der blinden Stellen rund um das Ego-Fahrzeug hat. Weil sich die Höhenabmessung der definierten Objekte jedoch über alle untersuchten Schnittebenen erstreckt, werden die Objekte in allen diesen Schnittebenen geschnitten, wodurch sich die blinden Stellen bei der Objektdetektion auf die minimalen blinden Stellen des theoretischen Erfassungsbereichs des

Ego-Fahrzeugs reduzieren. (Abbildung 4.25) zeigt die Detektionswahrscheinlichkeit eines Menschen bei sonnigen Bedingungen für die Überlagerung der Schnittebenen von 0 m bis 1,30 m.




Abbildung 4.25: Detektionswahrscheinlichkeit eines Menschen im Nahfeld bei der Überlagerung der Schnittebenen

Es zeigt sich eine sehr gute 360° Abdeckung, wobei sich die größten blinden Stellen an den Seiten des Ego-Fahrzeugs bei  $x = -4$  m befinden. Die blinden Stellen sind so groß, dass ein Mensch innerhalb dieser nicht detektiert werden kann, ein Motorrad hingegen wird detektiert. (Abbildung 4.26) stellt dies grafisch dar.




Abbildung 4.26: Lage und Größe der blinden Stellen bei der Überlagerung der Schnittebenen

### 4.3 Pfadoptimierung

Die Berechnung optimaler Annäherungspfade an autonome Fahrzeuge wird auf Basis der in Kapitel 4.1 und Kapitel 4.2 dargestellten Ergebnisse durchgeführt. Es werden die gleichen Rahmenbedingungen wie bei der Fernfelduntersuchung definiert und die Höhe der Schnittebene  $z$  wird auf 0,75 m festgelegt. Wie in Kapitel 3.3 beschrieben wird die Optimierung nur auf dieser  $xy$  Ebene durchgeführt. Für die Optimierung der Annäherungspfade müssen zusätzliche Bedingungen für die verwendete MATLAB-Funktion `fmincon` definiert werden. Als Optimierungsalgorithmus wird der Innere-Punkte-Algorithmus verwendet, der in MATLAB standardmäßig eingestellt ist und sich durch eine schnelle Konvergenz auszeichnet. Als Schrittweitentoleranz wird der standardmäßig eingestellte Wert von  $1e-10$  verwendet, der für die betrachteten Untersuchungen ausreichend klein ist. Die Schrittweitentoleranz ist eine Schranke für die Schrittgröße der Optimierung, d.h. wenn der Algorithmus von einer Iteration zur nächsten Iteration einen Schritt ausführt, der kleiner als die Schranke ist, wird die Optimierung beendet. Als Optimalitätstoleranz wird der standardmäßig eingestellte Wert von  $1e-6$  verwendet, der für die betrachteten Untersuchungen ausreichend klein ist. Die Optimalitätstoleranz ist ein Maß für die Nähe der Werte zum Optimum, d.h. wenn die Änderung der Werte von einer Iteration zur nächsten Iteration kleiner als Optimalitätstoleranz ist, wird die Optimierung beendet. Wie in Kapitel 2.5 beschrieben kann es sein, dass die Optimierung nicht konvergiert. Um in solchen Fällen eine unnötig lange Rechenzeit zu vermeiden kann die Optimierung bei Erreichen einer festgelegten Anzahl an Iterationen oder Aufrufen der Kostenfunktion beendet werden. Für die betrachteten Untersuchungen werden die Werte auf 500 mal die Anzahl an Pfadpunkten bzw. 5000 mal die Anzahl an Pfadpunkten festgelegt, um eine ausreichend große Anzahl an Optimierungsdurchläufen zu gewährleisten. Wie in Kapitel 3.3 beschrieben wird zwischen zwei Pfadpunkten linear interpoliert, so dass sich alle 0,5 m entlang des Annäherungspfads ein Berechnungspunkt befindet. Die Anzahl an Pfadpunkten bestimmt entsprechend die Form des Annäherungspfads und wird für die betrachteten Untersuchungen abhängig vom gewählten Startpunkt festgelegt.

Für die Berechnung der optimalen Annäherungspfade an das Ego-Fahrzeug wird ein Startpunkt außerhalb des Erfassungsbereichs des Ego-Fahrzeugs definiert. Im Rahmen der vorliegenden Arbeit wird dieser willkürlich auf  $x = 300$  m und  $y = 50$  m festgelegt. Die Pfadpunkte werden entlang einer geraden Linie zwischen Startpunkt und Endpunkt verteilt. Der Endpunkt befindet sich in der Mitte der Fahrzeugfront des Ego-Fahrzeugs, d.h. bei  $x = 0$  m und  $y = 0$  m. Für die folgenden Untersuchungen wird die Anzahl an Pfadpunkten auf 15 festgelegt, d.h. es befindet sich alle 20 m entlang der geraden Linie ein Pfadpunkt. Diese Pfadpunkte stellen die Startbedingungen dar und werden bei der Berechnung der optimalen Annäherungspfade so optimiert, dass sich ein minimaler Gesamtwert der Kostenfunktion  $p_{D,value,path}$  (Gl. (3.3)) ergibt.

(Abbildung 4.27) zeigt den optimierten Annäherungspfad eines PKW bei sonnigen Bedingungen ausgehend von den gegebenen Startbedingungen. Es ist ersichtlich, dass der dargestellte Annäherungspfad keinen optimalen Annäherungspfad beschreibt. Wie in Kapitel 2.5.2 erwähnt, ist mit MATLAB nur die Bestimmung lokaler Optima möglich. Der in (Abbildung 4.27) dargestellte Annäherungspfad beschreibt zwar ein lokales Minimum der Kostenfunktion, jedoch kein globales Minimum. Eine Möglichkeit zur Berechnung des tatsächlichen optimalen Annäherungspfads bietet die MATLAB-Funktion `multistart`. Durch diese Funktion wird die Optimierung mehrfach parallel ausgeführt und für jede Optimierung die Startbedingungen innerhalb der festgelegten Grenzen zufällig variiert, wodurch sich verschiedene lokale Optima ergeben. Aus den verschiedenen lokalen Optima wird das „globale“ Optimum ausgegeben. Dieses „globale“ Optimum ist jedoch nur das beste Optimum mehrerer lokaler Optima und somit wiederum selbst ein lokales

Optimum. Weil die Startbedingungen bei der mehrfachen parallelen Optimierung durch MATLAB zufällig variiert werden, ergeben sich für jeden Durchlauf außerdem unterschiedliche Ergebnisse. (Abbildung 4.28) zeigt den optimierten Annäherungspfad eines PKW bei sonnigen Bedingungen anhand der „globalen“ Optimierung.

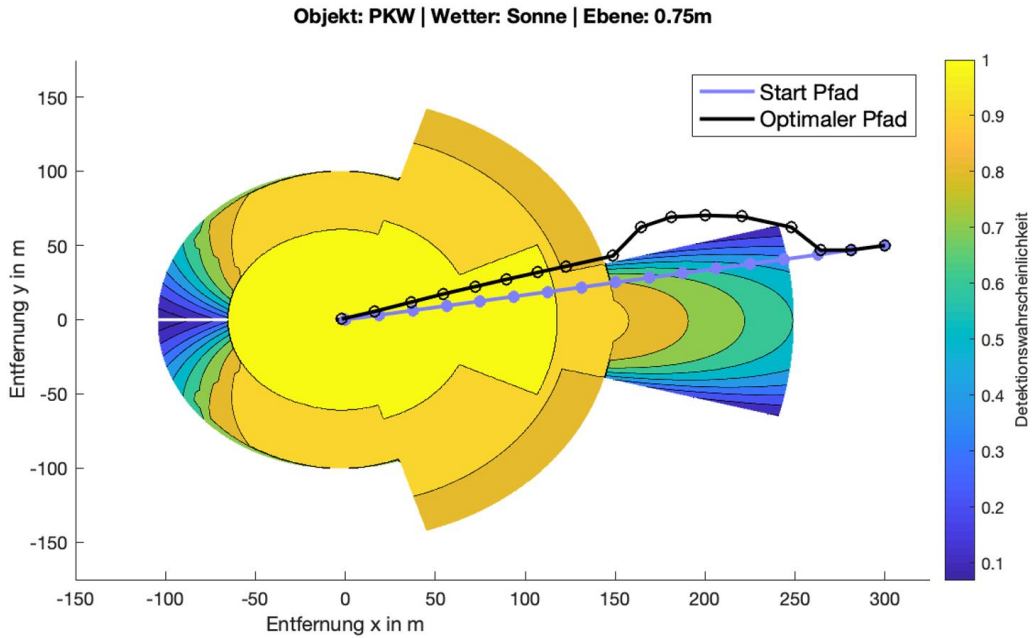


Abbildung 4.27: Lokale Pfadoptimierung




Abbildung 4.28: "Globale" Pfadoptimierung

Es zeigt sich, dass die Startbedingungen der Optimierung die Berechnung optimaler Annäherungspfade an autonome Fahrzeuge maßgeblich beeinflussen. Aus diesem Grund bietet das Berechnungsmodell die Möglichkeit die Startbedingungen (Pfadpunkte) interaktiv festzulegen, um die Ergebnisse der Optimierung zu verbessern. Hierbei bietet es sich an, die Ergebnisse der lokalen und „globalen“ Optimierung zu verwenden und die neuen Startbedingungen diesen anzupassen. Die sich dadurch ergebenden verbesserten Annäherungspfade werden im Folgenden als lokal optimaler Annäherungspfad und „global“ optimaler Annäherungspfad bezeichnet.

Die Auswertung dieser lokal optimalen und „global“ optimalen Annäherungspfade an das Ego-Fahrzeug wird anhand der in Kapitel 4.1 eingeführten sechs Werte durchgeführt. Um die Ergebnisse mit den Erkenntnissen aus der Fernfelduntersuchung in Bezug setzen zu können, wird als Detektionsobjekt ein PKW definiert, d.h. die Annäherungspfade beschreiben die Annäherung eines PKW an das Ego-Fahrzeug. (Tabelle 4.3) fasst die Ergebnisse bei verschiedenen Wetterbedingungen zusammen.

Tabelle 4.3: Auswertung der Berechnung optimaler Annäherungspfade für den Startpunkt (300,50)

		$p_{D,value,path}$	Kum. Distanz $p_D = 1$	Kum. Distanz $p_D > 0.75$	Kum. Distanz $p_D > 0.5$	Kum. Distanz $p_D > 0$	Gesamt- distanz
Sonne	Gerade Linie	215.9	117.05 m	169.07 m	226.10 m	249.11 m	304.13 m
	Lokales Optimum	149.3	69.01 m	149.32 m	149.32 m	150.31 m	315.14 m
	„Globales“ Optimum	71.8	58.94 m	58.94 m	59.94 m	59.94 m	616.15 m
Nacht	Gerade Linie	215.9	69.03 m	169.08 m	226.11 m	249.11 m	304.13 m
	Lokales Optimum	150.4	69.24 m	148.50 m	148.50 m	149.51 m	311.94 m
	„Globales“ Optimum	69.6	28.08 m	59.17 m	59.17 m	61.17 m	612.25 m
Regen	Gerade Linie	165.4	86.04 m	147.07 m	149.07 m	249.11 m	304.13 m
	Lokales Optimum	142.0	59.42 m	125.14 m	149.52 m	151.55 m	313.53 m
	„Globales“ Optimum	70.9	42.21 m	59.29 m	59.29 m	62.42 m	593.39 m
Stark- regen	Gerade Linie	135.5	59.03 m	117.06 m	124.06 m	175.08 m	304.13 m
	Lokales Optimum	120.9	51.01 m	97.23 m	113.47 m	151.25 m	313.58 m
	„Globales“ Optimum	69.6	30.14 m	59.28 m	59.28 m	66.06 m	588.00 m

Nebel	Gerade Linie	211.1	69.03 m	168.07 m	224.10 m	249.11 m	304.13 m
	Lokales Optimum	97.4	36.32 m	83.09 m	99.13 m	113.17 m	315.57 m
	„Globales“ Optimum	68.1	27.10 m	59.22 m	59.22 m	67.23 m	578.69 m

(Abbildung 4.29) und (Abbildung 4.30) zeigen den lokal und „global“ optimalen Annäherungspfad eines PKW an das Ego-Fahrzeug bei sonnigen Bedingungen. Der lokal optimale Annäherungspfad umgeht den Erfassungsbereich des LRR und geht an der Schnittstelle der Erfassungsbereiche mehrerer Sensoren geradlinig an die linke Frontecke des Ego-Fahrzeugs heran. Dieser Pfad weist im Vergleich zum Ausgangszustand (gerade Linie zwischen Start- und Endpunkt) einen deutlich geringen Gesamtwert der Kostenfunktion  $p_{D,value,path}$  auf und ist nur minimal länger. Der „global“ optimale Annäherungspfad umgeht die Erfassungsbereiche aller Sensoren an der Fahrzeugfront und der Fahrzeugseite und geht zentral an das Heck des Ego-Fahrzeugs heran. Dieser Pfad weist den minimalen Gesamtwert der Kostenfunktion  $p_{D,value,path}$  auf, ist im Vergleich aber doppelt so lang. Ähnliche Ergebnisse ergeben sich für die lokal und „global“ optimalen Annäherungspfade eines PKW an das Ego-Fahrzeug bei anderen Wetterbedingungen. Aus diesem Grund wird im Folgenden auf die Darstellung aller Wetterbedingungen verzichtet, die im Anhang ergänzend dargestellt sind. Überträgt man den lokal optimalen Annäherungspfad auf ein reales Verkehrsszenario, so könnte dieses wie folgt aussehen: das Ego-Fahrzeug befindet sich auf dem rechten Fahrsteifen einer 4-spurigen Autobahn, die bei x gleich 0 m eine Linkskurve mit dem Radius 900 m beschreibt. Der lokal optimale Annäherungspfad bewegt sich auf die Gegenfahrbahn und über die Straßengrenzen hinaus. Für einen Annäherungspfad, der sich innerhalb des Szenarios bewegt, müssen zusätzliche Nebenbedingungen definiert werden, die die Pfadpunkte innerhalb der Straßengrenzen beschränken.




Abbildung 4.29: Lokal optimaler Annäherungspfad eines PKW bei sonnigen Bedingungen






Abbildung 4.30: "Global" optimaler Annäherungspfad eines PKW bei sonnigen Bedingungen

(Abbildung 4.31) und (Abbildung 4.32) zeigen den lokal und „global“ optimalen Annäherungspfad eines PKW an das Ego-Fahrzeug bei nebligen Bedingungen. Der lokal optimale Annäherungspfad umgeht den Erfassungsbereich des LRR und der Frontkamera hinter der Windschutzscheibe und geht an der Schnittstelle der Erfassungsbereiche mehrerer Sensoren geradlinig an die linke Frontecke des Ego-Fahrzeugs heran. Der „global“ optimale Annäherungspfad umgeht die Erfassungsbereiche aller Sensoren an der Fahrzeugfront und der Fahrzeugseite und geht zentral an das Heck des Ego-Fahrzeugs heran.




Abbildung 4.31: Lokal optimaler Annäherungspfad eines PKW bei Nebel




Abbildung 4.32: "Global" optimaler Annäherungspfad eines PKW bei Nebel

Es zeigt sich, dass sich die lokal und „global“ optimalen Annäherungspfade an das Ego-Fahrzeug für die gewählten Startbedingungen und die festgelegte Sensortopologie bei verschiedenen Wetterbedingungen kaum verändern. Die Werte der Annäherungspfade ändern sich abhängig von den Wetterbedingungen gemäß (Tabelle 4.3) und entsprechen den in der Fernfelduntersuchung gewonnenen Erkenntnissen.

Bisher wurden die lokal und „global“ optimalen Annäherungspfade eines PKW an das Ego-Fahrzeug für einen Startpunkt berechnet der sich außerhalb des Erfassungsbereichs des Ego-Fahrzeugs befindet. Im Folgenden sollen die Annäherungspfade für einen Startpunkt berechnet werden, der sich bereits im Erfassungsbereich des Ego-Fahrzeugs befindet. Dieser wird im Rahmen der vorliegenden Arbeit willkürlich auf  $x = 150$  m und  $y = 0$  m festgelegt. Die Anzahl an Pfadpunkten bleibt bei 15, d.h. es befindet sich alle 10 m entlang der geraden Linie ein Pfadpunkt, wodurch im Vergleich zu den vorherigen Untersuchungen eine feinere Darstellung der Annäherungspfade möglich ist. Die lokal und „global“ optimalen Annäherungspfade eines PKW an das Ego-Fahrzeug werden bei sonnigen und bei nebligen Bedingungen untersucht. (Tabelle 4.4) fasst die Ergebnisse zusammen.

Tabelle 4.4: Auswertung der Berechnung optimaler Annäherungspfade für den Startpunkt (150,0)

		$p_{D,value,path}$	Kum. Distanz $p_D = 1$	Kum. Distanz $p_D > 0.75$	Kum. Distanz $p_D > 0.5$	Kum. Distanz $p_D > 0$	Gesamt- distanz
Sonne	Gerade Linie	152.6	116.67 m	150 m	150 m	150 m	150 m
	Lokales Optimum	152.6	116.67 m	150 m	150 m	150 m	150 m
	„Globales“ Optimum	152.6	116.67 m	150 m	150 m	150 m	150 m

Nebel + Nick-/ Wank- winkel +2°	Gerade Linie	150.3	87.50m	150 m	150 m	150 m	150 m
	Lokales Optimum	122.9	30.62 m	109.02 m	135.19 m	136.21 m	193.91 m
	„Globales“ Optimum	122.9	30.62 m	109.02 m	135.19 m	136.21 m	193.91 m

(Abbildung 4.33) zeigt den lokal und „global“ optimalen Annäherungspfad eines PKW an das Ego-Fahrzeug bei sonnigen Bedingungen. Lokal und „globale“ optimaler Annäherungspfad sind identisch und gehen ausgehend vom Startpunkt frontal an die Front des Ego-Fahrzeugs heran.

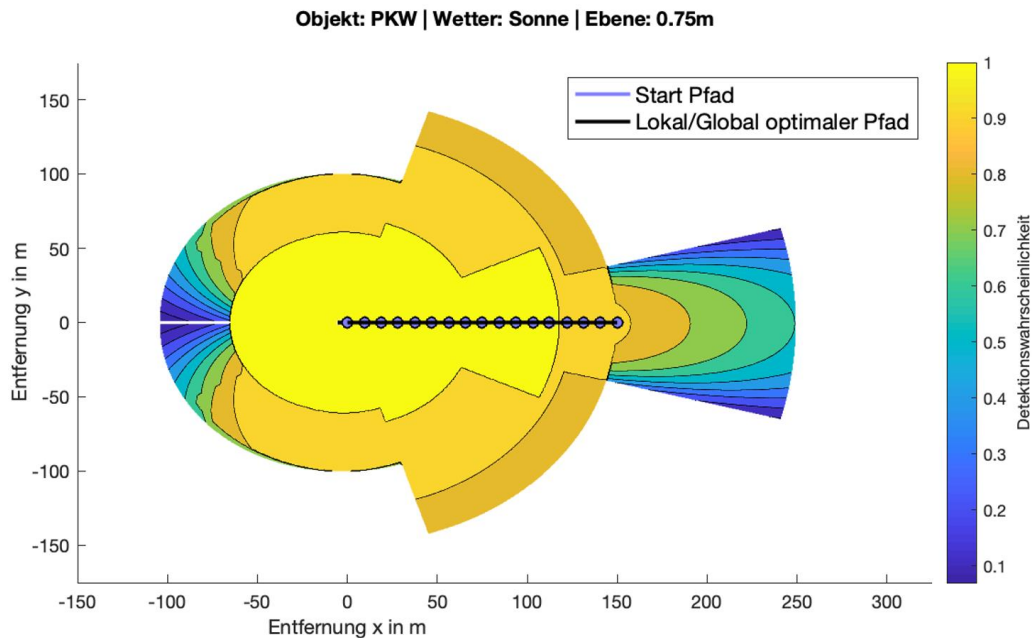


Abbildung 4.33: Lokal und "global" optimaler Annäherungspfad eines PKW bei sonnigen Bedingungen

(Abbildung 4.34) zeigt den lokal und „global“ optimalen Annäherungspfad eines PKW an das Ego-Fahrzeug bei sonnigen Bedingungen und einem permanenten Nickwinkel von +2° und einem permanenten Wankwinkel von +2° des Ego-Fahrzeugs. Lokal und „global“ optimaler Annäherungspfad sind identisch und gehen seitlich aus dem Erfassungsbereich des LLR heraus, um an der Schnittstelle der Erfassungsbereiche mehrerer Sensoren geradlinig an die rechte Frontecke des Ego-Fahrzeugs heran zu gehen. Dieser Pfad weist den minimalen Gesamtwert der Kostenfunktion  $p_{D,value,path}$  auf, ist im Vergleich aber ca. 25 % länger.

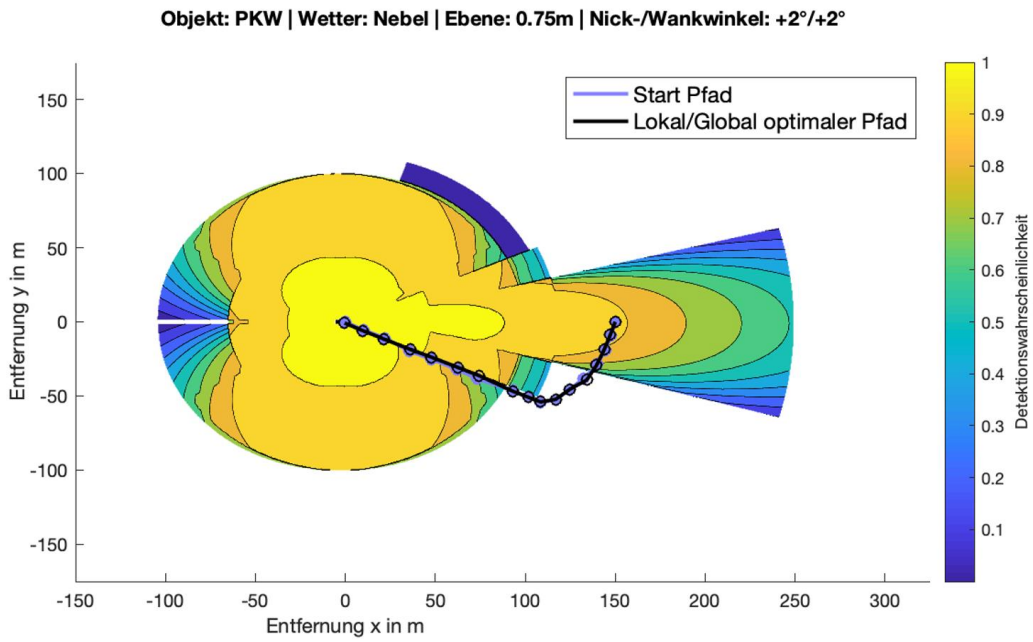


Abbildung 4.34: Lokal und "global" optimaler Annäherungspfad eines PKW bei Nebel und verändertem Fahrzeugzustand

(Abbildung 4.35) stellt einen Detailausschnitt dieses Szenarios dar und zeigt wie der Endpunkt der Annäherungspfade bei der Optimierung ebenfalls optimiert wird. Anstatt in der Mitte der Fahrzeugfront, befindet sich der Endpunkt an der rechten Frontecke des Ego-Fahrzeugs, wodurch sich der Annäherungspfad für ca. 0,5 m innerhalb einer blinden Stelle befindet.




Abbildung 4.35: Optimierung des Endpunkts der Annäherungspfade

## 4.4 Diskussion der Ergebnisse

Die im Rahmen der vorliegenden Arbeit durchgeführte Modellierung der Sensorabdeckung autonomer Fahrzeuge und Berechnung optimaler Annäherungspfade ist abhängig von der Sensortopologie, den Sensoreigenschaften, dem Detektionsobjekt, den Wetterbedingungen und der Höhe der Schnittebene in der diese betrachtet werden. Die Sensortopologie und die Sensoreigenschaften bestimmen den theoretischen und den tatsächlichen Erfassungsbereich des Ego-Fahrzeugs und bleiben in den durchgeführten Untersuchungen unverändert.

Der tatsächliche Erfassungsbereich des Ego-Fahrzeugs wird durch die angenommenen geometrischen Informationen der Sensoren bestimmt, d.h. die Detektionswahrscheinlichkeit wird nur bis zur maximalen angegebenen Reichweite innerhalb der angegebenen Öffnungswinkel in Azimuth und Elevation des Sensors berechnet. Außerhalb des durch die geometrischen Informationen aufgespannten theoretischen Erfassungsbereichs beträgt die Detektionswahrscheinlichkeit gleich null.

Wie die geometrischen Informationen der Sensoren definiert sind liegt bei den Sensorherstellern. So ist beispielsweise nicht bekannt, ob sich die maximale Reichweite auf die Detektion eines Menschen oder eines PKW bezieht, mit welcher Detektionswahrscheinlichkeit das Objekt innerhalb der maximalen Reichweite mindestens detektiert werden muss oder für welche Randbedingungen die angegebene maximale Reichweite gilt. Nimmt man beispielhaft an, dass für die Angabe der maximalen Reichweite das Detektionsobjekt mit einer Detektionswahrscheinlichkeit von mindestens 50% detektiert werden muss, so ergibt sich anhand der modellierten Sensormodelle eine maximale Reichweite des LRR von 89m bei einem Menschen als Detektionsobjekt und eine maximale Reichweite des LRR von 279 m bei einem PKW als Detektionsobjekt, vorausgesetzt es herrschen ideale Wetterbedingungen. Weil für den modellierten Fernbereichsradar (LRR) die angegebene Reichweite von 250 m verwendet wird, werden Bereiche in denen die Detektionswahrscheinlichkeit eines PKW gering ist nicht betrachtet. Durch die Verwendung der geometrischen Informationen der Sensoren ergeben sich somit Einschränkungen bei der Modellierung der Detektionswahrscheinlichkeit von Objekten.

Anhand des Beispiels zeigt sich ebenfalls der große Einfluss des Detektionsobjekts auf den tatsächlichen Erfassungsbereich des Ego-Fahrzeugs und die Detektionswahrscheinlichkeit des Objekts. So können beispielsweise in Fahrtrichtung PKW im Vergleich zu Menschen bereits in einer mehr als doppelt so großen Entfernung detektiert werden. In der Entfernung in Fahrtrichtung in der ein Mensch mit einer Detektionswahrscheinlichkeit von 50 % erkannt wird, wird ein PKW bereits mit einer Detektionswahrscheinlichkeit von 100 % erkannt. Im Nahfeld rund um das Ego-Fahrzeug hat das Detektionsobjekt keinen Einfluss. In diesem Bereich wird jedes der definierten Objekte mit einer Detektionswahrscheinlichkeit von 100 % erkannt.

Ebenso großen Einfluss auf den tatsächlichen Erfassungsbereich des Ego-Fahrzeugs und die Detektionswahrscheinlichkeit des Objekts haben die Wetterbedingungen. Abhängig von den Witterungsbedingungen und den Lichtverhältnissen verschlechtert sich die Leistungsfähigkeit der Sensoren oder diese fallen für die Objektdetektion komplett aus (z.B. Kamerasensoren, die durch die tiefstehende Sonne geblendet werden). Am stärksten ist die Detektionswahrscheinlichkeit eines Objekts bei Starkregen oder Nebel beeinflusst. Bei Starkregen ist die Leistungsfähigkeit aller Sensoren beeinflusst, wodurch der tatsächliche Erfassungsbereich des Ego-Fahrzeugs einschränkt wird und die Detektionswahrscheinlichkeit des Objekts abnimmt. Bei Nebel ist vor allem die Leistungsfähigkeit der Kamerasensoren und des Lidarsensors beeinflusst. Der tatsächliche Erfassungsbereich des Ego-Fahrzeugs wird nicht beeinflusst, der

Bereich mit einer Detektionswahrscheinlichkeit von 100 % rund um das Ego-Fahrzeug wird stark eingeschränkt. Im Nahfeld rund um das Ego-Fahrzeug haben die Wetterbedingungen keinen Einfluss. In diesem Bereich wird jedes der definierten Objekte mit einer Detektionswahrscheinlichkeit von 100 % erkannt, unabhängig von den Witterungsbedingungen.

Der Zustand des Ego-Fahrzeugs, d.h. der Nick- und Wankwinkel des Ego-Fahrzeugs haben einen Einfluss auf dessen tatsächlichen Erfassungsbereich, weil die Sensoren fest in ihrer Einbaulage verbaut sind und keine adaptive Anpassung an die Änderung des Fahrzeugzustands angenommen wird. Durch die Änderung des Nick- und Wankwinkels in dynamischen Fahrsituationen oder durch eine schlechte Beladung des Fahrzeugs ändert sich die Orientierung aller Sensoren, wodurch der tatsächliche Erfassungsbereich des Ego-Fahrzeugs einschränkt wird. Die Auswirkungen durch eine Änderung des Fahrzeugzustands ist jedoch nur bei Sensoren mit kleinen Erfassungsbereichen in Elevation erkennbar.

Die untersuchten Schnittebenen liegen auf unterschiedlichen Einbauhöhen der Sensoren, wodurch die entsprechenden Sensoren entlang ihrer Mittelachse geschnitten werden und ihre Erfassungsbereiche in dieser xy Ebene die maximalen Dimensionen beschreiben. Im Fernfeld hat dies kaum Einfluss auf den tatsächlichen Erfassungsbereich des Ego-Fahrzeugs. Im Nahfeld rund um das Fahrzeug, d.h. Bereiche die in keinem Erfassungsbereich eines Sensors liegen. Weil sich die Höhenabmessung aller definierten Objekte jedoch über alle untersuchten Schnittebenen erstreckt, werden die Objekte in allen diesen Schnittebenen geschnitten, wodurch sich die blinden Stellen bei der Objektdetektion auf die minimalen blinden Stellen des theoretischen Erfassungsbereichs des Ego-Fahrzeugs reduzieren. Für Objekte deren Höhenabmessung kleiner ist oder deren Abmessungen nicht von der Fahrbahn aus definiert sind, ist die Änderung der blinden Stellen in Abhängigkeit der Schnittebene relevant. Für die Detektion eines Balls der auf die Straße rollt beispielsweise, sind nur die blinden Stellen in den Schnittebenen  $z = 0$  m und  $z = 0,30$  m wesentlich.

Auf Basis der in der Fern- und Nahfelduntersuchung gewonnenen Erkenntnisse bezüglich der Abhängigkeiten der Detektionswahrscheinlichkeit von verschiedenen Faktoren, ergeben sich optimale Annäherungspfade an das Ego-Fahrzeug. Die optimalen Annäherungspfade unterteilen sich in lokale optimale Annäherungspfade und „globale“ optimale Annäherungspfade, abhängig von der zugrundeliegenden Optimierung. Die Annäherungspfade an sich ändern sich bei verschiedenen Wetterbedingungen kaum. Ihre Werte und die Detektionswahrscheinlichkeit des Objekts ändern sich abhängig vom Detektionsobjekt und den Wetterbedingungen.

Befindet sich der Startpunkt außerhalb des Erfassungsbereichs des Ego-Fahrzeugs, umgehen die „globalen“ optimalen Annäherungspfade die Erfassungsbereiche der meisten Sensoren und nähern sich frontal dem Heck des Ego-Fahrzeugs. Dabei umgehen sie das Ego-Fahrzeug in einer y Entfernung von bis zu 150 m, was in einem realistischen Verkehrsszenario nicht möglich ist. Die frontale Annäherung an das Heck des Ego-Fahrzeugs entspricht in einem realen Szenario einem Auffahrunfall. Für diese Art von Unfall ist jedoch das hinterherfahrende Fahrzeug verantwortlich und nicht das autonome Fahrzeug. Die „globalen“ optimalen Annäherungspfade stellen die optimalen Annäherungspfade an autonome Fahrzeuge dar, sind für die Definition von realistischen Verkehrsszenarien aber nur beschränkt zu gebrauchen. Um das Umgehen des Ego-Fahrzeugs zu vermeiden, kann der Faktor des zweiten Terms von Gl. (3.3) reduziert werden, um die Gewichtung der Pfadlänge zu vergrößern. Ebenso können die Annäherungspfade über entsprechende Nebenbedingungen eingeschränkt werden. Die ermittelten lokalen optimalen

Annäherungspfade liefern realistischere Annäherungspfade an das Ego-Fahrzeug und eignen sich als Grundlage für die Definition möglicher Worst-Case Szenarien.

Betrachtet man die optimalen Annäherungspfade im Nahfeldausschnitt rund um das Ego-Fahrzeug treffen diese an der Frontecke mit dem Ego-Fahrzeug zusammen, so dass sich den Annäherungspfad für einige Meter innerhalb einer blinden Stelle befindet. Diese blinde Stelle befindet sich in dieser Form jedoch nur in der betrachteten Höhe der Schnittebene. Für die Berechnung der optimalen Annäherungspfade eines Objekts an das autonome Fahrzeug im Nahfeld muss aus diesem Grund die Überlagerung der Schnittebenen verwendet werden.





# 5 Zusammenfassung und Ausblick

## 5.1 Zusammenfassung

Für die Absicherung und Freigabe autonomer Fahrzeuge muss theoretisch eine unendliche Anzahl an Testfällen abgeprüft werden, um alle Szenarien des realen Verkehrsgeschehens abzudecken. Selbst mit modernen Methoden und Simulationswerkzeugen ist der sich ergebende Testraum nicht beherrschbar. Aus diesem Grund bedarf es einer effizienten Absicherung autonomer Fahrzeuge, für die es aktuell noch keine passenden Konzepte gibt. Eine Möglichkeit bietet der szenariobasierte Ansatz, der nur die interessantesten und relevantesten Szenarien berücksichtigt, um den unendlichen Testraum auf eine endliche Anzahl an Testfällen einzugrenzen. Die Definition dieser sog. Worst-Case Szenarien stellt eine der großen Herausforderungen dar. Im Rahmen der vorliegenden Arbeit wurde dafür ein Berechnungsmodell entwickelt, das durch die Modellierung der Sensorabdeckung autonomer Fahrzeuge und die Berechnung optimaler Annäherungspfade Grundlagen für die Definition der Worst-Case Szenarien liefert.

Als entscheidende Einflussgröße wurde die Umfelderkennung autonomer Fahrzeuge identifiziert, die von den verwendeten Sensoren abhängt. Die Eigenschaften der Radar-, Ultraschall-, Lidar- und Kamerasensoren unterschieden sich entsprechend ihrem Funktionsprinzip. Es wurde gezeigt, dass sich die Sende- und Empfangscharakteristik, sowie die Leistungsfähigkeit aller Sensortechnologien durch Sensorgleichungen und Signal-Rauschverhältnisse ausdrücken lässt. Weil die Güte der Sensormodelle entscheidenden Einfluss auf die Ergebnisse des Berechnungsmodells hat, wurden phänomenologische Sensormodelle als vielversprechender Kompromiss zwischen Aussagekraft, Parametrierungsaufwand und Rechenzeit identifiziert. Im Rahmen der vorliegenden Arbeit wurden die Sensormodelle durch die hergeleiteten Sensorgleichungen und Signal-Rausch-Verhältnisse modelliert und in einem Evidence Based Sensor Coverage Model kombiniert, um die Fusion mehrerer verschiedener Sensoren zu ermöglichen. Um entsprechende physikalische Effekte phänomenologisch nachzubilden zu können, wurden Annahmen bezüglich der Sensoreigenschaften, der Antennencharakteristik, dem Detektionsobjekt, den Wetterbedingungen und den Receiver Operating Characteristics getroffen.

Anhand des entwickelten Berechnungsmodells wurde gezeigt, wie die Modellierung der Sensorabdeckung autonomer Fahrzeuge und die Berechnung optimaler Annäherungspfade beruhend auf den Sensormodellen möglich ist. Die Ergebnisse des Berechnungsmodells wurden in drei Untersuchungen unterteilt, um die verschiedenen Einflussgrößen auf den Erfassungsbereich autonomer Fahrzeuge und mögliche Annäherungspfade von Objekten an diese aufzuzeigen.

Abschließend wurden die Ergebnisse diskutiert, um zu zeigen in welcher Art und Weise sich das entwickelte Berechnungsmodell für die Definition von Worst-Case Szenarien eignet und welche Einschränkungen zu beachten sind.

## 5.2 Ausblick

Das entwickelte Berechnungsmodell ermöglicht die Darstellung und Bewertung verschiedener Einflüsse auf den Erfassungsbereich autonomer Fahrzeuge und auf die Annäherungspfade verschiedener Objekte an diese. Es eignet sich dadurch für die Untersuchung unterschiedlicher Szenarien, die als Grundlage für die Definition von Worst-Case Szenarien dienen können.

Innerhalb des Berechnungsmodells werden mehrere Vereinfachungen getroffen. Bei der Modellierung der Sensorabdeckung und der Berechnung der Detektionswahrscheinlichkeit eines Objekts werden die Geometrie und Materialeigenschaften der Objekte nicht berücksichtigt. Zum Beispiel wird die Farbe eines Objekts nicht berücksichtigt, obwohl diese die Absorption der ausgesendeten Strahlung beeinflusst oder den Kontrast der vom Kamerasensor aufgenommenen Bilder bestimmt. Ebenso wird nicht berücksichtigt, wie sich die Leistungsfähigkeit der Sensoren durch zusätzliche andere Objekte verändert, z.B. durch Interferenzen der ausgesendeten Strahlung bei der Reflexion an Leitplanken und der Einfahrt in Tunnel oder die Überlagerung der Sensorstrahlung mehrerer autonomer Fahrzeuge. Weiterhin wird ein freies Feld zwischen Sensor und Objekt angenommen, d.h. es werden keine Abschattungen der Objekte durch andere Objekte berücksichtigt.

Im Hinblick auf zukünftige Untersuchungen bietet sich hier ein Potential, um die Aussagekraft der Ergebnisse des Berechnungsmodells zu erhöhen und weitere Kritikalitäten bei der Betrachtung unterschiedlicher Szenarien zu berücksichtigen. Besonders die Implementierung der Orientierung der Objekte und die Berücksichtigung der Abschattung verspricht einen großen Informationsgewinn. Mit zusätzlichen Nebenbedingungen bei der Optimierung können durch die Berechnung optimaler Annäherungspfade anhand des entwickelten Berechnungsmodells detaillierte Aussagen für die Definition möglicher Worst-Case Szenarien getroffen werden. Mögliche Nebenbedingungen hierfür sind beispielsweise hinterlegte Funktionen, die die Fahrphysik realer Fahrzeuge beschreiben oder Nebenbedingungen, die die Optimierung der Pfadpunkte innerhalb vorgegebener Straßengrenzen beschränken.

# Abbildungsverzeichnis

Abbildung 1.1:	Unterschied zwischen konventionellen und autonomen Fahrzeugen (nach Rasmussen und Donges) [5], [7].....	2
Abbildung 1.2:	Aufbau der vorliegenden Arbeit .....	4
Abbildung 2.1:	Entwicklung von sicherheitsrelevanten Systemen anhand des V-Modells [18, S. 10].....	8
Abbildung 2.2:	Sende- und Empfangssignal beim Impulsradar [28, S. 13] .....	9
Abbildung 2.3:	Sende- und Empfangssignal beim FMCW-Radar [28, S. 16].....	10
Abbildung 2.4:	Richtcharakteristik einer Radarantenne [34, S. 17] .....	11
Abbildung 2.5:	Antennendiagramm des Bosch LRR 3 [35, S. 2378].....	12
Abbildung 2.6:	Nah- und Fernfeld eines Ultraschallsensors [18, S. 46] .....	15
Abbildung 2.7:	Verwendung mehrerer Laserscanner in einem Lidarsensor [47, S. 613] .....	17
Abbildung 2.8:	Einfluss der Auflösung eines Kamerasensors [44, S. 150].....	19
Abbildung 2.9:	Gegenüberstellung verschiedener Sensortechnologien [15, S. 34] .....	21
Abbildung 2.10:	Vergleich der Eigenschaften verschiedener Sensortechnologien .....	23
Abbildung 2.11:	Vergleich verschiedener Fusionsmethoden [60, S. 62] .....	24
Abbildung 2.12:	Evidence Based Sensor Coverage Model [66, S. 1463] .....	28
Abbildung 2.13:	Unterscheidung globaler und lokaler Optima innerhalb festgelegter Restriktionen.....	30
Abbildung 3.1:	Sensortopologie des Audi A8 [75] .....	35
Abbildung 3.2:	Abmessungen des Audi A8 [76] .....	35
Abbildung 3.3:	Antennendiagramm des Bosch LRR 3 [35, S. 2378].....	40
Abbildung 3.4:	Antennendiagramm des Continental SRR 200 [26, S. 307] .....	40
Abbildung 3.5:	Vergleich verschiedener Reflexionsarten .....	41
Abbildung 3.6:	Rückstreuquerschnitte eines PKW [89, S. 848].....	42
Abbildung 3.7:	Spezifische Dämpfung für verschiedene Frequenzen bei unterschiedlichen Witterungsbedingungen [58, S. 6] .....	43
Abbildung 3.8:	Erforderliche SNR-Werte bei unterschiedlichen Witterungsbedingungen [97, S. 7] .....	45
Abbildung 3.9:	Schematischer Aufbau des Berechnungsmodells .....	46

Abbildung 4.1:	Dreidimensionale Darstellung des theoretischen Erfassungsbereichs.....	52
Abbildung 4.2:	Theoretischer Erfassungsbereich des Ego-Fahrzeugs aus der Vogelperspektive .....	52
Abbildung 4.3:	Einfluss der Schnittebene auf den tatsächlichen Erfassungsbereich im Fernfeld .....	53
Abbildung 4.4:	Detektionswahrscheinlichkeit eines Menschen bei sonnigen Bedingungen im Fernfeld .....	54
Abbildung 4.5:	Detektionswahrscheinlichkeit eines Motorrads bei sonnigen Bedingungen im Fernfeld .....	55
Abbildung 4.6:	Detektionswahrscheinlichkeit eines PKW bei sonnigen Bedingungen im Fernfeld .....	55
Abbildung 4.7:	Detektionswahrscheinlichkeit eines LKW bei sonnigen Bedingungen im Fernfeld .....	56
Abbildung 4.8:	Breite der Fahrstreifen einer 4-spurigen Autobahn [98] .....	56
Abbildung 4.9:	Detektionswahrscheinlichkeit eines PKW beim Überholvorgang bei sonnigen Bedingungen .....	58
Abbildung 4.10:	Detektionswahrscheinlichkeit eines PKW beim Überholvorgang bei tiefstehender Sonne .....	58
Abbildung 4.11:	Detektionswahrscheinlichkeit eines PKW beim Überholvorgang bei Nacht .	59
Abbildung 4.12:	Detektionswahrscheinlichkeit eines PKW beim Überholvorgang bei Regen	60
Abbildung 4.13:	Detektionswahrscheinlichkeit eines PKW beim Überholvorgang bei Starkregen .....	60
Abbildung 4.14:	Detektionswahrscheinlichkeit eines PKW beim Überholvorgang bei Nebel .	61
Abbildung 4.15:	Einfluss des Fahrzeugzustands auf die Detektionswahrscheinlichkeit eines PKW beim Überholmanöver .....	62
Abbildung 4.16:	Detektionswahrscheinlichkeit eines PKW beim Überholvorgang bei Nebel und verändertem Fahrzeugzustand .....	62
Abbildung 4.17:	Einfluss des Detektionsobjekts auf die Detektionswahrscheinlichkeit im Nahfeld .....	63
Abbildung 4.18:	Einfluss der Wetterbedingungen auf die Detektionswahrscheinlichkeit im Nahfeld .....	64
Abbildung 4.19:	Theoretischer Erfassungsbereich im Nahfeld des Ego-Fahrzeugs aus der Vogelperspektive .....	64
Abbildung 4.20:	Detektionswahrscheinlichkeit eines Menschen im Nahfeld in der Schnittebene 0.00 m.....	65
Abbildung 4.21:	Detektionswahrscheinlichkeit eines Menschen im Nahfeld in der Schnittebene 0.30 m.....	66
Abbildung 4.22:	Detektionswahrscheinlichkeit eines Menschen im Nahfeld in der Schnittebene 0.60 m.....	66

---

Abbildung 4.23: Detektionswahrscheinlichkeit eines Menschen im Nahfeld in der Schnittebene 1.00 m.....	67
Abbildung 4.24: Detektionswahrscheinlichkeit eines Menschen im Nahfeld in der Schnittebene 1.30 m.....	67
Abbildung 4.25: Detektionswahrscheinlichkeit eines Menschen im Nahfeld bei der Überlagerung der Schnittebenen.....	68
Abbildung 4.26: Lage und Größe der blinden Stellen bei der Überlagerung der Schnittebenen .....	68
Abbildung 4.27: Lokale Pfadoptimierung.....	70
Abbildung 4.28: "Globale" Pfadoptimierung .....	70
Abbildung 4.29: Lokal optimaler Annäherungspfad eines PKW bei sonnigen Bedingungen .	72
Abbildung 4.30: "Global" optimaler Annäherungspfad eines PKW bei sonnigen Bedingungen .....	73
Abbildung 4.31: Lokal optimaler Annäherungspfad eines PKW bei Nebel.....	73
Abbildung 4.32: "Global" optimaler Annäherungspfad eines PKW bei Nebel .....	74
Abbildung 4.33: Lokal und "global" optimaler Annäherungspfad eines PKW bei sonnigen Bedingungen .....	75
Abbildung 4.34: Lokal und "global" optimaler Annäherungspfad eines PKW bei Nebel und verändertem Fahrzeugzustand .....	76
Abbildung 4.35: Optimierung des Endpunkts der Annäherungspfade .....	76



# Tabellenverzeichnis

Tabelle 2.1:	Definition der Automatisierungsgrade (nach BAST und SAE) [12], [13].....	6
Tabelle 3.1:	Positionen der Sensoren des Audi A8.....	36
Tabelle 3.2:	Ausführungsbeispiele für Mittel- und Fernbereichsradarsensoren .....	37
Tabelle 3.3:	Ausführungsbeispiele für Ultraschall-, Lidar- und Kamerasensoren .....	37
Tabelle 3.4:	Sensoreigenschaften der Sensormodelle.....	38
Tabelle 3.5:	Polynome der angenäherten Leistungsverteilung .....	40
Tabelle 3.6:	Rückstreuquerschnitte von Objekten im Straßenverkehr .....	42
Tabelle 3.7:	Spezifische Dämpfung verschiedener Sensoren bei unterschiedlichen Witterungsbedingungen .....	44
Tabelle 3.8:	Leistungsdichte der Sonnenstrahlung bei verschiedenen Witterungsbedingungen .....	44
Tabelle 4.1:	Auswertung der frühesten möglichen Objektdetektion bei sonnigen Bedingungen .....	53
Tabelle 4.2:	Auswertung des Überholmanövers eines PKW bei verschiedenen Wetterbedingungen .....	57
Tabelle 4.3:	Auswertung der Berechnung optimaler Annäherungspfade für den Startpunkt (300,50) .....	71
Tabelle 4.4:	Auswertung der Berechnung optimaler Annäherungspfade für den Startpunkt (150,0) .....	74





# Literaturverzeichnis

- [1] D. Fagnant und K. Kockelmann, "PREPARING A NATION FOR AUTONOMOUS VEHICLES: OPPORTUNITIES, BARRIERS AND POLICY RECOMMENDATIONS FOR CAPITALIZING ON SELF-DRIVEN VEHICLES," *Transportation Research*, Rn. Part A: 77, S. 167–181, 2015.
- [2] National Highway Traffic Safety Administration, "Critical Reasons for Crashes Investigated in the National Motor Vehicle Crash Causation Survey," 2015.
- [3] J. van Brummelen, M. O'Brien, D. Gruyer, Najjaran, und Homayoun, "Autonomous vehicle perception: The technology of today and tomorrow," *Transportation Research*, Rn. Part C 89, S. 384–406, 2018.
- [4] I. Y. Noy, D. Shinar, und W. J. Horrey, "Automated driving: Safety blind spots," *Safety Science*, Rn. 102, S. 68–78, 2018.
- [5] J. Rasmussen, "Skills, Rules, and Knowledge: Signals, Signs, and Symbols, and Other Distinctions in Human Performance Models," *IEEE TRANSACTIONS ON SYSTEMS, MAN AND CYBERNETICS*, Rn. Vol. 13, No. 3, S. 257–266, 1983.
- [6] W. Bernhart, "Automatisiertes Fahren – Evolution statt Revolution," *ATZ extra*, Rn. 04/2015, S. 12–16, 2015.
- [7] E. Donges, "Aspekte der Aktiven Sicherheit bei der Führung von Personenkraftwagen," *Automobil-Industrie*, S. 183–190, 1982.
- [8] C. Müller und B. Butting, "Von der Simulation auf die Straße: Fahrerassistenzsysteme sicher getestet," *ATZ extra*, Rn. 08/2016, S. 24–29, 2016.
- [9] M. Henzel, H. Winner, und B. Lattke, "Herausforderungen in der Absicherung von Fahrerassistenzsystemen bei der Benutzung maschinell gelernter und lernender Algorithmen," *Walting im Altmühltal*, 2017.
- [10] M. Hirz und B. Walzel, "Sensor and Object recognition technologies for self-driving cars," *Computer-Aided Design & Applications*, Rn. 4, S. 501–508, 2018.
- [11] H. Winner, "Introducing autonomous driving: an overview of safety challenges and market introduction strategies," *Automatisierungstechnik*, Rn. 66(2), S. 100–106, 2018.
- [12] Bundesanstalt Für Straßenwesen, "Rechtsfolgen zunehmender Fahrzeugautomatisierung," 2012.
- [13] *Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles*, SAE J3016\_201806.
- [14] Die Bundesregierung, *Automatisiertes Fahren auf dem Weg*. [Online] Verfügbar: <https://www.bundesregierung.de/breg-de/aktuelles/automatisiertes-fahren-auf-dem-weg-326108>. Gefunden am: Nov. 06 2018.

- [15] J. Schrepfer, J. Mathes, V. Picron, und H. Barth, "Automatisiertes Fahren und seine Sensorik im Test," *ATZ*, Rn. 01/2018, S. 28–37, 2018.
- [16] M. Feilhauer und J. Häring, "Anwendungsorientierte Absicherungsstrategie für Fahrerassistenzsysteme," *ATZ extra*, Rn. 07/2017, S. 32–35, 2017.
- [17] P. Koopman und M. Wagner, "Challenges in Autonomous Vehicle Testing and Validation," 2016.
- [18] D. Tellmann, *Hardware-in-the-Loop-gestützte Entwicklungsplattform für Fahrerassistenzsysteme: Modelle der Umfeldsensorik und angepasste Fahrermodelle*: Kassel University Press, 2012.
- [19] S. Bernsteiner, Z. Magosi, D. Lindvai-Soos, und A. Eichberger, "Radarsensormodell für den virtuellen Entwicklungsprozess," *ATZ*, Rn. 02/2015, S. 72–79, 2015.
- [20] H. Winner, "Absicherung automatischen Fahrens," München, Nov. 29 2013.
- [21] W. Wachenfeld, "How Stochastic can Help to Introduce Automated Driving," Dissertation, Fachbereich Maschinenwesen, Technische Universität Darmstadt, Darmstadt, 2016.
- [22] Pegasus, *Forschungsprojekt PEGASUS*. [Online] Verfügbar: <https://www.pegasusprojekt.de/de/>. Gefunden am: Jun. 14 2018.
- [23] S. Scholz, "Effiziente systematische Testgenerierung für Fahrerassistenzsysteme in virtuellen Umgebungen," 2013.
- [24] S. Rauch, M. Aeberhard, M. Ardelt, und N. Kämpchen, "Autonomes Fahren auf der Autobahn – Eine Potentialstudie für zukünftige Fahrerassistenzsysteme," 2012.
- [25] J. Steinbaeck, C. Steger, Holweg Gerald, und N. Druml, "Next Generation Radar Sensors in Automotive Sensor Fusion Systems," 2017.
- [26] H. Winner, S. Hakuli, F. Lotz, und C. Singer, Hrsg, *Handbuch Fahrerassistenzsysteme: Grundlagen, Komponenten und Systeme für aktive Sicherheit und Komfort*, 3rd Aufl.: Springer Vieweg, 2015.
- [27] F. Müller de Ponte, "Survey on Ranging Sensors and Cooperative Techniques for Relative Positioning of Vehicles," *Sensors*, Bd. 2017, Rn. 17/271, S. 1–27.
- [28] S. Pietzsch, "Modellgestützte Sensordatenfusion von Laserscanner und Radar zur Erfassung komplexer Fahrzeugumgebungen," Dissertation, Fakultät für Informatik, Technische Universität München, München, 2015.
- [29] I. Stroh, *Radar - ein großer Wachstumsmarkt*. [Online] Verfügbar: <https://www.elektroniknet.de/markt-technik/automotive/radar-ein-grosser-wachstumsmarkt-113386.html>. Gefunden am: Nov. 06 2018.
- [30] B. Shaffer und B. Kirchbeck, *Kfz-Radarsysteme - Die Gründe für den Wechsel von 24 GHz auf 77 GHz*. [Online] Verfügbar: <https://www.next-mobility.news/kfz-radarsysteme-die-gruende-fuer-den-wechsel-von-24-ghz-auf-77-ghz-a-698641/>. Gefunden am: Nov. 06 2018.
- [31] G. Rudolph und U. Voelzke, *Three Sensor Types Drive Autonomous Vehicles*. [Online] Verfügbar: <https://www.sensorsmag.com/components/three-sensor-types-drive-autonomous-vehicles>. Gefunden am: Jun. 03 2018.

- 
- [32] D. Wittmann, "Erkennung und Prädiktion anderer Verkehrsteilnehmer," Masterarbeit, Lehrstuhl für Fahrzeugtechnik, Technische Universität München, München, 2013.
- [33] F. Pfeiffer, "Analyse und Optimierung von Radomen für automobiler Radarsensoren," Dissertation, Fakultät für Elektrotechnik und Informationstechnik, Technische Universität München, München, 2010.
- [34] M. Grgic, "Generic Radar Model for Automotive Applications," Masterarbeit, Fakultät für Elektrotechnik, TU Graz, Graz, 2015.
- [35] W. Menzel und A. Moebius, "Antenna Concepts for Millimeter-Wave Automotive Radar Sensors," *Proceedings of the IEEE*, Rn. Vol. 100, No. 7, S. 2372–2379, 2012.
- [36] O. Günther, "Modellierung und Leakage-Kompensation von 77GHz FMCW-Weitbereichsradar-Transceivern in SiGe-Technologie für Kfz-Anwendungen," Dissertation, Technische Fakultät, Universität Erlangen-Nürnberg, Nürnberg, 2008.
- [37] J. Jotzo, "Aktive Landmarken zur Positionsbestimmung von autonomen Fahrzeugen," Dissertation, Fakultät für Elektrotechnik und Informationstechnik, Technische Universität Chemnitz, Chemnitz, 2001.
- [38] A. Ludloff, *Praxiswissen Radar und Radarsignalverarbeitung*: Vieweg + Teubner, 1998.
- [39] L. V. Blake, *Radar Range-Performance Analysis*: Artech House, 1986.
- [40] R. Lerch, G. Sessler, und D. Wolf, *Technische Akustik: Grundlagen und Anwendungen*: Springer, 2009.
- [41] O. Sonbul und A. Kalashnikov, "DETERMINING THE OPERATING DISTANCE OF AIR ULTRASOUND RANGE FINDERS: CALCULATIONS AND EXPERIMENTS," *International Journal of Computing*, Rn. 13 (2), S. 125–131, 2014.
- [42] R. H. Rasshofer und K. Gresser, "Automotive Radar and Lidar Systems for Next Generation Driver Assistance Functions," *Advances in Radio Science*, Rn. 3, S. 205–209, 2005.
- [43] R. R. H, S. M, und S. H, "Influences of weather phenomena on automotive laser radar systems," *Advances in Radio Science*, Rn. 9, S. 49–60, 2011.
- [44] C. H. Jang, C. S. Kim, K. C. Jo, und M. Sunwoo, "DESIGN FACTOR OPTIMIZATION OF 3D FLASH LIDAR SENSOR BASED ON GEOMETRICAL MODEL FOR AUTOMATED VEHICLE AND ADVANCED DRIVER ASSISTANCE SYSTEM APPLICATIONS," *International Journal of Automotive Technology*, Rn. Vol.18, No.1, S. 147–156, 2017.
- [45] B. Christmann, "Empfindliche Sensoren verleihen Autos Durchblick," *MM Maschinenmarkt*, Rn. KW48, S. 64–65, 2016.
- [46] D. Göhring, M. Wang, und M. Schnürmacher, "Radar/Lidar Sensor Fusion for Car-Following on Highways," 2011.
- [47] R. Philipp, Martin Holder, Marina Zirulnik, und Hermann Winner, "Analysis of Real World Sensor Behavior for Rising Fidelity of Physically Based Lidar Sensor Models," *IEEE Intelligent Vehicles Symposium*, S. 611–616, 2018.
- [48] W. Wagner, A. Ullrich, und C. Briese, "Der Laserstrahl und seine Interaktion mit der Erdoberfläche," *Österreichische Zeitschrift für Vermessung und Geoinformation*, Rn. 91(4), S. 223–235, 2003.

- [49] R. D. Richmond und S. C. Cain, *Direct-detection LADAR systems*: SPIE Press, 2010.
- [50] C. Tristan K, S. K. Clint, C. William E, und S. Kris Y, "Predicting Small Target Detection Performance of Low-SNR Airborne Lidar," *IEEE JOURNAL OF SELECTED TOPICS IN APPLIED EARTH OBSERVATIONS AND REMOTE SENSING*, Rn. Vol. 3, No. 4, 672-688, 2010.
- [51] A. Sameh, S. David, A. Mark, M. Fred, und A. Sam, "Signal to Noise Ratio Characterization of Coherent Doppler Lidar Backscattered Signals," 2016.
- [52] M. Hayat und G. Dong, "A New Approach for Computing the Bandwidth Statistics of Avalanche Photodiodes," *IEEE TRANSACTIONS ON ELECTRON DEVICES*, Rn. Vol. 47, No. 6, S. 1273–1279, 2000.
- [53] R. Lange und P. Seitz, "Solid-State Time-of-Flight Range Camera," *IEEE JOURNAL OF QUANTUM ELECTRONICS*, Rn. Vol. 37, No. 3, S. 390–397, 2001.
- [54] G. Stein, O. Mano, und A. Shashua, "Vision-based ACC with a Single Camera: Bounds on Range and Range Rate Accuracy," 2003.
- [55] R. Lange, "3D Time-of-flight distance measurement with custom solid-state image sensors in CMOS/CCD-technology," Dissertation, Fakultät für Elektrotechnik und Informationstechnik, Universität Siegen, Siegen, 2000.
- [56] T. Schmidt, "Kameratechnik muss besser werden: Autonomes Fahren," *Krafthand*, Rn. 12/2017, S. 40, 2017.
- [57] M. Feilhauer und J. Häring, "A real-time capable multi-sensor model to validate ADAS in a virtual environment," Wiesbaden, 2017.
- [58] S. Hasirlioglu und A. Riener, "Introduction to Rain and Fog Attenuation on Automotive Surround Sensors," 2017.
- [59] H. Cho, Y.-W. Seo, V. Kumar, und R. Rajkumar, "A Multi-Sensor Fusion System for Moving Object Detection and Tracking in Urban Driving Environments," *IEEE International Conference on Robotics & Automation*, S. 1836–1843, 2014.
- [60] K. Dietmayer, A. Kirchner, N. Kämpchen, M. Maurer, und C. Stiller, *Fahrerassistenzsysteme mit maschineller Wahrnehmung*: Springer, 2005.
- [61] R. Schubert, N. Mattern, und R. Bours, "SIMULATION OF SENSOR MODELS FOR THE EVALUATION OF ADVANCED DRIVER ASSISTANCE SYSTEMS," *ATZ*, Rn. 03/2014, S. 26–29, 2014.
- [62] P. Cao, "Modeling Active Perception Sensors for Real-Time Virtual Validation of Automated Driving Systems," Dissertation, Fachbereich Maschinenbau, Technische Universität Darmstadt, Darmstadt, 2017.
- [63] S. Hafner, "Echtzeitsimulation von ADAS-Sensoren," *HANSER automotive*, Rn. 7-8, S. 10–12, 2015.
- [64] B. Wang, *Coverage Control in Sensor Networks*: Springer, 2010.
- [65] M. Boudaren, M. Senouci, M. Senouci, und Mellouk Abdelhamid, "New Trends in Sensor Coverage Modeling and Related Techniques: a Brief Synthesis," 2014.

- [66] M. Senouci, A. Mellouk, L. Oukhellou, und A. Aissani, "An Evidence-Based Sensor Coverage Model," *IEEE COMMUNICATIONS LETTERS*, Rn. Vol. 16, No. 9, S. 1462–1465, 2012.
- [67] C. Jiming, L. Junkun, H. Shibo, und S. Youxian, "Energy-Efficient Coverage Based on Probabilistic Sensing Model in Wireless Sensor Networks," *IEEE COMMUNICATIONS LETTERS*, Rn. Vol. 14, No. 9, S. 833–835, 2010.
- [68] Z. Elouedi, K. Mellouli, und P. Smets, "Assessing Sensor Reliability for Multisensor Data Fusion Within the Transferable Belief Model," *IEEE TRANSACTIONS ON SYSTEMS, MAN AND CYBERNETICS*, Rn. Vol. 34, No. 1, S. 782–787, 2004.
- [69] M. Senouci, A. Mellouk, M. Senouci, und L. Oukhellou, "Belief functions in telecommunications and network technologies: an overview," *Ann. Telecommun*, Rn. 69, S. 135–145, 2014.
- [70] M. PIEPER, *Mathematische Optimierung: Eine Einführung in die kontinuierliche Optimierung mit Beispielen*: Springer, 2017.
- [71] R. Burkard und U. Zimmermann, *Einführung in die Mathematische Optimierung*: Springer, 2012.
- [72] L. Cromme, "Computerbasierte Mathematische Modellierung," Unterlagen zur Vorlesung, Lehrstuhl Mathematik, Brandenburgische Technische Universität Cottbus, Cottbus, 2010.
- [73] H. Benker, *Ingenieurmathematik kompakt - Problemlösungen mit MATLAB: Einstieg und Nachschlagewerk für Ingenieure und Naturwissenschaftler*: Springer, 2010.
- [74] G. Schiele, "Der neue Audi A8 - ADAS Next Level," *International AVL Conference "Engine & Environment"*, S. 65–74, 2018.
- [75] Audi AG, *Sensorfelder der Umfeldüberwachung*. [Online] Verfügbar: <https://www.audi-mediacentre.com/de/fotos/detail/sensorfelder-der-umfeldueberwachung-52926>. Gefunden am: Nov. 02 2018.
- [76] Audi AG, *Audi A8: Abmessungen*. [Online] Verfügbar: <https://www.audi.de/de/brand/de/neuwagen/a8/a8/layer/layer-dimensions.html>. Gefunden am: Nov. 05 2018.
- [77] Bosch, "Fourth generation long-range radar sensor (LRR4)," 2014.
- [78] Bosch, "Long-Range-Radar LRR3: Radar sensor for railway applications," 2010.
- [79] Continental, "ARS 30X /-2 /-2C/-2T/-21 Long Range Radar," 2009.
- [80] Bosch, "Mittelbereichsradarsensor (MRR) für Front- und Heckanwendungen," 2015.
- [81] Continental, "SRR 20X /-2 /-2C /-21 Short Range Radar," 2012.
- [82] Bosch, "Ultraschallbasierte Fahrerassistenzsysteme: Ultraschallsensoren, Generation 6," 2018.
- [83] Ibeo Automotive, "ibeo ScaLa B3.0: Data Sheet," 2018.
- [84] Bosch, "Videobasierte Fahrerassistenzsysteme: Nahbereichskamera-Systeme," 2017.
- [85] Bosch, "Videobasierte Fahrerassistenzsysteme: Multifunktionskamera, 2. Generation," 2017.

- [86] C. Wang, R. Qian, Y. Ming-hui, und Y. Sun, "A Low Cost 24-GHz FMCW Radar for Automobile Application," 2006.
- [87] Tesla, *Hardware für autonomes Fahren in allen Fahrzeugen*.
- [88] ProWave, "Air Ultrasonic Ceramic Transducers 400PT160," 2018.
- [89] J. Hasch *et al*, "Millimeter-Wave Technology for Automotive Radar Sensors in the 77 GHz Frequency Band," *IEEE TRANSACTIONS ON MICROWAVE THEORY AND TECHNIQUES*, Rn. Vol. 60, No. 3, S. 845–860, 2012.
- [90] E. Kamel, A. Peden, und P. Pajusco, "RCS Modeling and Measurements for Automotive Radar Applications in the W Band," *11th European Conference on Antennas and Propagation*, S. 2445–2449, 2017.
- [91] I. Matsunami, R. Nakamura, und A. Kajiwara, "RCS Measurements for Vehicles and Pedestrian at 26 and 79GHz," 2012.
- [92] T. Schipper, J. Fortuny-Guasch, D. Tarchi, L. Reichardt, und T. Zwick, "RCS Measurement Results for Automotive Related Objects at 23-27 GHz," *Proceedings of the 5th European Conference on Antennas and Propagation*, S. 683–686, 2011.
- [93] H. Ruser, "Ultraschall-Mikrowellen-Sensorsystem zur Geschwindigkeits- und Abstandsmessung mit diversitär redundanter Auswertung der Phasensignale," Dissertation, Fakultät für Elektrotechnik und Informationstechnik, Universität der Bundeswehr München, München, 2003.
- [94] Loeti, *Globalstrahlung*. [Online] Verfügbar: <https://www.sbz-monteur.de/2013/06/05/erklar-mal-globalstrahlung/>. Gefunden am: Nov. 03 2018.
- [95] Math Works, *Albersheim: Required SNR using Albersheim's equation*. [Online] Verfügbar: [https://de.mathworks.com/help/phased/ref/albersheim.html?searchHighlight=albersheim&s\\_tid=doc\\_srchtile](https://de.mathworks.com/help/phased/ref/albersheim.html?searchHighlight=albersheim&s_tid=doc_srchtile). Gefunden am: Nov. 03 2018.
- [96] Math Works, *Receiver Operating Characteristics*. [Online] Verfügbar: [https://de.mathworks.com/help/phased/ug/receiver-operating-characteristic-roc-curves.html?searchHighlight=rocsnr&s\\_tid=doc\\_srchtile](https://de.mathworks.com/help/phased/ug/receiver-operating-characteristic-roc-curves.html?searchHighlight=rocsnr&s_tid=doc_srchtile). Gefunden am: Nov. 06 2018.
- [97] S. Bernsteiner, Z. Magosi, und A. Eichberger, "Phänomenologisches Radarsensormodell zur Simulation längsdynamisch regelnder Fahrerassistenzsysteme," 2013.
- [98] Wikipedia, *Richtlinien für die Anlage von Autobahnen*. [Online] Verfügbar: [https://de.wikipedia.org/wiki/Richtlinien\\_für\\_die\\_Anlage\\_von\\_Autobahnen](https://de.wikipedia.org/wiki/Richtlinien_für_die_Anlage_von_Autobahnen). Gefunden am: Nov. 08 2018.

# Anhang

Abbildung A 1:	Lokal optimaler Annäherungspfad eines PKW bei Nacht.....	xiv
Abbildung A 2:	Lokal optimaler Annäherungspfad eines PKW bei Regen .....	xiv
Abbildung A 3:	Lokal optimaler Annäherungspfad eines PKW bei Starkregen.....	xv

# Anhang A Pfadoptimierung




Abbildung A 1: Lokal optimaler Annäherungspfad eines PKW bei Nacht




Abbildung A 2: Lokal optimaler Annäherungspfad eines PKW bei Regen






Abbildung A 3: Lokal optimaler Annäherungspfad eines PKW bei Starkregen