

Umgebungsmodellierung mit Radarsensoren und gestörten Sichtbedingungen

Von der Fakultät für Elektrotechnik und Informatik
der Gottfried Wilhelm Leibniz Universität Hannover zur Erlangung des Grades

Doktor der Ingenieurwissenschaft

Dr.-Ing.

genehmigte Dissertation von

M. Sc. Paul Fritsche

Erscheinungs- bzw. Druckjahr: 2019

Referent: Prof. Dr.-Ing. Bernardo Wagner

Korreferent: Prof. Dr.-Ing. Holger Blume

Tag der Promotion: 30.10.2019

I Kurzfassung

Ein mobiler Roboter benötigt ein Abbild seiner Umgebung, um eine autonome Navigation durchzuführen. Dieses Abbild, das sogenannte Umgebungsmodell, kann Objekte und Landmarken oder abstrakte Informationen beinhalten, wie topologische Beziehungen. Für diesen Zweck muss der Roboter mit seiner Sensorik sein Umfeld erfassen und die Sensordaten aufbereiten. Dabei stellen feste und flüssige Schwebeteilchen (Aerosole) für die mobile Robotik ein Problem dar. Zum Beispiel verdeckt aufgewirbelter Staub die Sicht für RGB-Kameras in der Agrar- und Bergbaurobotik, Rauch und Feuer beeinträchtigt die Messwerte von LiDAR¹-Scannern in der Search-and-Rescue-Robotik und schlechte Witterungsbedingungen (Regen, Schnee, Nebel) sind typische Probleme für autonome Straßenfahrzeuge. Dementsprechend liefern populäre Sensoren, wie LiDAR-Scanner, unter diesen Bedingungen nicht genügend brauchbare Messwerte, um die Kernkompetenzen eines autonom fahrenden Systems (Kartierung, Lokalisierung und Navigation) auszuführen. Daher ist die Integration von Sensortypen, die nicht von Aerosolen beeinträchtigt werden, erforderlich, um auch hier Umgebungsmodelle zu erstellen.

In diesem Zusammenhang beschäftigt sich diese Arbeit mit dem Einsatz von Radar² auf dem Gebiet der Kartierung und Lokalisierung. Zum einen werden neue Radarmessprinzipien zur Umgebungsmodellierung in der mobilen Robotik untersucht, zum anderen LiDAR-Radar-Fusionsverfahren vorgestellt. Durch die Fusionierung von Radar- und LiDAR-Messungen lassen sich besonders in Umgebungen mit wechselhaften Sichtbedingungen die Vorteile beider Sensoren kombinieren. Hierfür werden drei Fusionsverfahren und ein SLAM³-Verfahren ausführlich beschrieben und evaluiert. Die dargestellten Fusionsverfahren ermöglichen es, Umgebungen zu kartieren, in denen sowohl LiDAR- als auch Radar-Scanner allein nicht erfolgreich wären. Mit der durch die fusionierten Daten ermittelten Konzentrationsgröße wird die Verteilung von Aerosolen beschrieben und parallel zu dem vorgestellten SLAM-Verfahren mit einem Finite-Differenzen-Modell in das Umgebungsmodell eingetragen.

¹Engl. Light Detection and Ranging (LiDAR) - Optisches Verfahren zur Abstandsmessung

²Engl. Radio Detection and Ranging (Radar) - Ortungsverfahren im Funkwellenbereich

³Engl. Simultaneous Localization and Mapping (SLAM) - Gleichzeitiges Kartieren und Lokalisieren

Abstract

A mobile robot requires a model of the environment to move autonomously. A model of the environment can contain objects, landmarks, but also abstract information as topologic relations. In order to build such a model, the robot needs sensor data. But, solid particles or liquid droplets in air (aerosols) are problems in mobile robotics. Under such conditions, popular sensors as LiDAR⁴-scanner and RGB-cameras do not provide sufficient useful measurements in order to achieve the main capabilities of an autonomously driving system (Mapping, Localization and Navigation). For example, in the field of agriculture or mining, dust occludes the vision of RGB-cameras. In *Search and Rescue Robotics*, fire and smoke affect the measurement of LiDAR-scanners. Harsh weather conditions (rain, fog and snow) are typical problems for autonomous road vehicles. These examples require the integration of sensors, which are not affected by aerosols.

This work focusses on the integration of radar into the field of mapping and localization, presents research regarding new measurement principles and sensorfusion between LiDAR and radar⁵. The sensorfusion permits the combination of the advantages of both sensors, especially in environments with changing visibility. Therefore, this work presents and evaluates three fusion strategies and one SLAM⁶ algorithm. The presented fusion strategies allow robotic mapping in environments, where a LiDAR or radar scanner by itself would fail. Additionally, this work presents the modelling of the concentration of aerosols via a finite difference model in parallel to the SLAM algorithm.

⁴LiDAR - Measures distance to objects via pulsed laser signals

⁵Radar - Object-detection through radio waves

⁶SLAM - Simultaneous Localization and Mapping

II Inhaltsverzeichnis

I	Kurzfassung	I
II	Inhaltsverzeichnis	III
III	Abkürzungsverzeichnis	VI
IV	Symbolverzeichnis	VII
1	Einführung	1
1.1	Wissenschaftliche Fragestellung und Zielsetzung	2
1.1.1	Vorbetrachtung: Neue Messprinzipien zur Umgebungsmodellierung in der mobilen Robotik mit Radar	2
1.1.2	LiDAR-Radar-Fusionsverfahren	4
1.1.3	Verfahren zur Erstellung von metrischen Umgebungsmodellen und Aerosolverteilungen	6
1.2	Randbedingungen	7
1.3	Aufbau der Arbeit	8
2	Stand der Wissenschaft	9
2.1	Bauformen mobiler Roboter	9
2.2	Externe Sensoren in der mobilen Robotik	11
2.2.1	Optische Abstandssensoren	13
2.2.2	Akustische Abstandssensoren	14
2.2.3	Radarsensoren	15
2.2.4	Gassensoren	16
2.3	Grundlagen der Umgebungsmodellierung	17
2.3.1	Metrische gitterbasierte Umgebungsmodellierung	19
2.3.2	Metrische objektbasierte Umgebungsmodellierung	21
2.3.3	Modellierung von Punktmessungen und physikalische Grundlagen von Stoff- und Transportvorgängen	22
2.4	Simultaneous Localization and Mapping	24
2.5	Grundlagen der Datenfusion und Sensorintegration und existierende Methoden in Kombination mit Radar	27
2.6	Radargrundlagen	29
2.6.1	Radargeräte und deren Einteilung	31
2.6.2	Entfernungsmessung mit Dauerstrichverfahren	31
2.6.3	Genauigkeit und Auflösung	33
2.6.4	Detektion	34
2.7	Bildgebende Radarverfahren	34
2.7.1	Strahlformung und -schwenkung	34
2.7.2	ASR - Betrachtung der Leistung an der Empfängerantenne	37
2.7.3	Lateration	38

2.7.4	SEABED und SAR	39
3	Vorbetrachtung: Neue Messprinzipien zur Umgebungsmodellierung mit Radar	41
3.1	Funktionsweise des Laterations-Scanners	41
3.1.1	Fehlerbetrachtung des Laterations-Scanners	43
3.2	Erstellen von Rasterkarten mit einem Laterations-Scan-Verfahren	47
3.3	Erstellen von globalen Landmarkenarten mit einem Laterations-Scan-Verfahren	48
3.3.1	Landmarken für landmarkenbasierte SLAM-Verfahren mit Radar	48
3.3.2	Landmarkenkarten	51
4	LiDAR-Radar-Fusionsverfahren	54
4.1	Der Einfluss von gestörter Sicht auf LiDAR-Scanner	55
4.2	Vorbetrachtung zu LiDAR-Radar-Fusionsstrategien	57
4.3	Vorüberlegung zum Verhalten von LiDAR und Radar bei gestörter Sicht	59
4.4	LiDAR-Radar-Scan-Fusion zur Erzeugung von 2D-Scans	61
4.4.1	Vorverarbeitung der Sensordaten	61
4.4.2	Modellbasierte 2D-LiDAR- und 2D-Radar-Scan-Fusion	65
4.4.3	Heuristische 2D-LiDAR- und 2D-Radar-Scan-Fusion	69
4.4.4	2D-LiDAR- und 2D-Radar-Scan-Fusion mit virtuellem Sensor	70
4.5	LiDAR-Radar-Scan-Fusion zur Erzeugung von 3D-Scans	72
5	Verfahren zur Erstellung von metrischen Umgebungsmodellen und Aerosolverteilungen	74
5.1	2D-SLAM mit fusionierten 2D-Scans	75
5.1.1	Die Fusionskarte M_F	77
5.1.2	Die Robot-Location-Dependant-Karte M_{RLD}	77
5.1.3	Eine Variation des klassischen ICP-Algorithmus	79
5.1.4	Filterung der Positionsschätzung	82
5.1.5	Gewichtetes inverses Sensormodell	85
5.2	Landmarkenbasierte SLAM-Ansätze mit Radar- und LiDAR-Scannern	86
5.2.1	Landmarkenextraktion mit 2D-Radar-Scannern	86
5.2.2	Landmarkenextraktion mit 3D-LiDAR-Scannern	87
5.3	Bestimmung und Modellierung von Aerosolverteilungen	88
5.3.1	Schätzung der Position von gestörter Sicht	88
5.3.2	LiDAR-Radar-Ratio (LRR)	88
5.3.3	Modellierung des LiDAR-Radar-Verhältnisses in zweidimensionalen Umgebungsmodellen	90
6	Experimentelle Evaluierung der vorgestellten Verfahren	92
6.1	Evaluierung neuer Messprinzipien zur Umgebungsmodellierung in der mobilen Robotik mit Radar	93
6.1.1	Allgemeines Sensorverhalten des Laterations-Scanners	93
6.1.2	Rasterkartierung mit dem Laterations-Scanner	97
6.1.3	Feature-Kartierung mit dem Laterations-Scanner (Proof of Concept)	98
6.1.4	Kartierung mit Range-Only-Radarsensoren - SEABED	99
6.2	Evaluierung der LiDAR-Radar-Fusion	103
6.2.1	Gegenüberstellung und Parameterverhalten	103
6.2.2	Einfluss der Linienextraktion in der Vorverarbeitung	109

6.2.3	Einfluss der LiDAR-Radar-Fusion auf die Qualität von Rasterkarten	111
6.2.4	Integration von virtuellen 2D-Scans in der Vorverarbeitung	112
6.2.5	Reaktion der LiDAR-Radar-Fusion auf den Typ-I-Effekt	114
6.2.6	Reaktion der LiDAR-Radar-Fusion auf den Typ-II-Effekt	118
6.3	Metrische Umgebungsmodellierung mit Aerosolverteilungen	121
6.3.1	SLAM - Landmarken	121
6.3.2	SLAM - Registrierung	123
6.3.3	Modellierung des LRR	124
7	Bewertung, Diskussion und Ausblick	126
7.1	Vorbetrachtung: Neue Messprinzipien mit Radarsensoren	126
7.2	LiDAR-Radar-Fusionsverfahren	127
7.3	Metrische Umgebungsmodelle mit Aerosolverteilungen	128
7.4	Zukünftige Forschungsfragen	128
8	Zusammenfassung	130
A	Anhang	132
A.1	Technische Daten der Sensorik und Plattformen	132
A.2	Fallbetrachtungen LiDAR-Radar-Fusion	135
A.3	Datensätze für die Fusion von LiDAR und Radar	140
A.3.1	Geräte und Anordnungen	140
A.3.2	Datensatz I - Flur in Hannover	141
A.3.3	Datensatz II - Hof in Hannover	142
A.3.4	Datensatz III - Garage in Wien	143
	Quellenverzeichnis	144

III Abkürzungsverzeichnis

ACFR	Australien Centre for Field Robotics
ADU	Analog-Digital-Umsetzer
ASR	Engl. Amplitude Sensing Ratio
CW	Engl. Continuous Wave
EIF	Engl. Extended Information Filter
EIPR	Engl. Equivalent Isotropic Radiated Power
EKF	Engl. Extended Kalman Filter
FDM	Finite-Differenzen-Methode
FFT	Engl. Fast Fourier Transformation
FHR	Fraunhofer-Institut für Hochfrequenzphysik und Radartechnik
FMCW	Engl. Frequency Modulated Continuous Wave
IBST	Engl. Inverse Boundary Scattering Transform
ICP	Engl. Iterative Closest Point
KF	Kalman-Filter
LiDAR	Engl. Light Detection and Ranging
LOF	Local-Outlier-Faktor
LRR	LiDAR-Radar-Ratio
MPR	Engl. Mechanical Pivoting Radar
ND	Nebenkeulendämpfung
NN	Nächster-Nachbar
OL	Objektliste
Radar	Engl. Radio Detection and Ranging
RANSAC	Engl. RANdom SAmple Consensus
RLD	Engl. Robot Location Dependant
RTS	Institute of Systems Engineering - Real Time Systems Group
SAR	Engl. Synthetic Aperture Radar
SC	Engl. Sourcecloud
SEABED	Engl. Shape Estimation Algorithm based on BST and Extraction of Directly scattered waves
SLAM	Engl. Simultaneous Localization and Mapping
TC	Engl. Targetcloud
VRV	Vor-Rück-Verhältnis

IV Symbolverzeichnis

Grundlagen der Robotik

$x_R = (x, y, \Theta)^T$	Zustand eines Roboters an der Position x, y und Ausrichtung Θ
$x'_R = (x', y', \Theta')^T$	Folgezustand eines Roboters
z	Sensormessung
$M = \{m_1, m_2, \dots, m_n\}$	Rasterkarte M mit n Zellen m_i
$p(m_i)$	Belegungswahrscheinlichkeit einer Zelle
l	Log Odds Ratio
$M =_0, M_1, \dots, M_m\}$	Rasterkarte M bestehend aus m Layer M_i
μ_t	Aktueller Systemzustand mit Roboterposition, Ausrichtung und Landmarken
Σ_t	Aktuelle Kovarianzmatrix
$\bar{\mu}_t$	Geschätzter Systemzustand mit Roboterposition, Ausrichtung und Landmarken
$\bar{\Sigma}_t$	Geschätzte Kovarianzmatrix
G_t	Jacobi-Matrix
K_t	Kalmanverstärkung

Radargrundlagen

R	Abstand eines Objektes zu einem Radarsensor
R_{min}	Minimal messbarer Abstand eines Objektes zu einem Radarsensor
R_{max}	Maximal messbarer Abstand eines Objektes zu einem Radarsensor
ΔR	Distanzauflösung eines Radarsensors
$\Delta \Theta$	Öffnungswinkel der Antennenhauptkeule
c	Lichtgeschwindigkeit
RCS	Radarquerschnitt (engl. Radar Cross Section)
P_e	Radar-Empfangsleistung
P_s	Radar-Sendeleistung
G_e	Antennengewinn Radar-Empfänger
G_s	Antennengewinn Radar-Sender
λ	Wellenlänge der Trägerfrequenz eines Radarsensors
σ	Radarquerschnitt
τ	Sendepulslänge eines Pulsradars
Δf	Bandbreite eines Dauerstrichradars
f_s	Sendefrequenz
f_e	Empfängerfrequenz
f_d	Dopplerfrequenz
ASR	Amplitude Sensing Ratio
X, Y	2D-Messwerte im d-space (IBST)
x, y	2D-Messwerte im r-space (IBST)

Laterations-Scanner

l_{OL}	Maximale Länge der Objektliste
$O_i(x_{O_i}, y_{O_i})$	Objektposition
$S_j(x_{S_j}, y_{S_j})$	Sensorposition
d_{Ant}	Antennenabstand
d_{ij}	Abstand zwischen Sensor S_j und Objekt O_i
σ_R	Standardabweichung einer Distanzmessung eines Range Only Sensors
σ_{PD}	Unsicherheitsbereich
β	Rotationswinkel Laterations-Scanner
P_i	Scan-Punkt i

Sensorfusion und SLAM

$S = [R_0, R_1, R_2, \dots, R_n]$	Sensornachricht eines 2D-Scanners bestehend aus einem Array mit n Abstandsmessungen R_i .
$S_{LiDAR}, S_{Radar}, S_{Fusion}$	LiDAR-, Radar- und fusionierter 2D Scan
$S_{Fusion,Nav.}$	Fusionierter virtueller 2D-Scan zur Objektvermeidung
$S_{Fusion,Lok./Kart.}$	Fusionierter virtueller 2D-Scan zur Lokalisierung und Kartierung
$R_{Radar}, R_{LiDAR}, R_{Fusion}$	Einzelne Abstandsmessung
R_F, α	Grenze zwischen komplementären und konkurrierenden Fusionsbereich, Parameter zur Einstellung der Grenze
$f(i)$	Normierte Funktion für die modellbasierte Fusion
$Sig_{TypI}, Sig_{TypII}, Sig_{R_F}, Sig_{F_S}$	Sigmoidfunktionen der modellbasierten Fusion
p	Anstieg Sig_{TypI}
d_F	Fusionsband bei der heuristischen Fusion
$M_{VS,LiDAR}, M_{VS,Radar}, M_{VS,Fusion}$	LiDAR-Raster, Radarraster und Fusionsraster für die Fusionierung per virtuellen Sensor
a	Parameter zur Einstellung der Rastergewichtung beim virtuellen Sensor
res	Auflösung der Fusionsraster beim Virtuellen Sensor
$r_{VirtuellerSensor}$	Radius der Sensormodelle beim virtuellen Sensor
M_F, M_{ICP}, M_{RLD}	Fusionskarte, ICP-Karte und Robot-Location-Dependant-Karte beim SLAM
$M_{LiDAR}, M_{Radar}, M_{Fusion}$	Rasterkarten zur Erzeugung der ICP-Karte

Modellierung von gestörter Sicht

S_{Typ-I}	Scan zur Detektion des Typ-I-Effektes
LRR_{Typ-I}	LiDAR-Radar-Ratio zur Beschreibung des Typ-I-Effektes
LRR_{Typ-II}	LiDAR-Radar-Ratio zur Beschreibung des Typ-II-Effektes
v	Geschwindigkeitsfeld
d	Diffusionskoeffizient

1 Einführung

Mobile Roboter sind aus unserem Alltag nicht mehr wegzudenken. Die Grundlage für alle autonom funktionierenden Systeme, von Staubsaugroboter bis selbstfahrendes Auto, sind exakte Umgebungsmodelle.

Umgebungsmodelle dienen als Grundlage für die autonome Navigation und beinhalten Strukturen und Merkmale, die mit Sensoren detektierbar sind. Dabei sind metrische Umgebungsmodelle maßstabsgetreue Abbildungen eines Umfeldes und werden in der mobilen Robotik häufig mit Hilfe von LiDAR-Scannern⁷ erstellt. Ein LiDAR-Scanner vollzieht mehrere Abstandsmessungen hintereinander und fasst Strukturen einer Umgebung in einem Scan zusammen. Dieses Messprinzip kann jedoch gestört werden, wenn sich Aerosole⁸ (z. B. Nebel, Rauch und Staub) zwischen Sensor und Messobjekt befinden. Das führt zu dem Problem, dass detektierte Aerosolpartikel in das Umgebungsmodell als Hindernis eingetragen werden, was wiederum die autonome Navigation des Systems beeinträchtigt. Im Gegensatz zum LiDAR wird die Distanzmessung mit Radar⁹ nicht durch Nebel, Rauch und Staub verfälscht.

Erstmals beschäftigte sich das Australien Centre for Field Robotics (ACFR) mit Radar-Scannern in der mobilen Robotik [CW98], [CD99], [CDW98] und stellt Umgebungsmodelle vor, die auf Landmarken basieren. Da Radar-Scanner im Vergleich zu LiDAR-Scannern mit einer ungenauen Distanz- und Winkelauflösung arbeiten, sind die resultierenden Umgebungsmodelle nicht so detailgenau [VGC⁺13], [VCC13]. Im Gegensatz dazu kann mit LiDAR ein höherer Detailgrad der Struktur einer Umgebung erzielt werden [LKKW16], [BWW03]. Daher ist es ein relevantes Forschungsthema, auch in verrauchten, nebligen und staubigen Umgebungen detaillierte, metrische Umgebungsmodelle zu erstellen, indem die Vorteile beider Sensortypen kombiniert werden.

In Abbildung 1 ist der mobile Roboter (Taurob Tracker) des SmokeBot-Projektes¹⁰ dargestellt, der zur Unterstützung von Rettungskräften bei gefährlichen Einsätzen entwickelt wurde. Die Plattform und der in diesem Projekt vom Fraunhofer-Institut für Hochfrequenzphysik und Radartechnik (FHR) entwickelte Radar-Scanner (MPR¹¹) wurden für einen Teil der experimentellen Untersuchungen in dieser Dissertation verwendet.

⁷LiDAR - Optisches Verfahren zur Abstandsmessung

⁸Feste und flüssige Teilchen in der Luft

⁹Radar - Ortungsverfahren im Funkwellenbereich

¹⁰Mobile Robots with Novel Environmental Sensors for Inspection of Disaster Sites with Low Visibility (Call: H2020-ICT-2014-1)

¹¹Engl. Mechanical Pivoting Radar (MPR)

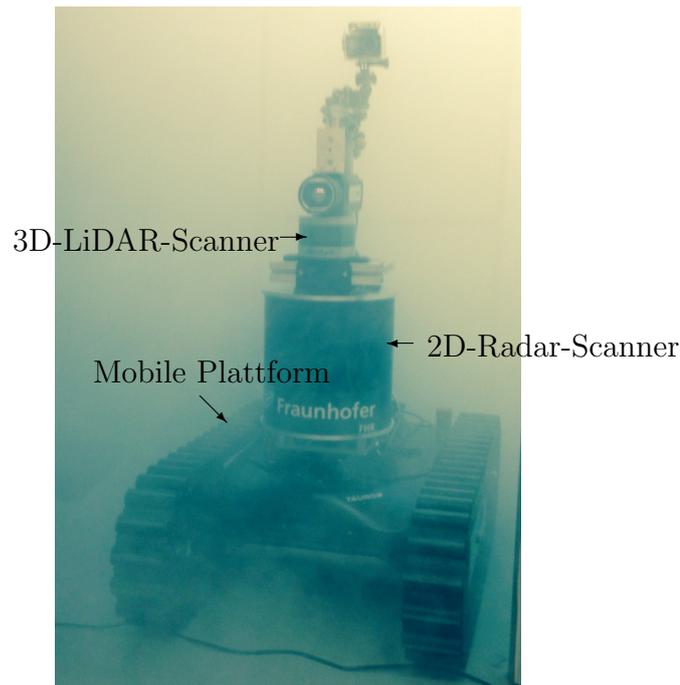


Abbildung 1: Das Erstellen von detaillierten Umgebungsmodellen in verrauchten, nebligen und staubigen Umgebungen ist mit LiDAR-Scannern problematisch.

1.1 Wissenschaftliche Fragestellung und Zielsetzung

Diese Arbeit liefert einen Beitrag auf dem Gebiet der zweidimensionalen Umgebungsmodellierung für die autonome Navigation von mobilen Robotern. Der Fokus liegt dabei auf strukturierten, jedoch durch Aerosole gestörten Umgebungen, in denen herkömmliche Verfahren, die nur auf LiDAR basieren, nicht ausreichen. Die wissenschaftliche Fragestellung dieser Dissertation lautet:

Mit welchen Verfahren können Umgebungen, in denen Aerosole die Distanzmessungen von LiDAR beeinträchtigen, mit Hilfe von mobilen Robotern modelliert werden, die zusätzlich mit Radarsensoren ausgestattet sind?

Aus dieser Fragestellung ergeben sich die Zielsetzungen.

1.1.1 Vorbetrachtung: Neue Messprinzipien zur Umgebungsmodellierung in der mobilen Robotik mit Radar

In dieser Arbeit sollen neue Ansätze zur Umgebungsmodellierung mit Radar in der mobilen Robotik entwickelt und untersucht werden. Die Verfahren müssen mit Experimenten oder in der Simulation hinreichend evaluiert und miteinander verglichen werden, um die Eignung für die mobile Robotik bewerten zu können.

Teilproblemstellung und Lösungsansatz

Diese Arbeit beschäftigt sich mit neuen Messprinzipien, jedoch nicht mit der Verbesserung der Radartechnik. Handelsübliche Radarsensoren besitzen den Nachteil, dass sie im Gegensatz zu LiDAR eine große Distanzauflösung ΔR und einen großen Öffnungswinkel Θ aufweisen. Diese Sensoreigenschaften

sind in Abbildung 2 verdeutlicht.

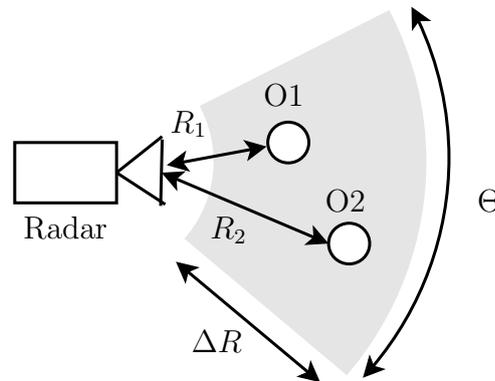


Abbildung 2: Die Distanzauflösung und der Öffnungswinkel von Radarsensoren sind der Grund dafür, dass die Bestimmung einer Objektposition im Vergleich zu LiDAR ungenauer ist.

Der im Experimenterteil dieser Arbeit verwendete *iSYS4004* FMCW¹²-Radar hat eine theoretische Distanzauflösung von 0.6 m und einen Öffnungswinkel Θ von ca. 49° . Daraus ergibt sich, dass unterschiedliche Objekte O1 und O2, welche einen kleineren Abstand zueinander als die Distanzauflösung ΔR besitzen, nicht voneinander unterschieden werden können ($|R_1 - R_2| < \Delta R$). Dadurch entsteht eine falsche Abstandsmessung zwischen den beiden Objekten. Ein großer Öffnungswinkel hat zusätzlich zur Folge, dass keine genaue Winkelinformation bezüglich der Objektposition ermittelt werden kann. Um dieses Problem zu lösen, werden in dieser Arbeit das Laterations-, ASR¹³- und SEABED¹⁴-Verfahren hinsichtlich der Eignung für die Umgebungsmodellierung in der mobilen Robotik untersucht. Lateration ist ein Verfahren zur Bestimmung der Position eines Objektes, indem mehrere Abstandsmessungen von unterschiedlichen Messpositionen zum Objekt durchgeführt werden. Eine einzelne Abstandsmessung ergibt, dass sich das Objekt auf einer Kreisbahn um den aktuellen Messpunkt befindet. Der Schnittpunkt der Kreisbahnen mehrerer Messungen ergibt dadurch die Position des Objektes. Das ASR-Verfahren ermöglicht ein genaueres Bestimmen der Position von Objekten mittels der Rückstrahlleistung P_e von Radarsensoren. Die Rückstrahlleistung ist maximal, wenn die Radarantenne direkt auf das Objekt gerichtet wird. Wenn mehrere Antennen mit versetzter Ausrichtung verwendet werden, dann kann aus dem Unterschied der Rückstrahlleistungen auf die Position des Objektes geschlossen werden. Mit dem SEABED-Verfahren wird das Problem des großen Öffnungswinkels Θ mathematisch gelöst. Die Voraussetzung des Verfahrens ist, dass der Sensor auf einer bekannten Trajektorie verfahren wird. Mit dem Laterations-Verfahren wird in dieser Arbeit ein rotierendes Scanprinzip (Laterations-Scanner) hergeleitet, evaluiert und mit dem bereits existierendem ASR-Verfahren¹⁵ verglichen. Weiterhin soll mit dem SEABED-Verfahren untersucht werden, ob sich SAR¹⁶-Verfahren für die Umgebungsmodellierung eignen.

¹²Engl. Frequency Modulated Continuous Wave (FMCW)

¹³Engl. Amplitude Sensing Ratio (ASR)

¹⁴Engl. Shape Estimation Algorithm based on BST and Extraction of Directly scattered waves (SEABED)

¹⁵Prinzip basiert auf dem Monopulsverfahren

¹⁶Engl. Synthetic Aperture Radar (SAR)

1.1.2 LiDAR-Radar-Fusionsverfahren

Ein weiteres Ziel dieser Arbeit besteht darin, Fusionsverfahren zu entwickeln, welche die Vorteile von LiDAR und Radar kombinieren. Die Voraussetzung dafür ist, dass die Effekte von Aerosolen auf LiDAR und Radar experimentell untersucht und klassifiziert werden, um aufzuzeigen in welchen Situationen die Verwendung von LiDAR-Sensoren oder Radarsensoren von Vorteil ist. Dadurch soll der Detailgrad von Umgebungsmodellen erhöht werden, wenn Aerosole die Distanzmessungen von LiDAR beeinträchtigen. Diese Arbeit beschäftigt sich nicht mit der Erfassung und Verfolgung (Tracking) von Objekten mit LiDAR und Radar in dynamischen und unstrukturierten Umgebungen und grenzt sich somit von typischen Problemstellungen der Automobilindustrie ab, wo Umgebungsmodelle mittels Objektlisten repräsentiert werden [Pie14], [Lun11], [Hab13]. Arbeiten, die sich mit der Umfeldwahrnehmung von Automobilen beschäftigen, unterscheiden zwischen Low-Level¹⁷, Mid-Level¹⁸ und High-Level¹⁹ Sensorfusion [Elm02]. Ein Verfahren zur Fusionierung von Low-Level Merkmalen unterschiedlicher bildgebender Sensoren zur Steigerung der Robustheit einer visuellen Odometrie wurde von Kleinschmidt [KW18] vorgestellt. Im Gegensatz dazu ist das Ziel dieser Arbeit das Erstellen von metrischen auf Rastern basierenden Umgebungsmodellen in strukturierten aber durch Aerosole beeinträchtigten Umgebungen.

Teilproblemstellung und Lösungsansatz

Die Verfahren müssen sich selbstständig auf unterschiedlich starke Störungen durch Aerosole anpassen können, sodass das Erstellen eines Umgebungsmodells gewährleistet ist. LiDAR und Radar liefern jeweils Distanzwerte und sind somit konkurrierende Sensoren. Jedoch weisen sie unterschiedliche Messbereiche auf und detektieren verschiedene Objekte. So werden nichtleitende Materialien, wie zum Beispiel Plastik und Keramik, von Radarsensoren nicht detektiert, wohingegen LiDAR lichtdurchlässige Objekte nicht erfasst. Weiterhin unterscheiden sich die Sensormodalitäten hinsichtlich ihrer Messgenauigkeit und haben unterschiedliche Messraten. Der Grund für die höhere Messgenauigkeit von LiDAR-Scannern gegenüber Radar-Scannern ist ein geringerer Öffnungswinkel einzelner Abstandsmessungen. Dadurch können Objekte detektiert werden, die mit Radar nicht zu erfassen sind (siehe Abbildung 3).

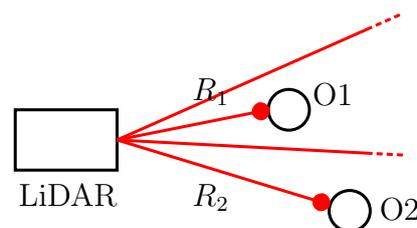


Abbildung 3: Mit LiDAR-Scannern können Objekte besser detektiert und unterschieden werden als mit Radar-Scannern.

¹⁷Fusion auf Sensorrohdatenebene. (Engl. raw data fusion)

¹⁸Fusion von detektierten Objekten (Engl. feature fusion)

¹⁹Fusion basierend auf Entscheidungen, Fuzzy-Logik und statistischen Methoden (Engl. decision fusion)

In dieser Dissertation werden drei konkurrierende Fusionsstrategien für heterogene Sensordaten vorgeschlagen.

- Heuristische Fusion
- Modellbasierte Fusion
- Virtueller Sensor

Heuristische Fusionsverfahren sind speziell an ein System angepasst und basieren auf experimentellen Beobachtungen der jeweiligen Sensoren. Allerdings kann der Austausch und die Anzahl der Sensoren nicht flexibel gehandhabt werden. Heuristische Verfahren sind nachvollziehbar, womit zum Beispiel unerwartete Fusionsergebnisse erklärbar werden. Weiterhin ist die Rechenzeit dieser Verfahren per *Worst-Case*-Abschätzungen ermittelbar. Somit sind heuristische Fusionsverfahren für sicherheitskritische Anwendungen geeignet. Santos [San13] stellt das heuristische Fusionsverfahren *SmokeNav* für eine Ultraschall-LiDAR-Fusion in nebligen Umgebungen vor, das zusätzlich einen Rauchsensor²⁰ benötigt, um die Präsenz von Rauch abzuschätzen. Im Gegensatz zum *SmokeNav*-Verfahren wird für die heuristische Fusion in dieser Dissertation kein zusätzlicher Sensor benötigt.

Bei der modellbasierten Fusion wird das gewünschte Fusionsverhalten mit einer mathematischen Funktion approximiert. Es ist ähnlich zum heuristischen Verfahren speziell an einen Sensoraufbau angepasst und setzt Randbedingungen für die Platzierung der Sensoren voraus.

Der virtuelle Sensor, der in dieser Arbeit vorgestellt wird, ist ein universelles Fusionsverfahren zur Erstellung eines 2D-Distanzsensors²¹. Das Verfahren basiert auf einer fusionierten lokalen Rasterkarte, in der per Strahlenverfolgung (engl. raytracing) Distanzmessungen zu einer definierbaren Sensorposition ermittelt werden. Somit besteht keine Abhängigkeit vom Sensortyp und der Anzahl an Sensoren. Die Fusionierung von mehreren Distanzsensoren mittels lokaler Rasterkarten wurde von Effertz [Eff09] vorgestellt, um das Umfeld eines Fahrzeuges in befahrbar bzw. nicht befahrbar zu klassifizieren.

²⁰Santos detektiert mit einem Alkoholsensor das Glykol im Nebel von Nebelmaschinen, da Experimente mit echtem Rauch schwierig zu realisieren sind.

²¹Z. B. 2D-LiDAR-Scanner

1.1.3 Verfahren zur Erstellung von metrischen Umgebungsmodellen und Aerosolverteilungen

Des Weiteren befasst sich diese Arbeit mit metrischen Umgebungsmodellen. Dabei sollen zwei unterschiedliche Ansätze der Umgebungsmodellierung mit LiDAR- und Radar-Daten hinsichtlich ihrer Eignung zur Erstellung von metrischen Umgebungsmodellen bewertet werden. Zum einen wird überprüft, ob mit LiDAR und Radar Landmarken extrahiert werden können, um ein Umgebungsmodell trotz vorhandener Aerosole aufzubauen, zum anderen wird ein Verfahren beschrieben, das fusionierte Scans mit einer Rasterkarte registriert (engl. matching). Aufbauend auf LiDAR-Radar-Fusionsverfahren und metrischen Umgebungsmodellen sollen Aerosolverteilungen modelliert werden. Dafür werden neben LiDAR- und Radar-Daten keine weiteren Sensoren verwendet.

Teilproblemstellung und Lösungsansatz

SLAM²²-Verfahren bilden eine grundlegende Struktur für Umgebungsmodelle in der mobilen Robotik. Durrant-Whyte entwickelte in den neunziger Jahren fundamentale, auf Landmarken basierende SLAM-Verfahren mit einem am ACFR entwickelten Radar-Scanner [CD99]. Adams verwendet für seine Versuche einen kommerziell erhältlichen Navtech Sensor [AMJ12]. Die genannten Forscher verfolgen einen landmarkenbasierten SLAM-Ansatz, stellen jedoch kein Verfahren zum Extrahieren von Landmarken vor. Daher wird in dieser Arbeit überprüft, ob der Distanzverlauf und die Rückstrahlleistung eines Radar-Scanners für die Extraktion von Punktzielen verwendet werden kann und ob dafür natürliche oder künstliche Landmarken benötigt werden. Zusätzlich wird eine Methode entwickelt, die auf ICP²³-Registrierungen zwischen den fusionierten Scans und einer fusionierten Rasterkarte basiert. Parallel zu diesem SLAM-Verfahren wird die partielle Differentialgleichung des Diffusionsgesetzes numerisch mit einem FDM²⁴-Modell in jedem SLAM-Zyklus gelöst, um die Aerosolverteilung zu modellieren. Für die lokale Bestimmung der Aerosoldichte mit LiDAR und Radar wird der LRR²⁵ eingeführt. Der LRR entspricht dem Verhältnis an Radarmessungen zu LiDAR-Messungen in einem fusionierten Scan und ist somit ein Indikator für die Aerosoldichte. Das beschriebene Verfahren ist im Zusammenhang mit den LiDAR-Radar-Fusionsverfahren in Abbildung 4 und 5 dargestellt.

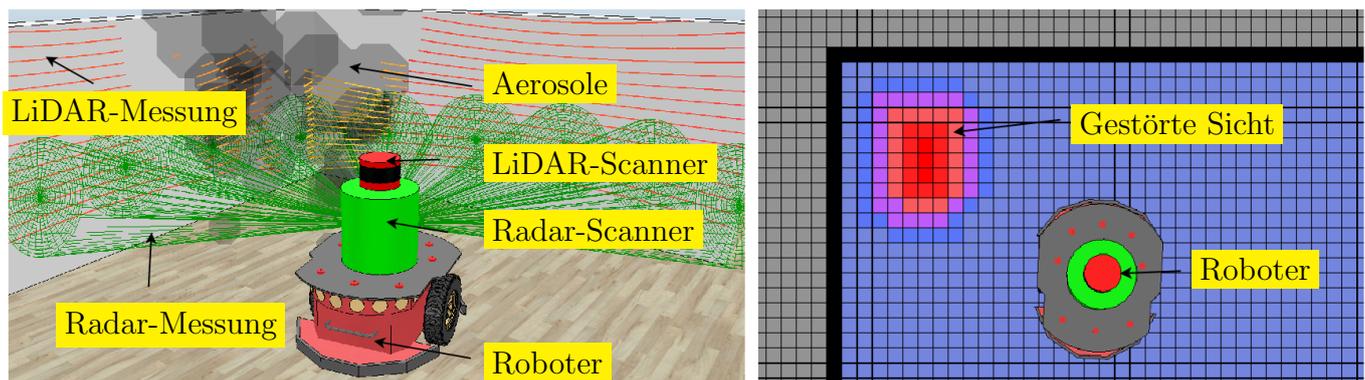


Abbildung 4: LiDAR-Scanner (rot) erzeugen ein detaillierteres Abbild einer Umgebung als Radar-Scanner (grün). LiDAR-Scanner werden jedoch durch Aerosole negativ beeinträchtigt.

²²SLAM - Gleichzeitige Kartierung und Lokalisierung

²³Engl. Iterative Closest Point (ICP)

²⁴Finite-Differenzen-Methode (FDM)

²⁵LiDAR-Radar-Ratio

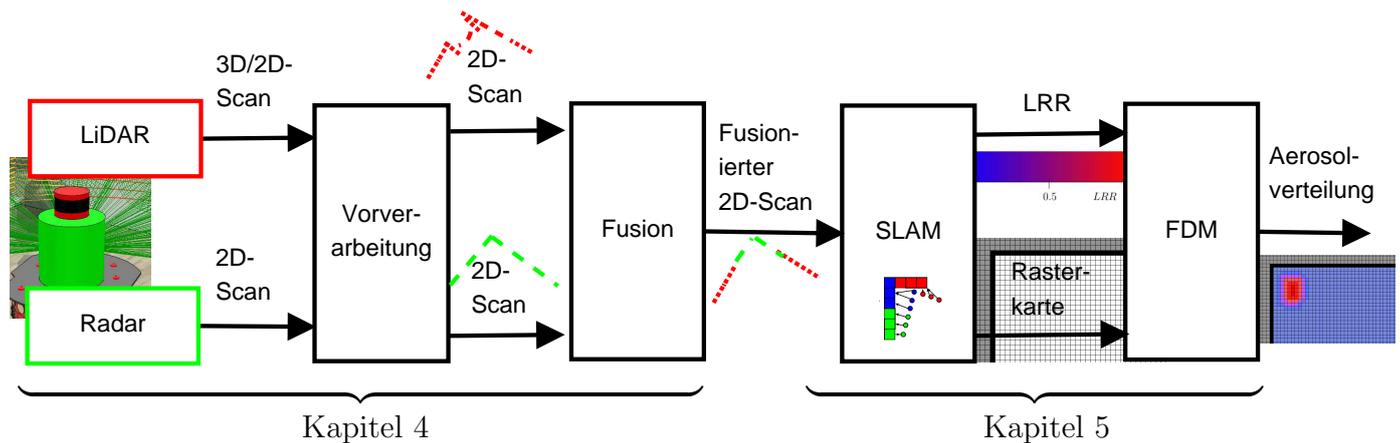


Abbildung 5: Modellierung von Aerosolverteilungen in metrischen Umgebungsmodellen während der Roboternavigation

Das in Abbildung 5 vorgestellte Verfahren benötigt mindestens einen LiDAR-Scanner und einen Radar-Scanner. Falls mehr als ein Sensor pro Modalität verwendet wird, muss der virtuelle Sensor zur Fusion eingesetzt werden. Die Vorverarbeitung beinhaltet mehrere bestehende Verfahren zur Aufbereitung der Sensordaten. Zum einen wird das Verfahren der *virtuellen 2D-Scans* von Wulf [Wul08] verwendet. Ob dieses Verfahren Vorteile in Umgebungen mit Aerosolen aufweist, ist eine zu untersuchende Fragestellung in dieser Arbeit. Zum anderen werden in den Scans gerade Strukturen und Ausreißer gesucht. Gerade Strukturen, die mittels Liniendetektionsalgorithmen im 2D-Scan detektierbar sind, werden im Gegensatz zu Ausreißern stärker in den Fusionsverfahren gewichtet. Weiterhin beinhaltet die Vorverarbeitung die Kalibrierung und die Sensorsynchronisierung.

1.2 Randbedingungen

Die untersuchten und entwickelten Verfahren in dieser Arbeit sind für mobile Roboter ausgelegt, die sich in der zweidimensionalen Ebene bewegen. Weiterhin wird angenommen, dass die Umgebungen statisch, strukturiert²⁶ jedoch von Aerosolen beeinträchtigt sind. Bei den zum Einsatz kommenden Sensoren handelt es sich um die Radarsensoren *iSYS4004* und *MPR*²⁷, und den LiDAR *Velodyne VLP-16*. Alle entwickelten Verfahren müssen weiche Echtzeitanforderungen erfüllen, sodass die Umgebungsmodelle zur Realzeit während der Roboternavigation erzeugt werden.

²⁶Innenräume von Gebäuden, Außenbereiche mit Gebäudestrukturen, keine freien Flächen, keine dynamischen Verkehrssituationen

²⁷MPR - Der Scanner wurde für das *SmokeBot*-Projekt vom FHR entwickelt.

1.3 Aufbau der Arbeit

Die vorliegende Arbeit ist folgendermaßen gegliedert:

- Kapitel 2 fasst den für diese Arbeit relevanten Stand der Wissenschaft der mobilen Robotik und der Radartechnik zusammen.
- Das Kapitel 3 beinhaltet im Rahmen einer Vorbetrachtung ein neues Messprinzip (Laterations-Scanner) zur Umgebungsmodellierung mit *Range Only* Radarsensoren.
- In Kapitel 4 sind neue LiDAR-Radar-Fusionsverfahren beschrieben.
- Das Erstellen von metrischen Umgebungsmodellen mit einem FDM-Modell zur Bestimmung von Aerosolverteilungen wird in Kapitel 5 hergeleitet.
- Das Kapitel 6 evaluiert die vorgestellten Verfahren experimentell und bewertet somit Machbarkeit, sowie Vor- und Nachteile der einzelnen Verfahren an simulierten und realen Daten.
- Kapitel 7 bewertet und diskutiert die Resultate dieser Arbeit und gibt einen Ausblick auf weitere wissenschaftliche Fragestellungen.
- Das Kapitel 8 fasst die Erkenntnisse dieser Arbeit zusammen.

2 Stand der Wissenschaft

Dieses Kapitel stellt den relevanten Stand der Wissenschaft dieser Dissertation vor. Das Kapitel 2.1-2.5 behandelt die Grundlagen der Robotik und gängige Verfahren zur Umgebungsmodellierung. Darauffolgend sind in Kapitel 2.6-2.7 die Grundlagen der Radartechnik beschrieben.

Das Erstellen eines Umgebungsmodells aus Sensordaten ist der Grundbaustein für die Lokalisierung und Navigation autonomer Roboter und unterscheidet sich in der lokalen und globalen Betrachtung. Das lokale Umgebungsmodell bezieht sich zentral auf den Roboter und spiegelt seine aktuelle sensorische Sichtweise in Bezug zu einem lokalen Koordinatensystem wieder [Hen12, S. 15]. Das globale Umgebungsmodell bezieht sich auf das Wissen über das Umfeld in dem sich der Roboter bewegt. Die Navigation beinhaltet das Teilgebiet der Lokalisation, der Wegsuche und der Bahnplanung. Die Lokalisation beschäftigt sich mit Verfahren, die die Positionsbestimmung eines Roboters in einem globalen Umgebungsmodell ermöglicht. Diese globalen Umgebungsmodelle können entweder vom Roboter selbst erstellt werden, oder von externen Quellen stammen. Externe Quellen sind zum Beispiel OpenStreetMap-Karten [HW10], Notfallpläne oder Umgebungsmodelle anderer Roboter. Algorithmen zur Lokalisation vergleichen, wo globales und lokales Umgebungsmodell des Roboters übereinstimmen. Eine präzise Lokalisierung und ein globales Umgebungsmodell ist für eine erfolgreiche Wegsuche notwendig, um von einer aktuellen Position zu einem Zielpunkt zu gelangen. Eine Fahrt zu einem Zielpunkt in einem Gebiet, über welches kein komplettes globales Umgebungsmodell zur Verfügung steht, ist dennoch möglich, jedoch kann in diesem Fall kein optimaler Weg garantiert werden. Die Wegsuche ist wiederum die Grundlage für die Bahnplanung, welche unter der Voraussetzung der kinematischen Eigenschaften des Roboters eine Trajektorie ermittelt [Bre04, S. 1-2].

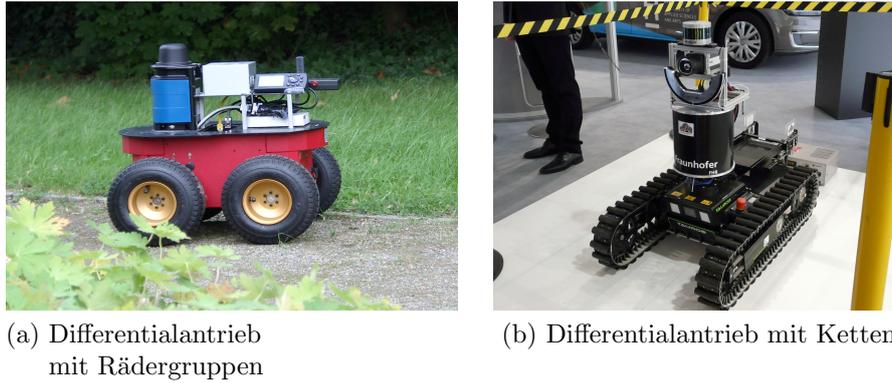
In den folgenden Abschnitten sind zunächst Bauformen von mobilen Robotern (Kapitel 2.1) und gängiger externer Sensorik (Kapitel 2.2) erläutert. Im Anschluss sind die Grundlagen der Umgebungsmodellierung (Kapitel 2.3), von SLAM-Verfahren (Kapitel 2.4) und der Sensor-Fusion (Kapitel 2.5) beschrieben. Das Kapitel 2.6 stellt technische Grundlagen von Radarsensoren dar. Bildgebende Radarverfahren, mit denen Strukturen einer Umgebung erfasst werden können, sind in Kapitel 2.7 dargestellt.

2.1 Bauformen mobiler Roboter

In der mobilen Robotik sind neben Laufrobotern hauptsächlich drei verschiedene Antriebssysteme zu finden. Die Mehrzahl der Indoor-Roboter²⁸ basieren auf Differential- und Omnidirektionalantrieben. In der Outdoor-Robotik²⁹ sind Ackermannantriebe häufig anzutreffen. Die Bestimmung der Roboterposition aus Drehgeberdaten der Räder kann mit einem Bewegungsmodell ermittelt werden. In Abbildung 6 sind zwei Varianten eines Differentialantriebes dargestellt. Differentialantriebe ermöglichen im Gegensatz zu Ackermannantrieben das Steuern eines Fahrzeuges ohne die Ausrichtung einzelner Räder zu ändern, wodurch der Wendekreis nicht limitiert ist und die Fahrtrichtung im Stand ausgerichtet werden kann. Omnidirektionalantriebe bieten den höchsten Manövrier-Freiheitsgrad und können sich zusätzlich linear in alle Fahrrichtungen bewegen. Sie benötigen jedoch eine glatte Oberfläche und sind somit für die Outdoor-Robotik ungeeignet. Da der experimentelle Teil dieser Arbeit mit Plattformen, welche auf Differentialantrieben basieren, durchgeführt wurde, wird in die-

²⁸Mobile Roboter die für die Anwendung in Gebäuden konzipiert sind. Z. B. Service-Roboter, Transport-Roboter für Lager, etc.

²⁹Mobile Roboter die für den Einsatz im Freien konzipiert sind. Z. B. Such- und Rettungsroboter.



(a) Differentialantrieb mit Rädergruppen

(b) Differentialantrieb mit Ketten

Abbildung 6: In den Abbildungen sind der Pioneer (6a) und der Taurob Tracker (6b) abgebildet.

sem Abschnitt dieses Bewegungsmodell vorgestellt. Ein Differentialantrieb besteht aus parallelen gegenüberliegenden Antrieben bzw. Antriebsgruppen. Diese können einzelne, gegenüberliegende Räder (wobei hier jedoch ein zusätzliches Stützrad notwendig ist), mehrere gegenüberliegende Rädergruppen (siehe Abbildung 6a) oder Kettenantriebe (siehe Abbildung 6b) sein. Der Zustand eines mobilen Roboters mit Differentialantrieb, der sich in einer Ebene bewegen kann, ist durch seine Position x, y und durch seine Ausrichtung Θ im globalen Koordinatensystems definiert

$$\vec{x}_R = (x, y, \Theta)^T. \tag{1}$$

Durch die Drehung der linken und rechten Radgruppe, die dadurch den Weg l bzw. r zurücklegt, ergibt sich der Folgezustand x'_R (siehe Abbildung 7). Die Position des Roboters im globalen Koordinatensystem wird durch die Summierung aller translatorischen und rotatorischen Bewegungen zu jedem Zeitschritt bestimmt, was Koppelnavigation genannt wird.

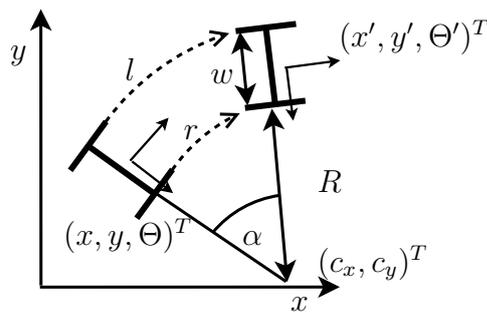


Abbildung 7: Bei der Koppelnavigation wird die Position des Roboters fortlaufend aus den Radbewegungen berechnet, indem die relative Positionsänderung aus den Inkrementalgebern ermittelt und zur letzten bekannten Position addiert wird.

Der neue Zustand $(x', y', \Theta')^T$ ergibt sich aus den Beziehungen in den Gleichungen 2 - 6, wobei l und

r die jeweiligen Wegstrecken der linken bzw. rechten Radgruppe darstellt.

$$\alpha = \frac{r - l}{w} \quad (2)$$

$$R = \frac{l}{\alpha} \quad (3)$$

$$\begin{pmatrix} c_x \\ c_y \end{pmatrix} = \begin{pmatrix} x \\ y \end{pmatrix} - \left(R + \frac{w}{2}\right) \begin{pmatrix} \sin(\alpha) \\ -\cos(\alpha) \end{pmatrix} \quad (4)$$

$$\Theta' = (\Theta + \alpha) \bmod 2\pi \quad (5)$$

$$\begin{pmatrix} x' \\ y' \end{pmatrix} = \begin{pmatrix} c_x \\ c_y \end{pmatrix} + \left(R + \frac{w}{2}\right) \begin{pmatrix} \sin(\Theta') \\ \cos(\Theta') \end{pmatrix}. \quad (6)$$

Bei einem Fahrtrichtungswechsel ergibt sich die neue Ausrichtung Θ' aus einer Drehung um α um den Rotationspunkt (c_x, c_y) . Im Fall, dass sich die Fahrtrichtung nicht ändert und linke und rechte Wegstrecke identisch sind, vereinfachen sich die Gleichungen [Bre15, A03]

$$\begin{pmatrix} x' \\ y' \\ \Theta' \end{pmatrix} = \begin{pmatrix} x \\ y \\ \Theta \end{pmatrix} + l \begin{pmatrix} \sin(\Theta) \\ \cos(\Theta) \\ 0 \end{pmatrix}. \quad (7)$$

Der Winkel Θ definiert die Ausrichtung des Roboters im globalen Koordinatensystem und hängt von den Fahrwegen der Räder und dem Radabstand w ab. Der Nachteil der reinen Koppelnavigation besteht in der inkrementellen Aufsummierung von Fehlern, wodurch ein immer größer werdender Versatz entsteht. Dies wirkt sich bei einem reinen Kartierungsverfahren, ohne Korrektur der Roboterposition über die externe Sensorik, negativ auf die Kartenqualität aus. Aufgrund von Schlupfeffekten zwischen den Rädern und dem Untergrund, kommt es besonders bei Drehbewegungen zu Fehlern. Einige Plattformen minimieren diesen Fehler, indem die inkrementelle Ausrichtungsänderung α nicht über die Drehgeber sondern zum Beispiel mit Gyroskop- und Kompassensoren bestimmt wird [Bre04, S. 60]. Der Trend in der Umgebungsmodellierung geht jedoch dahin, dass Odometrie-Daten nicht nur aus den Radbewegungen ermittelt werden. [FCDS16] erreichen durch eine Kombination aus visueller Odometrie und einem Beschleunigungssensor einen Drift unter 0.5 %. Das in dieser Arbeit vorgestellte SLAM-Verfahren (Kapitel 5.1) kann wahlweise mit oder ohne Rad-Odometrie betrieben werden.

2.2 Externe Sensoren in der mobilen Robotik

Die am häufigsten verwendeten externen Sensoren in der mobilen Robotik kategorisiert Dillmann [Dil15] entsprechend der Abbildung 8. Die Unterscheidung zwischen internen und externen Sensoren bezieht sich auf den mobilen Roboter. Interne Sensoren ermitteln Informationen über den internen Zustand des Roboters und externe Sensoren beschaffen Daten über seine Umgebung. Interne Sensoren sind beispielsweise Drehgeber, Inertialsensoren, interne Temperaturfühler oder Spannungsmesser für Batterien.

Taktile Sensoren dienen in der Robotik als Kollisionsdetektoren, Stabilisatoren von Greifvorgängen oder sogar als Fühler für das Erstellen von Umgebungsmodellen. Zum Beispiel ist der Shrewbot [PMC⁺11] mit Schnurrbart-ähnlichen Fühlern ausgestattet und in der Lage mit ihnen eine zweidimensionale Karte aufzubauen. Näherungssensoren werden häufig für die Kollisionsvermeidung eingesetzt, oder um zu überprüfen, ob bestimmte Gegenstände vorhanden sind. Mit induktiven

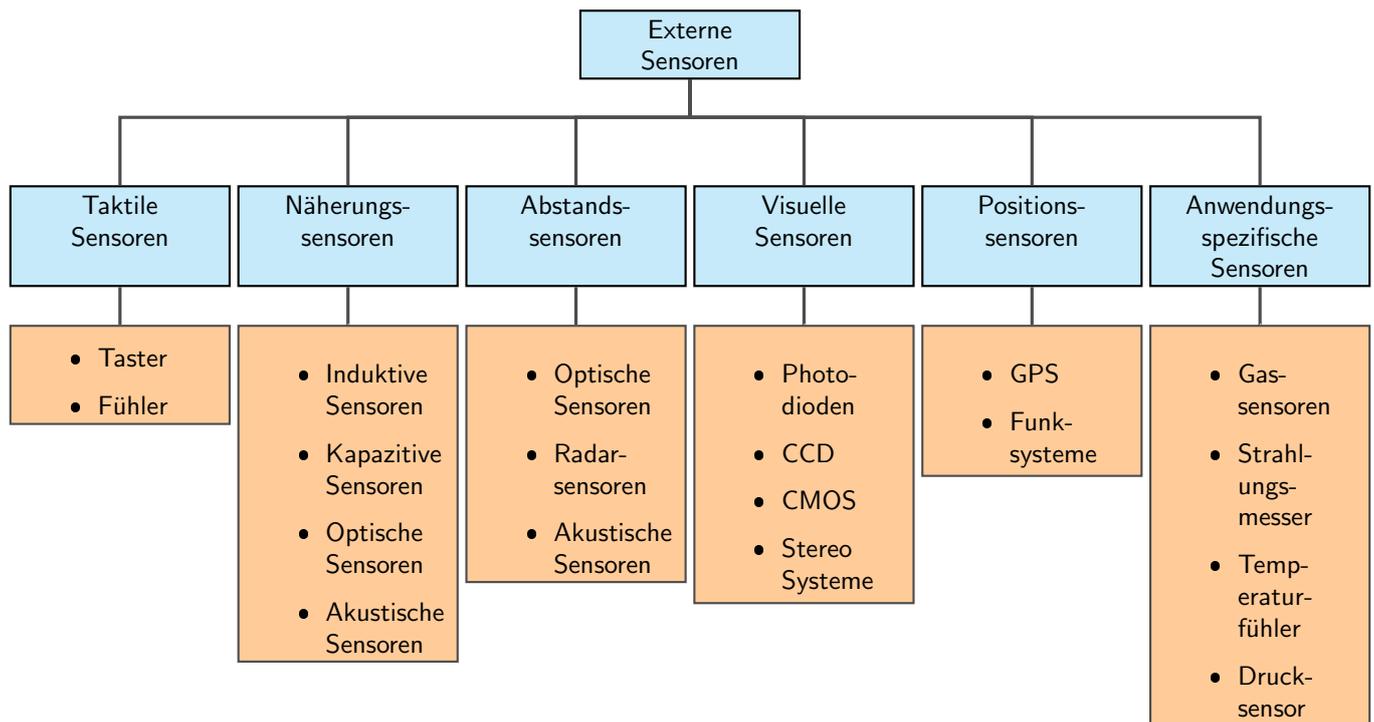


Abbildung 8: Übersicht externer Sensoren von [Dil15] mit der Erweiterung *Anwendungsspezifische Sensoren*.

Näherungssensoren können metallische und elektrisch leitende Objekte, mit kapazitiven Näherungssensoren auch nichtleitende Objekte detektiert werden. Optische und akustische Näherungssensoren reagieren auf reflektierte elektromagnetische Wellen bzw. Schallwellen und haben einen größeren Detektionsbereich als induktive und kapazitive Sensoren [Hau13, S. 421-422]. Abstandssensoren dienen in der Robotik der Orientierung und Geometrieerkennung. Optische Abstandssensoren liefern eine hohe Genauigkeit und Auflösung bezüglich der Entfernung, des Winkels und eignen sich daher sehr gut für die Kartierung und Lokalisierung. Radarsensoren eignen sich zur Objektverfolgung und werden besonders in der Automobilindustrie eingesetzt. Akustische Abstandssensoren eignen sich zum Beispiel für Unterwasseranwendungen. Ihre Parallelen zu Radarsensoren sind eine geringe Entfernungsauflösung und ein breiter Öffnungswinkel der Hauptantennenkeule, welches zu einer geringen Winkelauflösung führt [SSV09, S. 219]. Visuelle Sensoren eignen sich zur Erkennung, Klassifizierung und Verfolgung von Objekten. Stereo-Systeme eignen sich auch zur Kartierung [Hir03, S. 94], werden jedoch von vorherrschenden Lichtbedingungen beeinflusst. Mit Positionssensoren können mobile Roboter direkt lokalisiert werden. Ihre Nachteile sind Abschirmungen und limitierte Genauigkeiten.

Sensoren können eine interne Vorverarbeitung haben, deren Algorithmen per Parameter eingestellt werden. Wenn Sensoren eine interne Signalaufbereitung³⁰ beinhalten, werden sie als integrierte Sensoren bezeichnet. Intelligente Sensoren beinhalten bereits eine interne Auswertung³¹. Kommerziell erhältliche Radarsensoren sind integrierte oder sogar intelligente Sensoren, da bei vielen Modellen Schwellwert-Parameter für die Objektdetektion eingestellt werden können oder speziell bei Automobil-Radarsensoren sogar ein internes Tracking von Zielobjekten aktiviert werden kann.

³⁰Z. B. Filterung, Normierung, Mittlung

³¹Z. B. Mustererkennung oder Tracking

Unabhängig von der Art des Sensors werden in der mobilen Robotik Sensoren in *Range and Bearing* (Abstand und Winkel), *Range Only* und *Bearing Only* eingeteilt. Ein LiDAR-Scanner kann zum Beispiel mit einer Kantenextraktion den Abstand und Winkel zu Kanten und Ecken ermitteln, welche dadurch direkt als Landmarken verwendet werden können. Mit einer Kamera kann nur der Winkel zu speziellen Objekten detektiert werden (bei unbekannter Objektgeometrie). Demzufolge muss das gleiche Objekt aus weiteren Positionen detektiert werden, um somit zum Beispiel per Triangulation die Position des Objektes zu bestimmen, die jedoch unpräziser wird, je ungenauer die Positionsbestimmung des Roboters selbst über die Drehgeber ist. Einfache Radarsensoren mit einem großen Öffnungswinkel können als *Range Only* Sensoren betrachtet werden, wobei die Qualität der Abstandsmessung sehr von der Distanzauflösung abhängig ist, was im Kapitel 2.6.3 näher beschrieben wird.

Aufgrund der Relevanz zum Thema dieser Arbeit sind in Kapitel 2.2.1 optische Abstandssensoren, in Kapitel 2.2.2 akustische Abstandssensoren, in Kapitel 2.2.3 Radarsensoren und in Kapitel 2.2.4 Gassensoren näher beschrieben.

2.2.1 Optische Abstandssensoren

Der LiDAR-Scanner hat sich zu einem sehr geeigneten Sensor für die Erstellung von Umgebungsmodellen zur Navigation in der mobilen Robotik entwickelt. Es existieren unzählige Plattformen mit 3D- und 2D-LiDAR-Scannern. Das Sensorprinzip basiert auf der Laufzeitmessung von Laserimpulsen im nicht sichtbaren Wellenlängenbereich (Typisch 905 nm). Die hohe Fokussierung des Strahles ermöglicht eine Winkelgenauigkeit, die für Radarsensoren nicht zu erreichen ist [BÖ8, S. 10]. Ein Scan erfolgt mittels eines mechanischen Schwenkens dieses gebündelten Strahles über eine Umgebung. Das mechanische Schwenken wird im Fall von 2D-Scannern häufig mit einem internen Drehspiegel realisiert. 3D-LiDAR-Scanner basieren beispielsweise auf sich rotierenden Lasergruppen. Zum Beispiel besitzt der *Velodyne HDL-64E* 64 separate Laser deren Anordnung eine vertikale Auflösung ermöglicht. Andere 3D-LiDAR-Scanner basieren auf sich rotierenden 2D-LiDAR-Scannern, wie zum Beispiel der *ScanDrive 3D-LiDAR-Scanner* [RWW05] oder der *MultiSense SL* Sensor [Car]. Die genannten Scanner sind in Abbildung 9 dargestellt.



(a) ScanDrive



(b) Velodyne HDL-64E³²



(c) MultiSense SL³³

Abbildung 9: Verschiedene 3D-LiDAR-Scanner.

²⁹Quelle: <http://velodynelidar.com/hdl-64e.html>

³⁰Quelle: <http://carnegierobotics.com/multisense-sl/>

In Abhängigkeit der Schrittweite, bzw. der Winkelauflösung der einzelnen Entfernungsmessungen, kann die Form von Objekten besser wiedergegeben werden als mit Radarsensoren. Bei LiDAR-Scannern treten Entfernungsmessfehler besonders beim Wechsel der Reflexionseigenschaften von Objekten oder unebenen Oberfläche auf [LAW05]. Die Entfernungsmessgenauigkeit eines LiDAR-Scanners hängt stark von der Sensorelektronik und dem Messrauschen ab. Optisch bedingt nimmt der Strahldurchmesser eines LiDAR-Scanners mit steigender Entfernung vom Sensor zu. Hersteller geben demzufolge oft eine Mindestobjektgröße in Abhängigkeit der Objektentfernung zum Sensor an. Wenn das Objekt kleiner als der Strahldurchmesser ist, dann werden vom Objekt selbst als auch von einem dahinterliegenden Objekt Laserimpulse reflektiert. Dies tritt zum Beispiel bei Regentropfen, Rauch und Kanten auf, was zu mehreren Maxima an der Empfängerdiode des LiDAR-Scanners führt. Bei einigen LiDAR-Scannern, wie zum Beispiel der *Sick LMS 5xx*, kann ein Echo-Filter aktiviert werden, wodurch das erste oder das letzte Echo für die Detektion verwendet wird. Um beispielsweise Messfehler durch den Einfluss von Regen zu minimieren muss dieser Filter so eingestellt werden, dass nur das letzte Echo beachtet wird [SIC, S. 33]. Liegen diese Störobjekte jedoch zu dicht beieinander, dann kommt es zu einer Überlagerung der Echos, wodurch keine eindeutige Entfernungsbestimmung mehr möglich ist. Die Fähigkeit, reflektierte Laserimpulse zu unterscheiden, wird als Entfernungsauflösung bezeichnet. Dieser Effekt tritt vor allem als sogenannter “Kantenschuss” an Ecken und Kanten auf und hängt mit der Laserimpulsbreite zusammen, aus der sich auch die Entfernungsauflösung berechnen lässt. Die Entfernungsauflösung hängt vom Aufttrittswinkel und der Oberflächenbeschaffenheit des Objektes ab. Eine Beschreibung des Entfernungsmessfehlers eines LiDAR-Scanners ist daher mit einer Normalverteilung strenggenommen nicht möglich. Langerwisch [Lan14] stellt daher ein Verfahren aus der Intervallarithmetik vor, welches den Messfehlerverlauf als unbekannt annimmt, jedoch von bekannten Grenzen der Messfehlern ausgeht.

2.2.2 Akustische Abstandssensoren

LiDAR-Scanner, Ultraschall- und Radarsensoren basieren auf einem ähnlichen Messprinzip. Ultraschall ist eine mechanische Welle, wohingegen Radar und Laser auf elektromagnetischen Wellen basieren. Die genannten Wellenformen unterscheiden sich hinsichtlich ihrer Ausbreitungsgeschwindigkeit. Ultraschallwellen breiten sich mit Schallgeschwindigkeit aus, welche vom durchdrungenem Medium und dessen Temperatur abhängig ist. Dementsprechend muss eine medium- und temperaturabhängige Kalibrierung vollzogen werden. Elektromagnetische Wellen breiten sich mit Lichtgeschwindigkeit aus. Abgesehen von der Elektronik hat die Temperatur keinen nennenswerten Einfluss auf die Genauigkeit des physikalischen Messprinzips von Radarsensoren und LiDAR-Scannern. Sowohl Laser, Radar- als auch Ultraschallwellen unterliegen einer Abnahme der Energie während der Ausbreitung im Raum, sodass ab einem bestimmten Abstand das Signal nicht mehr vom Umgebungsrauschen unterschieden werden kann [KSS]. Mit Ultraschall- und Radarverfahren können sowohl der Abstand mittels Laufzeitmessung, der Winkel mittels mechanischer oder elektronischer Strahlsteuerung als auch die Geschwindigkeit von Objekten durch den Dopplereffekt gemessen werden. Radar- und Ultraschallwellen haben unterschiedliche Eigenschaften bezüglich der Durchdringung von Materie. Radargeräte senden im Mikrowellen-Bereich³⁴. Mikrowellen haben die Eigenschaft von Metallen und elektrischen Leitern reflektiert zu werden. Glas, Kermaik und Kunststoffe werden hingegen durchdrungen. Die mechanischen Wellen des Ultraschalls werden in jedem Medium absorbiert. Der Absorptionsgrad ist vom Material und damit von dessen spezifischer Schallgeschwindigkeit, abhängig. An Materialübergängen wird demzufolge immer ein Teil der Welle reflektiert.

³⁴1-300 GHz

Ultraschallsensoren eignen sich prinzipiell für die Kartierung von Umgebungen und waren historisch gesehen Mitte der neunziger Jahre häufig in Veröffentlichungen zu finden. Die ersten kartenbasierten Umgebungsmodelle wurden von Elfes [Elf89] mit einer mobilen Plattform und einem Ultraschall-Array durchgeführt. Problematische Eigenschaften sind jedoch die geringe Genauigkeit, eine durch die Bandbreite limitierte Auflösung, der Einfluss des Dopplereffekts bei der Eigenbewegung des Roboters und ein im Gegensatz zum LiDAR-Scanner nicht sehr fokussierter Strahl. Da Ultraschallwellen in der Luft sehr stark absorbiert werden, haben Ultraschallsensoren keine große Reichweite.

2.2.3 Radarsensoren

Radarsensoren werden im Gegensatz zu Ultraschall und LiDAR-Scanner relativ selten in der Robotik angewendet und eignen sich kaum für den Indoor-Einsatz. Das Hauptproblem ist vor allem die geringe Entfernungsauflösung von kommerziell erhältlichen Radarsensoren. Fast alle dem Autor bekannten Veröffentlichungen, die Radar in der mobilen Robotik anwenden, basieren auf einem selbst entwickelten, rotierenden Radargerät. Es ist zusätzlich zu berücksichtigen, dass die an sich schon limitierte Distanzauflösung von kommerziellen Radargeräten zusätzlich durch nationale Bandbreitenregulierungen beeinflusst wird. Weiterhin ist zu erwähnen, dass der Preis für Radarsensoren erst in den letzten Jahren auf ein interessantes Niveau gesunken ist. In dieser Dissertation wird untersucht, ob einfache kommerzielle Radarsensoren und ein speziell am Fraunhofer Institut für Hochfrequenztechnik (FHR) entwickelter Scanner zur Umgebungsmodellierung in der mobilen Robotik nutzbar sind. Drei Radarsensoren aus drei unterschiedlichen Einsatzgebieten sind in Abbildung 10 dargestellt.



Abbildung 10: Der Begriff Radarsensor umfasst ein breites Spektrum von Anwendungsfällen. Ein typischer Verwendungszweck in der Automobilindustrie ist das Adaptive Cruise Control (10a). Ein weiteres Anwendungsfeld sind industrielle Füll- und Abstandsmessungen (10b). Radar-Scanner werden auch für Überwachungszwecke auf Flughäfen und Autobahnen verwendet (10c).

³²Quelle: http://produkte.bosch-mobility-solutions.de/de/de/_technik/component/component_1_5251.html, 10.02.2017

³³Quelle: <http://www.innosent.de/isys-systeme/isys-4004/>, 14.04.2019

³⁴Quelle: <http://www.navtechradar.com/>, 14.04.2019

Die Anzahl der Forschungsgruppen, die sich mit dem Einsatz von Radar in der mobilen Robotik beschäftigen, ist gering. Zunächst ist das *Australian Centre for Field Robotics* zu erwähnen, hier wurden bereits Anfang der neunziger Jahre unter Hugh F. Durrant-Whyte grundlegende SLAM-Verfahren mit unscharfen Sensoren entwickelt [CD99]. Das ACFR entwickelt seit dieser Zeit auch eigene Radar-Scanner [CW98] und besitzt heutzutage bemerkenswert gut auflösende Radarsensoren, deren Messwerte der Qualität von LiDAR-Scannern nahe kommen. Neben dem ACFR ist Martin Adams zu erwähnen, dessen Buch *Robotic Navigation and Mapping with Radar* [AMJ12] einen wichtigen Beitrag auf diesem Gebiet darstellt. Adams verwendet für seine Versuche einen kommerziell erhältlichen Navtech Sensor und hat sich auf die Kartierung von Minen in Chile spezialisiert. Sein bekanntester Beitrag ist die Erweiterung des Extended-Kalman-Filter-SLAM mit dem phd-Filter, welches die Datenzuordnung und die Handhabung von falsch detektierten Landmarken verbessert. Die genannten Forschergruppen verfolgen einen landmarkenbasierten SLAM-Ansatz. Ein komplett anderer Ansatz wird vom Institut Pascal mit dem K2Pi Scanner vorgestellt. Das am Institut Pascal entwickelte Verfahren kann die Eigenbewegung durch Scan-Matching mit einer Fourier-Mellin Transformation bestimmen [VCC13]. Die präsentierten Veröffentlichungen zeigen große Rasterkarten. Die genannten drei Forschungsgruppen sind die bekanntesten auf den Gebieten Radar-SLAM und Outdoor-Robotik.

Neben den genannten drei Forschergruppen beschäftigen sich noch weitere Gruppen mit diesem Thema. Das Kartieren von Indoor-Bereichen wurde von Detlefsen [DRL93] und Marck [MMH13] untersucht. Beide Autoren benutzen jeweils einen selbst entwickelten Radar-Scanner, welcher auf einem mechanischen Schwenken eines fokussierten Strahles basiert. Den Aufbau eines weiteren Radar-Scanners und die Präsentation eines 360°-Scans wird in [MNOT15] beschrieben. Die Eignung von Radarsensoren unter sehr harten Umgebungsbedingungen wurde von Foessel [FCA99] bewiesen, der in einer arktischen Umgebung mit einem stationären Aufbau Objekte trotz eines Schneesturms detektierte. In der hier vorliegenden Dissertation wird unter anderem das Laterations-Scan-Prinzip untersucht, das nicht auf einem fokussierten Strahl basiert.

Auch die Automobilindustrie beschäftigt sich mit der Umgebungsmodellierung mittels Radarsensoren, jedoch werden hier rotierende Teile aufgrund des Verschleißes möglichst vermieden. Degerman et al. [DPA16] erstellen mit einem an einem Fahrzeug befestigtem Qamcom Radar ein 3D-Occupancy-Grid, während sie an vier parkenden Autos vorbeifahren. Weiterhin schlagen sie vor, die Rückstrahlleistung des Radars mit in das inverse Sensormodell einfließen zu lassen.

2.2.4 Gassensoren

Gassensoren können eine gasförmige Substanz detektieren und sie in ein elektrisches Signal umwandeln. Die meisten Gassensoren sind für die Detektion eines bestimmten Stoffes konzipiert. Die Sensoren selbst können auf physikalischen und chemischen Messmethoden basieren. Gassensoren werden in Warnsystemen integriert, die zum Beispiel Explosionsgefahren (Methan, Wasserstoff), Brandgefahren (Rauch) oder die Luftqualität (Kohlenmonoxid) überwachen.

Die Olfaktion beschäftigt sich mit der Wahrnehmung und Lokalisierung von Gerüchen (Odors). Die erste Verwendung von Gassensoren in der mobilen Robotik begann in den Neunzigern und fokussierte sich auf das Folgen von Odor-Spuren [Rus95] und dem Aufspüren von Odor-Quellen [ISNM94]. Die hier vorliegende Arbeit stellt ein Verfahren vor, wie mit fusionierten LiDAR- und Radar-Daten Aerosolverteilungen modelliert werden. Statt dass eine Umgebung mit einer bestimmten Anzahl von Sensoren ausgestattet wird, sollen sich die Sensoren auf dem Roboter selbst befinden, der jedoch nur

punktuelle Konzentrationsmessungen vollziehen kann. In der mobilen Robotik bietet es sich an, eine Gasverteilung in einer Rasterkarte darzustellen [FJC⁺07] [SPL09]. Das Eintragen der Werte erfolgt beispielsweise mit einer Gauß-Verteilung um den Messpunkt [LD03]. Eine von Windinformationen abhängige Erweiterung jener Gauß-Verteilung wird von Reggente [RL09] vorgestellt.

2.3 Grundlagen der Umgebungsmodellierung

Für die Umgebungsmodellierung eignen sich externe Sensoren (siehe Abbildung 8, Seite 12) und deren Kombination. Für metrische Umgebungsmodelle werden meistens Abstandssensoren verwendet. Metrische Umgebungsmodelle haben sich in der mobilen Robotik etabliert und eignen sich besonders in strukturierten Umgebungen. Objektbasierte metrische Umgebungsmodelle haben sich in Automobilanwendungen durchgesetzt, wo relevante Objekte im Umfeld eines Fahrzeuges getrackt und in Form einer Objektliste dargestellt werden [Eff09, S. 10].

In der Robotik wird zwischen metrischen, topologischen und semantischen Umgebungsmodellen unterschieden [Lec11, S.26-27]. Metrische Umgebungsmodelle geben Merkmale eines Umfeldes maßstabsgetreu bezüglich der Längeneinheit wieder und werden im Bezug zu einem Koordinatensystem dargestellt. Metrische Umgebungsmodelle können wiederum punktbasiert, gitterbasiert oder objektbasiert sein [Hen12, S. 15-17]. Punktbasierte metrische Umgebungsmodelle basieren auf Rohdaten von 2D- oder 3D-Abstandssensoren oder deren Reduzierung³⁸. Gitterbasierte Umgebungsmodelle basieren auf einer Rasterung des Umfeldes (z. B. Grid-Maps, OctoMaps, Mesh). Das Occupancy-Grid-Mapping-Verfahren, welches bereits 1985 von Moravec und Elfes vorgestellt wurde [ME85], eignet sich besonders zum Erstellen von zweidimensionalen metrischen gitterbasierten Umgebungsmodellen. Die in dieser Arbeit untersuchten Radar-Verfahren werden auch auf ihre Anwendbarkeit für metrische Umgebungsmodellierung evaluiert. Objektbasierte metrische Umgebungsmodelle extrahieren und klassifizieren Objekte aus den Sensormesswerten. Kanten und geometrische Primitive sind robust detektierbare Objekte und eignen sich besonders für landmarkenbasierte Lokalisierungs- und SLAM-Verfahren.

Topologische Umgebungsmodelle beschreiben die Relation einzelner Objekte untereinander. In der Robotik werden topologische Karten als Graphen dargestellt. Ein Knoten oder Zustand dieses Graphen wird von Thrun [TB96] als kritischer Punkt bezeichnet und beinhaltet beispielsweise lokale Bezeichnungen. Die Kanten bzw. Transitionen werden als kritische Linien definiert und können Distanzinformationen beinhalten. Topologische Karten können aus Rasterkarten extrahiert werden und befinden sich dementsprechend auf einem höheren Abstraktionsgrad (siehe Abbildung 11). [TB96] beschreibt wie aus einer Grid-Map einer Indoor-Umgebung mittels Voronoi Algorithmen kritische Punkte wie Kurven und Kreuzungen extrahiert werden können, die sich grafisch als topologischer Graph oder als topologische Regionen darstellen lassen. Topologische Graphen eignen sich um beispielsweise in Multiroboter-Systemen Verklemmungen zu vermeiden oder Erreichbarkeiten zu überprüfen. Gernert et al. [GSW⁺14] verwenden eine topologische Karte um ein Robotersystem, dass kleine Boxen zu vordefinierten Stationen bringt, zu koordinieren.

Das Erstellen von metrischen und topologischen Karten mit LiDAR-Scannern in statischen und strukturierten Umgebungen stellt zum derzeitigen Stand der Wissenschaft kein Problem dar. Schwierigkeiten bereiten hingegen unstrukturierte oder dynamische Umgebungen. Facettenreiche und abwechslungsreiche Strukturen führen bei den meisten Abstandssensoren zu weitaus mehr Schatteneffek-

³⁸Bei Beibehaltung des gleichen Datentyps (z. B. Punktwolke)

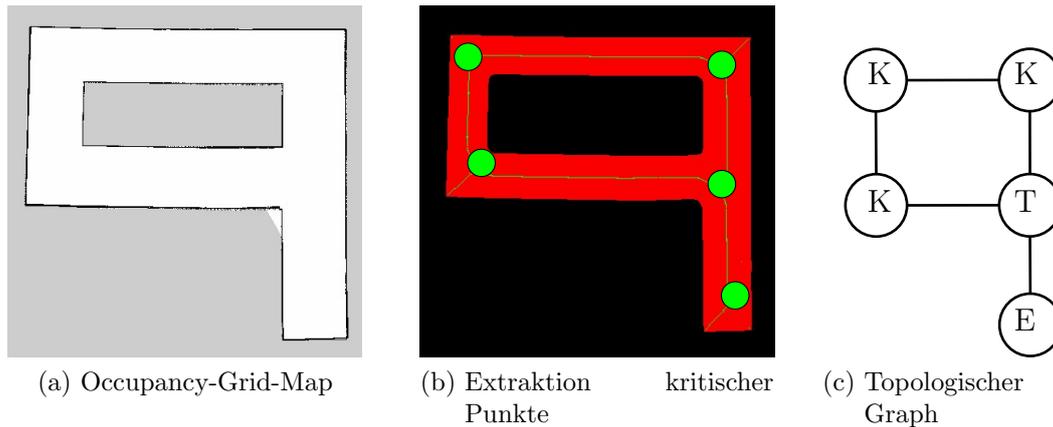


Abbildung 11: Mit Hilfe eines Voronoi-Algorithmus können aus einer Indoor-Umgebung (a) die Koordinaten für Kurven (K), T-Kreuzungen (T) und Sackgassen (E) extrahiert (b) und somit ein topologischer Graph erzeugt werden (c).

ten oder Mehrdeutigkeiten deren Einfluss zusätzlich vom Betrachtungswinkel abhängig ist. Lecking [Lec11] vermeidet das Problem von unstrukturierten Umgebungen am Beispiel eines Industrieumfeldes indem sein Verfahren sich an den Deckenstrukturen lokalisiert, welche wiederum klare Strukturen aufweisen und normalerweise nicht durch andere Objekte verdeckt werden. Dynamische Umgebungen stellen eine weitere Problematik dar. Dynamische Objekte, wie zum Beispiel Passanten, können bei der Kartierung zu Verwischungen führen. Wolf und Sukathme [WS04] stellen ein Verfahren vor, das jeweils eine Grid-Map von statischen und dynamischen Objekten, deren Bewegung mindestens einmal beobachtet wurde, erzeugt. Hierfür wird überprüft ob vor der aktuellen Observation die Zelle belegt war oder nicht. Bei der dynamischen Grid-Map werden nur Zellen mit einer hohen Belegheitswahrscheinlichkeit versehen, deren aktueller Zustand (belegt oder frei) sich geändert hat.

Eine besondere Herausforderung der Umgebungsmodellierung stellen Katastrophen und Rettungsszenarien dar. Hier kommen neben dynamischen und unstrukturierten Verhältnissen noch harsche Umgebungseinflüsse hinzu. Beispielsweise beeinträchtigt Rauch die Qualität der Entfernungsmessungen mit LiDAR-Scannern, da einzelne Rauchpartikel bereits registriert werden können. Ähnliche Effekte werden durch Wassertropfen einer Sprinkleranlage oder von Löschpulver eines Feuerlöschers hervorgerufen. Die Lösung derartiger Probleme ist ein zentraler Gegenstand in dieser Arbeit.

2.3.1 Metrische gitterbasierte Umgebungsmodellierung

Eine Form der metrischen gitterbasierten Umgebungsmodellierung, bei denen die Karte in eine Anzahl von Zellen eingeteilt werden, sind Rasterkarten (Grid-Maps) und Quadtree-Karten (engl. Quadmaps). Die Zellabstände und Zellgrößen bei Rasterkarten sind gleich und bei Quadtree-Karten variabel [Lan14, S. 38-40]. Eine Karte M besteht aus N Merkmalen m_i , welche Koordinaten durch den strukturellen Aufbau der Karte widerspiegeln (Abbildung 12)

$$M = (m_1, m_2, \dots, m_N). \quad (8)$$

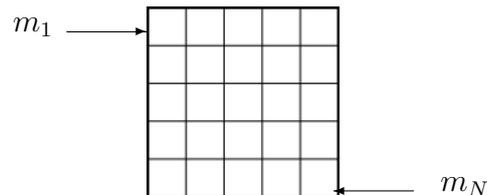


Abbildung 12: Rasterkarte bestehend aus N Merkmalen m_i

Der bis heute verwendete Ansatz von Moravec und Elfes basiert auf der Darstellung eines Abstandssensors durch ein inverses Sensormodell, welches hauptsächlich durch den Öffnungswinkel und den Wahrscheinlichkeiten für eine bzw. keine Detektion eines Objektes definiert ist. Durch Erhöhen bzw. Erniedrigen von Wahrscheinlichkeitswerten der einzelnen Zellen, auf die das inverse Sensormodell fällt, wird demzufolge eine Karte aufgebaut, die mit einem Schwellwert in belegte, unbelegte und unbekannte Regionen eingeteilt werden kann. Die Voraussetzung für dieses Verfahren sind bekannte Positionen des Sensors.

Rasterkarten können auch mit sogenannten Layern M_i aufgebaut werden, um für eine Zelle mehr als einen Informationstyp zu speichern. Bei gleicher Auflösung und Dimension ist der Zellindex für alle m Layer verwendbar, was einen schnelleren Speicherzugriff bedeutet (Abbildung 13)

$$M = (M_1, M_2, \dots, M_m). \quad (9)$$

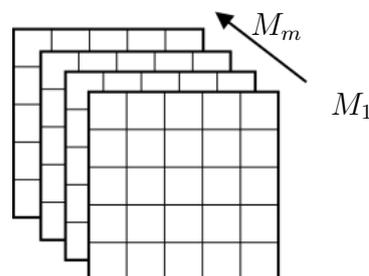


Abbildung 13: Rasterkarte bestehend aus m Layer M_i

Häufig berechnen autonom fahrende Systeme neben der metrischen Darstellung der Umgebung eine

Costmap in einem separaten Layer. Diese *Costmap* bildet zum Beispiel einen Sicherheitsradius um detektierte Objekte, um Kollisionen bei der Navigation und Bahnplanung zu vermeiden. Das in dieser Arbeit vorgestellte Verteilungsmodell für Aerosolkonzentrationen wird auch in einem eigenen Layer gespeichert.

Rasterkarten haben in Abhängigkeit der Karten- und der Zellengröße einen hohen Speicherbedarf, was bereits bei dreidimensionalen Rasterkarten zu Speicherproblemen führt. Eine Quadtree-Karte kann die Zellgrößen flexibel darstellen und zum Beispiel in strukturreichen Gegenden die Auflösung erhöhen. Die Struktur der Karte ist bei Quadtree-Karten keine Matrix sondern eine hierarchische Unterteilung gemäß eines Baumdiagrammes. Bei zweidimensionalen Karten wird stufenweise jedes Gebiet in vier kleinere Gebiete unterteilt, sodass jeder Strang im Baumdiagramm in vier weitere Stränge aufgeteilt wird, bis alle Zellen in einer Gebietsunterteilung den gleichen Wert beinhalten. Eine weitere Unterteilung (eine höhere Auflösung dieses Gebietes) hätte keinen Mehrertrag zur Folge. Die Genauigkeit der Karte ergibt sich aus der definierten maximalen Stufentiefe. Im dreidimensionalen Fall wird jedes Volumen in acht kleinere Volumina geteilt. Diese Rasterkarte wird Octree-Karte (engl. OctoMap) genannt (siehe Abbildung 14).

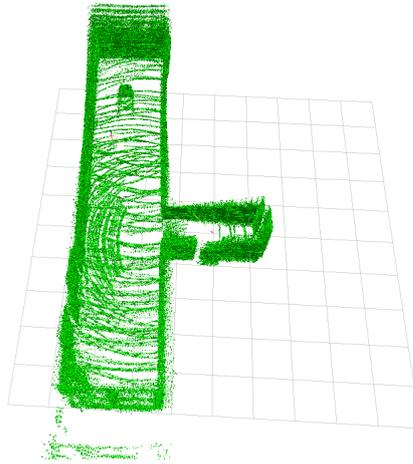


Abbildung 14: 3D-Octree-Karte eines Flures, die mit der Hilfe des Opensource Frameworks OctoMap von Hornung et al. [HWB⁺13] erstellt wurde.

2.3.2 Metrische objektbasierte Umgebungsmodellierung

Metrische objektbasierte Umgebungsmodelle werden in der Literatur oft als Landmarkenkarten bezeichnet. Eine Karte M besteht wiederum aus N Merkmalen m_i , jedoch ergibt sich die Position des Merkmals nicht durch die Datenstruktur der Karte, sondern wird im Merkmal gespeichert. Zusätzlich können Merkmale in einer Landmarkenkarte eine Signatur s_i beinhalten

$$m_i = (x_i, y_i, s_i). \quad (10)$$

Signaturen sind zusätzliche Informationen über die Landmarke³⁹. Signaturen ermöglichen eine bessere Unterscheidung von Landmarken untereinander, was die Datenzuordnung robuster und schneller macht. Landmarken können aus verschiedenen Positionen wiedererkannt werden und unterscheiden sich von der Umgebung, sodass sie sicher detektiert werden können. Weiterhin sind sie voneinander unterscheidbar und statisch [RB, S. 18]. Landmarken unterteilen sich in natürliche und künstliche Landmarken. Künstliche Landmarken werden der Umgebung hinzugefügt und sind an das Sensorprinzip angepasst. Zum Beispiel eignen sich Zylinder [Bre15] oder Retroreflektoren [CTH⁺03] als künstliche Landmarken für LiDAR-Scanner. Für Kameras eignen sich QR-Tags, Barcodes [AGSZ13] und LEDs [KAL11] die gleichzeitig eine Signatur bereitstellen können. Vorst et al. [VSYZ08] bestücken Regale in einem Supermarkt mit RFID-Tags und können somit die Position einer mobilen Plattform 30 cm genau bestimmen. Selbst Geräuschquellen können als Landmarken für Plattformen mit Mikrofonen zur Lokalisierung verwendet werden [LIZ⁺07]. Clark [CDW98] zeigt am bereits erwähnten ACFR⁴⁰, dass Winkelreflektoren in Outdoor-Umgebungen als künstliche Landmarken für einen Radar-Scanner [CW98] verwendet werden können. In Clarks Veröffentlichung [CDW98] führt jede Detektion eines Objektes in der FFT⁴¹ (nähere Erläuterung in Kapitel 2.6.4) zu einer detektierten Landmarke, die in einen Kalman-Filter-SLAM (siehe Kapitel 2.4) inkludiert wird. Falsche Detektionen wirken sich jedoch negativ auf den EKF⁴²-SLAM-Zyklus aus und führen zu falschen Landmarken im Zustandsvektor, wodurch zum einen die Karte unbrauchbar wird und zum anderen die Roboterposition nicht mehr sinnvoll bestimmt werden kann.

Die Detektion von natürlichen Landmarken ist schwieriger als das Detektieren künstlicher Landmarken und setzt voraus, dass eine Umgebung diese natürlichen Features beinhaltet. Grundsätzlich können Umgebungen in Indoor- und Outdoor-Umgebungen eingeteilt werden, wonach die Detektionsverfahren dementsprechend ausgewählt werden müssen. In Indoor-Umgebungen eignen sich geometrische Primitive⁴³ als natürliche Landmarken. Nguyen et al. [NMTS05] vergleichen sechs gängige Extraktionsalgorithmen für Linien. Nüchter et al. [N05] beschreiben wie mittels der Gradienten benachbarter Punkte in einer Punktwolke einer Indoor-Umgebung zwischen Böden, Decken, Wänden und Objekten unterschieden werden kann. Wübbold [WW12] stellt ein Verfahren zur Klassifizierung von einfachen Geometrien in 3D-LiDAR-Scanner-Daten vor. Die Extraktion natürlicher Landmarken in Outdoor-Umgebungen ist anspruchsvoll. Wenn die Outdoor-Umgebung urbane Elemente beinhaltet, dann kann mit LiDAR-Scannern weiterhin mit geometrischen Primitiven (Häuserwände, Laternen, usw.) gearbeitet werden [Wul08, S. 59]. Maeyama et al. [MOY98] detektieren Bäume als natürliche Landmarken und nehmen einen durchschnittlichen Baumradius als Detektionskriterium.

³⁹Z. B. Farben, Tag-ID-Nummern, geometrische Form, etc.

⁴⁰Australien Centre for Field Robotics (ACFR)

⁴¹Engl. Fast Fourier Transformation (FFT)

⁴²Engl. Extended Kalman Filter (EKF)

⁴³Z. B. Ecken, Kanten, Flächen, usw.

2.3.3 Modellierung von Punktmessungen und physikalische Grundlagen von Stoff- und Transportvorgängen

In Abhängigkeit des Anwendungsgebietes des mobilen Systems können Umgebungsmodelle zusätzliche Informationen beinhalten, die mit entsprechenden anwendungsspezifischen Sensoren (siehe Abbildung 8, Seite 12) ermittelt werden müssen. Sensoren, die nur zu einem bestimmten Zeitpunkt an einem Ort einen Messwertwert ermitteln können, sind beispielsweise Gassensoren, Rauchsensoren, Temperatursensoren oder Geigerzähler. Aufgrund der geringen Menge an Informationen dieser Sensoren ist die Darstellung der Messgrößen in einem Umgebungsmodell schwierig. Nielsen et al. [NGB⁺08] visualisieren Messwerte eines Geigerzählers entlang des Pfades des Roboters. Diese einfache Methode gibt jedoch dem Betrachter eine Vorstellung über die Verteilung der Messwerte im Umgebungsmodell. Über Gebiete, die nicht befahren wurden, können jedoch keine Aussagen getroffen werden. Mit der Integration von Gasmessungen in Umgebungsmodelle in der mobilen Robotik beschäftigt sich die Olfaktion. Lilienthal [LD03] stellt ein Verfahren vor, mit dem eine Rasterkarte mit einer gaußverteilten Dichtefunktion in jeder Messung aktualisiert wird. Gassensoren können einen Messwert nur an einem bestimmten Ort messen. Der Grund für die Aufnahme dieses Themas ist, dass in dieser Arbeit ein Verfahren vorgestellt wird, das aus fusionierten LiDAR- und Radar-Daten Aerosolkonzentrationen abschätzen kann, welche sich ähnlich wie Gase ausbreiten. Transportprozesse von Teilchen (Aerosole) oder Temperaturen werden in der Physik durch die Konvektions-Diffusions-Gleichung beschrieben. Die allgemeine Formel, also ungebunden an eine physikalische Größe⁴⁴, lautet für den eindimensionalen Fall

$$\frac{\partial u}{\partial t} = v \frac{\partial u}{\partial x} + d \frac{\partial^2 u}{\partial x^2}. \quad (11)$$

Die Gleichung setzt sich aus dem zweiten Fick'schen Gesetz und einem Konvektionsterm zusammen. Das zweite Fick'sche Gesetz beschreibt Diffusionsvorgänge. Wenn zum Beispiel ein Tropfen Tinte in ein Glas Wasser gegeben wird, dann wird sich farblich sichtbar die Tinte im Laufe der Zeit im Glas verteilen. Die Diffusion ist zeitlich nicht konstant und wird immer mehr abnehmen, da die Konzentrationsunterschiede geringer werden. Das Gesetz für einen konstanten Diffusionskoeffizienten d lautet

$$\frac{\partial u}{\partial t} = d \frac{\partial^2 u}{\partial x^2}. \quad (12)$$

In dieser Arbeit wird die Konzentrationsgröße LRR (LiDAR-Radar-Ratio) mit der Konvektions-Diffusions Gleichung modelliert ($u = LRR$). Um die partielle Differentialgleichung 11 zu lösen, wird in dieser Arbeit ein einfaches aber in weicher Echtzeit berechenbares Verfahren der Finite-Differenzen-Methoden benutzt. Mit der Finiten-Differenzen-Methode wird ein nichtalgebraischer in einen algebraischen Ausdruck umgewandelt, um ihn auf einem Computer zu lösen. Dafür muss der Raum, auf dem die Gleichung angewendet werden soll, diskretisiert werden. Eine Diskretisierung der Umgebung erfolgt in der Robotik häufig im Zusammenhang mit der Erstellung eines metrischen Umgebungsmodells (siehe Kapitel 2.3.1). In dieser Arbeit wird vorgeschlagen, gitterbasierte metrische Umgebungsmodelle (Rasterkarten) für die Knotendarstellung der Finite-Differenzen-Methode zu verwenden.

Um die Ableitungen in der Gleichung 11 durch algebraische Ausdrücke zu ersetzen, werden die Terme durch Differenzquotienten ersetzt. Die vorwärtigen, rückwertigen und zentralen Differenzquotienten

⁴⁴Z. B. $u =$ (Gaskonzentration, Rauchkonzentration, Energie, Temperature, etc.)

für die ersten Ableitungen nach dem Ort lauten

$$u' \approx \frac{u(x + \Delta x) - u(x)}{\Delta x}, \quad u' \approx \frac{u(x) - u(x - \Delta x)}{\Delta x}, \quad u' \approx \frac{u(x + \Delta x) - u(x - \Delta x)}{2\Delta x}. \quad (13)$$

Diese Quotienten können mit der Taylorreihe hergeleitet werden. Die weggelassenen Reste sind für jeden Differenzquotienten in Abhängigkeit von Δx unterschiedlich groß.

Äquivalent kann die zweite Ableitung bestimmt werden. Der zentrale Differenzquotient lautet

$$u''(x) \approx \frac{u(x + \Delta x) - 2u(x) + u(x - \Delta x)}{\Delta x^2}. \quad (14)$$

Für die Endknoten gilt

$$u''(x) \approx 2 \cdot \frac{u(x + \Delta x) - u(x)}{\Delta x^2}, \quad (15)$$

$$u''(x) \approx -2 \cdot \frac{u(x) - u(x - \Delta x)}{\Delta x^2}. \quad (16)$$

Somit können bereits stationäre Probleme gelöst werden, d.h. $\frac{\partial u}{\partial t} = 0$. Da die Simulation der Verteilung im Umgebungsmodell sich jedoch zeitlich anpassen und kontinuierlich neue Sensormessungen integrieren soll, muss die Ableitung nach der Zeit $\frac{\partial u}{\partial t}$ auch betrachtet werden. Für Differenzquotienten der zeitlichen Ableitung kann zwischen der expliziten und impliziten Variante unterschieden werden. Beim expliziten Verfahren muss kein Gleichungssystem gelöst werden. Für das Fick'sche Gesetz mit einer vorwärtigen Zeit und zentralen Diffusion ergibt sich folgende Beziehung

$$\frac{U_j^{t+1} - U_j^t}{\Delta t} = d \frac{U_{j-1}^t - 2U_j^t + U_{j+1}^t}{\Delta x^2}, \quad (17)$$

$$U_j^{t+1} = U_j^t + d \frac{\Delta t}{\Delta x^2} (U_{j-1}^t - 2U_j^t + U_{j+1}^t). \quad (18)$$

Bei der impliziten Variante muss für jeden Zeitschritt ein Gleichungssystem gelöst werden, da eine einzelne Gleichung allein nicht lösbar ist

$$\frac{U_j^{t+1} - U_j^t}{\Delta t} = d \frac{U_{j-1}^{t+1} - 2U_j^{t+1} + U_{j+1}^{t+1}}{\Delta x^2}, \quad (19)$$

$$U_{j,t+1} = U_j^t + d \frac{\Delta t}{\Delta x^2} (U_{j-1}^{t+1} - 2U_j^{t+1} + U_{j+1}^{t+1}). \quad (20)$$

Demzufolge können verschiedene Annäherungen für die Gleichung 11 aufgestellt werden. Die explizite Variante mit vorwärtiger Zeit, zentraler Konvektion und zentraler Diffusion lautet beispielsweise

$$\frac{U_j^{t+1} - U_j^t}{\Delta t} = v \frac{U_{j+1}^t - U_{j-1}^t}{2\Delta x} + d \frac{U_{j+1}^t - 2U_j^t + U_{j-1}^t}{\Delta x^2}. \quad (21)$$

Die explizite Variante ist wesentlich einfacher und ressourcenschonender implementierbar, da jeder Zellwert einzeln berechnet werden kann. Jedoch müssen Stabilitätskriterien erfüllt werden, um beispielsweise ein Aufschwingen zu verhindern. Mit der Peclet Zahl $P = \frac{c\Delta x}{2d}$ und $R = \frac{d\Delta t}{\Delta x^2}$ kann jeder

neue Knotenwert gemäß der Gleichung 21 folgendermaßen berechnet werden [Str06]

$$U_j^{t+1} = (1 - 2R)U_j^t + (R + RP)U_{j+1}^t + (R - RP)U_{j-1}^t. \quad (22)$$

Die Stabilitätsbedingungen sind erfüllt, wenn alle drei Koeffizienten positiv sind. Demzufolge muss $R < 0.5$ sein [Str06]. Nach dem Von Neumann Kriterium ausgedrückt muss folgendes erfüllt sein

$$\frac{2d\Delta t}{\Delta x^2} \leq 1. \quad (23)$$

2.4 Simultaneous Localization and Mapping

Die Lokalisierung unter der Voraussetzung einer bekannten Karte⁴⁵ oder die Kartierung unter der Voraussetzung einer bekannten Position⁴⁶ ist nicht problematisch. Jedoch ist zum einen nicht immer eine Karte einer Umgebung vorhanden und zum anderen unterliegen mobile Roboter systematischen⁴⁷ und nicht-systematischen⁴⁸ Fehlern, wodurch der Fehler in der Positionsbestimmung durch die Koppelnavigation immer größer wird. Das genannte Problem muss mit einer gleichzeitigen Lokalisierung und Kartierung (SLAM⁴⁹) gelöst werden. Die Herausforderung jedes SLAM-Verfahrens ist, dass eine genaue Karte für die Positionsbestimmung des Roboters notwendig ist, aber auf der anderen Seite eine genaue Position des Roboters notwendig ist, um eine genaue Karte zu erstellen. In den letzten 30 Jahren wurden viele SLAM-Verfahren entwickelt. Eine gute Übersicht wird von Niko Sünderhauf [Sün12, S. 22] gegeben (Siehe Abbildung 15 und 16).

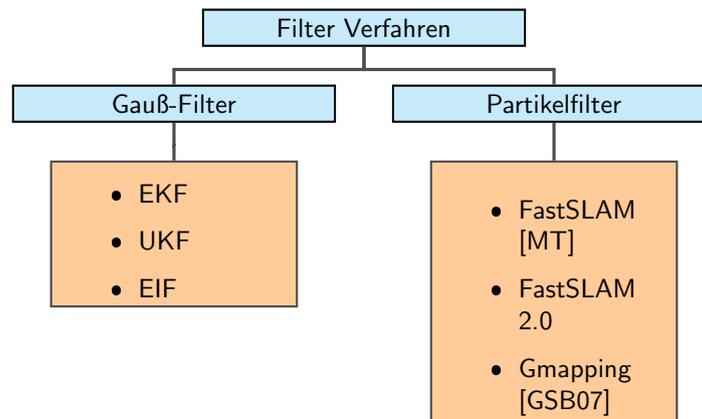


Abbildung 15: Übersicht filterbasierter SLAM-Verfahren

Historisch gesehen ist der EKF⁵⁰-SLAM einer der ersten SLAM-Algorithmen und ist eine Implementierung der Erweiterung des Kalman-Filters für nichtlineare Fälle [TBF05, S. 312]. Mit dem EKF-SLAM, der von Smith [SC86] vorgestellt wurde, können Landmarkenkarten, unter der Voraussetzung von normalverteilten Messfehlern, erstellt werden. Die Zustandsschätzung einer neuen

⁴⁵Z. B. Scan-Matching, Iterative Closest Point (ICP), Monte-Carlo-Lokalisation, etc.

⁴⁶Z. B. Occupancy-Grid-Mapping, etc.

⁴⁷Z. B. unterschiedliche Radgrößen, begrenzte Auflösung der Rad-Drehgeber

⁴⁸Z. B. unebener Untergrund, Schlupf durch starke Beschleunigung, Drehung oder äußere Krafteinwirkung, Störobjekte auf dem Untergrund

⁴⁹Engl. Simultaneous Localization and Mapping (SLAM)

⁵⁰Engl. Extended Kalman Filter (EKF)

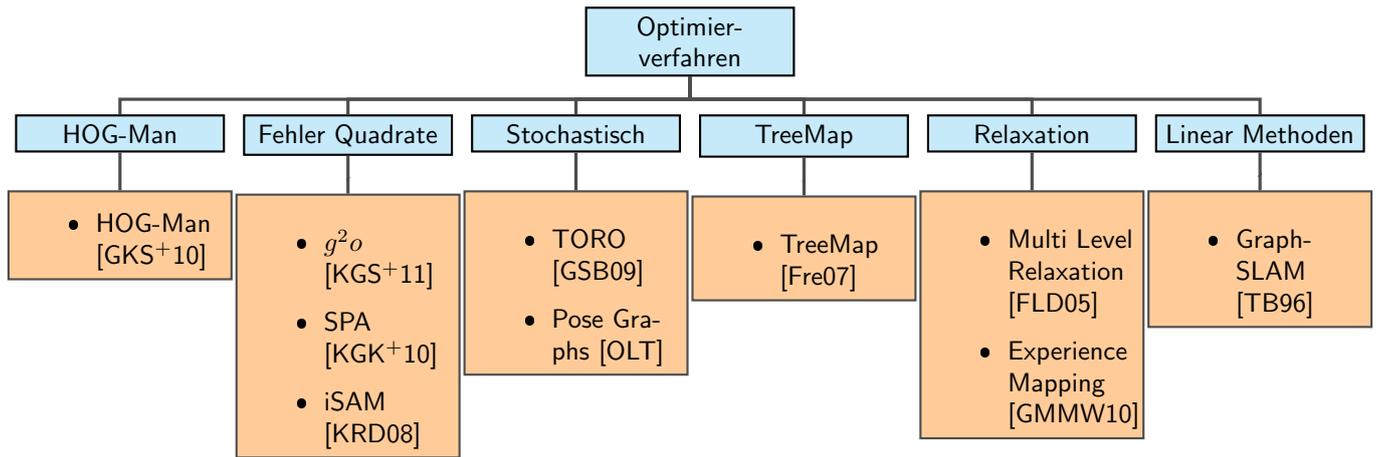


Abbildung 16: Übersicht über SLAM-Verfahren basierend auf Optimierungen

Position und Orientierung des Roboters $\vec{x}_R = (x, y, \Theta)^T$ erfolgt über das Bewegungsmodell bei gegebenen Radbewegungen. Der Systemzustand wird über den Zustandsvektor bzw. Erwartungswert und der dazugehörigen Kovarianzmatrix beschrieben. Der Erwartungswert für den Zustandsvektor μ beinhaltet neben x_R auch die Positionen der N Landmarken ($M = [x_1, y_1, \dots, x_N, y_N]$) und hat die Dimension im zweidimensionalen Fall $2N + 3$,

$$\mu = \begin{pmatrix} x_R \\ M \end{pmatrix}. \tag{24}$$

Zusätzlich zum Zustandsvektor wird eine Kovarianzmatrix für jeden Zyklus ermittelt, mit der der Fehler in der Positionsschätzung des Roboters und der Landmarken ausgedrückt wird

$$\Sigma = \begin{pmatrix} \Sigma_{x_R x_R} & \Sigma_{x_R M} \\ \Sigma_{M x_R} & \Sigma_{M M} \end{pmatrix}. \tag{25}$$

Die Schätzung der Positionen der Landmarken ergibt sie aus den Sensormesswerten. Nach einer Messung erfolgt die Datenassoziiierung bzw. Datenzuordnung. Typische Entscheidungskriterien der Datenzuordnung sind die Berechnung der euklidischen oder Mahalanobis-Distanzen zwischen den Landmarken im Zustandsvektor und der detektierten Landmarken im aktuellen Messzyklus. Dadurch wird eine Landmarke entweder einer bestehenden zugeordnet, wodurch ihre Position und Varianz im Korrekturschritt aktualisiert wird, oder es wird eine neue Landmarke dem Zustandsvektor zugefügt.

Eine Variation des EKF-SLAMs ist der EIF⁵¹-SLAM, welcher μ und Σ in eine Informationsmatrix bzw. einen Informationsvektor transformiert. Der EIF-SLAM führt zum gleichen Resultat wie der EKF SLAM und unterscheidet sich nur im Rechenaufwand, wobei die Prädiktion rechenaufwändiger und die Korrektur schneller als beim EKF ist [Sta12].

Ein Partikel-Filter-SLAM, der sich aufgrund seiner Robustheit bewährt hat, ist FastSLAM, der von Montemerlo [MT07] vorgestellt wurde. Beim EKF-SLAM werden der Roboter und die Landmarken seiner Umgebung mit einer multimodalen Gauß-Verteilung durch Zustandsvektor und zugehöriger Kovarianzmatrix dargestellt. FastSLAM modelliert den Roboterzustand nicht über Erwartungswert

⁵¹Engl. Extended Information Filter (EIF)

und Varianz, sondern mit einer definierbaren Anzahl von möglichen Roboterpositionen, die durch Partikel repräsentiert werden. Dadurch ist die Unsicherheit nicht mehr an eine Gauß-Verteilung sondern an die Partikeldichte gebunden. Beim klassischen Partikel-Filter-SLAM steigt jedoch die Anzahl der Partikel exponentiell zur Anzahl der Landmarken, was einen hohen Rechenaufwand bei steigender Zahl an Landmarken bedeutet. Beim FastSLAM wird daher der Rao-Blackwellised-Partikelfilter verwendet, bei dem nur die Roboterposition durch Partikel repräsentiert wird, wodurch jeder einzelne Partikel einen eigenen Pfad hat. Für jeden Partikel werden die Landmarken durch jeweils einen EKF Gauß-verteilt dargestellt.

Eine SLAM-Methode, die auf Optimierungen beruht, ist GraphSLAM [TB96]. Beim GraphSLAM-Verfahren werden die relativen Beziehungen zwischen den Positionen und Landmarken nach dem Prinzip von elastischen Bändern in der Informationsmatrix Ω und ξ festgehalten. Danach kann der Systemzustand μ , der die gesamten Positionen des Roboters und die Landmarken enthält, mit folgender Gleichung einfach berechnet werden

$$\mu = \Omega^{-1}\xi. \quad (26)$$

In dieser Arbeit wird der EKF-SLAM als ein mögliches SLAM-Verfahren für den Laterations-Scanner vorgeschlagen und untersucht. Der Grund für die Wahl dieses Ansatzes ist, dass dieser Filter die Positionsschätzung verbessern kann, selbst wenn nur eine einzige Landmarke erkannt wird, da mit dem Laterations-Scanner weitaus weniger Informationen aus einer Umgebung entnommen werden können, als mit einem LiDAR-Scanner oder dem MPR⁵².

SLAM-Verfahren, die nicht auf Datenzuordnungen von Landmarken basieren, arbeiten z. B. mit der Registrierung von aufeinanderfolgenden Scans (engl. matching, registration). Ein Verfahren zur Registrierung ist zum Beispiel der ICP-Algorithmus. Mit dem ICP-Algorithmus kann eine Rotation R_{ICP} und eine Translation t_{ICP} von aufeinanderfolgenden Scans bestimmt werden. Dabei wird der Fehler, meist die Summe der Abstände der nächsten Nachbarn beider Scans, minimiert. Die Realisierung eines SLAM-Verfahrens basierend auf einzelnen ICP-Berechnungen zwischen jedem Scan und der sich aufbauenden Karte M wurde in [HB10] vorgestellt

$$x_{R,t} = R_{ICP}x_{R,t-1} + t_{ICP}. \quad (27)$$

⁵²Engl. Mechanical Pivoting Radar (MPR)

2.5 Grundlagen der Datenfusion und Sensorintegration und existierende Methoden in Kombination mit Radar

Die Integration und Fusion von Radar mit anderen externen Sensoren ist selten in der mobilen Robotik zu finden. Ein Grund dafür ist, dass der Nutzen von Radarsensoren für die meisten Anwendungen im Verhältnis zum Beschaffungspreis und Auswertungsaufwand im Vergleich zu LiDAR-Scannern gering ist. Jedoch existiert eine Anzahl von Veröffentlichungen, die die Fusion von Ultraschall und LiDAR-Daten beschreiben.

Die Termini Daten- und Informationsfusion werden in der Literatur synonym verwendet und beziehen sich auf Prozesse, die sowohl Sensorrohdaten als auch andere Informationen verknüpfen [RP07], sodass ein Mehrwert entsteht. Ein Mehrwert entsteht beispielsweise, wenn ein genaueres Messergebnis erzielt werden kann, eine zusätzliche Messgröße zum Messzeitpunkt ermittelt wird, die Ermittlung der Messwerte robuster wird oder abstraktere Informationen aus der Messsituation abgeleitet werden können. Die Begriffe Sensor- oder Multisensorintegration beschreiben die Kombination gleicher oder unterschiedlicher Sensoren von gleichen oder unterschiedlichen Positionen und Zeitpunkten. Die Integration unterteilt sich in folgende Fälle:

- Konkurrierende Integration bezieht sich auf Sensoren, die die gleiche Messgröße über ein Objekt oder Zustand liefern und somit eine Reduzierung der Unsicherheit ermöglichen.
- Komplementäre Integration bezieht sich auf Sensoren, die sich zum Beispiel durch unterschiedliche Messbereiche gegenseitig ergänzen.
- Kooperative Integration bezieht sich auf Sensoren, die nur im Zusammenspiel eine Nutzinformation liefern.

In Abhängigkeit des Integrationsprinzips können verschiedene Fusionsmethoden angewendet werden. Bei der konkurrierenden Integration bieten sich Entscheidungen und gewichtete Durchschnitte an, wohingegen ein Durchschnitt bei der komplementären Integration die Messergebnisse verfälschen würde. Bei der komplementären Integration bieten sich Schwellwerte an. Ein Beispiel für eine komplementäre Integration ist die Verwendung von zwei Sensoren mit gleichen Messgrößen jedoch mit unterschiedlichen Messbereichen. Kooperative Integrationen basieren auf physikalischen oder geometrischen Zusammenhänge. In dieser Arbeit werden konkurrierende, komplementäre und kooperative Integrationsmethoden mit Radar behandelt. Der Laterations-Scanner (Kapitel 3) stellt eine kooperative Integration von mehreren Radarsensoren des selben Typs dar. Die Fusionierung von einzelnen LiDAR- und Radar-Scans (Kapitel 4.4) unterteilt sich in einen komplementären Bereich, da die Sensoren unterschiedliche Reichweiten haben, und in einen konkurrierenden Bereich.

Castro [CP12] stellt eine Methode zur Fusionierung von Radar- mit LiDAR-Scan-Punkten vor, welche die kleinsten euklidischen Abstände zwischen Radar- und LiDAR-Punkten berechnet und diesen mit einem Schwellwert zwecks einer Entscheidung vergleicht. Somit konnten fehlerhafte LiDAR-Messwerte, die aufgrund einer Staubaufwirbelung entstanden sind, verworfen werden. Santos [MSCPR14] fusioniert einen LiDAR-Scanner mit Ultraschallsensoren in einer verrauchten Umgebung indem in Abhängigkeit eines Gassensors entweder dem LiDAR oder dem Ultraschall vertraut wird. Yamauchi [Yam10] verwendet Radar und LiDAR zur Hindernisvermeidung.

In der Literatur wird häufig zwischen numerischen und geometrischen Fusionsmethoden unterschieden. Die numerische Fusion kann als die direkte Verknüpfung von Sensorrohdaten betrachtet werden.

Die einfachste Form der numerischen Fusion ist der gewichtete Mittelwert von Messwerten z die einer Normalverteilung folgen. Diese Form eignet sich bei konkurrierender Sensorintegration

$$z = \frac{\sigma_{z2}^2}{\sigma_{z1}^2 + \sigma_{z2}^2} z_1 + \frac{\sigma_{z1}^2}{\sigma_{z1}^2 + \sigma_{z2}^2} z_2. \quad (28)$$

Eine Fusionierung von Linien und Ecken, die aus LiDAR- und Ultraschalldaten segmentiert werden, mit einem gewichteten Mittelwert wird von Diosi und Kleeman vorgestellt [DK04, S. 1858].

Geometrische Fusionsmethoden werden zum Beispiel im Automobilbereich zur Erstellung einer lokalen Rasterkarte für PreCrash-Sicherheitsanwendungen verwendet [SL05]. Geometrische Fusionsmethoden lassen sich prinzipiell mit den numerischen Fusionsmethoden kombinieren. Eine Variante zur Umgebungsmodellierung ist die Fusionierung einer Anzahl von Abstands-Sensoren mit jeweils einem eigenen inversen Sensormodell in einer Rasterkarte. Bei unterschiedlichen Messzyklen der jeweiligen Sensoren ist darauf zu achten, dass der Sensor mit der höchsten Messrate am häufigsten zu einem Update mit seinen Werten in der Rasterkarte führt und dadurch eine höhere Gewichtung hat. Die Messfrequenzunterschiede sollten jedoch keinen Einfluss auf die Entstehung der Rasterkarte haben, sodass eine Synchronisierungsstrategie implementiert werden muss.

Bei den Synchronisierungsvarianten der Sensorintegration wird zwischen synchronen und asynchronen Verfahren unterschieden. Synchroner Verfahren sind mit den gleichen Sensortypen des gleichen Herstellers am einfachsten zu realisieren. Einige Sensoren können durch externe Signale oder Befehle getriggert werden. Interne Verzögerung zwischen Triggerung und Messwertaufnahme sind jedoch in den meisten Fällen unbekannt. Wenn Sensoren keine Zeitstempel für den Messzeitpunkt liefern, wird häufig ein Zeitstempel durch die datenverarbeitende Einheit des Sensorsystem hinzugefügt. Da die Abarbeitung der Algorithmen in intelligenten und integrierten Sensoren Zeit in Anspruch nimmt, kommt es unweigerlich zu einer unbekanntem Latenz. Eine asynchrone Fusionierung erfolgt über einen Fusionstakt, der sich aus dem langsamsten Sensor definiert. Häufig wird für Sensordaten, die vor dem Fusionszeitpunkt aufgenommen wurden, eine Prädiktion zum Fusionszeitpunkt berechnet.

In dieser Arbeit werden drei Fusionsverfahren vorgestellt. Die Synchronisierung der asynchronen Sensoren erfolgt dabei in der Vorverarbeitung. Die *modellbasierte* (siehe Kapitel 4.4.2) und *heuristische Fusion* (siehe Kapitel 4.4.3) stellen numerische Fusionsmethoden dar. Das *Virtuelle Sensor Verfahren* (siehe Kapitel 4.4.4) entspricht einer geometrischen Fusionsmethode.

2.6 Radargrundlagen

Ein Radar-System sendet elektromagnetische Wellen im Gigahertz-Bereich aus. In Abhängigkeit der Form und Materialeigenschaft eines Objektes kann es zu optischen Effekten wie Reflexion, Brechung und Beugung dieser Wellen kommen. Reflektierte Wellen können von einem Empfänger detektiert werden. Aus der Signallaufzeit Δt und bei Lichtgeschwindigkeit c ist die Entfernung R eines Objektes zu einem Radarsensor bestimmbar. Da die Welle nach der Detektion den Hin- und den Rückweg zu dem Objekt zurückgelegt hat, muss der ermittelte Abstand halbiert werden

$$R = \frac{c \cdot \Delta t}{2}. \quad (29)$$

Wenn elektromagnetische Wellen mit der Wellenlänge λ an einem dynamischen Objekt reflektiert werden, dann kommt es zur Streckung oder Stauchung der Sendefrequenz f . Die Differenz zwischen gesendeter und empfangener Frequenz wird Dopplerfrequenz f_{Dopp} genannt und ist proportional zur Geschwindigkeit des sich bewegenden Objektes

$$v = \frac{f_{Dopp} \lambda}{2}. \quad (30)$$

Die Reflexionseigenschaften hängen von der Form, der Oberfläche und dem Material des Objektes ab. Die Signalleistung am Empfänger P_e kann nach einer diffusen Reflexion an einem Punktziel mit folgender Formel beschrieben werden und dient als generelles Verständnis der Detektion von Objekten [Wei, S. 7]

$$P_e = P_s \cdot \frac{G_e G_s \lambda^2 \sigma}{(4\pi)^3 R^4}. \quad (31)$$

Diese Gleichung gilt nur für sogenannte elektrisch kleine Streukörper. Der Bruch in Gleichung 31 bestimmt inwiefern die Sendeleistung P_s abgeschwächt wird. Der Radarquerschnitt σ ist abhängig vom Objekt (Tabelle 1). G_e stellt den Gewinn der Empfänger- und G_s den Gewinn der Sendeantenne dar. Der Antennengewinn G ist ein Faktor der sich aus der Leistung der Antenne durch die Leistung einer Referenzantenne ergibt. Als Referenzantenne wird häufig ein Kugelstahler genommen⁵³. Normalerweise ist der Antennengewinn senkrecht zur Antenne in der Hauptkeule am größten. Ein Parabolspiegel bündelt beispielsweise die Hauptkeule und sorgt für einen hohen Antennengewinn und somit eine höhere Reichweite. Die Hersteller von Radarsensoren stellen in ihren Datenblättern Antennendiagramme zur Verfügung, aus denen jedoch nicht direkt der Antennengewinn abgelesen werden kann. Die Werte in einem Antennendiagramm beziehen sich auf den Maximalwert der Hauptkeule. Die physikalisch maximale Reichweite eines Radarsensors kann durch Umstellen der Gleichung 31 nach dem Abstand zwischen Objekt und Sensor R erfolgen

$$R_{max} = \sqrt[4]{\frac{P_s G_s G_e \lambda^2 \sigma}{(4\pi)^3 P_{e_{min}}}}. \quad (32)$$

Der maximale messbare Abstand ergibt sich über die minimale detektierbare Leistung am Empfänger $P_{e_{min}}$. Kleinere Leistungen können nicht vom Umgebungsruschen unterschieden werden. Die maximale Sendeleistung P_s ist jedoch gesetzlich limitiert⁵⁴.

⁵³Wird der Antennengewinn in Dezibel angegeben, weist die Einheit [iDB] auf den isotropen Kugelstrahler hin

⁵⁴Engl. Equivalent Isotropic Radiated Power (EIPR) und Antennengewinn G

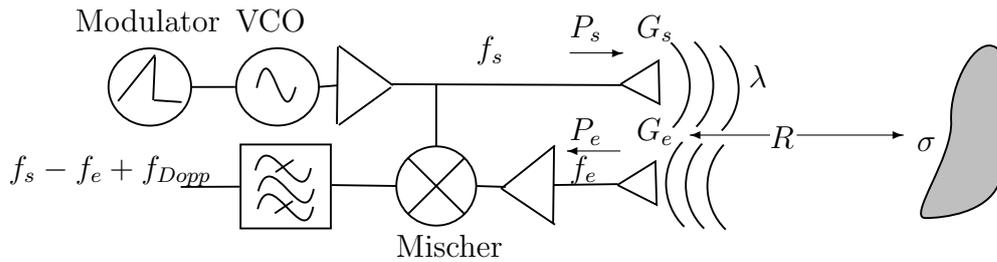


Abbildung 17: Der Zusammenhang zwischen Sende- und Empfängerleistung hängt hauptsächlich vom Antennengewinnen G , dem Abstand R , der Trägerfrequenz λ und dem Radarquerschnitt σ ab.

Große Objekte können nicht als Kugelstrahler gesehen werden. Eine planare unendlich große metallische Oberfläche streut die Strahlen nicht isotropisch in alle Richtung, sondern sorgt für eine Umkehrung der Ausbreitungsrichtung. In diesem Fall nimmt die Leistung an der Empfängerantenne bezüglich des Abstandes R zum Sensor nur mit dem Faktor $\frac{1}{R^2}$ ab.

Der prinzipielle Aufbau eines FMCW⁵⁵-Radars ist in der Abbildung 17 dargestellt. Ein frequenzmoduliertes Signal wird mit einem Modulator und einem spannungsgesteuerten Oszillator (engl. Voltage-Controlled Oscillator (VCO)) erzeugt, verstärkt und über eine Antenne ausgestrahlt. Nach der Reflexion an einem Objekt wird das Signal mit einer Empfängerantenne erfasst, verstärkt und mit dem Sendesignal gemischt. Das Differenzsignal wird gefiltert, digitalisiert, Fourier-transformiert und an die Detektionsalgorithmen weitergeleitet. Neben der Wellenlänge der Trägerfrequenz λ spielt der Radar-Querschnitt (engl. Radar Cross Section) σ eine wichtige Rolle bei der Detektion von Objekten. Der Radarquerschnitt stellt die effektive Rückstrahlfläche eines Objektes dar. Eine Übersicht über ausgewählte Objekte bei einer Trägerfrequenz von 24 GHz ist in Tabelle 1 gegeben.

Objekt	RCS in $[m^2]$
PKW	10
Garagentor	> 100
Schiff	> 1000
Mensch	1
Winkelreflektor (15 cm Kantenlänge)	13

Tabelle 1: Empirische Werte des RCS. Je höher der RCS, desto höher ist die Wahrscheinlichkeit, dass das Objekt vom Radarsensor detektiert wird. Winkelreflektoren sind aufgrund ihrer Bauweise sehr gute Radarziele.

Tabelle 1 gibt eine Übersicht, welche Art von Objekt mit einem Radarsensor detektiert werden kann. Der RCS kann für Standardgeometrien rechnerisch bestimmt werden, muss jedoch für die meisten Objekte empirisch ermittelt werden. Abgesehen von einer kugelförmigen Geometrie, verändert sich der RCS in Abhängigkeit des Aspektwinkels. Eine Übersicht über den RCS von Standardgeometrien und dessen Abhängigkeit vom Aspektwinkel ist in [CPGG05] gegeben.

⁵⁵Engl. Frequency Modulated Continuous Wave (FMCW)

2.6.1 Radargeräte und deren Einteilung

Radargeräte können in Dauerstrich- und Pulsradargeräte eingeteilt werden. Pulsradargeräte senden pulsformige Signale mit einer Pulsbreite τ aus. Dauerstrichradare unterteilen sich in un- und frequenzmodulierte Varianten. Unmodulierte Dauerstrichradargeräte⁵⁶ senden mit konstanter Frequenz und Amplitude und können nur für die Geschwindigkeitsmessung über die Dopplerfrequenz genutzt werden. Frequenzmodulierte Dauerstrichverfahren⁵⁷ ermöglichen eine kontinuierliche Entfernungsmessung durch Rampen-förmige Frequenzverläufe mit einer Bandbreite Δf .

Die Frequenzbereiche, in denen ein Radar senden darf, sind national und international reguliert, um Störungen mit anderen Funkmedien zu vermeiden. Je höher die verwendete Trägerfrequenz, desto höher ist die Funkfelddämpfung und dementsprechend wird die Reichweite limitiert. Bei einer niedrigen Trägerfrequenz ist die Wellenlänge und die entsprechende Antennengröße ein limitierender Faktor für die meisten praktischen Anwendungen.

2.6.2 Entfernungsmessung mit Dauerstrichverfahren

Die Entfernung zu stationären und dynamischen Objekten kann mit einem FMCW-Radar bestimmt werden, dass im Gegensatz zum CW-Radar die Sendefrequenz moduliert, wodurch Laufzeitinformation entstehen. Grundsätzlich ist jede Rampenform möglich. Die einfachste Rampenform, die nur zur reinen Entfernungsmessung von stationären Objekten geeignet ist, ist die steigende oder fallende Sägezahnmodulation [Wei, AS II, S5]. Abbildung 18 stellt die Funktionsweise des reinen FMCW-

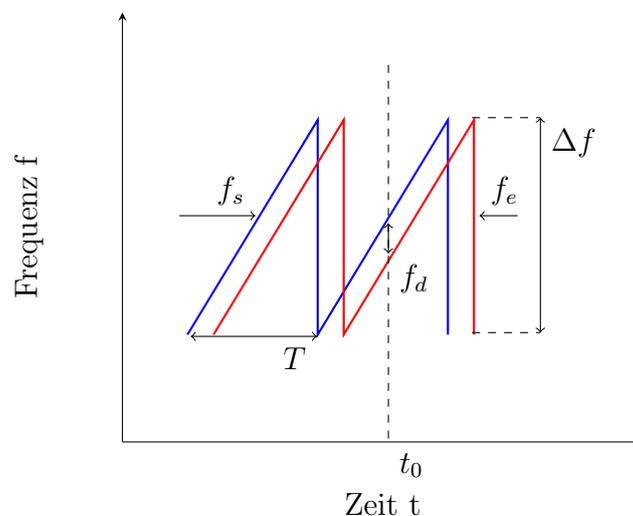


Abbildung 18: Beim einfachsten Fall eines FMCW-Radars zur reinen Entfernungsmessung werden Sägezahnrampen gefahren.

Entfernungsmessprinzip dar. Der blaue Frequenzverlauf stellt den Verlauf der Sendefrequenz f_s und der rote Frequenzverlauf stellt den Verlauf der Empfängerfrequenz f_e dar. Die Sägezahnfunktion ist durch die Periode T und den Frequenzhub Δf definiert. Aus den Frequenzen f_e und f_s kann im Sensor intern mit einem Mischer die Differenzfrequenz f_d zum Zeitpunkt t_0 ermittelt werden, die im linearen Zusammenhang mit dem Abstand des Objektes steht, an denen die Radarwellen reflektieren.

⁵⁶Engl. Continuous Wave (CW)

⁵⁷Engl. Frequency Modulated Continuous Wave (FMCW)

Zur Bestimmung des Abstandes R eines Objektes wird folgende Gleichung verwendet

$$R = \frac{cT f_d}{2\Delta f}. \tag{33}$$

Um Mehrdeutigkeiten zu vermeiden wird die Periodendauer T größer gewählt als die maximale Laufzeit der Radarwelle zwischen Sender und Empfänger. Der minimale messbare Abstand zu einem Objekt ergibt sich für den Fall, wenn gerade noch eine ganze Periode der Differenzfrequenz f_d gemessen werden kann. Für die Periode der Sägezahnfunktion bedeutet dies $T = 1/f_d$. Somit erhält man für die minimal messbare Distanz folgende Entfernung

$$R_{min} = \frac{c}{2\Delta f}. \tag{34}$$

Bei der Sägezahnmodulation kommt es jedoch bei sich bewegenden Objekten aufgrund des Dopplereffektes zu einem Messfehler, da zur Differenzfrequenz f_d noch eine nicht unterscheidbare Dopplerfrequenz f_{Dopp} hinzukommt.

Um den Abstand zu sich bewegenden Objekten zu bestimmen, muss das Signal beispielsweise mit einer Dreiecksfunktion moduliert werden. Mit dieser Modulation ist eine gleichzeitige Geschwindigkeitsbestimmung eines Objektes möglich. Bei dynamischen Objekten kommt zur Verschiebung des Empfängersignals auf der Zeitachse durch die Signallaufzeit noch eine Verschiebung parallel zur Frequenzachse durch den Dopplereffekt hinzu. Um den Einfluss der Signallaufzeit und des Dopplereffektes auf die Differenzfrequenz bestimmen zu können, stehen bei der Dreieckmodulation zwei Differenzfrequenzen, f_{d1} und f_{d2} , zur Verfügung.

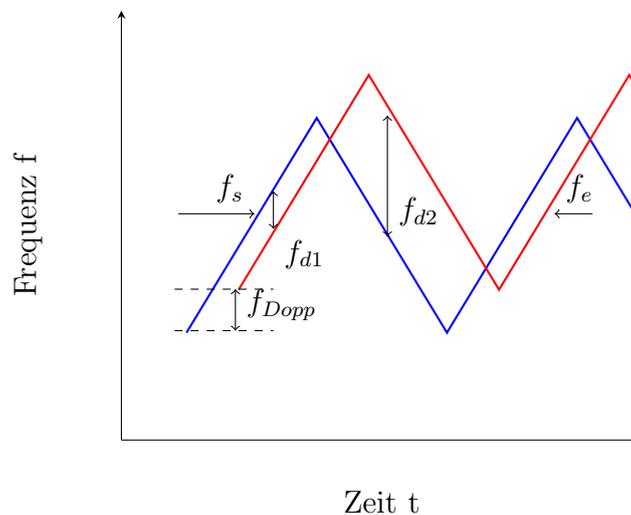


Abbildung 19: Die Dreieckmodulation ermöglicht eine gleichzeitige Bestimmung des Abstandes und der Geschwindigkeit eines dynamischen Objektes.

Somit ergibt sich für f_d in Gleichung 33 folgende Beziehung:

$$f_d = \frac{|f_{d1} + f_{d2}|}{2}. \tag{35}$$

Die Dopplerfrequenz, welche mit der Gleichung 30 zur Geschwindigkeitsbestimmung verwendet werden

kann, ergibt sich folgendermaßen:

$$f_{Dopp} = \frac{|f_{d1} - f_{d2}|}{2}. \quad (36)$$

Generell liefern Radarsensoren nur die Geschwindigkeitskomponente eines Objektes, die senkrecht zum Sensor verläuft. Bewegt sich ein Objekt auf einer Kreisbahn um den Sensor, würde der Radarsensor keine Geschwindigkeit detektieren.

2.6.3 Genauigkeit und Auflösung

Messgeräte werden mit einer Genauigkeit und einer Auflösung bezüglich ihrer Messgrößen beschrieben. Die Genauigkeit mit der eine Messgröße bestimmt werden kann, gibt an, inwiefern das Messergebnis vom wahren physikalischen Wert abweicht. Bei einer angenommenen Normalverteilung ist die Angabe der Genauigkeit ein Maß, wie viel Prozent der Messwerte innerhalb eines Bereiches liegen [B08, S. 28]. Normalerweise wird die Genauigkeit mittels der Standardabweichung beschrieben. Die exakte Definition der Genauigkeit wird jedoch in vielen Datenblättern nicht gegeben.

Die Auflösung ist ein Maß für das Vermögen zwischen zwei Messwerten zu unterscheiden. Somit haben FMCW-Radargeräte mit einer Dreiecksmodulation eine Geschwindigkeits- und Entfernungsmessgenauigkeit und eine Geschwindigkeits- und Entfernungsauflösung.

Die Geschwindigkeits- und Entfernungsmessgenauigkeit eines FMCW-Radars hängen von dem Antennendesign, der verwendeten Elektronik, den Signalverarbeitungsalgorithmen und dem Signal-Rausch Verhältnis ab [Dev, S.68-72] [Cur05, S.172].

Die Geschwindigkeitsauflösung eines Dauerstrichradars hängt von der Wellenlänge und der Auflösung der möglichen Frequenzmessung Δf_{Auf} ab [F06, S. 21]

$$\Delta v = \frac{\lambda}{2} \Delta f_{Auf}. \quad (37)$$

Bei der Diskretisierung der Differenzfrequenz f_d mittels einer FFT wird eine Periode T mit N Abtastwerten mit der Abtastfrequenz f_a diskretisiert. Die Frequenzauflösung ergibt sich aus der Länge der Messzeit T [Mey14, S. 184]

$$\Delta f_{Auf} = \Delta f_{FFT} = \frac{f_a}{N} = \frac{1}{T}. \quad (38)$$

Die Entfernungsauflösung ΔR wird durch die Trennfähigkeit benachbarter Maxima im FFT-Spektrum bestimmt [B08, S. 42]

$$\Delta R = \frac{c}{2\Delta f} \Delta f_{Auf} T = \frac{c}{2\Delta f}. \quad (39)$$

Mit der Definition der Frequenzauflösung in Gleichung 38 ist somit die Entfernungsauflösung nur vom Frequenzhub Δf abhängig, welcher auch als Signalbandbreite B bezeichnet wird und inter- und national beschränkt ist. Durch das Erhöhen der Abtastrate oder der Anzahl der Abtastpunkte kann demzufolge die Entfernungsauflösung nicht verbessert werden. Die Auflösung eines Radars ist somit gesetzlich durch die Bandbreite und nicht physikalisch limitiert.

2.6.4 Detektion

Bevor die Entfernung oder die Geschwindigkeit eines Objektes bestimmt werden kann, muss das Objekt zunächst im Empfangssignal detektiert und von Stör- oder Rauschsignalen unterschieden werden [Det89, S.48]. Das in der Signalaufbereitungselektronik mit Mischern generierte analoge Signal des Radarechos wird zunächst mit einem Analog-Digital-Umsetzer (ADU) in konstanten Zeitabständen (T/N) abgetastet und digitalisiert. Anschließend wird die FFT berechnet, wodurch ein Frequenzspektrum mit der Frequenzauflösung Δf_{Auf} entsteht (siehe Gleichung 38).

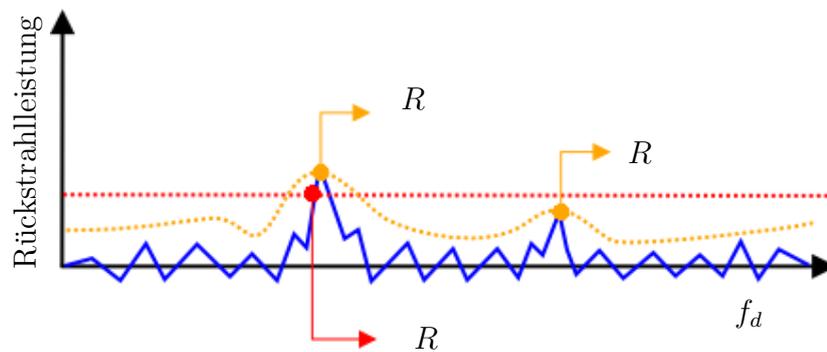


Abbildung 20: Darstellung eines Objektes im FFT-Spektrum nach der Frequenzmischung von Sendesignal und Empfangssignal. Zur Detektion können **Schwellwerte** oder **Hüllkurvenverfahren** angewendet werden.

Die Abbildung 20 stellt das Frequenzspektrum nach der Frequenzmischung und Filterung der Sendesignale und Empfangssignale dar.

2.7 Bildgebende Radarverfahren

Ein gewöhnlicher FMCW-Radarsensor mit einer Sendesignal- und Empfangsantenne ist nur in der Lage Entfernung und Geschwindigkeit, nicht aber den Winkel, zu Objekten zu bestimmen. Radargeräte werden in bildgebend und nicht-bildgebend eingeteilt. Nicht-bildgebende Radarsensoren sind zum Beispiel Doppler-Radargeräte zur Geschwindigkeitsmessung von Fahrzeugen oder Sensoren zur Füllstandsüberwachung in Silos oder Reaktoren. Bildgebende Radargeräte sind zum Beispiel Schiffs- oder Wetterradare. Für die Kartierung und Lokalisierung autonomer Roboter sind bildgebende Radargeräte notwendig. Im folgenden Kapitel werden bildgebende Verfahren vorgestellt.

2.7.1 Strahlformung und -schwenkung

Aufgrund der optischen Eigenschaften elektromagnetischer Wellen kann der Verlauf von Radarstrahlen durch Antennen beeinflusst werden. Indem ein gebündelter Radarstrahl mittels eines Rotationsmechanismus über eine Umgebung bewegt wird, kann ein Abbild erzeugt werden. Die Winkelgenauigkeit und -auflösung werden durch die Genauigkeit und Auflösung der Drehgeber und den Grad der Bündelung bestimmt. Der Grad der Bündelung eines Radarsensors wird in einem Antennendiagramm dargestellt (siehe Abbildung 21a). Die Richtcharakteristik beschreibt Antennencharakteristiken wie den Öffnungswinkel Θ der Hauptkeule, die Nebenkeulendämpfung (ND) und das Vor-Rück-Verhältnis (VRV). Antennencharakteristiken werden in Polarkoordinaten oder kartesisch dargestellt. Die Werte sind nicht mit dem Antennengewinn zu verwechseln sondern beziehen sich auf

den Maximalwert der Hauptkeule, welcher 0 dB entspricht. Der Öffnungswinkel, oder auch die Halbwertsbreite, einer Antenne ist der Winkel bei dem die Leistung um die Hälfte ($10 \cdot \log(0.5) \approx -3$ dB) abfällt. Die ND ist das Verhältnis zwischen dem maximalen Wert der Hauptkeule zu dem maximalen Wert der größten Nebenkeule. Eine kleine ND kann bei einem scannenden Radar zu fehlerhaften Positionsbestimmungen führen, da ein Objekt durch eine Nebenkeule detektiert werden kann, jedoch gemäß des Winkels der Hauptkeule interpretiert wird. Das VRV berechnet sich äquivalent zur ND. Radarbasierte 2D-Scan-Verfahren benötigen Sensoren mit einem möglichst schmalen Öffnungswinkel, einer hohen ND und einem hohen VRV.

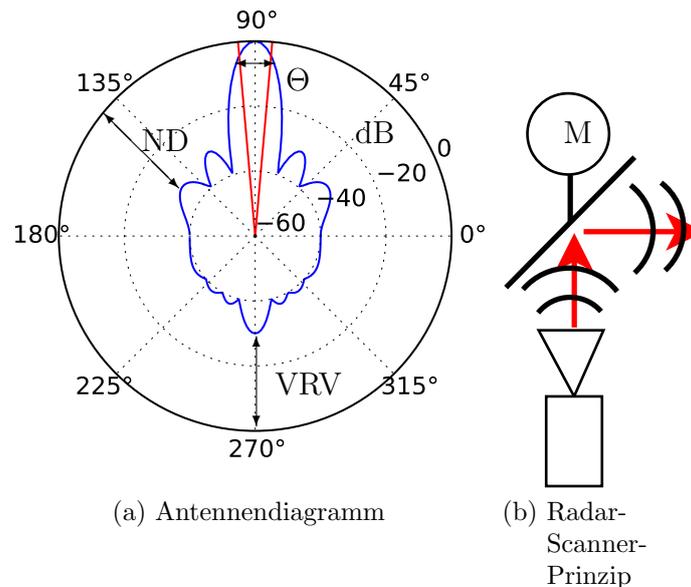


Abbildung 21: Radar-Scanner basieren auf einem mechanischen Rotieren eines fokussierten Radarstrahls.

Zur Formung des Antennendiagramms kommen in der Radartechnik Flächenantennen und Gruppenantennen zum Einsatz. Zu den Flächenantennen (bzw. Aperturstrahlern) gehören Hornstrahler, Spiegel und Linsenantennen [ZV90, S. 415]. Hornstrahler sind offene trichterförmige Hohlleiter und werden oft auf Spiegelantennen gerichtet oder mit einem Linsensystem am offenem Ende versehen, um ihre Richtcharakteristik zu verbessern [ZV90, S. 421]. Der häufigste Vertreter der Spiegelantennen ist der Parabolspiegel in dessen Brennpunkt eine Sende- bzw. Empfangsantenne platziert wird. Marck et al. [MMH13] stellen einen Radar-Scanner für Robotik-Anwendungen vor, bei dem eine Sendantenne auf einen sich rotierenden Parabolspiegel gerichtet ist. Der Antennengewinn kann auch mit Linsenantennen verbessert werden. Da jedoch Glas teuer, schwer und zerbrechlich ist haben sich Mischelektronika aus Schaumstoffen mit Metallkugeln in Gitteranordnung oder parallele Metallplatten etabliert [ZV90, S. 425]. Eine weitere Linsenform sind dielektrische Kugeln, bzw. Luneburg-Linsen, die eine ebene Wellenfront erzeugen können, wenn ein Erreger direkt auf den Kugelrand gelegt wird.

Im Gegensatz zu den gerade genannten Flächenantennen bestehen Gruppenantennen aus einer Anzahl von Einzelantennenelementen, deren Anordnung zu Überlagerungen und Auslöschungen von Wellenfronten führen und dementsprechend ein Antennendiagramm formen. Aufgrund der einfachen Fertigung haben sich Patch-Array-Gruppenantennen etabliert, die aus mehreren rechteckigen Metallflächen bestehen. Wenn einzelne Patch-Elemente separat gespeist werden, kann durch die Phasenver-

schiebung die Richtung der Antenne gesteuert werden. Dies wird auch elektronisches Strahlschwenken genannt.

2D-Radar-Scanner funktionieren nach dem in der Abbildung 21b bereits dargestellten Prinzip und liefern ein Scanbild, welches die FFT Spektren der detektierten Objekte beinhaltet. Abbildung 22 zeigt Scanbilder zweier Radar-Scanner, in denen zu erkennen ist, dass Objekte aufgrund des größeren Öffnungswinkels Θ sichelförmig verwischt werden.

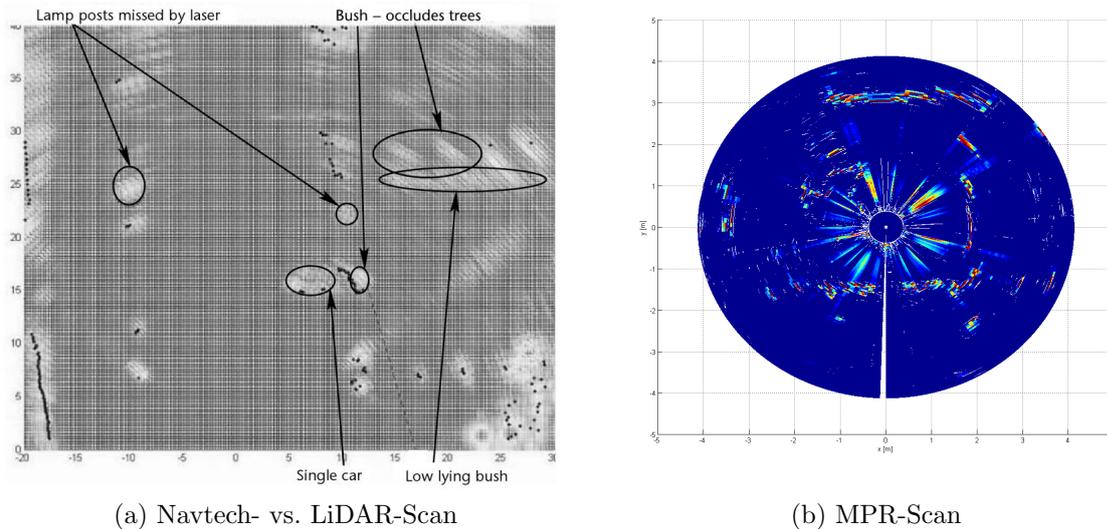


Abbildung 22: In 22a wird ein Scanbild eines Navtech MMW Radar-Scanners gezeigt. Die grauen Werte entsprechen Radar- und die schwarzen Punkte LiDAR-Messwerten. Weiterhin sind Objekte eingekreist, die vom Radar aber nicht vom LiDAR detektiert werden. Quelle: [AMJ12, S. 16]. Abbildung 22b zeigt einen Scan mit den einzelnen Fourier-Spektren des MPR-Scanners. Starke Reflektoren werden rot dargestellt.

Für jede einzelne Radarmessung⁵⁸ werden die Objekte aus dem Fourier-Spektrum extrahiert, wodurch ein klassischer Scan S_{Radar} entsteht, der aus einem Array mit Distanzwerten R besteht:

$$S_{\text{Radar}} = (R_0, R_1, R_i, \dots, R_{(n-1)}). \quad (40)$$

Aus dem Fourier-Spektren kann für die Detektionen gleichzeitig die Rückstahlleistungen der einzelnen Messungen entnommen werden:

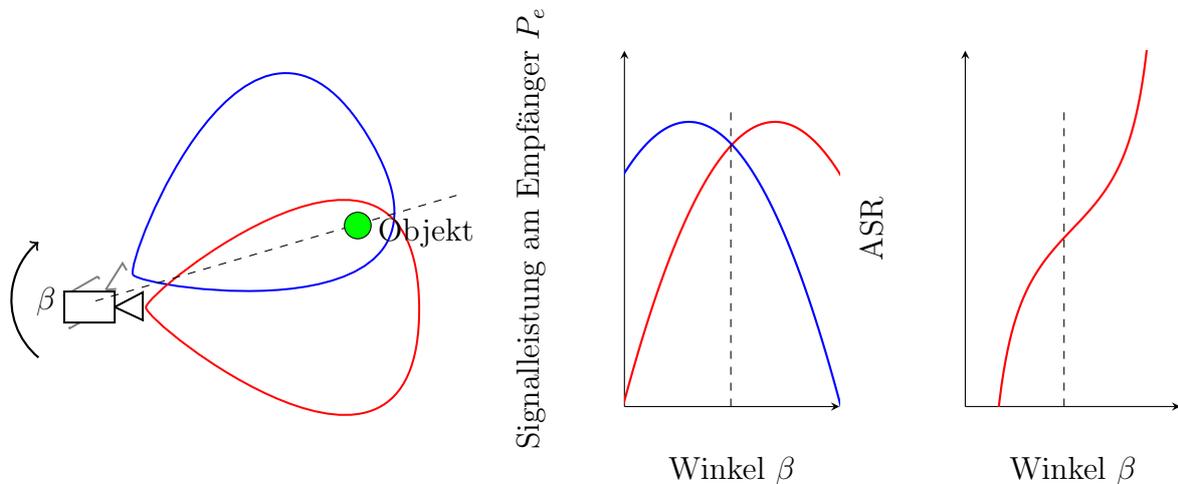
$$P_{\text{Radar}} = (P_{e,0}, P_{e,1}, P_{e,i}, \dots, P_{e,n-1}). \quad (41)$$

Ein Radar-Scan S_{Radar} beinhaltet im Vergleich zu einem LiDAR-Scan mehr Messfehler. Die Fehler treten aufgrund von Fehldetektionen, Reflexionen und anderen optischen Effekten auf.

⁵⁸Der MPR führt 200 einzelne Messungen pro 360°-Scan durch.

2.7.2 ASR - Betrachtung der Leistung an der Empfängerantenne

Aufgrund der Antennencharakteristik ist die empfangene Leistung abhängig vom Winkel zwischen Antenne und Objekt. In den meisten Fällen ist die Leistung maximal, wenn das Objekt sich senkrecht zur Antenne befindet. Befinden sich zwei Sensoren an der gleichen Position, aber zeigen in unterschiedliche Richtungen, so kann beim Vergleich der Rückstrahlleistungen der einzelnen Sensoren auf die Position des Objektes geschlossen werden. Mit dem Verfahren kann somit auch bei einem großen Öffnungswinkel Θ ein Winkel des Objektes ermittelt werden. Die Eigenschaften eines Scanners, der nach dem ASR⁵⁹-Verfahren funktioniert, ist in der Abbildung 23 dargestellt. Mit Hilfe des Amplitudenverhältnisses kann der Winkel β des Objektes berechnet werden. Für die Winkelbestimmung ist jedoch eine Referenzkurve notwendig, die empirisch ermittelt werden muss.



(a) Aufbau eines ASR Scanners mit zwei Sensoren, deren Antennendiagramme rot und blau dargestellt sind. (b) Verlauf der Empfängerleistung und des ASR bei einem Scan vor einem Objekt.

Abbildung 23: Wenn sich ein ASR-Scanner (23a) vor einem Obejekt um den Winkel β dreht, dann verlaufen die Empfängerleistungen entsprechend des Versatzes der Sensoren (23b).

$$ASR = \frac{\Delta}{\Sigma} = \frac{P_{e1} - P_{e2}}{P_{e1} + P_{e2}} \tag{42}$$

Das beschriebene Verfahren wird in Bezug zu Puls-Doppler-Radaren als Mono-Puls-Verfahren bezeichnet, wobei der ASR sich aus Differenzkanal Δ durch Summenkanal Σ ergibt. Im zweidimensionalen Fall (horizontale Ebene) genügen zwei Antennen für den Azimut-Differenzkanal (Δ_{Az}). Um zusätzlich eine Höheninformation zu erhalten, ist eine weitere Antenne für den Elevations-Differenzkanal (Δ_{El}) notwendig.

⁵⁹Engl. Amplitude Sensing Ratio (ASR)

2.7.3 Lateration

Im Gegensatz zur Triangulation, wo aus drei Winkelinformationen auf die Position eines Objektes geschlossen wird, bezieht sich der Terminus Trilateration auf die Messung von drei Entfernungen. Drei Entfernungsmessungen sind mindestens notwendig um die Position eines Objektes im zweidimensionalen Raum eindeutig zu bestimmen. Dementsprechend sind mindestens vier Sensoren für eine Positionsbestimmung im dreidimensionalen Raum notwendig. Mit zwei Sensoren können theoretisch zwei mögliche Objektpositionen im zweidimensionalen Raum bestimmt werden, jedoch entfällt eine der beiden Lösungen in den meisten Fällen aufgrund der Richtcharakteristik des Antennendiagramms des Radarsensors.

Allgemein unterteilt man Radarnetzwerke in mono- und bistatisch (Abbildung 24). Bei monostatischen Radarnetzwerken befinden sich Sende- und Empfängerantenne am selben Ort bzw. der Sensor nutzt die selbe Antenne um Signale zu senden und zu empfangen. Bei bistatischen Radaranlagen befinden sich Sende- und Empfängerantenne an unterschiedlichen Orten [Cur05, S. 19]. Der Laterations-Scanner, der in dieser Arbeit vorgestellt wird, basiert auf einem monostatischen Radarnetzwerk.

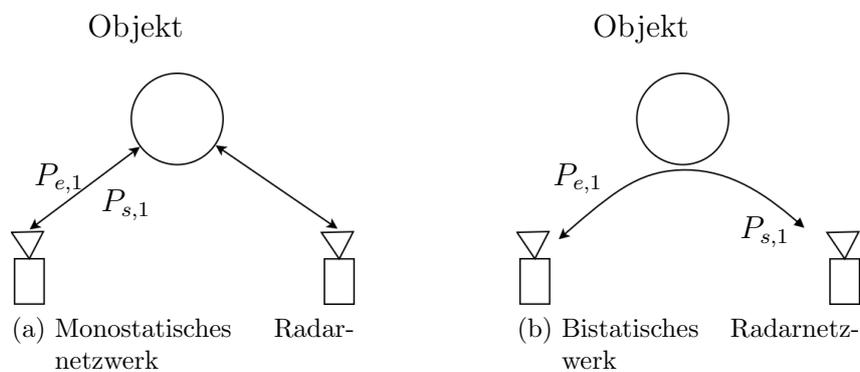


Abbildung 24: Monno- und bistatisches Radarnetzwerk

Wijk und Christensen [WC00] nutzen den Laterationsansatz zur Umgebungsmodellierung in der mobilen Robotik, indem sie mit einer mobilen Plattform und Ultraschallsensoren während der Fahrt von verschiedenen Positionen Distanzmessungen durchführen und somit den Ort von Tisch-, Stuhlbeinen und anderen Gegenständen bestimmen.

2.7.4 SEABED und SAR

Eine große Apertur (Öffnungsweite) eines Radarnetzwerkes kann auch mit nur einem Sensor realisiert werden. Anstelle der Nutzung von mehreren Sensoren reicht es aus, wenn ein Sensor zu unterschiedlichen Zeitpunkten an bekannten Positionen einer Trajektorie platziert wird. Wenn ein Radarsensor auf einer geraden Linie verfahren wird, kommt es zu einer hyperbolischen Verzerrung im Messwertraum (d-Space) aufgrund der unterschiedlichen Distanzmessungen (siehe Abbildung 25).

Es existiert eine Vielzahl von bildgebenden SAR-Algorithmen⁶⁰, welche teilweise sehr rechenaufwändig sind. Sakamoto und Sato stellten im Jahr 2004 einen Algorithmus vor, der es ermöglicht Oberflächenformen von konvexen und konkaven Objekten zu rekonstruieren. Der SEABED⁶¹-Algorithmus berechnet zu einem Punkt im Messraum (d-Space) einen zugehörigen Punkt im realen Raum und ist die mathematische Lösung des inversen Reflexions Problems. Die Herleitung der IBST⁶² kann in [SS04] eingesehen werden.

Die IBST ermöglicht es, Messpunkte aus dem Messwertraum direkt in den realen Raum zu transformieren.

$$\begin{aligned} x &= X - \alpha Y \frac{dY}{dX} \\ y &= Y \sqrt{1 - \alpha \left(\frac{dY}{dX} \right)^2}. \end{aligned} \quad (43)$$

Der differenzielle Term der Gleichung 43 verursacht eine starke Anfälligkeit gegenüber Messrauschen. Sakamoto erweiterte die Gleichung mit dem Parameter α , um sie robuster gegenüber veräuschten Messwerten zu machen [Sak07]. Mit dem Parameter α können die Messwerte aus dem d-Space auf einen Zustand zwischen d-Space und r-Space transformiert werden. Die Anfälligkeit gegenüber Messrauschen erfordert eine Glättung und Rauschreduzierung der Messwerte. Die einfachste Form der Glättung ist die Faltung des Messsignals mit einem Filterkern, welcher als linearer Filter bezeichnet wird. Ein weiteres Verfahren zur Bildrekonstruktion ist die Kirchhoff-Migration, das dem Grundprinzip des Occupancy-Grid-Mapping-Verfahrens ähnelt. Den Einsatz von SEABED und Kirchhoff-Migration wurde von Sakamoto et al. [SWS⁺13] auch auf einem mobilen Roboter getestet. Jedoch eignet sich das Verfahren nur für ein reines Mapping und beinhaltet keine Lagekorrektur. Weiterhin wurde der Roboter während des Experiments sehr langsam verfahren, um möglichst wenig Messrauschen zu erhalten.

⁶⁰Engl. Synthetic Aperture Radar (SAR)

⁶¹Engl. Shape Estimation Algorithm based on BST and Extraction of Directly scattered waves (SEABED)

⁶²Engl. Inverse Boundary Scattering Transform (IBST)

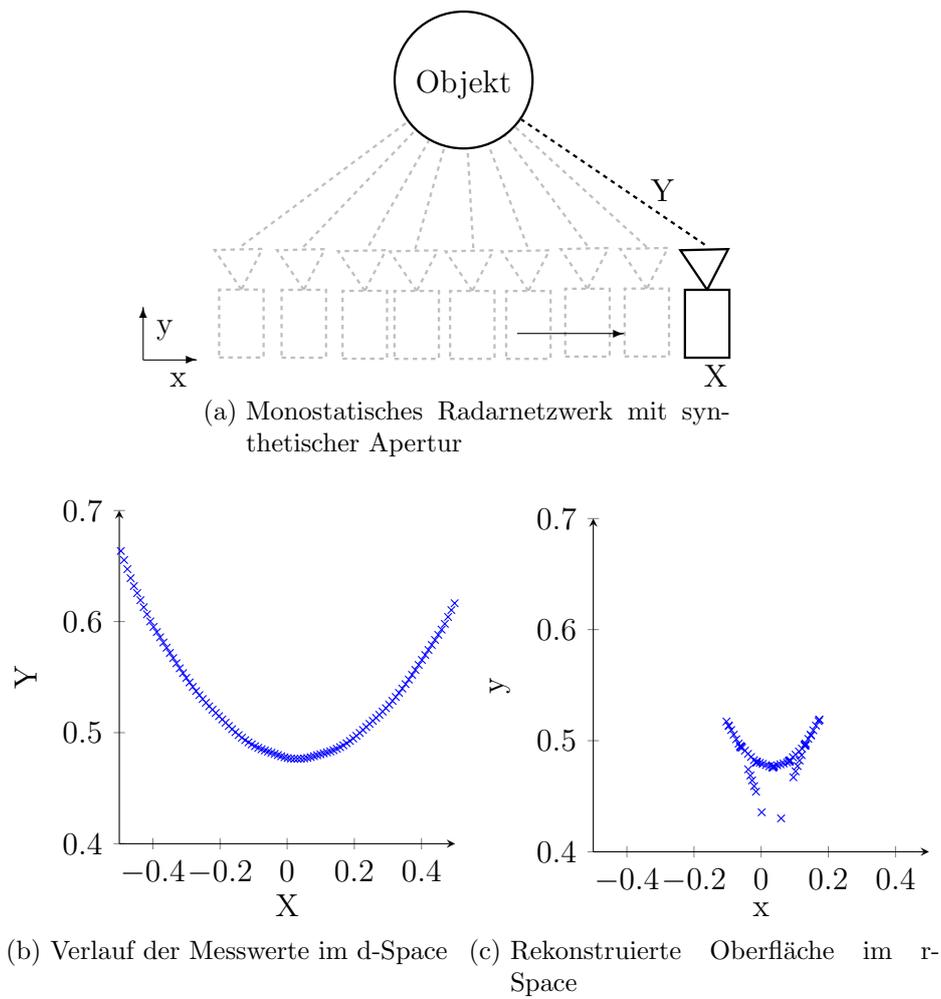


Abbildung 25: Sakamoto et al. beschreiben den realen Raum als r-Space und den Messwertraum als d-Space. Die Distanzmessungen werden zu den Reflexionszentren angenommen, die sich auf Objektoberflächen befinden, die senkrecht zum Sensor stehen.

3 Vorbetrachtung: Neue Messprinzipien zur Umgebungsmodellierung mit Radar

Um die wissenschaftliche Fragestellung nach Verfahren zur Umgebungsmodellierung mit Hilfe von mobilen Robotern, die zusätzlich mit Radarsensoren ausgestattet sind, zu beantworten, wird im folgenden Kapitel ein neues Messprinzip im Rahmen einer Vorbetrachtung vorgestellt.

Dieses Kapitel stellt ein Scan-Verfahren vor, das auf einem sich rotierenden monostatischen Radarnetzwerk basiert und in dieser Arbeit als Laterations-Scanner bezeichnet wird. Im Gegensatz zu den in Kapitel 2.2.3 vorgestellten Scan-Verfahren, basiert dieses Verfahren nicht auf einer optischen Fokussierung der Hauptkeule des Radars⁶³. Die einfachste Variante eines 2D-Laterations-Scanners ist in der Abbildung 26 schematisch dargestellt und besteht aus zwei Radarsensoren, die sich im Winkel β um einen Drehpunkt bewegen.

In den folgenden Unterkapiteln wird das Funktionsprinzip des Scanners (Kapitel 3.1), die Verknüpfung zur Umgebungsmodellierung mit Rasterkarten (Kapitel 3.2) und Landmarkenkarten (Kapitel 3.3) beschrieben.

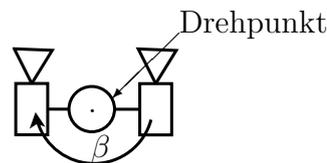


Abbildung 26: Skizze der einfachsten Variante eines 2D-Laterations-Scanners.

3.1 Funktionsweise des Laterations-Scanners

Kommerzielle Radarsensoren, die in der Automobilindustrie, der chemischen Industrie oder der Verkehrsüberwachung zum Einsatz kommen, sind integrierte Sensoren und stellen Objektlisten (OL) über eine Schnittstelle in einer bestimmten Messrate zur Verfügung. In der Objektliste (OL) können Abstands- Geschwindigkeits- und Leistungswerte vorhanden sein. Einige Sensoren liefern auch eine Winkelinformation. Die maximale Anzahl an Objekten und somit die Länge der OL l_{OL} ist, durch Distanzauflösung ΔR und maximale Messreichweite R_{max} des Sensors definiert

$$l_{OL} = \lfloor \frac{R_{max}}{\Delta R} \rfloor. \quad (44)$$

Ein einzelner Radarsensor mit der Eigenschaft nur Entfernungen zu messen, ermöglicht die Schlussfolgerung, dass sich ein detektiertes Objekt im zweidimensionalen Fall auf einem Kreis, bzw. im dreidimensionalen Fall auf einer Kugeloberfläche um den Sensor befindet. Da die meisten Radarannten keine isotropen Kugelstrahler sind, sondern eine Richtung gemäß ihres Antennendiagramms haben, kann der Bereich hinter der Antenne ausgeschlossen werden. Mit zusätzlichen Radarsensoren kann somit über die Schnittpunkte der Kreise oder Kugeloberflächen die Position eines Objektes bestimmt werden. Geometrisch bedingt können auf diese Weise jedoch Mehrdeutigkeiten entstehen (siehe Abbildung 27).

⁶³Handelstübliche Radarsensoren besitzen aufgrund ihrer Einsatzgebiete häufig einen großen Öffnungswinkel

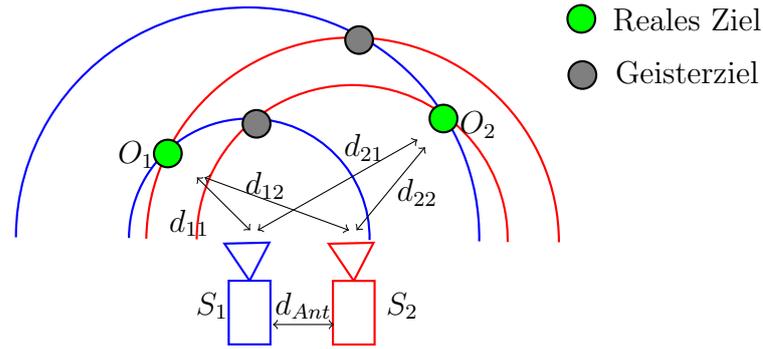


Abbildung 27: Bestimmung von Objektpositionen O_i . Sogenannte Geisterziele spiegeln Mehrdeutigkeiten wieder.

In einer zweidimensionalen Ebene ergeben sich für n Objekte O_i ($i=1..n$) und m Sensoren S_j ($j=1..m$), $k = m \cdot n$ Kreisgleichungen. Die euklidischen Distanzen zwischen den Sensorpositionen $S_j(x_{S_j}, y_{S_j})$ und den Objektposition $O_i(x_{O_i}, y_{O_i})$ werden durch Gleichung 45 beschrieben. Der Abstand d_{ij} entspricht der Entfernung zwischen Objekt O_i und Sensor S_j

$$\begin{aligned}
 (x_{S_1} - x_{O_i})^2 + (y_{S_1} - y_{O_i})^2 &= d_{i1}^2 \\
 (x_{S_j} - x_{O_i})^2 + (y_{S_j} - y_{O_i})^2 &= d_{ij}^2 \\
 &\vdots \\
 (x_{S_m} - x_{O_i})^2 + (y_{S_m} - y_{O_i})^2 &= d_{im}^2.
 \end{aligned}
 \tag{45}$$

Wenn sich mehrere Objekte vor dem Laterationsnetzwerk befinden, müssen die Gleichungen gruppiert werden, sodass für jedes Objekt mit den Objektpositionen x_{O_i} und y_{O_i} ein Gleichungssystem besteht. Werden die Abstandswerte falsch assoziiert, wird ein Scheinziel, bzw. Geisterziel berechnet. Die Voraussetzung, dass ein Geisterziel entstehen kann ist, dass der Antennenabstand d_{Ant} mindestens zweimal so groß ist wie die Entfernungsaufösung der Sensoren [RDA⁺09]

$$d_{Ant} > 2\Delta R.
 \tag{46}$$

Mit diesem Kriterium kann abgeschätzt werden, welche Datenassoziiierungsstrategie angewendet werden muss. Die reale Entfernungsaufösung der meisten Radarsensoren ist zwei bis dreimal die theoretische Auflösung (siehe Gleichung 39, Seite 33). Wenn der Antennenabstand kleiner als die doppelte Entfernungsaufösung ist, ist die Datenzuordnung aufzulösen, indem nur Abstandswerte zu einem Objekt zugeordnet werden, die eine relative Differenz kleiner als d_{Ant} haben.

Falls der Antennenabstand größer als die Auflösung ist, können Geisterziele entstehen, welche zu einer nicht eindeutigen Lösung führen. In einem monostatischen Radarnetzwerk werden zur Auflösung eines Geisterziels im zweidimensionalen Fall mindestens drei Sensoren benötigt. Im dreidimensionalen Fall werden dementsprechend vier Sensoren benötigt. Zur Lösung des Problems wird der Messraum vor den Sensoren in eine endliche Anzahl von möglichen Messpunkten diskretisiert. Danach wird für jeden diskretisierten Messpunkt ein Fehler E berechnet, der sich aus der Summe der minimalen Differenzen zwischen dem Distanzwert d_{ij} eines Sensors S_j und dem Abstand des diskretisierten Punktes $d(x, y)$ ergibt. Wird dies für jeden möglichen Punkt berechnet, werden für die Punkte, die

dem wahren Objekten am nächsten liegen, die kleinsten Fehlerwerte berechnet. Dieses Verfahren wurde als Bottom-up-Verfahren von Fölster [FR05] vorgestellt (Gleichung 47).

$$E(x, y) = \sum_{j=1}^m \left[\min_{d_{ij} \in OL_i} (d_{ij} - d(x, y)) \right]^2. \quad (47)$$

Wenn alle Abstandswerte der Sensoren korrekt zugeordnet sind, dann kann für jedes Objekt ein Gleichungssystem mit maximal m Gleichungen aufgestellt werden. Die allgemeine Matrix-Vektorprodukt-Schreibweise ergibt sich nach der Subtraktion der letzten Gleichung m von allen Gleichungen $j = 1 \dots m-1$ [Sch13, S. 8] (siehe Gleichung 45)

$$\begin{pmatrix} 2 \cdot (x_{S1} - x_{Sm}) & 2 \cdot (y_{S1} - y_{Sm}) \\ 2 \cdot (x_{S1} - x_{Sm}) & 2 \cdot (y_{S1} - y_{Sm}) \\ \vdots & \vdots \\ 2 \cdot (x_{Sm-1} - x_{Sm}) & 2 \cdot (y_{Sm-1} - y_{Sm}) \end{pmatrix} \cdot \begin{pmatrix} x_{O_i} \\ y_{O_i} \end{pmatrix} = \begin{pmatrix} x_{S1}^2 - x_{Sm}^2 + y_{S1}^2 - y_{Sm}^2 - d_1^2 - d_m^2 \\ x_{S2}^2 - x_{Sm}^2 + y_{S2}^2 - y_{Sm}^2 - d_2^2 - d_m^2 \\ \vdots \\ x_{Sm-1}^2 - x_{Sm}^2 + y_{Sm-1}^2 - y_{Sm}^2 - d_{m-1}^2 - d_m^2 \end{pmatrix}$$

$$A \cdot \vec{o}_i = \vec{d}. \quad (48)$$

Wenn die Anzahl der Sensoren mindestens um zwei ($m+2$) höher ist als die Dimension des Messraums entsteht ein überbestimmtes Gleichungssystem. Demzufolge lässt sich das Gleichungssystem 48 nicht mehr mit der inversen Matrix A^{-1} nach \vec{o} umstellen⁶⁴. Aufgrund von Messfehlern der einzelnen Sensoren wird dieses überbestimmte Gleichungssystem keine eindeutige Lösung haben (inkonsistent). Dementsprechend gibt es keine eindeutigen Schnittpunkte der Kreisbögen. Im zweidimensionalen Fall spannen die Schnittpunkte, die zu einem Objekt gehören eine Fläche auf. Diese macht sogleich eine Aussage über den Messfehler der Messung. Typischerweise werden überbestimmte lineare Gleichungssysteme mit Hilfe der Pseudoinversen Matrix A^+ als Minimierung des quadratischen Fehlers gebildet [Sch13, S. 8] [Fö6, S. 39]

$$A^+ = (A^T A)^{-1} A^T. \quad (49)$$

Mit Hilfe der Pseudoinversen 49 lässt sich eine Pseudolösung \vec{o}^* berechnen. Voraussetzung für das Verfahren ist, dass sich die Sensoren nicht in der selben Ebene befinden und die Einträge in der Matrix A linear unabhängig sind.

Ein Scan-Punkt P wird mit der aktuellen Ausrichtung des Scanners β berechnet

$$P_i = o_i \cdot \begin{pmatrix} \cos(\beta) \\ -\sin(\beta) \end{pmatrix}. \quad (50)$$

3.1.1 Fehlerbetrachtung des Laterations-Scanners

Die Verwendung von redundanten Radarsensoren hat den Vorteil, dass die Genauigkeit der Positionsbestimmung verbessert werden kann, wenn der Fehler der Distanzmessungen normalverteilt ist. Jeder Sensor hat eine Genauigkeit bezüglich der Entfernungsmessung, die mit der Standardabweichung σ_R behaftet ist. Das rechte Diagramm der Abbildung 28 zeigt eine Messreihe mit dem 24-GHz-iSYS4004-

⁶⁴Da die Systemmatrix nicht mehr quadratisch ist

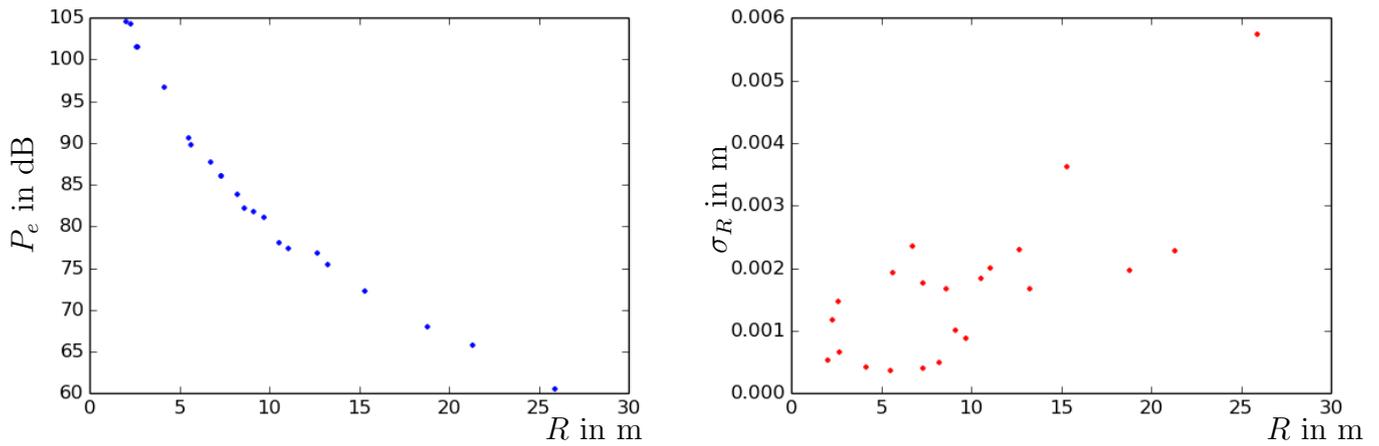


Abbildung 28: Die Diagramme zeigen den Verlauf der Rückstrahlleistung und der Standardabweichung der Distanzmessung in Abhängigkeit des Objektabstandes

FMCW-Radarsensor der Firma InnoSent. Die Standardabweichung σ_R der Entfernungsmessung des Sensors nimmt mit steigender Objektdistanz zu.

Abbildung 29 verdeutlicht den rautenförmigen Unsicherheitsbereich einer Messung mit zwei Radarsensoren. Wenn sich das Verhältnis zwischen Entfernung des Objektes und Abstand der Sensoren

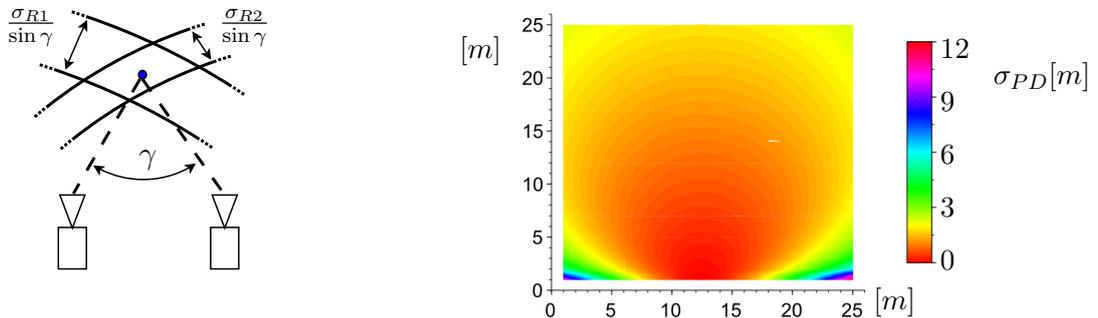


Abbildung 29: Die linke Skizze zeigt, dass die Standardabweichungen der Entfernungsmessfehler eine Fläche ergeben, die den Unsicherheitsbereich σ_{PD} entspricht. Das rechte Diagramm zeigt den Verlauf von σ_{PD} für ein Beispiel mit zwei Sensoren an den Positionen $S1(12.3,0)$, $S2(12.7,0)$, und einer konstanten Standardabweichung von $\sigma_R = 3cm$. Die Genauigkeit der Positionsbestimmung per Laterations-Scanners wird mit steigender Distanz schlechter. Weiterhin ist die Genauigkeit zu senkrecht zu den Sensoren stehenden Objekten höher.

vergrößert, wird der Winkel γ kleiner. Je kleiner der Winkel γ wird, desto breiter wird die rautenförmige Fläche des Unsicherheitsbereiches (σ_{PD}). Die Verteilung des Unsicherheitsbereiches in Abhängigkeit der Objektposition im rechten Diagramm ist in der Abbildung 29 dargestellt. An den Rändern ist die Unsicherheit besonders hoch (siehe Gleichung 51)

$$\sigma_{PD} \approx \frac{\sigma_{Rmax}}{\sin \gamma}. \tag{51}$$

Über einen Laterations-Scanner kann demzufolge keine genaue Aussage über die Winkelgenauigkeit

und Winkelauflösung gemacht werden, da sie von den Abständen und geometrischen Eigenschaften (RCS) der Objekte abhängen.

Die Positionsbestimmung mittels Lateration setzt voraus, dass alle Sensoren des Radarnetzwerkes die Entfernung zum gleichen Punkt messen. Diese Annahme kann getroffen werden, wenn die Dimension des zu erfassenden Objektes kleiner ist als die Entfernungsauflösungszelle des Radars [Jen, S. 26] oder das Objekt eine bestimmte geometrische Form besitzt. Diese Fälle werden als Punktziele bezeichnet. Je kleiner das Punktziel ist, desto genauer wird die Messung mittels Lateration. Wenn kein exaktes Punktziel vorliegt, messen die Sensoren eines Radarnetzwerkes Entfernungen zu unterschiedlichen Reflexionszentren, wodurch eine fehlerhafte Positionsbestimmung per Lateration erfolgt. Die Verschiebung beruht darauf, dass die Sensoren sich an unterschiedlichen Positionen befinden und somit andere Wellenfronten detektieren. Jordan [Liu10, S. 80] stellt fest, dass das Reflexionszentrum bei einer Messung zu einem Auto in Abhängigkeit der Position des Sensors wandert. Die gleichen Effekte treffen für die meisten Objekte zu. Da sich bei einem rotierendem Laterationsnetzwerk die Sensoren auf einer Kreisbahn bewegen, kann es zum Wandern der Reflexionszentren kommen, wodurch die Sensoren selbst nicht die Entfernung zu dem exakt gleichen Punkt messen.

Für den Fall eines einfachen Laterations-Scanners mit zwei Sensoren und mittiger Rotationsachse verlaufen die Abstandswerte für ein Punktziel gemäß der Gleichung 52, wobei X_1 und X_2 normalverteilte Zufallsvariablen sind. Der Abstand zwischen dem Punktziel und der Rotationsachse des Scanners ist d_0

$$\begin{aligned}
 d_{1B} &= \sqrt{\left(d_0 - \frac{d_{Ant}}{2} \sin \beta\right)^2 + \left(\frac{d_{Ant}}{2} \cos \beta\right)^2} + X_1 \\
 d_{2B} &= \sqrt{\left(d_0 + \frac{d_{Ant}}{2} \sin \beta\right)^2 + \left(\frac{d_{Ant}}{2} \cos \beta\right)^2} + X_2.
 \end{aligned}
 \tag{52}$$

Abbildung 30 zeigt einen Vergleich zwischen dem theoretischen Verhalten eines Punktziels mit einem Experiment.

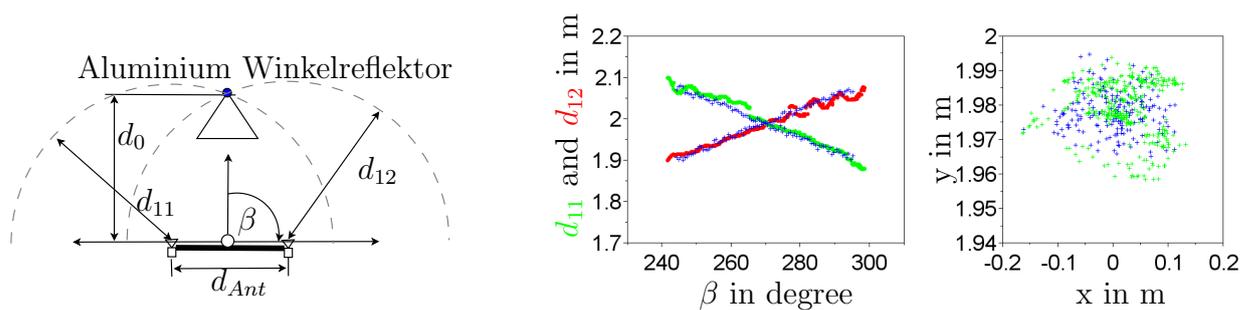


Abbildung 30: Die Abbildungen zeigen ein Experiment, bei dem ein statisch aufgestellter Laterations-Scanner ca. zwei Meter vor einem Winkelreflektor platziert wurde. Ein Winkelreflektor stellt ein Punktziel dar. Die linke Abbildung stellt den Aufbau des Experiments dar. Das Diagramm in der Mitte zeigt den Verlauf der Distanzwerte der Sensoren (rot und grün) und stellt den theoretischen Verlauf gemäß der Gleichung 52 (blau) dar. Das rechte Diagramm zeigt die ermittelten (grün) und theoretischen (blau) Positionsrechnungen des Scan-Ausschnitts.

In Abbildung 31 ist dargestellt, wie sich der Laterations-Scanner bei Objekten verhält, die keine Punktziele darstellen.

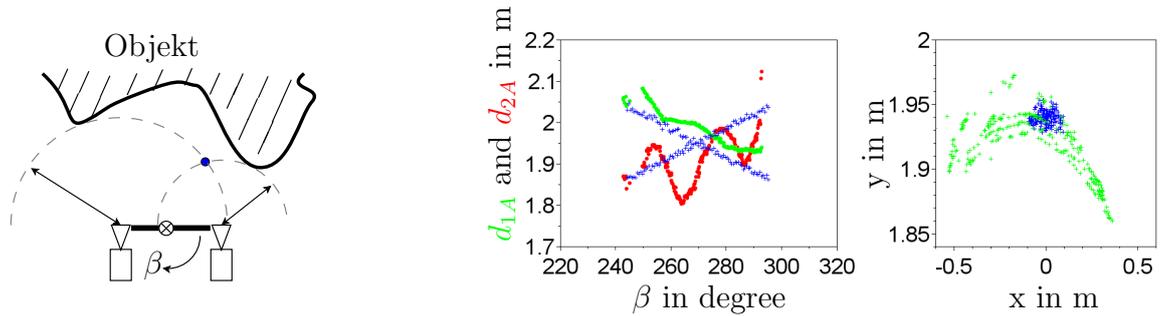


Abbildung 31: Die Abbildungen Stellen ein Experiment dar, bei dem ein statisch platzierter Laterations-Scanner vor einem Objekt (kein Punktziel) Messwerte aufnimmt. In der Abbildung in der Mitte sind die Wanderungen der Reflexionszentren sichtbar. Im Gegensatz zu einem Punktziel, verteilen sich die berechneten Objektpositionen auf einen großen Bereich von ca. 1m, was im rechten Diagramm sichtbar ist.

3.2 Erstellen von Rasterkarten mit einem Laterations-Scan-Verfahren

Die metrische Kartierung einer Umgebung mit verrauschten Sensordaten kann mit dem Occupancy-Grid-Mapping-Verfahren erfolgen. Dafür müssen jedoch bekannte Sensorpositionen angenommen werden. Das Verfahren lässt sich auf das Laterations-Scan-Verfahren übertragen. Beim Occupancy-Grid-Mapping wird die Umgebung eines Roboters in eine Rasterkarte M mit einer endlichen Anzahl von Zellen m_i zerlegt, welche bei Hindernissen belegt oder bei passierbaren Regionen unbelegt sind. Zellen, die unbekannte Regionen repräsentieren, beinhalten weiterhin die Inertialwerte der Rasterkarte. Das Eintragen eines detektierten Objektes in eine Rasterkarte ist in der Abbildung 32 dargestellt.

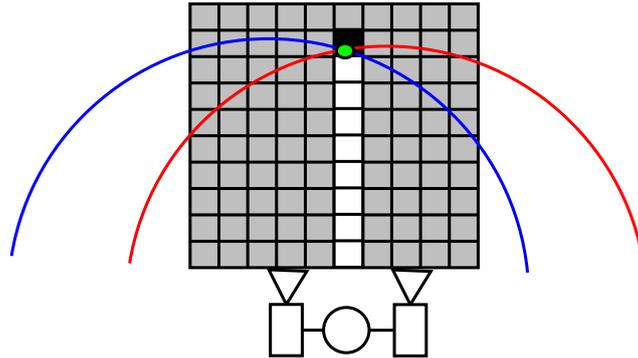


Abbildung 32: Bei der Maximum-Likelihood-Map entsprechen weiße Zellen $p(m_i) = 0$ einem befahrbaren Bereich, schwarze Zellen $p(m_i) = 1$ stellen ein Objekt dar und grauen Zellen $p(m_i) = 0.5$ beziehen sich auf Regionen über die keine Aussage getroffen werden kann.

Unter der Annahme, dass diese Zellen unabhängig voneinander sind, kann die Wahrscheinlichkeit einer Karte in die Produkte der Wahrscheinlichkeiten der einzelnen Zellen zerlegt werden

$$p(M) = \prod_i p(m_i). \quad (53)$$

Die Zellen, die vor dem Hindernis liegen, werden als passierbar angenommen und ihre Werte verkleinert. Die Wahrscheinlichkeiten in den Zellen werden mit der log-odd Form berechnet. Die Rasterkarte wird typischerweise mit der Wahrscheinlichkeit $p(m_i) = 0.5$ für jede Zelle initialisiert. Das Log odds Verhältnis wird für die Inertialwahrscheinlichkeit l_0 folgendermaßen definiert

$$l_0 = \log \frac{p(m_i)}{1 - p(m_i)} = 0. \quad (54)$$

Das log odds Verhältnis des inversen Sensormodells wird äquivalent mit den Wahrscheinlichkeiten $p(m_i|z_t, x_t)$ berechnet, die bei einem detektierten Objekt typischerweise größer als 0.5 bzw. bei dem freien Bereich vor dem Objekt kleiner als 0.5 sind. Iterativ kann somit für jede Messung die Rasterkarte aktualisiert werden

$$l_{t,i} = \log \frac{p(m_i|z_t, x_t)}{1 - p(m_i|z_t, x_t)} + l_{t-1,i} - l_0 \quad (55)$$

und

$$p(m_i|z_{1:t}, x_{1:t}) = 1 - \frac{1}{1 + \exp^{l_{t,i}}}. \quad (56)$$

Das log-odds-Verhältnis hält Werte für die Wahrscheinlichkeiten gemäß der Definition zwischen 0 und 1. Die sogenannte Maximum-Likelihood-Map entspricht der auf- bzw. abgerundeten Occupancy-Grid-Map und enthält die Zellwerte 0, 0.5 und 1.

Bei der Verwendung des Occupancy-Grid-Mapping-Verfahrens mit Radarsensoren ist zu beachten, dass mit einer Messung mehrere Objekte detektiert werden können. Mit dem klassischen inversen Sensormodell kommt es zu dem Effekt, dass weiter entfernte Objekte die Objekte, die näher am Sensor liegen, wieder auslöschen. Um dies zu verhindern, sollte nur das nächstliegende Objekt zur Erstellung einer Rasterkarte verwendet werden. Die genannten Rasterkarten sind am Beispiel eines Scans mit dem Laterations-Scanner in der Abbildung 33 dargestellt.

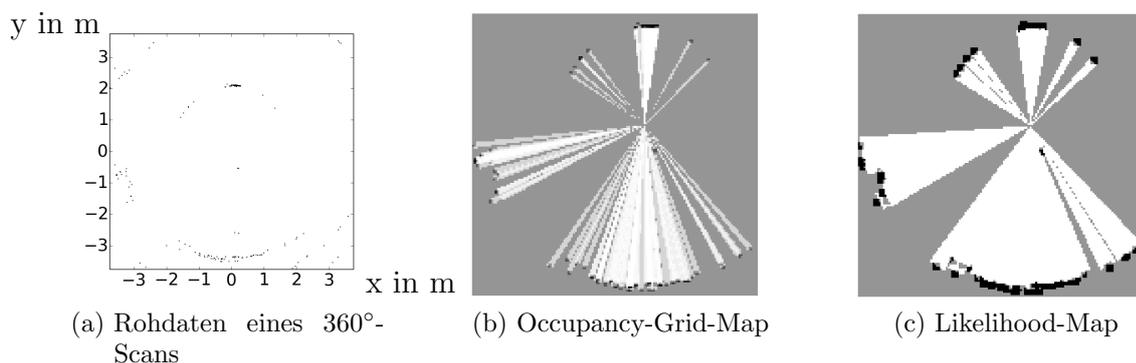


Abbildung 33: Die Abbildungen zeigen die Rasterkartierung mit dem Laterations-Scanner. Abbildung 33a zeigt Rohdaten eines 360°-Scan in einem Büro. Abbildung 33b zeigt eine Occupancy-Grid-Map, wobei der Öffnungswinkel des inversen Sensormodells 1° beträgt. Abbildung 33c zeigt eine Likelihood-Map. Der Öffnungswinkel des inversen Sensormodells beträgt in diesem Fall 3°.

3.3 Erstellen von globalen Landmarkenarten mit einem Laterations-Scan-Verfahren

Das gerade vorgestellte Occupancy-Grid-Mapping-Verfahren eignet sich zwar zur Erstellung von metrischen Karten, jedoch ist eine gleichzeitige Lokalisierung auf Basis der Grid-Map mit dem Laterations-Scanner schwierig. Dies liegt daran, dass der Scanner kein klassischer LiDAR-Scanner ist, der einen kontinuierlichen 360°-Scan liefert (siehe Kapitel 3.1). Ein alternativer Ansatz zur gleichzeitigen Lokalisierung sind landmarkenbasierte SLAM-Verfahren. Da der in dieser Arbeit aufgebaute Laterations-Scanner eine sehr langsame Scangeschwindigkeit hat, bietet sich der EKF-SLAM an, da dieses Verfahren auch zu einer Verbesserung der Positionsschätzung führt, wenn nur eine einzige Landmarke detektiert wird. Andere Verfahren zur Lokalisierung in der zweidimensionalen Ebene, zum Beispiel eine rigide Transformation zwischen detektierten Landmarken und Karte, benötigen mindestens drei Landmarken in einer Messung bzw. einem Scan.

3.3.1 Landmarken für landmarkenbasierte SLAM-Verfahren mit Radar

Landmarken werden generell in künstliche und natürliche Landmarken unterschieden. Für Radarsensoren bieten sich Landmarken an, die Geometrielemente eines Winkelreflektors beinhalten. Winkelreflektoren haben den Vorteil, dass ihr Reflexionszentrum konstant an der gleichen Stelle bleibt,

auch wenn der Sensor sich an einer anderen Stelle befindet. Wie bereits erwähnt, kann bei einem Laterationsverfahren nur von einer korrekten Positionsbestimmung ausgegangen werden, wenn jeder Sensor die Distanz zu dem gleichen Reflexionszentrum misst. Weiterhin haben sie den Vorteil, dass sie aufgrund eines höheren Radarquerschnitts besser detektiert werden können. Zwei geeignet künstliche Landmarken für Radarsensoren sind in der Abbildung 34 dargestellt.

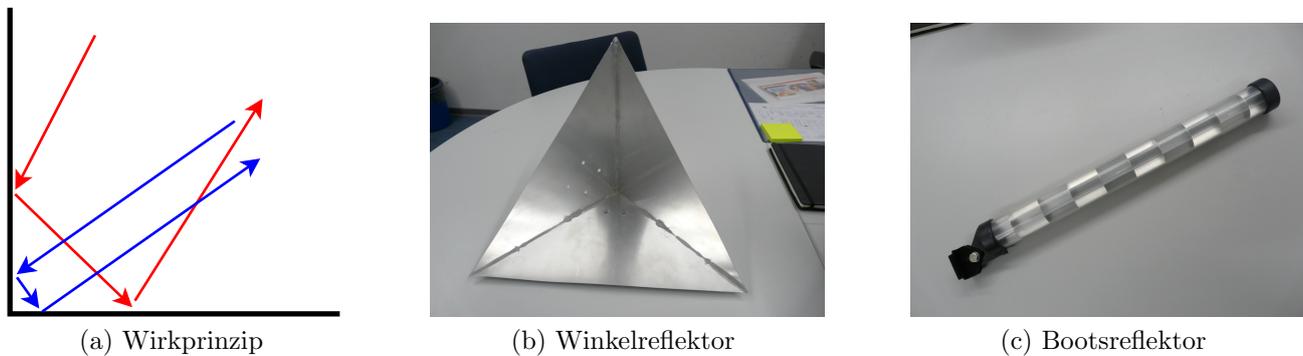


Abbildung 34: Radarreflektoren reflektieren eingehende Strahlen in die gleiche Richtung zurück.

Da eine Landmarke von allen möglichen Positionen aus detektierbar sein muss, bieten sich beispielsweise Bootsreflektoren an (Abbildung 34c). In [CPGG05] werden verschiedene Reflektortypen vorgestellt. Für das Laterations-Verfahren eignen sich Radarreflektoren für Segel- und Motorboote, da sie bei senkrechter Aufstellung zu der Operationsebene eines mobilen Roboters von allen Richtungen detektiert werden können. Bei der Platzierung von Radar-Landmarken muss der Öffnungswinkel und die Distanzauflösung der Sensoren beachtet werden. Befinden sich die Radar-Landmarken zu dicht beieinander, können sie nicht voneinander unterschieden werden. Wenn sie zu weit entfernt vom Sensor befinden, wird ihre Positionsbestimmung ungenau (siehe Gleichung 51, Seite 44).

In Abbildung 35 wird aus der Vogelperspektive dargestellt, wie sich der Öffnungswinkel Θ und die Distanzauflösung ΔR von Radarsensoren auf Bereiche auswirken, in denen mehrere Marken nicht mehr voneinander unterschieden werden können (dunkelblau). In diesen Bereichen werden falsche Koordinaten für die Marken ermittelt, was zu einer fehlerhaften Kartierung bzw. Lokalisierung führt. Um jede Marke befindet sich ein kreisförmiger Bereich mit einem Radius gleich der minimalen Detektionsreichweite, in dem eine Marke nicht erkannt werden kann (siehe Gleichung 34). Neben dem kreisförmigen Bereich befinden sich senkrecht zu einem Markenpaar jeweils zwei kegelförmige Bereiche, in denen keine Unterscheidung des Markenpaares erfolgen kann. In Abbildung 35 ist weiterhin zu erkennen, dass die kegelförmigen Bereiche schmaler werden, wenn die Distanzauflösung besser wird. Der Bereich wird wieder breiter, wenn sich das Markenpaar annähert. Ist der Abstand des Markenpaares kleiner als die Distanzauflösung, dann können die Marken ab einer bestimmten Distanz von keiner Messposition aus unterschieden werden. Wenn der Öffnungswinkel Θ des Radarsensors vergrößert wird, dann verlängert sich die Spitze des kegelförmigen Bereiches, welcher keine Unterscheidung zulässt. Diese Fakten erschweren besonders in einer objektreichen Umgebung den erfolgreichen Einsatz von einfachen Radarsensoren.

Der in Abbildung 35 dargestellte Effekt führt dazu, dass sich in einer Umgebung mit mehreren Marken der Operationsraum, in dem sich der Roboter bewegen und Marken korrekt erkennen kann, sehr einschränkt. In Abbildung 36 ist verdeutlicht, inwiefern sich der Operationsraum einschränken kann. In dieser Abbildung darf der Roboter Δ die durch blaue Quadrate markierte Landmarken nicht

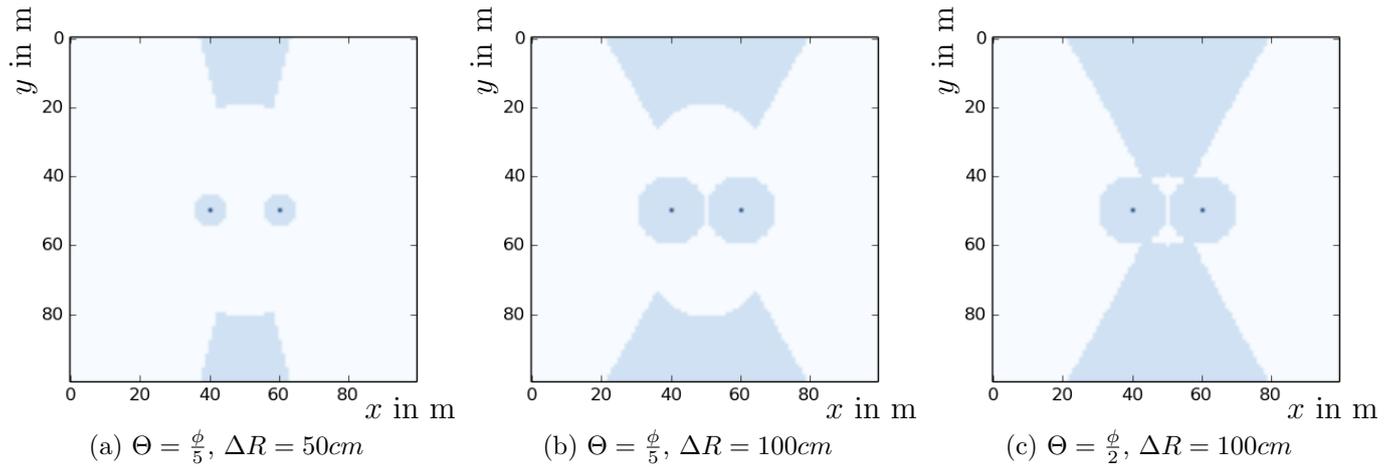


Abbildung 35: Die Abbildung stellt die Bereiche in Abhängigkeit der Distanzauflösung ΔR und des Öffnungswinkels Θ dar, in denen zwei Marken (hier bei M1(40,60) und M2(60,50)) nicht voneinander unterschieden werden können.

zur Lokalisierung verwenden, wenn er sich an der ange deuteten Position befindet.

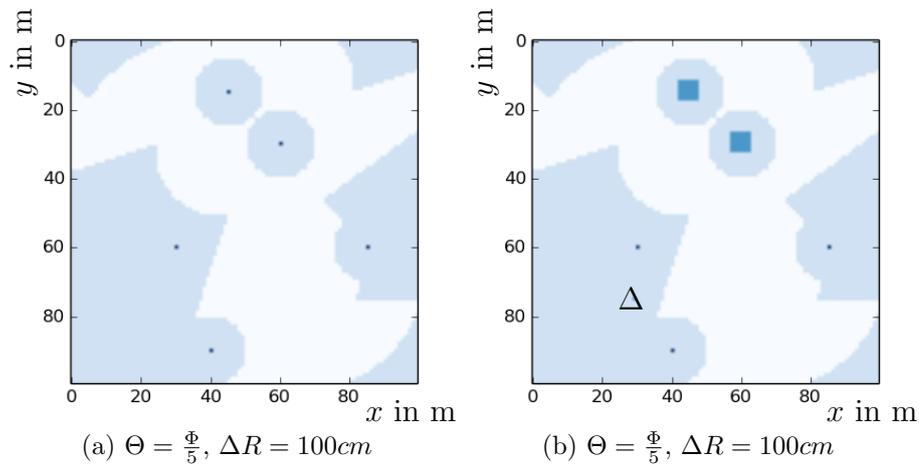


Abbildung 36: In einer Umgebung mit mehreren Marken ist bei einem großen Öffnungswinkel Θ und einer geringen Auflösung ΔR der Bereich in denen alle Marken erkannt, bzw. voneinander unterschieden werden können, eingeschränkt (heller Bereich). In der Abbildung 36b sind durch dunkelblaue Quadrate die Marken dargestellt, die nicht zur Lokalisierung verwendet werden sollten, wenn der Roboter sich an der Position Δ befindet.

3.3.2 Landmarkenkarten

Für das Erstellen von Landmarkenkarten mit dem Iterations-Scan-Verfahren kann der EKF-SLAM verwendet werden. Der EKF-Filter verläuft zyklisch und benötigt eine initiale Schätzung der Position des Roboters und die dazugehörige Unsicherheit. Der Filter wird in einen Prädiktions- und einen Korrekturschritt eingeteilt.

Prädiktion:

$$\bar{\mu}_t = g(\mu_{t-1}, u_t) \quad (57)$$

$$\bar{\Sigma}_t = G_t \Sigma_{t-1} G_t^T + R_t. \quad (58)$$

$$(59)$$

Korrektur:

$$K_t = \bar{\Sigma}_t H_t^T (H_t \bar{\Sigma}_t H_t^T + Q_t)^{-1} \quad (60)$$

$$\mu_t = \bar{\mu}_t + K_t (z_t - h(\bar{\mu}_t)) \quad (61)$$

$$\Sigma_t = (I - K_t H_t) \bar{\Sigma}_t. \quad (62)$$

Bevor der Filter gestartet wird, muss ein Anfangswert für den Systemzustand μ und der dazugehörigen Kovarianzmatrix Σ gegeben werden. Diese müssen die Position und Ausrichtung des Roboters oder auch bereits Landmarken beinhalten. Nach dem Start des Filters wird der geschätzte Zustand $\bar{\mu}_t$ mit dem Bewegungsmodell im Prädiktionschritt ermittelt. Die Positionen von Landmarken $(x_1, y_1, \dots, x_N, y_N)$ werden bei der Zustandsschätzung nicht verändert. Die Grundlagen zu Bewegungsmodellen wurde in Kapitel 2.1 erläutert.

$$g(\mu_{t-1}, u_t) = g(x, y, \Theta, x_1, y_1, \dots, x_N, y_N, l, r) = \begin{pmatrix} x \\ y \\ \Theta \\ x_1 \\ y_1 \\ \vdots \\ x_N \\ y_N \end{pmatrix} + \begin{pmatrix} (R + \frac{w}{2})(\sin(\Theta + \alpha) - \sin(\Theta)) \\ (R + \frac{w}{2})(-\cos(\Theta + \alpha) + \cos(\Theta)) \\ \alpha \\ 0 \\ 0 \\ \vdots \\ 0 \\ 0 \end{pmatrix} \quad (63)$$

Nach der Schätzung des Zustands $\bar{\mu}_t$, wird die geschätzte Kovarianzmatrix $\bar{\Sigma}_t$ berechnet, die von G_t (Gleichung 64) und R_t abhängig ist (Gleichung 58). G_t ist die Jacobi-Matrix von der Systemfunktion g mit den partiellen Ableitungen der Systemfunktion g (Gleichung 63) nach den Elementen des

Systemzustands.

$$G = J_{g(x,y,\Theta,x_1,y_1,\dots,x_N,y_N)} = \begin{pmatrix} 1 & 0 & \frac{\partial g_1}{\partial \Theta} & 0 & 0 & \dots & 0 & 0 \\ 0 & 1 & \frac{\partial g_2}{\partial \Theta} & 0 & 0 & & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & & 0 & 0 \\ \vdots & & & & & \ddots & & \\ 0 & 0 & 0 & 0 & 0 & & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & & 0 & 1 \end{pmatrix} \quad (64)$$

R_t (Gleichung 65) repräsentiert das Rauschen durch die Steuergröße u und setzt sich aus V_t (Gleichung 66), der Jacobi-Matrix der Systemfunktion mit den partiellen Ableitungen nach den Steuergrößen, zusammen. Die Steuergrößen sind die Distanzen, die das linke bzw. rechte Rad während eines Filterzyklus zurücklegt. Die Kovarianz der Steuergröße Σ_{Sg} setzt sich aus den voneinander unabhängigen Varianzen für die Wegstrecken des linken (σ_l^2) bzw. des rechten Rades (σ_r^2) zusammen. Für σ_l^2 bzw. σ_r^2 kann ein Fehlermodell entworfen werden, was zum Beispiel neben den zurückgelegten Distanzen l und r von der Geschwindigkeit und der Beschleunigung der Räder, Reibkoeffizienten usw. abhängig sein kann

$$R_t = V_t \Sigma_{Sg} V_t^T \quad (65)$$

$$V_t = J_{g(l,r)} = \begin{pmatrix} \frac{\partial g_1}{\partial l} & \frac{\partial g_2}{\partial l} & \frac{\partial g_3}{\partial l} & 0 & 0 & \dots & 0 & 0 \\ \frac{\partial g_1}{\partial r} & \frac{\partial g_2}{\partial r} & \frac{\partial g_3}{\partial r} & 0 & 0 & \dots & 0 & 0 \end{pmatrix}^T \quad (66)$$

$$\Sigma_{Sg} = \begin{pmatrix} \sigma_l^2 & 0 \\ 0 & \sigma_r^2 \end{pmatrix}. \quad (67)$$

Mit den genannten Gleichungen wird der Prädiktionsschritt berechnet. Wenn nur dieser Schritt implementiert wird, dann wird die Position des Roboters gemäß der Koppelnavigation bestimmt und zusätzlich eine Kovarianzmatrix, die zu einer sich vergrößernden Ungenauigkeit der Positionsschätzung führt. Entgegen des sich vergrößernden Fehlers der Positionsschätzung durch die Integration von kleinen Fehlern, wird die Positionsbestimmung eines Objektes mit einem Abstandssensor in jedem Zeitschritt genauer, solange der Fehler der Distanzmessung normalverteilt ist.

Im Korrekturschritt wird der aktuelle Systemzustand μ_t und die aktuelle Kovarianzmatrix Σ_t zum Zeitpunkt t ermittelt. Ob zur Bestimmung der Werte mehr den Schätzwerten aus dem Prädiktionsschritt oder den Messwerten vertraut werden soll, wird über den Verstärkungsfaktor K_t definiert. K_t ergibt sich aus der geschätzten Kovarianz $\bar{\Sigma}_t$, der Beobachtungsmatrix H und der Messkovarianzmatrix Q_t . Die Messung z ergibt sich aus der Messfunktion. Der Winkel α bezieht sich auf das lokale Sensorkoordinatensystem und den Landmarken (Abbildung 37)

$$z = \begin{pmatrix} r \\ \alpha \end{pmatrix} = \begin{pmatrix} \sqrt{(x_n - x_S)^2 + (y_n - y_S)^2} \\ \text{atan}\left(\frac{y_M - y_S}{x_M - x_S}\right) - \Theta \end{pmatrix}. \quad (68)$$

Die Beobachtungsmatrix ergibt sich aus der Jacobi-Matrix der Messfunktion, mit den partiellen

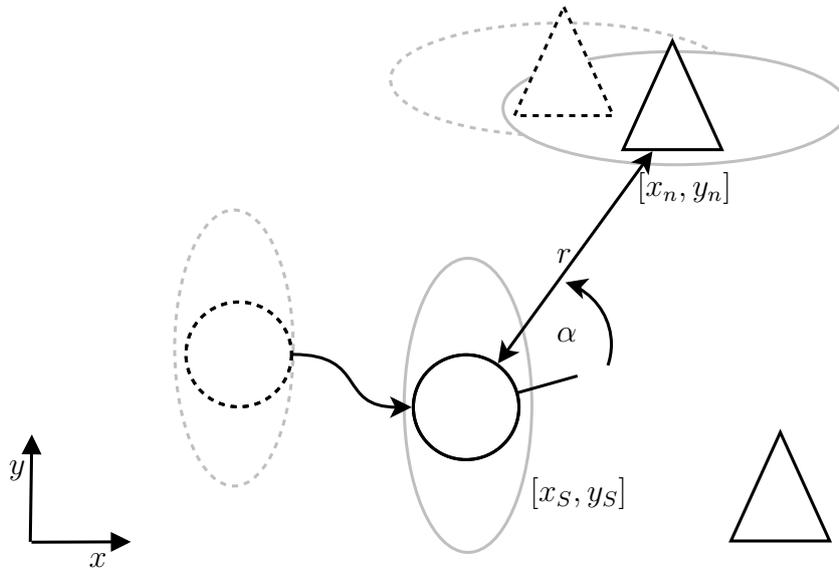


Abbildung 37: Die geschätzte Markenposition (gestrichelt) entspricht nicht der gemessenen Markenposition (nicht gestrichen). Die Datenzuordnung ermöglicht eine Zuordnung. In Abhängigkeit der Kalmanverstärkung wird die Roboterposition mehr in Richtung der Schätzung oder der Messung korrigiert.

Ableitungen nach dem gesamten Zustandsvektor

$$H = J_{h(x,y,\Theta,x_1,y_1,\dots,x_N,y_N)} = \begin{bmatrix} \frac{\partial r}{\partial x} & \frac{\partial r}{\partial y} & \frac{\partial r}{\partial \Theta} & \frac{\partial r}{\partial x_1} & \frac{\partial r}{\partial y_1} & \cdots & \frac{\partial r}{\partial x_N} & \frac{\partial r}{\partial y_N} \\ \frac{\partial \alpha}{\partial x} & \frac{\partial \alpha}{\partial y} & \frac{\partial \alpha}{\partial \Theta} & \frac{\partial \alpha}{\partial x_1} & \frac{\partial \alpha}{\partial y_1} & \cdots & \frac{\partial \alpha}{\partial x_N} & \frac{\partial \alpha}{\partial y_N} \end{bmatrix}. \tag{69}$$

Q_t (Gleichung 70) beinhaltet die Varianzen der Distanz- und Winkelfehler. Hier können auch Fehlermodelle implementiert werden, die man zum Beispiel aus Testmessungen, wie zum Beispiel in Abbildung 28 dargestellt wird, bestimmen kann

$$Q = \begin{pmatrix} \sigma_r^2 & 0 \\ 0 & \sigma_\alpha^2 \end{pmatrix}. \tag{70}$$

Mit der Kalmanverstärkung K_t kann für den Filterzyklus der Erwartungswert für den Zustandsvektor μ_t berechnet werden. Die Kalmanverstärkung setzt eine Gewichtung zwischen der aktuellen Messung z und die über das Messmodell geschätzte Messung mittels des Messmodells h . Die Differenz zwischen aktueller Messung und geschätzter Messung wird als Innovation bezeichnet. Als letzter Schritt wird die neue Kovarianzmatrix Σ_t berechnet.

4 LiDAR-Radar-Fusionsverfahren

Kapitel 3 hat im Rahmen einer Vorbetrachtung ein neues Verfahren zur Umgebungsmodellierung mit Radarsensoren vorgestellt. Der in diesem Kapitel vorgestellte Laterations-Scanner eignet sich jedoch nicht für SLAM-Verfahren, die auf der Registrierung einzelner Scans basieren. Weiterhin ist im Vergleich zu LiDAR-Scannern kein hoher Detailgrad der Umgebungsmodelle zu erreichen. Solange ein Teil der Messwerte eines LiDAR-Scanners nicht von gestörter Sicht beeinträchtigt ist, führt eine LiDAR-Radar-Fusion zu einem höheren Detailgrad des Umgebungsmodells. Das folgende Kapitel beschreibt neue LiDAR-Radar-Fusionsverfahren zur Lokalisierung und Navigation in Umgebungen mit gestörter Sicht. Darauf aufbauend setzt sich Kapitel 5 mit der Modellierung von Aerosolkonzentrationen auseinander. Die in diesem Kapitel erläuterten Verfahren sind auf Aufbauten mit mindestens einem LiDAR- und einem Radar-Scanner anwendbar.

Kapitel 4.1 klassifiziert die negativen Einflüsse von Aerosolen auf LiDAR-Scanner und beschreibt somit die Motivation für die LiDAR-Radar-Fusionsverfahren. Darauf aufbauend diskutiert Kapitel 4.2 Ansätze für LiDAR-Radar-Fusionsverfahren. Auf diese Weise wird begründet, warum in dieser Dissertation die Fusionierung auf Sensorebene (Scan-Fusion) gewählt wird. Kapitel 4.3 definiert die grundlegenden Anforderungen an die LiDAR-Radar-Fusion. Darauf folgend stellt Kapitel 4.4 drei Fusionsverfahren zur Erzeugung von zweidimensionalen fusionierten Scans vor. Ein Ausblick auf LiDAR-Radar-Fusionsverfahren für dreidimensionale Scans ist in Kapitel 4.5 gegeben.

4.1 Der Einfluss von gestörter Sicht auf LiDAR-Scanner

Phillips et al. [PGM17] beschreiben vier Effekte, die durch Staub bei LiDAR-Sensoren hervorgerufen werden (siehe Abbildung 38). Im Rahmen einer Voruntersuchung für die experimentellen Evaluierungen der vorgestellten Verfahren, wird im Folgenden untersucht, ob Nebel die gleichen Effekte verursacht. Im Gegensatz zu Staub kann Nebel kontrolliert mit Nebelmaschinen erzeugt werden und ist daher für Experimente mit mobilen Robotern geeignet.

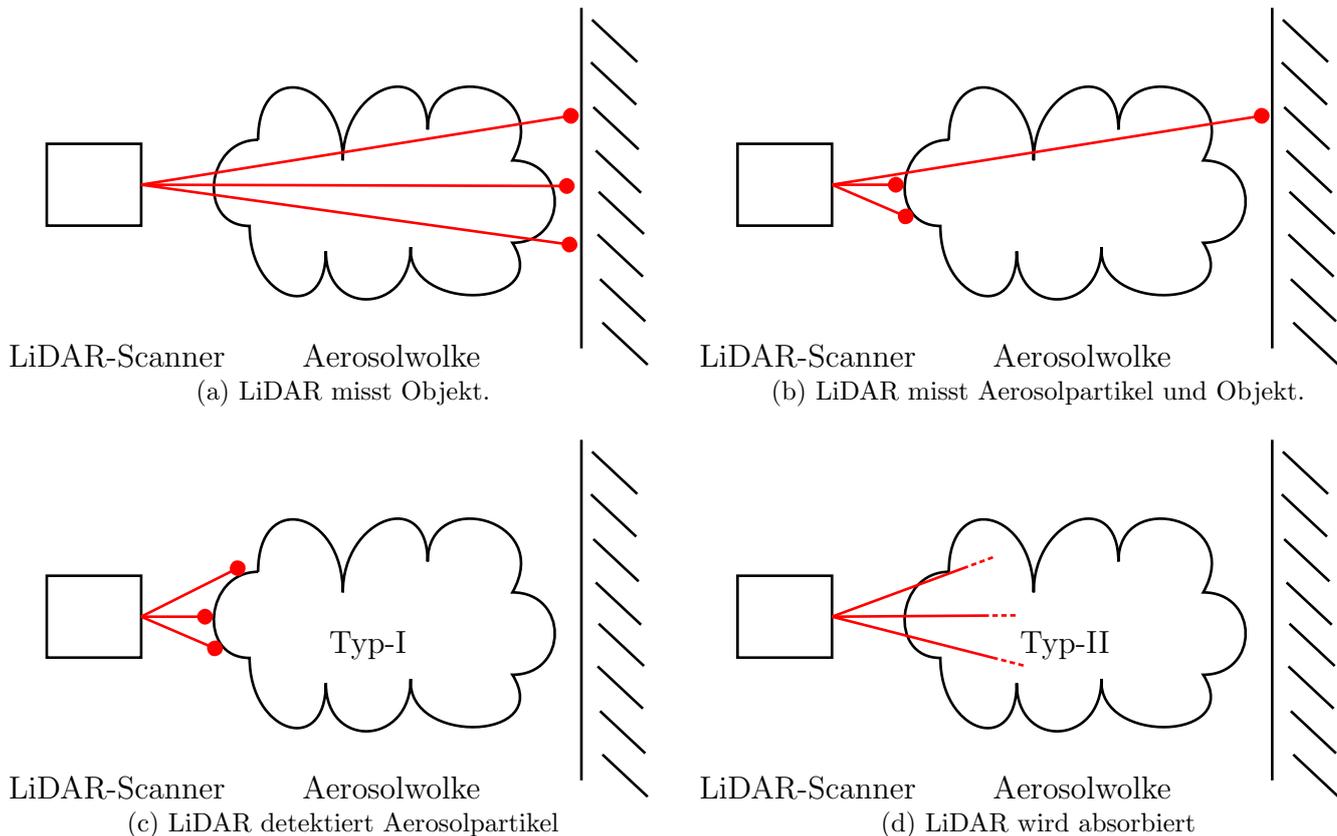


Abbildung 38: Im Fall a liefert der LiDAR vollständig brauchbare Werte. Im Fall b ist der LiDAR teilweise verwendbar. Der Störeinfluss kann oft per Sensoreinstellung (nächster, stärkster oder entferntester Reflektor) gelöst werden. Im Fall c werden nur Aerosolpartikel erkannt. Im Fall d kommt es zur Absorption einzelner LiDAR-Messungen.

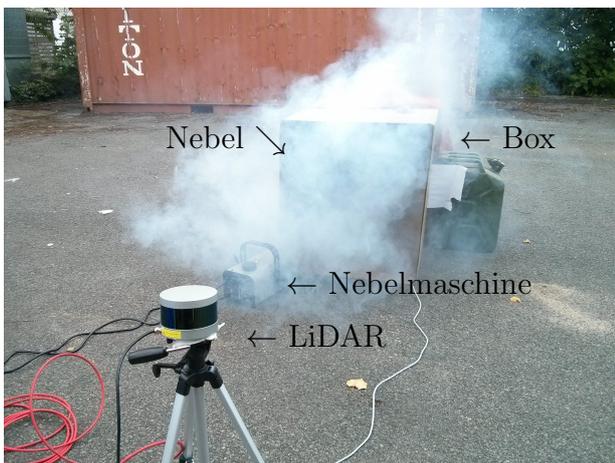
Der Fall in Abbildung 38a stellt für die mobile Robotik kein Problem dar, da die Zielfähigkeiten Lokalisierung, Kartierung und Navigation weiterhin ausgeführt werden können.

Der Fall in Abbildung 38b führt zu Problemen bei der Erreichung der genannten Zielfähigkeiten. Der Fall b kann jedoch in den meisten Fällen gelöst werden, indem in den Sensoreinstellungen der stärkste oder entfernteste Reflektor gewählt wird. Wenn 3D-LiDAR-Scanner verwendet werden, kann zusätzlich nach den entferntesten Punkten bezüglich eines vertikalen Schnittes gesucht werden, um einen 2D-Scan zu erzeugen. Dieses Verfahren wurde unter dem Namen *Virtual 2D-Scans* von [Wul08] vorgestellt, um geeignete Punkte für die Lokalisierung in Indoor-Umgebungen zu suchen.

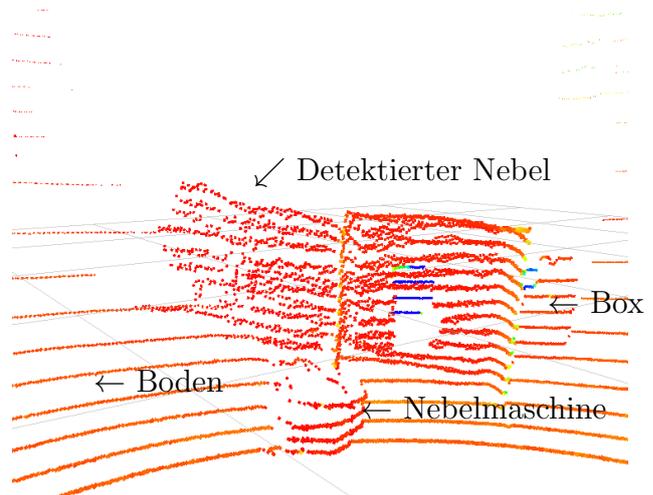
Der Fall in Abbildung 38c ist problematisch, da Objekte nicht detektiert werden können. Zusätzlich

befinden sich viele Detektierungen von Aerosolpartikel im Scan, die für die Lokalisierung und Kartierung nicht geeignet sind. Zum einen wird ein Scan, der viele von Aerosolpartikeln stammende Messwerte beinhaltet bei einer Registrierung zwischen Scan und Karte zu einer falschen Ausrichtung führen. Zum anderen werden durch Aerosolpartikel unerwünschte Objekte in die Karte eingetragen. Weiterhin wird bei der autonomen Fahrt eines Roboters oft ein lokaler Pfad auf der Grundlage des aktuellen Scans berechnet, um dynamischen Hindernissen ausweichen zu können, die nicht in der globalen Karte eingetragen sind. Dementsprechend hat ein Scan, der detektierte Aerosolpartikel enthält, auch einen negativen Einfluss auf die Navigation. Abbildung 39 zeigt in einem Experiment diesen Fall, der im Nachfolgenden als Typ-I bezeichnet wird. Abbildung 39 demonstriert, dass das Objekt (Box) nicht erkannt werden kann, da der LiDAR die Aerosolpartikel detektiert, die sich zwischen LiDAR und Objekt befinden.

Phillips et al. [PGM17] legen dar, dass retroreflektive Objekte trotz gestörter Sicht durch Staub mit LiDAR-Scannern detektiert werden können. Abbildung 39 bestätigt, dass der gleiche Effekt bei Nebel auftritt. Im Experiment in Abbildung 39 ist zu erkennen, dass der DIN A4 große Reflektor an der Rückwand der Box trotz Nebel detektiert wird (blaue Punkte in Abbildung 39b).



(a) Statisch aufgebauter LiDAR vor einer Box, die mit Nebel befüllt wird.



(b) In den Messwerten des LiDAR ist eine Detektion des Nebels erkennbar. Der LiDAR-Scan des VLP-16 besteht aus 16 horizontalen Ringen.

Abbildung 39: Die Abbildungen stellen den Typ-I-Effekt dar. Auf der linken Abbildung ist eine Szene mit Nebel zu sehen. Auf der rechten Abbildung sind 3D-Scan-Punkte des Velodyne-VLP-16-3D-LiDAR-Scanners zu erkennen, die den detektierten Nebel darstellen.

Wenn einzelne LiDAR-Strahlen absorbiert werden, tritt der Effekt auf, der in Abbildung 38d skizziert ist. Da in diesem Fall keine detektierbaren Echos für den LiDAR auftreten, interpretiert der Sensor die betroffenen Messungen als unendliche Distanz (*inf.*, Englisch infinite). Dieser Effekt wird in dieser Arbeit Typ-II-Effekt genannt und führt zu Lücken im Scanbild. Befinden sich zu viele Lücken in einem Scan, können wiederum die Zielfunktionen nicht erreicht werden. Ein lückenhafter Scan wird im Experiment in Abbildung 40 dargestellt.

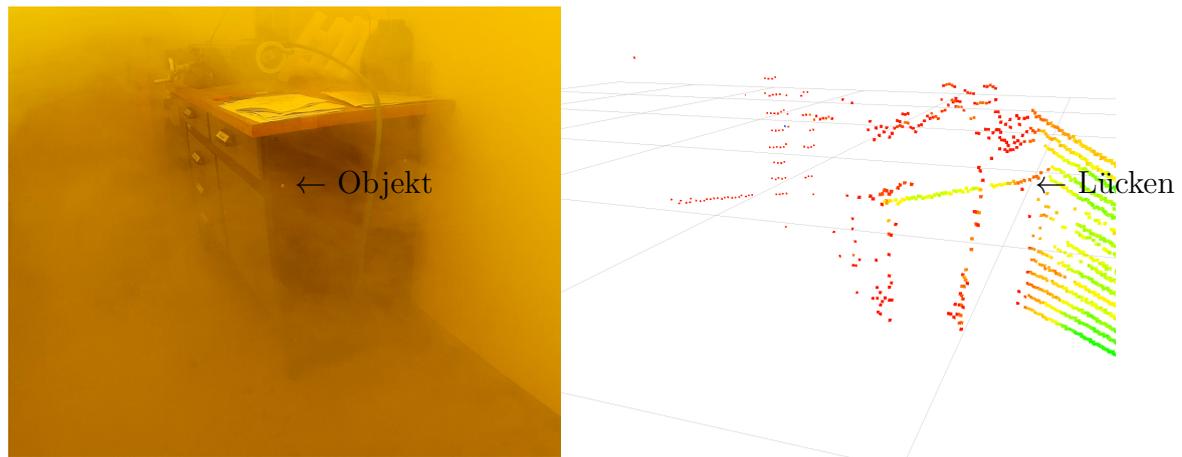


Abbildung 40: Die Abbildung zeigt den Typ-II-Effekt. LiDAR-Messwerte können von Aerosolen absorbiert werden.

Die beschriebenen Effekte verdeutlichen, dass gestörte Sichtbedingungen negative Auswirkungen auf die hier beschriebenen Zielfunktionen haben. In den nachfolgenden Unterkapiteln sind LiDAR-Radar-Fusionsverfahren vorgestellt, die unter der Berücksichtigung der genannten Effekte sich dynamisch an unterschiedliche Situationen anpassen.

4.2 Vorbetrachtung zu LiDAR-Radar-Fusionsstrategien

In Kapitel 4.1 wurde der störende Einfluss durch Aerosole auf LiDAR-Scanner erörtert und experimentell aufgezeigt. Eine Zielsetzung dieser Dissertation ist die Fusionierung von LiDAR- und Radar-Scannern, um Umgebungen zu modellieren, in denen Aerosole die Distanzmessungen von LiDAR beeinträchtigen. Grundsätzlich können die Sensordaten auf unterschiedlichen Ebenen fusioniert werden:

- Kartenebene
- Odometrieebene
- Sensorebene

In diesem Unterkapitel wird eine kurze Vorbetrachtung gegeben, um aufzuzeigen, auf welcher Ebene die Sensordaten fusioniert werden müssen.

Die Fusionierung von Sensoren auf Kartenebene wurde von Lee [Lee14] mit LiDAR und Sonar untersucht. Lee erzeugt mit jedem Sensor getrennt eine Karte, die im Anschluss per Min-Max-Fusion⁶⁵ zusammengeführt werden. In Abbildung 41 ist eine Systementwurf zur LiDAR-Radar-Fusion auf Kartenebene skizziert. Da die Transformation der Karten zueinander bekannt sein muss, kann nur ein Sensor für SLAM-Verfahren genutzt werden, um die Position des Roboters zu erhalten und eine Karte zu erzeugen. Mit dieser Position und einem Kartierungs-Verfahren werden die Sensorwerte des anderen Sensors in eine weitere Karte eingetragen. Der Vorteile des Verfahrens ist, dass keine

⁶⁵Vereinigungsmenge beider Karten

Sensordaten trotz unterschiedlicher Messraten verworfen werden müssen. Der Nachteil ist, dass für die Lokalisierung nur ein Sensor verwendet wird (gleichermaßen kann Radar für SLAM und LiDAR für die Kartierung genutzt werden). Dadurch wird dieses Verfahren sich nicht korrekt lokalisieren können, wenn der Typ-I- bzw. Typ-II-Effekt auftritt. Falls Radar für SLAM und LiDAR für die Kartierung genutzt wird, ist die Lokalisierung in Umgebungen mit freier Sicht schlechter als mit LiDAR. Weiterhin werden in diesem Fall Messwerte, die durch den Typ-I-Effekt erzeugt werden, in die Karte eingetragen.

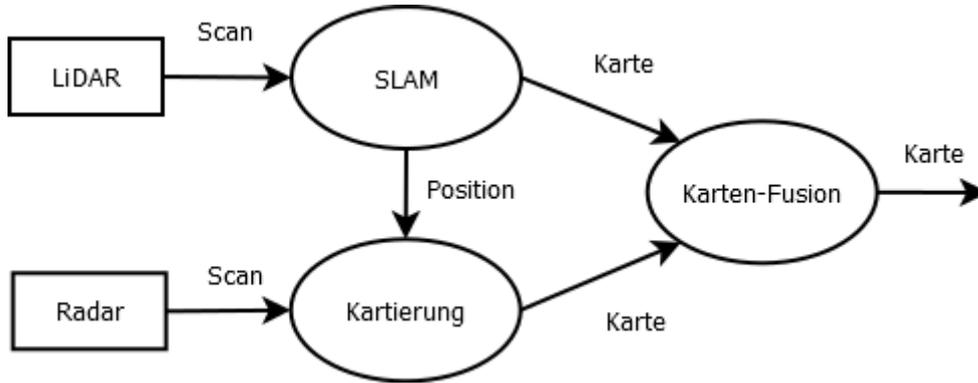


Abbildung 41: LiDAR-Radar-Fusion auf Kartenebene

Aus LiDAR- und Radar-Scannern kann getrennt eine Odometrie ermittelt werden. Durch die Fusionierung dieser Odometrien kann somit eine Position berechnet werden, von der die Scans in eine Karte eingetragen werden (siehe Abbildung 42). Der Vorteil ist, dass wiederum keine Sensordaten verworfen werden müssen. Der Nachteil des Verfahren ist, dass durch den Typ-I- und Typ-II-Effekt die LiDAR-Odometrie beeinträchtigt wird und dass LiDAR-Messwerte des Typ-I-Effektes in die Karte eingetragen werden.

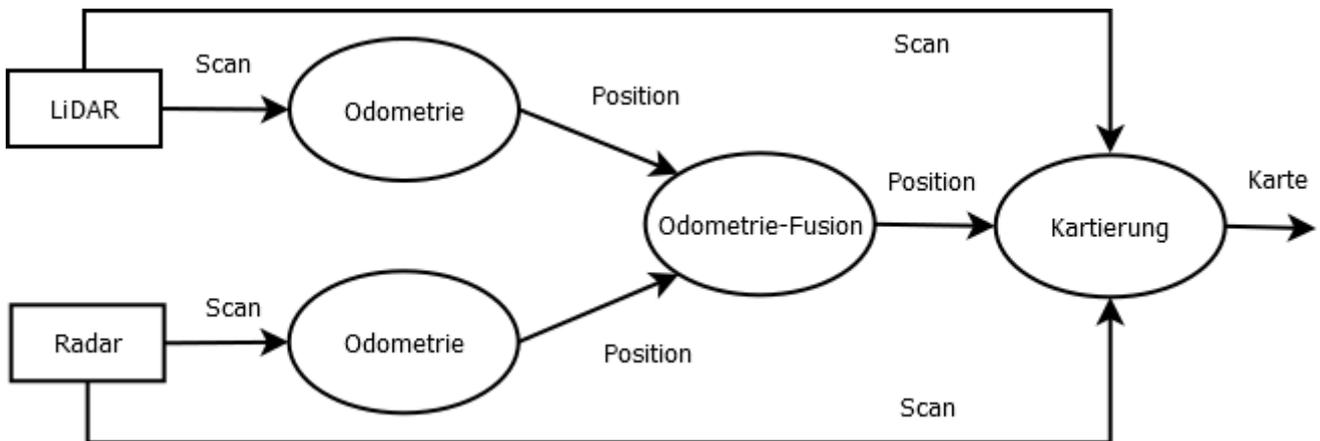


Abbildung 42: LiDAR-Radar-Fusion auf Odometrie-Ebene

Die Fusionierung von LiDAR und Radar auf Sensorebene ist vorteilhaft, da der Typ-I- und Typ-II-Effekt im LiDAR-Scan behoben werden kann und ein fusionierter Scan erzeugt wird. Dieser fusionierte Scan kann somit an Standardverfahren zur Lokalisierung und Kartierung anknüpfen (siehe Abbildung 43). Der Nachteil des Verfahrens ist, dass die Sensoren synchronisiert werden müssen, wodurch Sensordaten verworfen werden, falls die Messrate der Sensoren sich unterscheiden.

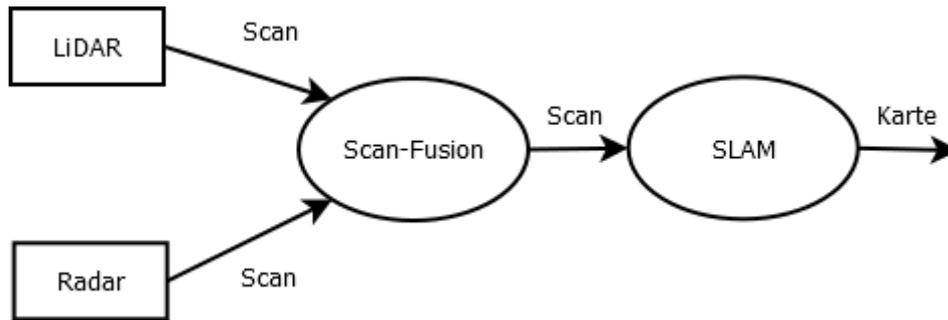


Abbildung 43: LiDAR-Radar-Fusion auf Sensorebene

Aufgrund der genannten Vorbetrachtung behandelt diese Dissertation die Fusionierung auf Sensorebene.

4.3 Vorüberlegung zum Verhalten von LiDAR und Radar bei gestörter Sicht

Das folgende Unterkapitel beschreibt Vorüberlegungen zur Fusionierung von LiDAR- und Radar-Scans. Dabei wird der in Kapitel 4.1 eingeführte Typ-I- und Typ-II-Effekt auf LiDAR-Scanner berücksichtigt. Die LiDAR-Radar-Fusionsverfahren sind Scan-Fusions-Verfahren, die einen fusionierten Scan S_{Fusion} erzeugen, der in Abhängigkeit der Situation Radar, LiDAR oder fusionierte Distanzwerte enthält

$$S_{Fusion} = [R_{LiDAR}, R_{Radar}, R_{Fusion}, \dots]. \quad (71)$$

Zum Beispiel müssen Radar-Distanzwerte R_{Radar} dem fusionierten Scan hinzugefügt, wenn der Typ-I- oder Typ-II-Effekt detektiert wird. Im Gegensatz dazu muss eine LiDAR-Distanzmessung R_{LiDAR} dem fusionierten Scan hinzugefügt werden, wenn der Radar keinen Messwert liefert. Eine Fusion der Messwerte R_{Fusion} kann dementsprechend nur berechnet werden, wenn beide Sensoren das gleiche Objekt beschreiben.

Aufgrund der unterschiedlichen Reichweiten von Sensoren teilt sich die Fusionierung in einen konkurrierenden und in einen komplementären Bereich ein, was durch den Schwellwert R_F voneinander abgegrenzt wird (siehe Abbildung 44). Der Schwellwert wird für jeden Scantakt aus den durchschnittlichen Entfernungswerten des Sensors mit dem kleineren Messbereich berechnet. Hinsichtlich der Experimente in Kapitel 6 wird im folgenden Kapitel davon ausgegangen, dass der Messbereich des LiDAR-Scanners größer ist. Der Schwellwert setzt sich aus dem durchschnittlichen Entfernungswert $R_{Radar,\emptyset}$ und der maximalen Distanzmessung $R_{Radar,max}$ eines Radar-Scans zusammen. Zusätzlich kann mit dem Parameter $\alpha = [0..1]$ die Grenze R_F verschoben werden

$$R_F = R_{Radar,\emptyset} + \alpha(R_{Radar,max} - R_{Radar,\emptyset}). \quad (72)$$

In Tabelle 2 sind die grundlegenden Anforderungen an die Scan-Fusion zusammengefasst. Eine ausführliche Betrachtung einzelner Fälle wird in Anhang A.2 (Seite 135) gegeben.

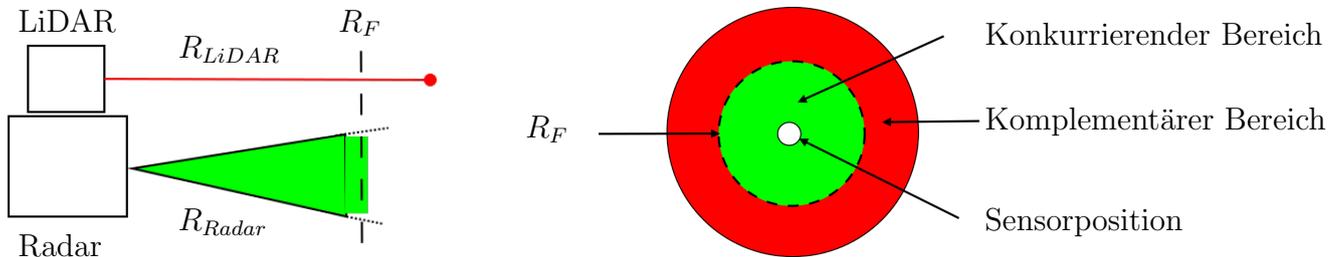


Abbildung 44: Aufgrund unterschiedlicher maximaler Reichweiten ergibt sich ein konkurrierender und ein komplementärer Bereich. In der linken Abbildung sind LiDAR-Scanner, Radar-Scanner und die Abgrenzung R_F der Fusionsbereiche skizziert. In der rechten Abbildung wird die dazugehörige Draufsicht dargestellt.

Fusionsverhalten	Bedingung
$R_{Radar} \rightarrow S_{Fusion}$	- Typ-I-Effekt - Typ-II-Effekt
$R_{LiDAR} \rightarrow S_{Fusion}$	- LiDAR detektiert gerade Struktur z. B. Linie ($R_{LiDAR} \in Linie$) - LiDAR-Messung im komplementären Bereich $R_{LiDAR} > R_F$
$R_{Fusion} \rightarrow S_{Fusion}$	- LiDAR- und Radar-Messung beziehen sich auf das gleiche Objekt (z. B. $ R_{LiDAR} - R_{Radar} < d_F$)

Tabelle 2: Der fusionierte Scan setzt sich aus den Distanzmessungen R_{LiDAR} , R_{Radar} und R_{Fusion} zusammen.

4.4 LiDAR-Radar-Scan-Fusion zur Erzeugung von 2D-Scans

Das folgende Kapitel beschreibt die Vorverarbeitung der Sensordaten und drei Fusionsverfahren zur Erzeugung von zweidimensionalen fusionierten Scans (siehe Abbildung 45).

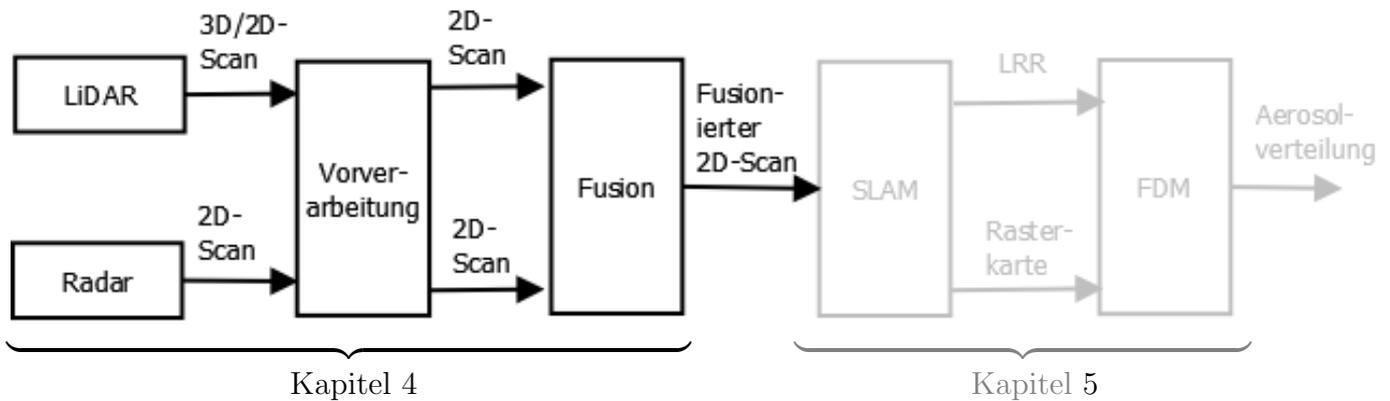


Abbildung 45: Die Scan-Fusion setzt sich aus der Vorverarbeitung und der Fusion zusammen.

4.4.1 Vorverarbeitung der Sensordaten

Die Vorverarbeitung der Sensordaten dient zur Synchronisierung, Integration von virtuellen 2D-Scans, Anpassung der Anzahl der Distanzmessungen pro Scan und der Detektion von Strukturen und Ausreißern.

Synchronisierung der Sensoren

Die Fusionierung von Scans erfolgt in einem Fusionstakt, der sich durch den Sensor mit der geringsten Messrate ergibt⁶⁶.

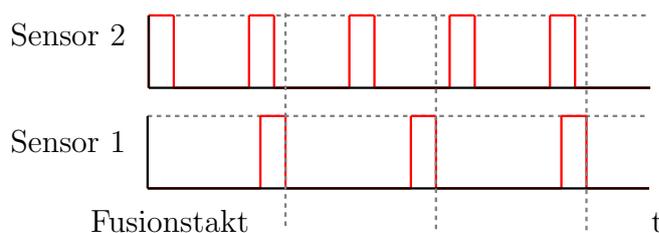


Abbildung 46: Die Fusion von asynchronen Sensordaten erfolgt in einem Fusionstakt. Für die Fusionsverfahren werden jeweils die aktuellsten Messdaten verwendet.

⁶⁶Die meisten LiDAR-Scanner haben höhere Messraten als Radar-Scanner.

Integration von virtuellen 2D-Scans

Da es sich bei den in dieser Arbeit vorgestellten LiDAR-Radar-Fusionsverfahren um 2D-Fusionsverfahren handelt, müssen Messdaten von 3D-LiDAR-Scannern entsprechend reduziert werden. Dafür stellt Wulf [Wul08] die Reduktion eines 3D-Scans zu einer Teilmenge V_C , den virtuellen 2D-Scans, vor.

$$V_C \subset S \quad (73)$$

Für die Reduktion müssen Heuristiken in Abhängigkeit der Einsatzumgebung gewählt werden. Die einfachste Variante ist ein horizontaler Schnitt durch den 3D-Scan zur Erzeugung eines 2D-Scans S_{LiDAR} . Eine weitere Variante ist die Extraktion von zwei unterschiedlichen 2D-Scans. In diesem Fall wird ein Scan zur Objektvermeidung $S_{LiDAR,Nav.}$ und ein Scan für die Kartierung und Lokalisierung $S_{LiDAR,Kart./Lok.}$ erzeugt. Die Algorithmen zur Erzeugung der 2D-Scans hängen jedoch vom verwendeten Sensor und der Umgebung ab und müssen in den meisten Fällen adaptiert werden. Wulf unterscheidet Indoor-, Hallen- und Outdoor-Umgebungen. Virtuelle 2D-Scans zur Lokalisierung in Indoor-Umgebungen werden extrahiert, indem der entfernteste Punkt jeder vertikalen Zeile eines 3D-Scans ermittelt und auf die 2D-Ebene projiziert wird. Für Hallen, in denen markante Deckenstrukturen vorherrschen, schlägt Wulf einen 2D Schnitt im Scan vor, der diese Strukturen trifft. In diesem Fall muss die Höhe der Deckenstrukturen bekannt sein. In Outdoor-Umgebungen segmentiert Wulf gerade vertikale Flächen und fügt sie dem virtuellen 2D-Scan hinzu.

Die Fusion von virtuellen 2D-Scans und 2D-Radar-Scans hat gegenüber der Verwendung von 2D-LiDAR-Scannern Vorteile. Virtuelle 2D-Scans zur Kartierung und Lokalisierung ($S_{LiDAR,Kart./Lok.}$) beinhalten weniger Scan-Punkte, die von Aerosolen betroffen sind als 2D-Scans von 2D-LiDAR-Scanner. Die Ursache dafür ist in der Abbildung in Tabelle 9.L (Anhang, Seite 138) verdeutlicht. Die Fusionierung der virtuellen 2D-Scans erfolgt getrennt für $S_{Kart./Lok.}$ und $S_{Nav.}$. Die Zusammensetzungen des fusionierten Scans zur Lokalisierung und Kartierung $S_{Fusion,Nav.}$ und des fusionierten Scans zur Kartierung und Lokalisierung $S_{Fusion,Kart./Lok.}$ werden in den Tabellen 9 und 10 dargestellt. Ein grundlegende Unterscheidung der Scans erfolgt, indem bei allen Verfahren der entfernteste ($R_{LiDAR,max}$) und der nächste LiDAR-Messpunkt ($R_{LiDAR,min}$) eines vertikalen Schnitts zur Fusionierung betrachtet werden.

Ausrichtung der Sensoren

Für die in Kapitel 4.4.2 und 4.4.3 vorgestellten Scan-Fusions-Verfahren müssen die Sensoren zur gleichen Rotationsachse in z-Richtung ausgerichtet werden (siehe Abbildung 44, Seite 60). Bei der Verwendung von 2D-LiDAR- und 2D-Radar-Scannern ist der Abstand zwischen den Sensoren möglichst klein zu wählen. Die Fusionierung erfolgt hier bezüglich einzelner Abstandsmessungen R , die in einer Scan-Nachricht S in polarer Form sortiert enthalten sind und einen definierten Winkelbereich mit gleichmäßigem Inkrement abdecken. Eine Scan-Nachricht hat die Länge n . Korrespondierende Punktpaare bei unterschiedlichen Winkelauflösungen können daher effizient über den Index i berechnet werden

$$i_{Radar} = \frac{n_{Radar}}{n_{LiDAR}} \cdot i_{LiDAR} + k. \quad (74)$$

Da das modellbasierte und heuristische Verfahren korrespondierende Punktpaare benötigt, wird zunächst der Scan S_{Radar} mit der Gleichung 74 zu S_{Radar}^* erweitert, sodass $n_{Radar^*} = n_{LiDAR}$ ist. Die Kalibrierung der Sensoren erfolgt bei diesem Aufbau über den Parameter k .

Im Gegensatz zu den heuristischen und modellbasierten Verfahren benötigt der virtuelle Sensor (Kapitel 4.4.4) keine Ausrichtung der Sensoren zur gleichen z-Achse. Die Fusionierung erfolgt nicht bezüglich der einzelnen Abstandsmessungen, sondern über eine zweidimensionale Rasterkarte, wobei die Abstandsmessungen der Scan-Nachrichten zunächst in kartesische Koordinaten überführt werden müssen.

Zusätzliche Informationen in den Scan-Nachrichten

Neben den einzelnen Abstandsmessungen R_i werden weitere Informationen, wie zum Beispiel die Rückstrahlleistungen $P_{e,i}$ und der LOF⁶⁷ von Radarmessungen, und die Intensitäten I_i und die freie Sicht⁶⁸ $p_{FS,i}$ bezüglich LiDAR-Messungen, angegeben.

$$S = [R_0, R_1, R_2, \dots, R_{n-1}] \quad (75)$$

$$I = [I_0, I_1, I_2, \dots, I_{n-1}] \quad (76)$$

$$FS = [p_{FS,0}, p_{FS,1}, p_{FS,2}, \dots, p_{FS,n-1}] \quad (77)$$

$$LOF = [LOF_0, LOF_1, LOF_2, \dots, LOF_{n-1}] \quad (78)$$

Mit FS wird die Information angegeben, ob sich eine Distanzmessung auf einer geraden Struktur befindet. Diese Information ist relevant, da im LiDAR-Scan ungerade Strukturen durch den Typ-I-Effekt erzeugt werden. Um gerade Strukturen zu entdecken, werden in 2D-LiDAR-Scans Linien extrahiert. Eine Gegenüberstellung von sechs gängigen Linien-Extraktionsverfahren wird von Nguyen [NGM⁺07] gegeben. Das in dieser Arbeit vorgestellte Verfahren integriert RANSAC⁶⁹. Bei RANSAC wird ein Modell in eine Anzahl von Messpunkten gelegt. Der Algorithmus ist iterativ und wählt im Fall eines Geraden-Modells in jedem Iterationsschritt zufällig zwei Messpunkte, bildet mit diesen zwei Punkten eine Gerade und berechnet die Distanz der LiDAR-Messwerte zu dieser Geraden. Ist die Distanz zu dem Modell zu groß, wird der Messwert nicht als zum Modell gehörend betrachtet. In jedem Iterationsschritt wird die Anzahl der Messwerte bestimmt, die dem Modell zugeordnet werden können. Dies wird unabhängig voneinander wiederholt. Je nachdem wie oft diese Schritte wiederholt werden, wird eine maximale Anzahl von Punkten, die einem Modell zugeordnet werden können, berechnet. Nachdem die Punkte bestimmt worden sind, wird ein Ausgleichsverfahren, zum Beispiel die Methode der minimalen Fehlerquadrate, angewandt. Das Resultat des beschriebenen Verfahrens ist in der Abbildung 47 am Beispiel eines Scans dargestellt.

In der hier vorliegenden Arbeit wird die Struktur der Messpunktverteilungen eines Radar-Scans zur Schätzung der Standardabweichung σ_{Radar} einbezogen. Die Standardabweichung σ_{Radar} wird in jedem Fusionstakt neu ermittelt und ergibt sich aus dem Local-Outlier-Faktor (LOF)-Wert für jeden Radar-Messpunkt. Der LOF wurde von [BKNS00] als Verfahren vorgestellt, Ausreißer mittels lokaler Dichten zu bestimmen. Die Dichte eines Punktes, welche über die durchschnittlichen Abstände seiner k nächsten Nachbarn berechnet wird, wird wiederum mit der Dichte dieser k Nachbarn in ein Verhältnis gesetzt, welches LOF genannt wird. Das Prinzip ist in der Abbildung 48b dargestellt.

Aufgrund des technischen Prinzips von 2D-Scannern nimmt die Punktdichte mit steigendem Abstand zwischen Objekt und Sensor ab. Da der LOF-Wert aus den unterschiedlichen lokalen Dichten ermittelt wird, ist der Wert unabhängig von Bereichen mit unterschiedlichen globalen Dichten. Das Verfahren

⁶⁷Mit dem Local-Outlier-Faktor können Ausreißer identifiziert werden

⁶⁸Liniensegmentierung im LiDAR-Scans dient zur Abschätzung der Beeinträchtigung durch Aerosole

⁶⁹Engl. RANdom SAMple Consensus (RANSAC)

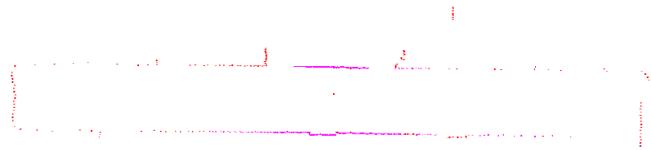
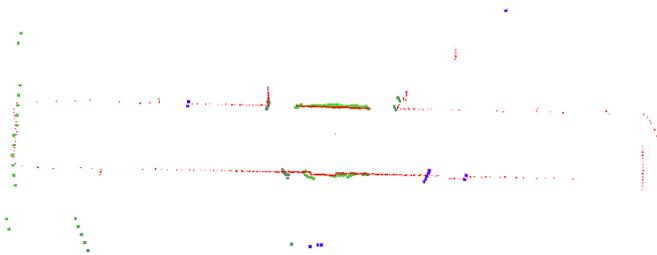
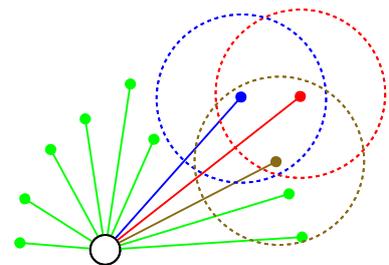


Abbildung 47: Im Laserscan (rot) sind die erkannten Linien magenta eingefärbt.

wurde bereits von [Sot06] auf einen statischen Datensatz eines Riegl LiDAR-Scanners angewandt. In der Abbildung 48a ist zu erkennen, dass der LOF bei einzelnen Ausreißern höher ist (blau dargestellt).



(a) Der Radar-Scan ist mit den LOF-Werten eingefärbt. Hohe LOF-Werte sind blau dargestellt. Zum Vergleich ist auch ein LiDAR-Scan dargestellt (rot).



(b) LOF Prinzip
 $(LOF = \frac{2}{\frac{1}{2}(2+4)})$

Abbildung 48: Für jeden Radar-Scan-Punkt wird die Anzahl der Punkte innerhalb eines definierten Radius bestimmt. Danach werden die Werte von benachbarten Punkten in ein Verhältnis gesetzt. Somit können Ausreißer unabhängig von der Messwertdichte bestimmt werden.

In Abbildung 48a ist weiterhin zu erkennen, dass ein LiDAR-Scanner die Struktur einer Umgebung deutlich besser darstellt als ein Radar-Scanner. Eine Fusionierung mit statischen Fehlervarianzen würde zum Beispiel an Stellen wo die Radarmessungen sichelförmig verlaufen - Was zur Extraktion von Punktzielen für Landmarken-SLAM-Verfahren in Kapitel 5.2.1 genutzt wird - dazu führen, dass der fusionierte Scan an diesen Stellen auch ungenauer wird. In einer strukturierten Umgebung mit vielen planaren Elementen muss daher eine LiDAR-Messung stärker gewichtet werden, wenn der Messpunkt auf einer geraden Geometrie liegt. Im Gegensatz dazu müssen sichelförmige Artefakte, die durch die große Antennenöffnung des Radar entstehen, weniger gewichtet werden.

4.4.2 Modellbasierte 2D-LiDAR- und 2D-Radar-Scan-Fusion

Die Scan-Fusions-Verfahren orientieren sich an den einzelnen Fällen der Tabellen 7-10 (Anhang, Seiten 136-139). Im folgenden Unterkapitel wird vorgestellt, wie eine Scan-Fusion mit normierten Funktionen realisiert werden kann. Der fusionierte Scan S_{Fusion} ergibt sich durch den Zusammenhang mit der normierten Funktion $f(i)$,

$$S_{Fusion}[i] = f(i) \cdot S_{LiDAR}[i] + (1 - f(i)) \cdot S_{Radar}^*[i]. \quad (79)$$

Da die Differenz korrespondierender Distanzmessungen ein wichtiges Maß zur Unterscheidung der in den Tabellen 7-10 beschriebenen Fällen ist, wird zunächst die Differenz beider Scans ΔS zueinander berechnet

$$\Delta S = S_{LiDAR} - S_{Radar}^*. \quad (80)$$

Die einfachste Funktion für $f(i)$ ist eine Signumfunktion zwischen 0 und 1

$$f(i) = \text{sgn}(\Delta S(i)) = \begin{cases} +1 & \text{falls } \Delta S(i) > 0 \\ 0 & \text{falls } \Delta S(i) < 0 \end{cases}. \quad (81)$$

Mit der Signumfunktion können dem fusionierten Scan entweder LiDAR- oder Radar-Distanzwerte hinzugefügt werden. Jedoch werden keine fusionierten Distanzmessungen R_{Fusion} erzeugt, wenn beide Sensoren das gleiche Objekt detektieren. Ein weiterer Nachteil ist, dass der Typ-II-Effekt nicht behoben werden kann.

Für die Funktion $f(i)$ können Kurvenformen (siehe Abbildung 49) erzeugt werden, um die Fälle aus den Tabellen 7-10 abzudecken.

Um fusionierte Distanzwerte zu erzeugen, muss ein Übergangsbereich eingeführt werden, in dem die Distanzmessungen verrechnet werden. Dies kann zum Beispiel mit einer linearen Funktion erzielt werden

$$f(i) = l(\Delta S(i)) = \begin{cases} +1 & \text{falls } \Delta S(i) > \frac{0.5}{m} \\ mx + 0.5 & \text{falls } \frac{-0.5}{m} < \Delta S(i) < \frac{0.5}{m} \\ 0 & \text{falls } \Delta S(i) < \frac{-0.5}{m} \end{cases}. \quad (82)$$

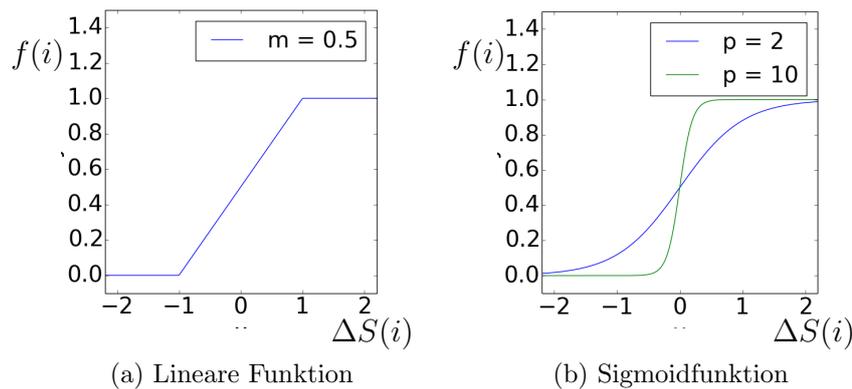


Abbildung 49: Für das Erstellen der Funktion $f(i)$ eignen sich zum Beispiel lineare Funktionen und Sigmoidfunktionen.

Eine Funktion, die ein ähnliches Verhalten zu $l(\Delta S(i))$ abbildet, ist die Sigmoidfunktion. Mit einer einzelnen Sigmoidfunktion kann jedoch wiederum der Typ-II-Effekt nicht behoben werden.

Der Vorteil von Sigmoidfunktionen ist, dass sie einfach miteinander kombiniert werden können. Somit können mehr Fälle aus den Tabellen 7-10 abgedeckt werden. Der Typ-I-Effekt kann bereits mit einer Funktion behoben werden

$$sig_{TypI}(i) = \frac{1}{1 + e^{-p\Delta S(i)}}. \quad (83)$$

Der Parameter p gibt an, wie groß der Bereich ist, in denen LiDAR und Radar das gleiche Objekt detektieren und ihre Messwerte gewichtet verrechnen. Da mit der Gleichung 83 der Typ-I-Effekt behoben werden kann, wird sie als sig_{Typ-I} bezeichnet.

Der Typ-II-Effekt kann detektiert werden, wenn der LiDAR eine unendliche Messung misst, der Radar jedoch ein Objekt detektiert

$$sig_{TypII}(i) = \frac{1}{1 + e^{b(\Delta S(i)-c)}}. \quad (84)$$

Der Parameter b dient nur zum Umschalten der Funktion, wenn $R_{LiDAR} \rightarrow \infty$ und muss mit einem Wert gegen unendlich belegt werden, um einen Verlauf zu erhalten, der einer Signumfunktion ähnlich ist. Der Parameter c muss größer als die maximale Reichweite des LiDAR gewählt werden. Mit $f(i) = sig_{TypI}(i) \cdot sig_{TypII}(i)$ kann bereits der Typ-I- und der Typ-II-Effekt behoben werden. Die Zusammenhänge der zwei Funktionen ist in der Abbildung 50 dargestellt.

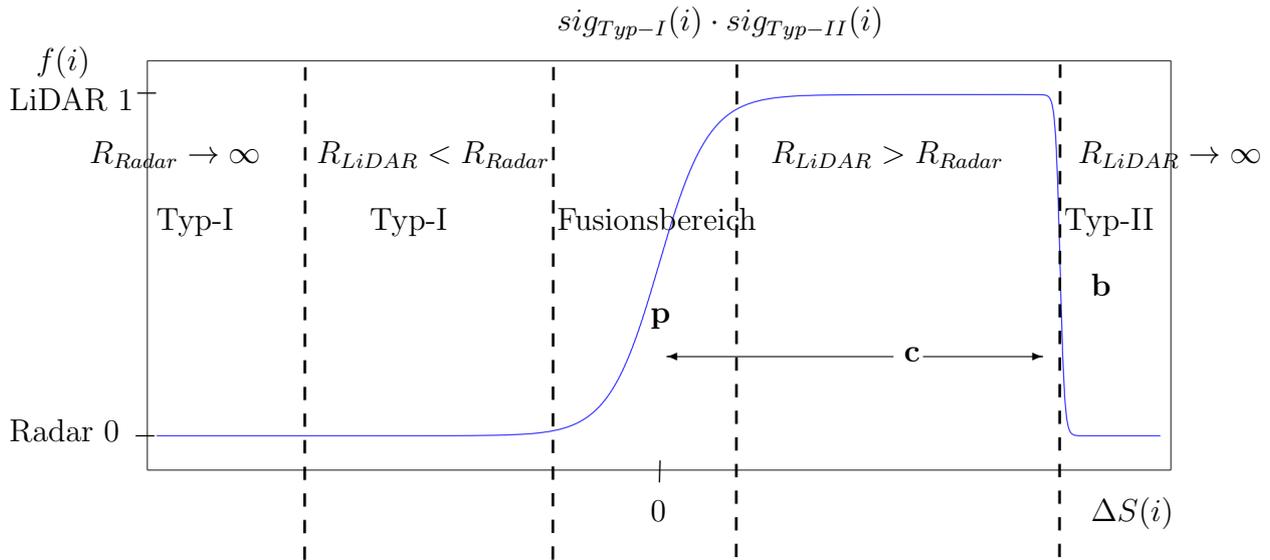


Abbildung 50: Mit sig_{Typ-I} und sig_{Typ-II} lässt sich bereits der Typ-I- und der Typ-II-Effekt beheben.

Das Modell in Abbildung 50 bezieht sich nur auf den konkurrierenden Fusionsbereich (siehe Abbildung 44, Seite 60). Mit der Gleichung 85 lässt es sich durch den komplementären Bereich erweitern

$$sig_{R_F} = \frac{1}{1 + e^{b(S_{LiDAR}[i]+R_F)}} \tag{85}$$

In den Tabellen 7-10 ist ersichtlich, dass bestimmte Fälle mit LiDAR und Radar schwer zu unterscheiden sind. Beispielsweise ist der Fall E und J schwer vom Fall B zu unterscheiden. Problematisch sind dabei Objekte, die nicht vom Radar, jedoch vom LiDAR detektiert werden können, da die gleiche Definition auch für den Typ-I-Effekt zutrifft. Um trotzdem eine Unterscheidung dieser Fälle zu ermöglichen (ohne weitere Sensoren einzubinden) wird für jeden LiDAR-Messpunkt p_{FS} ermittelt, indem in der Sensorvorverarbeitung der gesamte Scan S_{LiDAR} auf gerade Strukturen untersucht wird

$$sig_{FS}(i) = \frac{1}{1 + e^{-b \cdot FS(i)}} \tag{86}$$

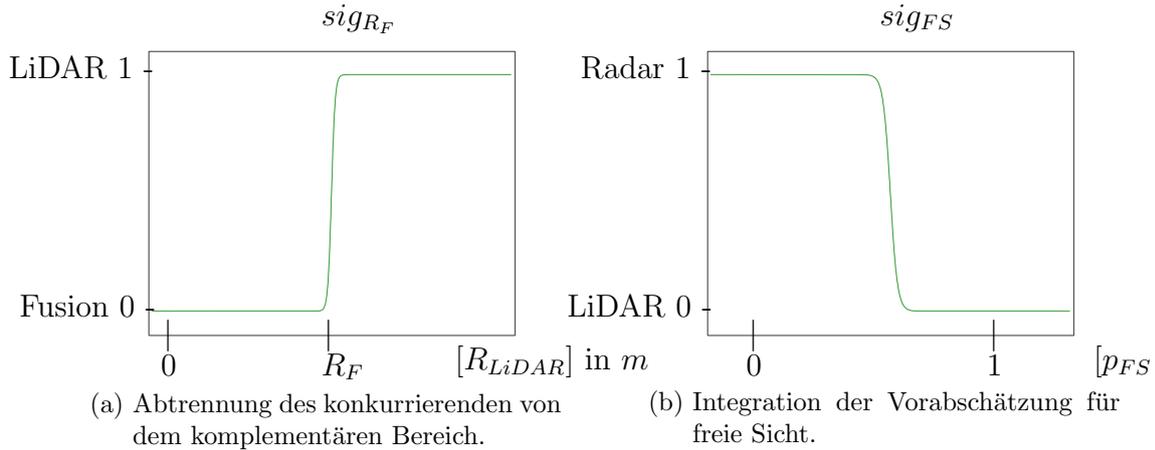


Abbildung 51: Integration der Unterscheidung zwischen konkurrierenden und komplementären Bereich und einer Vorabschätzung über freie Sicht.

Im Anschluss ergibt sich die Funktion $f(i)$ durch folgendes Modell:

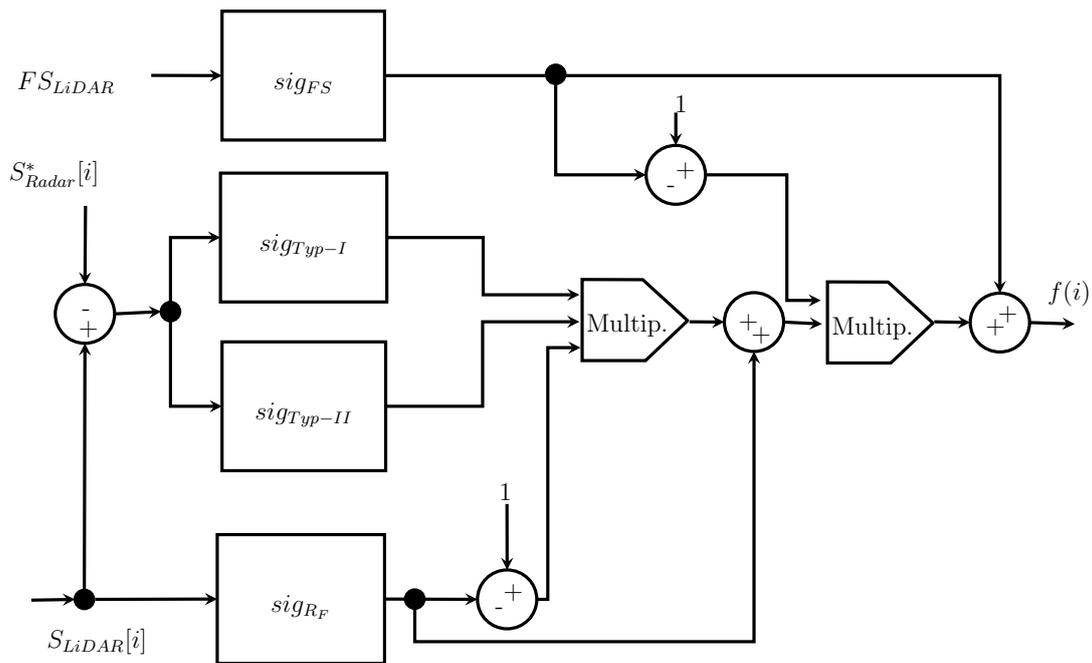


Abbildung 52: Blockdiagramm der modellbasierten Fusion.

4.4.3 Heuristische 2D-LiDAR- und 2D-Radar-Scan-Fusion

In diesem Unterkapitel wird eine Scan-Fusion basierend auf heuristischen Regeln vorgestellt. Die in Gleichung 4.4.3 vorgestellten heuristischen Regeln werden jeweils auf korrespondierende Distanzmessungen in den Scans angewendet, um zu entscheiden, ob eine LiDAR-, Radar- oder fusionierte Distanzmessung dem fusionierten Scan hinzugefügt wird. Als Entscheidungskriterium wird dabei der Abstand korrespondierender Distanzmessungen verwendet. Die Unterteilung des Fusionsbereiches mit dem Abstand R_F in einen konkurrierenden und komplementären Bereich ist identisch zur modellbasierten Fusion. Wenn sich sowohl LiDAR- als Radar-Messung innerhalb des Fusionsradius R_F befinden und ihr Abstand zueinander kleiner als d_F ist, wird davon ausgegangen, dass beide Sensoren das gleiche Objekt beschreiben

$$|R_{LiDAR} - R_{Radar}| < d_F. \quad (87)$$

In diesem Fall erfolgt eine Sensorfusion mit einer gewichteten Mittelung. Der fusionierte Abstand R_{Fusion} des Scan-Punktes ergibt sich folgendermaßen

$$R_{Fusion} = R_{Radar} + \frac{\sigma_{Radar}^2}{\sigma_{Radar}^2 + \sigma_{LiDAR}^2} \cdot (R_{LiDAR} - R_{Radar}). \quad (88)$$

Die Varianzen σ_{Radar}^2 und σ_{LiDAR}^2 können mit statischen Werten aus den Datenblättern oder mit einem Modell verknüpft werden, das die Distanzmessungen, die LiDAR-Intensität bzw. Radar-Rückstrahlleistung, die Temperatur oder den LOF beinhaltet. In Kapitel 3 ist in Abbildung 28 (Seite 44) die Standardabweichung eines FMCW-Radarsensors in Abhängigkeit der Rückstrahlleistung und der gemessenen Distanz abgebildet. Die Standardabweichung der Abstandsmessung R dieses Sensors steigt proportional zur gemessenen Distanz und indirekt proportional zur Rückstrahlleistung. Der Zusammenhang wird durch die Radargleichung (Gleichung 31, Seite 29) verständlich. Ye und Borenstein [YB] haben in einer Untersuchung eines SICK-LMS200-LiDAR-Scanners festgestellt, dass die Standardabweichung von der Reflektivität der Objekte, d.h. der gemessenen Intensität abhängig ist. Demzufolge muss eine größere Reflektivität zu einer geringeren Standardabweichung führen. Sowohl Intensität und Rückstrahlleistung nehmen bei steigender Messdistanz ab. Bei dem in Kapitel 6 verwendeten Velodyne-VLP-16-3D-LiDAR-Scanner kann die Abhängigkeit von der Temperatur ausgeschlossen werden, was von Glennie et al. [GKF16] belegt wird.

Die Berechnung des fusionierten Scans S_{Fusion} mit Heuristiken ist in Gleichung 4.4.3 gegeben

$$S_{Fusion} = \begin{cases} R_{LiDAR}, & \text{wenn } |R_{LiDAR} - R_{Radar}| > d_F \cap R_{LiDAR} \in \text{Linie} \\ & R_{LiDAR} > R_F \cap R_{LiDAR}! = \text{inf} \\ & R_{LiDAR} - R_{Radar} > d_F \cap R_{LiDAR} < R_F \\ R_{Radar}, & \text{wenn } R_{LiDAR} - R_{Radar} < -d_F \cap R_{LiDAR} < R_F \quad (\text{Typ - I}) \\ & R_{LiDAR} = \text{inf} \cap R_{Radar}! = \text{inf} \quad (\text{Typ - II}) \\ R_{Fusion}, & \text{wenn } |R_{LiDAR} - R_{Radar}| < d_F \end{cases} \quad (89)$$

4.4.4 2D-LiDAR- und 2D-Radar-Scan-Fusion mit virtuellem Sensor

In folgendem Unterkapitel wird ein Fusionsverfahren vorgestellt, das auf zweidimensionalen Verteilungsfunktionen basiert. Im Gegensatz zu in Kapitel 4.4.2 und 4.4.3 vorgestellten Verfahren müssen hierbei die Sensoren nicht zur gleichen Achse ausgerichtet werden. Die Scanebenen der Sensoren müssen jedoch weiterhin parallel sein. Ein weiterer Vorteil dieses Verfahrens ist, dass es nicht auf zwei Sensoren beschränkt ist und auf eine beliebige Anzahl an Sensoren erweitert werden kann. Das Grundprinzip der Fusion mit virtuellem Sensor basiert darauf, dass für jeden Sensor die Umgebung in ein Raster diskretisiert und jeder Messpunkt mit einem Verteilungsmodell (siehe Abbildung 53) eingetragen wird. Dadurch entstehen am Beispiel von einem LiDAR- und einem Radar-Scanner zwei Raster $M_{VS,LiDAR}$ und $M_{VS,Radar}$.

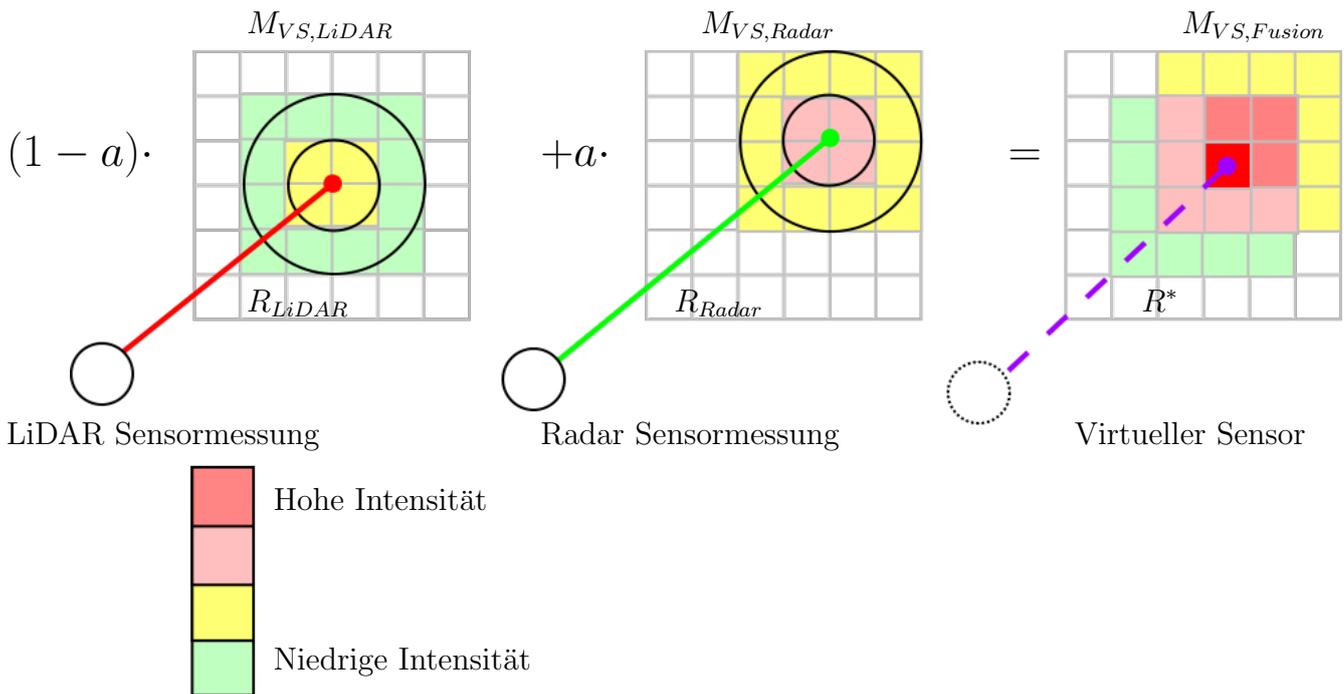


Abbildung 53: Grundprinzip des virtuellen Sensors

Die Raster, die die einzelnen Scans der Sensoren enthalten, werden in jedem Fusionstakt zu $M_{VS,Fusion}$ summiert. Die Gewichtung der einzelnen Raster kann per Parameter a eingestellt werden⁷⁰.

$$M_{VS,Fusion} = (1 - a) \cdot M_{VS,LiDAR} + a \cdot M_{VS,Radar} \quad a \in [0, 1]. \quad (90)$$

Das Raster $M_{VS,Fusion}$ enthält Verteilungen aller aktuellen Scans und muss wieder in eine Scan-Nachricht überführt werden. Dafür wird in der Fusionsebene ein virtueller Sensor an einer beliebigen Stelle erzeugt, wodurch der virtuelle Sensor durch ein eigenes Koordinatensystem definiert wird. Danach werden für den virtuellen Sensor Messwerte erzeugt, indem vom Scan-Ursprung aus $n_{virtuell}$ virtuelle Messungen $R^* \in M_{VS,Fusion}$ in dem fusioniertem Raster vollzogen werden. Äquivalent zu Radar- bzw. LiDAR-Messprinzipien kann dabei nach dem ersten oder letzten lokalen Maximum

⁷⁰Im Fall von zwei Sensoren ist ein Parameter ausreichend

bzw. nach dem größten globalen Maximum gesucht werden. Das Verfahren wird durch Abbildung 53 verdeutlicht.

In Abbildung 54 wird dargestellt, dass der Parameter a einen Einfluss auf die Behebung des Typ-I-Effektes hat.

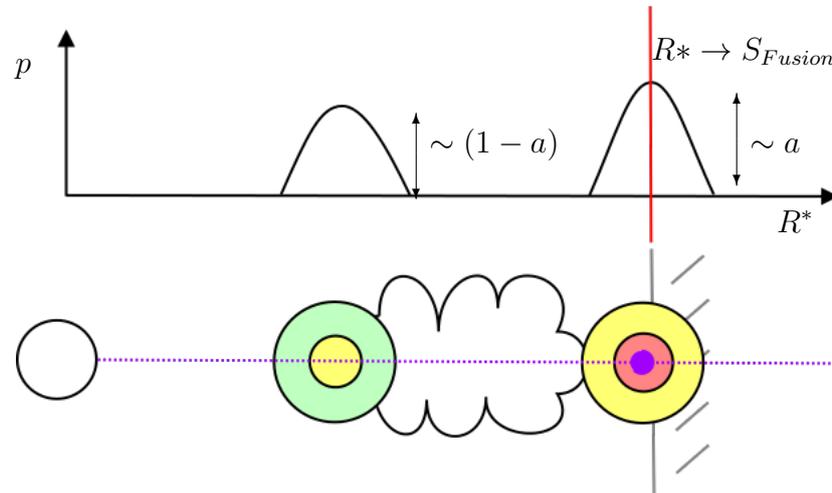


Abbildung 54: Um den Typ-I-Effekt Fall zu beheben, muss die Gewichtung des Radars $M_{VS,Radar}$ größer als vom LiDAR sein und das globale Maximum als Abstandswert verwendet werden.

Der Typ-II-Effekt stellt kein Problem für dieses Fusionsverfahren dar solange $a > 0$ ist. Wenn sich jedoch die Sensoren in einer offenen Umgebung ohne Hindernisse befinden, werden LiDAR Messpunkte die Aerosole detektieren, dem fusionierten Scan zugefügt.

4.5 LiDAR-Radar-Scan-Fusion zur Erzeugung von 3D-Scans

Die in Kapitel 4.4 beschriebenen Verfahren zur Fusionierung von LiDAR- und Radar-Scans lassen sich gleichermaßen auf Sensoren übertragen, die die Umgebung dreidimensional erfassen. 3D-Radar-Scanner sind jedoch zum heutigen Stand der Technik schwer für Experimente zu erhalten. 3D-SAR-Verfahren sind hingegen für die Robotik zu langsam, da die Sensoren mechanisch über eine statische Umgebung verfahren werden müssen. Ein sich schwenkender 2D-Radar-Scanner ist ein weiterer Ansatz, der jedoch aufgrund der langsamen Messraten nicht für den Einsatz auf Fahrzeugen geeignet ist. Zum Beispiel kann der MPR ca. zwei Scans pro Sekunde aufnehmen. Um 16 horizontale Zeilen (im Vergleich zum Velodyne-VLP-16-3D-LiDAR-Scanner) aufzunehmen, vergehen im Idealfall acht Sekunden. In der Abbildung 55a ist eine Version des MPR abgebildet, welche durch eine zusätzliche Schwenkachse 3D-Scans erzeugen kann. In der Abbildung 55b ist ein Experiment (vom FHR durchgeführt) und das dazugehörige Scanbild dieses Scanners zu sehen.

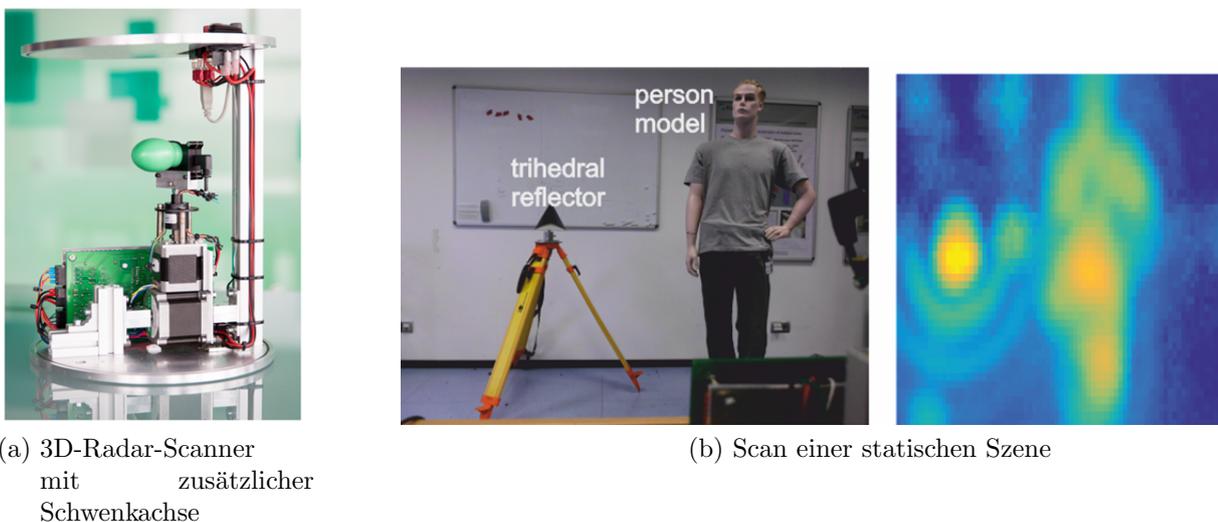


Abbildung 55: Mit einem mechanischen Schwenken eines 2D-Scanners können 3D-Scans erzeugt werden. Zur Erzeugung des Scans in Abbildung 55b werden ca. fünf Minuten benötigt. Das Experiment wurde vom FHR im Rahmen des SmokeBot-Projektes durchgeführt. Quelle: FHR

Aufgrund der langsamen Messraten aktueller 3D-Radar-Scanner, ist eine Fusionierung auf Scan-Ebene nicht praktikabel, da sich der fusionierte Scan aus dem langsamsten Scan ergibt (siehe Abbildung 46, Seite 61).

Im Gegensatz zur 3D-Scan-Fusion ist die Fusionierung von 3D-LiDAR- und 2D-Radar-Scans für praxistaugliche Anwendungen geeignet, indem 3D-Scans konservativ gefiltert werden (einzelne Messungen werden gelöscht). Durch die Filterung entsteht der Scan $S_{LiDAR,3D}^*$. Für dieses Verfahren müssen die Rotationsachsen beider Sensoren übereinstimmen. Die konservative Filterung filtert vertikal alle LiDAR-Messpunkte, wenn sich im fusionierten Scan ein Radarmesspunkt befindet. Der Ablauf der Filterung ist in Abbildung 56 dargestellt.

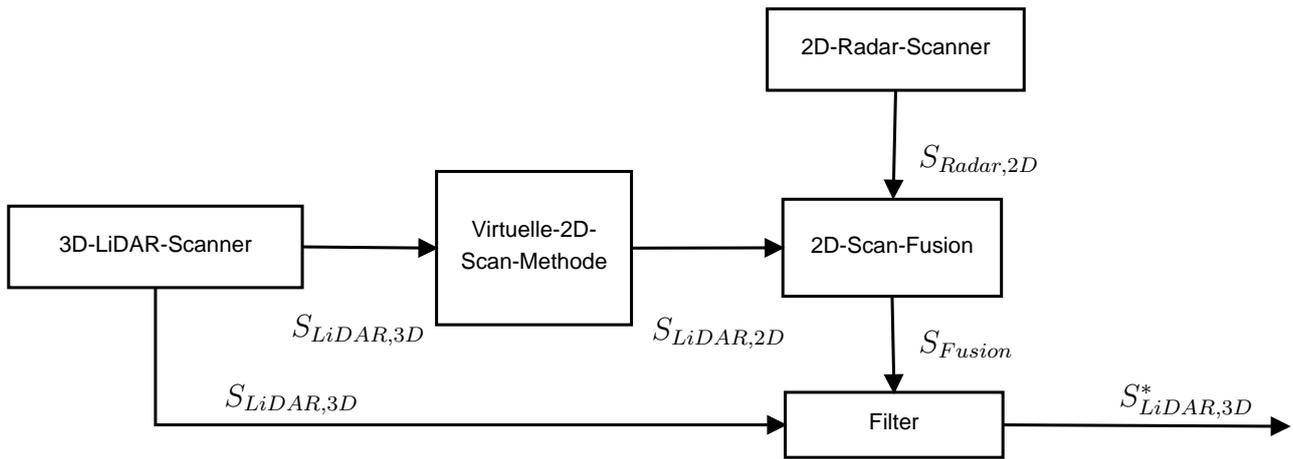


Abbildung 56: Integration von 3D-LiDAR- und 2D-Radar-Scans zur Filterung eines 3D-LiDAR-Scans.

Zur Verdeutlichung ist in Abbildung 57a ein Scan $S_{LiDAR,3D}$ dargestellt, in dem der Einfluss von Nebel mit einem Kreis markiert ist. In Abbildung 57b ist zu erkennen, dass die betroffenen Scan-Punkte gelöscht wurden.

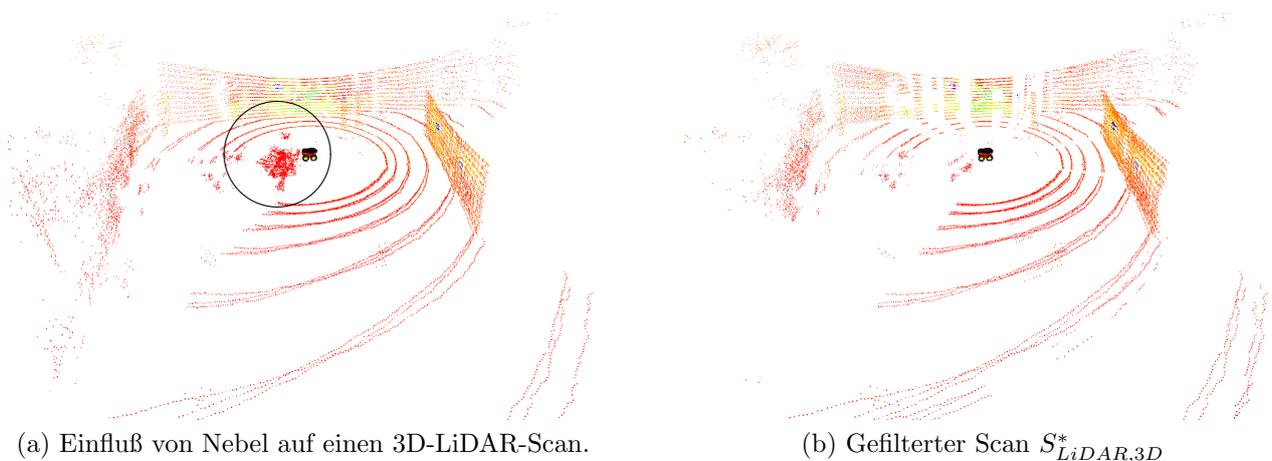


Abbildung 57: Filterung von 3D-Scans mittels Radarinformation

5 Verfahren zur Erstellung von metrischen Umgebungsmodellen und Aerosolverteilungen

In Kapitel 4 sind drei LiDAR-Radar-Fusionsverfahren beschrieben, mit denen fusionierte Scans (S_{Fusion}) erzeugt werden können. Das folgende Kapitel stellt Verfahren vor, die mit diesen fusionierten Scans eine Rasterkarte während der Roboternavigation erzeugen können (Kapitel 5.1). Im Gegensatz dazu ist in Kapitel 5.2 erklärt, wie mit Radar-Scannern ein landmarkenbasiertes SLAM-Verfahren realisiert wird. Die somit gewonnene korrigierte Roboterposition lässt sich wiederum für die Rasterkartierung verwenden. Neben der metrischen Repräsentation der Umgebung ist in Kapitel 5.3 ein Verfahren dargelegt, das die Verteilung von Aerosolen parallel zur Kartierung abbildet. Dafür werden Aerosolkonzentrationen mit dem LRR-Wert⁷¹ abgeschätzt. Der Zusammenhang der vorgestellten Funktionen ist in Abbildung 58 dargestellt.

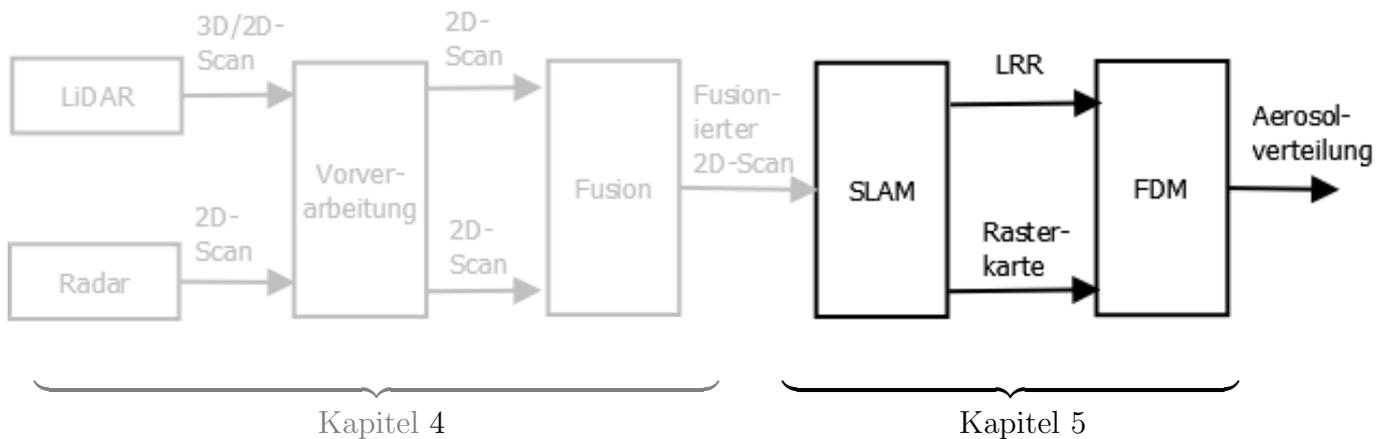


Abbildung 58: Die fusionierten Scans bilden die Grundlage für das Erstellen von Rasterkarten und der Modellierung von Aerosolverteilungen.

⁷¹Der LiDAR-Radar-Ratio (LRR) repräsentiert den Anteil an Radar-Messwerten R_{Radar} im fusionierten Scan S_{Fusion} .

5.1 2D-SLAM mit fusionierten 2D-Scans

LiDAR-Scanner eignen sich aufgrund der hohen Messgenauigkeit für SLAM-Ansätze, die auf der Registrierung einzelner Scans basieren. Holz [HB10] beschreibt, dass sich bereits mit dem ICP-Verfahren⁷² ohne Hinzunahme von Odometrie-Information des Roboters ein SLAM-Ansatz realisieren lässt. Dafür eignen sich drei Herangehensweisen.

- Registrierung aufeinanderfolgender Scans.
- Registrierung des aktuellen Scans mit der Summe aller Scans.
- Registrierung des aktuellen Scans mit der aktuellen globale Karte.

Die Registrierung aufeinanderfolgender Scans hat den Nachteil, dass der Drift-Fehler von jeder Registrierung aufsummiert wird, wodurch die geschätzte Roboterposition ungenau wird. Wenn der aktuelle Scan mit allen aufgenommenen Messpunkten registriert wird, verbessert sich die resultierende Karte, jedoch steigt somit die Anzahl der Punkte, mit denen der ICP berechnet werden muss. In diesem Fall sind viele Punkte redundant. Holz [HB10] speichert aus diesem Grund nur neue Messpunkte ab, wenn sie einen Mindestabstand zu einem bereits gespeicherten Wert haben. Ein ähnlicher Effekt wird erzielt, wenn die Messpunkte in eine Rasterkarte eingetragen werden. Mit dieser Herangehensweise kann zusätzlich die Auftrittswahrscheinlichkeit eines Hindernisses gespeichert und gleichzeitig falsche Messungen wieder gelöscht werden. Die Grundlagen von Rasterkarten und deren Erstellung mit einem inversen Sensormodell sind in Kapitel 3.2 erörtert. In folgendem Kapitel wird ein SLAM-Verfahren vorgestellt, das auf ICP-Registrierungen zwischen dem aktuellen fusionierten Scan S_{Fusion} und den belegten Zellen einer erweiterten Rasterkarte basiert (siehe Abbildung 59). Dabei besteht diese Rasterkarte aus weiteren Layern, in denen die Zusammensetzung des Scans und die Blickwinkel zum Sensor gespeichert und bei der ICP-Registrierung (Kapitel 5.1.3) berücksichtigt werden. Weiterhin wird die Positionsschätzung des Roboters mit einem Kalman-Filter stabilisiert.

⁷²Engl. Iterative Closest Point (ICP), ist ein Verfahren zum Anpassen zweier Punktwolken mit der Transformation T_{ICP} .

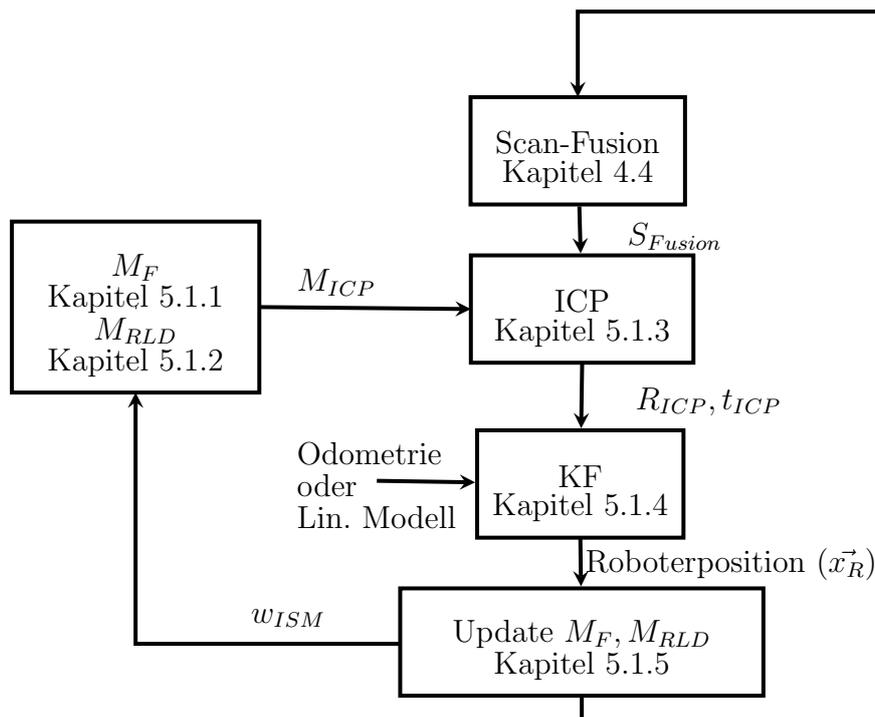


Abbildung 59: Ablauf des SLAM-Zyklus basierend auf Scan-zu-Karte Registrierungen.

Die Translation t_{ICP} und Rotation R_{ICP} zwischen Scan S_{Fusion} und der ICP-Karte M_{ICP} wird mit einem Kalman-Filter (KF) wahlweise mit einem allgemeinen Bewegungsmodell oder mit dem Bewegungsmodell des Roboters fusioniert. Die ICP-Karte ergibt sich aus der Schnittmenge von der RLD⁷³-Karte M_{RLD} (Kapitel 5.1.1) und der Fusionskarte M_F (Kapitel 5.1.2)

$$M_{ICP} = M_F \cap M_{RLD}. \quad (91)$$

Die RLD-Karte ist eine globale Rasterkarte, die sich dynamisch in Abhängigkeit der Position des Roboters verändert und beinhaltet nur belegte bzw. unbelegte Zellen, die zu einem früheren Zeitpunkt von dem Blickwinkel der aktuellen Roboterposition gesehen wurden. Dadurch wird verhindert, dass der aktuelle Scan S_{Fusion} nicht mit Zellen registriert wird, die geometrisch bedingt nicht aus der aktuellen Position des Roboters gesehen werden können. Die Fusionskarte M_F beinhaltet die Information, ob eine Zelle von einem Radar, LiDAR oder fusioniertem Messpunkt getroffen wurde, was bei der Datenzuordnung zwischen fusioniertem Scan und Karte berücksichtigt wird. Der Ablauf des Verfahrens ist in der Abbildung 59 dargestellt.

⁷³Engl. Robot Location Dependant (RLD)

5.1.1 Die Fusionskarte M_F

Die Fusionskarte besteht aus drei Layern (M_{LiDAR} , M_{Radar} , M_{Fusion}), die den Fusionsfällen in Gleichung 89 (Seite 69) entsprechen. Somit werden im Layer M_{LiDAR} Distanzmessungen R_{LiDAR} des fusionierten Scans gespeichert. M_{Radar} und M_{Fusion} werden äquivalent erzeugt und in M_F zusammengefasst

$$M_F = [M_{LiDAR}, M_{Radar}, M_{Fusion}]. \quad (92)$$

M_F wird in jedem SLAM-Zyklus aktualisiert. Die Karte M_{ICP} , die für die Registrierung genutzt wird, ergibt sich mit der Robot-Location-Dependant-Karte M_{RLD} folgendermaßen:

$$M_{ICP} = [M_{LiDAR} \cap M_{RLD}, M_{Radar} \cap M_{RLD}, M_{Fusion} \cap M_{RLD}] \quad (93)$$

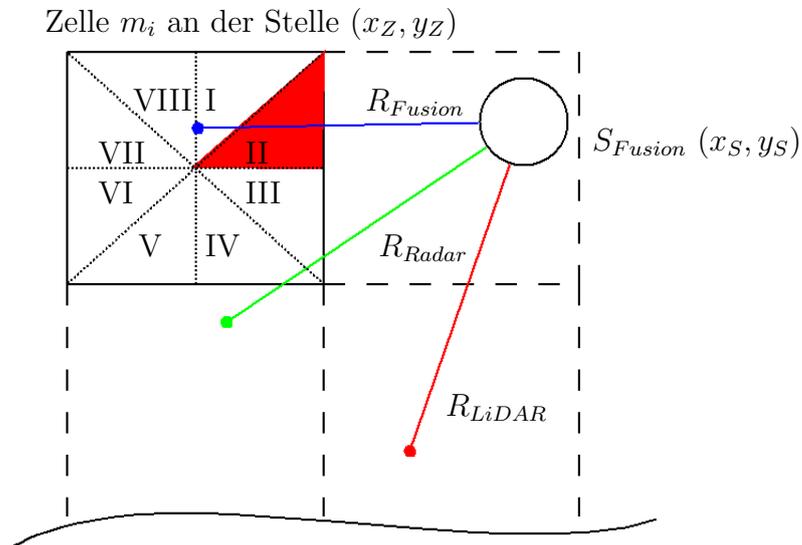
$$M_{ICP} = [M_{ICP,LiDAR}, M_{ICP,Radar}, M_{ICP,Fusion}] \quad (94)$$

5.1.2 Die Robot-Location-Dependant-Karte M_{RLD}

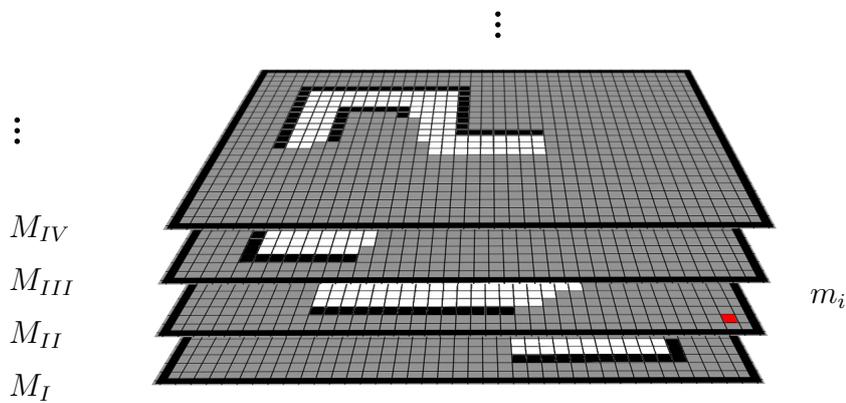
Das ICP-Verfahren hat den Nachteil, dass ein Scan auch zu einem falschen lokalen Minimum tendieren kann, wodurch im ungünstigsten Fall das SLAM-Verfahren fehlschlägt. Um dieses Problem zu reduzieren, wird in dieser Arbeit die RLD-Karte vorgeschlagen, welche nur Messwerte enthält, die von der aktuellen Roboterposition sichtbar sein können. Für jede Zelle m_i werden acht Blickwinkel BW definiert, von denen sie gesehen werden kann. Der Blickwinkel jeder Zelle wird jeweils mit der Positionen der Zelle x_Z und y_Z und der Position des Sensors x_S und y_S ermittelt

$$BW = \begin{cases} I, falls & x_Z > x_S \wedge y_Z > y_S \wedge |y_Z - y_S| > |x_Z - x_S| \\ II, falls & x_Z > x_S \wedge y_Z > y_S \wedge |y_Z - y_S| \leq |x_Z - x_S| \\ III, falls & x_Z > x_S \wedge y_Z \leq y_S \wedge |y_Z - y_S| \leq |x_Z - x_S| \\ IV, falls & x_Z > x_S \wedge y_Z \leq y_S \wedge |y_Z - y_S| > |x_Z - x_S| \\ V, falls & x_Z < x_S \wedge y_Z \leq y_S \wedge |y_Z - y_S| > |x_Z - x_S| \\ VI, falls & x_Z < x_S \wedge y_Z \leq y_S \wedge |y_Z - y_S| \leq |x_Z - x_S| \\ VII, falls & x_Z < x_S \wedge y_Z > y_S \wedge |y_Z - y_S| \leq |x_Z - x_S| \\ VIII, falls & x_Z < x_S \wedge y_Z > y_S \wedge |y_Z - y_S| > |x_Z - x_S| \end{cases} . \quad (95)$$

In jedem SLAM-Zyklus wird der Scan in Abhängigkeit des Blickwinkels in acht separate Layer eingetragen. Gemäß der Position des Sensors wird eine Zelle von einem Blickwinkel aus detektiert und in den entsprechenden Layer der Karte M_{BW} eingetragen (Abbildung 60).



(a) Einteilung einer Zelle in acht Blickwinkel. In dem angedeuteten Fall wird die Zelle vom Blickwinkel II detektiert und dementsprechend in M_{II} eingetragen.



(b) Zusammensetzung von M_{BW}

Abbildung 60: Darstellung der Abspeicherung jedes Blickwinkels in einem eigenen Layer in der Karte M_{BW}

$M_{BW} = [M_I, M_{II}, \dots, M_{VIII}]$ beinhaltet acht Layer, die die Wahrscheinlichkeiten für die Belegung bezüglich der Blickwinkel beinhalten. Das Eintragen in die einzelnen Layer wird zusätzlich durch den Faktor w_{ISM} gewichtet, dessen Hintergrund in Kapitel 5.1.5 näher beschrieben wird. Somit ist eine Zelle m_i durch ihre Position x_z, y_z , der Objektwahrscheinlichkeit $p(m_i)$, dem Fusionstyp (LiDAR, Radar oder Fusion) und ihre m Blickwinkel BW_{m_i} definiert.

M_g ist die global Karte die sich aus der Vereinigungsmenge von M_F ergibt. Sie entspricht einer klassischen Rasterkarte die alle Informationen enthält:

$$M_g = M_{LiDAR} \cup M_{Radar} \cup M_{Fusion}. \quad (96)$$

Um M_{RLD} zu erhalten wird verglichen, ob für jeden Blickwinkel BW jeder belegten Zelle in M_g eine belegte Zelle in dem entsprechenden Layer von M_{BW} existiert (siehe Abbildung 60).

Das Verfahren ist im Pseudocode 1 dargestellt.

```

Data:  $M_g, M_{BW}, x_R$ 
Result:  $M_{RLD}$ 
/* Gehe über alle belegten Zellen in  $M_g$  */
foreach  $p(m_{g,i}) > 0.7$  do
    /* Berechne die Blickwinkel für die belegten Zellen in  $M_g$  mit der
       aktuelle Position  $x_R$  */
     $BW(m_{g,i})$ 
    /* Überprüfe ob die Zelle  $m_{BW,i}$  des Layers  $BW(m_{g,i})$  in  $M_{BW}$  belegt ist
       */
    if  $p(m_{BW,i}(BW(m_{g,i}))) > 0.7$  then
        /* Falls diese Zelle bereits von dem aktuellen Blickwinkel gesehen
           wurde, dann füge sie zur RLD-Map hinzu */
        add  $m_{g,i}$  to  $M_{RLD}$ 
    end
end
    
```

Pseudocode 1: Berechnung der RLD-Map. In dem Beispiel ist der Schwellwert für eine belegte Zelle bei $p(m_i) = 0.7$.

5.1.3 Eine Variation des klassischen ICP-Algorithmus

Der ICP-Algorithmus ist ein Standardverfahren um Punktwolken durch eine Transformation T_{ICP} aufeinander abzubilden, indem der Abstand zueinander iterativ minimiert wird. In der Literatur wird häufig die Punktwolke, die fest verankert bleibt, als Targetcloud⁷⁴ l bezeichnet und die Punktwolke, die transformiert wird, als Sourcecloud⁷⁵ r . Die Punktwolken l und r müssen jedoch zuerst bestimmt werden. Der klassische ICP sucht dafür für jeden Punkt aus SC den nächsten Nachbarn in TC. Danach wird die Gleichung 97 gelöst und die ermittelte Transformation auf SC angewandt. Im Anschluss werden erneut die nächsten Nachbarn zwischen der neuen Position von der SC und der TC ermittelt. Dies geschieht in jedem Iterationsschritt j . Der hier vorgeschlagene ICP-Algorithmus sucht die nächsten Nachbarn mit übereinstimmenden Fusionsfall. Die Grundidee ist in der Abbildung

⁷⁴Engl. Targetcloud (TC)

⁷⁵Engl. Sourcecloud (SC)

61 dargestellt

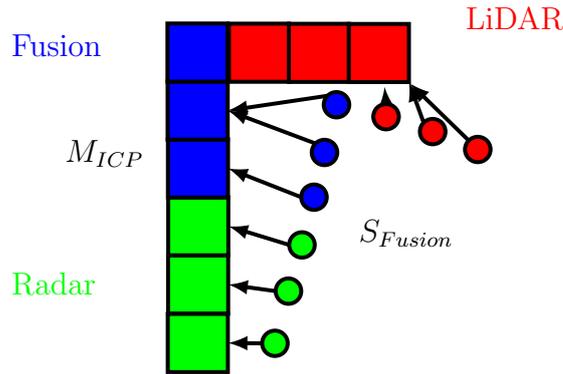


Abbildung 61: Bei der Suche des nächsten Nachbarn jedes Scan-Punktes in S_{Fusion} werden nur Zellen in der Karte M_{ICP} mit übereinstimmenden Fusionsfall betrachtet.

$$R_j l_j + t_j = r_j \quad (97)$$

$$r = (r_x, r_y)^T \quad l = (l_x, l_y)^T. \quad (98)$$

Der ICP-Algorithmus basiert auf der Minimierung der Fehlerquadrate der Abstände zwischen TC und SC. Somit wird für jede Iteration eine Rotation R_j und Translation t_j ermittelt, die die Gesamttransformation T_{ICP} ergibt

$$T_{ICP} = \prod_j T_j, \quad T_j = \begin{pmatrix} R_j & |t_j \\ 0 & |1 \end{pmatrix}. \quad (99)$$

Die Punktwolken SC und TC werden mit einer Nächster-Nachbar-Suche⁷⁶ ermittelt, die mit einem Distanzschwellwert d_{NN} begrenzt ist. Der Distanzschwellwert sorgt dafür, dass keine Punktpaare aus SC und TC zueinander zugeordnet werden die zu weit voneinander entfernt liegen. An dieser Stelle befindet sich die Variation, der in dieser Arbeit vorgestellten ICP-Variante. Anstelle, dass für jeden Punkt in SC per NN-Suche ein korrespondierender Punkt in TC gesucht wird, wird zusätzlich zwischen den Fällen *Fusion*, *Radar* und *LiDAR* unterschieden. Dafür wird in Abhängigkeit des Fusionsfalles jedes Scan-Punktes $(R_{LiDAR}, R_{Radar}, R_{Fusion})$ der nächste Nachbar in $M_{ICP,LiDAR}$, $M_{ICP,Radar}$ oder $M_{ICP,Fusion}$ gesucht. Jede NN-Suche ist weiterhin mit einem Distanzschwellwert d_{NN} begrenzt. Wenn die Distanz eines nächsten Nachbarn größer als d_{NN} ist, dann werden die Punkte verworfen. Dadurch entstehen zwei Punktwolken l und r mit der Punktzahl N .

Zur Lösung der Gleichung 97 werden zunächst die Mittelwerte \bar{l} und \bar{r} von SC und TC und die

⁷⁶Nächster-Nachbar (NN)

reduzierten Koordinaten l' und r' für jeden Punkt berechnet:

$$\bar{l} = \frac{1}{N} \sum l_i \quad \bar{r} = \frac{1}{N} \sum r_i \quad (100)$$

$$l'_i = l_i - \bar{l} \quad r'_i = r_i - \bar{r}. \quad (101)$$

Danach werden die Summen der Cosinus- und Sinus-Beziehungen ermittelt:

$$cs = \sum_{i=0}^N (r'_{x,i} l'_{x,i} + r'_{y,i} l'_{y,i}) \quad (102)$$

$$ss = \sum_{i=0}^N (-r'_{x,i} l'_{y,i} + r'_{y,i} l'_{x,i}) \quad (103)$$

$$rr = \sum_{i=0}^N (r'_{x,i} r'_{x,i} + r'_{y,i} r'_{y,i}) \quad (104)$$

$$ll = \sum_{i=0}^N (-l'_{x,i} l'_{x,i} + l'_{y,i} l'_{y,i}). \quad (105)$$

Schließlich kann die Rotation mit $\tan(\alpha) = \frac{\sin(\alpha)}{\cos(\alpha)}$ berechnet werden:

$$\begin{pmatrix} \cos(\alpha) \\ \sin(\alpha) \end{pmatrix} = \frac{\begin{pmatrix} cs \\ ss \end{pmatrix}}{\sqrt{cs^2 + ss^2}}. \quad (106)$$

Die Berechnung der Translation ergibt sich folgendermaßen:

$$\begin{pmatrix} t_x \\ t_y \end{pmatrix} = \begin{pmatrix} \bar{r}_x \\ \bar{r}_y \end{pmatrix} - \sqrt{\frac{rr}{ll}} \begin{pmatrix} \cos(\alpha) & -\sin(\alpha) \\ \sin(\alpha) & \cos(\alpha) \end{pmatrix} \begin{pmatrix} \bar{l}_x \\ \bar{l}_y \end{pmatrix}. \quad (107)$$

Der Grad der Annäherung kann mit den quadratischen Abständen zusammengehöriger Punkte aus TC und SC definiert werden

$$E = \frac{1}{N} \sum_i \sqrt{(r_{x,i} - l_{x,i})^2 + (r_{y,i} - l_{y,i})^2}. \quad (108)$$

Kleine Rotationen führen bei Punkten, die weiter vom Rotationspunkt entfernt sind, zu einem größeren Fehler. Gewöhnlicherweise wird die Anzahl der Iterationen festgelegt oder abgebrochen, wenn der Fehler E einen Grenzwert unterschreitet.

Der gesamte Ablauf des variierten ICP-Verfahrens ist in der Abbildung 62 dargestellt.

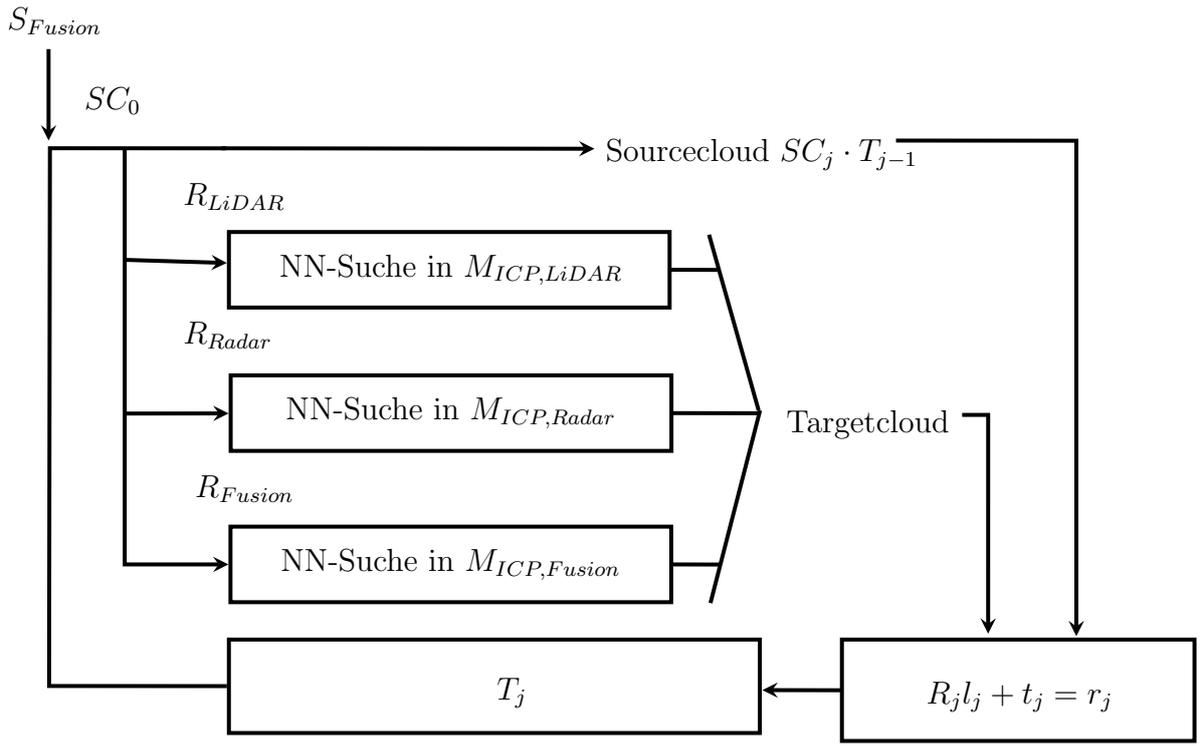


Abbildung 62: Das ICP-Verfahren unterscheidet bei der Suche der zugehörigen Punkte die Fusionsfälle.

5.1.4 Filterung der Positionsschätzung

Mit dem variierten ICP-Verfahren aus Kapitel 5.1.3 kann bereits ein einfaches SLAM-Verfahren mit dem fusionierten Scan implementiert und somit der Zustand des Roboters $x_{R,t} = (x_R, y_R, \Theta)_t^T$ bestimmt werden. Der somit berechnete Pfad ist jedoch sprunghaft, wodurch der SLAM-Zyklus nicht robust verläuft

$$\begin{pmatrix} x_R \\ y_R \\ 1 \end{pmatrix}_t = T_{ICP,t} \cdot \begin{pmatrix} x_R \\ y_R \\ 1 \end{pmatrix}_{t-1} \tag{109}$$

$$\Theta_t = \Theta_{t-1} + \alpha. \tag{110}$$

Um die Robustheit zu erhöhen, kann die Positionsschätzung durch den ICP-Algorithmus entweder mit der Roboterodometrie oder einem allgemeinem Bewegungsmodell fusioniert werden.

Ein Verfahren zur Glättung von verrauschten Sensordaten ist der Kalman-Filter, der zum Beispiel beim Tracking von Objekten angewendet werden kann. Hier wird vorgestellt, den Roboter in einer Karte zu tracken. Der Takt des Kalman-Filters Δt richtet sich dabei nach dem Fusionszyklus der Scan-Fusion. Wenn der hier vorgestellte SLAM-Ansatz auf einer Plattform ohne Odometriedaten angewendet werden soll, dann wird in jedem SLAM-Zyklus die Position durch den ICP-Algorithmus mit einem allgemeinen linearen Bewegungsmodell ($x_t = x_{t-1} + \dot{x}_{t-1}\Delta t + 0.5\ddot{x}\Delta t^2$) fusioniert.

Für die Implementierung des allgemeinen Bewegungsmodells werden zusätzlich die Geschwindigkeiten mit in den Zustandsvektor aufgenommen

$$\vec{x}_{R,t} = (x_t, y_t, \Theta_t, \dot{x}_t, \dot{y}_t, \dot{\Theta}_t)^T. \quad (111)$$

Dementsprechend hat die Kovarianzmatrix Σ des Zustandes die Dimension 6×6

$$\Sigma_t = \begin{pmatrix} \sigma_{x_t, x_t} & \sigma_{x_t, y_t} & \sigma_{x_t, \Theta_t} & \sigma_{x_t, \dot{x}_t} & \sigma_{x_t, \dot{y}_t} & \sigma_{x_t, \dot{\Theta}_t} \\ \sigma_{y_t, x_t} & \sigma_{y_t, y_t} & \sigma_{y_t, \Theta_t} & \sigma_{y_t, \dot{x}_t} & \sigma_{y_t, \dot{y}_t} & \sigma_{y_t, \dot{\Theta}_t} \\ \sigma_{\Theta_t, x_t} & \sigma_{\Theta_t, y_t} & \sigma_{\Theta_t, \Theta_t} & \sigma_{\Theta_t, \dot{x}_t} & \sigma_{\Theta_t, \dot{y}_t} & \sigma_{\Theta_t, \dot{\Theta}_t} \\ \sigma_{\dot{x}_t, x_t} & \sigma_{\dot{x}_t, y_t} & \sigma_{\dot{x}_t, \Theta_t} & \sigma_{\dot{x}_t, \dot{x}_t} & \sigma_{\dot{x}_t, \dot{y}_t} & \sigma_{\dot{x}_t, \dot{\Theta}_t} \\ \sigma_{\dot{y}_t, x_t} & \sigma_{\dot{y}_t, y_t} & \sigma_{\dot{y}_t, \Theta_t} & \sigma_{\dot{y}_t, \dot{x}_t} & \sigma_{\dot{y}_t, \dot{y}_t} & \sigma_{\dot{y}_t, \dot{\Theta}_t} \\ \sigma_{\dot{\Theta}_t, x_t} & \sigma_{\dot{\Theta}_t, y_t} & \sigma_{\dot{\Theta}_t, \Theta_t} & \sigma_{\dot{\Theta}_t, \dot{x}_t} & \sigma_{\dot{\Theta}_t, \dot{y}_t} & \sigma_{\dot{\Theta}_t, \dot{\Theta}_t} \end{pmatrix}. \quad (112)$$

Die Schätzung des Zustandes \vec{x}_R erfolgt mit dem linearen Modell. Die Beschleunigungen werden durch den Fehler err modelliert

$$A_t = \begin{pmatrix} 1 & 0 & 0 & \Delta t & 0 & 0 \\ 0 & 1 & 0 & 0 & \Delta t & 0 \\ 0 & 0 & 1 & 0 & 0 & \Delta t \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{pmatrix} \quad (113)$$

$$err_t = \left(\frac{1}{2} \cdot a_x \Delta t^2, \frac{1}{2} \cdot a_y \Delta t^2, \frac{1}{2} \cdot a_\theta \Delta t^2, a_x \Delta t, a_y \Delta t, a_\theta \Delta t \right)^T \quad (114)$$

$$\vec{x}_{R,t} = A_t \vec{x}_{R,t-1} + err_t. \quad (115)$$

Die Kovarianzmatrix der Schätzung $\bar{\Sigma}_t$ wird folgendermaßen berechnet:

$$\bar{\Sigma}_t = A_t \bar{\Sigma}_{t-1} A_t^T + R_t. \quad (116)$$

Die Berechnung von R_t ergibt sich folgendermaßen:

$$R_t = \frac{\partial err_t}{\partial a} \Sigma_a \frac{\partial err_t}{\partial a}^T = \begin{pmatrix} \frac{1}{4}\Delta t^4 \sigma_x^2 & 0 & 0 & \frac{1}{2}\Delta t^3 \sigma_x^2 & 0 & 0 \\ 0 & \frac{1}{4}\Delta t^4 \sigma_y^2 & 0 & 0 & \frac{1}{2}\Delta t^3 \sigma_y^2 & 0 \\ 0 & 0 & \frac{1}{4}\Delta t^4 \sigma_\Theta^2 & 0 & 0 & \frac{1}{2}\Delta t^3 \sigma_\Theta^2 \\ \frac{1}{2}\Delta t^3 \sigma_x^2 & 0 & 0 & \Delta t^2 \sigma_x^2 & 0 & 0 \\ 0 & \frac{1}{2}\Delta t^3 \sigma_y^2 & 0 & 0 & \Delta t^2 \sigma_y^2 & 0 \\ 0 & 0 & \frac{1}{2}\Delta t^3 \sigma_\Theta^2 & 0 & 0 & \Delta t^2 \sigma_\Theta^2 \end{pmatrix}. \quad (117)$$

Die Kovarianzmatrix der Beschleunigungen $a = (a_x, a_y, a_\Theta)$ ist normalerweise parametrierbar:

$$\Sigma_a = \begin{pmatrix} \sigma_{a_x}^2 & 0 & 0 \\ 0 & \sigma_{a_y}^2 & 0 \\ 0 & 0 & \sigma_{a_\Theta}^2 \end{pmatrix}. \quad (118)$$

Für die Korrektur des geschätzten Roboterzustandes $\vec{x}_{R,t}$ wird zunächst aus der geschätzten Kovarianz $\bar{\Sigma}$ und der parametrisierbaren Kovarianz für den Messfehler aus der Registrierung Q die Kalman Verstärkungsmatrix K berechnet

$$C = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \end{pmatrix} \quad (119)$$

$$Q = \begin{pmatrix} \sigma_{x,icp}^2 & 0 & 0 \\ 0 & \sigma_{y,icp}^2 & 0 \\ 0 & 0 & \sigma_{\Theta,icp}^2 \end{pmatrix} \quad (120)$$

$$K = \frac{\bar{\Sigma}_t C^T}{C \bar{\Sigma}_t C^T + Q}. \quad (121)$$

Danach kann mit dem Kalmanverstärkung K und der Messung $mess_t = (t_x, t_y, \alpha)$ (aus T_{ICP}), die sich aus der Registrierung des Scans S_{Fusion} mit M_{ICP} ergibt, der Roboterzustand $\vec{x}_{R,t}$ und die Kovarianzmatrix Σ_t zum aktuellen Zeitpunkt berechnet werden:

$$\vec{z}_{mess} = C \vec{x}_{R,t} + mess_t \quad (122)$$

$$\vec{x}_{R,t} = \vec{x}_{R,t} + K(\vec{z}_{mess,t} - C \vec{x}_{R,t}) \quad (123)$$

$$\Sigma_t = (I - KC) \bar{\Sigma}_t. \quad (124)$$

5.1.5 Gewichtetes inverses Sensormodell

Der vorgestellte SLAM-Algorithmus verläuft fehlerhaft, wenn der ICP-Algorithmus zu einem lokalen Minimum konvergiert. Dieser Fall führt zu einer falschen Ausrichtung zwischen S_{Fusion} und M_{ICP} . Um eine falsche Registrierung zu detektieren, kann zum einen der Fehler E einer ICP-Registrierung als Kriterium genutzt werden. Zum anderen haben falsche Registrierungen die Eigenschaft, dass sie zu einem sprunghaften Verlauf des Zustandsvektors x_R führen. Daher wird hier der Gewichtungsfaktor $w_{ISM} \in [0, 1]$ für das inverse Sensormodell definiert, um in stabilen Zuständen die Zellen mit einer höheren Gewichtung zu aktualisieren. Im Gegensatz tendiert w_{ISM} gegen 0, wenn der Verlauf des Zustandsvektors sprunghaft verläuft. Die Faktoren a_w und b_w dienen zur Parametrisierung des Einflusses von translatorischer und rotatorischer Bewegung

$$w_{ISM} = \frac{1}{1 + \left(a_w \frac{|x_t - x_{t-1}|}{\Delta t} + a_w \frac{|y_t - y_{t-1}|}{\Delta t} + b_w \frac{|\Theta_t - \Theta_{t-1}|}{\Delta t} \right)}. \quad (125)$$

Danach kann die klassische Formel des inversen Sensormodells mit der Gewichtung w_{ISM} erweitert werden

$$l_{t,i} = \log \frac{w \cdot p(m_i | z_t, x_t)}{1 - w \cdot p(m_i | z_t, x_t)} + l_{t-1,i} - l_0 \quad (126)$$

$$p(m_i | z_{1:t}, x_{1:t}) = 1 - \frac{1}{1 + \exp^{l_{t,i}}}. \quad (127)$$

Das gewichtete inverse Sensormodell ist in der Abbildung 63 dargestellt.

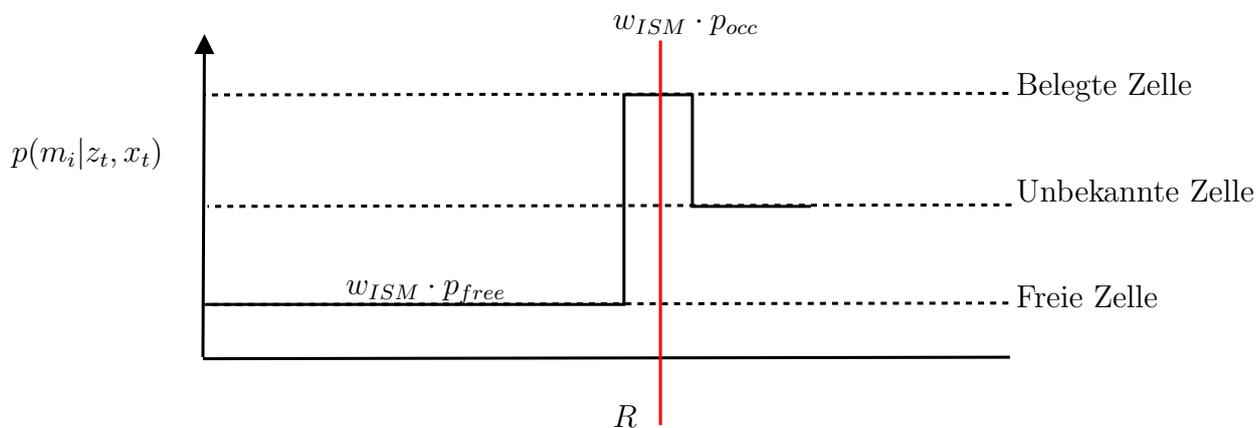


Abbildung 63: Der Gewichtungsfaktor w_{ISM} beeinflusst die Wahrscheinlichkeiten p_{occ} und p_{free} .

5.2 Landmarkenbasierte SLAM-Ansätze mit Radar- und LiDAR-Scannern

In diesem Unterkapitel wird auf ein Verfahren eingegangen, mit dem in Umgebungen mit gestörter Sicht eine Landmarkenkarte erstellt werden kann. Um eine Landmarkenkarte zu erstellen, müssen mit den externen Sensoren eines Roboters Landmarken detektiert werden.

5.2.1 Landmarkenextraktion mit 2D-Radar-Scannern

In Abbildung 64 ist zu erkennen, dass es bei Ecken und Kanten zu sichelförmigen Verwischungen im Scanbild des Radar-Scanners kommt. Diese Verwischungen werden größer, je größer der Radarquerschnitt eines Objektes σ , je stärker die Sendeleistung P_S und je größer der Öffnungswinkel Θ des Radars ist. Die Verwischungen haben den negativen Effekt, dass die Scan-Qualität verschlechtert wird. Jedoch kann dieser Effekt auch zur Extraktion von Landmarken genutzt werden. Bei einem Punktziel wird während des Ein- und Austretens des Objektes in die Hauptkeule immer die gleiche Distanz zum Sensor gemessen. Dadurch entsteht ein Kreisabschnitt (Verwischung). Zusätzlich haben Punktziele die Eigenschaft, dass die detektierte Rückstrahlleistung P_e einen charakteristischen Verlauf aufweist, der anhand eines Beispiels in Abbildung 64b dargestellt ist.

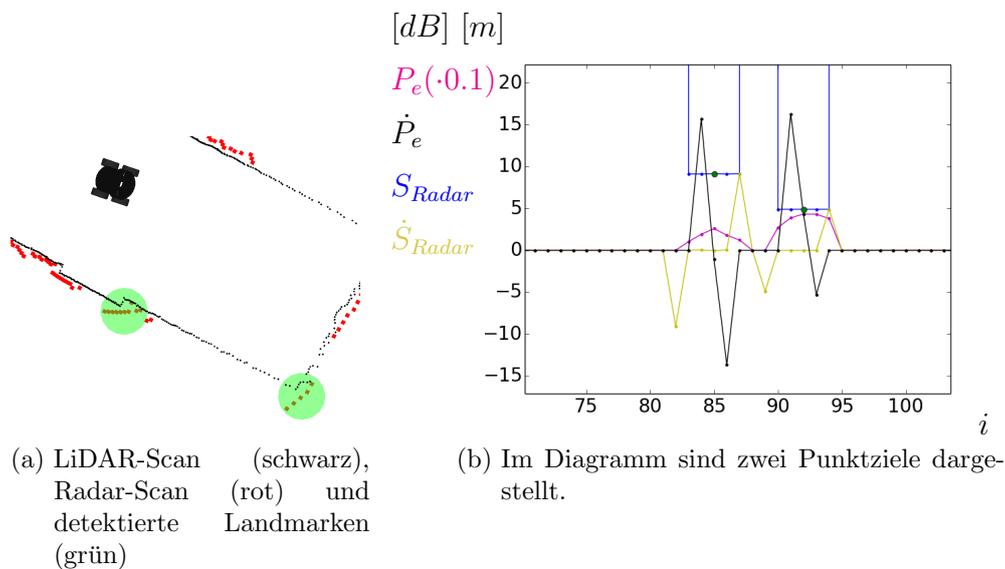


Abbildung 64: Ein Punktziel hinterlässt eine eindeutige Charakteristik in einem Radar-Scan. Die Rückstrahlleistung P_e ist maximal, wenn der Radarsensor direkt auf das Punktziel gerichtet ist. Beim Ein- bzw. Austreten des Punktzieles aus der Hauptkeule Θ entsteht daher ein An- bzw. Absteigen der Rückstrahlleistung. Weiterhin sind die Distanzmessungen $R_{Radar,i}$ konstant, solange das Punktziel detektiert wird.

Folgende Kriterien müssen in einem Algorithmus implementiert werden, um Punktziele zu extrahieren.

- Das Ein- und Austreten eines Punktzieles in die Hauptkeule des Radars wird durch die erste Ableitung des Scans $\dot{S}_{Radar}(i)$ markiert. $\dot{S}_{Radar}(i)$ ist beim Eintritt des Punktzieles negativ und beim Austritt positiv.

- Solang das Punktziel sich in der Hauptkeule befindet, bleibt $S_{Radar}(i)$ konstant, bzw. $\dot{S}_{Radar}(i)$ null.
- Die Rückstrahlleistung P_e nimmt zwischen Eintreten und orthogonaler Ausrichtung der Antenne zum Punktziel kontinuierlich zu, wodurch $\dot{P}_e(i)$ positiv ist. Beim Austreten ist $\dot{P}_e(i)$ negativ.

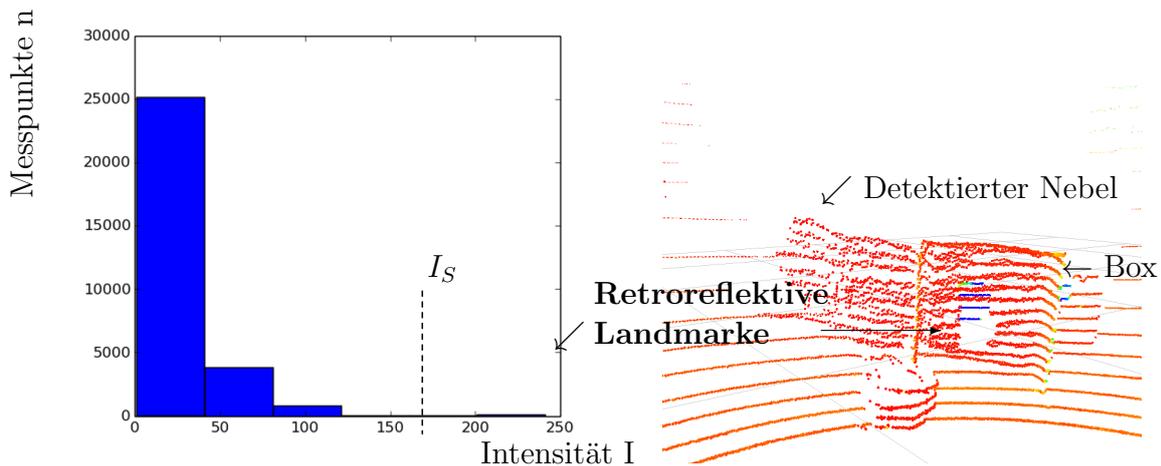
5.2.2 Landmarkenextraktion mit 3D-LiDAR-Scannern

LiDAR-Scanner liefern unter gestörten Sichtbedingungen kaum brauchbare Messwerte, da die vom Objekt zurückgestrahlte Intensität I von Aerosolen absorbiert wird. Jedoch ist die Detektionswahrscheinlichkeit von stärker reflektierenden Objekten höher. Retroreflektive Reflektoren eignen sich daher als künstliche Landmarken, da sie noch erkannt werden können, wenn Aerosole die Messwerte umliegender Objekte beeinträchtigen. Dieser Fall ist in Abbildung 65b dargestellt. Hier kann der retroreflektive Reflektor (blaue Messpunkte) trotz Nebelwolke detektiert werden. In Abbildung 65a ist die Verteilung der Anzahl der Messpunkte des 3D-Scans aus Abbildung 65b in Abhängigkeit der Intensität I dargestellt.

Die Extraktion eines Reflektor kann mit einer einfachen Trennung der LiDAR-Messung auf der Basis der Intensitäten $I = [I_0, I_1, \dots, I_n]$ mittel eines Schwellwertes I_S vollzogen werden. Der Schwellwert I_S ergibt sich durch den Parameter γ zwischen durchschnittlicher Intensität I_\emptyset und Maximalwert I_{max} pro Scan.

$$I_S = I_\emptyset + \gamma(I_{max} - I_\emptyset), \quad \gamma \in [0, 1]. \tag{128}$$

Die Messwerte $S_{LiDAR, I > I_S}$ müssen im Anschluss per Clustering voneinander getrennt werden, um die Position der Landmarken zu erhalten.



(a) Histogrammdarstellung der Verteilung der Intensitätswerte eines 3D-LiDAR-Scans in dem sich eine retroreflektive Marke befindet.
 (b) Retroreflektive Landmarken können trotz Aerosole erkannt werden

Abbildung 65: Bei gestörter Sicht können retroreflektive Landmarken zur Orientierung eingesetzt werden

5.3 Bestimmung und Modellierung von Aerosolverteilungen

Das folgende Kapitel stellt Verfahren vor, mit denen aus fusionierten LiDAR- und Radar-Daten der Grad der gestörten Sicht abgeschätzt werden kann. In Kapitel 4.1 (Seite 55) werden Typ-I- und Typ-II-Effekt beschrieben. Die Effekte sind in den Abbildungen 39 und 40 (Seite 56) verdeutlicht (Typ-I = Detektion von Aerosolpartikeln mit LiDAR, Typ-II = Absorption von LiDAR-Messungen). Mit einer Kombination aus LiDAR und Radar können diese Effekte detektiert werden, sodass eine Aussage über ihre Verteilung getroffen werden kann. Der Typ-I-Effekt kann detektiert werden, indem Messpunkte in den Scan-Nachrichten ermittelt werden, die von gestörter Sicht beeinträchtigt werden. Dadurch ergibt sich die Position von Arealen mit gestörter Sicht im Umfeld des Roboters. Die Konzentration an Aerosolpartikeln in einer Umgebung kann mit einem Verhältnis an Radarmessungen in den fusionierten Scans (LRR) bestimmt werden. Der LRR repräsentiert eine Aerosolkonzentration im aktuellen sensorischen Umfeld. Hier wird vorgeschlagen, die Aerosolverteilung mit einem Finite-Differenzen-Modell zu beschreiben.

5.3.1 Schätzung der Position von gestörter Sicht

Die Detektion des Typ-I-Effektes erfolgt mit einer Heuristik. Die Voraussetzung zur Anwendung des vorgestellten Verfahrens ist, dass LiDAR- und Radar-Scanner zur gleichen Rotationsachse zueinander ausgerichtet und kalibriert sind. Der Typ-I-Effekt kann mit folgender Regel pro Fusionszyklus ermittelt und in einer Scan-Nachricht dargestellt werden

$$\begin{aligned}
 R_{LiDAR} - > S_{Typ-I}, \text{ wenn } R_{LiDAR} - R_{Radar} < -d_F \cap R_{LiDAR} < R_F \\
 & \cap R_{LiDAR} \notin \text{Linie} \\
 & \cap R_{LiDAR} \notin M_{Kostenkarte}.
 \end{aligned} \tag{129}$$

5.3.2 LiDAR-Radar-Ratio (LRR)

In dieser Arbeit wird vorgeschlagen, die Zusammensetzung des fusionierten Scans S_{Fusion} zu nutzen, um den Typ-I- bzw. Typ-II-Effekt mit einem Konzentrationsmaß zu beschreiben. Im Fall der modellbasierten und heuristischen Scan-Fusion besteht ein fusionierter Scan aus LiDAR, Radar und fusionierten Distanzmessungen ($R_{LiDAR}, R_{Radar}, R_{Fusion}$). Die Zusammensetzung des fusionierten Scans kann als Indikator für den Grad der Störung durch Aerosole genutzt werden. Das entsprechende Maß wird in dieser Arbeit als LRR bezeichnet

$$LRR_{Typ-I} = \frac{\sum R_{Radar} \in Typ - I}{\sum R_{LiDAR} + \sum R_{Radar} + \sum R_{Fusion}} \tag{130}$$

$$LRR_{Typ-II} = \frac{\sum R_{Radar} \in Typ - II}{\sum R_{LiDAR} + \sum R_{Radar} + \sum R_{Fusion}}. \tag{131}$$

Die Berechnung des LRR_{Typ-I} , bzw. LRR_{Typ-II} ergibt sich demzufolge aus dem Verhältnis von Radarmessungen, die durch den Typ-I-, bzw. Typ-II-Effekt in der Scan-Fusion verwendet werden.

Der LRR gibt die Stärke der Störung durch Aerosole an (siehe Abbildung 66).

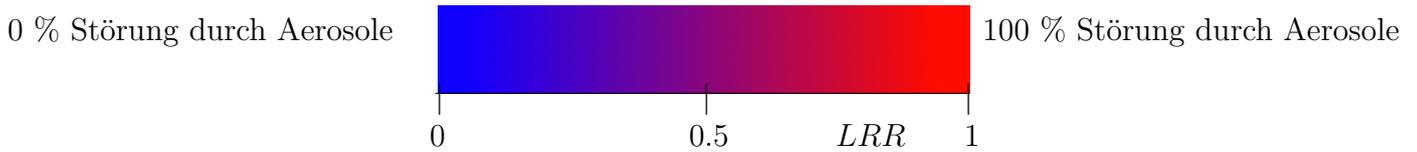


Abbildung 66: Der LRR -Wert beschreibt die Aerosolkonzentration mit einem Wert zwischen 0 (0 % Störung durch Aerosole) und 1 (100 % Störung durch Aerosole).

Die Zusammensetzung des fusionierten Scans S_{Fusion} ist von der Vorverarbeitung, dem Fusionsverfahren und der entsprechenden Parameter abhängig. Zum Beispiel bewirkt die Integration von virtuellen 2D Scans einen geringeren Anteil an Radar-Distanzmessungen im fusionierten Scan. Daraus resultiert jedoch, dass der LRR auch von den genannten Faktoren abhängig ist.

Mit dem virtuellen Sensor ist eine Trennung nach Typ-I und Typ-II nicht mehr möglich. Das LiDAR-Radar-Verhältnis kann ermittelt werden, indem die Anzahl der besetzten Zellen in den Rastern M_{Fusion} und M_{Radar} in ein Verhältnis gesetzt werden

$$LRR = \frac{\sum m_{Radar}(i)}{\sum m_{Fusion}(i)}. \quad (132)$$

5.3.3 Modellierung des LiDAR-Radar-Verhältnisses in zweidimensionalen Umgebungsmodellen

Die Ursachen für diese Störungen werden durch Aerosolpartikel hervorgerufen, deren Verhalten mittels Diffusions- und Konvektionsgesetze beschrieben werden kann (siehe Kapitel 2.3.3, Seite 22).

Zur Modellierung der Aerosolverteilung werden folgende Annahmen getroffen:

- LRR wird in einer zweidimensionalen Rasterkarten M_{LRR} modelliert.
- In abgetrennten Räumen ohne Luftströmungen verteilt sich gestörte Sicht entsprechend des Diffusionsgesetzes gleichmäßig in x- und y-Richtung wenn $t \rightarrow \infty$.
- Die Verteilung in einem abgetrennten Raum kann bestimmt werden, wenn für $t \rightarrow \infty$ an beliebigen Orten in diesem Raum kontinuierlich Messungen durchgeführt werden.

Die allgemeine Konvektions-Diffusions-Gleichung für den LRR lautet:

$$\frac{\partial LRR(x, y, t)}{\partial t} = v_x \frac{\partial LRR(x, y, t)}{\partial x} + v_y \frac{\partial LRR(x, y, t)}{\partial y} + d_x \frac{\partial^2 LRR(x, y, t)}{\partial x^2} + d_y \frac{\partial^2 LRR(x, y, t)}{\partial y^2}. \quad (133)$$

Gemäß der Erläuterung in Kapitel 2.3.3 (Seite 22) ergibt sich daraus die explizite vorwärtige Zeit, zentrale Konvektion in x-Richtung, zentrale Konvektion in y-Richtung, zentrale Diffusion in x-Richtung, zentrale Diffusion in y-Richtung - Variante für eine numerische Lösung

$$\begin{aligned} \frac{LRR_{i,j}^{t+1} - LRR_{i,j}^t}{\Delta t} = & v_x \frac{LRR_{i+1,j}^t - LRR_{i-1,j}^t}{2\Delta x} + v_y \frac{LRR_{i,j+1}^t - LRR_{i,j-1}^t}{2\Delta y} + \\ & d_x \frac{LRR_{i+1,j}^t - 2LRR_{i,j}^t + LRR_{i-1,j}^t}{\Delta x^2} + d_y \frac{LRR_{i,j+1}^t - 2LRR_{i,j}^t + LRR_{i,j-1}^t}{\Delta y^2}. \end{aligned} \quad (134)$$

Die Stabilitätsbedingung für die Gleichung ist folgendermaßen

$$\frac{d_x \Delta t}{\Delta x^2} + \frac{d_y \Delta t}{\Delta y^2} \leq 0.5. \quad (135)$$

In Gleichung 134 wird dargestellt, wie sich die einzelnen Zellwerte in der Rasterkarte $M_{LRR} = [LRR_0, LRR_1, \dots, LRR_n]$ berechnen. Da sich Aerosole im freien Raum ausbreiten, wird die Gleichung dementsprechend nur auf Zellen angewandt, die gemäß der Rasterkarte M_g (Gleichung 96, Seite 79) frei sind. Die freien Zellen an den Grenzen zu belegten Zellen stellen dabei einen besonderen Fall dar. Wenn beispielsweise eine Nachbarzelle $LRR_{i-1,j}^t$ belegt ist, dann liegt diese Zelle außerhalb der zu berechnenden Fläche. In diesem Fall wird die vorwärtige Zeit, vorwärtige Diffusion in x-Richtung, zentrale Diffusion in y, vorwärtige Konvektion in x-Richtung, zentrale Konvektion in y-Richtung verwendet.

$$\frac{LRR_{i,j}^{t+1} - LRR_{i,j}^t}{\Delta t} = v_x \frac{LRR_{i+1,j}^t - LRR_{i,j}^t}{\Delta x} + v_y \frac{LRR_{i,j+1}^t - LRR_{i,j-1}^t}{2\Delta y} + d_x 2 \frac{LRR_{i+1,j}^t - LRR_{i,j}^t}{\Delta x^2} + d_y \frac{LRR_{i,j+1}^t - 2LRR_{i,j}^t + LRR_{i,j-1}^t}{\Delta y^2}. \quad (136)$$

Nach dem Schema sind insgesamt neun verschiedene Gleichungen in Abhängigkeit der Position der angrenzenden belegten Zellen möglich (siehe Abbildung 67). Dadurch wird die Struktur der Umgebung bei der Berechnung des Verteilungsmodells mit einbezogen.

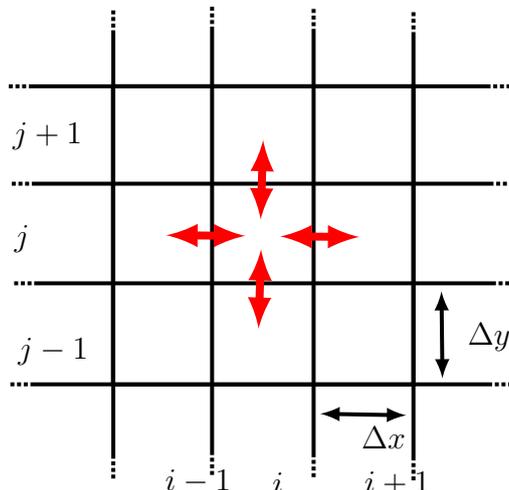


Abbildung 67: Abhängigkeit eines Konzentrationswertes von seinen Nachbarzellen.

6 Experimentelle Evaluierung der vorgestellten Verfahren

Dieses Kapitel präsentiert die Evaluierung der vorgestellten Verfahren mittels realer Sensordaten. Die Struktur dieses Kapitels richtet sich nach den drei Zielsetzungen, die sich aus der wissenschaftlichen Fragestellung dieser Dissertation (Kapitel 1.1, Seite 2) ergeben. Demzufolge stellt Kapitel 6.1 neue Messprinzipien mit Radar in der mobilen Robotik dar. Kapitel 6.2 untersucht die drei vorgestellten LiDAR-Radar-Fusionsverfahren. Dabei wurden im Rahmen dieser Dissertation drei Datensätze erstellt, die teilweise gestörte Sichtbedingungen aufweisen. Die Datensätze sind in Anhang A.3 näher beschrieben. In Kapitel 6.3 ist das Erstellen von metrischen Umgebungsmodellen und Aerosolverteilungen der Untersuchungspunkt.

Die Experimente in folgendem Kapitel basieren auf den Roboterplattformen *Pioneer 3-AT* und *Tau-rob Tracker*, den Radarsensoren MPR und *iSYS4004*, und dem LiDAR-Scanner *Velodyne VLP-16*. Informationen über die genannte Hardware kann in Anhang A.1 (Seite 132) eingesehen werden.

Der *iSYS4004*-Radarsensor arbeitet in einem kleinerem Frequenzband Δf als der MPR. Eine Voruntersuchung der *iSYS4004*-Radarsensoren hat ergeben, dass die reale Auflösung im Gegensatz zur theoretischen Auflösung sogar bei ca. 1 m liegt. Im Gegensatz dazu ermöglicht die hohe Bandbreite des MPR eine hohe Distanzauflösung. Die wichtigsten Sensoreigenschaften des Laterations-Scanners und des MPRs sind in Tabelle 3 gegenübergestellt.

	Lat-Scanner	MPR	Einheit
Frequenzbereich	24.0 - 24.25	88-92	GHz
Theoretische Distanzauflösung	60	3.75	cm
Drehfrequenz	0.1	2.5	Hz
Öffnungswinkel	49	4.9	°

Tabelle 3: Gegenüberstellung der Sensoreigenschaften des Laterations-Scanners und des MPR.

Die niedrige Drehfrequenz des Laterations-Scanners basiert auf der geringen Messrate der *iSYS4004*-Radarsensoren. Vergleichbare Anbieter von Radarsensoren bieten kaum besser Messraten (Zeitpunkt der Durchführung der Experimente 2018). Da die Sensoren für Füllstandsmessungen oder Kollisionsvermeidungen im industriellen Umfeld verwendet werden, ist eine höhere Messrate von den meisten Endanwendern nicht gefordert. Der große Öffnungswinkel der Hauptkeule des *iSYS4004*-Radarsensors ist zugleich die Voraussetzung für ein großes Detektionsfeld gemäß des Laterationsprinzips. Der Öffnungswinkel eines Laserstrahls des *SICK LMS200* beträgt zum Vergleich 0.26° und des *Velodyne VLP-16* 0.17° .

6.1 Evaluierung neuer Messprinzipien zur Umgebungsmodellierung in der mobilen Robotik mit Radar

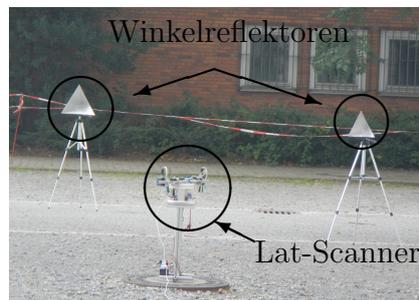
Dieser Abschnitt untersucht neue Messprinzipien mit allgemeinen Radarsensoren hinsichtlich ihrer Eignung für die Umgebungsmodellierung in der mobilen Robotik. In Kapitel 6.1.1 ist zunächst das Sensorverhalten des in dieser Arbeit vorgestellten Laterations-Scanners dargelegt. Kapitel 6.1.2 zeigt, ob sich der Laterations-Scanner für die Rasterkartierung eignet und vergleicht die Ergebnisse mit dem ASR-Scanner. Das Erstellen von Feature-Karten mit dem Laterations-Scanner ist in Kapitel 6.1.3 dargestellt. Ob sich das SEABED-Verfahren zur Erstellung von Umgebungsmodellen eignet, ist in Kapitel 6.1.4 beschrieben.

6.1.1 Allgemeines Sensorverhalten des Laterations-Scanners

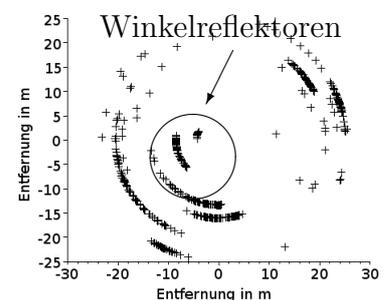
Der erste Versuch vergleicht das Scanbild des Laterations-Scanners mit dem Scanbild eines ASR-Scanners. Die Versuche basieren auf *iSYS4004*-Radarsensoren der Firma InnoSenT (siehe Abbildung 68a). Eine ausführlichere Beschreibung der Sensoren befindet sich in Anhang A.1. Für das Experiment wurde aus zwei Sensoren ein Laterations-Scanner (siehe Abbildung 68b) und ein ASR-Scanner mit einer Dreheinheit aufgebaut. Die Dreheinheit ist frei drehbar und sendet über einen Schleifring Sensordaten an einen *Raspberry Pi*. Dieser Mini-Computer steuert auch den Motor zur Drehung der Einheit und liest Drehgeberwerte zur Winkelbestimmung ein. Ein 360°-Scan des Aufbaus ist in Abbildung 68c dargestellt.



(a) *iSYS4004*-Abstandssensor der Firma InnoSenT



(b) Aufbau des Laterations-Scanners (Lat-Scanner)



(c) Scanbild (Sensorposition bei (0,0))

Abbildung 68: In 68b ist der Aufbau des Laterations-Scanners und zwei Aluminiumwinkelreflektoren sichtbar. In 68c ist das Scanbild, der Umgebung aus Abbildung 68b dargestellt. Neben den Winkelreflektoren werden zusätzlich größere Metallobjekte (Autos, Metallcontainer) erkannt.

Um das allgemeine Sensorverhalten zu untersuchen, wurde mit den *iSYS4004*-Radarsensoren ein Laterations-Scanner und ein ASR-Scanner aufgebaut und vor einem 2 m entfernten Winkelreflektor platziert. Das Experiment ist in Abbildung 69 skizziert.

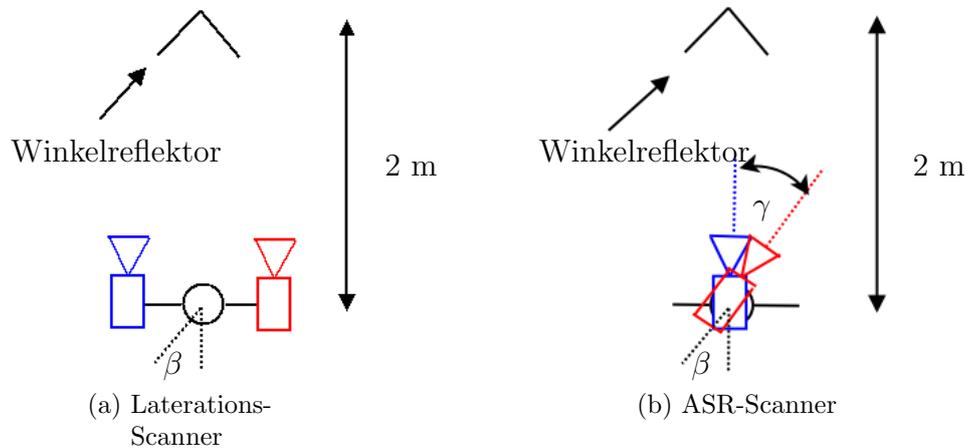


Abbildung 69: Laterations-Scanner und ASR-Scanner wurden mit der gleichen Dreheinheit mit dem Drehwinkel β aufgebaut. Der Versatz der Sensoren wird mit dem Winkel γ beschrieben.

Mit den Laterations- und ASR-Scanner wurde jeweils ein Scanbild aufgenommen. In Abbildung 70 ist das Scanbild des Laterations-Scanners zu sehen. Der ca. 2 m entfernte Winkelreflektor ist deutlich erkennbar. Die Abstandswerte d_1 und d_2 verdeutlichen, dass nur die Position von Punktezielen genau ermittelt werden kann. Andere Objekte weisen unterschiedliche Reflexionszentren auf, wenn sie aus unterschiedlichen Richtungen detektiert werden, was bei der Sensoranordnung beim Laterations-Prinzip bedingt durch den Aufbau der Fall ist. Aber, Abbildung 68c verdeutlicht, dass größere Objekte, wie z. B. Autos und Container, auch sehr gut detektiert werden können. In einer Indoor-Umgebung mit vielen kleinen Gegenständen ist jedoch mit einer Sensorauflösung - also Separationsfähigkeit - von ca. 1 m das detaillierte Darstellen von Objekten nicht möglich.

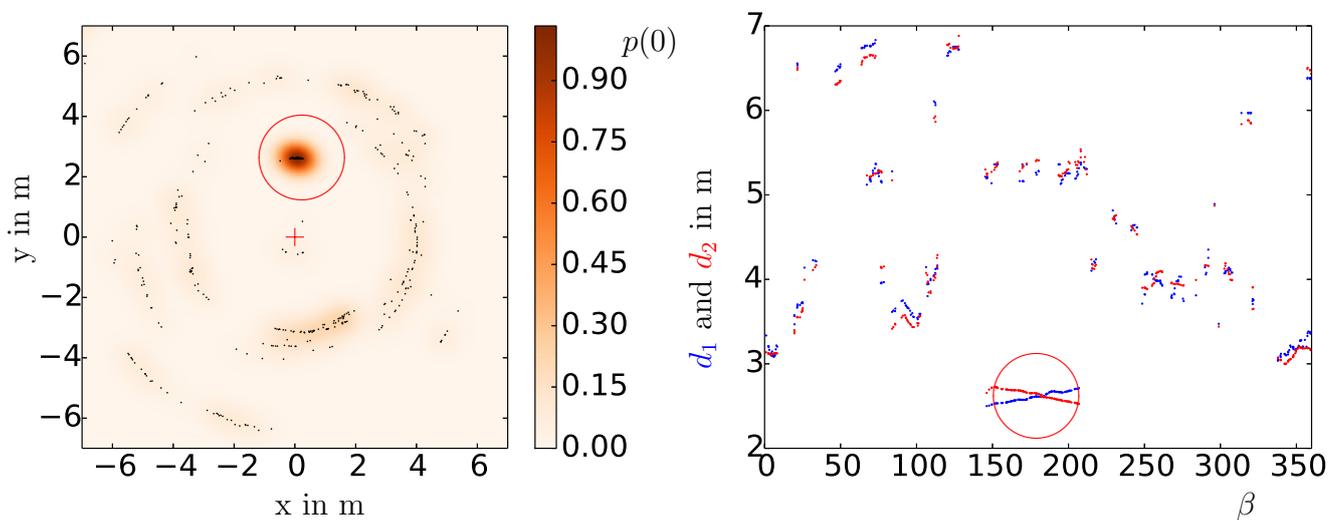


Abbildung 70: Links: Diese Abbildung zeigt den Scanbereich aus der Vogelperspektive. Das rote Kreuz markiert die Position des Sensors. Der Winkelreflektor ist deutlich durch eine höhere Anhäufung von Messwerten erkennbar und ist mit einem roten Kreis markiert. Die dichte der Messpunkte ist farblich gekennzeichnet und auf 1 normiert. Rechts: Im Diagramm sind die Abstandswerte der Sensoren zu sehen. Punktziele sind durch ein symmetrisches Kreuzen der Abstandswerte erkennbar.

In der Abbildung 71 ist das Scanbild des ASR-Scanners zu sehen. Der ca. 2 m entfernte Winkelreflektor wird erkannt, jedoch kann er nicht durch eine höhere Punktdichte von anderen detektierten Objekten unterschieden werden. Für den Einsatz als Landmarkendetektor ist der ASR-Scanner demzufolge weniger geeignet. Auch hier führt der Effekt, dass Reflexionszentren wandern, zu starken Abweichungen vom Modell des ASR-Prinzips. Eine Winkelbestimmung mit einer interpolierten Funktion ist für Umgebungen mit vielen Objekten nicht realisierbar. Stattdessen kann angenommen werden, dass sich ein Objekt bei $\frac{\gamma}{2}$ vor dem Scanner befindet, wenn $P_{e1} = P_{e2}$ ist.

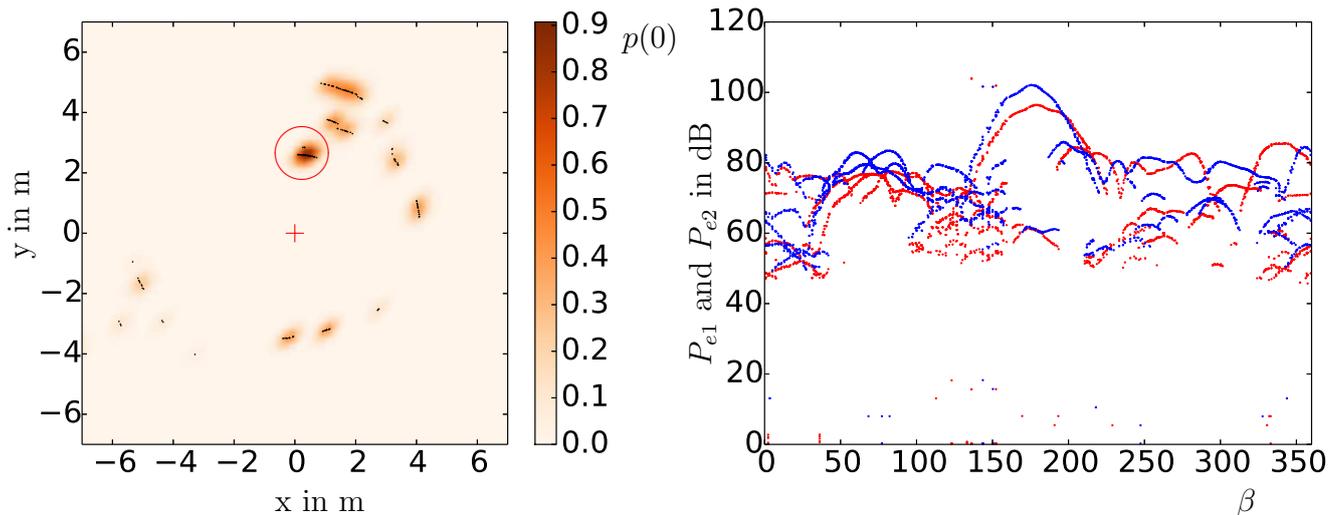


Abbildung 71: Links: Die Abbildung zeigt einen zweidimensionalen Scan mit dem ASR-Prinzip. Die Scannerposition ist äquivalent zur Abbildung 70 und durch ein rotes Kreuz markiert. Die Position des Winkelreflektors ist mit einem roten Kreis markiert. Rechts: Das Diagramm zeigt den Verlauf der Empfängerleistungen $P_{e,1}$ und $P_{e,2}$ im 360°-Verlauf auf.

6.1.2 Rasterkartierung mit dem Laterations-Scanner

Für diesen Versuch wurde die Dreheinheit sowohl als Laterations- als auch als ASR-Aufbau auf bekannten Positionen in einem Flur platziert. Die Versuchsumgebung ist in der Abbildung 72 dargestellt.

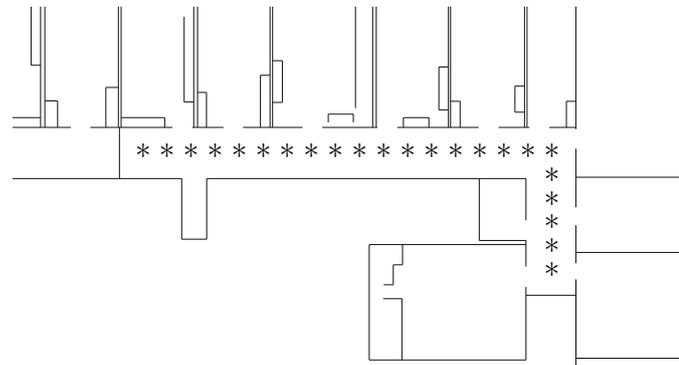
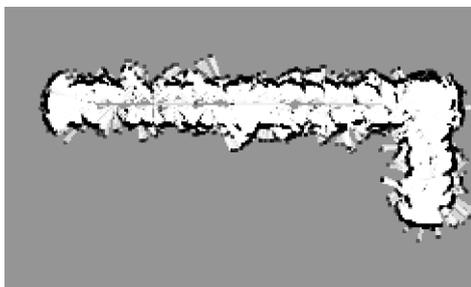
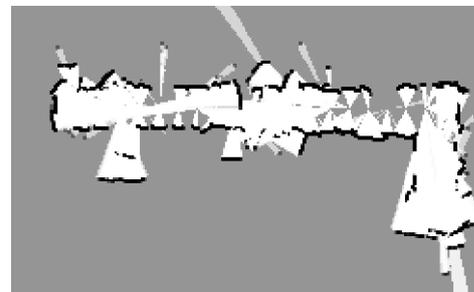


Abbildung 72: Entlang des L-förmigen Flures wurde sowohl Laterations-Scanner als auch ASR-Scanner an vorgegebenen Sensorposition (*) platziert, um Messwerte zu generieren.

In der Abbildung 73 sind zwei Rasterkarten zu sehen, die mit dem Laterations-Scanner und mit dem ASR-Scanner erzeugt wurden. Die Sensoren befanden sich an den gleichen Positionen während der Messwertaufnahmen.



(a) Mit dem Laterations-Scanner erstellte Rasterkarte

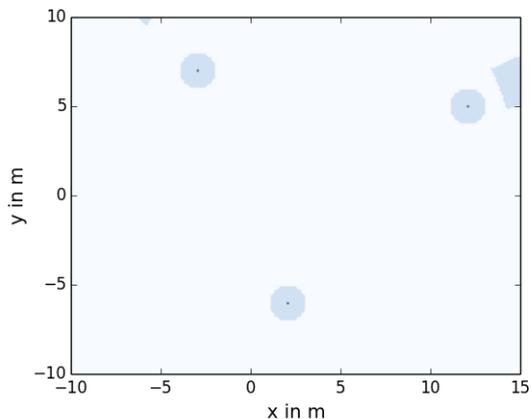


(b) Mit dem ASR-Scanner erstellte Rasterkarte

Abbildung 73: Zwei Rasterkarten der gleichen Umgebung die jeweils mit dem Laterations- und dem ASR-Verfahren aufgenommen wurden.

6.1.3 Feature-Kartierung mit dem Laterations-Scanner (Proof of Concept)

Für diesen Versuch wurde der Laterations-Scanner auf einer *Pioneer*-Plattform montiert (Abbildung 74b). Danach wurden auf einer Wiese drei Winkelreflektoren im Dreieck aufgestellt. Durch die Aufstellung im Dreieck wird ein Bereich erzeugt, in dem die Landmarken eindeutig voneinander unterschieden werden können (Abbildung 74a). In Abbildung 70 (Seite 95) wird gezeigt, dass mit dem Laterations-Scanner Objekte mit konstantem Reflexionszentrum detektiert werden können. Die Abbildung 75 zeigt, dass dies für einen EKF-SLAM genutzt werden kann.

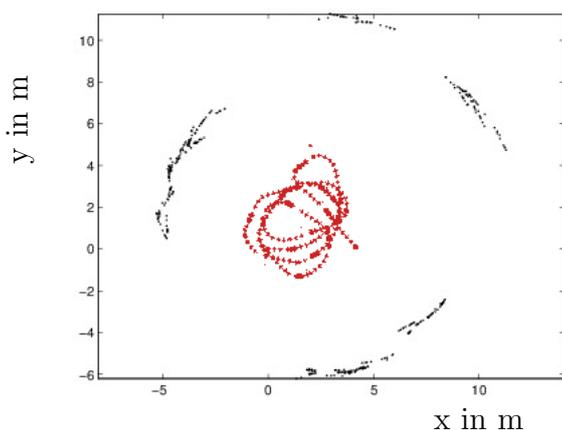


(a) Durch die Aufstellung der Landmarken im Dreieck entsteht ein Bereich ohne Doppeldeutigkeiten (Doppeldeutiger Bereich ist blau dargestellt).

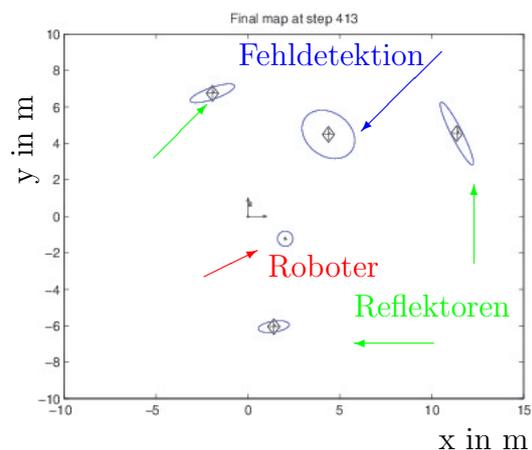


(b) Montage des Laterations-Scanners auf der *Pioneer*-Plattform.

Abbildung 74: Mit dem Versuch wird die Realisierbarkeit (Proof of Concept) der Lokalisierung mit dem Laterations-Scanner gezeigt.



(a) Rohdaten spiegeln die Verzerrung der detektierten Landmarken durch die Odometriefehler wieder. Der Pfad ist rot markiert.



(b) Varianzen der Landmarken und des Roboters

Abbildung 75: Experiment auf einer Wiese mit drei künstlichen Landmarken (Winkelreflektoren).

6.1.4 Kartierung mit Range-Only-Radarsensoren - SEABED

In folgendem Unterkapitel wird experimentell untersucht, ob der SEABED-Algorithmus von Sakamoto [SWS⁺13] für die mobile Robotik geeignet ist, wenn Radarsensoren mit großen Öffnungswinkeln der Hauptkeule Θ senkrecht zur Fahrtrichtung des mobilen Roboters montiert werden. Das Prinzip des Verfahrens ist in der Abbildung 76 dargestellt.

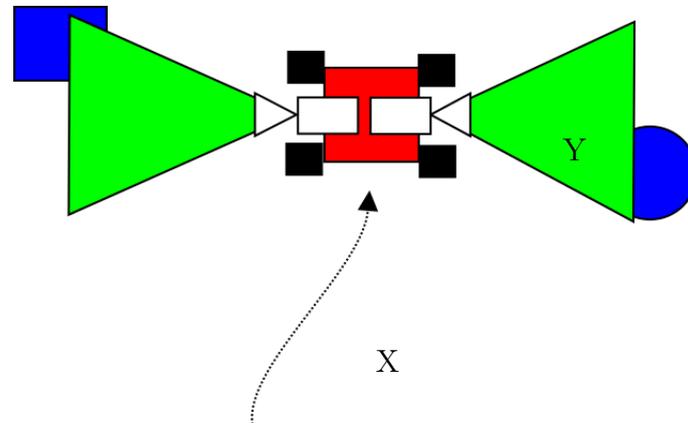


Abbildung 76: In diesem Experiment wird untersucht, ob der SEABED-Algorithmus für die Kartierung in der mobilen Robotik geeignet ist.

Das Verfahren wird zunächst theoretisch in der Simulationsumgebung *v-rep* (Abbildung 77) untersucht. In der *v-rep*-Umgebung werden Objekte platziert, an denen ein Roboter mit einem Radarsensor vorbeifährt und Messungen aufnimmt.

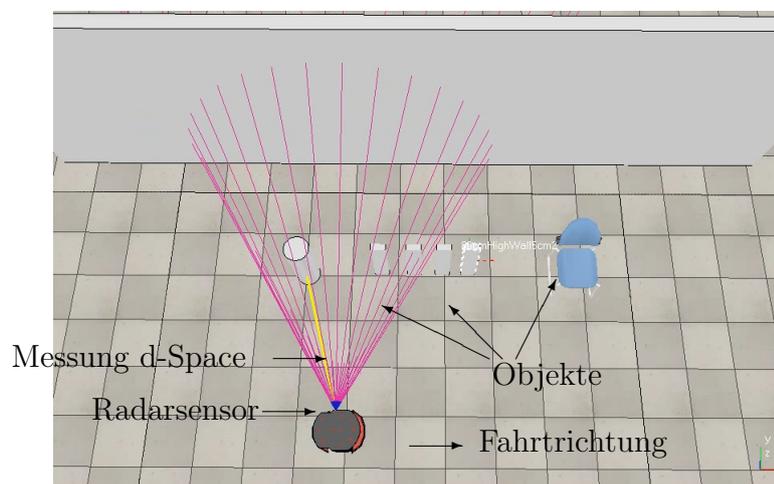


Abbildung 77: In der Simulation fährt ein mobiler Roboter, an dem ein Radarsensor seitlich angebracht ist, an Objekten vorbei. Aufgrund des großen Öffnungswinkels Θ werden die Objekte verzerrt im d-Space dargestellt.

Die Simulation ermöglicht es, fehlerfreie Distanzmessungen mit dem Radar zu ermitteln. Bei der Untersuchung der Standardabweichung der *iSYS4004*-Sensoren hat sich ergeben, dass σ_R für einen starken Reflektor zwischen 1 mm - 5 mm liegt (Abbildung 28). Schwächere Reflektoren resultieren in

einer größeren Standardabweichung. Um das Ergebnis des SEABED-Algorithmus bei Distanzmessfehlern abzuschätzen, wird in der Abbildung 78 dargestellt, wie sich die Rekonstruktion durch den Algorithmus in Abhängigkeit von Distanzfehlern verschlechtert. Ab einem Distanzfehler von 5 mm ist bereits keine gute Rekonstruktion mehr möglich.

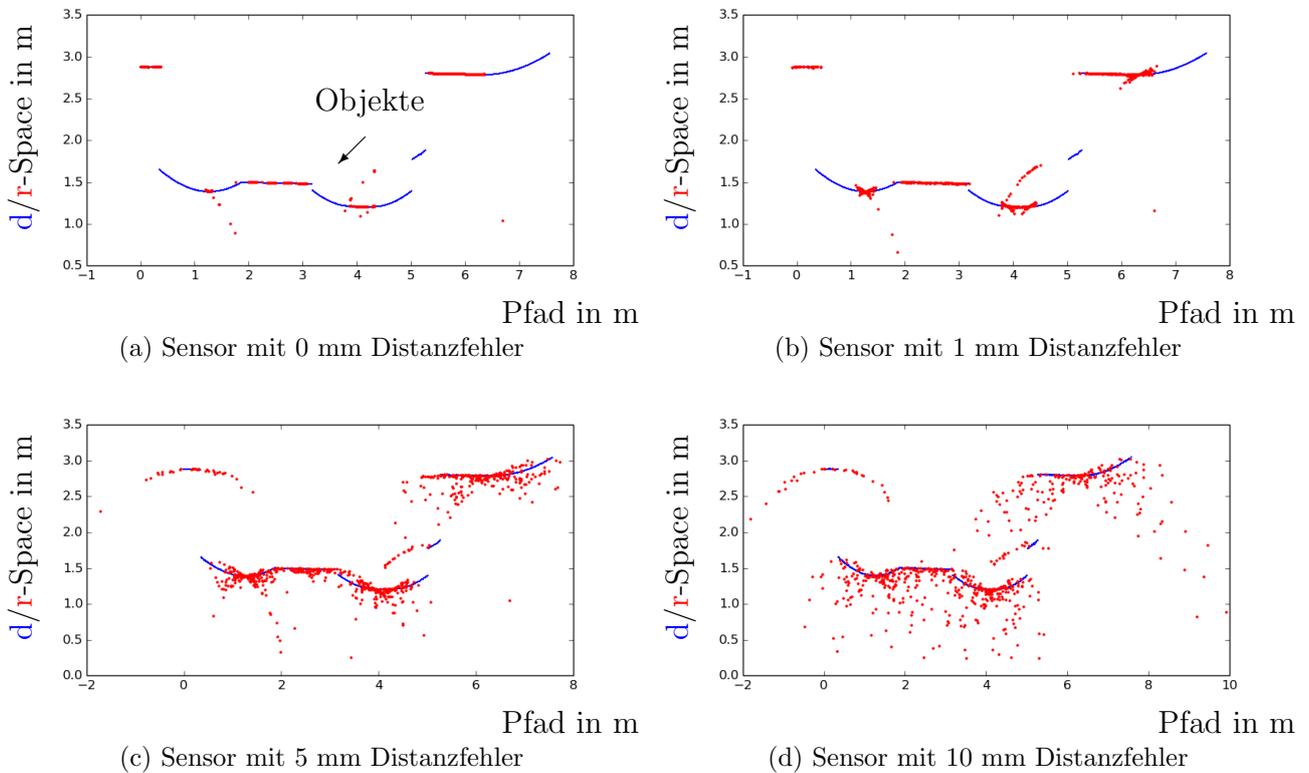


Abbildung 78: Einfluss des Distanzfehlers auf den SEABED-Algorithmus (Der d-Space ist blau und der r-Space is rot dargestellt).

Es ist zu erkennen, dass der Algorithmus zu störanfällig gegenüber Messfehlern ist, um mit einfachen Radarsensoren eine Rasterkartierung durchzuführen. Sakamoto führt zur Verbesserung des Verfahren den Faktor α (Gleichung 137) ein. Die Beziehung zwischen d-Space und r-Space ist durch

$$x = X - \alpha Y \frac{dY}{dX}$$

$$y = Y \sqrt{1 - \alpha \left(\frac{dY}{dX} \right)^2} \quad (137)$$

gegeben.

In der Abbildung 79 wird gezeigt, dass mit α das Ergebnis des SEABED-Verfahren zwischen d-Space und r-Space verschoben werden kann.

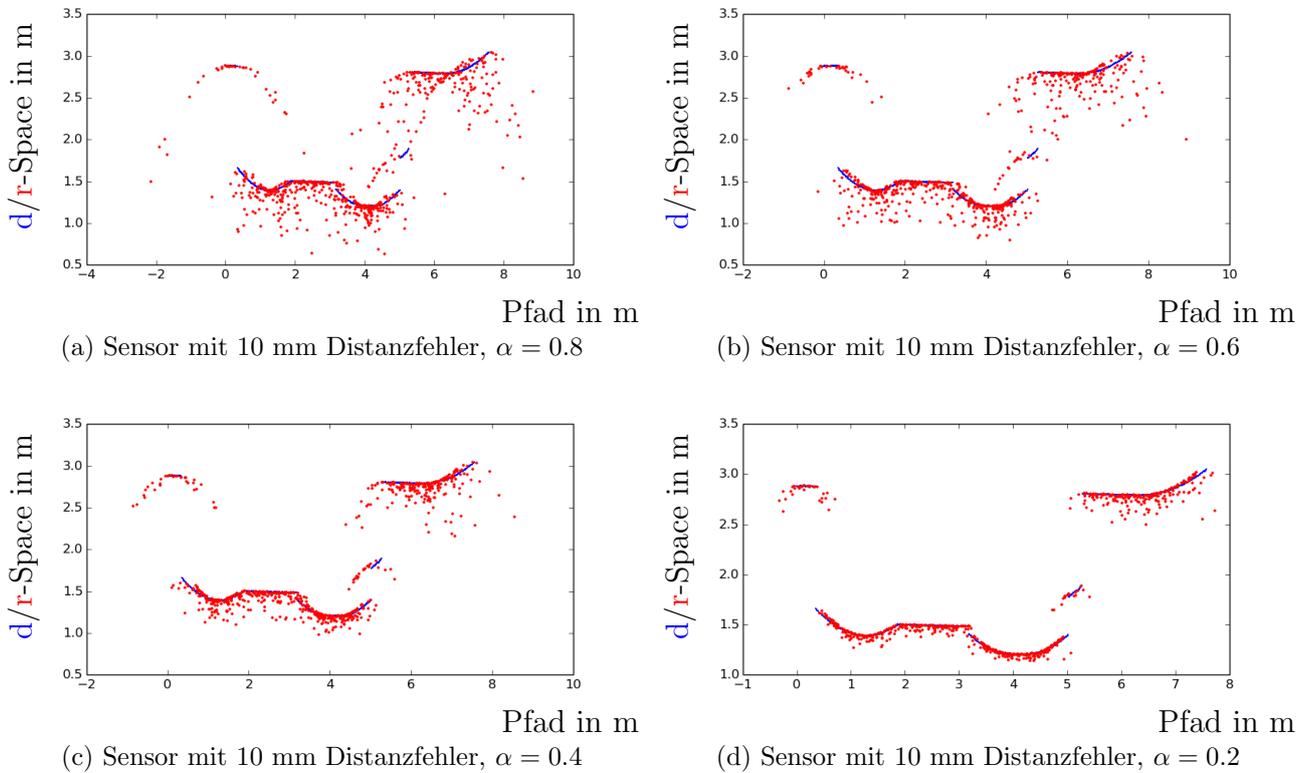


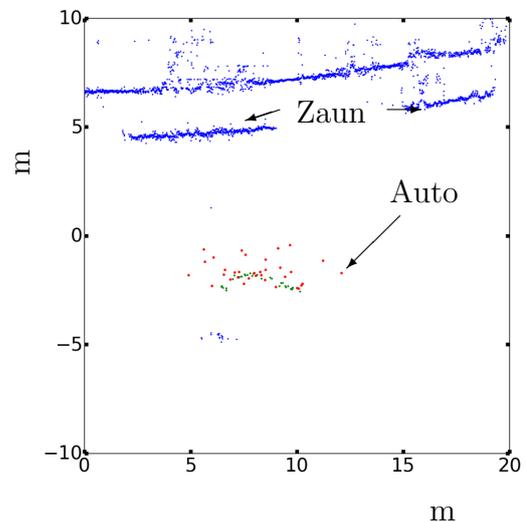
Abbildung 79: Einfluss des Faktors α auf den SEABED-Algorithmus (Der d-Space ist blau und der r-Space is rot dargestellt).

Das Ein- bzw. Austreten von Objekten in den Öffnungswinkel des Radarsensors ist im Gegensatz zur Simulation nicht konstant und hängt von der Rückstrahlleistung P_e des Objektes ab. Objekte mit einem niedrigen RCS führen dementsprechend zu einer kleineren Verzerrung im d-Space. Bei schwachen Reflektoren kann α kleiner gewählt werden.

Um den Einsatz des SEABED-Algorithmus unter realen Bedingungen zu testen wurde ein Experiment mit den *iSYS4004*-Sensoren durchgeführt. Das Experiment und das Resultat ist in der Abbildung 80 dargestellt.



(a) Experimentierumgebung beinhaltet Objekte mit großem RCS



(b) SEABED auf das Auto angewandt (d-Space, r-Space)

Abbildung 80: Das Experiment mit realen Sensordaten zeigt, dass SEABED zu störanfällig gegenüber dem Messrauschen ist.

Das Experiment bestätigt die Erkenntnis, die bereits in der Simulation gewonnen wurde. Aufgrund des Messrauschens der *iSYS4004*-Sensoren ist der SEABED-Algorithmus nicht für die Kartierung in der mobilen Robotik geeignet.

6.2 Evaluierung der LiDAR-Radar-Fusion

Die folgenden Untersuchungen beziehen sich auf die Fusionsverfahren, die in Kapitel 4 vorgestellt werden. Das Hauptkriterium an die Scan-Fusion ist, dass der Typ-I- und Typ-II-Effekt behoben werden können und dass sich möglichst wenig Radarmessungen im fusionierten Scan S_{Fusion} befinden. Radarmessungen R_{Radar} dürfen sich nur im Scan befinden, wenn die LiDAR-Messung unbrauchbar ist.

In den folgenden Unterkapiteln werden diverse Aspekte der Radar-LiDAR-Fusion untersucht.

6.2.1 Gegenüberstellung und Parameterverhalten

Da die Scan-Fusionsverfahren auf unterschiedlichen Methoden basieren, wird hier untersucht, inwiefern sich die resultierenden fusionierten Scans S_{Fusion} unterscheiden. Die prozentualen Anteile der Fusionsfälle pro Scan werden in folgendem Kapitel zur Evaluierung der Scan-Fusionen eingeführt. Der prozentuale Anteil eines Fusionsfalls $A_{Fusionsfall}$ ergibt sich aus dem Verhältnis der Summe der Messpunkte eines Fusionsfalls $n_{Fusionsfall}$ durch die Summe der gesamten Messpunkte des fusionierten Scans $n_{S_{Fusion}}$.

$$A_{Fusionsfall} = \frac{n_{Fusionsfall}}{n_{S_{Fusion}}} \cdot 100\% \quad (138)$$

Auf die Datensätze bezogen ergibt sich somit der Durchschnitt der Anteile der Fusionsfälle $A_{Startzeit,Endzeit}^{\varnothing}$. Die Fusionsfälle können bei der modellbasierten Fusion von der normierten Funktion $f(i)$ abgeleitet werden. Da die verwendeten Sigmoidfunktionen gegen 0 bzw. 1 für ∞ bzw. $-\infty$ tendieren, muss ein Schwellwert s definiert werden, ab dem ein Messpunkt als LiDAR-, bzw. Radar-Messpunkt interpretiert wird. In folgendem Kapitel wurde für $s = 0.001$ gewählt.

$$S_{Fusion}[i] = f(i) \cdot S_{LiDAR}[i] + (1 - f(i)) \cdot S_{Radar}^*[i] \quad (139)$$

$$Fusionsfall = \begin{cases} LiDAR, & \text{wenn } f(i) \geq 1 - s \\ Radar, & \text{wenn } f(i) \leq s \\ Fusion, & \text{wenn } s < f(i) < 1 - s \end{cases} \quad (140)$$

Bei der heuristischen Fusion ergibt sich der Fusionsfall direkt aus den Heuristiken.

$$Fusionsfall = \begin{cases} LiDAR, & \text{wenn } |R_{LiDAR} - R_{Radar}| > d_F \cap R_{LiDAR} \in Linie \\ & R_{LiDAR} > R_F \cap R_{LiDAR}! = inf \\ & R_{LiDAR} - R_{Radar} > d_F \cap R_{LiDAR} < R_F \\ Radar, & \text{wenn } R_{LiDAR} - R_{Radar} < -d_F \cap R_{LiDAR} < R_F \quad (Typ - I) \\ & R_{LiDAR} = inf \cap R_{Radar}! = inf \quad (Typ - II) \\ Fusion, & \text{wenn } |R_{LiDAR} - R_{Radar}| < d_F \end{cases} \quad (141)$$

Bei der Fusionierung mittels virtuellen Sensor muss für die Berechnung eines virtuellen Messpunktes an der Stelle $M(x, y)$ überprüft werden, ob Intensitätswerte in den entsprechenden Rastern vorliegen.

$$M_{VS,Fusion} = (1 - a) \cdot M_{VS,LiDAR} + a \cdot M_{VS,Radar} \quad a \in [0, 1] \quad (142)$$

$$Fusionsfall = \begin{cases} LiDAR, & \text{wenn } M_{VS,LiDAR}(x, y) > 0 \cap M_{VS,Radar}(x, y) = 0 \\ Radar, & \text{wenn } M_{VS,LiDAR}(x, y) = 0 \cap M_{VS,Radar}(x, y) > 0 \\ Fusion, & \text{wenn } M_{VS,LiDAR}(x, y) > 0 \cap M_{VS,Radar}(x, y) > 0 \end{cases} \quad (143)$$

Neben der Zusammensetzung der Scans ist der absolute Distanzfehler ein weiteres Maß, um die Ähnlichkeit der Scans zu evaluieren. Der absolute Fehler zwischen modellbasierten und heuristischen fusionierten Scan ist zum Beispiel folgendermaßen:

$$E_{Heuristik}^{Modell} = \frac{1}{n_{S_{Fusion}}} \sum |S_{Fusion,Heuristik} - S_{Fusion,Modell}|. \quad (144)$$

Die genannten drei Fusionsverfahren basieren auf Parameter, mit denen ihr Verhalten beeinflusst werden kann. Die wichtigsten Parameter sind in der Tabelle 4 zusammengefasst.

Fusionsverfahren	Parameter	Beschreibung
Vorverarbeitung	α	Entfernung zum komplementären Bereich
	n_{Linie}	Mindestgröße detektierter Linien
Modellbasierte Fusion	p	Anstieg sig_{Typ-I}
Heuristische Fusion	d_F	Größe des Fusionsbandes $ R_{LiDAR} - R_{Radar} < d_F$
Virtueller Sensor	a	Gewichtung der Raster im Fall von zwei Sensoren
	res	Auflösung der Fusions-Raster
	$r_{VirtuellerSensor}$	Radius der Sensormodelle

Tabelle 4: Übersicht der Parameter der Fusionsverfahren

Bei der modellbasierten Fusion sind die Parameter p und α die Stellgrößen. Die Größe des Bereiches, in dem fusionierte Messpunkte entstehen bzw. zwischen LiDAR und Radar unterschieden wird, wird über den Anstieg der Sigmoidfunktion Sig_{Typ-I} realisiert. Die Größe des Fusionsbandes d_F bei der heuristischen Fusion hat einen ähnlichen Effekt wie der Parameter p . Die Trennung zwischen komplementären und konkurrierenden Messbereich bei $R_F = R_{Radar,\emptyset}(\alpha = 0)$ bis $R_F = R_{Radar,max}(\alpha = 1)$ wird über den Faktor α in sig_{RF} realisiert. Die Parameter beim virtuellen Sensor sind a , res und $r_{VirtuellerSensor}$. Der Parameter a bestimmt die Gewichtung bei der Fusionierung der Raster (Siehe Gleichung 142). Die Auflösung der Raster hat einen entscheidenden Einfluss auf die Genauigkeit des virtuellen Sensors. Die Größe der Sensormodelle ergibt sich normalerweise aus den Standardabweichungen der Distanzmessungen der Sensoren. Bei der Wahl eines kreisförmigen Sensormodells haben Radius $r_{VirtuellerSensor}$ und Auflösung res einen entscheidenden Einfluss auf die Zusammensetzung des fusionierten Scans (siehe Abbildung 81).

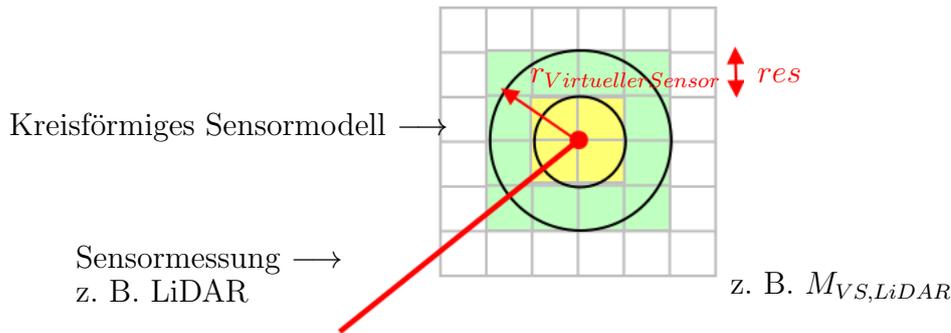
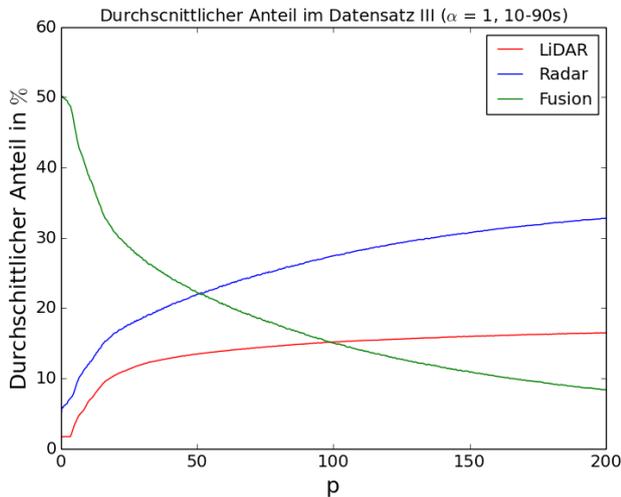


Abbildung 81: Das kreisförmige Sensormodell wird über den Radius $r_{\text{Virtueller Sensor}}$ parametrisiert.

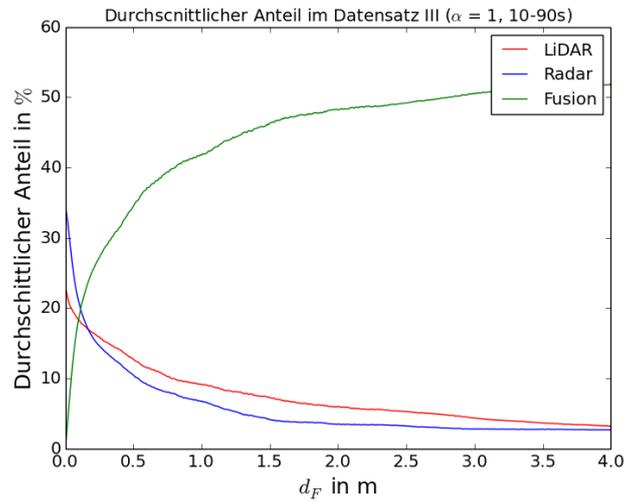
In Abbildung 82 ist dargestellt, welchen Effekt die Parameter p , d_F und a auf die durchschnittlichen Anteile $A_{10,90}^\emptyset$ des fusionierten Scans S_{Fusion} haben. Zur Evaluierung wird hier der Datensatz III (Garage in Wien, Anhang A.3.4, Seite 143) im Zeitrahmen 10-90 s betrachtet, da es hier nicht zum Typ-I- und Typ-II-Effekt kommt. Diese Effekte werden in Kapitel 6.2.5 und 6.2.6 (ab Seite 114) näher betrachtet. Weiterhin wird hier die Linienextraktion zur Vorverarbeitung für schlechte Sichtbedingungen ausgeschaltet, um den Einfluss besser zu unterscheiden. Der Einfluss dieser Vorabschätzung wird näher in Kapitel 6.2.2 (Seite 109) untersucht.

Im Verlauf in Abbildung 82a ist zu erkennen, dass bei steigendem p bei der modellbasierten Fusion sich weniger fusionierte Scan-Punkte im Scan befinden und die Anzahl an reinen LiDAR- und Radarwerten steigt. In der Abbildung 82b ist zu erkennen, dass ein größeres Fusionsband d_F zu einer Erhöhung der fusionierten Distanzmessungen führt. In der Abbildung 82c ist zu erkennen, dass die Gewichtung der Raster durch a bei dem virtuellen Sensorverfahren einen Einfluss auf die Zusammensetzung von S_{Fusion} hat. Wenn $a = 0$, dann ist die Gewichtung komplett auf $M_{\text{VS, LiDAR}}$ wodurch dementsprechend der Anteil an LiDAR-Messungen A_{LiDAR} 100 % ist. Das Gegenteil tritt bei $a = 1$ ein. In der Abbildung 82d sind die Summen der Anteile der fusionierten Scans dargestellt. Da ein Scan auch unendliche Messung enthalten kann (inf) ist die Summe bei der heuristischen und modellbasierten Fusion nicht 100 %. Die Parameter p und d_F haben keinen Einfluss auf den Anteil an unendlichen Messungen. Der LiDAR-Scanner selbst hat im Zeitraum 10-90 s einen Anteil an brauchbaren Werten von 90.96 % und der Radar-Scan hat einen Anteil von 56.37 %. Der fusionierte Scan des virtuellen Sensors beinhaltet 100 % brauchbare Messwerte. Die fusionierten Scans der modellbasierten und heuristischen Fusion beinhalten nur circa 60% brauchbar Messwerte (Abbildung 82d). Der Anteil an brauchbaren Messwerten ist jedoch abhängig vom Parameter α (Abbildung 83), mit dem die Grenze zwischen komplementären und konkurrierenden Fusionsbereich eingestellt wird.

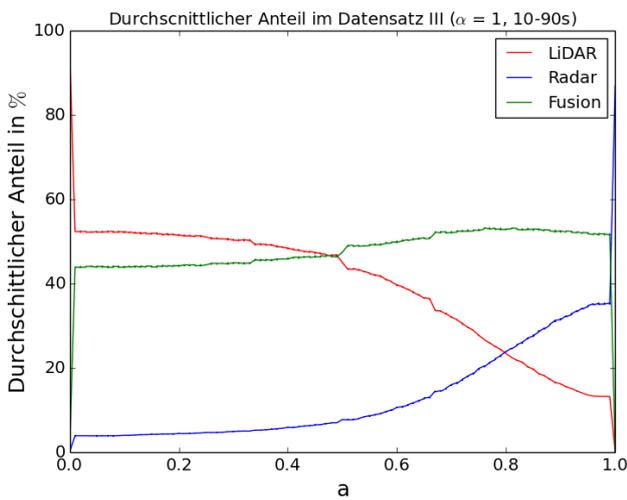
In den Diagrammen in den Abbildungen 83a und 83b wird verdeutlicht, dass durch einen niedrigeren α Parameter der Anteil an brauchbaren Messwerten in den fusionierten Scans bei der heuristischen und modellbasierten Fusion auf ca. 80 % erhöht werden kann. Dies wird in den oberen zwei Diagrammen in der Abbildung 83d deutlich. Im Gegensatz dazu hängt der virtuelle Sensor nicht von α ab. Die Abhängigkeit der Zusammensetzung des Scans vom Radius des Sensormodells $r_{\text{Virtueller Sensor}}$ ist in der Abbildung 83c dargestellt. Je größer der Radius des Fusionsmodelles, desto größer ist der Anteil an fusionierten Scans. Durch die Vergrößerung des Radius steigt jedoch auch die Ungenauigkeit des fusionierten Scans, was in der Abbildung 84b erkenntlich ist. Der absolute Fehler zum LiDAR-Scan steigt auch mit größerer Auflösung res der Fusionsraster, was in der Abbildung 84a gezeigt wird.



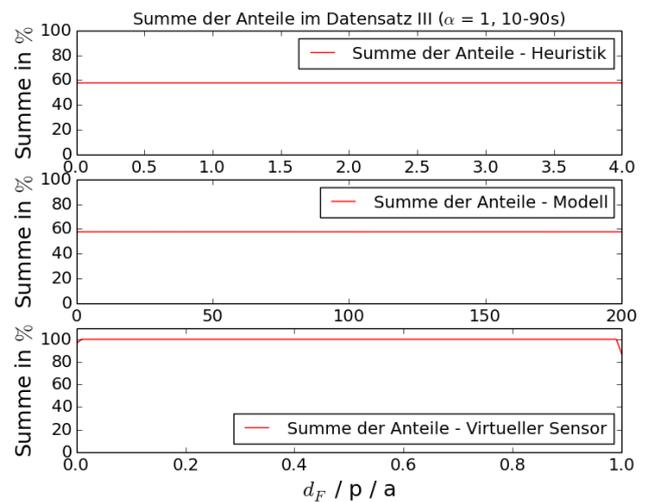
(a) Modellbasierte Fusion



(b) Heuristische Fusion

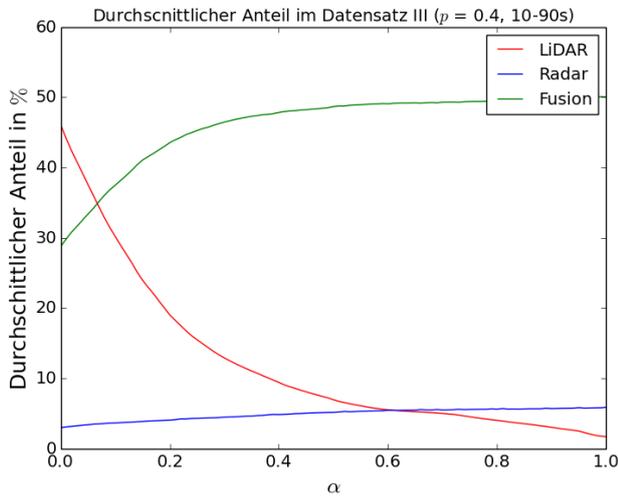


(c) Virtueller Sensor

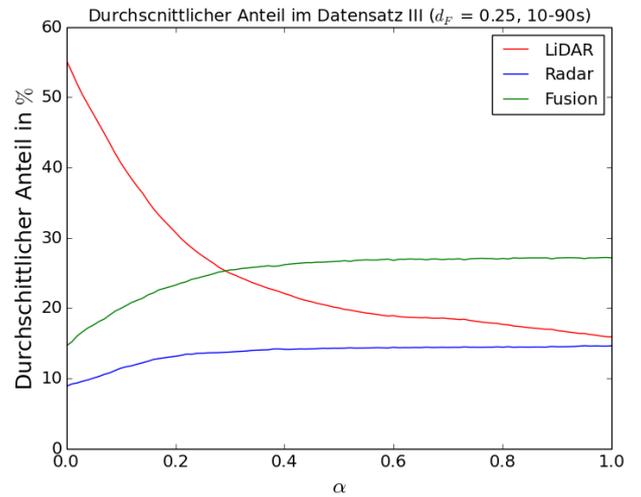


(d) Summe der Anteile

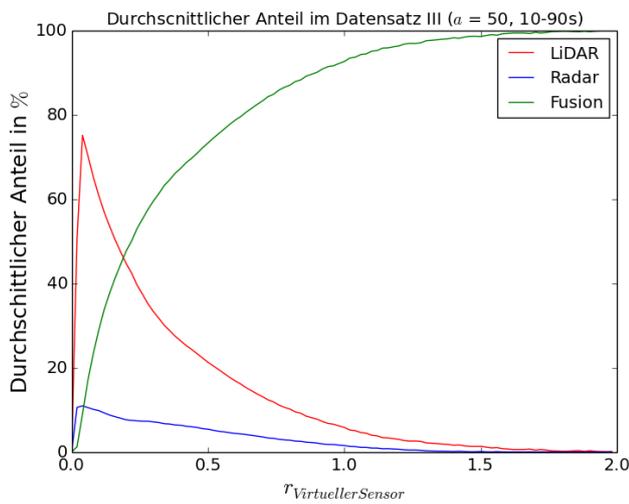
Abbildung 82: In den Diagrammen ist das Verhalten der Fusionsalgorithmen in Abhängigkeit der Parameter p, d_F und a dargestellt.



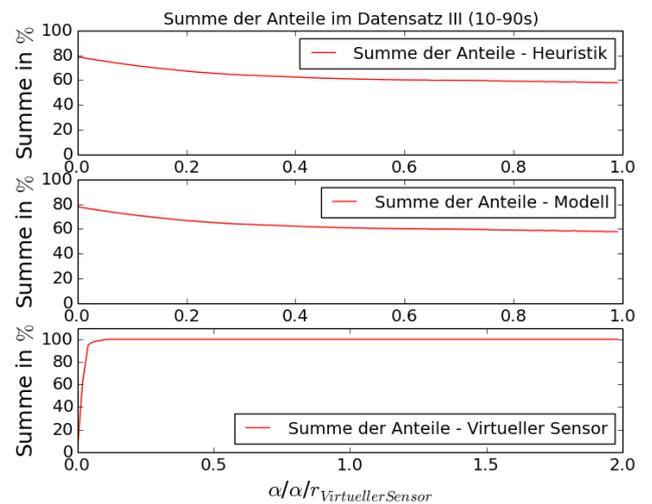
(a) Modellbasierte Fusion



(b) Heuristische Fusion

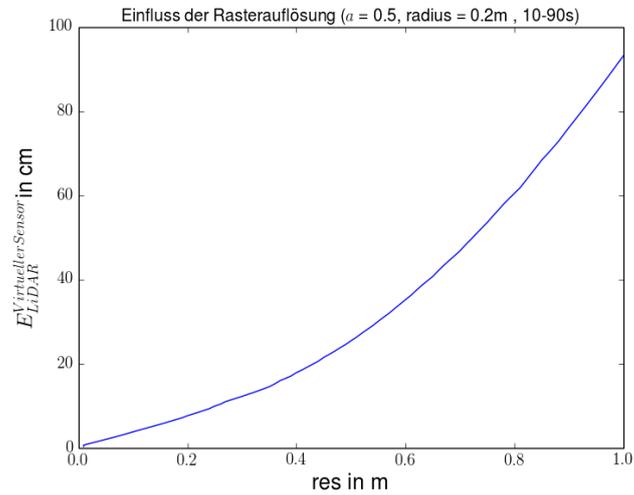


(c) Virtueller Sensor

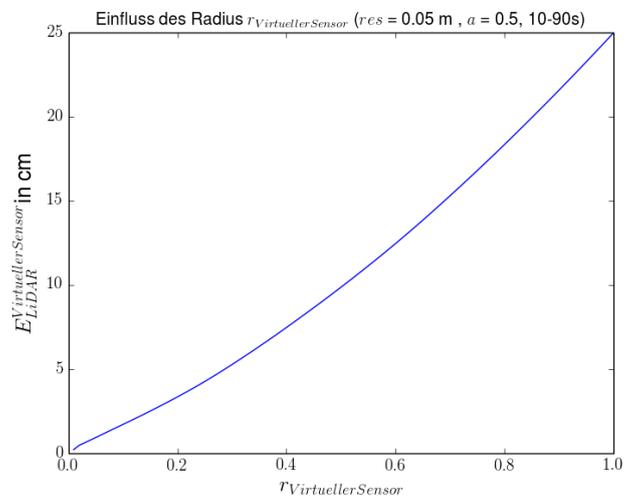


(d) Summe der Anteile

Abbildung 83: In den Diagrammen ist das Verhalten der Fusionsalgorithmen in Abhängigkeit der Parameter α und $r_{VirtuellerSensor}$ dargestellt.



(a) Verlauf des Fehlers $E_{LiDAR}^{VirtuellerSensor}$ in Abhängigkeit der Rasterauflösung res .



(b) Verlauf des Fehlers $E_{LiDAR}^{VirtuellerSensor}$ in Abhängigkeit des Sensormodells

Abbildung 84: Einfluss der Rasterauflösung und des Radius auf die Genauigkeit des virtuellen Sensors

6.2.2 Einfluss der Liniextraktion in der Vorverarbeitung

In Kapitel 4.4.1 (Seite 61) wird vorgestellt, dass mit einer Liniextraktion im LiDAR-Scan abgeschätzt werden kann, ob der LiDAR-Scanner freie Sicht hat (nicht von Aerosol beeinträchtigt wird). Im Fall der modellbasierten Fusion wird dies durch sig_{FS} realisiert. Bei der heuristischen Fusion wird dieser Fall durch die Heuristik zum Fall E⁷⁷ (Tabelle im Anhang 7, Seite 136) ausgedrückt. Beim virtuellen Sensor werden die entsprechenden LiDAR-Messwerte mit stärkerer Gewichtung in das Raster M_{LiDAR} eingetragen.

Die Untersuchung der Anteile der jeweiligen Fusionsfälle $A_{Fusionsfall}$ soll zeigen, wie sich situationsabhängig der fusionierte Scan zusammensetzt. Da Radar-Scanner ungenauer als LiDAR-Scanner sind, müssen sich in einer Umgebung ohne Aerosolpartikel mehrheitlich fusionierte Messungen und LiDAR-Messungen im fusionierten Scan befinden. Radarmessungen müssen demzufolge minimal sein. Für die Evaluierung wird der Datensatz I (Flur in Hannover, Anhang A.3.2, Seite 141) verwendet, da hier keine störenden Aerosolwolken enthalten sind. Wie in der Tabelle 7 in Anhang 7 beschrieben ist, können Ausreißer seitens des Radar-Scanners vermindert werden, indem im LiDAR-Scan Linien segmentiert und dem Radar vorgezogen werden (Heuristik E). Die Abbildung 85 stellt den Verlauf der Radaranteile im fusionierten Scan im Datensatz I dar.

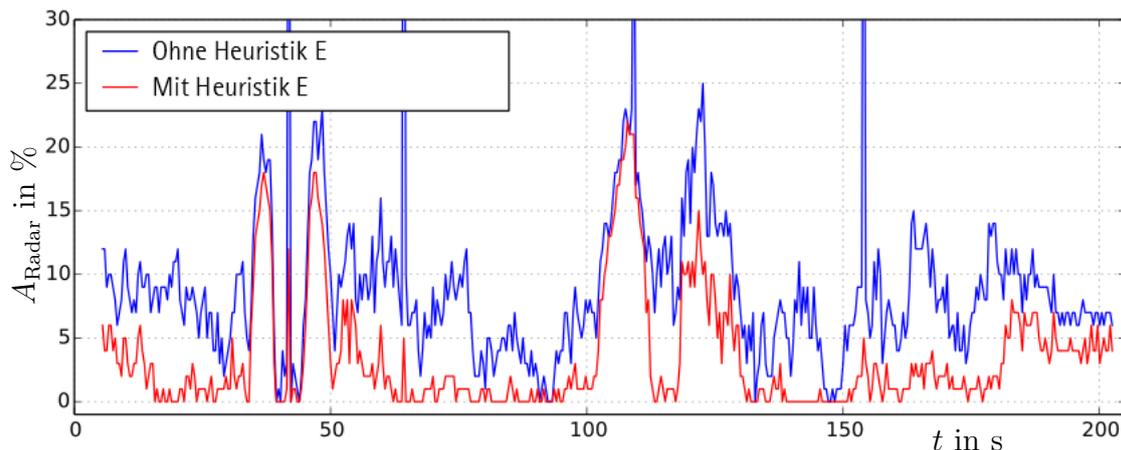


Abbildung 85: Anteil der Radarmessungen in % im fusionierten Scan im Verlauf des Flurexperiments (Datensatz I).

In Abbildung 85 ist deutlich erkennbar, dass die Heuristik E dazu führt, dass fusionierte Scans weniger Radar-Messungen enthalten. Dieser Effekt tritt in allen Datensätzen auf, was anhand der durchschnittlichen Anteile der einzelnen Fusionsfälle bezogen auf die Dauer des Datensatzes in der Tabelle 5 dargestellt wird. Da in allen Datensätzen nicht permanent Nebel präsent ist, lässt sich quantitativ für alle Datensätze die gleiche Aussage treffen.

⁷⁷Bezüglich der heuristischen Fusion wird dieser Fall hier *Heuristik E* genannt.

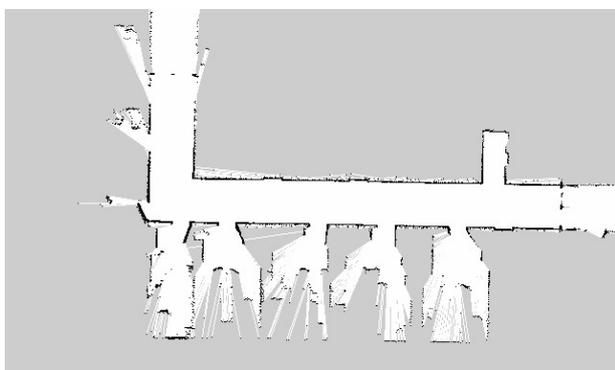
In Tabelle 5 ist zu erkennen, dass die Heuristik E den Anteil an Radar-Messungen verringert und den Anteil an LiDAR-Messungen erhöht. Der Anteil der fusionierten Messpunkte ist unabhängig von der Heuristik E, da der Anteil der fusionierten Messpunkte nur vom euklidischen Abstand eines korrespondierenden Punktepaars abhängig ist, was durch d_F definiert wird. Im Datensatz I (Flur in Hannover, Anhang A.3.2, Seite 141) ist weiterhin deutlich zu erkennen, dass die Zahl an unbrauchbaren, bzw. unendlichen Messungen (inf) reduziert wird. Der Anteil an unendlichen Messungen ist im Datensatz II (Hof in Hannover, Anhang A.3.3, Seite 142) verhältnismäßig hoch, da hier die Umgebung eine freie Fläche aufweist. Im Datensatz III (Garage in Wien, Anhang A.3.4, Seite 143) sind viele LiDAR-Messungen unendlich, da es in der Experimentierumgebung zum Typ-II-Effekt kommt.

Tabelle 5: Durchschnittliche Zusammensetzung des fusionierten Scans S_{Fusion} aus der heuristischen Fusion in den Datensätzen I-III (Datensatz I - Flur in Hannover, Anhang A.3.2, Seite 141), (Datensatz II - Hof in Hannover, Anhang A.3.3, Seite 142), (Datensatz III - Garage in Wien, Anhang A.3.4, Seite 143).

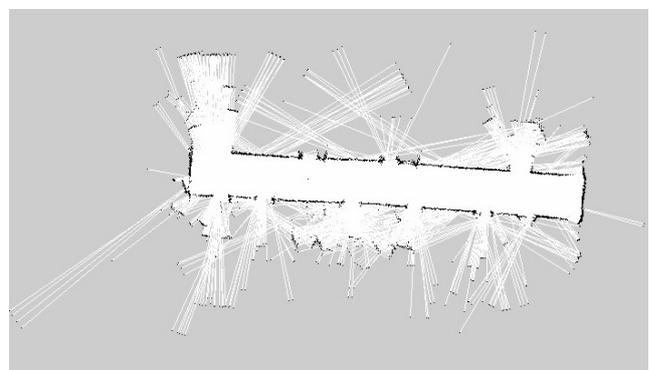
Datensatz	Untersuchungspunkt	LiDAR	Radar	Fusion	inf
I	Ohne Heuristik E \emptyset in %	32.97	9.38	37.78	19.58
	Mit Heuristik E \emptyset in %	54.99	3.87	37.78	3.34
II	Ohne Heuristik E \emptyset in %	52.35	5.23	16.76	25.65
	Mit Heuristik E \emptyset in %	63.64	2.86	16.76	16.72
III	Ohne Heuristik E \emptyset in %	19.98	43.02	8.33	28.65
	Mit Heuristik E \emptyset in %	22.49	42.32	8.33	26.84

6.2.3 Einfluss der LiDAR-Radar-Fusion auf die Qualität von Rasterkarten

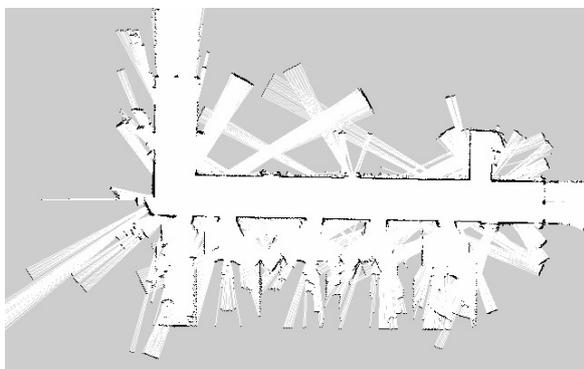
Ein geringerer Anteil an Radar-Messwerten im fusionierten Scan wirkt sich auch positiv auf die Kartenqualität aus. Zur Evaluierung wurden vier Karten mit dem Datensatz I (Flur in Hannover, Anhang A.3.2, Seite 141) aufgebaut. In Abbildung 86a ist die Karte abgebildet, die mit LiDAR-Scans erzeugt wurde. In Abbildung 86b ist die Karte abgebildet, die mit dem MPR erzeugt wurde. In der Karte ist zu erkennen, dass diverse Ausreißer zu einem schlechteren Kartenergebnis führen. Die beste Karte, die mit fusionierten Scans aufgebaut wird, muss dementsprechend der LiDAR-Karte 86a ähnlich sein. In Abbildung 86c ist die Karte abgebildet, die mit dem heuristischen fusionierten Scan und ohne Vorabschätzung für schlechte Sicht (Heuristik E) aufgebaut wurde. In Abbildung 86d wurde eine Karte mit dem fusionierten Scan und Vorabschätzung für schlechte Sicht aufgebaut. Allgemein betrachtet sind in der Karte in Abbildung 86d weniger Ausreißer zu erkennen als in der Karte in Abbildung 86c.



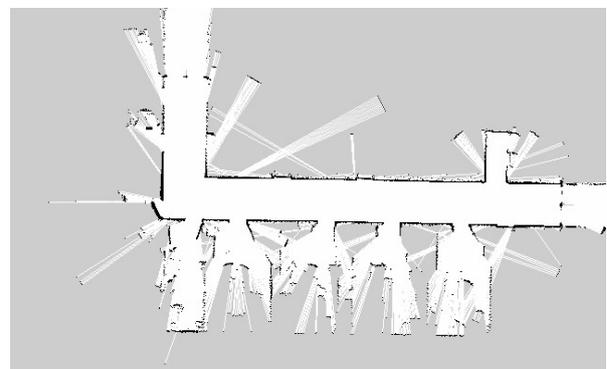
(a) LiDAR-Karte ($V_M = 110335$ Zellen, $\tau_{bin} = -$)



(b) Radar-Karte ($V_M = 108058$ Zellen, $\tau_{bin} = 2240$)



(c) Fusionskarte ohne Heuristik E ($V_M = 149250$ Zellen, $\tau_{bin} = 1738$)



(d) Fusionskarte mit Heuristik E ($V_M = 128621$ Zellen, $\tau_{bin} = 1604$)

Abbildung 86: Gegenüberstellung von LiDAR-, Radar- und Fusionskarten und Verdeutlichung des Einflusses der Heuristik E.

Zur Evaluierung der Kartenunterschiede wird das Kartenvolumen V_M und der Mapscore τ herangezogen. Nach Martins [MM96] setzt sich der Map Score τ aus der Differenz der korrespondierenden Zellwerte von zwei Karten zusammen. Da ein Schwellwert entscheidet, ob eine Zelle belegt, frei oder unbekannt ist, schlägt Langerwisch [Lan14, S. 111] den binären Map Score τ_{BIN} vor. Gegenüber Martins Map Score summiert Langerwisch den binären Map Score τ_{BIN} um +1, wenn eine Zelle in der Ground-Truth-Karte belegt ist und die korrespondierende Zelle in der Referenzkarte frei oder

unbekannt ist. Das Kartenvolumen ist die Summe aller belegten und freien Zellen. Mit dem Map Score und dem Kartenvolumen kann eine Karte mit einer Ground-Truth-Karte verglichen werden. Hier wird die LiDAR-Karte als Ground-Truth-Karte verwendet (Karte in Abbildung 86a).

Das höchste Kartenvolumen, der in Abbildung 86 vorgestellten Karten, hat die Fusionskarte ohne Liniensegmentierung. Das Kartenvolumen kann nicht direkt zu einer Aussage über die Kartenqualität herangezogen werden. Jedoch ist sichtbar, dass mit Heuristik E das Kartenvolumen zu dem der LiDAR-Karte tendiert. Der binäre Map Score tendiert gegen Null, wenn die Karten identisch sind. Da diese Größe nicht genormt ist und stark von der Umgebung abhängig ist, kann nur die Aussage getroffen werden, dass ein kleinerer Wert eine größere Ähnlichkeit zur Referenzkarte darstellt (siehe Karte 86d).

Zusammenfassend ist zu sagen, dass der Anteil an Radarmessungen im fusionierten Scan einen Einfluss auf die Kartenqualität hat. Wenn eine Vorabschätzung für das Vorhandensein für schlechte Sicht vollzogen wird, kann der Anteil an Radarmessungen im fusionierten Scan verringert und somit die Kartenqualität verbessert werden.

6.2.4 Integration von virtuellen 2D-Scans in der Vorverarbeitung

Bei der Integration von virtuellen 2D-Scans entstehen zwei fusionierte Scans. Der Scan $S_{Fusion,Kart./Lok.}$ ist für die Kartierung und Lokalisierung, und der Scan $S_{Fusion,Nav.}$ zu Objektvermeidung und Lokalisierung geeignet. In der Tabelle 6 sind die durchschnittlichen Anteile der Fusionsfälle dargestellt, wenn 3D-LiDAR-Scanner⁷⁸ in die heuristische Scan-Fusion integriert werden. Im Vergleich zur Tabelle 5 (Seite 110) ist erkennbar, dass die Integration von virtuellen 2D-Scans den Radaranteil verringert.

Tabelle 6: Durchschnittliche Zusammensetzung der fusionierten Scans $S_{Fusion,Kart./Lok.}$ und $S_{Fusion,Nav.}$. (Datensatz I - Flur in Hannover, Anhang A.3.2, Seite 141), (Datensatz II - Hof in Hannover, Anhang A.3.3, Seite 142), (Datensatz III - Garage in Wien, Anhang A.3.4, Seite 143).

Datensatz	Untersuchungspunkt	LiDAR	Radar	Fusion	inf
I	$S_{Fusion,Kart./Lok.} A^\emptyset$ in %	55.87	2.22	38.25	3.66
	$S_{Fusion,Nav} A^\emptyset$ in %	32.26	8.07	39.27	20.39
II	$S_{Fusion,Kart./Lok.} A^\emptyset$ in %	62.57	2.57	16.11	18.74
	$S_{Fusion,Nav} A^\emptyset$ in %	36.67	12.72	14.79	35.8
III	$S_{Fusion,Kart./Lok.} A^\emptyset$ in %	33.52	38.65	5.69	22.12
	$S_{Fusion,Nav} A^\emptyset$ in %	71.99	6.02	9.96	12.01

Die Integration von virtuellen 2D-Scans ist besonders in Umgebungen mit verteilten kleineren Hindernissen (Möbel, Personen, etc.) vorteilhaft, da der Scan $S_{Fusion,Kart./Lok.}$ die Raumstruktur ohne Hindernisse auffasst. Hindernisse hingegen werden separat im Scan $S_{Fusion,Nav}$ erfasst.

⁷⁸Velodyne VLP-16

In Abbildung 87 wird dargestellt, dass mit virtuellen 2D-Scans im Fall der heuristischen Scan-Fusion der höchste Anteil an Lidar-Messwerten in Umgebungen ohne schlechte Sicht erzielt werden kann. Im Kartenvergleich in der Abbildung 86 (Seite 111) wurde bereits festgestellt, dass in Umgebungen ohne schlechte Sicht ein besseres Ergebnis erzielt wird, je mehr LiDAR-Messungen im fusionierten Scan sind.

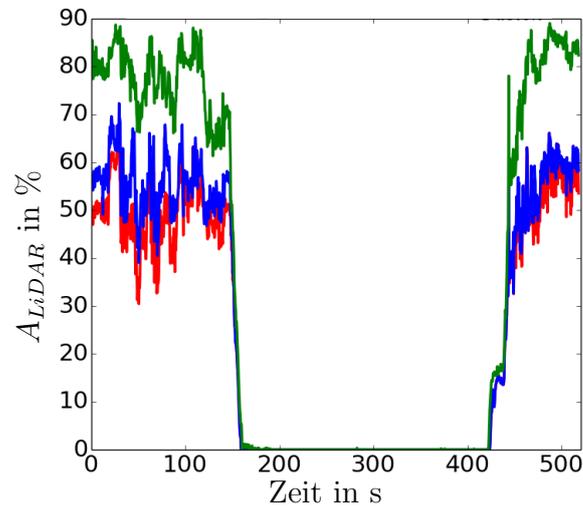


Abbildung 87: LiDAR Messwerte im heuristischen fusionierten Scan im Verlauf des Datensatzes III (Mit virtuellen 2D-Scans, Mit Heuristik E, Ohne Heuristik E). Im Zeitraum von 150s - 450s befindet sich die Plattform im dichten Nebel und kann dementsprechend keine LiDAR-Messungen verwenden.

6.2.5 Reaktion der LiDAR-Radar-Fusion auf den Typ-I-Effekt

Das geforderte Verhalten der Scan-Fusion auf den Typ-I-Effekt ist in einer Momentaufnahme in Abbildung 88 dargestellt. Abbildung 88a zeigt den Typ-I-Effekt am LiDAR-Scan, der im Datensatz II (Hof in Hannover, Anhang A.3.3, Seite 142) auftritt. Aus Abbildung 88b ist zu entnehmen, dass der MPR den Nebel nicht detektiert. Im fusionierten Scan (88c) werden die betroffenen LiDAR-Messungen durch Radarmessungen (grün) ersetzt. Die gelben Messpunkte in der Abbildung 88c stellen fusionierte Messpunkte dar.

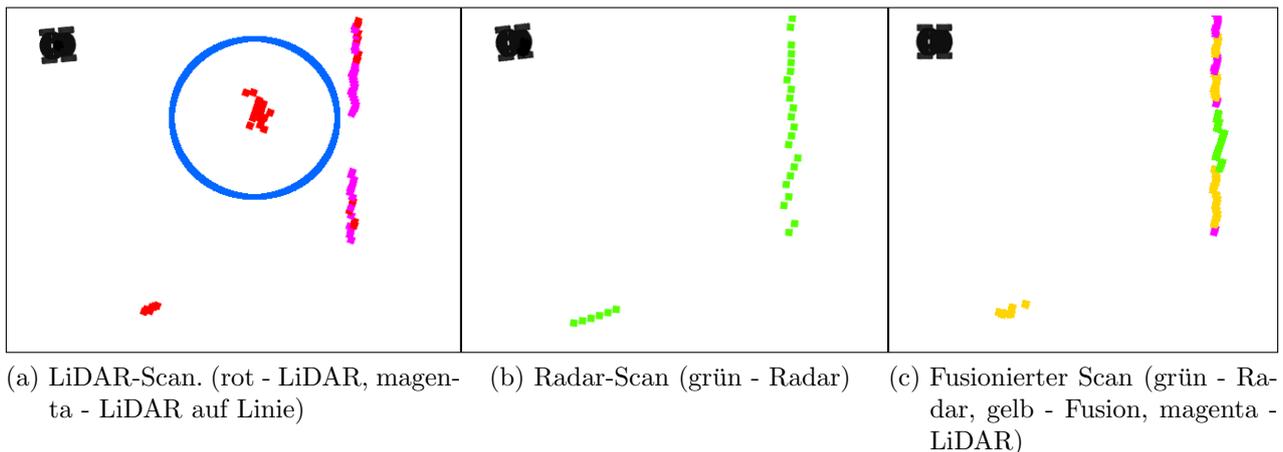


Abbildung 88: Reaktion der Scan-Fusion (Heuristik) auf den Typ-I-Effekt

Im Datensatz II ist der Typ-I-Effekt sichtbar. Dies bedeutet, dass sich im LiDAR-Scan Messungen befinden, die für die Kartierung oder Lokalisierung nachteilig sind. Dementsprechend müssen die LiDAR-Messungen, die Nebel detektieren, mit Radar-Messungen im fusionierten Scan belegt werden. Um zu überprüfen, inwiefern die Scan-Fusion dieses Problem behebt, wird im Datensatz II eine Kontrollfläche A_K über die freie Fläche gespannt (siehe Abbildung 89).

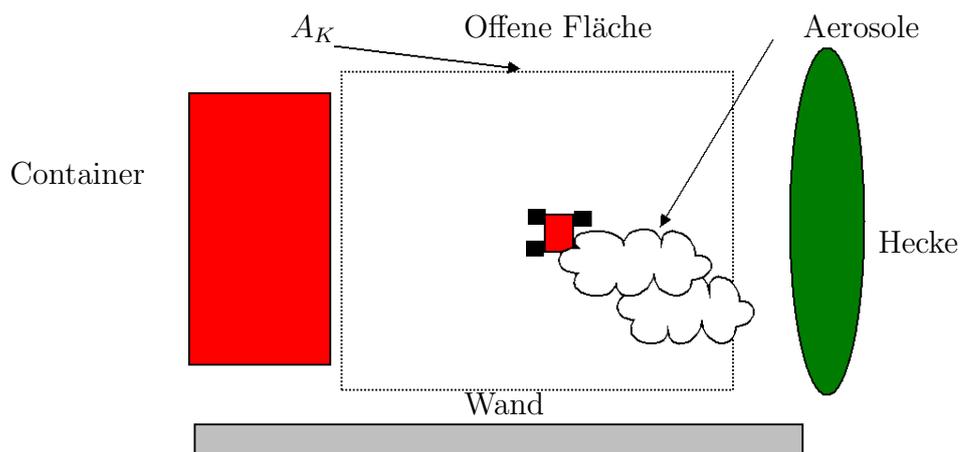
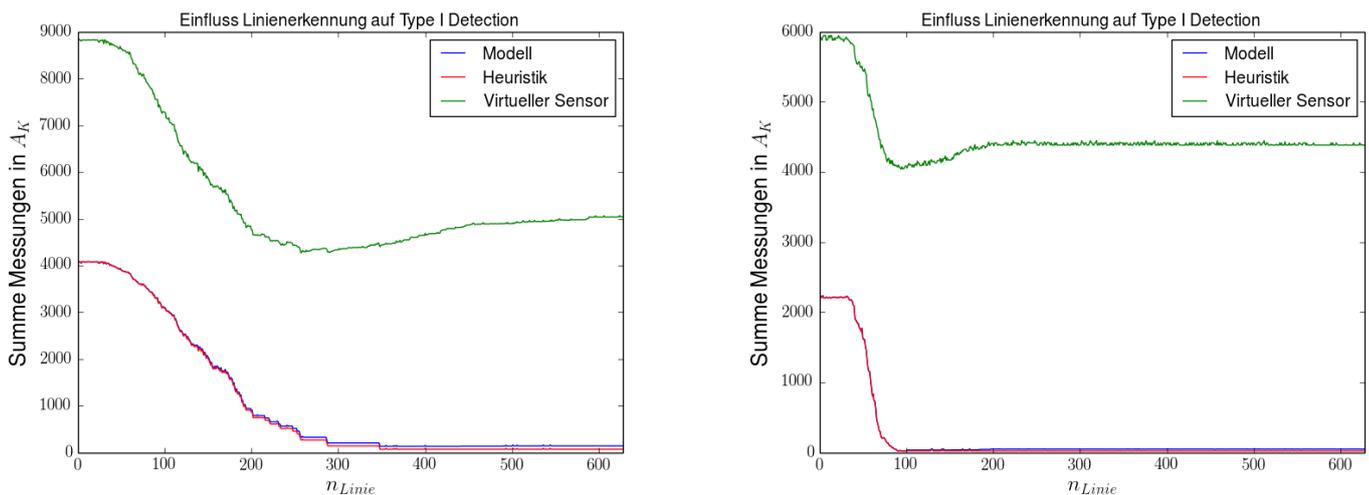


Abbildung 89: Datensatz II (Hof in Hannover, Anhang A.3.3, Seite 142). Die Kontrollfläche A_K wird um die freie Fläche gelegt, in der sich keine Objekte befinden. Somit entsprechen Messpunkte innerhalb dieser Fläche Detektionen von Aerosolen.

Die Anzahl der Messungen innerhalb der Kontrollfläche wird über den Zeitraum des Datensatzes aufsummiert (Am Anfang und Ende des Datensatzes befindet sich für insgesamt ca. 10 s eine Person innerhalb der Kontrollfläche. Dieser Zeitabschnitt wird nicht beachtet.). Alle weiteren Messungen innerhalb der Kontrollfläche stammen von Detektionen des Nebels. Im untersuchten Zeitraum kommt es zu 7157 Detektionen mit S_{LiDAR} . Der virtuelle 2D-Scan $S_{LiDAR,Kart./Lok.}$ weist 5120 Detektionen auf, wodurch geschlussfolgert werden kann, dass virtuelle 2D-Scans zur Kartierung und Lokalisierung weniger vom Typ-I-Effekt betroffen sind.

Die Vorabschätzung per Linienerkennung wirkt sich positiv auf die LiDAR-Radar-Fusion aus (Kapitel 6.2.2). In Tabelle 5 (Seite 110) ist zu erkennen, dass mit der Linienerkennung der LiDAR-Anteil A_{LiDAR} erhöht und damit die Kartenqualität verbessert wird (siehe auch Abbildung 86, Seite 111). Die Linienerkennung hat auch einen Einfluss auf die Behebung des Type-I-Effektes. Der wichtigste Stellparameter der Linienerkennung ist die minimale Anzahl an Punkten n_{Linie} , die als Linie erkannt werden. Ein sehr niedriges n_{Linie} hat den Effekt, dass auch in detektierten Aerosolwolken Linien hineingelegt werden können. Im Gegensatz dazu sinkt die Anzahl an detektierten Linien in den Scans, wenn n_{Linie} erhöht wird. In der Abbildung 90 ist die Anzahl der aufsummierten Detektionen in der Kontrollfläche A_K in Abhängigkeit von n_{Linie} dargestellt.



- (a) Bei steigendem n_{LiDAR} wird der Typ-I-Effekt besser behoben, jedoch befinden sich auch mehr Radarmessungen im fusionierten Scan, was wiederum zu einer schlechteren Kartenqualität führt.
- (b) Durch die Integration von virtuellen 2D-Scans sinkt die Zahl an detektierten Aerosolpartikeln

Abbildung 90: Die Diagramme zeigen die Anzahl an Nebeldetektionen im Datensatz II (Hof in Hannover, Anhang A.3.3, Seite 142) in Abhängigkeit des Parameters n_{LiDAR}

In Abbildung 90a ist erkennbar, dass die modellbasierte und heuristische Fusion ein sehr ähnliches Verhalten bezüglich der Behebung des Typ-I-Effektes aufweisen. Die minimale Linienlänge n_{Linie} geht von 1 bis 628 Messpunkten⁷⁹. Je kleiner n_{Linie} , desto öfter werden Linien in die Aerosolwolke gelegt und dem fusionierten Scan hinzugefügt. Weiterhin ist in Abbildung 90a zu sehen, dass der virtuelle Sensor den Typ-I-Effekt schlechter behebt. Dies liegt daran, dass die Szene im Datensatz II

⁷⁹Die Anzahl an Messungen in einem fusionierten Scan ist in diesem Experiment 628.

eine offene Fläche aufweist. Wenn Nebel vor einer offenen Fläche detektiert wird, dann ist dies an dieser Stelle das einzige Maximum im fusionierten Raster M_{Fusion} , jedoch ist zu beachten, dass ein Scan des virtuellen Sensors generell mehr brauchbare Messwerte beinhaltet. Für den virtuellen Sensor kann jedoch sehr gut der optimale Parameter, um den Typ-I-Effekt zu beheben, abgelesen werden. Da ein kleiner n_{LiDAR} Wert bei guter Sicht eine bessere Kartenqualität bedeutet, jedoch dadurch der Type-I-Effekt nicht so gut behoben werden kann, wird für n_{LiDAR} ca. 300 Punkte empfohlen (Abbildung 90a).

In Abbildung 90b ist die Summe der Nebeldetektionen dargestellt, die im fusionierten Scan und virtuellen 2D-Scans in der Vorverarbeitung entstehen. Bei der Integration von virtuellen 2D-Scans ist zu erkennen, dass es zu weniger Detektion kommt, und dass für n_{LiDAR} ein kleinerer Wert ausreichend ist. Die Integration von virtuellen 2D-Scans in die Scan-Fusion bewirkt demzufolge eine bessere Kartenqualität und ein besseres Beheben des Typ-I-Effektes.

Der Datensatz II weist einen Sonderfall auf, der nur sehr schwierig mit der Sensorfusion zu lösen ist. Im Datensatz II befinden sich drei große Objekte. Der Container, die Wand und die Hecke sind statische Objekte und können mit LiDAR-Scannern detektiert werden. Die Hecke wird jedoch nicht vom MPR detektiert. Demzufolge stellt die Hecke ein radardurchlässiges Ziel dar und ist somit zu Aerosolwolken ähnlich. Wenn jedoch im LiDAR-Scan Linien extrahiert werden können, dann kann dieser Fall unterschieden werden (Tabelle 7.E, Seite 136). Um zu evaluieren, ob in dieser Situation die Linienerkennung oder virtuelle 2D-Scans zu einer Verbesserung führen, wird um die Hecke eine Kontrollfläche A_K aufgespannt (Abbildung 91). Zur Evaluierung wird für den Datensatz II die Anzahl der fusionierten Punkte gezählt, die die Hecke erkennen.

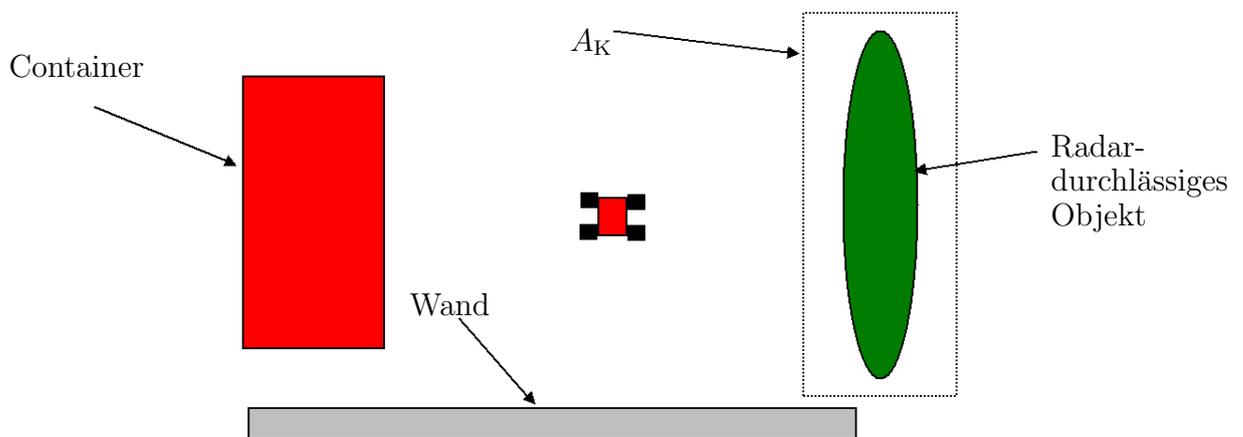
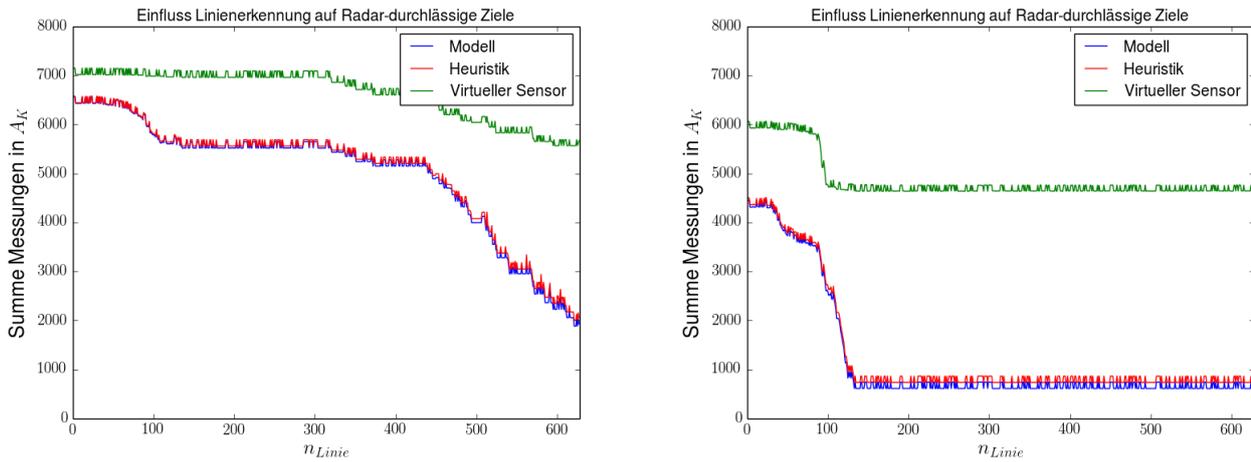


Abbildung 91: Umgebung im Datensatz II (Hof in Hannover, Anhang A.3.3, Seite 142). Die Kontrollfläche A_K wird um die Hecke gelegt.

In der Abbildung 92 ist zu erkennen, dass die modellbasierte und heuristische Fusion quasi einen identischen Verlauf aufweisen. Der virtuelle Sensor behebt schlechter den Typ-I-Effekt, jedoch hat demzufolge weniger Probleme bei radardurchlässigen Objekten. In beiden Diagrammen ist zu erkennen, dass das Detektieren von radardurchlässigen Objekten besser wird, je kleiner n_{LiDAR} ist. Dieser Effekt steht dem Verhalten beim Typ-I-Effekt, das in den Diagrammen in der Abbildung 90 dargestellt wird, gegenüber.

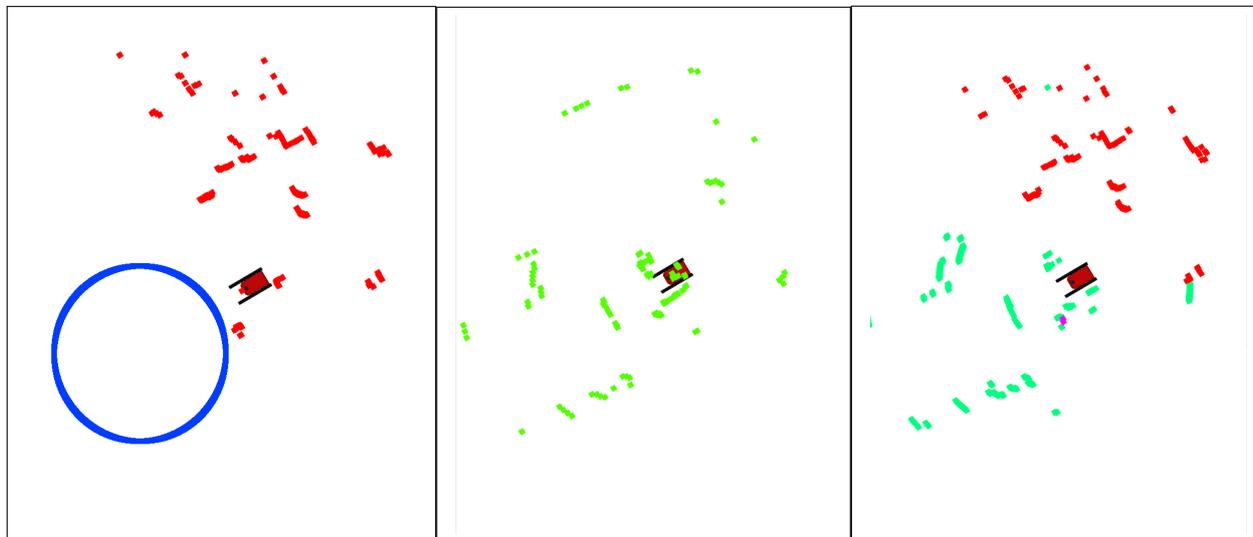


(a) Detektion eines radardurchlässigen Objektes in Abhängigkeit von n_{Linie} in(b) Detektion eines radardurchlässigen Objektes in Abhängigkeit von n_{Linie} mit integrierten virtuellen 2D-Scans

Abbildung 92: Bei steigendem n_{LiDAR} wird das radardurchlässige Objekt schlechter detektiert. Dieser Effekt steht dem Ergebnis aus den Diagramme der Abbildung 90 gegenüber.

6.2.6 Reaktion der LiDAR-Radar-Fusion auf den Typ-II-Effekt

Abbildung 93 zeigt eine Momentaufnahme der Scans im Datensatz III (Garage in Wien, Anhang A.3.4, Seite 143), bei der der Roboter in einen mit Nebel befüllten Raum hineinfährt (ähnlich zur Abbildung 107, Seite 143). Aufgrund der Dichte des Nebels tritt der Typ-II-Effekt auf.



(a) LiDAR-Scan (rot - LiDAR), absorbierte Messwerte (blauer Kreis) (b) Radar-Scan (grün - Radar) (c) Fusionierter Scan (grün Radar, rot - LiDAR)

Abbildung 93: Reaktion der Scan-Fusion (Heuristik) auf den Typ-II-Effekt

In Abbildung 94 ist M_{LiDAR} , M_{Radar} und M_{Fusion} dargestellt. In Abbildung 94a ist zu erkennen, dass in der Umgebung ohne Aerosol (Raum A), fast alle Zellen vom LiDAR erfasst wurden. In dem mit Nebel befüllten Raum B in der Abbildung 94b wurden alle Zellen vom Radar detektiert. Ein geringer Anteil an Radar-Messungen im fusionierten Scan bleibt jedoch auch bei freier Sicht bestehen, wodurch einige Zellen im Raum A auch von Radar-Messungen detektiert werden. In Abbildung 94c ist M_{Fusion} dargestellt.

Der Anteil an LiDAR-Messungen sinkt dementsprechend im Raum B.

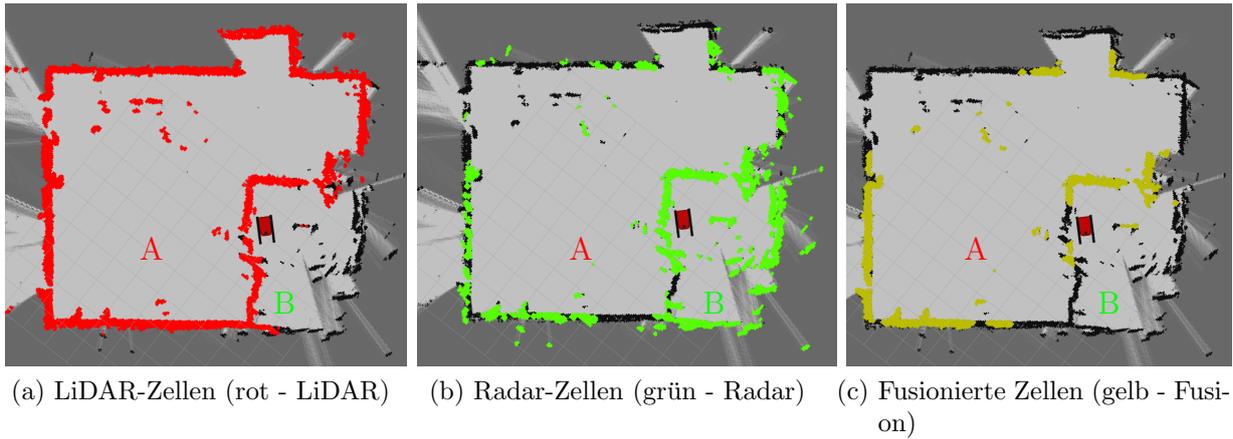
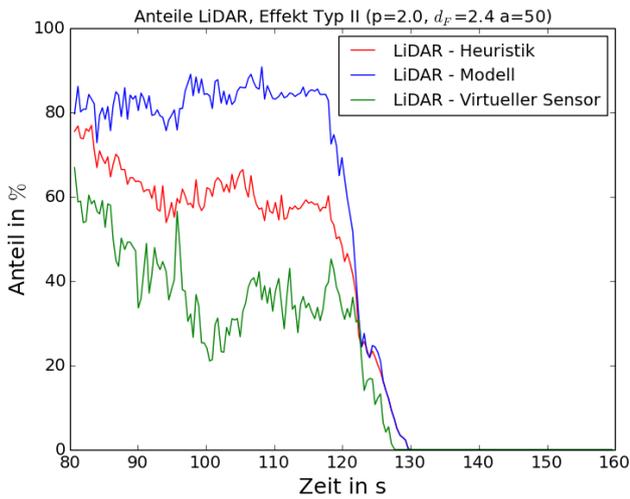
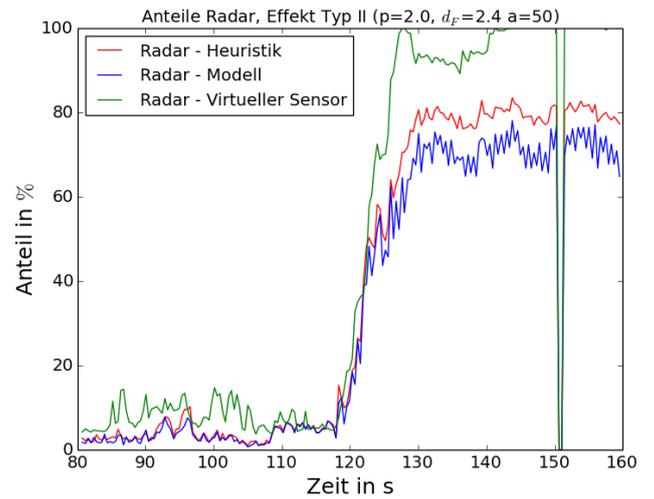


Abbildung 94: Im Raum B tritt der Typ-II-Effekt auf, wodurch nur Radar-Messungen sich im fusionierten Scan befinden.

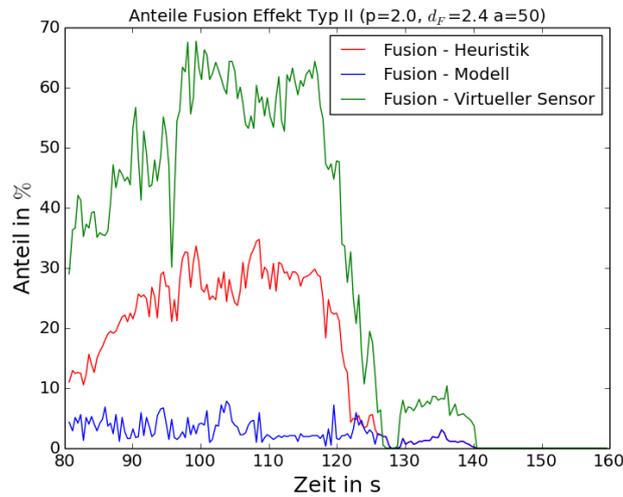
Alle drei Fusionsverfahren sind in der Lage auf den Typ-II-Effekt zu reagieren. In Abbildung 95 wird gezeigt, dass der fusionierte Scan im Raum B im Datensatz III (Garage in Wien, Anhang A.3.4, Seite 143) ausschließlich Radar-Messungen beinhaltet.



(a) LiDAR Anteile in S_{Fusion}



(b) Radar Anteile in S_{Fusion}



(c) Fusionierte Anteile in S_{Fusion}

Abbildung 95: Alle Fusionsverfahren reagieren richtig auf den Typ-II-Effekt

6.3 Metrische Umgebungsmodellierung mit Aerosolverteilungen

6.3.1 SLAM - Landmarken

Der Gegenstand der folgenden Untersuchungen bezieht sich auf das Extrahieren von Landmarken, welche sich zur Lokalisierung von mobilen Robotern in Umgebungen mit schlechten Sichtbedingungen eignen. Es soll untersucht werden, ob die Extraktionsmethode von Radarlandmarken aus Kapitel 5.2.1 (Seite 86) auf natürliche und künstliche Landmarken anwendbar ist. Für die Untersuchung wird der Datensatz I (Flur in Hannover, Anhang A.3.2, Seite 141) und II (Hof in Hannover, Anhang A.3.3, Seite 142) und der EKF-SLAM verwendet (Abbildung 96).

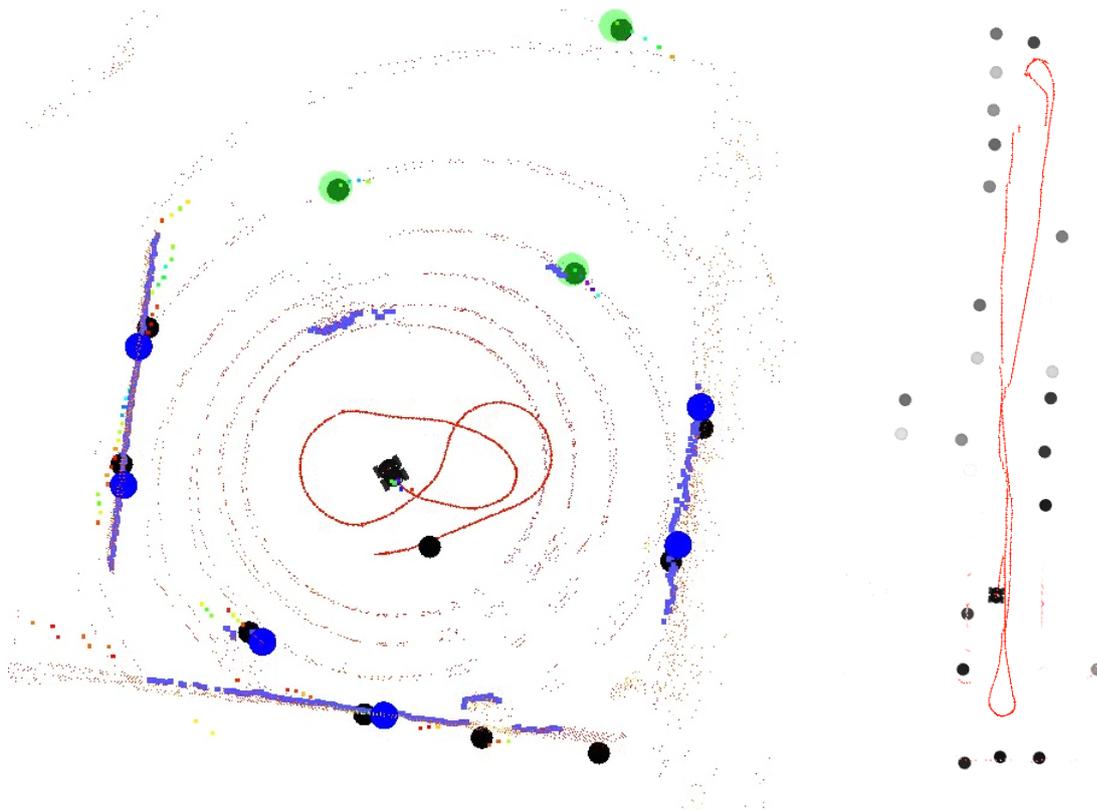


Abbildung 96: Links: Im Datensatz II (Hof in Hannover, Anhang A.3.3, Seite 142) können künstliche Landmarken erkannt werden. Die schwarzen Punkte stellen die Marken im Zustandsvektor z dar. Die grünen Marken spiegeln zum Aufnahmezeitpunkt detektierte Winkelreflektoren dar. Die blauen Marken stellen detektierte Reflektoren dar. Rechts: In strukturierten Umgebungen (Datensatz I, Flur in Hannover, Anhang A.3.2, Seite 141) befinden sich Gegenstände die die gleiche Eigenschaft wie Punktziele aufweisen. Somit kann sich auch ohne künstliche Landmarken lokalisiert werden.

Abbildung 96 demonstriert, dass eine Lokalisierung in einer Umgebung mit gestörter Sicht mit künstlichen Landmarken möglich ist. Bei den Experimenten wurde festgestellt, dass sich natürliche Landmarken, wie zum Beispiel Kanten und Ecken, auch für die Lokalisierung mit dem MPR eignen. Dabei muss das vorgestellte Verfahren zur Extraktion von Punktzielen verwendet werden.

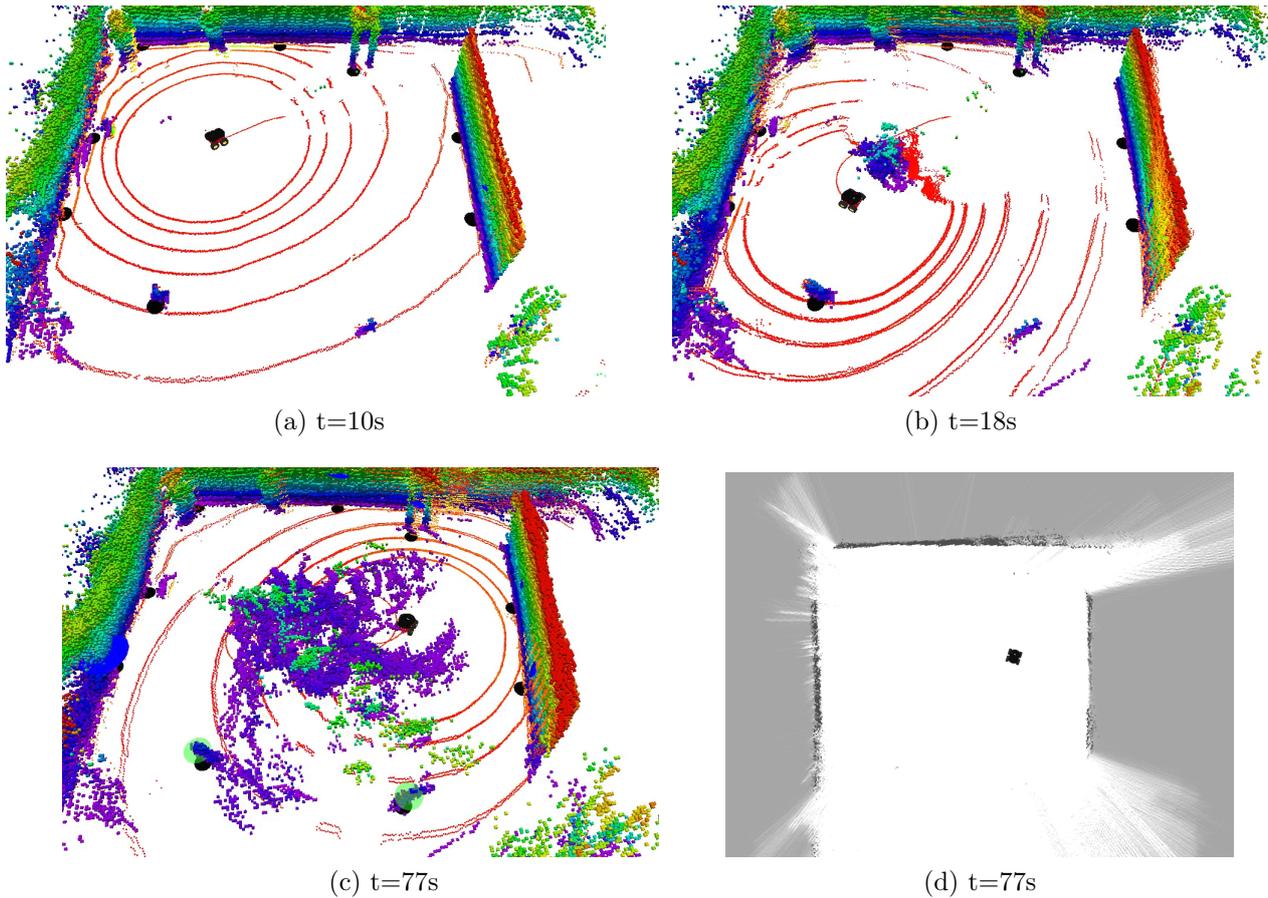
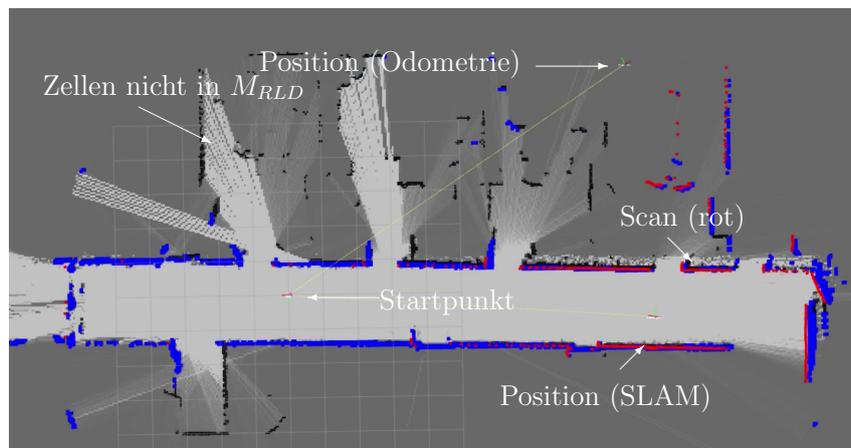


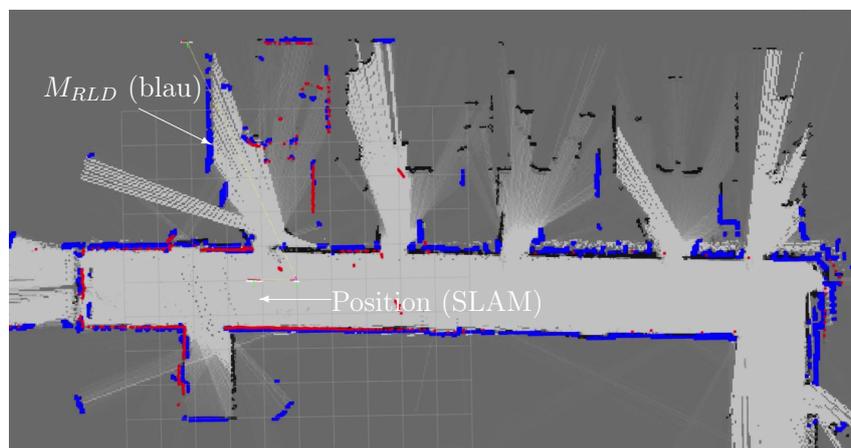
Abbildung 97: Mit künstlichen Landmarken für Radar und LiDAR kann trotz Nebel mit dem EKF SLAM und einem 3D Mapping eine 3D Karte erstellt werden. Durch den Typ-I-Effekt wird der Nebel auch kartiert. Die Integration der fusionierten Scans ermöglicht jedoch ein zweidimensionales Erstellen von Rasterkarten ohne Typ-I-Effekt.

6.3.2 SLAM - Registrierung

Das in dieser Arbeit vorgestellte SLAM-Verfahren basiert auf ICP-Registrierungen zwischen fusionierten Scans S_{Fusion} und der Rasterkarte M_{ICP} . Die Rasterkarte M_{ICP} setzt sich aus den Fusionsfällen und den Blickwinkeln für jede Zelle zusammen. In der Abbildung 94 (Seite 119) ist farblich dargestellt, dass jede Zelle von unterschiedlichen Fusionsfällen gesehen werden kann. Die Datenzuordnung im in dieser Arbeit vorgestellten ICP-Algorithmus unterscheidet neben dem Fusionsfall auch den Blickwinkel. In der Abbildung 98 ist die Robot-Location-Dependant-Karte M_{RLD} blau dargestellt. Der aktuelle Scan ist rot dargestellt. Die schwarzen Zellen sind auch belegt, jedoch werden sie für den ICP ignoriert, da sie von der aktuellen Roboterposition nicht gesehen werden können. Die Karte M_{RLD} verändert sich in Abhängigkeit der Roboterposition, was beim Vergleich der Abbildung 98a mit der Abbildung 98b deutlich wird.



(a) Durch das SLAM-Verfahren wird die Odometrie des Roboters korrigiert, sodass das Erstellen einer Rasterkarte ermöglicht wird.



(b) Die Robot-Location-Dependant-Karte M_{RLD} (blau) verändert sich in Abhängigkeit der Roboterposition, sodass nur Zellen mit Sichtkontakt für die ICP-Registrierung verwendet werden.

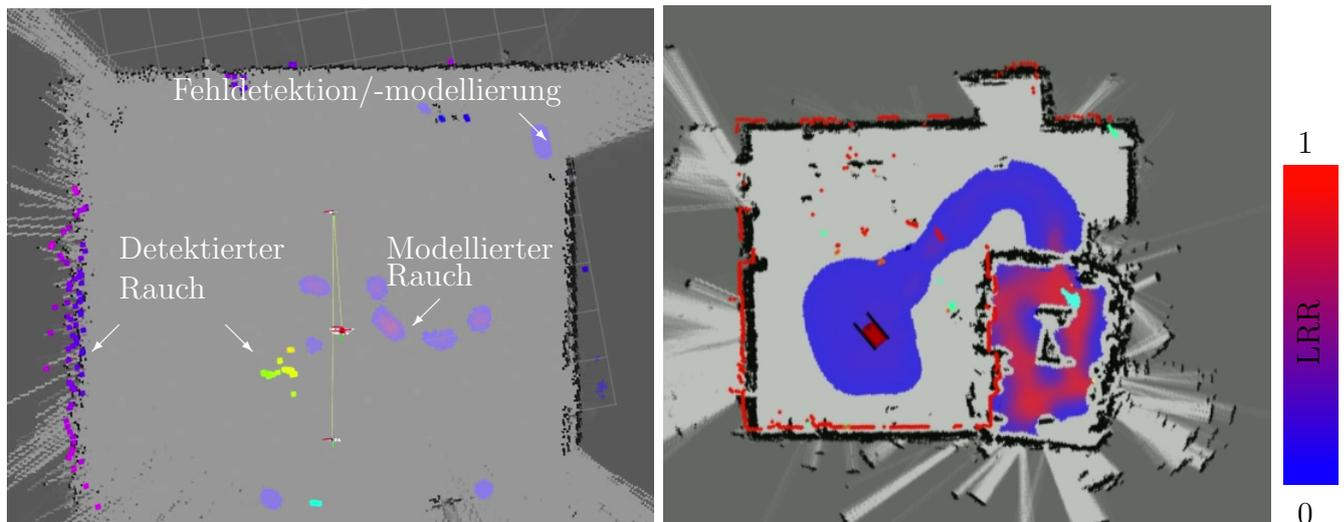
Abbildung 98: Die Robot-Location-Dependant-Karte M_{RLD} beinhaltet nur besetzte Zellen, die von der aktuellen Roboterposition gesehen wurden.

In der Abbildung 98a wird dargestellt, dass der SLAM-Algorithmus die Position des Roboters korrigiert (Position (SLAM)). Mit der Odometrie aus den Radgeberwerten des Roboters ist keine Kartie-

rung möglich (Position (Odometrie)).

6.3.3 Modellierung des LRR

Im Datensatz II (Hof in Hannover, Anhang A.3.3, Seite 142) wurde der Typ-I-Effekt und im Datensatz III (Garage in Wien, Anhang A.3.4, Seite 143) wurde der Typ-II-Effekt mit einer Nebelmaschine hervorgerufen. In Abbildung 99a ist die Detektion und Modellierung des Typ-I-Effektes mittels S_{Typ-I} dargestellt. Im Diagramm in Abbildung 85 (Seite 109) ist dargestellt, dass fusionierte Scans trotz freier Sicht Radarmessungen enthalten. Demzufolge können fälschlich detektierte Aerosolwolken nicht immer ausgeschlossen werden.



(a) In der Abbildung ist der Scan S_{TypI} dargestellt der sowohl Aerosolwolken als auch radardurchlässige Objekte detektiert. Fälschlich als Aerosol erkannte Objekte können jedoch nicht auf belegten Zellen liegen und werden somit unterschieden.

(b) Modellierung des LRR_{TypII} Effektes.

Abbildung 99: Die Abbildungen zeigen, dass durch die Fusionierung von LiDAR und Radar schlechte Sicht detektiert werden kann.

In Abbildung 99b wird deutlich, dass ein Modell, das schlechte Sichtbedingungen visualisiert, hilfreich für die menschliche Interpretation einer Umgebung ist. Der LRR_{Typ-I} beinhaltet jedoch stets Fehler aufgrund radardurchlässiger Objekte im Scan-Bereich. Daher ist der Verlauf nicht Null, wenn sich der Roboter in Raum A befindet.

Abbildung 100 stellt den zeitlichen Verlauf der LRR-Werte im Datensatz III (Garage in Wien, Anhang A.3.4, Seite 143) dar. Das Herein- bzw. Herausfahren des Roboters in den Raum B ist am Verlauf des LRR_{Typ-I} Wertes an den sprunghaften Verläufen erkennbar (rot eingekreist). Diese Sprünge entstehen in den Momenten, in denen die Tür zum Raum B geöffnet wird und der Roboter sich noch nicht im Raum B befindet. Dadurch kommt es seitens des LiDAR-Scanners zum Typ-I-Effekt und zeitgleich kann der Radar bereits Messungen von Raum B ermitteln. Sobald sich der Roboter im Raum B befindet, kommt es aufgrund des dichten Nebels zum Typ-II-Effekt.

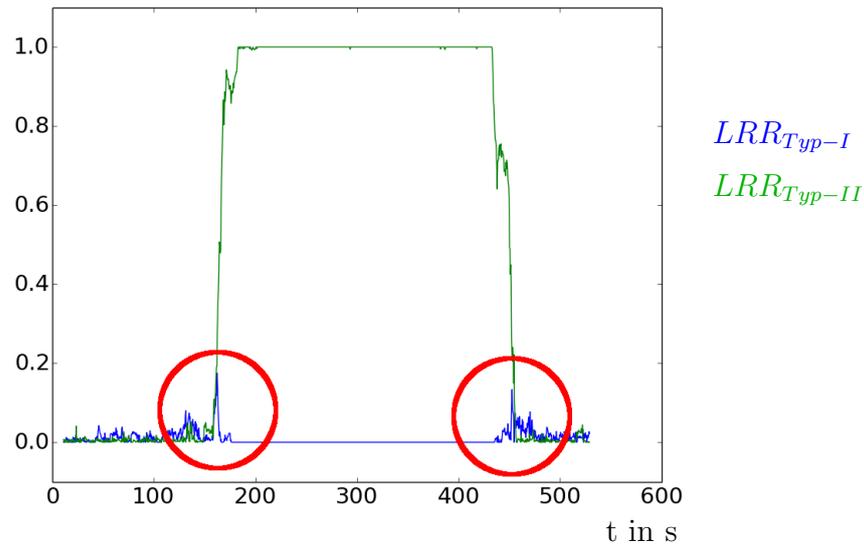


Abbildung 100: Im zeitlichen Verlauf der LRR-Werte ist deutlich erkennbar, wann sich die Plattform im Raum B befindet. Da im Raum B alle LiDAR-Messungen absorbiert werden oder unbrauchbar sind, ist im Raum B der $LRR_{Typ-II} = 1$. Beim Herein- bzw. Herausfahren aus dem Raum B kommt es zum Typ-I-Effekt (rote Kreise).

7 Bewertung, Diskussion und Ausblick

In dieser Arbeit wurden neue Messprinzipien mit Radarsensoren, LiDAR-Radar-Fusionsverfahren sowie die Modellierung von Aerosolverteilungen in metrischen Umgebungsmodellen experimentell untersucht. Das Ziel dieser Arbeit war es herauszufinden, mit welchen Verfahren Umgebungen, in denen Aerosole die Distanzwerte von LiDAR beeinträchtigen, mit Hilfe von Radarsensoren und mobilen Robotern modelliert werden können. Hierfür wurden diverse Messreihen und drei Datensätze (Kapitel A.3), teilweise in Gegenwart von Aerosolen, aufgenommen.

7.1 Vorbetrachtung: Neue Messprinzipien mit Radarsensoren

Kapitel 6.1.1-6.1.3 evaluiert den Laterations-Scanner. Die ersten Messergebnisse zeigen, dass typische Radarziele (Metallobjekte) detektiert werden können. Der Laterations-Scanner kann weiterhin die Position von Punktzielen im Nahbereich besser bestimmen als ein einzelner sich rotierender Radarsensor mit dem gleich Öffnungswinkel. Jedoch besteht das Problem, dass besonders in Gebäuden aufgrund der großen Distanzauflösung⁸⁰ selten geeignete Punktziele vorhanden sind. In diesem Fall messen einzelne Sensoren des Laterations-Scanners unterschiedliche Reflexionszentren, wodurch eine falsche Position berechnet wird. Dennoch zeigt der Vergleich mit dem ASR-Verfahren, dass Rasterkarten auch mit dem Laterations-Scanner erstellt werden können. Das Erstellen von Rasterkarten und das gleichzeitige Lokalisieren hat sich jedoch in unmodifizierten Umgebungen nicht bewährt. Um dennoch mit dem Laterations-Scanner einen mobiler Roboter zu lokalisieren, müssen Punktziele (z. B. Winkelreflektoren) in einer Umgebung künstlich platziert werden. Dabei ist bei der Positionierung der Landmarken auf Distanzauflösung und Öffnungswinkel der Sensoren zu achten, sodass keine Mehrdeutigkeiten entstehen. Ein Beispiel für die Positionierung ist in Kapitel 3.3.1 erläutert. Aufgrund der limitierten Bereiche für die Positionierung der Landmarken und der geringen Drehfrequenz des Scanners ist mit dem Laterations-Scanner oft nur eine Landmarken zu einem Messzeitpunkt detektierbar. Daher eignet sich der EKF-SLAM als SLAM-Verfahren. Die Möglichkeit der Lokalisierung eines mobilen Roboters mit dem Laterations-Scanner ist in Kapitel 6.1.3 aufgezeigt. Somit ist zwar das Proof of Concept erfüllt, jedoch erschweren die genannten Einschränkungen einen praxisnahen Einsatz des Verfahrens.

Kapitel 6.1.4 untersucht das SEABED-Verfahren sowohl in der Simulation als auch in realen Experimenten. Der Ansatz besteht darin, eine synthetische Apertur entlang des Pfades eines Roboters zu bilden. Der Ansatz bewährt sich nur in der Simulation unter der Annahme, dass die Distanzmessungen keine Messfehler aufweisen. Sobald zu den Distanzmessungen ein normal-verteiltes Rauschen addiert wird, führt das SEABED-Verfahren zu sehr ungenauen Ergebnissen. Auch der von Sakamoto [Sak07] eingeführte Faktor zur Unterdrückung des Rauschens erzielt bei den Messwerten, die in dieser Arbeit aufgenommen wurden, kein Ergebnis, das für die Robotik verwendet werden kann. Neben dem Sensorrauschen führt die Eigenbewegung des Roboters zu einer zusätzlichen Verschlechterung des Verfahrens. Somit ist das SEABED-Verfahren zur Kartierung in der mobilen Robotik mit den im Rahmen dieser Arbeit verfügbaren Sensorik nicht geeignet. Neben dem SEABED-Verfahren existieren weitere SAR-Verfahren, die hier nicht untersucht werden. Eine Gegenüberstellung diverser SAR-Algorithmen für den Einsatz in der mobilen Robotik muss in weiteren Arbeiten aufgegriffen werden.

⁸⁰Distanzauflösung des *iSYS4004* wurde per Experiment auf ca. 1 m bestimmt.

7.2 LiDAR-Radar-Fusionsverfahren

In dieser Arbeit wird eine Klassifizierung der Effekte auf LiDAR-Scanner im Rahmen einer Voruntersuchung dargestellt. In Kapitel 4.1 ist beschrieben, dass wenn LiDAR-Scanner Aerosolpartikel detektieren, die Lokalisierung und Kartierung eines Roboters aufgrund mangelnder statischer Strukturen beeinträchtigt wird. Weiterhin können detektierte Aerosolpartikel als Hindernis für die Navigation interpretiert werden. Dieser Fall wird in dieser Arbeit anhand von Messdaten bestätigt und als Typ-I definiert. Wenn aufgrund der Arosoldichte einzelne LiDAR-Messungen absorbiert werden, resultiert ein lückenhafter oder komplett leerer Scan. In diesem Fall ist ebenfalls keine autonome Navigation möglich. Diese Situation wird in dieser Arbeit experimentell nachgewiesen und als Typ-II definiert. Obwohl Radar-Scanner nicht von dem Typ-I- und Typ-II-Effekt beeinträchtigt werden, besitzen sie gegenüber LiDAR-Scannern Nachteile. Zum Beispiel führen Ausreißer, Reflexionen und eine schlechtere Distanz und Winkelauflösung zu unpräzisen Rasterkarten, was in Kapitel 6.2.3 gezeigt wird.

In Kapitel 6.2 wird das heuristische, modellbasierte Verfahren und der virtuelle Sensor evaluiert. Generell können alle Verfahren automatisch auf den Typ-I- und den Typ-II-Effekt reagieren. Gleichzeitig befinden sich in den fusionierten Scans nur Radarmessungen, wenn korrespondierende LiDAR-Messungen von dem Typ-I- oder Typ-II-Effekt betroffen sind. Dadurch ist der fusionierte Scan in einem Umfeld ohne Aerosole mit dem LiDAR-Scan vergleichbar, woraus detailliertere Karten als mit Radar-Scannern resultieren. Der virtuelle Sensor ist durch Variation der Anzahl an Sensoren leicht erweiterbar, jedoch behebt das Verfahren schlechter den Typ-I-Effekt, als das heuristische und modellbasierte Verfahren. Der Typ-II-Effekt wird hingegen von allen Verfahren korrekt kompensiert.

Im Vorverarbeitungsschritt der LiDAR-Radar-Fusion werden gerade Strukturen (Linien) detektiert. In dieser Arbeit wurde gezeigt, dass das Extrahieren von geraden Strukturen in der Vorverarbeitung der Sensorfusion zu präziseren Rasterkarten führt. Gleichzeitig ist der Anteil an vom Typ-I-Effekt beeinträchtigte LiDAR-Messungen im fusionierte Scan geringer. Ein weiterer Vorteil der Extraktion von geraden Strukturen ist, dass radardurchlässige und strukturierte Objekte nicht als Aerosole detektiert werden. Jedoch müssen die zu detektierenden Geometrien und das Detektionsverfahren aufeinander abgestimmt werden. Zum einen werden gerade Strukturen in den vom Typ-I-Effekt hervorgerufenen Messwerten erkannt, wenn das Detektionsverfahren zu kleine Objekte berücksichtigt. Zum anderen werden kleinere radardurchlässige Objekte nicht erfasst, wenn das Detektionsverfahren auf zu große Objekte ausgelegt ist. Der Einfluss des Detektionsverfahrens wird in Kapitel 6.2.5 dargelegt.

In dieser Arbeit wird auch untersucht, ob virtuelle 2D Scans die LiDAR-Radar-Fusion beeinflussen. Die Integration von virtuellen 2D-Scans im Vorverarbeitungsschritt führt zu einem höheren Anteil an LiDAR-Messungen in den fusionierten Scans, wodurch wiederum die Kartenqualität steigt.

7.3 Metrische Umgebungsmodelle mit Aerosolverteilungen

In Kapitel 6.3 wird ein auf Scan-Registrierungen und auf Landmarken basierender Ansatz überprüft, um metrische Umgebungsmodelle trotz einer Beeinträchtigung durch Aerosole zu erstellen. Für den landmarkenbasierten Ansatz werden in Kapitel 5.2.1 Methoden zur Extraktion von geeigneten Landmarken vorgestellt. Aufgrund des Typ-I- und Typ-II-Effektes können mit LiDAR-Scannern natürliche Landmarken nicht sicher detektiert werden. LiDAR-Scanner erfordern somit Landmarken mit stärkerer Rückstrahlung, z. B. retroreflektive Marken. Punktziele mit einem großen Radarquerschnitt - wie zum Beispiel Winkelreflektoren - sind geeignete Landmarken für Radar-Scanner. In dieser Arbeit wird vorgeschlagen den charakteristischen Verlauf der Distanzwerte und der Rückstrahlleistung von Punktzielen im Radar-Scan für die Detektion zu nutzen. Strukturierte Umgebungen enthalten natürliche Punktziele, wie z. B. Ecken und Kanten, wodurch landmarkenbasierte SLAM-Verfahren mit Radar in Indoor-Umgebungen ohne künstliche Landmarken möglich sind, was in Kapitel 6.3.1 mit einem Experiment dargelegt wird. Auf der Grundlage der somit erhaltenen Roboterposition kann mit den fusionierten Scans, die den Typ-I- und den Typ-II-Effekt kompensieren, eine Rasterkarte aufgebaut werden. Der auf Scan-Registrierungen basierende Ansatz, der in dieser Arbeit untersucht wurde, fundiert auf ICP-Registrierungen zwischen den fusionierten Scans und einer Rasterkarte. Dabei werden gemäß der Zusammensetzung des fusionierten Scans die Fusionsfälle und die Blickwinkel in den Rasterzellen gespeichert. Somit wird bei der Datenzuordnung garantiert, dass nur Rasterzellen mit den aktuellen fusionierten Messungen assoziiert werden, die zuvor von den korrespondierenden Fusionsfällen und Blickwinkeln detektiert wurden. In dieser Arbeit wird gezeigt, dass mit beiden Ansätzen eine Rasterkarte erzeugt werden kann, die zum einen nicht von dem Typ-I- und Typ-II-Effekt beeinträchtigt ist und andererseits einen höheren Detailgrad aufweist als Rasterkarten, die nur mit Radar-Scannern erstellt werden. Die Ansätze zur Erstellung von Rasterkarten bilden wiederum die Grundlage für die Berechnung der Aerosolverteilungen. Hierfür wird in jedem SLAM-Zyklus die Diffusionsgleichung numerisch in den freien Zellen der Rasterkarte gelöst. Die Aerosolkonzentrationen werden mit dem LRR beschrieben, der sich aus fusionierten LiDAR- und Radar-Messungen ergibt. Die Evaluierung in einem Experiment mit Nebel (siehe Kapitel 6.3.3) zeigt, dass somit mit mobilen Robotern unter weichen Echtzeitbedingungen Verteilungsmodelle erstellt werden können. Die Grenzen der SLAM-Ansätze sind ein fehlender Loop-Closure, wodurch ein Drift in der Karte nach längerer Fahrt entsteht. Weiterhin ist die Bestimmung der Aerosolkonzentration per LRR fehlerhaft, wenn sich radardurchlässige Objekte, die keine Standardgeometrie aufweisen, im Scan-Bereich befinden oder LiDAR-Scanner aufgrund Störobjekte keine Distanzmessungen liefern können.

7.4 Zukünftige Forschungsfragen

Die Kombination der drei vorgestellten LiDAR-Radar-Fusionsverfahren sowie der Einfluss anderer störender Aerosole, wie zum Beispiel Regen, wurde hier nicht untersucht und muss in weiterführenden Arbeiten aufgegriffen werden. Zukünftige Arbeiten müssen sich auf weitere Verfahren zur Bestimmung von Aerosolkonzentrationen fokussieren, da der LRR in Umgebungen mit vielen radardurchlässigen Objekten kein aussagekräftigen Wert bezüglich der Aerosolkonzentration darstellt. Um dieses Problem zu lösen, müssen weitere Sensormodalitäten integriert werden. Diesbezüglich wurden während der Promotion erste grundlegende Experimente durchgeführt. Die Erkenntnis aus diesen Experimenten ist, dass mittels LRR und detektierten Features aus Kamerabildern ein neuronales Netz trainiert werden kann, um die Aerosolkonzentration zu bestimmen. Somit können Sichtweitensensoren mit LiDAR, Radar und Kameradaten abgebildet werden. Der Aspekt Loop-Closure

wurde in dieser Arbeit nicht behandelt und stellt im Zusammenhang mit Aerosolverteilungen eine weitere zukünftige Forschungsfrage dar.

8 Zusammenfassung

Das Umfeld eines mobilen Roboters muss sensorisch erfasst und in einem Umgebungsmodell zusammengetragen werden, um ein zuverlässiges und robustes Lokalisieren und Navigieren zu garantieren. Für diese Aufgabe hat sich der LiDAR-Scanner⁸¹ als unverzichtbarer Sensor etabliert. Aufgrund der Beeinträchtigung der Distanzmessungen durch Aerosole (z. B. Nebel, Rauch) sind LiDAR-Scanner jedoch nicht in jeder Umgebung einsetzbar. Die wissenschaftliche Fragestellung dieser Dissertation beschäftigt sich deswegen mit Verfahren, mit denen mobile Roboter Umgebungen modellieren können, in denen Aerosole die Distanzmessungen von LiDAR beeinträchtigen. Die Rahmenbedingung dieser Arbeit definiert, dass neben LiDAR und Radar keine weiteren Sensormodalitäten integriert werden dürfen. Weiterhin wird der Fokus auf strukturierte und statische Umgebungen gelegt. Aus der Fragestellung und den dazugehörigen Randbedingungen leiten sich drei Zielsetzungen ab, die dementsprechend in drei Kapiteln im Hauptteil (Kapitel 3-5) behandelt werden. Im Anschluss daran werden die vorgestellten Verfahren in Kapitel 6 experimentell evaluiert.

Die erste Zielsetzung dieser Dissertation konzentriert sich im Rahmen einer Vorbetrachtung auf neue Messprinzipien mit Radar in der mobilen Robotik. Kapitel 3 stellt ein neues Messprinzip - den Laterations-Scanner - mit Radar zur Umgebungsmodellierung vor. Der Scanner basiert auf einem rotierenden monostatischen Radarnetzwerk. Trotz großem Öffnungswinkel und großer Distanzauflösung von handelsüblichen Radarsensoren ergab sich, dass mit dem Laterations-Scanner metrische Umgebungsmodelle erstellt werden können, wenn künstliche Landmarken zuvor platziert werden. Mit dem Laterations-Prinzip kann der Winkel zu Objekten genauer bestimmt werden, jedoch müssen Punktzeileigenschaften gegeben sein. Falls diese Voraussetzung nicht gegeben ist, werden aufgrund unterschiedlicher Reflexionszentren falsche Objektpositionen berechnet. Darum müssen Winkelreflektoren⁸² als künstliche Landmarken verwendet werden. Aufgrund des großen Öffnungswinkels und der geringen Distanzauflösung muss bei der Positionierung dieser Landmarken darauf geachtet werden, dass im Operationsraum des Roboters Gebiete existieren, in denen eine Unterscheidung bestimmter Landmarken nicht möglich ist (Kapitel 3.3.1). Die Positionen der betroffenen Landmarken werden in diesen Fällen falsch berechnet. In dieser Arbeit wird weiterhin beschrieben, inwiefern sich das SEABED⁸³-Verfahren als neues Messprinzip in der mobilen Robotik zur Kartierung eignet. Das Verfahren hat sich in der Simulation, jedoch aufgrund der Rauschanfälligkeit mit der verwendeten Hardware nicht mit realen Messdaten bewährt.

Die zweite Zielsetzung dieser Arbeit umschließt die Fusionierung von LiDAR- und Radar-Daten um speziell in Umgebungen, die von Aerosolen beeinträchtigt werden, den Vorteil beider Sensormodalitäten zu kombinieren. In Kapitel 4.1 wird dafür zunächst der Einfluss von Aerosolen auf LiDAR-Scanner klassifiziert und somit der Typ-I- und Typ-II-Effekt definiert. Der Typ-I-Effekt stellt die Detektion von Aerosol-Partikeln dar, was zu störenden Distanzmessungen in den LiDAR-Scans führt. Dadurch kann ein LiDAR-Scan Strukturen eines Umfeldes nicht mehr erfassen. Weiterhin werden detektierte Aerosol-Partikel bei der Kartierung in das Umgebungsmodell eingetragen, was in Kapitel 6.3.1 verdeutlicht ist. Der Typ-II-Effekt führt hingegen zur Absorption von LiDAR-Distanzmessungen. Wenn zu viele Distanzmessungen in einem LiDAR-Scan absorbiert werden, kann demzufolge ein Roboter keine Lokalisierung und Kartierung durchführen. Im Gegensatz dazu ist die Wellenlänge von Radar groß genug, sodass es nicht zu den genannten Effekten kommt. Der Nachteil

⁸¹Engl. Light Detection and Ranging (LiDAR) - Optische Abstandsmessung

⁸²Winkelreflektoren stellen Punktziele dar.

⁸³Radar-Rekonstruktionsalgorithmus

des Radar-Scanners ist jedoch, dass die Scan-Qualität schlechter ist als von LiDAR. Die Qualität von Rasterkarten, die mit Radar-Scannern erstellt werden, ist daher deutlich ungenauer, was in Kapitel 6.2.3 beschrieben ist. Die in Kapitel 4.4 vorgestellten LiDAR-Radar-Fusionsverfahren sind jedoch in der Lage sich automatisch an unterschiedlich starken Störungen durch Aerosole anzupassen und ermöglichen somit Umgebungen zu kartieren, in denen LiDAR- oder Radar-Scanner getrennt voneinander nicht erfolgreich sind. Gleichzeitig bleiben die Vorteile beider Sensormodalitäten (hohe Scan-Qualität von LiDAR und keine Beeinflussung durch Aerosole bei Radar) erhalten. Für die Erzeugung der fusionierten Scans wird in dieser Arbeit die heuristische Fusion, die modellbasierte Fusion und der virtuelle Sensor vorgeschlagen und untersucht. Die heuristische Fusion basiert auf Entscheidungsregeln, die auf empirischen Beobachtungen der zwei Sensormodalitäten beruhen. Dabei wurden Nebelmaschinen für die Generierung von Datensätzen, die Aerosole enthalten, verwendet. Die modellbasierte Fusion fundiert im Gegensatz dazu auf einem mathematischen Modell. Der virtuelle Sensor wird durch die Fusionierung von LiDAR- und Radar-Daten in einem Fusionsraster erzeugt. Es wird aufgezeigt, dass das heuristische und modellbasierte Fusionsverfahren in statischen und strukturierten Umgebungen den Typ-I- und den Typ-II-Effekt komplett beheben können (Kapitel 6.2.5-6.2.6). Der Nachteil dieser beiden Verfahren ist, dass die Anzahl und Platzierung der Sensoren fest definiert ist. Der virtuelle Sensor ist dagegen flexibel und eignet sich für die Fusion jeglicher Distanzsensoren. Weiterhin wird dargestellt, dass der virtuelle Sensor den Typ-II-, jedoch im Vergleich zu den anderen beiden Verfahren schlechter den Typ-I-Effekt beheben kann. Die vorgestellten Verfahren sind für die Fusionierung mit 3D- sowie 2D-LiDAR-Scannern geeignet. In den Ergebnissen der Untersuchungen wird weiterhin gezeigt, dass eine Sensorvorverarbeitung, die gerade Strukturen detektiert und virtuelle 2D-Scans integriert, zu detaillierteren Umgebungsmodellen führt. Somit ermöglichen die LiDAR-Radar-Fusionsverfahren SLAM-Ansätze, die sowohl auf Landmarken als auch auf Registrierungen ganzer Scans basieren, um Rasterkarten zu erstellen.

Die dritte Zielsetzung dieser Arbeit beschäftigt sich mit der metrischen Repräsentation eines Umfeldes. Dafür wurde in dieser Arbeit ein SLAM-Ansatz vorgestellt, der auf Registrierungen zwischen fusionierten Scans und einer fusionierten Rasterkarte in einem Kalman-Filter-Zyklus basiert. Die fusionierte Rasterkarte speichert in jeder Rasterzelle den Fusionsfall und den Blickwinkel, von dem sie mit dem fusionierten Scan detektiert wurde und verändert sich dementsprechend in Abhängigkeit der aktuellen Position des Roboters. Dadurch wird die Datenzuordnung zwischen Scan und Rasterkarte verbessert. Zusätzlich wird die Verteilung der Aerosole mit dem LRR-Wert parallel zu dem laufenden SLAM-Verfahren mit einem Finite-Differenzen-Modell berechnet. Dadurch entsteht eine zeitabhängige Repräsentation von Aerosolverteilungen in einem Umgebungsmodell.

Abschließend kann festgestellt werden, dass insbesondere mit den LiDAR-Radar-Fusionsverfahren praxistaugliche Lösungen für ein relevantes Problem vorgestellt werden, da eine autonome Navigation in Bereichen, in denen Aerosole die Funktion von LiDAR beeinträchtigt, nicht mit Standardverfahren zu bewältigen ist. Die LiDAR-Radar-Fusionsverfahren dieser Arbeit erhöhen die Robustheit und erweitern das Einsatzgebiet von mobilen Systemen. Die Grenzen der Verfahren sind unstrukturierte Umgebungen, die größtenteils aus radardurchlässigen Objekten bestehen. In diesen Situationen müssen weitere Sensormodalitäten integriert werden, worauf sich zukünftige Forschungsfragen konzentrieren müssen.

A Anhang

A.1 Technische Daten der Sensorik und Plattformen



PARAMETER	CONDITIONS	SYMBOL	MIN	TYP	MAX	UNITS
Radar						
transmit frequency		f	24.000		24.250	GHz
occupied bandwidth	EU-version	B _{EU}			250	MHz
	US/UK-version	B _{US}			100	MHz
output power (EIRP)	@ 25°C	P _{out}			20	dBm
Sensor						
detection distance	EU-version	d _{r,EU}	0.9		35	m
	US/UK-version	d _{r,US}	2.5		35	m
accuracy @ 250MHz bandwidth	compare test conditions on page 3	A _{EU}		+/- 3		cm
accuracy @ 100MHz bandwidth		A _{US}		+/- 7.5		cm
update rate				75		ms
resolution	@ 250MHz	r _{EU}			60	cm
	@ 100MHz	r _{US}			150	cm
standard detection field	compare with plot on page 4	horizontal		34		°
		vertical		49		°
Power supply						
supply voltage		V _{CC}	10		30	V
supply current		I _{CC}		350	550	mA
Environment						
operating temperature		T _{OP}	-25		+60	°C
storage temperature		T _{STG}	-25		+60	°C
Mechanical Outlines						
outline dimensions	compare to schematic on page 5	height length width		43.4 75.6 40.0		mm

Abbildung 101: Sensoreigenschaften iSYS 4004. (Quelle: <https://www.innosent.de/radarsysteme/isys-4004/>)



Specifications:	
Sensor:	<ul style="list-style-type: none"> • Time of flight distance measurement with calibrated reflectivities • 16 channels • Measurement range up to 100 meters • Accuracy: +/- 3 cm (typical) • Dual returns • Field of view (vertical): 30° (+15° to -15°) • Angular resolution (vertical): 2° • Field of view (horizontal/azimuth): 360° • Angular resolution (horizontal/azimuth): 0.1° - 0.4° • Rotation rate: 5 - 20 Hz • Integrated web server for easy monitoring and configuration
Laser:	<ul style="list-style-type: none"> • Class 1 - eye safe • 903 nm wavelength
Mechanical/ Electrical/ Operational	<ul style="list-style-type: none"> • Power consumption: 8 W (typical) • Operating voltage: 9 - 32 VDC (with interface box and regulated power supply) • Weight: 830 grams (without cabling) • Dimensions: 103 mm diameter x 72 mm height • Shock: 500 m/sec² amplitude, 11 msec duration • Vibration: 5 Hz to 2000 Hz, 3G rms • Environmental Protection: IP67 • Operating temperature -10° to +60° C • Storage temperature -40° to +105° C
Output:	<ul style="list-style-type: none"> • Up to 0.3 million points/second • 100 Mbps Ethernet connection • UDP packets containing <ul style="list-style-type: none"> - Distances - Calibrated reflectivities - Rotation angles - Synchronized time stamps (µs resolution) • \$GPRMC NMEA sentence from GPS receiver (GPS not included)

Copyright ©2015 Velodyne Acoustics, Inc. Specifications are subject to change without notice.
Other trademarks or registered trademarks are property of their respective owners.
63-9229 Rev-B

Abbildung 102: Sensoreigenschaften Velodyne VLP-16. (Quelle: <https://velodynelidar.com/vlp-16.html>)



Abbildung 103: Taurob Tracker

Dimensions	100 x 58 x 42 cm
Weight	60 kg
Payload	25kg
Operating Distance (Line of sight)	500 – 1000 m
Speed	7 kph
Temperature Range	-20°C to +60°C
Battery Endurance	3 hrs. (driving), 10 hrs. (measuring)
Certifications	ATEX, IP 67
Max. Climb Capabilities	40°, 35 cm obstacles, stairs



Abbildung 104: Pioneer 3 AT (Quelle: <https://www.generationrobots.com/de/402397-robot-mobile-pioneer-3-at.html>)

Dimensions	50.1 x 49.3 x 27.7 cm
Weight	14 kg
Payload	40 kg
Operating Distance (Line of sight)	500 – 1000 m
Speed	2.52 kph
Battery Endurance	2-3 hrs.

A.2 Fallbetrachtungen LiDAR-Radar-Fusion

Auf den folgenden Seiten befindet sich eine Auflistung diverser Fälle, die in Kombination mit LiDAR und Radar in strukturierten, statischen jedoch durch Aerosole beeinträchtigten Umgebungen auftreten können. Weiterhin wird beschrieben, welche Sensorwerte der fusionierte Scan demzufolge beinhalten muss. Die auf Modellfunktionen und Heuristiken basierenden Varianten der Scan-Fusion in Kapitel 4.4.2 und 4.4.3 orientieren sich direkt an diesen Fällen und beinhalten zwei hauptsächliche Parameter. Der Abstand korrespondierender Messwerte wird als d_F deklariert. Weiterhin entsteht bei der Fusion von unterschiedlichen Sensoren mit gleicher Messgröße immer ein konkurrierender und komplementärer Bereich, der durch die Distanz R_F voneinander getrennt wird. In der Tabelle 7 sind die häufigsten Fälle bei der Fusionierung eines 2D-LiDAR und eines 2D-Radars in Form einer Vorbetrachtung dargestellt. Spezielle Fälle, in denen der Radar keine Messung liefert, werden in der Tabelle 8 erläutert.

Die Fälle, die bei der Fusionierung von 3D-LiDAR und 2D-Radarscans auftreten, sind in den Tabellen 9 und 10 dargestellt. Hier wird gemäß dem virtuellen 2D-Scan-Verfahren zwischen einem 2D-Scan für die Lokalisierung und Kartierung $S_{Fusion,Kart./Lok.}$ und einem Scan für die Hindernisvermeidung bei der Navigation $S_{Fusion,Nav.}$ unterschieden.

	<p>LiDAR und Radar erfassen das gleiche Objekt. Eine Fusionierung der jeweiligen Distanzmessungen erhöht die Genauigkeit der Abstandsbestimmung.</p> $R_{Fusion} \rightarrow S_{Fusion}.$
	<p>Wenn Aerosolpartikel mit LiDAR detektiert werden, ist die Distanzmessung des LiDAR mindestens kleiner als vom Radar. Der fusionierten Scan muss in dieser Situation nur die Radarmessung verwenden</p> $R_{Radar} \rightarrow S_{Fusion}.$
	<p>Wenn eine LiDAR Messung absorbiert und gleichzeitig eine Distanzinformation vom Radar ermittelt wird, ist dies ein Zeichen für das Vorhandensein von Aerosolwolken. Dementsprechend muss der Radarmesspunkt verwendet werden</p> $R_{Radar} \rightarrow S_{Fusion}.$
	<p>Dieser Fall tritt an Kanten auf, da Radarscanner größere Öffnungswinkel als LiDAR besitzen. Weiterhin werden gitterförmige Metallgegenstände (z. B. Metallzaun) von LiDAR teilweise nicht aber von Radar detektiert. Da diese Gegenstände potentielle Hindernisse bei der Navigation darstellen muss der Radarmesspunkt verwendet werden</p> $R_{Radar} \rightarrow S_{Fusion}.$
	<p>Gegenstände ohne elektrische Leitfähigkeit werden vom Radar nicht erkannt. Die Unterscheidung zu dem Fall B kann verbessert werden, indem der LiDAR auf gerade Strukturen (Linien) überprüft wird</p> $R_{LiDAR}, wenn \in Linie \rightarrow S_{Fusion}.$

Tabelle 7: 2D-LiDAR und 2D-Radar Fusion.

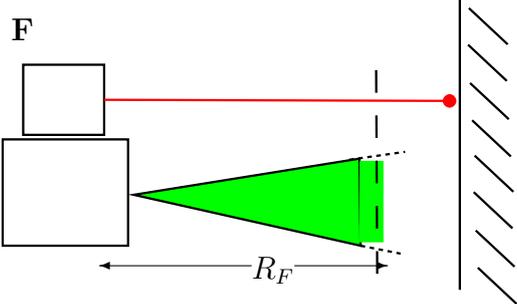
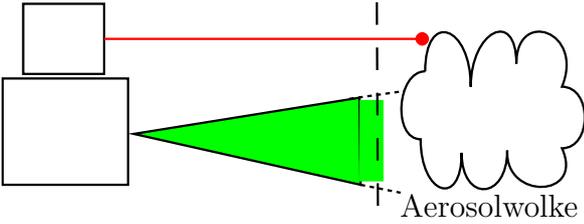
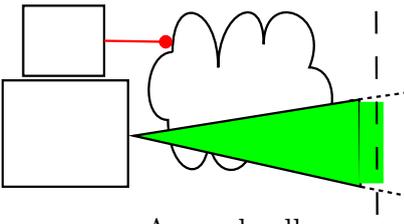
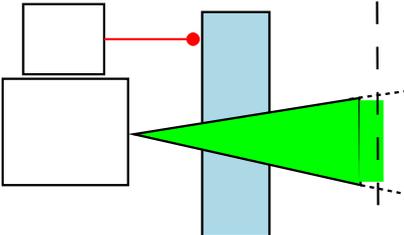
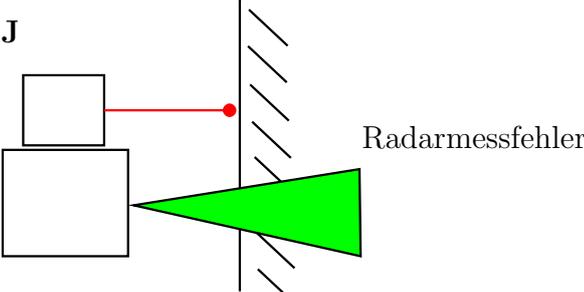
<p>F</p> 	<p>Außerhalb des konkurrierenden Fusionsbereichs R_F liefert nur der LiDAR einen Messwert. Wenn $R_{Radar} = inf$ und $R_{LiDAR} > R_F$ ist, kann entweder kein Wert oder der LiDAR (Verwechslung mit G möglich) verwendet werden</p> <p>R_{LiDAR} oder $R_{LiDAR} \in Linie$ oder $inf \rightarrow S_{Fusion}$.</p>
<p>G</p> 	<p>Dieser Fall ist schwer von F zu unterscheiden. Per Linienextraktion können wiederum strukturierte Gegenstände ermittelt werden. Wenn LiDAR Punkte von Aerosolpartikeln definitiv ausgeschlossen werden sollen, dann muss der Wert freigelassen werden</p> <p>R_{LiDAR} oder $R_{LiDAR} \in Linie$ oder $inf \rightarrow S_{Fusion}$.</p>
<p>H</p> 	<p>Wenn sich Aerosolwolken jedoch keine Objekte im komplementären Fusionsbereich befinden ($R_{LiDAR} < R_F$ und $R_{Radar} = inf$), existiert kein geeigneter Distanzwert für den fusionierten Scan.</p> <p>$inf \rightarrow S_{Fusion}$.</p>
<p>I</p> 	<p>Die Konstellation für Radar-durchlässige Objekte ist äquivalent zu H. Für die Kartierung und Lokalisierung ist dies nicht negativ. Bei der Navigation besteht die Gefahr einer Kollision. Eine autonome Navigation in freien Flächen ist aufgrund fehlender Strukturen generell problematisch. Wenn die Gegenstände gerade Strukturen aufweisen, können sie per Linienextraktion von H unterschieden werden</p> <p>$R_{LiDAR} \in Linie \rightarrow S_{Fusion}$.</p>
<p>J</p> 	<p>Ausreißer und Reflexion im Radarscan führen zur Verschlechterung der Qualität der Kartierung und Lokalisierung und können wiederum mit einer Linienextraktion von B unterschieden werden</p> <p>$R_{LiDAR} \in Linie \rightarrow S_{Fusion}$.</p>

Tabelle 8: Übersicht über Sonderfälle der 2D-LiDAR und 2D-Radar Fusion.

	<p>Der nächste und der entfernteste LiDAR-Messpunkt repräsentieren das selbe Objekt. Da $R_{LiDAR,max} - R_{Radar} < d_F$ und $R_{LiDAR,min} - R_{Radar} < d_F$ ergeben sich ähnliche Messpunkte für beide Scans</p> $R_{Fusion} \rightarrow S_{Fusion,Nav.}$ $R_{Fusion} \rightarrow S_{Fusion,Kart./Lok.}$
	<p>Die entfernteste LiDAR-Messung und der Radar messen das gleiche Objekt ($R_{LiDAR,max} - R_{Radar} < d_F$). Wenn Aerosole präsent sind, ist die LiDAR-Distanzmessung kleiner als die Radar-Distanzmessung ($R_{Radar} - R_{LiDAR,min} > d_F$). Aerosole sollten bei der Navigation nicht berücksichtigt werden</p> $R_{Fusion} \rightarrow S_{Fusion,Nav.}$ $R_{Fusion} \rightarrow S_{Fusion,Kart./Lok.}$
	<p>Wenn alle LiDAR-Distanzmessungen Aerosole detektieren ($R_{Radar} - R_{LiDAR,min} > d_F$ und $R_{Radar} - R_{LiDAR,max} > d_F$), kann nur der Radar für die fusionierten Scans benutzt werden</p> $R_{Radar} \rightarrow S_{Fusion,Nav.}$ $R_{Radar} \rightarrow S_{Fusion,Kart./Lok.}$
	<p>Wenn alle LiDAR-Distanzmessungen absorbiert werden, kann nur der Radar für die fusionierten Scans benutzt werden</p> $R_{Radar} \rightarrow S_{Fusion,Nav.}$ $R_{Radar} \rightarrow S_{Fusion,Kart./Lok.}$
	<p>Die Konstellation für Radar-durchlässige Objekte ist äquivalent zu M. Die Gegenstände werden entweder außerhalb des Fusionsbereiches erkannt oder müssen geraden Strukturen aufweisen</p> $R_{LiDAR} \in Linie \rightarrow S_{Fusion,Nav.}$ $R_{Radar} \rightarrow S_{Fusion,Kart./Lok.}$
	<p>Spezielle Objekte (z. B. metallische Gitter) werden nicht vom LiDAR, jedoch per Radar detektiert. Da sie ein Hindernis darstellen müssen sie in den Scan $S_{Fusion,Nav}$ aufgenommen werden</p> $R_{Radar} \rightarrow S_{Fusion,Nav.}$ $R_{LiDAR,max} \rightarrow S_{Fusion,Kart./Lok.}$

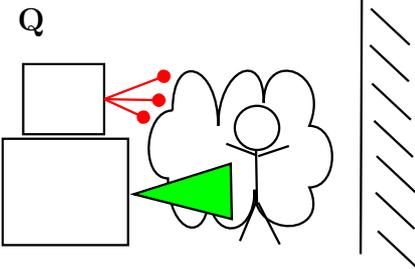
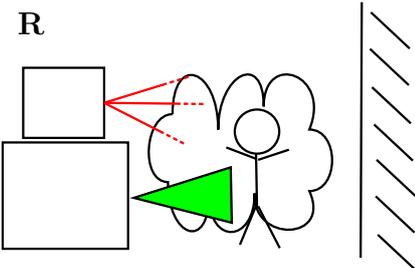
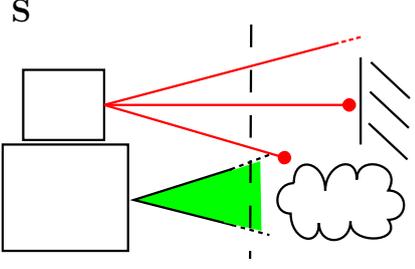
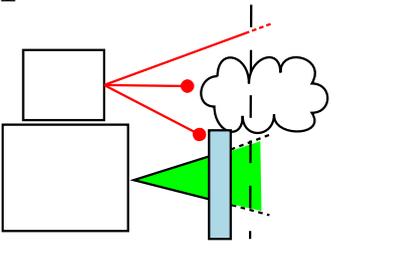
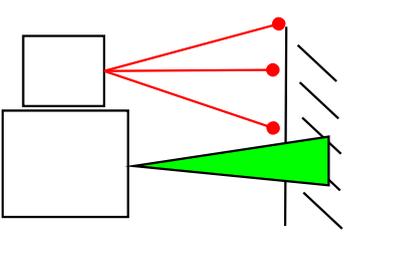
<p>Q</p> 	<p>Dynamische Objekte müssen trotz Aerosolwolken detektiert und zur Hindernisvermeidung verwendet werden ($R_{Radar} - R_{LiDAR,min} > d_F$ und $R_{Radar} - R_{LiDAR,max} > d_F$)</p> $R_{Radar} \rightarrow S_{Fusion,Nav.}$ $R_{Radar} \rightarrow S_{Fusion,Kart./Lok.}$
<p>R</p> 	<p>Dynamische Objekte müssen detektiert und zur Hindernisvermeidung verwendet werden ($R_{min} = R_{max} = inf$)</p> $R_{Radar} \rightarrow S_{Fusion,Nav.}$ $R_{Radar} \rightarrow S_{Fusion,Kart./Lok.}$
<p>S</p> 	<p>Außerhalb des konkurrierenden Fusionsbereichs R_F liefert nur der LiDAR einen Messwert ($R_{Radar} = inf$ und $R_{LiDAR} > R_F$). Die Unterscheidung zwischen Aerosolen und Hindernissen ist wiederum nur per Objektsegmentierung möglich.</p> $inf \rightarrow S_{Fusion,Nav.}$ $R_{LiDAR,max} \rightarrow S_{Fusion,Kart./Lok.}$
<p>T</p> 	<p>In diesem Fall kann es zu Kollisionen mit Radar-durchsichtigen Objekten kommen</p> $R_{LiDAR} \in Linie \rightarrow S_{Fusion,Nav.}$ $R_{Radar} \rightarrow S_{Fusion,Kart./Lok.}$
<p>U</p> 	<p>Ausreißer und Reflexion im Radarscan führen zur Verschlechterung der Qualität der Kartierung und Lokalisierung und können wiederum mit einer Linienextraktion von Q unterschieden werden</p> $R_{LiDAR} \in Linie \rightarrow S_{Fusion,Nav.}$ $R_{LiDAR} \in Linie \rightarrow S_{Fusion,Kart./Lok.}$

Tabelle 10: Sonderfälle bei der Zusammensetzung von $S_{Fusion,Nav}$ und $S_{Kart./Lok.,Nav}$.

A.3 Datensätze für die Fusion von LiDAR und Radar

Für die Evaluierung der in dieser Arbeit beschriebenen Fusionsverfahren wurden drei Datensätze angefertigt. Für die Durchführung der Experimente (außer die Untersuchungen zum Laterations-Scanner) wurde der MPR und ein Velodyne VLP-16 auf einer Pioneer Plattform, bzw. verschiedenen Versionen des Taurob Trackers montiert. Beide Plattformen basieren auf dem Differentialantrieb.

A.3.1 Geräte und Anordnungen

Radar-Scanner können die Struktur einer Umgebung nicht so genau wiedergeben wie LiDAR-Scanner. Die Tabelle 11 stellt die wichtigsten Sensoreigenschaften des Velodyne VLP-16, des MPR and des NatTech MMW Radar, welcher von Adams in [AMJ12, p. 329] verwendet wurde, gegenüber.

	Velodyne VLP-16	MPR	NavTech MMW radar
Reichweite	bis 100 m	bis 15 m	bis 200-800 m
Winkelauflösung	0.1-0.4°	1.8°	0.09°
Öffnungswinkel	0.17°	4.9°	1.8°
Wellenlänge	903 nm	3.26-3.41 mm (88-92 GHz)	3.89-3.95 mm (76-77 GHz)
Messrate	5-20 Hz	2.5 Hz	2.5 Hz

Tabelle 11: Vergleich zwischen Velodyne VLP-16, MPR and NavTech Radar.

Die Reichweite hängt vor allem von der Sendeleistung P_S , dem Fokus der Antenne, dem RCS des Objektes und dem Detektionsalgorithmen des Sensor ab. Der NavTech Radar hat eine größere Reichweite. Seine Einsatzgebiete sind Flug- und Verkehrsüberwachung. Bei 2D-Scannern bezieht sich die Winkelauflösung auf den Schrittwinkel zwischen zwei Messungen während einer Drehung. Die Winkelauflösung ist beim NavTech am geringsten, jedoch spielt der Öffnungswinkel Θ bei der Qualität des Scans eine stärkere Rolle. Aufgrund des großen Öffnungswinkels Θ erscheinen Objekte in einem Radar-Scan sichelförmig verschmiert.

A.3.2 Datensatz I - Flur in Hannover



Abbildung 105: Aufbau für den Datensatz I

Der Datensatz wurde im Oktober 2015 im Flur des Institute of Systems Engineering - Real Time Systems Group (RTS) aufgenommen und diente zur ersten Evaluierung des MPR. Für den Datensatz wurde ein Pioneer Roboter mit dem MPR und einem Velodyne VLP-16 bestückt (siehe Abbildung 105). Die Plattform wurde während der Datenaufnahme einmal entlang des Flures teleoperiert. Die Fahrt endete wieder am Ausgangspunkt. Folgende Daten wurden aufgenommen:

- Odometriedaten des Roboters
- 3D-Punktwolken des Velodyne VLP-16
- 2D-Scans des MPR

Der Datensatz eignet sich um diverse SLAM-Verfahren zu testen und die beiden Sensoren gegenüberzustellen. Weiterhin kann sich mit dem Datensatz in anderen Karten von der Flurumgebung lokalisiert werden, um z. B. die Qualität der Lokalisierung der beiden Sensoren zu beurteilen.

A.3.3 Datensatz II - Hof in Hannover

Der Datensatz wurde im November 2015 auf dem Hof nahe dem Gebäude Appelstraße 7 in Hannover aufgenommen. Für den Datensatz wurde ein Pioneer Roboter mit dem MPR und einem Velodyne VLP-16 bestückt. Die Plattform wurde während der Datenaufnahme im Hof navigiert. Während der Fahrt wurde in regelmäßigen Abständen eine Nebelmaschine angeschaltet. Zusätzlich befinden sich retroreflektive Marken und drei Winkelreflektoren in der Szene (siehe Abbildung 106).

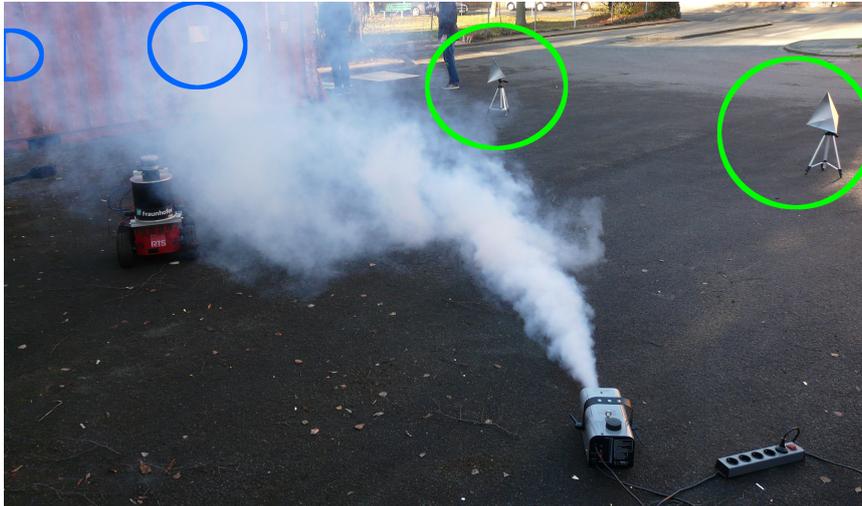


Abbildung 106: Aufbau für den Datensatz II. In der Szene befinden sich drei Winkelreflektoren (grüne Kreise) und acht retroreflektive Marken (blaue Kreise).

Der Hof besteht aus einer Hauswand, einem Metallcontainer und einer Hecke, wodurch ein rechteckiger Raum gebildet wurde, der eine offene Seite aufweist. Folgende Daten wurden aufgenommen:

- Odometriedaten des Roboters
- 3D-Punktwolken des Velodyne VLP-16
- 2D-Scans des MPR

Der Datensatz eignet sich sowohl für auf Landmarken basierende SLAM-Verfahren als auch für auf Scan-Registrierung basierende Verfahren. Zusätzlich ist der Einfluss von Nebel auf LiDAR-Scanner sichtbar (Typ-I-Effekt). Weiterhin ist im Datensatz zu erkennen, dass die Hecke nicht vom Radar detektiert wird. Dadurch entsteht für die Sensorfusion die Herausforderung, dass sowohl Nebel als auch bestimmte Objekte Radar-durchlässig sind. Die offene Seite des Hofes liefert auch hilfreiche Daten, da die Sensorfusion sowohl in geschlossenen Räumen als auch vor offenen Flächen funktionieren muss.

A.3.4 Datensatz III - Garage in Wien

Der Datensatz wurde im April 2016 in einer Garage der Firma Taurob in Wien aufgenommen. Für den Datensatz wurde eine Tracker-Plattform mit dem MPR, einem Velodyne VLP-16 und einem Prototypen eines Gassensors der Universität Warwick⁸⁴ bestückt. Die Plattform wurde während der Datenaufnahme in eine Garage navigiert, die zuvor mit sehr dichten Nebel gefüllt wurde. Dabei kam es zu dem Typ-II-Effekt (siehe Abbildung 107).

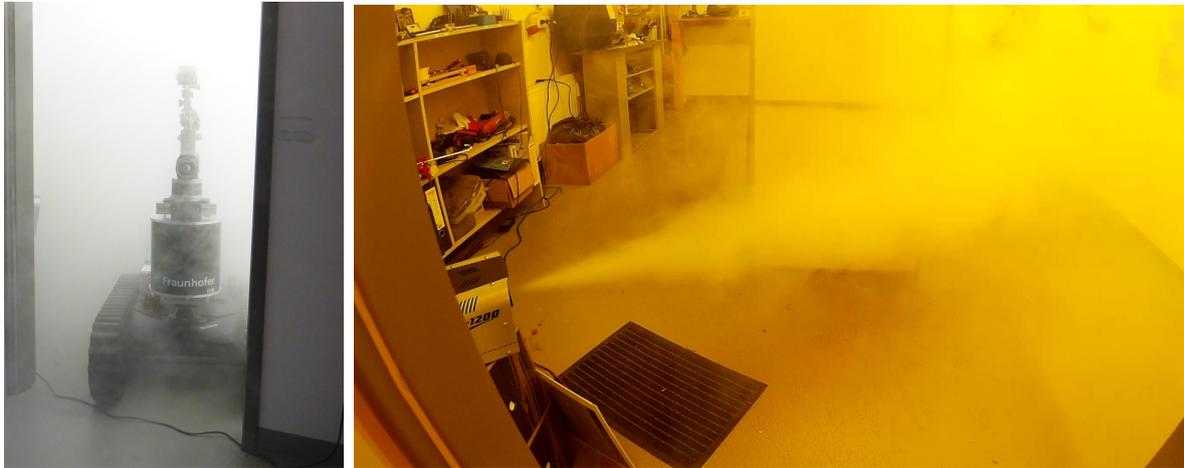


Abbildung 107: Aufbau für den Datensatz III

Folgende für diese Arbeit relevanten Daten wurden aufgenommen:

- Odometriedaten des Roboters
- 3D Punktwolken des Velodyne VLP-16
- 2D-Scans des MPR

Der Datensatz eignet sich für die Untersuchung der im Kapitel 4 vorgestellten Scan-Fusion und der Detektion und Modellierung von Aerosolen, was im Kapitel 5.3 beschrieben ist.

⁸⁴Microsensors and Bioelectronics Laboratory, Warwick University

Quellenverzeichnis

- [AGSZ13] ALEKSANDROVICH, Yudin D. ; GENNADIEVICH, Postolsky G. ; STEPANOVICH, Kizhuk A. ; ZALMANOVICH, Magergut V.: Mobile Robot Navigation Based on Artificial Landmarks with Machine Vision System. In: *World Applied Sciences Journal 24* (2013)
- [AMJ12] ADAMS, M. ; MULLANE, J. ; JOSE, E.: *Robotic Navigation and Mapping with Radar*. ARTECH HOUSE, 2012
- [Bö8] BÜHREN, Markus: *Simulation und Verarbeitung von Radarziellisten im Automobil*, Universität Stuttgart, Diss., 2008
- [BKNS00] BREUNIG, Markus M. ; KRIEGEL, Hans-Peter ; NG, Raymond T. ; SANDER, Jörg: LOF: Identifying Density-Based Local Outliers. In: *Proc. ACM SIGMOD 2000 Int. Conf. On Management of Data, Dallas, TX* (2000)
- [Bre04] BRENNEKE, C.: *Ein scanbasierter Ansatz zur exploratorischen Navigation mobiler System in unstrukturierten Outdoor-Umgebungen*, Leibniz Universität Hannover, Diss., 2004
- [Bre15] BRENNER, Claus: *Homepage of Claus Brenner: SLAM lecture*. <http://www.clausbrenner.de/slam.html>. Version: 2015
- [BWW03] BRENNEKE, Christian ; WULF, Oliver ; WAGNER, Bernardo: Using 3D Laser Range Data for SLAM in Outdoor Environments. In: *Proceedings 2003 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2003)* (2003)
- [Car] *Data sheet: MultiSense-SL (Carnegie Robotics)*. : *Data sheet: MultiSense-SL (Carnegie Robotics)*
- [CD99] CLARK, S. ; DISSANAYAKE, G.: Simultaneous Localisation and Map Building Using Millimetre Wave Radar to Extract Natural Features. In: *International Conference on Robotics and Automation* (1999)
- [CDW98] CLARK, S. ; DURRANT-WHYTE, H.: Autonomous Land Vehicle Navigation Using Millimeter Wave Radar. In: *Proceedings of the IEEE International Conference on Robotics & Automation* (1998)
- [CP12] CASTRO, M. P. G. ; PEYNOT, T: Laser-to-Radar Sensing Redundancy for Resilient Perception in Adverse Environmental Conditions. In: *Australasian Conference on Robotics and Automation*, 2012
- [CPGG05] *Kapitel Chapter 6*. In: CAPT. PHILIP G. GALLMAN, Ph.D.: *Radar Reflectors for Cruising Sailboats - Why they Work, What the Limitations are, and How to Evaluate them*. Gallman, 2005, S. 67–72
- [CTH⁺03] CHANG, Chih-Fu ; TSAI, Ching-Chih ; HSU, Jui-Cheng ; LIN, Shoei-Chuen ; LIN, Chu-Chen: Laser Self-Localization for a Mobile Robot Using Retro-reflector Landmarks. In: *Proceeding of th 7th international conference on Automation Technology* (2003)

- [Cur05] CURRY, G. R.: *Radar System Performance Modeling*. Artech House, 2005
- [CW98] CLARK, S. ; WHYTE, H. D.: The Design of a High Performance MMW Radar System for Autonomous Land Vehicle Navigation. In: *Field and Service Robotics*, 1998
- [Det89] DETLEFSON, J.: *Radartechnik*. Springer-Verlag, 1989
- [Dev] DEVINE, P.: *Füllstandmessung mit Radar - Leitfaden für die Prozessindustrie*. VEGA Grieshaber KG
- [Dil15] DILLMANN, R.: *Robotik III, Externe Sensoren (Foliensatz)*. http://i61www.ira.uka.de/Teaching/VorlesungRobotikIII/Pdf-Files/3SW_ExterneSensoren.pdf, Mai 2015
- [DK04] DIOSI, A ; KLEEMAN, L: Advanced Sonar and Laser Range Finder Fusion for Simultaneous Localization and Mapping. In: *International Conference on Intelligent Robots and Systems* (2004)
- [DPA16] DEGERMAN, Johan ; PERNSTAL, Thomas ; ALENLJUNG, Klas: 3D occupancy grid mapping using statistical radar models. In: *2016 IEEE Intelligent Vehicles Symposium (IV)* (2016), Jun. <http://dx.doi.org/10.1109/ivs.2016.7535495>. – DOI 10.1109/ivs.2016.7535495. ISBN <http://id.crossref.org/isbn/978-1-5090-1821-5>
- [DRL93] DETLEFSEN, J. ; ROZMANN, M. ; LANGE, M.: 94 HGz 3-D Imaging Radar Sensor for Industrial Environments. In: *EARSel ADVANCEA IN REMOTE SENSING* (1993)
- [Eff09] EFFERTZ, J.: *Autonome Fahrzeugführung in urbaner Umgebung durch Kombination objekt- und kartenbasierter Umfeldmodelle*, Technischen Universität Carolo-Wilhelmina zu Braunschweig, Diss., 2009
- [Elf89] ELFES, A.: Using Occupancy Grids for Mobile Robot Perception and Navigation. In: *Computer* (1989)
- [Elm02] ELMENREICH, Wilfried: An Introduction to Sensor Fusion / Institut für Technische Informatik, Vienna University of Technology, Austria. 2002. – Forschungsbericht
- [Fö6] FÖLSTER, Florian: *Erfassung ausgedehnter Objekte durch ein Automobil-Radar*, Technische Universität Hamburg-Harburg, Diss., 2006
- [FCA99] FOESSEL, Alex ; CHHEDA, Sachin ; APOSTOLOPOULOS, Dimitrios: Short-Range Millimeter-Wave Radar Perception in a Polar Environment. In: *Proceedings of the Field and Service Robotics Conference* (1999)
- [FCDS16] FORSTER, Christian ; CARLONE, Luca ; DELLAERT, Frank ; SCARAMUZZA, Davide: On-Manifold Preintegration for Real-Time Visual-Inertial Odometry. In: *IEEE Transactions on Robotics* (2016), 1–21. <http://dx.doi.org/10.1109/tro.2016.2597321>. – DOI 10.1109/tro.2016.2597321. – ISSN 1941-0468
- [FJC⁺07] FERRI, Gabriele ; JAKUBA, Michael V. ; CASELLI, Emanuele ; MATTOLI, Virgilio ;

- MAZZOLAI, Barbara ; YOERGER, Dana R. ; DARIO, Paolo: Localizing multiple gas/odor sources in an indoor environment using bayesian occupancy grid mapping. In: *2007 IEEE/RSJ International Conference on Intelligent Robots and Systems* (2007), Oct. <http://dx.doi.org/10.1109/iros.2007.4399413>. – DOI 10.1109/iros.2007.4399413. ISBN <http://id.crossref.org/isbn/978-1-4244-0912-9>
- [FLD05] FRESE, Udo ; LARSSON, Per ; DUCKETT, Tom: A multilevel relaxation algorithm for simultaneous localization and mapping. In: *IEEE Transactions on Robotics* 21 (2005), Nr. 2, S. 196–207
- [FR05] FÖLSTER, F. ; ROHLING, H.: Data Association and Tracking for Automotive Radar Networks. In: *IEEE TRANSACTIONS ON INTELLIGENT TRANSPORTATION SYSTEMS* (2005)
- [Fre07] FRESE, Udo: Efficient 6-DOF SLAM with Treemap as a Generic Backend. In: *Proceedings 2007 IEEE International Conference on Robotics and Automation* (2007), Apr. <http://dx.doi.org/10.1109/robot.2007.364221>. – DOI 10.1109/robot.2007.364221. – ISBN <http://id.crossref.org/isbn/1-4244-0601-3>
- [GKF16] GLENNIE, C. L. ; KUSARI, A. ; FACCHIN, A.: CALIBRATION AND STABILITY ANALYSIS OF THE VLP-16 LASER SCANNER. In: *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XL-3/W4* (2016), Mar, 55–60. <http://dx.doi.org/10.5194/isprs-archives-xl-3-w4-55-2016>. – DOI 10.5194/isprs-archives-xl-3-w4-55-2016. – ISSN 2194-9034
- [GKS⁺10] GRISETTI, Giorgio ; KÜMMERLE, Rainer ; STACHNISS, Cyrill ; FRESE, Udo ; HERTZBERG, Christoph: Hierarchical optimization on manifolds for online 2D and 3D mapping. In: *Robotics and Automation (ICRA), 2010 IEEE International Conference on* IEEE, 2010, S. 273–278
- [GMMW10] GLOVER, Arren J. ; MADDERN, William P. ; MILFORD, Michael J. ; WYETH, Gordon F.: FAB-MAP + RatSLAM: Appearance-based SLAM for multiple times of day. In: *2010 IEEE International Conference on Robotics and Automation* (2010), May. <http://dx.doi.org/10.1109/robot.2010.5509547>. – DOI 10.1109/robot.2010.5509547. ISBN <http://id.crossref.org/isbn/978-1-4244-5038-1>
- [GSB07] GRISETTI, Giorgio ; STACHNISS, Cyrill ; BURGARD, Wolfram: Improved techniques for grid mapping with rao-blackwellized particle filters. In: *IEEE transactions on Robotics* 23 (2007), Nr. 1, S. 34–46
- [GSB09] GRISETTI, Giorgio ; STACHNISS, Cyrill ; BURGARD, Wolfram: Nonlinear constraint network optimization for efficient map learning. In: *IEEE Transactions on Intelligent Transportation Systems* 10 (2009), Nr. 3, S. 428–439
- [GSW⁺14] GERNERT, B. ; SCHILD, S ; WOLF, L ; ZEISE, B ; FRITSCH, P ; WAGNER, B. ; MANESH, R ; MÜLLER, P.: An Interdisciplinary Approach to Autonomous Team-based Exploration in Disaster Scenarios. In: *SSRR* (2014)
- [Hab13] HABERJAHN, Mathias: *Multilevel Datenfusion konkurrierender Sensoren in der Fahr-*

- zeugumfelderfassung, Diss., 2013
- [Hau13] HAUN, Matthias: *Handbuch Robotik: Programmieren und Einsatz intelligenter Roboter*. Springer-Verlag, 2013
- [HB10] HOLZ, Dirk ; BEHNKE, Sven: Sancta simplicitas - on the efficiency and achievable results of SLAM using ICP-based incremental registration. In: *ICRA, IEEE*, 2010, 1380-1387
- [Hen12] HENTSCHEL, M.: *Langzeitnavigation mobiler Roboter in teilstrukturierten Umgebungen auf Basis eines raum- und zeitvarianten Umgebungsmodells*, Leibniz Universität Hannover, Diss., 2012
- [Hir03] HIRSCHMÜLLER, H.: *Stereo Vision Based Mapping and Immediate Virtual Walkthroughs*, School of Computing De Montfort University, Diss., 2003
- [HW10] HENTSCHEL, M. ; WAGNER, B.: Autonomous Robot Navigation Based on OpenStreet-Map Geodata. In: *13th International IEEE Conference on Intelligent Transportation Systems*, 2010
- [HWB⁺13] HORNING, Armin ; WURM, Kai M. ; BENNEWITZ, Maren ; STACHNISS, Cyrill ; BURGARD, Wolfram: OctoMap: An Efficient Probabilistic 3D Mapping Framework Based on Octrees. In: *Autonomous Robots (2013)*. <http://octomap.github.com>
- [ISNM94] ISHIDA, H. ; SUETSUGU, K. ; NAKAMOTO, T. ; MORIIZUMI, T.: Study of autonomous mobile sensing system for localization of odor source using gas sensors and anemometric sensors. In: *Sensors and Actuators A: Physical* 45 (1994), Nov, Nr. 2, 153–157. [http://dx.doi.org/10.1016/0924-4247\(94\)00829-9](http://dx.doi.org/10.1016/0924-4247(94)00829-9). – DOI 10.1016/0924-4247(94)00829-9. – ISSN 0924-4247
- [Jen] JENN, Prof. D.: *Radar Fundamentals*. Lecture Presentation,
- [KAL11] KIM, Yoon-Gu ; AN, Jinung ; LEE, Ki-Dong: Localization of Mobile Robot Based on Fusion of Artificial Landmark and RF TDOA Distance under Indoor Sensor Network. In: *INTECH (2011)*
- [KGK⁺10] KONOLIGE, Kurt ; GRISSETTI, Giorgio ; KÜMMERLE, Rainer ; BURGARD, Wolfram ; LIMKETKAI, Benson ; VINCENT, Regis: Efficient sparse pose adjustment for 2D mapping. In: *Intelligent Robots and Systems (IROS), 2010 IEEE/RSJ International Conference on IEEE*, 2010, S. 22–29
- [KGS⁺11] KUMMERLE, Rainer ; GRISSETTI, Giorgio ; STRASDAT, Hauke ; KONOLIGE, Kurt ; BURGARD, Wolfram: G2o: A general framework for graph optimization. In: *2011 IEEE International Conference on Robotics and Automation (2011)*, May. <http://dx.doi.org/10.1109/icra.2011.5979949>. – DOI 10.1109/icra.2011.5979949. ISBN <http://id.crossref.org/isbn/978-1-61284-386-5>
- [KRD08] KAESSE, Michael ; RANGANATHAN, Ananth ; DELLAERT, Frank: iSAM: Incremental smoothing and mapping. In: *IEEE Transactions on Robotics* 24 (2008), Nr. 6, S. 1365–1378

- [KSS] KHYE, T. S. ; SIM, N. C. ; SOLOMON, S. H. Y.: Comparative Analysis of Radar and Sonar Principles. – Forschungsbericht
- [KW18] KLEINSCHMIDT, S. P. ; WAGNER, B.: Visual Multimodal Odometry: Robust Visual Odometry in Harsh Environments. In: *2018 IEEE International Symposium on Safety, Security, and Rescue Robotics (SSRR)*, 2018. – ISSN 2475–8426
- [Lan14] LANGERWISCH, M.: *Kartierung und Lokalisation durch mobile Serviceroboter unter der Annahme unbekannter aber begrenzter Sensorfehler*, RTS - Leibniz Universität Hannover, Diss., 2014
- [LAW05] LIU, B. ; ADAMS, M. ; WIJESOM, W.: Range Error Detection Caused by Occlusion in Non-Coaxial LADARs for Scene Interpretation. In: *Journal of Robotic System* (2005)
- [LD03] LILIENTHAL, Achim ; DUCKETT, Tom: Creating gas concentration gridmaps with a mobile robot. In: *Intelligent Robots and Systems, 2003.(IROS 2003). Proceedings. 2003 IEEE/RSJ International Conference on* Bd. 1 IEEE, 2003, S. 118–123
- [Lec11] LECKING, D.: *Lokalisationsverfahren autonomer mobiler SSystem mittels 2D- und 3D-Umgebungsmodellen im industriellen Umfeld auf Basis einer 3D-Umgebungserfassung*, Leibniz Universität Hannover, Diss., 2011
- [Lee14] LEE, Timothy E.: Multiple Sensor Indoor Mapping Using a Mobile Robot / CS229 Final Project, Stanford. 2014. – Forschungsbericht
- [Liu10] LIU, F.: *Objektverfolgung durch Fusion von Radar- und Monokameradaten auf Merkmalsebene für zukünftige Fahrerassistenzsysteme*, Karlsruher Institut für Technologie (KIT), Diss., 2010
- [LIZ⁺07] LI, Huakang ; ISHIKAWA, Satoshi ; ZHAO, Qunfei ; EBANA, Michiko ; YAMAMOTO, Hiroyuki ; HUANG, Jie: Robot Navigation and Sound Based Position Identification. In: *IEEE International Conference on Systems, Man and Cybernetics* (2007)
- [LKKW16] LANGERWISCH, M. ; KRÄMER, S. M. ; KUHNERT, K. D. ; WAGNER, B.: Construction of 3D Environment Models by Fusing Ground and Aerial Lidar Point Cloud Data. In: *Intelligent Autonomous Systems 13. Advances in Intelligent Systems and Computing, vol 302. Springer, Cham* (2016)
- [Lun11] LUNDQUIST, Christian: *Sensor Fusion for Automotive Applications*, Diss., 2011
- [ME85] MORAVEC, H. ; ELFES, A: High resolution maps from wide angle sonar. In: *In Proc. of the IEEE Int. Conf. on Robotics & Automation (ICRA)* (1985)
- [Mey14] MEYER, M.: *Signalverarbeitung - analoge und digitale Signale, System und Filter*. Springer Vieweg, 2014
- [MM96] MARTIN, M. C. ; MORAVEC, H. P.: Robot Evidence Grids / Carnegie Mellon University. 1996. – Forschungsbericht

- [MMH13] MARCK, Jan W. ; MOHAMOUD, Ali ; HOUWEN, Rob v. Eric vd qnd Hejster H. Eric vd qnd Hejster: Indoor Radar SLAM . A Radar Application for Vision and GPS Denied Environments. In: *10th European Radar Conference*, 2013
- [MNOT15] MUHAMMAD, Shakeel ; NARDI, Daniele ; OHNO, Kazunori ; TADOKORO, Satoshi: Environmental Sensing using Millimeter Wave Sensor for Extreme Conditions. In: *SSRR* (2015)
- [MOY98] MAEYAMA, Shoichi ; OHYA, Akihisa ; YUTA, Shin' ichi: Outdoor Navigation of a Mobile Robot Using Natural Landmarks. In: *Proceedings of the Fifth International Conference on Intelligent Autonomous Systems* (1998)
- [MSCPR14] MACHADO SANTOS, Jo ao ; COUCEIRO, Micael S. ; PORTUGAL, David ; ROCHA, Rui P.: Fusing Sonars and LRF data to Perform SLAM in Reduced Visibility Scenarios. In: *International Conference on Autonomous Robot Systems and Competitions (ICARSC)*, 2014
- [MT] MONTEMERLO, M. ; THRUN, S.: Simultaneous localization and mapping with unknown data association using FastSLAM. In: *2003 IEEE International Conference on Robotics and Automation (Cat. No.03CH37422)*. <http://dx.doi.org/10.1109/robot.2003.1241885>. – DOI 10.1109/robot.2003.1241885. ISBN <http://id.crossref.org/isbn/0-7803-7736-2>
- [MT07] MONTEMERLO, Michale ; THRUN, Senbastian ; SICILIANO, Bruno (Hrsg.) ; KHATIB, Oussama (Hrsg.) ; GROEN, Frans (Hrsg.): *FastSLAM - A Scalable Method for the Simultaneous Localization and Mapping Problem in Robotics*. Springer, 2007
- [N05] NÜCHTER, A. et. a.: 3D Mapping with Semantic Knowledge. In: *RoboCup International Symposium* (2005)
- [NGB+08] NIELSEN, Curtis W. ; GERTMAN, David I. ; BRUEMMER, David J. ; HARTLEY, R. S. ; WALTON, Miles C. ; NIELSEN, Curtis W. ; GERTMAN, David I. ; BRUEMMER, David J. ; HARTLEY, R. S. ; WALTON, Miles C.: *EVALUATING ROBOT TECHNOLOGIES AS TOOLS TO EXPLORE RADIOLOGICAL AND OTHER HAZARDOUS ENVIRONMENTS*. 2008
- [NGM+07] NGUYEN, Viet ; GÄCHTER, Stefan ; MARTINELLI, Agostino ; TOMATIS, Nicola ; SIEGWART, Roland: A comparison of line extraction algorithms using 2D range data for indoor mobile robotics. In: *Autonomous Robots* 23 (2007), Aug, Nr. 2, 97–111. <http://dx.doi.org/10.1007/s10514-007-9034-y>. – DOI 10.1007/s10514-007-9034-y. – ISSN 1573-7527
- [NMTS05] NGUYEN, V. ; MARTINELLI, A. ; TOMATIS, N. ; SIEGWART, R.: A Comparison of Line Extraction Algorithms using 2D Laser Rangefinder for Indoor Mobile Robotics. In: *IROS* (2005)
- [OLT] OLSON, E. ; LEONARD, J. ; TELLER, S.: Fast iterative alignment of pose graphs with poor initial estimates. In: *Proceedings 2006 IEEE International Conference on Robotics and Automation, 2006. ICRA 2006*. <http://dx.doi.org/10.1109/robot.2006>.

1642040. – DOI 10.1109/robot.2006.1642040. ISBN <http://id.crossref.org/isbn/0-7803-9505-0>
- [PGM17] PHILLIPS, Tyson G. ; GUENTHER, Nicky ; MCAREE, Peter R.: When the Dust Settles: The Four Behaviors of LiDAR in the Presence of Fine Airborne Particulates. In: *Journal of Field Robotics* (2017), Jan. <http://dx.doi.org/10.1002/rob.21701>. – DOI 10.1002/rob.21701. – ISSN 1556-4959
- [Pie14] PIETZSCH, S.: *Modellgestützte Sensordatenfusion von Laserscanner und Radar zur Erfassung komplexer Fahrzeugumgebungen*, Diss., 2014
- [PMC⁺11] PEARSON, M. J. ; MITCHINSON, B ; C., Sullivan J. ; PIPE, A. G. ; PRESCOTT, T. J.: Biomimetic vibrissal sensing for robots. In: *Philosophical Transactions of the Royal Society B* (2011)
- [RB] RIISGAARD, Søren ; BLAS, Morten R.: *A Tutorial Approach to Simultaneous Localization and Mapping*
- [RDA⁺09] RABE, H. ; DENICKE, E. ; ARMBRECHT, G. ; MUSCH, T. ; ROLFES, I.: Considerations on radar localization in multi-target environments. In: *Advances in Radio Science* (2009)
- [RL09] REGGENTE, Matteo ; LILIENTHAL, Achim J.: Using local wind information for gas distribution mapping in outdoor environments with a mobile robot. In: *2009 IEEE Sensors* (2009), Oct. <http://dx.doi.org/10.1109/icsens.2009.5398498>. – DOI 10.1109/icsens.2009.5398498. ISBN <http://id.crossref.org/isbn/978-1-4244-4548-6>
- [RP07] RUSER, H. ; P., Leòn F.: InformaInformation - Eine Übersicht. In: *Technische Messe 74* (2007)
- [Rus95] RUSSELL, R.A.: Laying and sensing odor markings as a strategy for assisting mobile robot navigation tasks. In: *IEEE Robotics & Automation Magazine* 2 (1995), Nr. 3, 3-9. <http://dx.doi.org/10.1109/100.414920>. – DOI 10.1109/100.414920. – ISSN 1070-9932
- [RWW05] REIMER, M. ; WULF, O. ; WAGNER, B.: Continuous 360 degree real-time 3D laser scanner. In: *1st Range Imaging Research Day* (2005)
- [Sak07] SAKAMOTO, T.: A 2-D Image Stabilization Algorithm for UWB Pulse Radars with Fractional Boundary Scattering Transform. In: *The Institute of Electronics, Information and Communication Engineering* (2007)
- [San13] SANTOS, J. P. M.: *SmokeNav Simultaneous Localization and Mapping in Reduced Visibility Scenarios*, University of Coimbra - Faculty of Sciences and Technology - Department of Electrical and Computer Engineering, Diss., 2013
- [SC86] SMITH, Randall C. ; CHEESEMAN, Peter: On the Representation and Estimation of spatial Uncertainty. In: *International Journal of Robotics Research* (1986), S. 59-68
- [Sch13] SCHNEIDER, M.: *LSB-Methode Bestimmung von Distanzunterschieden mittels parame-*

- trierter Schwebungen*, Universität Rostock, Diss., 2013
- [SIC] *Operating Instructions - LMS5xx Laser Measurement Sensors. : Operating Instructions - LMS5xx Laser Measurement Sensors*
- [SL05] STUTEK, M. ; LINZMEIER, D.: Fusion von Sensordaten am Beispiel von Sicherheitsanwendungen in der Automobiltechnik. In: *Automatisierungstechnik* (2005)
- [Sot06] SOTOODEH, S.: OUTLIER DETECTION IN LASER SCANNER POINT CLOUDS. In: *IAPRS Volume XXXVI* (2006)
- [SPL09] STACHNISS, Cyrill ; PLAGEMANN, Christian ; LILIENTHAL, Achim J.: Learning gas distribution models using sparse Gaussian process mixtures. In: *Autonomous Robots* 26 (2009), Mar, Nr. 2-3, 187–202. <http://dx.doi.org/10.1007/s10514-009-9111-5>. – DOI 10.1007/s10514-009-9111-5. – ISSN 1573-7527
- [SS04] SKAMOTO, T. ; SATO, T.: A Target Shape Estimation Algorithm for Pulse Radar System Based on Boundary Scattering Transform. In: *IEICE TRANS. COMMUN* (2004)
- [SSV09] SICILIANO, Bruno ; SCIAVICCO, Lorenzo ; VILLANI, Giuseppe Luigi O. Luigi Oriolo: *Robotics: ModeModel, Planning and Control*. Springer-Verlag, 2009
- [Sta12] STACHNISS, Cyrill: *Summary on the Kalman Filter and Friends: KF, EKF, UKF, EIF, SEIF*. <http://ais.informatik.uni-freiburg.de/teaching/ws12/mapping/pdf/slam08-kf-wrapup.pdf>. Version: 2012
- [Str06] STRANG, Gilbert: *The Heat Equation and Convection-Diffusion*, 2006. <https://ocw.mit.edu/courses/mathematics/18-086-mathematical-methods-for-engineers-ii-spring-2006/readings/am54.pdf>. – Lecture Notes
- [Sün12] SÜNDERHAUF, Niko: Robust optimization for simultaneous localization and mapping. (2012)
- [SWS+13] SALMAN, R. ; WILLMS, I. ; SAKAMOTO, T. ; SATO, T. ; SATO, A. T.: Environmental Imaging with Mobile UWB Security Robot for Indoor Localisation and PosPosition Application. In: *10th European Radar Conference* (2013)
- [TB96] THRUN, S. ; BÜCKEN, A.: Integrating Grid-Based and Topological Maps for Mobile Robot Navigation. In: *Thirteenth National Conference on Artificial Intelligence* (1996)
- [TBF05] THRUN, Senastian ; BURGARD, Wolfram ; FOX, Dieter: *Probabilistic Robotics*. The MIT Press, 2005
- [VCC13] VIVET, D. ; CHECCHIN, P. ; CHAPUIS, R.: Localization and Mapping Using Only a Rotating FMCW Radar Sensor. In: *Sensors* (2013)
- [VGC+13] VIVET, Damien ; GEROSIER, Franck ; CHECCHIN, Paul ; TRASSOUDAIN, Laurent ; CHAPUIS, Roland: Mobile Ground-Based Radar Sensor for Localization and Map-

- ping: An Evaluation of two Approaches. In: *International Journal of Advanced Robotic Systems*, 2013
- [VSYZ08] VORST, Philipp ; SCHNEEGANS, Sebastian S. ; YANG, Bin ; ZELL, Andreas: Self-Localization with RFID Snapshots in Densely Tagged Environments. In: *IEEE/RSJ International Conference on Intelligent Robots and Systems* (2008)
- [WC00] WIJK, O. ; CHRISTENSEN, H. I.: Triangulation-Based Fusion of Sonar Data with Application in Robot Pose Tracking. In: *IEEE Transactions on Robotics and Automation* (2000)
- [Wei] WEIDMANN, W.: Radarsensorik zur Erfassung bewegter und stationärer Objekte (Applikationsschrift 1-4) / InnoSenT GmbH. – Forschungsbericht
- [WS04] WOLF, D. F. ; SUKHATME, S. G: Mobile robot simultaneous localization and mapping in dynamic environment. In: *ICRA* (2004)
- [Wul08] WULF, Oliver: *Virtuelle 2D-Scans - Ein Verfahren zur echtzeitfähigen Roboternavigation mit dreidimensionalen Umgebungsdaten*, RTS Uni Hannover, Diss., 2008
- [WW12] WÜBBOLD, F. ; WAGNER, B.: A Joint Segmentation and Classification of Object Shapes with Feedback for 3D Point Clouds. In: *ICINCO* (2012)
- [Yam10] YAMAUCHI, Brian: Fusing ultra-wideband radar and lidar for small UGV navigation in all-weather conditions. In: *Proc. SPIE 7692, Unmanned Systems Technology XII* (2010)
- [YB] YE, Cang ; BORENSTEIN, J.: Characterization of a 2D laser scanner for mobile robot obstacle negotiation. In: *Proceedings 2002 IEEE International Conference on Robotics and Automation (Cat. No.02CH37292)*. <http://dx.doi.org/10.1109/robot.2002.1013609>. – DOI 10.1109/robot.2002.1013609. ISBN <http://id.crossref.org/isbn/0-7803-7272-7>
- [ZV90] ZINKE, O ; VLCEK, A: *Lehrbuch der Hochfrequenztechnik*. Springer-Verlag, 1990

Liste der wissenschaftlichen Veröffentlichungen

Erstautor

- 2018 Fritsche P., Kueppers S., Briese G., Wagner B. : Fusing LiDAR and Radar Data to Perform SLAM in Harsh Environments, In: Madani K., Peaucelle D., Gusikhin O. (eds) Informatics in Control, Automation and Robotics. Lecture Notes in Electrical Engineering, vol 430. Springer, Cham
- 2017 Fritsche, P. and Wagner, B. : Modeling Structure and Aerosol Concentration with Fused Radar and LiDAR Data in Environments with Changing Visibility, 30th IEEE International Conference on Intelligent Robots and Systems (IROS), September 24-28, Vancouver, Canada.
- 2017 Fritsche, P., Zeise, B., Hemme, P. and Wagner, B. : Fusion of radar, LiDAR and thermal information for hazard detection in low visibility environments, Proc. IEEE International Symposium on Safety, Security, and Rescue Robotics (SSRR), pp. 96-101, Shanghai, China.
- 2016 Fritsche, P. and Wagner, B. : Scanning Techniques with Low Bandwidth Radar for Robotic Mapping and Localization, 12th International Conference on Informatics in Control, Automation and Robotics (ICINCO 2015), Volume 383 of Lecture Notes in Electrical Engineering, pp. 321-335, Springer International Publishing
- 2016 Fritsche, P. and Wagner, P. : Evaluation of a Novel Radar Based Scanning Method, Journal of Sensors (volume 2016, Article ID 6952075, 10 pages)
- 2016 Fritsche, P., Wagner, B. : Radar and LiDAR Sensorfusion in Low Visibility Environments, 13th International Conference on Informatics in Control, Automation and Robotics (ICINCO 2016), Lisabon, Portugal
- 2016 Fritsche, P., Zeise, B., Hemme, P. and Wagner, B. : New Perception Approaches for Mobile Robots in Low Visibility Environments, Proceedings DGR Days 2016, pp. 14
- 2015 Fritsche, P., Wagner, B. : Comparison of two Radar-Based Scanning-Techniques for the Use in Robotic Mapping, 12th International Conference on Informatics in Control, Automation and Robotics (ICINCO 2015), pp. 365-372, Colmar, France

Mitautor

- 2015 Fiosins, M., Zeise, B., Gernert, B., Schildt, S., Fritsche, P., Manesh, R., Müller, J., P., Wagner, B. and Wolf, L.: dCIM: An Agent-Based Distributed Common Information Model for Teams of Mobile Robots, Proceedings of the Autonomous Agents and Multi-Agent Systems at Scale Workshop at the International Conference on Auto Autonomous Agents and Multi-Agent Systems at Scale Workshop at the International Conference on Autonomous Agents and Multiagent Systems (AAMAS 2015), May 4-8, Istanbul, Turkey
- 2014 Gernert, B., Schildt, S., Wolf, L., Zeise, B., Fritsche, P., Wagner, B., Fiosins, M., Manesh, R. and Müller, J.: An Interdisciplinary Approach to Autonomous Team-based Exploration in Disaster Scenarios, 12th IEEE International Symposium on Safety, Security, and Rescue Robotics (SSRR), October 27–30, 2014, Lake Toya, Hokkaido, Japan

Lebenslauf

Name: Paul Fritsche

Geburtsdatum: 24.04.1987

Familienstand: verheiratet

2006 Abitur, Johann-Gottfried-Seume-Gymnasium

2006-2010 Bachelor, Maschinenbau, Hochschule Lausitz

2008 Auslandssemester, Elektrotechnik, University of Southern Denmark

2010-2012 Master, Mechatronik, Leibniz Universität Hannover

2012 Masterarbeit, Research Group on Intelligent Robotics and Systems, Polytechnic University of Catalonia

2013-2019 Wissenschaftlicher Mitarbeiter am Institut für Systems Engineering, Fachgebiet Echtzeitsysteme der Leibniz Universität Hannover