

**Ein Verfahren zur Kartierung und präzisen Lokalisierung mit  
klassifizierten Umgebungscharakteristiken der Straßeninfrastruktur  
für selbstfahrende Kraftfahrzeuge**

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

Doktor-Ingenieur

(abgekürzt Dr.-Ing.)

genehmigte Dissertation

von M. Sc. Marek Stess  
geboren am 26.06.1985 in Kattowitz

August 2017

Referent: Prof. Dr.-Ing. Bernardo Wagner  
Korreferent: Prof. Dr.-Ing. Christian Müller-Schloer  
Tag der Promotion: 07. August 2017



# Kurzfassung

Für zukünftige selbstfahrende Personenkraftwagen ist das präzise Wissen über die Position und Ausrichtung des Fahrzeugs eine fundamentale Voraussetzung. Durch den Einsatz der mobilen Systeme in natürlichen, weitläufigen und komplexen Außenszenarien, die sich fortlaufend verändern, sind Zuverlässigkeit und Robustheit von großer Bedeutung für die Lokalisierung.

In dieser Arbeit wird ein echtzeitfähiges Gesamtsystem, die Landmarkenbasierte Lokalisierung (LbL), vorgestellt. Im Gegensatz zu bisher gezeigten Lokalisierungsverfahren wird hier eine einheitliche, linienbasierte Repräsentation der Umgebung fokussiert. Es werden hierfür festgelegte Umgebungscharakteristiken der Straßeninfrastruktur, Fahrbahnmarkierungen und säulenförmige Objekte verwendet und als geometrische Grundprimitive modelliert. Insbesondere wird im Unterschied zu bestehenden Ansätzen sowohl in der Kartierung als auch in der Lokalisierung zum einen dieselbe Sensorik zur Umgebungswahrnehmung verwendet, zum anderen wird in beiden Phasen das identische Verfahren zum Aufbau eines Umfeldmodells und der daraus folgenden Kartengenerierung eingesetzt.

In dem vorgestellten Verfahren, dem Tracking- & Fusionsmodell (TFM), erfolgt der kombinierte Aufbau des Umfeldmodells und der Kartengenerierung. Das ermöglicht die zeitliche Nachverfolgung und Fusion der verwendeten Umgebungscharakteristiken. Das Grundgerüst bildet dafür ein statistischer Test, der Sequential Probability Ratio Test (SPRT). Im nachfolgenden Verfahren, dem Partikelfilterbasierten Lokalisierungsmodell (PLM), wird ein neues Sensormodell entwickelt, um eine zuverlässige und präzise Lokalisierung mit der linienbasierten Umgebungsrepräsentation durchzuführen. Für die benötigte Korrespondenzbestimmung zwischen Umfeldmodell und Karte werden deshalb neue Abstandsmetriken eingeführt.

Ein großer Teil dieser Arbeit widmet sich daher der Entwicklung und Evaluierung des Gesamtsystems und seiner Teilkomponenten. Die Bewertung der entwickelten Ansätze erfolgt durch den experimentellen Einsatz in einem Versuchsträger. Es wird eine definierte Versuchsstrecke, die vom komplexen städtischen Raum bis zum ländlichen Bereich alle Facetten abdeckt, herangezogen. Der Schwerpunkt liegt auf einer qualitativen und quantitativen Auswertung der Kartierungs- und Lokalisierungsergebnisse. Es wird dadurch gezeigt, dass die neu entwickelten Verfahren zur präzisen Lokalisierung selbstfahrender Personenkraftwagen geeignet sind.

## **Schlagworte:**

Selbstfahrende Personenkraftwagen, Linienbasierte Umfeldrepräsentation, Kartierung, Lokalisierung, Partikelfilter, Sequential Probability Ratio Test



# Abstract

For self-driving vehicles it is of fundamental importance to know the vehicle's position and orientation. The resulting challenge is to allow mobile systems for a localization with a high degree of reliability and robustness in changing outdoor settings. These settings are often natural, spacious and complex.

This work will present a real-time overall system: the Landmark based Localization (LbL). In contrast to previous localization systems the LbL uses a uniform, sparse line-based representation of the surrounding environment. As characteristics of the surrounding environment elements containing in the road infrastructure are used. In detail road markings and column shaped objects are taken into account and modelled as geometric primitives. Contrary to previous research the same sensors are used for the mapping as well as the localization of the vehicle. Also, for both phases the same methods are used to create a model of the surrounding environment (so-called environmental model) and to generate a sparse line-based map on this model.

The presented method, the Tracking and Fusion Model (TFM), combines the creation of the environmental model with the generation of the map. This allows for a temporal tracking and a fusion of the used characteristics. The TFM is based on a statistical test: the Sequential Probability Ratio Test (SPRT). A Particle based Localization Model (PLM) will be presented. This PLM aims at a precise and reliable localization in a sparse line-based representation by applying a newly introduced sensor model. A new distance metric will be pointed out to associate the environmental model into the map.

Experiments with a test vehicle will be used to evaluate the previously presented approaches. The test vehicle will drive on a priori defined test track. This track will cover different facets of urban and rural driving situations. It will be shown that the presented approaches are capable of precisely localizing self-driving vehicles.

## **Keywords:**

self-driving vehicles, sparse line-based representations, mapping, localisation, particle filter, Sequential Probability Ratio Test



# Inhaltsverzeichnis

<b>Abbildungsverzeichnis</b>	<b>xii</b>
<b>Tabellenverzeichnis</b>	<b>xvii</b>
<b>Abkürzungsverzeichnis</b>	<b>xxi</b>
<b>Symbolverzeichnis</b>	<b>xxiv</b>
<b>1 Einleitung</b>	<b>1</b>
1.1 Wissenschaftlicher Beitrag und Zielsetzung . . . . .	2
1.2 Problemstellung und Randbedingungen . . . . .	4
1.3 Lösungsansatz: Landmarkenbasierte Lokalisierung . . . . .	8
1.4 Struktur der Arbeit . . . . .	11
<b>2 Grundlagen und Stand der Technik</b>	<b>12</b>
2.1 Auszüge bisher erreichter Meilensteine automatisierter Kraftfahrzeuge . . . . .	12
2.2 Übersicht Lokalisierung . . . . .	16
2.2.1 Lokale Lokalisierung . . . . .	18
2.2.2 Globale Lokalisierung . . . . .	19
2.2.3 SLAM-Verfahren . . . . .	24
2.3 Übersicht Umfeldrepräsentation . . . . .	25
2.3.1 Punktbasierte Umfeldrepräsentation . . . . .	26
2.3.2 Rasterbasierte Umfeldrepräsentation . . . . .	27
2.3.3 Objektbasierte Umfeldrepräsentation . . . . .	28
2.3.4 Bewertungsmetriken für Karten . . . . .	30
2.4 Datenassoziiierung und Objektverfolgung . . . . .	32
2.4.1 Datenassoziiierung . . . . .	32
2.4.2 Objektverwaltung . . . . .	35
2.5 Eingliederung der Arbeit . . . . .	36
<b>3 Rahmenbedingungen und Vorarbeiten</b>	<b>39</b>
3.1 Versuchsträger und Sensorik . . . . .	39
3.1.1 Referenzlokalisierung . . . . .	41
3.1.2 Globale Poseschätzung . . . . .	41
3.1.3 Eigenbewegungsschätzung . . . . .	42
3.1.4 Umfeldsensorik . . . . .	43

3.2	Koordinatensysteme . . . . .	53
3.2.1	World Geodetic System 1984 . . . . .	54
3.2.2	Earth-Centered, Earth-Fixed . . . . .	54
3.2.3	East-North-Up . . . . .	55
3.2.4	Lokale Koordinatensysteme . . . . .	55
3.2.5	Koordinatentransformationen . . . . .	56
<b>4</b>	<b>Landmarkenbasierte Lokalisierung</b>	<b>61</b>
4.1	Gesamtarchitektur der Landmarkenbasierten Lokalisierung . . . . .	61
4.1.1	Landmarkenbeschreibung . . . . .	65
4.2	Tracking- & Fusionsmodell . . . . .	67
4.2.1	Sensor-Management-Layer (SML) . . . . .	69
4.2.2	Track-Management-Layer (TML) . . . . .	70
4.2.3	Map-Management-Layer (MML) . . . . .	72
4.2.4	Gating, Distanzfunktionen und Korrespondenzbestimmung . . . . .	74
4.2.5	Track-Management mit SPRT . . . . .	81
4.2.6	Track-Innovation . . . . .	84
4.2.7	Sichtbereiche . . . . .	89
4.3	Partikelfilterbasiertes Lokalisierungsmodell . . . . .	91
4.3.1	Bewegungsmodell . . . . .	94
4.3.2	Sensormodell . . . . .	95
4.3.3	Gewichtung der Partikel . . . . .	99
4.3.4	Smoothing . . . . .	100
4.3.5	Ergebnisberechnung . . . . .	100
4.3.6	Sampling und Resampling . . . . .	101
4.4	Verfahren zur SPRT-Parameterermittlung und Kartenbewertung . . . . .	103
4.4.1	SPRT-Parameterermittlung . . . . .	104
4.4.2	Kartenbewertung . . . . .	107
4.5	Zusammenfassung . . . . .	109
<b>5</b>	<b>Experimentelle Untersuchungen und Ergebnisse</b>	<b>111</b>
5.1	SPRT-Parameterermittlung . . . . .	112
5.1.1	Durchführung . . . . .	112
5.1.2	Ergebnisse . . . . .	114
5.1.3	Zusammenfassung . . . . .	117
5.2	Untersuchung der Kartierung und Lokalisierung . . . . .	119
5.2.1	Szenario- und Konfigurationsbeschreibung . . . . .	119
5.2.2	Kartenbewertung . . . . .	121
5.2.3	Lokalisierungsbewertung . . . . .	140
5.2.4	Zusammenfassung und Kartengröße . . . . .	149
5.3	Witterungsbasierte Lokalisierungsoptimierung . . . . .	153
5.3.1	Durchführung . . . . .	154
5.3.2	Ergebnisse und Aussage . . . . .	157
5.3.3	Zusammenfassung . . . . .	162

---

<b>6</b>	<b>Bewertung und Diskussion</b>	<b>163</b>
<b>7</b>	<b>Zusammenfassung und Ausblick</b>	<b>169</b>
<b>A</b>	<b>Versuchsträger und Sensorik</b>	<b>174</b>
A.1	Architektur des Versuchsträgers . . . . .	174
A.2	Beschreibung und technische Daten der Ortungsreferenz . . . . .	175
A.3	Beschreibung und technische Daten der globalen Poseschätzung . . . . .	176
A.4	Beschreibung und technische Daten der Eigenbewegungsschätzung . . . . .	177
A.5	Beschreibung und technische Daten der Umfeldsensorik . . . . .	177
A.5.1	Laserscanner . . . . .	177
A.5.2	Kamersysteme . . . . .	179
<b>B</b>	<b>Koordinatensysteme und Koordinatentransformationen</b>	<b>182</b>
B.1	Parameter des Erdmodells . . . . .	182
B.2	Iterativer Algorithmus zur Rücktransformation von ECEF nach WGS84 . . . . .	182
B.3	Drehmatrizen zur Transformation von ECEF nach ENU . . . . .	183
B.4	Rotationsmatrix für 6-DOF-Drehungen . . . . .	184
B.5	Transformationen zwischen zwei Bewegungszeitpunkten im VRF . . . . .	185
<b>C</b>	<b>Lösungsansatz Landmarkenbasierte Lokalisierung</b>	<b>187</b>
C.1	Darstellung der Landmarken in den unterschiedlichen Leveln . . . . .	187
C.2	Beispieldarstellung eines Tracks . . . . .	192
C.3	Beispieldarstellung der Fusion . . . . .	192
C.4	Tracking- & Fusionsmodell . . . . .	194
C.4.1	Schematische Darstellung der Eingangs- und Ausgangsdaten des TFM . . . . .	194
C.4.2	Schematische Darstellung der Konfigurationsdatei . . . . .	194
C.4.3	Abbildung der Chi-Quadrat-Verteilung . . . . .	196
C.4.4	Verfahren zur Berechnung von Lotpunkten . . . . .	196
C.5	Partikelfilterbasiertes Lokalisierungsmodell . . . . .	197
C.5.1	Schematische Darstellung der Eingangs- und Ausgangsdaten des PLM . . . . .	198
C.5.2	Beweis zur Umformung innerhalb des Sensormodells . . . . .	198
C.5.3	Dynamisches Resampling . . . . .	199
C.5.4	Exemplarisches Verhalten des Partikelfilters . . . . .	200
<b>D</b>	<b>Experimente</b>	<b>201</b>
D.1	Überblick der Versuchsstrecke zur SPRT-Parameterbestimmung . . . . .	201
D.2	Überblick der Versuchsstrecke zur Kartierung und Lokalisierung . . . . .	202
D.3	Visualisierung der Kartierungsergebnisse der LbL . . . . .	212
D.4	Weiterführende Lokalisierungsergebnisse der LbL . . . . .	224
D.5	Algorithmus zur Bestimmung der Standardabweichung für den Mittelwert . . . . .	227
D.6	Verrauschen der Applanix . . . . .	227

---

<b>Stichwortverzeichnis</b>	<b>231</b>
<b>Literaturverzeichnis</b>	<b>256</b>
<b>Disclaimer</b>	<b>258</b>
<b>Danksagung</b>	<b>260</b>
<b>Liste der Veröffentlichungen</b>	<b>263</b>
<b>Liste der betreuten Arbeiten</b>	<b>264</b>
<b>Selbstständigkeitserklärung</b>	<b>266</b>
<b>Über den Autor</b>	<b>268</b>





# Abbildungsverzeichnis

1.1	Darstellung der Unsicherheitsbereiche bei verschiedenen Lokalisierungen . . . . .	4
1.2	Übersicht der Landmarkenbasierten Lokalisierung (LbL) . . . . .	10
2.1	Versuchsfahrzeug VaMoR . . . . .	13
2.2	Versuchsfahrzeug VaMP . . . . .	13
2.3	DARPA-Gewinnerfahrzeuge Standley und BOSS . . . . .	15
2.4	Exemplarische Darstellung unterschiedlicher Forschungsfahrzeuge . . . . .	16
2.5	Punktbasierte lokale und globale Umfeldrepräsentation . . . . .	27
2.6	Exemplarisches Beispiel für Rasterkarten . . . . .	28
2.7	Übersicht der punktbasierten Tracking-Verfahren . . . . .	33
3.1	Versuchsfahrzeug Audi Piloted Driving Concept . . . . .	40
3.2	Schritte der Kamerakalibrierung . . . . .	41
3.3	Genauigkeitsanalyse des OEMStar GPS-Empfängers . . . . .	42
3.4	Geschwindigkeitskorrektur der Eigenbewegungsschätzung . . . . .	42
3.5	Schematische Darstellung der Laserstrahlen . . . . .	44
3.6	Straßenreflexionen im Vergleich . . . . .	45
3.7	Sichtbereich des Laserscanners . . . . .	46
3.8	Landmarken aus dem Kamerabild . . . . .	47
3.9	Sichtbereich der Front-Monokamera . . . . .	47
3.10	Ausgabe der Fischaugenkameras . . . . .	48
3.11	Vogelperspektive des TopView-Systems . . . . .	49
3.12	Sichtbereich des TopView-Systems . . . . .	49
3.13	Ermittelte Kovarianzen des Laserscanner . . . . .	51
3.14	Schematische Darstellung des Kameramodells . . . . .	52
3.15	Ermittelte Kovarianzen der Kamera . . . . .	53
3.16	Übersicht der relevanten Koordinatensysteme . . . . .	54
3.17	Übersicht der lokalen, fahrzeugeigenen Koordinatensysteme . . . . .	56
3.18	Darstellung der Transformation zwischen zwei Koordinatensystemen . . . . .	59
3.19	Schematische Darstellung der Transformation zwischen zwei Zeitpunkten . . . . .	60
4.1	Architekturübersicht der LbL . . . . .	64
4.2	3-Schichten-Architektur des Tracking- & Fusionsmodells . . . . .	67
4.3	Datenverarbeitungsprozess des TFM . . . . .	68
4.4	Ablauf der zeitlichen Synchronisierung . . . . .	70

4.5	Ablauf der Kartengenerierung im MML . . . . .	73
4.6	Visualisierung der erzeugten Karte des TFM . . . . .	74
4.7	Elliptisches und rechteckiges Gating . . . . .	76
4.8	Abstandsberechnung der punktbasierten Landmarken . . . . .	77
4.9	Abstandsberechnung der linienbasierten Landmarken . . . . .	77
4.10	Abstandsberechnung der polylinienbasierten Landmarken . . . . .	79
4.11	Exemplarische Verlaufsentwicklung des LLR . . . . .	83
4.12	Positionsaktualisierung der polylinienbasierten Landmarken . . . . .	87
4.13	Exemplarische Darstellung der Sichtbereiche . . . . .	89
4.14	Mathematisch positiver Umlauf der Sichtbereichspunkte . . . . .	90
4.15	Vektorbildung der Sichtbereichspunkte zur Landmarke . . . . .	91
4.16	Approximation einer Verteilung mit gewichteten Stichproben . . . . .	92
4.17	Datenverarbeitungsprozess des PLM . . . . .	94
4.18	Exemplarische Veranschaulichung des entwickelten Sensormodells . . . . .	98
4.19	Visualisierung der Blickrichtungsberechnung . . . . .	101
4.20	Zufallsgenerator der Halton-Sequenz und der Gauß-Verteilung . . . . .	102
4.21	Verfahren zum stochastisch-universellen Ziehen . . . . .	103
4.22	Schematische Darstellung der SPRT-Parameterermittlung . . . . .	106
4.23	Unterteilung der Fahrzeugtrajektorie durch Kreisabschnitte . . . . .	108
4.24	Kartenvergleich je Kreisabschnitt . . . . .	108
4.25	Schematische Darstellung der Ähnlichkeitsanalyse . . . . .	109
5.1	Luftbild der urbanen Versuchsstrecke für die SPRT-Parameterbestimmung . . . . .	113
5.2	Ausschnitt der erzeugten Referenzkarte . . . . .	113
5.3	SPRT-Parameter des Laserscanners . . . . .	114
5.4	SPRT-Parameter der Front-Monokamera . . . . .	115
5.5	SPRT-Parameter der vorderen Fischaugenkamera . . . . .	116
5.6	SPRT-Parameter der linken Fischaugenkamera . . . . .	116
5.7	SPRT-Parameter der hinteren Fischaugenkamera . . . . .	117
5.8	SPRT-Parameter der rechten Fischaugenkamera . . . . .	117
5.9	Versuchsstrecke der Kartierung und Lokalisierung . . . . .	120
5.10	Ortsaufgelöster Landmarkenunterschied punktbasierter Kartenlandmarken . . . . .	122
5.11	Qualitative Betrachtung der punktbasierten Kartenlandmarken . . . . .	123
5.12	Ortsaufgelöster Landmarkenunterschied linienbasierter Kartenlandmarken . . . . .	124
5.13	Qualitative Betrachtung der linienbasierten Kartenlandmarken . . . . .	125
5.14	Ortsaufgelöster Landmarkenunterschied polylinienbasierter Kartenlandmarken . . . . .	126
5.15	Qualitative Betrachtung der polylinienbasierten Kartenlandmarken . . . . .	127
5.16	Ortsaufgelöster Landmarkenunterschied kombinierter Kartenlandmarken . . . . .	128
5.17	Qualitative Betrachtung der kombinierten Kartenlandmarken . . . . .	129
5.18	Landmarkenunterschiede in punktbasierten Kartenlandmarken . . . . .	130
5.19	Quantitative Betrachtung der punktbasierten Kartenlandmarken . . . . .	131
5.20	Landmarkenunterschiede in linienbasierten Kartenlandmarken . . . . .	133
5.21	Quantitative Betrachtung der linienbasierten Kartenlandmarken . . . . .	134
5.22	Landmarkenunterschiede in polylinienbasierten Kartenlandmarken . . . . .	135

5.23	Quantitative Betrachtung der polylinienbasierten Kartenlandmarken . . . . .	136
5.24	Landmarkenunterschiede mit kombinierten Kartenlandmarken . . . . .	137
5.25	Quantitative Betrachtung der kombinierten Kartenlandmarken . . . . .	138
5.26	Ermittlung der Genauigkeitsanforderung . . . . .	141
5.27	Streuung und Schiefe der LbL . . . . .	142
5.28	Ortsaufgelöste LbL-Positionsfehler . . . . .	143
5.29	LbL-Positionsfehler im Zeitverlauf . . . . .	145
5.30	Histogramm der LbL-Positionsfehler . . . . .	146
5.31	Kumulative Verteilung der LbL-Positionsfehler . . . . .	147
5.32	Boxplot der LbL-Positionsfehler . . . . .	147
5.33	Umgebungswahrnehmung je Kategorie . . . . .	154
5.34	Schematische Darstellung des Sichtbereichs . . . . .	155
5.35	Darstellung verschiedener Sichtbereichsvariationen . . . . .	156
5.36	Ergebnis der Parameteroptimierung einer Fahrt . . . . .	160
5.37	Ermittelte Parameterkombinationen je Kategorie . . . . .	161
5.38	Schematische Darstellung der optimierten Sichtbereiche . . . . .	162
A.1	Architektur des Versuchsträgers . . . . .	174
A.2	Komponenten der verwendeten Ortungsreferenz . . . . .	175
A.3	Darstellung des verwendeten GPS-Empfänger . . . . .	176
A.4	Genauigkeitsanalyse des GPS-Empfänger . . . . .	176
A.5	Genauigkeitsvergleich der Eigenbewegungsschätzung . . . . .	177
A.6	Darstellungen des Laserscanners . . . . .	178
A.7	Schematische Draufsicht der Laserstrahlen . . . . .	179
A.8	Darstellung der Front-Monokamera . . . . .	179
A.9	Darstellung einer Fischaugenkamera des TopView-Systems . . . . .	180
A.10	Schematischer Zusammenhang der kamerabasierten Fehlerfortpflanzung . . . . .	181
B.1	3D-Rotationsübersicht . . . . .	184
B.2	Zusammenhang der Positionen in den Koordinatensystemen . . . . .	185
C.1	Darstellung der Landmarken aus der Front-Monokamera in jeder Gütestufe . . . . .	188
C.2	Darstellung der Landmarken des Laserscanners in jeder Gütestufe . . . . .	189
C.3	Darstellung der Landmarken aus dem TopView-System in jeder Gütestufe . . . . .	190
C.4	Darstellung der Landmarken aus der Fusion im TFM in jeder Gütestufe . . . . .	191
C.5	Darstellung eines Tracks . . . . .	192
C.6	Beispiel der Fusion . . . . .	193
C.7	Eingangs- und Ausgangsdaten für das TFM . . . . .	194
C.8	Struktur der Konfigurationsdatei . . . . .	195
C.9	Chi-Quadrat-Verteilung . . . . .	196
C.10	Schematische Darstellung der Lotpunktberechnung . . . . .	197
C.11	Eingangs- und Ausgangsdaten des PLM . . . . .	198
C.12	Exemplarische Darstellung des dynamischen Resamplings . . . . .	199
C.13	Phasen des PLM . . . . .	200

D.1	1. Teilabschnitt der SPRT-Versuchsstrecke . . . . .	201
D.2	2. Teilabschnitt der SPRT-Versuchsstrecke . . . . .	202
D.3	3. Teilabschnitt der SPRT-Versuchsstrecke . . . . .	202
D.4	4. Teilabschnitt der SPRT-Versuchsstrecke . . . . .	202
D.5	Start/Ende der Versuchsstrecke . . . . .	203
D.6	Abschnitt 2 und 3 der Versuchsstrecke . . . . .	204
D.7	Abschnitt 4 der Versuchsstrecke . . . . .	205
D.8	Abschnitt 5 der Versuchsstrecke . . . . .	205
D.9	Abschnitt 6 der Versuchsstrecke . . . . .	206
D.10	Abschnitt 7 und 8 der Versuchsstrecke . . . . .	207
D.11	Abschnitt 9 der Versuchsstrecke . . . . .	208
D.12	Abschnitt 10 der Versuchsstrecke . . . . .	209
D.13	Abschnitt 11 der Versuchsstrecke . . . . .	209
D.14	Abschnitt 12 der Versuchsstrecke . . . . .	211
D.15	Abschnitt 13 der Versuchsstrecke . . . . .	211
D.16	Abschnitt 14 der Versuchsstrecke . . . . .	211
D.17	Ende/Start der Versuchsstrecke in Braunschweig . . . . .	212
D.18	Kartenlandmarken des 1. Streckenabschnitts . . . . .	213
D.19	Kartenlandmarken des 2. Streckenabschnitts . . . . .	214
D.20	Kartenlandmarken des 3. Streckenabschnitts . . . . .	214
D.21	Kartenlandmarken des 4. Streckenabschnitts . . . . .	215
D.22	Kartenlandmarken des 5. Streckenabschnitts . . . . .	216
D.23	Kartenlandmarken des 6. Streckenabschnitts . . . . .	217
D.24	Kartenlandmarken des 7. Streckenabschnitts . . . . .	218
D.25	Kartenlandmarken des 8. Streckenabschnitts . . . . .	218
D.26	Kartenlandmarken des 9. Streckenabschnitts . . . . .	219
D.27	Kartenlandmarken des 10. Streckenabschnitts . . . . .	220
D.28	Kartenlandmarken des 11. Streckenabschnitts . . . . .	221
D.29	Kartenlandmarken des 12. Streckenabschnitts . . . . .	222
D.30	Kartenlandmarken des 13. Streckenabschnitts . . . . .	223
D.31	Kartenlandmarken des 14. Streckenabschnitts . . . . .	223
D.32	Kartenlandmarken des letzten Streckenabschnitts . . . . .	224
D.33	Visualisierung von Fehlern und Standardabweichung der LbL . . . . .	225
D.34	Blickrichtungs-, Geschwindigkeits- und Gierwinkelfehler der LbL . . . . .	226
D.35	Absolutes Verrauschen der Ortungsreferenz . . . . .	228
D.36	Relatives Verrauschen der Ortungsreferenz . . . . .	229



# Tabellenverzeichnis

2.1	Exemplarische Darstellung einer Korrespondenzmatrix . . . . .	33
3.1	Auflistung der erkannten Landmarken pro verwendetem Sensor . . . . .	43
4.1	Zustandsvektordefinition der Landmarken . . . . .	65
4.2	Beschreibung der SPRT-Parameter . . . . .	105
5.1	Auflistung der SPRT-Parameter je Landmarkentyp . . . . .	118
5.2	Wahrheitsmatrix des punktbasierten Kartenvergleichs . . . . .	132
5.3	Absolute Bewertung des punktbasierten Kartenvergleichs . . . . .	132
5.4	Wahrheitsmatrix des linienbasierten Kartenvergleichs . . . . .	133
5.5	Absolute Bewertung des linienbasierten Kartenvergleichs . . . . .	133
5.6	Wahrheitsmatrix des polylinienbasierten Kartenvergleichs . . . . .	137
5.7	Absolute Bewertung des polylinienbasierten Kartenvergleichs . . . . .	137
5.8	Wahrheitsmatrix des kombinierten Kartenvergleichs . . . . .	139
5.9	Absolute Bewertung des kombinierten Kartenvergleichs . . . . .	139
5.10	Absolute Fehlerbetrachtung der LbL . . . . .	145
5.11	Sigma-Werte der LbL-Positionsfehler . . . . .	148
5.12	Boxplot-Werte der LbL-Positionsfehler . . . . .	149
5.13	Auflistung der Kartengrößen der LbL-Versuchsstrecke . . . . .	151
5.14	Auflistung der Kartengrößen der SPRT-Versuchsstrecke . . . . .	152
5.15	Absolute Durchschnittsabweichung der LbL bei verschiedenen Sichtbereichen .	159
5.16	Ermittelte Sichtbereiche je Witterungskategorie . . . . .	162
A.1	Genauigkeiten der Ortungsreferenz mit GNSS . . . . .	175
A.2	Genauigkeiten der Ortungsreferenz ohne GNSS . . . . .	175
A.3	Technische Angaben zum GPS-Empfänger . . . . .	176
A.4	Technische Daten des Laserscanners . . . . .	178
A.5	Technische Daten der Front-Monokamera . . . . .	180
A.6	Technische Daten einer Fischaugenkamera des TopView-Systems . . . . .	181
B.1	Parameter des WGS84-Erdmodells . . . . .	182





# Abkürzungsverzeichnis

<b>ABS</b>	Antiblockiersystem
<b>DDS</b>	Data Distribution Service
<b>DGPS</b>	Differential Global Positioning System
<b>DOF</b>	Degrees Of Freedom
<b>DQVS</b>	Distance of Quadratic Vertex Sum
<b>ECEF</b>	Earth-Centered, Earth-Fixed
<b>EKF</b>	Extended Kalman Filter
<b>EM</b>	Expectation Maximization
<b>ENU</b>	East-North-Up
<b>ESP</b>	Elektronisches Stabilitätsprogramm
<b>FAST</b>	Features from Accelerated Segment Test
<b>FOV</b>	Field Of View
<b>GLONASS</b>	Global Navigation Satellite System
<b>GML</b>	Geography Markup Language
<b>GNN</b>	Global Nearest Neighbour
<b>GNSS</b>	Global Navigation Satellite System
<b>GPS</b>	Global Positioning System
<b>HCA</b>	Hierarchical Cluster Analysis
<b>ICP</b>	Iterative Closest Point
<b>ID</b>	Identifikationsnummer
<b>IMU</b>	Inertial Measurement Unit
<b>JPDA</b>	Joint Probabilistic Data Association
<b>KF</b>	Kalman-Filter
<b>Ladar</b>	Laser Detection and Ranging
<b>LAN</b>	Local Area Network
<b>LbL</b>	Landmarkbasierte Lokalisierung
<b>LaDAR</b>	Laser Detection and Ranging
<b>LiDAR</b>	Light Detection and Ranging
<b>LLR</b>	Log-Likelihood-Quotienten
<b>MC-JPDA</b>	Monte Carlo Joint Probabilistic Data Association
<b>MCL</b>	Monte-Carlo-Lokalisierung
<b>MHT</b>	Multi Hypothesis Tracking

---

<b>MML</b>	Map-Management-Layer
<b>MSER</b>	Maximally Stable Extremal Regions
<b>NAVSTAR</b>	Navigation System using Time and Ranging
<b>NDS</b>	Navigation Data Standard
<b>NDT</b>	Normal Distributions Transform
<b>NED</b>	North-East-Down
<b>NN</b>	Nearest Neighbour
<b>NTP</b>	Network Time Protocol
<b>OCCS</b>	Origin Car Coordinate System
<b>OEM</b>	Original Equipment Manufacturer
<b>PCA</b>	Principal Component Analysis
<b>PDA</b>	Probabilistic Data Association
<b>PF</b>	Partikelfilter
<b>PKW</b>	Personenkraftwagen
<b>PLM</b>	Partikelfilterbasiertes Lokalisierungsmodell
<b>PRN</b>	Pseudo Random Noise
<b>RANSAC</b>	Random Sample Consensus
<b>RMS</b>	Root Mean Square
<b>ROI</b>	Region Of Interest
<b>ROS</b>	Robot Operating System
<b>SBAS</b>	Satellite Based Augmentation System
<b>SDM</b>	Sensor-Data-Management
<b>SDO</b>	Sensor-Data-Object
<b>SIFT</b>	Scale Invariant Feature Transform
<b>SLAM</b>	Simultaneous Localisation and Mapping
<b>SML</b>	Sensor-Management-Layer
<b>SNR</b>	Signal-to-Noise-Ratio
<b>SoG</b>	Sum of Gaussians
<b>SPRT</b>	Sequential Probability Ratio Test
<b>SRF</b>	Sensor Reference Frame
<b>SURF</b>	Speeded Up Robust Features
<b>TFM</b>	Tracking- & Fusionsmodell
<b>TML</b>	Track-Management-Layer
<b>UKF</b>	Unscented Kalman Filter
<b>VRF</b>	Vehicle Reference Frame
<b>WGS84</b>	World Geodetic System 1984
<b>XML</b>	Extensible Markup Language



# Symbolverzeichnis

Dieses Symbolverzeichnis mit den folgenden aufgeführten Formelzeichen listet lediglich die zum Verständnis der Arbeit wichtigsten Notationen auf. Selten verwendete Symbole, Zeichen und eventuelle Mehrdeutigkeiten werden explizit im Text erläutert.

## Koordinatensysteme

$\xi$	Koordinatensystem
$\xi^{\text{wgs}}, \xi^{\text{enu}}, \xi^{\text{vrf}}, \xi^{\text{srf}}, \xi^{\text{oocs}}$	WGS-, ENU-, VRF-, SRF- und OCCS-Koordinatensysteme
$x, y, z$	Koordinatenachsen im kartesischem Koordinatensystem
$\lambda, \phi$	Longitude und Latitude Angabe im $\xi^{\text{wgs}}$
$\varsigma$	Pose des Fahrzeugs
$\theta$	Blickrichtung des Fahrzeugs

## SPRT-Parameter

$P_G$	Probability Gate: Wahrscheinlichkeit, dass eine Messung eines Ziels im Gate liegt
$P_D$	Probability Detection: Wahrscheinlichkeit, dass eine Messung von einem Ziel stammt
$\beta_{NT}$	New Target Rate: Wahrscheinlichkeit, dass eine neue Messung ein echtes Ziel ist
$\beta_{FA}$	False Alarm Rate: Wahrscheinlichkeit, dass eine Messung kein echtes Ziel ist
$\text{LLR}^i(\tau)$	Log-Likelihood-Quotienten (Konfidenzwert) der $i$ -ten Landmarke zum Zeitpunkt $\tau$

## Landmarkenbasierte Lokalisierung

$\Upsilon$	Ergebnispose der LbL
$A$	Matrix der Korrespondenzbestimmung
$d^{\text{PO}}, d^{\text{DL}}, d^{\text{PL}}$	Distanzfunktionen für punktbasierte, linienbasierte und polylinienbasierte Landmarken

## Landmarkendefinitionen

$PO, DL, PL$	Punktbasierte, linienbasierte und polylinienbasierte Landmarke
$s^{PO}, s^{DL}, s^{PL}$	Zustandsvektor der punktbasieren, linienbasieren und polylinienbasieren Landmarken
$b^{s^{PO}}, b^{s^{DL}}, b^{s^{PL}}$	Punktbasierte, linienbasierte und polylinienbasierte Level-1 Landmarke (eine Landmarke einer Messung $\mathcal{B}$ )
$t^{s^{PO}}, t^{s^{DL}}, t^{s^{PL}}$	Punktbasierte, linienbasierte und polylinienbasierte Level-2 Landmarke (eine Landmarke aus den Tracks $\mathcal{T}$ )
$m^{s^{PO}}, m^{s^{DL}}, m^{s^{PL}}$	Punktbasierte, linienbasierte und polylinienbasierte Level-3 Landmarke (eine Landmarke aus der Karte $\mathcal{M}$ )
$\mathcal{B}$	Menge aller Level-1-Landmarken (Messung)
$\mathcal{T}$	Menge aller Level-2-Landmarken (Tracks)
$\mathcal{M}$	Menge aller Level-3-Landmarken (Karte)

## Partikelfilter

$z$	Wahrgenommene Beobachtung
$\mathcal{Z}$	Menge aller wahrgenommenen Beobachtungen
$\mathcal{P}$	Menge aller Partikel
$s^{\text{Partikel}}$	Zustandsvektor eines Partikels
$\omega$	Gewicht eines Partikels
$\nu$	Minimalwahrscheinlichkeit einer Korrespondenzbestimmung

## Allgemeine Indizes

$\tau$	Zeitpunkt
$\hat{s}$	Prädiktion eines Zustands $s$
$\tilde{s}$	Aktualisierter Zustands $s$
$\bar{x}$	Normierung eines Wertes
$\Sigma$	Kovarianzmatrix
$S^{-1}$	Inverse der Kovarianzmatrix
$J$	Jacobi-Matrix
$p, q$	Jeweils ein Punkt
$\mathcal{O}$	Landau-Symbol zur Laufzeitangabe von Algorithmen
$h, i, k, r, n, o, l, f, j, g$	Laufindizes
$H, I, K, R, N, O, L, F, J, G$	Maximaler Wert des Laufindex
$R$	Rotationsmatrix
$\chi^2$	Chi-Quadrat-Verteilung
$\mathcal{N}$	Normalverteilung
$\sigma$	Standardabweichung



# Kapitel 1

## Einleitung

Seit mehreren Jahrzehnten nimmt der Einsatz von automatisierten mobilen Systemen stetig zu [1, 2]. Dabei ist die Verwendung von Robotersystemen nicht nur auf das industrielle Umfeld beschränkt, sondern hält auch immer mehr Einzug in den privaten Bereich. Vor allem beim Personenkraftwagen (PKW) ist eine fortschreitende Automatisierung zu beobachten. Das oberste Ziel ist dabei die Entwicklung eines selbstfahrenden PKWs. Im Zuge der Verwirklichung dieses Ziels müssen vor allem Fragen der Ortung untersucht und gelöst werden.

Daher stehen im Fokus aktueller Forschungen Ortungsverfahren, die in realen, veränderlichen und weitläufigen Arbeitsumgebungen eine präzise Lokalisation erlauben. Hierfür werden Lokalisierungsverfahren eingesetzt, die aufgrund der aktuellen Umgebungswahrnehmung, die Position und Orientierung des mobilen Systems innerhalb einer vorab bekannten Karte ermitteln. Für die Generierung der Karte werden Kartierungsverfahren auf Basis der bekannten Positionen des mobilen Systems genutzt. Die Grundlage für die Kartierung und Lokalisierung bildet die sensorische Umgebungswahrnehmung. Mit den heutigen Verfahren zur Kartierung und Lokalisierung ergeben sich jedoch zwei Problemstellungen.

Zum einen werden bislang die einzelnen Verfahren voneinander getrennt betrachtet. Die für die Lokalisation benötigte Karte wird einmalig mit gesonderten Messfahrzeugen erzeugt. Eingesetzt werden dafür aufwendige, spezielle Verfahren und teure, hochwertige Sensorkonstellationen, um ein möglichst präzises Abbild der Umgebung zu schaffen. Während der Lokalisierung wird bisher eine fortlaufende Gültigkeit der Karte angenommen. Selbstfahrende Automobile bewegen sich jedoch in realen Umgebungen, in denen dynamische Veränderungen auftreten. Die Folge ist, dass nicht alle während der Lokalisierung wahrgenommenen Objekte in der zur Verfügung stehenden Karte enthalten sind und umgekehrt nicht jedes in der Karte enthaltene Objekt wahrgenommen wird. Diese Problematik kann nur gelöst werden, indem die Karte zukünftig ständig aktualisiert wird. Aufgrund der unterschiedlichen Repräsentation des Umfeldmodells während der Kartierung und Lokalisierung ist das heute nicht möglich, weshalb in dieser Dissertation die Grundlagen für spätere Kartenaktualisierungen gebildet werden.

Zum anderen verwenden die heutigen Verfahren eine reichhaltige, dichte (viele Elemente) Umgebungsrepräsentation, um die geforderten Genauigkeitsanforderungen der Lokalisierung zu erfüllen. Durch die weitläufigen und großflächigen Einsatzgebiete selbstfahrender Kraftfahrzeuge sind solche Umgebungsrepräsentationen mit Nachteilen behaftet. Einerseits steigt der benötigte Speicherbedarf der Karte mit dem wachsenden Kartierungsbereich an [3–6]. Andererseits

ist eine zukünftige kontinuierliche Aktualisierung der Karte (z.B. über eine Luftschnittstelle) mit dieser Umgebungsrepräsentation nicht kosteneffizient möglich.

Die Herausforderung liegt daher in der Entwicklung eines Verfahrens zur kombinierten Kartierung und präzisen Lokalisierung eines selbstfahrenden PKWs mit einer dünnen (geringen Anzahl an Elementen und evtl. Lücken) Umgebungsrepräsentation (engl. sparse map). Im Rahmen dieser Arbeit wird ein Ortungsverfahren, basierend auf klassifizierten Straßeninfrastrukturelementen, den Fahrbahnmarkierungen und säulenförmigen Objekten, vorgestellt. Aufgrund der Fusion von abstrakten Sensordaten unterschiedlicher Sensorik sowie zeitlicher Nachverfolgung findet die Erstellung eines konsistenten Umfeldmodells und daraus die Generierung einer Karte statt. Das Verfahren kommt sowohl während der Kartierung als auch der Lokalisierung mit der gleichen umfeldwahrnehmenden Sensorik zum Einsatz. Es erfolgt die Vorstellung einer skalierbaren Ortungsarchitektur.

## 1.1 Wissenschaftlicher Beitrag und Zielsetzung

Diese Arbeit liefert einen Beitrag zur zweidimensionalen Kartierung und Lokalisierung für den Einsatz in selbstfahrenden Automobilen. Das Hauptaugenmerk liegt dabei auf komplexen urbanen, vielseitigen Außenszenen. Im Gegensatz zu bisherigen Verfahren steht dabei einerseits die Erzeugung einer kompakten, dünnen Karte und andererseits die präzise Lokalisierung innerhalb einer solchen Karte im Fokus.

Zur Lokalisation in Innenszenarien, wie beispielsweise in Büroräumen, Privatwohnungen oder industriellen Umgebungen, kann durch Integration zusätzlicher spezieller Infrastruktur, wie beispielsweise Reflektorfolie, Magnetenägel oder aktive Sender, eine Positionsbestimmung mit einmaliger Kartierung erreicht werden. Eine solche Lösung kann aus Kostengründen, den dynamischen Eigenschaften und des weiträumigen Einsatzraumes der Kraftfahrzeuge nicht angewendet werden. Einschränkend kommt hinzu, dass typische Strukturen, die in Innenbereichen genutzt werden, wie beispielsweise Wände oder Decken, in Außenszenarien erst gar nicht vorhanden oder durch Verdeckungen nicht sensorisch erfassbar sind.

Der aktuelle Forschungsschwerpunkt liegt in der Entwicklung angepasster Kartierungs- und Lokalisierungsverfahren für weiträumige, komplexe Einsatzgebiete im Außenbereich. Die grundlegenden Ansätze unterscheiden sich in der verwendeten Umgebungsrepräsentation (siehe Kapitel 2.3). Hierbei sind Verfahren mit punktbasierter [7–11] und rasterbasierter Umgebungsrepräsentation [12–15] zu nennen. Ebenso finden Mischformen beider Repräsentationen Einsatz [16–18]. Jedoch haben diese Verfahren zwei Einschränkungen. Zum einen wird für die Kartierung spezielle umfeldwahrnehmende Sensorik mit besonderem Aufbau verwendet (im Gegensatz zur genutzten Sensorik bei der Lokalisierung) und teilweise ist eine manuelle Nachbearbeitung der erstellten Karte nötig. Zum anderen entstehen bei punktbasierten und rasterbasierten Repräsentationen dichte Karten, dessen Folge eine Steigerung des benötigten Speicherbedarfs ist [3–6]. Das führt zu einer signifikanten Einschränkung aktueller Verfahren in ihrer Skalierbarkeit zur weiträumigen Kartierung. Um diesen Nachteil auszugleichen, können linienbasierte Repräsentationen (Teilgebiet der objektbasierten Repräsentation, in der alle Elemente in geometrischen Grundprimitiven modelliert werden (engl. line-based maps, siehe Kapitel 2.3.3)), ähnlich den Verfahren für Innenszenarien [3, 19–22], auf die Umgebungscharakteristiken der



Kraftfahrzeuge übertragen werden. Eine solche Repräsentation bietet eine höhere Genauigkeit. Begründet ist das durch die Verwendung von Fließkommaauflösungen und -berechnungen, in denen trotz einer gleichzeitigen kompakten Umgebungsdarstellung [23] keine Diskretisierungsprobleme auftreten. Zudem wird in [24–26] gezeigt, dass eine Lokalisierung bei Nutzung von linienbasierten Karten und einem linienbasierten Umgebungsmodell erfolgreich durchgeführt werden kann.

Der Ansatz linienbasierter Repräsentationen wird in der vorliegenden Arbeit auf selbstfahrende Kraftfahrzeuge angewendet. Hiermit wird die wissenschaftliche Lücke der bisher unterschiedlichen Umgebungsrepräsentationen und Sensorikkonstellationen während der Kartierung und Lokalisierung geschlossen. Das übergeordnete Ziel ist dabei die präzise Lokalisierung des mobilen Systems unter Verwendung einer kompakten, dünnen Karte und eines linienbasierten Umfeldmodells.

In dieser Arbeit wird während der Kartierung und Lokalisierung dieselbe Umfeldsensorik verwendet. Die Sensorik stellt direkt klassifizierte, abstraktere Sensordaten, im Sinne von geometrischen Grundprimitiven wie Linien, Polylinien (Linienzüge) und Punkten, der wahrgenommenen Straßeninfrastruktur bereit. Hierfür werden invariante semi-persistente Umgebungsmerkmale der vorhandenen Straßeninfrastruktur verwendet, die sich in den genannten geometrischen Strukturen abbilden lassen. Herangezogen werden Fahrbahnmarkierungen (gestrichelte, durchgezogene, und Haltelinien sowie Pfeile) und säulenförmige Objekte (Stangen bzw. Pfosten von Ampelanlagen, Straßenschildern oder Litfaßsäulen). Für die gewählte Repräsentation der geometrischen Grundprimitive (siehe Kapitel 4.1) wird in dieser Arbeit erstmalig ein effizientes und modulares Verfahren zur Fusion und Nachverfolgung auf Basis eines statistischen Tests, dem SPRT [27], eingeführt. Es ermöglicht den Aufbau eines konsistenten, linienbasierten Umfeldmodells, trotz unterschiedlicher Qualitäten und Frequenzen der jeweiligen Sensorik und die kontinuierliche Erzeugung einer Karte. Zur Gewährleistung einer robusten und präzisen Lokalisierung auf Grundlage eines linienbasierten Umfeldmodells und einer linienbasierten Karte, wird das probabilistische Verfahren eines Partikelfilters [28] eingesetzt. Die Methode wird zur Verwendung mit den beschriebenen Objekten adaptiert. Vor allem wird ein neues, robustes Sensormodell zur Korrespondenzbestimmung mit geometrischen Grundprimitiven eingeführt.

Insgesamt lassen sich die folgenden Ziele und deren wissenschaftlicher Beitrag festhalten:

- eine Untersuchung auf Eignung der beschriebenen Landmarken zur Kartierung und Lokalisierung,
- die Entwicklung eines Verfahrens zur präzisen Lokalisierung, das durch Korrespondenzbestimmung zwischen linienbasiertem Umfeldmodell und einer linienbasierten Karte die Pose (Position und Orientierung) des Fahrzeugs ermittelt,
- die Entwicklung eines einheitlichen Verfahrens für die Kartierung und Lokalisierung, das effizient und modular die Fusion und zeitliche Nachverfolgung der Landmarken aus unterschiedlichen Sensoren ermöglicht,
- die experimentelle Evaluation und Prüfung der entwickelten Verfahren zur Kartierung und Lokalisierung auf die Eignung zum Einsatz in selbstfahrenden Personenkraftwagen.

## 1.2 Problemstellung und Randbedingungen




Abbildung 1.1: Darstellung der Unsicherheitsbereiche bei verschiedenen Lokalisierungen [29]

Die Enabler-Technologie für selbstfahrende Automobile ist die Lokalisierung. Begründet werden kann das beispielsweise mit Abbildung 1.1, die einen Kreuzungsbereich darstellt. Schematisch visualisiert ist der erhöhte Unsicherheitsbereich aus ungenauen Positionsschätzern (z.B. Global Positioning System (GPS), das durch Mehrwegausbreitungen und Abschattungen keine zuverlässige Positionsschätzung liefert [30]). Das führt unweigerlich zu einem erhöhten Kollisionsbereich, also der Fläche eines möglichen Zusammenstoßes mit einem anderen Teilnehmer. Der Kollisionsbereich kann mit einer präzisen Lokalisierung minimiert werden. Eine solch genaue Lokalisierung ist vor allem bei komplexen zukünftigen automatischen Fahrmanövern wie beispielsweise bei Spurwechseln, Abbiegevorgängen, Kreuzungsüberquerungen oder Überholmanövern notwendig.

Die Problemstellung bildet die Frage nach einer Ortungsarchitektur, bestehend aus Verfahren zur Kartierung und Lokalisierung für selbstfahrende PKW. Hierfür müssen die erhöhten Anforderungen des Einsatzgebietes und der Automobilindustrie erfüllt werden. Es werden im Folgenden die Randbedingungen (R1 bis R7) der Arbeit aufgezeigt und die daraus resultierenden Herausforderungen erläutert. Die einzelnen Randbedingungen sind als Einschränkungen des Lösungsraums der zu entwickelnden Ortungsarchitektur zu interpretieren.

### R1: Dezentrale Karte

Eine der wichtigsten Randbedingungen für die in dieser Arbeit entwickelte Ortungsarchitektur ist der Kerngedanke einer „dezentralen Karte“. Es wird vorausgesetzt, dass die verwendete Karte nicht vollständig auf dem Computersystem des Fahrzeugs vorliegt, sondern von einem Rechenzentrum bereitgestellt wird. Jeder PKW hat über eine Luftschnittstelle Zugriff auf die Karte. Eine solche Karte bietet einen erweiterten Karteninhalt an [31–34]. Hierbei enthalten

die erweiterten Karteninhalte Elemente für unterschiedliche Anwendungen in verschiedenen Datenmodellsschichten. Eine der Datenmodellsschichten stellt die Umgebungsmerkmale für die Lokalisierung zur Verfügung.

Durch den dezentralen Ansatz, der einen bidirektionalen Austausch über eine Luftschnittstelle zwischen Fahrzeug und Rechenzentrum ermöglicht (vgl. Erläuterung zur Datenmenge und Bandbreite in R4), kann die Karte zukünftig kontinuierlich mit kleinen, inkrementellen Kartenaktualisierungen auf dem neuesten Stand gehalten werden. Die Grundlage für solche Kartenaktualisierungen bildet eine einheitliche, dünne Umgebungsrepräsentation in der Kartierung und Lokalisierung. Hieraus folgen direkt weitere Herausforderungen in Bezug auf die Repräsentation der Karte.

Zum einen muss ein standardisiertes Kartenformat eingesetzt werden. Das ist notwendig, damit eine Vielzahl von Fahrzeugen die Karte abrufen und aktualisieren kann. Der Navigation Data Standard (NDS) [35] als bekanntes, standardisiertes und weitverbreitetes Kartenformat bildet die Grundlage zur Einhaltung dieser Randbedingung. Durch den hierarchischen Aufbau der NDS-Karten sind diverse Datenmodellsschichten bereits vorhanden. Dort sind die verwendeten Umgebungsmerkmale integriert. Jedoch bietet NDS nur bestimmte Geometrietypen zur Modellierung von Elementen, was direkt zu Einschränkungen der verwendeten Umgebungsrepräsentation innerhalb der Ortungsarchitektur führt.

Zum anderen müssen die übermittelten Daten der Umgebungsmerkmale für die Kartenaktualisierung der unterschiedlichen Fahrzeuge im Rechenzentrum in einem gemeinsamen, einheitlichen Koordinatensystem vorliegen. Auch für zukünftige Anwendungsfälle bei Datenübermittlungen von Fahrzeug zu Fahrzeug (engl. Car2Car) [36–39] ist diese Bedingung notwendig. Hieraus ergibt sich die Nutzung eines globalen, weitverbreiteten Koordinatensystems. Das sogenannte „World Geodetic System 1984“-Koordinatensystem (WGS84) erfüllt diese Randbedingung und wird hier vorausgesetzt.

Abschließend stellt der dezentrale Ansatz die Anforderung, dass während der Lokalisierung auch eine Kartierung durch die selbstfahrenden Kraftfahrzeuge durchgeführt wird. Insbesondere muss daher die Kartierung mit einem einheitlichen Verfahren erfolgen. Es gilt dabei, Datenbanken kompakt zu halten und nur zwingend erforderliche Informationen abzulegen. Hiermit soll eine niedrige Bus- und Kommunikationslast erreicht werden. Diese Anforderungen haben direkt Einfluss auf die Wahl der Umgebungsmerkmale für die Kartierung und Lokalisierung.

Im Rahmen dieser Arbeit liegt der Fokus auf einer einheitlichen, dünnen Umgebungsrepräsentation, die sowohl in der Kartierung als auch der Lokalisierung zum Einsatz kommt. Ziel ist es, mit dem genannten standardisierten Kartenformat, dem einheitlichen Koordinatensystem und der daraus resultierenden eingeschränkten Umgebungsmodellierung (vgl. R3) eine präzise Lokalisierung zu gewährleisten. Die eigentlichen Kartenaktualisierungen und deren Verarbeitung in einem Rechenzentrum werden in dieser Dissertation nicht betrachtet.

## **R2: Invariante, semi-persistente Umgebungsmerkmale in vielfältigen Außenszenarien**

In dieser Arbeit werden invariante, semi-persistente Umgebungsmerkmale für die Kartierung und Lokalisierung vorausgesetzt. Im Einsatzgebiet der Kraftfahrzeuge sind das typischerweise Objekte der Straßeninfrastruktur. Fokussiert werden Fahrbahnmarkierungen und säulenförmige

Objekte, die von der umfeldwahrnehmenden Sensorik direkt als abstrakte, aggregierte und klassifizierte Sensordaten bereitgestellt werden.

Die genannten Objekte sind grundsätzlich invariant gegenüber Veränderungen über lange Zeiträume. Fahrbahnmarkierungen oder Ampelanlagen verändern sich nur bei einem direkten Eingriff in die Straßeninfrastruktur, z.B. beim Erneuern eines Straßenzugs. Jedoch kann eine Abnutzung der Markierungen im Laufe der Zeit eintreten oder sie werden kurzzeitig verdeckt. Daher können die verwendeten Umgebungsmerkmale als semi-persistent betrachtet werden.

Die genannten Landmarken stehen in mannigfaltigen Einsatzgebieten zur Verfügung und eignen sich daher besonders zur Lokalisierung selbstfahrender PKW mit einer Karte. Jedoch sind die Umgebungsmerkmale nicht als vollständig befreit von Verdeckung und dynamischen Hindernissen anzusehen. Trotz der hohen Invarianz und Persistenz der Landmarken, bilden die sich stetig ändernden äußeren Einflussfaktoren die Herausforderung. Beispielhaft können hier andere Teilnehmer im Arbeitsraum (parkende oder sich bewegende Verkehrsteilnehmer) und atmosphärische Störungen (Regen, Nebel, Helligkeitsunterschiede, Jahreszeitenwechsel) genannt werden.

Inwieweit eine Lokalisierung mit den genannten Landmarken möglich ist, wird im Rahmen dieser Arbeit untersucht. Dabei liegt das Augenmerk auf komplexen, urbanen Außenszenarien. In einem erweiterten Experiment wird abschließend geprüft, ob spezielle Parameter-Sets für unterschiedliche atmosphärische Gegebenheiten zu einer Lokalisierungsverbesserung führen.

### **R3: Zweidimensionale, sensorische Umgebungswahrnehmung mit Seriensorik**

Im Gegensatz zu anderen automatisierten Forschungskraftfahrzeugen [12, 13, 16, 40, 41], die eine beliebige Sensorkonfiguration erlauben, soll die verwendete Sensorik vollständig in den PKW integriert sein (vgl. Kapitel 3.1). Die Randbedingung soll mögliche Einschränkungen für die Zulassung im öffentlichen Straßenverkehr vermeiden, das „Gestaltungsdesign“ von Kraftfahrzeugen beibehalten und die Kosten der Herstellung minimieren. Einher geht damit die Einschränkung, dass keine Rohdaten der Sensorik zur Verfügung stehen.

Aus der Randbedingung ergeben sich weitere, wissenschaftliche Anforderungen an die zu entwickelnde Ortungsarchitektur. Sie lassen sich auf die verbauten Seriensensoren zurückführen, die generell eine schwächere Leistungsfähigkeit (niedrigere Ausgaberraten, weniger Messdatenpunkte, geringere Auflösung) besitzen und durch den Verbauort stärkeren äußeren Einflüssen (Gischt des vorausfahrenden Fahrzeugs, Spiegelungen, Verschmutzungen) ausgesetzt sind.

Als Konsequenz muss ein geeignetes Fehlermodell für die jeweilige Sensorik gefunden werden. Hier ist zu berücksichtigen, dass unterschiedlichste Fehlerquellen die von der Sensorik zur Verfügung gestellten Landmarken beeinflussen können.

Für das in dieser Arbeit vorgestellte Kartierungs- und Lokalisierungsverfahren wird daher vorausgesetzt, dass die verwendete Sensorik abstrakte Sensordaten zur Verfügung stellt. Es wird erwartet, dass die in R2 beschriebenen Umgebungscharakteristiken als klassifizierte Objekte in geometrischen Grundprimitiven (Punkt, Linie, Polylinie) mit jedem Datenpaket bereitgestellt werden. Um mit dieser sensorischen Umfeldwahrnehmung die in R2 genannten Gegebenheiten der Einsatzumgebung zu bewältigen, wird eine Multi-Sensor-Umfeldwahrnehmung zur Erkennung ausreichend vieler Landmarken vorausgesetzt. Für das entwickelte Verfahren ist das keine Einschränkung, weil es auch mit nur einem einzelnen Sensor funktionsfähig ist.

#### **R4: Initiales Vorwissen**

Für das entwickelte Lokalisierungsverfahren ist es notwendig, initiales Vorwissen bereitzustellen. Es handelt sich zum einen um die Karte mit den Umgebungsmerkmalen für die Lokalisation und zum anderen um eine initiale, ungefähre Poseschätzung des Fahrzeugs.

Durch die Randbedingung R1, die dezentrale Karte, wird vorausgesetzt, dass das Fahrzeug mit einem Rechenzentrum kommuniziert und jederzeit einen zur aktuellen Position gültigen Kartenausschnitt anfragen kann. Die Übertragung der Karte zwischen Rechenzentrum und Fahrzeug über eine Luftschnittstelle stellt Anforderungen an Verfügbarkeit, Verlässlichkeit und die benötigte Datenrate an das Kommunikationsnetz. Wird die bisherige und zukünftige Entwicklung mobiler Kommunikationssysteme betrachtet, so ist eine immer höhere Abdeckung (Verfügbarkeit und Verlässlichkeit) des Kommunikationsnetzes mit steigender Datenrate erkennbar [42, 43]. Herausforderungen und Anforderungen für zukünftige Anwendungsfälle wie der Randbedingung R1 werden bereits von Telekommunikationsdienstleistern und Telekommunikationsnetzausrüstern bearbeitet [44–48]. Aktuelle Forschungsarbeiten, um die genannten Anforderungen zu erfüllen, sind in [49–51] gegeben. Erste technische Umsetzungen und daraus resultierende Verbesserungen in Verfügbarkeit, Verlässlichkeit und Datenrate für den Einsatz im PKW können schon genannt werden [52–54]. Mit dem aufgeführten Voranschreiten der Telekommunikationsnetzentwicklung kann die benötigte Kommunikation zwischen Rechenzentrum und Fahrzeug mit der nächsten Generation der Telekommunikationstechnik als einschränkungs-frei eingestuft werden.

Das initiale Vorwissen, die Karte mit Umgebungseigenschaften für die Lokalisierung, muss einmalig erstellt und in der dezentralen Karte (R1) vorgehalten werden. Im Rahmen dieser Arbeit wird das initiale Vorwissen im Sinne der dezentralen Karte mit dem entwickelten Kartierungsverfahren, das den Randbedingungen R2 und R3 Rechnung trägt, erstellt. Um eine präzise Karte zu erhalten, wird für die initiale Kartierung eine Ortungsreferenz (siehe Kapitel 3.1.1) verwendet. Die durchschnittliche Kartengröße der benötigten Luftschnittstellenübertragung beträgt circa 240 Kilobyte pro Kilometer (siehe Kapitel 5.2.4). Zukünftig kann das initiale Erstellen einer dezentralen Karte einerseits einmalig bei großen Kartenherstellern wie beispielsweise TomTom [55] oder NavInfo [56] (sogenannte Erstausrüster, engl. Original Equipment Manufacturer (OEM)) eingekauft werden. Die OEMs arbeiten an einer immer detaillierteren Kartendarstellung [57, 58] mit eigenen Kartierungsverfahren. Andererseits bündeln Fahrzeughersteller ihr Wissen, um selbst Karten mit notwendigen Elementen zur Lokalisierung zu erzeugen. Ein erster Schritt dazu war 2015 der Kauf des Kartenherstellers Here durch ein Autokonsortium [59]. Die Annahme des Vorwissens einer solchen Karte kann daher nicht als Einschränkung gewertet werden.

Die Notwendigkeit einer ungefähren Positions- und Orientierungsschätzung des Fahrzeugs in der Startphase ist darin begründet, dass direkt eine Anfrage an die dezentrale Karte gesendet werden kann. Zum einen wird mit der ungefähren Pose in der Kartenanfrage ein passender Kartenausschnitt für das Lokalisierungsverfahren zur Verfügung gestellt. Zum anderen kann damit eine erste Schätzung der Positionen in der Karte erfolgen. Generell steht dieses Vorwissen in modernen Kraftfahrzeugen zur Verfügung. Bereitgestellt werden kann die Schätzung der Pose über integrierte Navigationsgeräte oder durch das sogenannte EmergencyCall [60]. Verwendet werden für diesen Einsatz GPS-Empfänger (siehe Kapitel 2.2.2).

### **R5: Zweidimensionale Fahrzeugbewegung**

In dieser Arbeit wird von vernetzten und mit diverser umfeldwahrnehmender Sensorik versehenen Personenkraftwagen, einem bodengebundenen Transportsystem, ausgegangen. Diese Fahrzeuge haben durch die Erdanziehungskraft immer Bodenkontakt, weshalb eine Bewegung in vertikaler Richtung unzulässig ist. Deshalb wird vereinfacht eine ebene, zweidimensionale Welt angenommen. Zusätzlich wird ein nicht-holonomes Bewegungsmodell des Fahrzeugs vorausgesetzt. Das folgt aus der Beschaffenheit des Antriebssystems. Eine direkte seitliche Bewegung und das Drehen auf der Stelle ist unzulässig.

Die Bewegungsinformationen des Fahrzeugs werden von der vorhandenen Seriensorik direkt zur Verfügung gestellt (siehe Kapitel 3.1.3). Ein Zugriff auf die Rohdaten ist nicht möglich. Hierbei müssen im Lokalisierungsverfahren etwaige Fehler durch geeignete Methoden berücksichtigt werden.

Aufgrund der zweidimensionalen Umgebungswahrnehmung und Fahrzeugbewegung wird in dieser Arbeit ein zweidimensionales Kartierungs- und Lokalisierungsverfahren vorgestellt. Zur Vereinfachung werden Fahrbahnunebenheiten (Schlaglöcher, Bodenwellen etc.) vernachlässigt.

### **R6: Zeitstempel und Zeitverhalten**

Als Grundannahme der Arbeit wird die Randbedingung von gültigen Zeitstempeln erwartet. Es wird vorausgesetzt, dass alle Eingangsdaten durch eine gemeinsame Uhr zeitgestempelt sind. Innerhalb des Systems sind Verzögerungen (engl. latency) bekannt und Bearbeitungszeiten der Verfahren berechenbar. Somit ist das Alter der einzelnen Daten bestimmbar.

Zusätzlich spielt der Ausgabezeitpunkt der berechneten Lokalisierung eine wichtige Rolle. Er ergibt sich zum großen Teil aus den Verzögerungen der benötigten Eingangsdaten. Für die hier vorgestellte Lokalisierung wird ein maximales Alter von 150 Millisekunden akzeptiert.

### **R7: Kosteneffiziente Realisierung und Serieneinsatz**

Die oberen Randbedingungen R1 bis R3 tragen zu einer kosteneffizienten Realisierung und einem Serieneinsatz (Einsetzbarkeit für den Massenmarkt) der entwickelten Ortungsarchitektur bei. Insgesamt können die Anforderungen in der hier beschriebenen, übergeordneten Randbedingung zusammengefasst werden. Die Kernbestandteile bilden die vollständig integrierte Seriensorik der Umfeldwahrnehmung (R3), die Modellierung der Karte in NDS und Verwendung des Koordinatensystems World Geodetic System 1984 (WGS84), um einen dezentralen Ansatz zu ermöglichen (R1), sowie letztendlich die linienbasierte Repräsentation der Umgebungscharakteristiken mit geometrischen Grundprimitiven (R2).

## **1.3 Lösungsansatz: Landmarkenbasierte Lokalisierung**

Eine Ortungsarchitektur, also ein Kartierungs- und Lokalisationsverfahren, das die aufgestellten Randbedingungen in seiner Breite erfüllt, ist bisher nicht bekannt. Daher wird, aufbauend auf den Randbedingungen, im Rahmen dieser Arbeit die als Landmarkenbasierte Lokalisierung (LbL) bezeichnete Ortungsarchitektur mit klassifizierten Umgebungsmerkmalen der Stra-

Beninfrastruktur für automatisierte PKW vorgeschlagen und untersucht. Dabei stehen die drei Kernaufgaben Kartierung, Erzeugung eines konsistenten Umfeldmodells sowie die Lokalisierung durch Nutzung von abstrakten Sensordaten (klassifizierte Objekte der Straßeninfrastruktur als geometrische Grundprimitive) im Fokus und bilden die Hauptkomponenten der entwickelten Ortungsarchitektur.

Die Architektur der LbL ist in Abbildung 1.2 dargestellt. Der dezentrale Ansatz (R1) mit den Phasen der Kartierung und Lokalisierung ist darin visualisiert. Für die initiale Generierung der dezentralen Karte (im oberen Teil der Abbildung) wird zuerst die Phase der Kartierung durchgeführt (linker Teil der Abbildung). Nachfolgend kann die erzeugte Karte für die Phase der Lokalisierung verwendet werden. Die Trennung der beiden Phasen ist durch einen Schalter über dem Bereich der Sensordatenverarbeitung im unteren Teil der Abbildung angedeutet. Der Schalter visualisiert insbesondere, dass die Sensordatenverarbeitung mit den enthaltenen Sensoren und Verfahren in beiden Phasen gleichbleibend genutzt wird. Die zentralen Komponenten der Arbeit sind die als Tracking- & Fusionsmodell (TFM) und Partikelfilterbasiertes Lokalisierungsmodell (PLM) bezeichneten Verfahren, die in Blau gekennzeichnet sind.

Die Sensordatenverarbeitung fasst die Randbedingungen R2 und R3 zusammen. Es werden für die unterschiedlichen Sensoren verschiedene Detektionsalgorithmen eingesetzt. Jeder Sensor stellt die erkannten Straßeninfrastrukturelemente in den definierten geometrischen Grundprimitiven zur Verfügung. Es stehen bereits diverse Kamerasysteme zur Verfügung. Als Erweiterung wird im Rahmen der Arbeit zusätzlich ein Detektionsalgorithmus für die Erkennung der benötigten Straßeninfrastrukturelemente auf Basis eines 2D-Laserscanners entwickelt und hier erstmalig vorgestellt.

Die Basis für die Kartierung und Lokalisierung bilden die Beobachtungen der wahrgenommenen Landmarken aus der Sensordatenverarbeitung. Die Daten werden sequenziell, in unterschiedlichen Qualitäten und Frequenzen der jeweiligen Sensorik bereitgestellt. Die erhaltenen Beobachtungen der einzelnen Ausgaben müssen über den Zeitverlauf zusammengefasst und nachverfolgt werden, damit ein konsistentes, linienbasiertes zweidimensionales Umfeldmodell aufgebaut wird. Hieraus kann anschließend eine Karte erzeugt werden. Sowohl das Umfeldmodell als auch die Karte werden mit einem neuartigen, effizienten und modularen Verfahren, dem TFM, erstellt. Als Grundgerüst zur Nachverfolgung und Fusion der Landmarken wird ein statistischer Test, der Sequential Probability Ratio Test (SPRT), für geometrische Grundprimitive adaptiert und erstmalig präsentiert. Auf Grundlage von SPRT wird eine sensorspezifische Fusion und damit verbundene Konfidenzwertberechnung für Landmarken vorgestellt.

Mit der Verwendung des TFM, sowohl in der Kartierung als auch der Lokalisierung (vgl. Abbildung 1.2) mit der gleichen Umfeldsensorik, wird erstmalig eine Vereinheitlichung der unterschiedlichen Repräsentationen und Verfahren in den beiden Phasen erreicht. Durch das TFM wird während der Lokalisation eine Karte erstellt, die entsprechend den Erläuterungen aus R1 zur zukünftigen Aktualisierung der dezentralen Karte herangezogen werden kann. Die dafür notwendigen Verarbeitungsschritte im Rechenzentrum und Fragestellungen (z.B. fehlerfreie Aktualisierung, inkonsistente Aktualisierung) sind jedoch nicht Teil dieser Arbeit. Mit dem modularen Aufbau ist die interne Verarbeitung im TFM unabhängig von der Anzahl angeschlossener Sensoren und den verwendeten Bewegungsquellen. Das TFM wird zur Erzeugung der initial benötigten Karte für die Lokalisation eine Ortungsreferenzeinheit als Eigenbewegungs- und

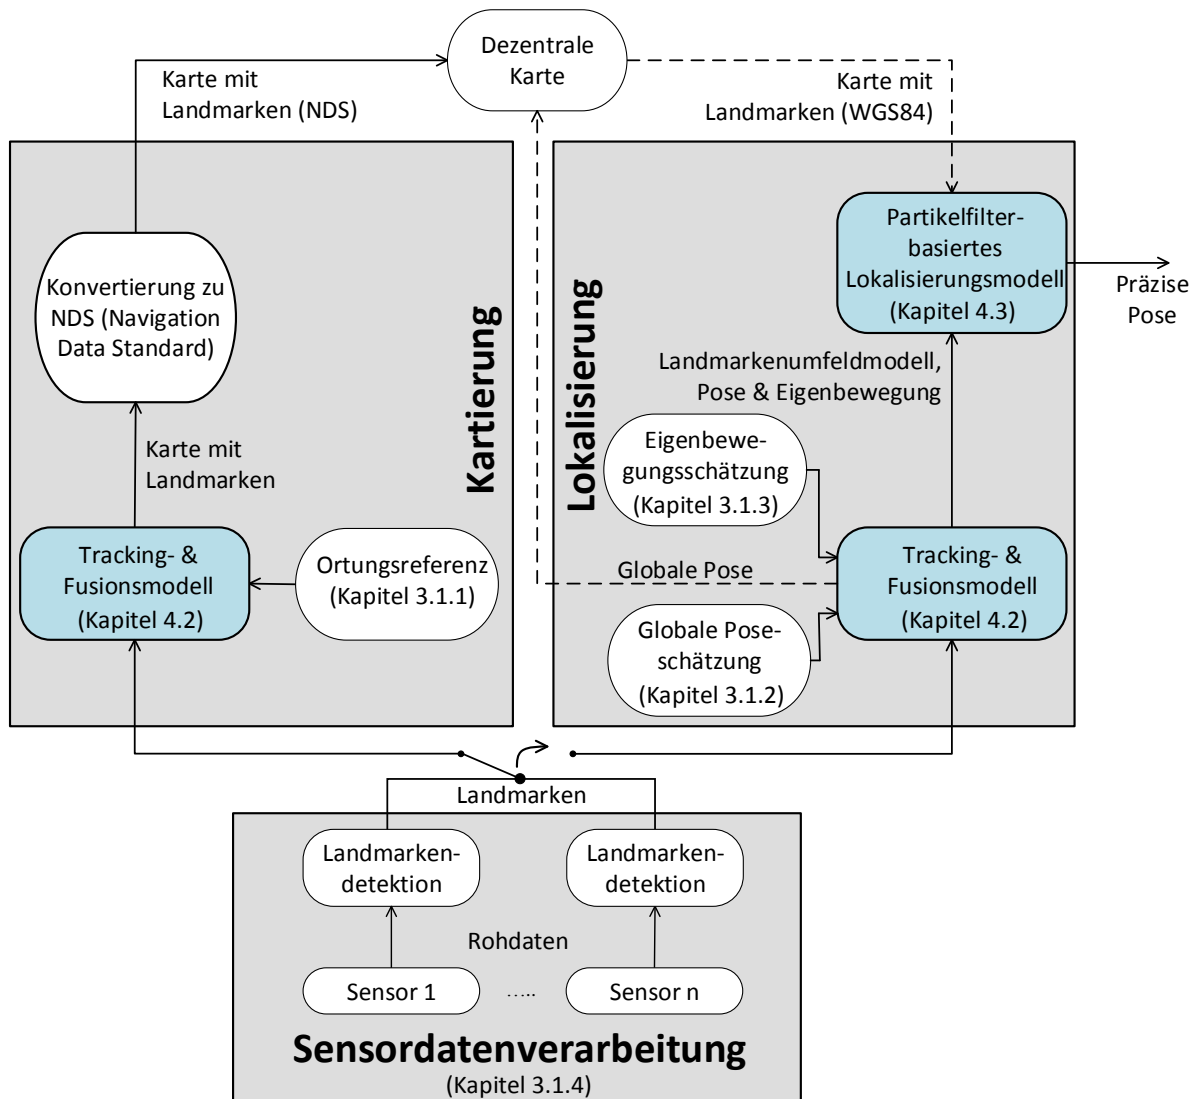


Abbildung 1.2: Übersicht der Landmarkenbasierten Lokalisierung (LbL) mit der Dreiteilung Sensordatenverarbeitung, Kartierung und Lokalisierung. Durch den angedeuteten Schalter wird verdeutlicht, dass die beiden Phasen (Kartierung und Lokalisierung) getrennt voneinander ausgeführt werden, jedoch dieselben umfeldwahrnehmenden Sensoren nutzen. Die untersuchten und entwickelten Hauptkomponenten sind in Blau hinterlegt. Gestrichelte Linien symbolisieren die Kommunikation über eine Luftschnittstelle zu und von der dezentralen Karte.

globale Poseschätzung verwendet. Im Gegensatz dazu wird in der Lokalisierung, entsprechend der Randbedingung R7, Seriensensorik für die Bewegungsinformationen genutzt.

Die Berechnung einer präzisen Pose unter den schwierigen Bedingungen des Einsatzgebietes selbstfahrender Kraftfahrzeuge auf Basis einer linienbasierten Karte und des linienbasierten Umfeldmodells des TFM wird im PLM durchgeführt. Es wird das probabilistische Verfahren eines Partikelfilters für dünne, linienbasierte Repräsentationen adaptiert und kontinuierlich erweitert. Insbesondere wird ein neues Sensormodell für die gewählte Umfeldrepräsentation aufgezeigt



und erstmalig formal eingeführt. Dadurch wird eine robuste und zuverlässige Korrespondenzbestimmung zwischen den unterschiedlichen geometrischen Grundprimitiven der Kartenlandmarken und der Landmarken des Umfeldmodells ermöglicht. Dafür werden spezielle geometriebasierte Distanzfunktionen für die einzelnen Grundprimitive eingeführt. Insgesamt wird eine verlässliche Posebestimmung erreicht.

Die Bereitstellung der benötigten Karte erfolgt über die Übermittlung der ungefähren GPS-Pose an ein Rechenzentrum, das die dezentrale Karte vorhält und einen entsprechenden Kartenausschnitt über eine Luftschnittstelle zurückliefert (vgl. Abbildung 1.2: gestrichelte Linie von der globalen Poseschätzung zur dezentralen Karte und von der dezentralen Karte zum PLM).

## 1.4 Struktur der Arbeit

Im nachfolgenden Kapitel 2 werden die Grundlagen und der Stand der Technik zu den Fragestellungen dieser Arbeit vorgestellt. Es werden zuerst vorangegangene und aktuelle Forschungsschwerpunkte im Bereich selbstfahrender Personenkraftwagen beispielhaft besprochen und im Weiteren wird auf Gemeinsamkeiten der grundlegenden Techniken eingegangen.

Die Rahmenbedingungen und Vorarbeiten folgen in Kapitel 3. Es erfolgt ein Überblick des verwendeten Versuchsträgers mit den integrierten Sensoren, wie beispielsweise der Umfeldsensorik, dem Referenzortungssystem und dem Bewegungsschätzer. Als Teil dieses Kapitels werden die verwendeten Koordinatensysteme eingeführt und erläutert.

Eine vollständige Architekturübersicht und Beschreibung des entwickelten Ortungsverfahrens, der Landmarkenbasierten Lokalisierung (LbL), ist in Kapitel 4 gegeben. Im Unterkapitel 4.1 ist die Architektur und Landmarkenrepräsentation anhand geometrischer Grundprimitive tiefgehend erläutert. Aufbauend werden die neuen Ansätze und Funktionsweisen sowohl des Tracking- & Fusionsmodells (TFM) als auch des Partikelfilterbasierten Lokalisierungsmodells (PLM) in den Unterkapiteln 4.2 sowie 4.3 beschrieben.

Anschließend erfolgt in Kapitel 5 die Beschreibung der Experimente sowie deren Ergebnispräsentation. Die Versuche sind in realen Umgebungen und unter realen Bedingungen, mit realen Sensordaten, durchgeführt worden. Sie stellen die Erprobung und den Nachweis der entwickelten Ansätze dar und liefern einen Beitrag zur experimentellen Robotik.

Im folgenden Kapitel 6 werden die Ergebnisse der Experimente aus Kapitel 5 in Hinblick auf die formulierten Randbedingungen diskutiert. Es werden die Vorteile, aber auch die Einschränkungen des Verfahrens verdeutlicht.

Kapitel 7 schließt diese Arbeit mit einer Zusammenfassung und offenen Fragestellungen ab.

# Kapitel 2

## Grundlagen und Stand der Technik

In diesem Kapitel wird eine Übersicht der Techniken, Verfahren und Ansätze der Kartierung und Lokalisierung für automatisierte PKW gegeben. In den einzelnen Kapiteln werden zuerst die Grundlagen der Verfahren erläutert. Anschließend erfolgt eine Übersicht des aktuellen Stands der Forschung.

Zunächst wird im ersten Abschnitt ein Auszug bisheriger Erfolge im Bereich selbstfahrender Automobile aufgezeigt. Aufbauend werden im Folgenden die einzelnen, notwendigen Techniken umrissen. Es werden vor allem die Themenbereiche der Lokalisierungsverfahren, Umfeldrepräsentationen sowie Datenassoziiierungs- und Objektverfolgungsmethoden erläutert.

Den Abschluss des Kapitels bildet die Eingliederung des entwickelten Ortungsverfahrens im Vergleich zu den bisherigen Methoden. Der Fokus liegt dabei auf selbstfahrenden PKW, die den beschriebenen Randbedingungen unterliegen.

### 2.1 Auszüge bisher erreichter Meilensteine automatisierter Kraftfahrzeuge

Schon seit gut zwei Jahrzehnten gibt es Forschungsarbeiten und Meilensteine im Bereich der Entwicklung von automatisierten Kraftfahrzeugen mit einem hohen Grad an Selbstständigkeit. Als Start dieser Periode kann das Forschungsprojekt von Ernst Dickmanns aus dem Jahre 1986 genannt werden. Das Forschungsteam der Universität der Bundeswehr in München um Dickmanns vollführte mit seinem Versuchsträger VaMoRs (Versuchsfahrzeug für autonome Mobilität und Rechnersehen) eine autonome, 20 Kilometer lange Fahrt von München nach Ingolstadt [61]. Das Versuchsfahrzeug (vgl. Abbildung 2.1) war derart umgebaut, dass ein Rechnersystem Gas, Bremse und Lenkung ansprechen konnte. Die Regelung erfolgte auf Basis einer videobasierten Fahrstreifenenerkennung.

Dieser wissenschaftliche und technische Erfolg war der Anstoß für viele weitere Forschungsinitiativen und Projekte rund um das Thema automatisierte Kraftfahrzeuge. Es startete 1987 das europäische Forschungsprojekt Prometheus (Program for a European Traffic with Highest Efficiency and Unprecedented Safety) [62, 63]. Ziel des Projekts war die Untersuchung von automatisierbaren Funktionen des Fahrzeugs (selbstständige Geschwindigkeitsregelung, Spurhalteunterstützung, etc.) um „Konzepte und Lösungen zu schaffen, die den Weg zu einem



Abbildung 2.1: Versuchsfahrzeug VaMoR (links: von außen, rechts: innen) [61]

flüssigen Straßenverkehr, hoher Umweltverträglichkeit und Wirtschaftlichkeit mit bisher noch nie erreichter Sicherheit“ aufzuzeigen [63]. Im Vergleich zur Fahrt von Dickmanns stand innerhalb des Forschungsprojekts eher eine frühzeitige Harmonisierung und Standardisierung der künftigen Systeme im Mittelpunkt. Aus den Unterpunkten ergaben sich Grundbausteine heutiger Fahrerassistenzsysteme. Erste Erfolge des Projekts konnten 1994 und 1995 erreicht werden. Die beiden Forschungsfahrzeuge VITA-2 (Vision Technology Application) und VaMP (Versuchsfahrzeug für autonome Mobilität und Rechnersehen) [64, 65] fuhren nahe Paris automatisch (selbstständige Längs- und Querverführung auf einer dreispurigen Autobahn sowie durchgeführte Fahrspurwechsel bei Anfrage durch den Fahrer) mit bis zu 130 Stundenkilometer. Beide Versuchsfahrzeuge basieren auf einem Mercedes 500 SEL. Ihre Umgebung nahmen die Fahrzeuge durch 18 Kameras wahr und waren so in der Lage, die Positionen und Geschwindigkeiten anderer Fahrzeuge, Verkehrszeichen sowie Informationen über den Straßenverlauf zu erkennen. Im Gegensatz zu heutigen Ansätzen wurde auf GPS verzichtet und ausschließlich die visuelle Information benutzt [65]. Festzuhalten ist, dass mit VaMP und VITA-2 viele Konzepte untersucht wurden, die heute in modernen Automobilen wiederzufinden sind. Abbildung 2.2 zeigt das Versuchsfahrzeug. Eine gute Beschreibung über die Versuchsfahrzeuge und eingesetzten Verfahren ist in [61, 66, 67] zu finden.



Abbildung 2.2: Versuchsfahrzeug VaMP (links: von außen, rechts: innen) [66, 67]

An das Prometheus Projekt knüpfte das deutsche Forschungsprojekt MoTiV (Mobilität und Transport im intermodalen Verkehr) an [68]. Auf Basis der zuvor erzielten Ergebnissen sollte untersucht werden, wie sich Mobilität in Zukunft gestalten lässt. Die Zielfragestellung bestand darin, wie Menschen und Umwelt vom stetig steigenden Verkehrsaufkommen entlastet werden können. Ein „nationales Gesamtkonzept für Mobilitäts- und Transportdatenverbund“ in Ballungsgebieten stand im Mittelpunkt. Es ergaben sich die Teilgebiete „Sichere Straße“

und „Mobilität in Ballungsräumen“. Als Meilensteine des Projektes konnte die Nutzung von erweiterter Umfeldsensorik, um selbstständige Anhalte- und Anfahrmanöver durchzuführen, vorgestellt werden [69].

Der Nachfolger, INEVNT (Intelligenter Verkehr und nutzergerechte Technik), wurde 2005 als fünfjähriges Forschungsprojekt eingeleitet [70, 71]. Ein Zusammenschluss von 24 Projektpartnern untersuchte die drei Forschungsbereiche „Fahrerassistenz, aktive Sicherheit“ (FAS), „Verkehrsmanagement 2010“ (VM2010) und „Verkehrsmanagement in Transport und Logistik“ (VMTL) in insgesamt acht Teilprojekten. Zur Erreichung der Ziele lag der Schwerpunkt der entwickelten Ansätze auf vorausschauender Umfeldsensorik.

Ein weiteres Forschungsprogramm, gefördert vom Bundesministerium für Wirtschaft und Technologie (BMWi) sowie vom Bundesministerium für Bildung und Forschung (BMBF), startete im September 2006 und endete 2010 [72]. Das Projekt AKTIV (Adaptive und Kooperative Technologien für den Intelligenten Verkehr) legte den Schwerpunkt auf eine korrekt interpretierte Fahrzeugumgebungserfassung und eine Fahreraufmerksamkeitserfassung, um das Fahrzeug in gefährlichen Situationen zum rechtzeitigen Eingreifen zu befähigen. Bei normaler Bedienung sollte sich das System im Hintergrund halten. Das Ziel war ein situations- und fahreradaptives Eingreifen des Systems, wobei eine angemessene Verhaltensweise unter Einbeziehung des Fahrerzustands und einer Bewertung der Fahrsituation verlangt wurde. In [73] findet sich eine Analyse über die Durchdringung und den Mehrwert solcher Systeme.

Insgesamt konzentrieren sich die genannten Forschungsprojekte auf die Stabilisierung von Längs- und Querführung unter Einbeziehung der Fahrzeugumgebung, die grundsätzlich über Kamerasensoren wahrgenommen wurde. Das Hauptziel war lediglich die Unterstützung des Fahrers in schwierigen Situation.

Im Hinblick auf selbstfahrende Automobile sind die genannten Verfahren zwar Grundbausteine, bilden jedoch nicht alle Aspekte (z.B. Unsicherheit der aktuellen Pose) ab. Mit den „Defense Advanced Research Projects Agency“-Grand-Challenge-Wettbewerben (DARPA) des amerikanischen Verteidigungsministeriums änderte sich der Schwerpunkt von unterstützenden zu selbstständigen Automobilen.

Ziel des Wettbewerbs 2004 war es, eine 150 Meilen (241.4 Kilometer) lange Strecke durch die Mojave-Wüste nach Primm mit einem autonomen Fahrzeug in unter zehn Stunden zu absolvieren. Insgesamt war die Strecke nur durch GPS-Wegpunkte abgesteckt und musste ohne Eingriffe von außen abgefahren werden. Es gab auf der Strecke unterschiedliche Untergründe und Hindernisse, die umfahren werden mussten. Die größte Herausforderung entsprach der Umgebungswahrnehmung und Bahnplanung. 100 Teams aus Wissenschaft und Forschung nahmen an der ersten DARPA Grand Challenge teil, jedoch gelangte kein Team ins Ziel. Das erfolgreichste Fahrzeug schaffte 11.9 Kilometer.

Der zweite Versuch der DARPA Grand Challenge folgte 2005 mit der gleichen Strecke durch die Mojave-Wüste nach Primm. Es beteiligten sich 195 Teams, wobei nur fünf davon die Strecke erfolgreich meisterten. Sieger war Sebastian Thrun mit einem Team der Stanford University, der die Strecke von 132.2 Meilen (212.76 Kilometer) in 6 Stunden, 53 Minuten und 58 Sekunden mit seinem Fahrzeug Standley (siehe Abbildung 2.3) abfahren konnte.

Der dritte und vorerst letzte DARPA-Wettbewerb im Kontext des autonomen Fahrens, die Urban Challenge, fand 2007 statt. Der Fokus lag nun nicht mehr auf der reinen Bahnplanung

und Navigation, sondern vor allem auf der Interaktion mit der Umgebung. Hierfür wurden andere Verkehrsteilnehmer simuliert und ein vereinfachtes, innerstädtisches Szenario aufgebaut. Das Fahrzeug BOSS ging als Gewinner (siehe Abbildung 2.3) der Urban Challenge hervor.



Abbildung 2.3: Standley DARPA-Gewinnerfahrzeug 2005 (links) [74] und BOSS DARPA-Gewinnerfahrzeug 2007 (rechts) [75]

Eine Zusammenfassung der Anforderungen, Erkenntnisse und der verwendeten Verfahren sind für die DARPA Grand Challenge 2005 in [41, 74] und für die DARPA Urban Challenge 2007 in [75, 76] aufgeführt. Ein Abriss der nach den DARPA-Wettbewerben noch offenen Fragestellungen ist in [77] gegeben.

Im Vergleich zu der hier durchgeführten Arbeit und den entwickelten Verfahren sind zum einen die in den DARPA-Wettbewerben eingesetzten enormen Sensorkonstellationen und deren Qualitäten zu nennen (vgl. Abbildung 2.3). Mit diesen Sensoren waren während der Wettbewerbe eine gute Wahrnehmung und Abdeckung der Umgebung gewährleistet (vgl. R5). Zum anderen wurde eine dichte Umfeldrepräsentation für die Verfahren gewählt, was durch die hier genannten Randbedingungen R1, R2 und R3 nicht möglich ist.

Die DARPA-Wettbewerbe zeigten die Machbarkeit von selbstfahrenden Fahrzeugen, jedoch mit künstlichen Bedingungen und hohem sensorischen Aufwand. Heutige Meilensteine in der Forschung heben diese Bedingungen auf, indem sie direkt im menschlichen Umfeld agieren und die verwendete Sensorik tief ins Fahrzeug integrieren. Als ein Beispiel kann das Projekt Stadtpilot der TU Braunschweig aufgeführt werden. Das Versuchsfahrzeug Leonie (siehe Abbildung 2.4) parkte aus einer Parklücke aus, fädelt in den regulären Stadtverkehr ein und parkte nach der Umrundung des Braunschweiger Stadtrings wieder am Ausgangspunkt ein [13, 78, 79]. Es wurde eine deutlich kleinere Sensorkonstellation verwendet, die aber nicht vollständig ins Fahrzeug integriert ist. Der Aufbau der Umfeldwahrnehmung und Sensordatenfusion erfolgt über mehrere sensorspezifische Rasterkarten (siehe Teilkapitel 2.3.2) [80, 81]. Die Nutzung von abstrakten Sensordaten, wie sie in dieser Arbeit untersucht werden, erfolgte nicht.

Als neueste Meilensteine hin zu selbstfahrenden PKWs können die erreichten Ergebnisse unterschiedlicher Automobilhersteller genannt werden. BMW zeigte 2011 einen Prototypen, der automatisch auf Autobahnen fahren kann [14, 82, 83]. Mercedes zeigte 2013 ein Fahrzeug, das automatisch auf der Bertha-Benz-Strecke von Mannheim nach Pforzheim fuhr, unter anderem auf Bundesstraßen und in Ortschaften mit selbstständigem Spurwechsel [11, 84]. 2015 fuhr Audi mit dem Prototypen Jack (siehe Kapitel 3.1) ca. 900 Kilometer von Stanford nach Las Vegas zur Consumer Electronics Show (CES) [85]. Aber auch Unternehmen, die nicht direkt zur Automobilbranche gehören, forschen in dem Bereich. Als Beispiel kann hier Google aufgeführt werden, die in den letzten Jahren etliche Kilometer im dichten Stadtverkehr erfolgreich zurückgelegt haben [86, 87]. Die vollständige Integration der Sensorik ins Fahrzeug und

der Einsatz verschiedener Verfahren der Umfeldrepräsentation, Sensordatenfusion und Lokalisierung unterscheiden die Ansätze der einzelnen Prototypen. Abbildung 2.4 zeigt exemplarisch die diversen Versuchsträger auf.



Abbildung 2.4: Unterschiedliche Forschungsfahrzeuge (im Uhrzeigersinn): Google Forschungsfahrzeug [88], Mercedes Versuchsträger [84] und das Fahrzeug von BMW [82], Forschungsfahrzeug Leonie (TU Braunschweig) [13]

In den folgenden Abschnitten werden die Grundlagen der unterschiedlichen Verfahren erläutert und aktuelle Forschungsarbeiten beleuchtet.

## 2.2 Übersicht Lokalisierung

Ziel der Lokalisierung ist die Ausgabe der geschätzten Pose, also der Position und Ausrichtung des Robotersystems. Die zweidimensionale Lösung wird aufgrund der beschränkten Bewegungsfreiheit von mobilen Robotern (keine Bewegung in vertikaler Richtung) fokussiert. Die Lokalisierung bildet die essenzielle Aufgabe für alle Anwendungen, die ein Robotersystem durchführen soll. Bahnplanung, Navigation und kollisionsfreie Bewegung sind nur einige der zu nennenden Anwendungen, für die eine zuverlässige und genaue Lokalisierung zur korrekten Durchführung der Aufgabe benötigt wird.

Die Aufgabe der Lokalisierung wird in zwei Fälle unterschieden, zum einen die *lokale* Lokalisierung und zum anderen die *globale* Lokalisierung. Einen generellen Überblick über die jeweiligen Verfahren in beiden Gebieten sind in [28, 89–91] aufgeführt.

Die *lokale* Lokalisierung (engl. Dead Reckoning, auch Position Tracking) [92, 93] beschreibt die kontinuierliche Positionsschätzung durch Integration bewegungsschätzender Sensorik. Fehler können sich durch die Sensorik aufaddieren, sodass Verfahren zur Abschätzung und Korrektur der Fehler nötig sind.

Bei der *globalen* Lokalisierung soll die Pose des Roboters ohne jegliches Vorwissen in einer Karte bestimmt werden. Dabei können unter anderem funktechnische, aber auch umgebungs-



erfassende Verfahren verwendet werden. Die Messung der Pose mit funktechnischen Verfahren ist nicht in allen Situationen und Bereichen direkt einsetzbar. Bei umgebungserfassenden Verfahren wird Sensorik zur Wahrnehmung des Umfeldes eingesetzt. Im Anschluss wird versucht, Referenzen zwischen den Umgebungsdaten und der Karte zu identifizieren. Eine Posebestimmung ist dann möglich.

Das sogenannte „Simultaneous Localisation and Mapping“-Problem (SLAM)[94, 95] beschreibt die Lokalisierung und gleichzeitige Kartenerstellung des Systems in einer vorher unbekanntem Umgebung. Während bei der *globalen* Lokalisierung eine Karte als Vorwissen angenommen wird, muss die Karte bei SLAM aufgebaut werden, während simultan die Pose zu bestimmen ist. Die Bereitstellung einer Umgebungskarte ist unter bestimmten Umgebungsbedingungen nicht immer möglich. Da jedoch häufig die Lokalisierung in vorher unbekannter Umgebung von großer Bedeutung ist, stellt Simultaneous Localisation and Mapping (SLAM) ein weit verbreitetes Forschungsgebiet dar. Auch hier akkumulieren sich die Fehler der Sensorik und führen beim Schließen von Schleifen (engl. Loop Closing) zu einer fehlerhaften Karte. Mit geeigneten Methoden müssen diese Fehler korrigiert werden [96].

Festzuhalten ist, dass in den unterschiedlichen Fällen der Lokalisierung die Verfahren unabhängig von der Repräsentation der Umgebung und der Karte sind. Die Art der Repräsentation beeinflusst jedoch die Güte der Lokalisierung.

Es wird für alle beschriebenen Varianten der Lokalisierung Sensorik benötigt. Bei der *lokalen* Lokalisierung zur Bewegungsschätzung, bei der *globalen* Lokalisierung zur Umgebungserfassung. Bei der Lösung des SLAM-Problems müssen Bewegungsschätzung und Umgebungserfassung durchgeführt werden. Allgemein ist Sensorik fehlerbehaftet. Um die Fehler abzuschätzen und auszugleichen, werden sogenannte Bayes-Filter (auch stochastische Filter genannt) eingesetzt [28, 89, 90, 97]. Bei diesem Ansatz wird die gesuchte Pose des Roboters als Zustand beschrieben, wobei der aktuelle Zustand zum Zeitpunkt  $\tau$  nur vom Zustand zum Zeitpunkt  $\tau - 1$  abhängt. Das wird als Markov-Annahme bezeichnet und allgemein wird von *Markov-Lokalisierung* gesprochen. Solche Verfahren basieren auf probabilistischen Methoden, wobei ein Systemzustand  $x_\tau$  aus dem Sensormodell  $z_\tau$  und dem Bewegungsmodell  $u_\tau$  bestimmt wird. Zusätzlich gibt der *Belief*-Wert  $bel(x_\tau)$  die Güte bzw. die Wahrscheinlichkeit des berechneten Systemzustands wieder. Das Sensor- sowie das Bewegungsmodell, deren Daten von unterschiedlicher Sensorik bereitgestellt werden, sind mit Rauschen behaftet. Prinzipiell werden bei diesen Verfahren nacheinander die Schritte der Prädiktion (mittels Bewegungsmodell) und Korrektur (mittels Sensormodell) durchgeführt. Für die Problemstellungen der Lokalisierung sind die häufigsten Verfahren aus dem Bayes-Ansatz der Kalman-Filter (KF), Extended Kalman Filter (EKF), Unscented Kalman Filter (UKF) und der Partikelfilter (PF).

Der KF ist der klassische Vertreter aus den Bayes-Ansätzen. Eingeführt wurde er 1960 von Rudolf E. Kálmán [98, 99]. Es handelt sich dabei um ein zeitdiskretes, rekursives Verfahren, das aus einer Folge von fehlerbehafteten Messungen (normalverteiltes Rauschen) ein lineares (unimodale Normalverteilung), dynamisches System schätzt.

Bei Fragestellungen mit nichtlinearen Systemen muss der KF entweder zum EKF [100, 101] oder zum UKF [102] erweitert werden. Hierbei wird beim EKF die Nichtlinearität durch eine Taylorreihenentwicklung erster Ordnung angenähert (Linearisierungsschritt). Im Gegensatz dazu wird beim UKF eine statistische Methode verwendet, indem die unimodale Verteilung durch

wenige, aber aussagekräftige Sigmapunkte approximiert und mit einer nichtlinearen Transformation wieder in eine Normalverteilung für den Folgeschritt überführt wird [89, 103]. Eine effiziente Umsetzung des Verfahrens, das sparsam mit Rechen- und Speicherkapazitäten umgeht, ist möglich. Jedoch können nur unimodale Verteilungen betrachtet und Rauschen nur als mittelwertfreie Normalverteilung angenommen werden. Nachteilig festzuhalten ist, dass die Filter bei Nichtlinearitäten divergieren oder in einem lokalen Optimum stecken bleiben [89, 104, 105] können.

Ein weiteres Verfahren zur Lokalisierung sind die PF-Methoden. In der Robotik wird das Konzept auch Monte-Carlo-Lokalisierung (MCL) genannt [103, 106–108]. Der gesuchte Systemzustand wird durch eine festgelegte Anzahl von Hypothesen, den sogenannten Partikeln, repräsentiert. In jedem Schritt werden das Bewegungsmodell und das Sensormodell auf jeden Partikel angewendet. Der *Belief*-Wert  $bel(x_\tau)$  repräsentiert die zum aktuellen Zeitpunkt gültige Wahrscheinlichkeit eines jeden Partikels. Der Vorteil der Verwendung von PF liegt in der Möglichkeit, multimodale Verteilungen der Schätzung des Systemzustandes durch die Partikel zu approximieren. Es können bei Mehrdeutigkeiten mehrere Hypothesen ausgedrückt werden. Das Verfahren ist durch seine Parallelisierbarkeit besonders recheneffizient. Für eine genauere Beschreibung des Verfahrens sei hier auf Kapitel 4.3 verwiesen.

Vergleiche der unterschiedlichen Verfahren in diversen Szenarien werden in [91, 103, 109–112] untersucht und vorgestellt. Nachfolgend sind einige Untersuchungen mit den beschriebenen Verfahren zur *lokalen* und *globalen* Lokalisierung wiedergegeben. Der Vollständigkeit halber wird auch eine Übersicht von SLAM-Verfahren im Bereich des automatischen Fahrens skizziert. Im Fokus aktueller Untersuchungen liegt die Verwendung der beschriebenen Verfahren mit unterschiedlichen Umfeldrepräsentationen (siehe Kapitel 2.3), der Datenassoziiierung und Datenfusion.

### 2.2.1 Lokale Lokalisierung

Die *lokale* Lokalisierung (auch Koppelortung oder Eigenbewegung genannt) basiert auf der Schätzung der Pose des Roboters aus den reinen Bewegungsänderungen. Es wird ausschließlich Sensorik verwendet, die direkt das Robotersystem betrifft. Die systeminternen Sensoren liefern Informationen, wie Blickrichtung und Geschwindigkeit des Roboters. Hierdurch lässt sich die aktuelle Pose des Roboters durch Addition der Bewegung auf die zuletzt bekannte Pose ermitteln. Als typische Sensoren zur Bewegungs- und Orientierungserfassung können odometrische Sensoren, Kreiselsysteme und Neigungsmesser (Gyrosensoren) genannt werden. Häufig werden die verschiedenen Sensoren in der sogenannten Inertial Measurement Unit (IMU) (de. Inertiale Messeinheit) zusammengefasst. Je nach Antriebsart kann die Bewegung über verschiedene Modelle abgebildet werden. Die wichtigsten Vertreter für Kraftfahrzeuge sind das Einspurmodell und das Zweispurmodell (auch Ackermann-Modell genannt) [89, 90]. Fehler wie Drift und Schlupf der Räder können trotz dieser Modelle nicht ausgeschlossen werden. Es bieten sich die oben genannten Bayes-Filter zur Berechnung der Pose an, um die entstandenen Fehler der Modelle zu schätzen und auszugleichen.

Auch über umfeldwahrnehmende Sensorik kann die Eigenbewegung bestimmt werden. Bewegt sich ein Roboter mit auf ihm befestigter Sensorik, so kann aus zwei hintereinanderfolgenden Sensormessungen die Bewegung ermittelt werden. Bei Verwendung eines kamerabasiertern



Ansatzes, wird von *visueller Odometrie* (engl. visual odometry, auch optischer Fluss genannt) gesprochen. Es wird versucht, zwischen zwei Bildern Korrespondenzen zu finden. Verwendet werden sogenannte Merkmale in Bildern. Als Vertreter der Merkmalsextraktion können unter anderem die Verfahren Scale Invariant Feature Transform (SIFT) [113], Speeded Up Robust Features (SURF) [114, 115], Maximally Stable Extremal Regions (MSER) [116] oder Features from Accelerated Segment Test (FAST) [117] genannt werden. Eine weitere Auflistung kann [90] entnommen werden.

Um die Zuordnung zwischen den Merkmalen zu ermöglichen, werden Verfahren des *Scan Matching* verwendet. Deren bekanntester Vertreter ist das Iterative Closest Point (ICP). Es eignet sich z.B. direkt zur Verwendung mit Punktwolken. Die ICP-Verfahren unterscheiden sich in der Auswahl, Korrespondenzbestimmung, Gewichtung sowie dem Verwerfen von Daten und wurden in zahlreichen Kombinationen untersucht. In [118] wird eine umfassende Analyse der ICP-Verfahren und ihrer Effizienz gegeben.

Als Einschränkung der Registrierung zweier Punktwolken mittels ICP lässt sich der benötigte Startwert festhalten. Nur somit können ausreichend viele Korrespondenzen mit wenig Iterationsschritten gefunden werden. Der Startwert beschreibt das Vorwissen über die Verschiebung der Punktwolken zueinander. Zur Bestimmung des Startwertes werden in vielen Methoden die Kenntnisse der Eigenbewegung, z.B. durch IMU-Daten, zur Stützung des ICP herangezogen.

Um die Eigenbewegung anhand von aufeinanderfolgenden 2D-Laserscannerdaten zu berechnen, werden in [119] zwei iterative Verfahren vorgestellt. Der Autor Magnusson führt in [120] das Konzept Normal Distributions Transform (NDT) ein und nutzt ICP zur Registrierung von Oberflächen in 3D-Punktwolken. Darauf aufbauend wird NDT als eigenständiges Verfahren zur Registrierung weiterentwickelt und in [121] mit dem ICP-Ansatz verglichen. In [122] wird ein Verfahren zur Eigenbewegungsschätzung auf Basis von Merkmalen in Kamerabildern und eines KF vorgestellt. Die Registrierung erfolgt wiederum mit einem ICP.

Die Kombination von visueller Odometrie und IMU wird in [123] präsentiert. Ein auf dem KF basierendes Verfahren zur Fusion von Odometrie und IMU-Daten wird in [124] beschrieben. Es legt den Fokus auf die Anwendung in Kraftfahrzeugen und eine Ausgabe der Eigenbewegung, die für Fahrerassistenzsysteme genutzt werden kann. Die Pose wird in sechs Freiheitsgraden (engl. Degrees Of Freedom (DOF), siehe Anhang B.4) modelliert und ausgegeben.

Die Bestimmung der Eigenbewegung durch Nutzung des Elektronischen Stabilitätsprogrammes (ESP), des Antiblockiersystems (ABS) und der Raddrehzahlsensoren auf Basis eines Einspurmodells wird für Kraftfahrzeuge in [12] gezeigt.

Für viele Anwendungen der *globalen* Lokalisierung sowie für SLAM ist eine präzise Eigenbewegung nötig, die mit den genannten Methoden und Verfahren realisiert werden kann. Häufig wird die Bestimmung der Eigenbewegung direkt in die Verfahren zur *globalen* Lokalisierung zur Vorhersage des nächsten Zustandes, also der Anwendung des Bewegungsmodells, integriert und nicht separat behandelt.

## 2.2.2 Globale Lokalisierung

Das Ziel der *globalen* Lokalisierung ist die Berechnung einer Pose in einer gegebenen Karte. Um zukünftig Informationen zwischen Fahrzeugen austauschen zu können, wird im Automotiv-

bilbereich ein einheitliches Koordinatensystem gefordert. Deshalb wird die Pose des Kraftfahrzeuges in einem Weltkoordinatensystem, dem World Geodetic System 1984 (WGS84) (siehe Kapitel 3.2), benötigt.

Es wird auf das funktechnische Verfahren der Satellitenortung (engl. Global Navigation Satellite System (GNSS)), das GPS, gesetzt. Das GPS liefert eine erste grobe Schätzung der Position, die anschließend durch eine Markov-Lokalisierung verbessert wird. Für ein solches Vorgehen gibt es eine Vielzahl von KF- und PF-Methoden. Es wird nicht nur bei der Wahl des jeweiligen Verfahrens und seiner Realisierung unterschieden, sondern vor allem in der Repräsentation der Umgebungswahrnehmung (Kapitel 2.3). Des Weiteren ist in der *globalen* Lokalisierung das Erstellen der benötigten Karte (engl. Mapping) ein wichtiger Schritt [97, 125–127].

Im Weiteren ist zuerst eine kurze Einführung in die Funktionsweise des GPS gegeben. Anschließend sind aktuelle Forschungsarbeiten zur *globalen* Lokalisierung, basierend auf den Methoden der Markov-Lokalisierung, erläutert.

### 2.2.2.1 GPS

Für eine weltweite Positionsbestimmung in geografischen Koordinaten des WGS84-Koordinatensystems (vgl. Kapitel 3.2) wird das funktechnische Ortungsverfahren Navigation System using Time and Ranging – Global Positioning System (NAVSTAR GPS) verwendet.

Entwickelt wurde das System vom US-Verteidigungsministerium und ist seit dem 2. Mai 2000 auch für die zivile Nutzung mit voller Genauigkeit freigegeben. Das System besteht aus 24 erdumlaufenden Satelliten, die über präzise Atomuhren verfügen und untereinander synchronisiert sind. Die Zeit wird allgemein als GPS-Systemzeit bezeichnet. Für die Positionsbestimmung wird die Methode des Laufzeitverfahrens zugrunde gelegt. Die Satelliten senden aktiv ein Signal aus, das durch passive Komponenten auf der Empfängerseite angenommen und aufbereitet wird. Das gesendete Signal enthält die Position und Zeit des Satelliten und ist als sogenannter C/A-Code verschlüsselt. Es ergeben sich codierte Impulsfolgen, die eine spezifische statistische Verteilung, als Pseudo Random Noise (PRN) bezeichnet, besitzen. Das ermöglicht, die einzelnen Satellitensignale am Empfänger über gleiche Frequenzen gleichzeitig anzunehmen und auszuwerten. Der Empfänger erzeugt ebenso PRN-Folgen und kann über eine Korrelationsfunktion den zeitlichen Versatz zwischen dem Versenden und Empfangen des Signals bestimmen. Die Signallaufzeit kann über die angenommene Signalausbreitungsgeschwindigkeit in der Atmosphäre ermittelt werden. Daraus ergibt sich direkt die Entfernung zwischen Satellit und Empfänger.

Allgemein ist das GPS einigen Fehlerquellen ausgesetzt. Hier können Zeitfehler und Ortsfehler des Satelliten sowie Fehler in der Ionosphäre und Troposphäre genannt werden. Zudem weisen die eingesetzten Uhren auf der Empfängerseite durch den Einsatz von kostengünstigen Komponenten einen Zeitdrift auf. Hinzu kommen Fehler von Mehrwegausbreitungen (z.B. Reflexionen an Gebäuden) und Abschattungen (z.B. Tunneldurchfahrten) des Signals.

Aufgrund der zuvor genannten Fehlerquellen sind vier Satelliten für eine Positionsbestimmung nötig. Anschaulich wird die Positionsbestimmung durch Schneiden der aus den Entfernungen zum jeweiligen Satelliten aufgespannten Kugeloberfläche durchgeführt. Zwei Kugeln schneiden sich in einem Kreis, bei drei Kugeln ergeben sich als Schnittmenge zwei Punkte. Der

unwahrscheinlicherer Punkt kann verworfen werden, was zur gesuchten Position führt. Je mehr Entfernungen, also Satellitensignale, empfangen werden, desto genauer wird die Positionsbestimmung.

Zur weiteren Verbesserung werden heute differenzielle Korrekturdaten, Differential Global Positioning System (DGPS), verwendet. Es wird eine Funkbasisstation in die Berechnung integriert. Die Basisstation ist geografisch exakt vermessen und dient als Referenzpunkt. Aus den empfangenen GPS-Signalen an der Basisstation kann ein Korrektursignal berechnet werden, das über konventionelle Funktechnik verbreitet wird. Mit den Korrekturdaten kann der Empfänger die Laufzeitverzögerung in der Atmosphäre berichtigen. Die Genauigkeit der Korrekturdaten nimmt mit der Entfernung zur Basisstation ab.

Festzuhalten ist, dass GPS nur eine Umsetzung von GNSS ist. Globale Satellitensysteme zur Positionsbestimmung gibt es auch in weiteren Ländern. Die Europäische Union betreibt das Galileo genannte Satellitensystem, die Russische Föderation bietet Global Navigation Satellite System (GLONASS) an und in China wird Beidou zur Verfügung gestellt. Heutige Empfänger können unabhängig vom eigentlichen System alle zur Verfügung stehenden GNSS-Satelliten gleichzeitig verwenden. Werden zwei GPS-Empfänger verwendet, ist es auch möglich, die Orientierung zu bestimmen und damit eine Pose auszugeben.

Eine genaue und detaillierte Beschreibung der einzelnen GNSS-Systeme, Codierung der Signale und die Positionsbestimmung am Empfänger ist in [89, 128] beschrieben, wobei die hier gegebene Zusammenfassung auf den genannten Quellen beruht.

Festzuhalten ist, dass GPS alleine nicht die nötige Genauigkeit für eine präzise Lokalisierung liefert und nicht überall verfügbar ist [30].

### 2.2.2.2 Markov-Lokalisierung

Aufgrund der beschriebenen Fehlerquellen bei der Verwendung von GPS ist die sich ergebende Posebestimmung nicht mit der nötigen Genauigkeit möglich, um selbstfahrende Kraftfahrzeuge zu realisieren. In heutigen Verfahren wird die Genauigkeit der GPS-Lösung durch Nutzung von Markov-Lokalisierungen erhöht. Die Verfahren der Markov-Lokalisierungen sind als Datenfusionsalgorithmen aufzufassen. Es werden die Eigenbewegung, also die *lokale* Lokalisierung, die GPS-Lösung sowie die Korrespondenzbestimmung zwischen der Umgebungswahrnehmung und einer Karte fusioniert, um eine präzise Pose zu erhalten.

Das Prinzip der Markov-Lokalisierungen lässt sich in die beiden Verfahren der KF und PF unterteilen. Entsprechend erfolgt nachfolgend eine separierte Aufführung aktueller Untersuchungen zur *globalen* Lokalisierung.

### Kalman-Filter-basierte Verfahren

In [129] wird ein EKF zur Fusion von Odometrie und reflektierenden Landmarken vorgestellt. Es wurden Reflektoren in der Umgebung platziert und mit einem Laserscanner detektiert. Zur Fusion in dem EKF geht eine relative Positionsbestimmung der Landmarken als auch die Radodometrie ein.

Bonnifait et al. verwenden in [130] vier ABS-Sensoren und ein GPS-System zur Fusionierung in einem EKF. Es wird zwischen einem Odometrie-EKF (*lokale* Lokalisierung) und einem

Lokalisierungs-EKF (*globale* Lokalisierung) unterschieden. Der erste EKF fusioniert die vier ABS-Signale, die statt der reinen Radodometrieinformation eine höhere Genauigkeit besitzen. Der zweite EKF fusioniert das Ergebnis aus dem ersten EKF und dem GPS.

Eine EKF-Lokalisierung mit mehreren parallelen Hypothesen wird in [131] vorgestellt. Jede Hypothese, die heuristisch erzeugt wird, realisiert ein EKF. Für jede Hypothese wird die Wahrscheinlichkeit für ihre Korrektheit über einen Konfidenzwert ausgedrückt. Die Lösung der Lokalisierung entspricht der Hypothese mit dem höchsten Konfidenzwert. Durch den Einsatz mehrere EKF müssen explizit neue Hypothesen generiert und alte Hypothesen verworfen werden. Dazu wird in [131] das „Sequential Probability Ratio Test“-Verfahren (SPRT) verwendet, das direkt den Konfidenzwert der jeweiligen Hypothese berechnet (siehe Kapitel 2.4). Aufbauend auf [131] wird in [132, 133] die Idee von Multi-Hypothesen-EKF mit SPRT als Verwaltungsschicht der EKF-Hypothesen auf das SLAM-Problem angewendet.

Lingmann et al. verwenden in [134] eine Linienkarte, Radodometrie und einen 2D-Laserscanner zur Umfeldwahrnehmung. Mit einem EKF wird zuerst über Radodometrie die Prädiktion der nächsten Pose berechnet. Die Korrespondenzbestimmung zwischen Beobachtung und Karte wird immer zum vorherigen Zeitschritt bestimmt. Es ergibt sich ein Positionsversatz, der in den EKF als Korrektur eingeht.

Homm präsentiert in [14, 82] ein Verfahren zur robusten Querführung des Fahrzeugs. Es werden Straßenmarkierungen aus Laserscanner und Kamera durch eine gridbasierte Umfeldrepräsentation extrahiert sowie mit einem KF fusioniert. Daraus wird die Fahrspurabgrenzung abgeleitet und das Fahrzeug in der Querablage geregelt.

In [30] wird eine robuste Fahrzeugortung für Fahrerassistenzsysteme präsentiert. Hierbei wird ein EKF zur Fusion von Fahrzeugodometrie, GPS und einem Geländemodell (Höhenmodell) verwendet. Es werden auch insbesondere Aspekte der Zuverlässigkeit der Zustandsschätzung, im Sinne der Integrität der ausgegebenen Lösung der Lokalisierung, untersucht. Der Suchraum der GPS-Mehrdeutigkeiten wird durch das Geländemodell eingeschränkt.

Scheide et al. zeigen in [135] eine Architektur für die präzise Eigenortung eines Kraftfahrzeugs basierend auf einem EKF. Als Eingangsdaten für den Fusionsansatz stehen die fahrzeugeigenen Sensoren wie Beschleunigungssensoren, Gyrometer, das ABS, das ESP und die Radodometrie zur Verfügung. Zusätzlich wird mit den Rohdaten des GNSS gearbeitet, wodurch genauere Berechnungen möglich sind. Der Vorteil des gezeigten Verfahrens liegt in der tiefen Integration (engl. *tightly coupled*) von Fahrzeugsensoren und GNSS-Daten.

In [136] wird zur Fusion von Fahrzeugsensoren und GNSS ebenso ein EKF vorgeschlagen. Zusätzlich zu dem aufgezeigten Verfahren aus [135] wird ein weiterer Korrekturterm aus einer Korrespondenzbestimmung zwischen den aktuell durch eine Kamera detektierten Straßenmarkierungen und einer vorher erstellten Straßenmarkierungskarte herangezogen. Die Erstellung der Karte erfolgte in einem vorgelagerten Kartierungsschritt.

Alle KF-Verfahren haben die Einschränkung, dass sie eine unimodale Verteilung annehmen und nur eine normalverteilte Betrachtung erfolgt. Messrauschen wird in den Methoden als mittelwertfreie Normalverteilung modelliert, was nicht immer treffend ist. Bei nichtlinearen Systemen treten oft Divergenzen auf und sie bleiben in lokalen Optima stecken, was durch die notwendige Linearisierung hervorgerufen wird.

### Partikelfilterbasierte Verfahren

Ein umfassender Überblick der *globalen* Lokalisierung mit PF unter Verwendung von Karten, Umfeldwahrnehmung, GNSS-Informationen und Odometrie wird in [137] und [28] gegeben. In der Robotik wird diese Art der Lokalisation als Monte-Carlo-Lokalisierung (MCL) bezeichnet.

In [20] wird ein Partikelfilter zur Lokalisierung eines autonomen Gabelstaplers verwendet. Die A-priori-Karte besteht aus den vorhandenen Deckenstrukturen, die mit einem 3D-Laserscanner ermittelt werden.

Hentschel et al. [138] nutzen einen PF zur Lokalisation eines autonomen Fahrzeugs im Außenbereich. Über einen KF wird die erste GPS-Position zusammen mit Odometriedaten sowie einer verwendeten IMU fusioniert und zusammen mit extrahierten Daten eines 3D-Laserscanners in einen PF übergeben. Es werden Partikel um die GPS-Information gestreut, um sich ggf. aus lokalen Optima zu retten. Durch die vorherige Fusion im KF kann auch bei geringen Korrespondenzen zwischen Beobachtungen und Karte noch eine Korrektur der Vorhersage durchgeführt werden. Weiterführend wurde in [139] eine Karte aus Gebäudeumrissen generiert. Während der Lokalisierung werden die Gebäudeumrisse durch den eingesetzten Laserscanner detektiert. Es wird eine linienbasierte Repräsentation gewählt. Die Korrespondenzberechnung bildet den Korrekturschritt im PF.

Eine Lokalisation für autonome Golf Fahrzeuge in einer Parkumgebung wird von Pendleton et al. in [140] präsentiert. Die notwendige konsistente Karte wird durch manuelles Abfahren aller möglichen Fahrwege und nachfolgender Ausgleichung aufgebaut. Sowohl für die Kartierung als auch für die Lokalisierung wird ein 3D-Laserscanner verwendet. Um die Datenmenge gering zu halten, werden die 3D-Scans in ein sogenanntes „Synthetisches LiDAR“ umgewandelt. Das entspricht einer 2D-Darstellung der wahrgenommenen 3D-Messpunkte. Die Lokalisation erfolgt mittels der Registrierung der angereicherten 2D-Repräsentation mit einem PF und ist in [141] beschrieben.

Der grundlegende Ansatz zur Reduzierung der 3D-Umgebungsdaten in 2D-Daten wurde bereits in [142] diskutiert und der Begriff von „virtuellen 2D-Scans“ definiert. Die Methode zur Verwendung einer solchen Datenrepräsentation für eine MCL wird erstmalig in [20] aufgezeigt.

Ein Verfahren zur Fusion von GNSS, Eigenbewegung und einer Straßenmarkierungskarte mit einem PF wird in [143] vorgestellt. Die Straßenmarkierungen werden allerdings nicht als eindeutige, einzelne Elemente repräsentiert, sondern als sogenannte Klothoiden (Splines) modelliert. Um eine stabile und robuste Lösung des PF zu erreichen, werden spezielle Mechanismen zur Streuung der Partikel eingeführt.

Mattern et al. extrahieren in [24] Straßenmarkierungen aus georeferenzierten Luftbildern und bilden daraus eine Karte. Während der Lokalisierung werden die Straßenmarkierungen mit einer Monokamera über einen histogrammbasierten Ansatz detektiert. Das Bewegungsmodell des PF bildet die Fusion aus Odometrie und GNSS. Das Sensormodell des PF berechnet die Korrespondenzbestimmungen zwischen den Liniensegmenten in der Karte und den detektierten Markierungen der Monokamera. Es wurden besondere Verfahren zur Steuerung des PF verwendet (vor allem Gewichtung und Smoothing).

Wolcott et al. zeigen in [144] einen PF zur visuellen Lokalisierung. Es wird eine rasterbasierte Karte aus Reflexionswerten von Laserscannern erzeugt, wobei die Strecke zweimal abgefahren

und die Datensätze anschließend über ein graphbasiertes Optimierungsverfahren zu einer Karte kombiniert wurden. In der Lokalisierungsphase werden die Monokamerabilder mit einem PF in der Karte registriert und eine Position ermittelt.

In [18] wird eine MCL, basierend auf Landmarken aus einem Laserscanner im unwegsamen Gelände, gezeigt. Es wird ein qualitativer Laserscanner von „Velodyne“ zur Detektion verwendet. Landmarken sind als spezielle detektierbare Muster in den Rohdaten (vgl. SIFT, SURF für Kameramerkmale) definiert. Sie werden in einem Merkmalsvektor gespeichert und über einen Deskriptor beschrieben. Für die Erstellung der Karte wird kein spezieller Kartierungsschritt mit hochgenauen Sensoren durchgeführt, sondern die Strecke mehrfach abgefahren und ein graphbasiertes Optimierungsverfahren ausgeführt. Die Lokalisierung wird durch Partikel in der Karte durchgeführt, wobei der Mittelwert aus den besten 50% der Partikel ausgegeben wird. Das Ergebnis wird anschließend in einem EKF mit der Bewegung des Fahrzeugs kombiniert.

Saha und Sarkar stellen in [25, 26] eine Methode zur Lokalisierung in linienbasierten Karten vor. Es werden Liniensegmente aus Lasersensordaten extrahiert. Die Liniensegmente repräsentieren die aktuelle Wahrnehmung des Robotersystems und werden in der vorhandenen, zuvor erstellten linienbasierten Karte registriert. Die Schätzung der Pose erfolgt über einen Partikelfilter. Die Autoren verwenden für die Korrespondenzbestimmung eines wahrgenommenen Liniensegments zu einem Liniensegment in der Karte das Raytracing-Verfahren. Das Gewicht eines Partikels und damit die Schätzung der aktuellen Pose des Roboters wird durch die erfolgte Korrespondenzbestimmung des Partikels abgeleitet. Partikel, deren Wahrnehmung gut in die Karte passt, erhalten somit ein größeres Gewicht. Es wird aufgezeigt, dass das Verfahren eine präzise Lokalisierung in Gebäuden ermöglicht. Eingesetzt wird eine reichhaltige, detaillierte Karte.

In den MCL-Verfahren wird die Position und Orientierung des mobilen Systems über die einzelnen Partikel bestimmt. Die Partikel beschreiben dabei die möglichen Posen des mobilen Systems. Abgeschätzt wird die Pose über die Partikel, deren aktuelle Beobachtungen die Karte am besten beschreiben. Die Güte der Pose hängt dabei von Methoden zur korrekten und robusten Korrespondenzbestimmung zwischen Beobachtungen und der Karte ab. Der Aspekt zeigt, dass vor allem in dynamischen Umgebungen eine aktuelle Karte vorhanden sein muss, und schränkt MCL-Verfahren in solchen Szenarien ein.

### 2.2.3 SLAM-Verfahren

Steht eine initiale Umgebungskenntnis nicht zur Verfügung oder ist eine funktechnische Positionsbestimmung nicht möglich, dann muss das Robotersystem gleichzeitig eine Karte aufbauen und sich darin lokalisieren.

SLAM wird, wie die *globale* Lokalisierung, durch die Verwendung von EKF und PF gelöst. Das Vorgehen wird in der Literatur als FastSLAM bezeichnet [145, 146].

Gil et al. zeigen in [147] ein verbessertes (im Sinne der Effizienz und Genauigkeit) Verfahren für visuellen SLAM auf Basis eines PF. Es werden Merkmale aus einem Stereokamerabild extrahiert und über eine angepasste Mahalanobis-Distanz wird die Korrespondenzbestimmung durchgeführt.

In [148] wird ein hybrider Ansatz präsentiert. Es werden zwei unterschiedliche Kartenrepräsentationen verwaltet, wobei jede Repräsentation ein anderes Abstraktionslevel besitzt.

In den Arbeiten [132, 133] wird SLAM mit mehreren EKF, die jeweils eine mögliche Hypothese der Pose wiedergeben, gelöst. Für jeden EKF wird mit einem statistischen Test (SPRT) ein Konfidenzwert errechnet und die Verwaltung der Hypothesen gesteuert.

In [149] wird visuelles SLAM in autonomen Landfahrzeugen betrachtet. Es wird zwischen globalen und lokalen Karten unterschieden. Da visuelle Merkmale aus Bildern verwendet werden, wird von dichten und speicherintensiven Karten gesprochen.

Die Arbeit von Weiss [12] führt einen rasterbasierten SLAM-Ansatz, „gridSLAM“ genannt, für Kraftfahrzeuge ein.

Eine andere Betrachtungsweise des SLAM-Problems wird in [150, 151] beschrieben. Es wird eine Backend-Formulierung des Problems aufgestellt, die robust gegen Korrespondenzbestimmungsfehlern ist. SLAM wird als graphenbasiertes Optimierungsproblem betrachtet. Den Kern des Verfahrens bildet der Ansatz, dass das Backend (Optimierung des Graphen) während der eigentlichen Optimierung Veränderungen (Updates) im Frontend (Datenassoziiierung, Sensordatenverarbeitung und Graphenbildung) vornehmen kann.

Entsprechend der einleitenden Erläuterung zu SLAM in Kapitel 2.2 ist das Schließen von Schleifen die größte Herausforderung. Nur wenn ein bereits kartierter Bereich wiedererkannt wird und die anschließende korrekte Registrierung der aktuellen Wahrnehmung erfolgt, können Driftfehler entfernt werden. Vor allem bei großen Gebieten ist das Auffinden des zugehörigen kartierten Bereiches und eine richtige Registrierung erforderlich, da sonst ein starker Drift entsteht [152]. Hinzu kommt, dass bei selbstfahrenden Kraftfahrzeugen eine zielgerichtete Bewegung stattfindet und das Schließen einer Schleife bei langen Fahrten nicht zwingend erfolgen kann. Auch der Berechnungsaufwand zur Optimierung nach erfolgreichem Schleifenschluss bei großen Karten ist ein Nachteil.

## 2.3 Übersicht Umfeldrepräsentation

Entsprechend der Beschreibung in Teilkapitel 2.2.2, basieren die verwendeten Verfahren zur Posebestimmung eines mobilen Systems auf der Markov-Lokalisierung. Es wird davon ausgegangen, dass eine vorab bekannte Umgebungskarte vorliegt und eine interne Repräsentation der aktuellen Umgebungswahrnehmung auf dem Robotersystem besteht. Wird zusätzlich, wie in dieser Arbeit betrachtet, die Randbedingung R1 gefordert, so muss die interne Umgebungsrepräsentation kontinuierlich aktualisiert und erweitert werden.

Allgemein wird zwischen der *lokalen* und *globalen* Umgebungsrepräsentation unterschieden. Werden aktuelle Sensormesswerte zu einem bestimmten Zeitpunkt betrachtet, so wird von der *lokalen* Umgebungsrepräsentation, auch Umfeldmodell genannt, gesprochen. Die *lokale* Umgebungsrepräsentation ist auf das Robotersystem zentriert und gibt seine aktuelle Wahrnehmung zu einem Zeitpunkt wieder. Die Wahrnehmung kann von einem Sensor oder von der Fusion mehrerer Sensoren stammen. Die *globale* Umgebungsrepräsentation, auch Karte genannt, bezieht sich auf ein ortsfestes Koordinatensystem. Im Kontext von selbstfahrenden Kraftfahrzeugen und der Randbedingung R4 folgend, wird in dieser Arbeit das Weltkoordinatensystem WGS84 (vgl. Kapitel 3.2) verwendet.

In den folgenden Unterkapiteln werden die verschiedenen Umgebungsrepräsentation vorgestellt. Sie lassen sich in punkt-, raster- und objektbasierte Darstellungen unterteilen. Die einzelnen Repräsentationen unterscheiden sich in der Dichte ihrer Daten und deren Abstraktionsgrad. Die Umgebungsrepräsentationen können auch als Mischform, sogenannte hybride Umgebungsrepräsentation, eingesetzt werden. Dabei kann je nach Anwendungsfall, z.B. Lokalisierung und Bahnplanung, eine andere Umgebungsrepräsentation verwendet werden [153–155].

### 2.3.1 Punktbasierte Umfeldrepräsentation

Die in der Robotik verwendeten Sensoren, beispielsweise Radarsensoren und Laserscanner, liefern in der Regel Entfernungsmessungen. Werden Kameras als Sensoren eingesetzt, so können mit den in Teilkapitel 2.2.1 vorgestellten Verfahren (SIFT, SURF, MSER etc.) Merkmale des Bildes als Punkte zurückgegeben werden. Das Messergebnis liegt dann entweder in 2D oder 3D als Punktwolke vor. Bedingt durch die punktbasierten Eingangsdaten, die als Rohdaten des Sensors aufgefasst werden können, ergibt sich direkt die punktbasierte Umfeldrepräsentation. Gruppierungen und semantische Interpretationen finden in dieser Umfeldrepräsentation nicht statt. Jedoch können Ausreißer in den Messdaten über bestimmte Verfahren (z.B. Random Sample Consensus (RANSAC)) herausgefiltert werden.

Für die Lokalisierung von selbstfahrenden Kraftfahrzeugen wird häufig eine punktbasierte Umfeldrepräsentation verwendet. Das liegt am Vorteil der detaillierten Beschreibung der Umgebungswahrnehmung, die ohne Informationsverlust einhergeht und zu einer robusten, präzisen Lokalisierung führt. Andererseits entsteht der Nachteil des wachsenden Speicherplatzes für die *lokale* und *globale* Umfeldrepräsentation. Zusätzlich findet keine Interpretation der Daten statt, die ggf. für höherwertige Anwendungen nötig ist.

Mühlenfellner et al. stellen in [156, 157] ein Lokalisierungsverfahren für das autonome Einparken auf Parkplätzen (im Außen- wie Innenbereich) auf Basis der Markov-Lokalisierung mit KF und einer punktbasierten Umfeldrepräsentation vor. Es werden vier Fischaugenkameras als Sensorik zur Umgebungserfassung verwendet. Insbesondere führt Mühlenfellner ein, dass eine punktbasierte Karte aus kamerabasierten Merkmalen für weitläufige Außenszenarien (Parkplätze) bei stetiger Weiterverwendung immer mehr Speicherkapazität benötigt. Als Grund werden atmosphärische Einflüsse (z.B. Helligkeitsunterschiede, Jahreszeiten) auf die Merkmalsvektoren und Deskriptoren genannt. Mühlenfellner zeigt in [157] einen Ansatz auf, der die punktbasierte Karte durch lineare Ausgleichungen zusammenfasst und die initiale Datenmenge weitestgehend beibehält.

Lategahn et al. zeigen in [8, 10, 149] ein auf Stereokameras aufbauendes *globales* Lokalisierungsverfahren, wobei eine punktbasierte Umfeldwahrnehmung und eine Karte gewählt wurden. Es wird während der Kartierung sowohl eine nach vorne als auch eine nach hinten gerichtete Stereokamera genutzt. In der Lokalisierung wird nur die vordere Stereokamera verwendet.

In [17] wird ein Verfahren zur Lokalisierung basierend auf Straßenmarkierungen vorgestellt. Die Eigenbewegung des Fahrzeugs wird aus einer Stereokamera mit visueller Odometrie ermittelt. Die Straßenmarkierungen werden aus Kamerabildern durch geeignete Deskriptoren detektiert. Die Umrandung der Landmarke wird als zusammengehörige (gruppierte) Punktmenge modelliert. Diese Repräsentation wird sowohl für die Karte als auch für die Wahrnehmung



während der Lokalisation verwendet. Um Drifts der Eigenbewegung während der Lokalisation auszugleichen, wird bei jeder Detektion einer Straßenmarkierung eine lineare Ausgleichung durchgeführt.

Abschließend wird in Abbildung 2.5 beispielhaft eine *lokale* und eine *globale* punktbasierte Umfeldrepräsentation gezeigt.




Abbildung 2.5: Lokale Umfeldrepräsentation (Umfeldmodell, links) und globale Umfeldrepräsentation (Karte, rechts)

### 2.3.2 Rasterbasierte Umfeldrepräsentation

Eine alternative Repräsentation des Umfeldes sind sogenannte Rasterkarten, auch Belegungskarten (engl. Gridmap) genannt. Die Umgebung wird in ein zweidimensionales, regelmäßiges Raster (engl. Grid) unterteilt, wobei jede Rasterzelle einem räumlichen Bereich der Umgebung entspricht. Die wahrgenommenen Entfernungsmessungen der Sensoren können direkt in die entsprechende Rasterzelle eingetragen werden. Jede Rasterzelle erhält eine Wahrscheinlichkeit für deren Belegtheit. Ist die Rasterzelle frei, hat sie den Wert 0. Ist sie belegt, hat die Rasterzelle den Wert 1. Der Wahrscheinlichkeitswert einer Rasterzelle wird entsprechend einer mathematischen Vorgabe mit jeder eingehenden Messung der Sensoren aktualisiert. Falls eine Entfernungsmessung vorliegt wird die Wahrscheinlichkeit der Rasterzelle erhöht, andernfalls verringert. Es entsteht eine Hinderniskarte, da die Repräsentation direkt freie und belegte Bereiche beschreibt. Über die mathematische Beschreibung der Aktualisierung können Charakteristiken der verwendeten Sensorik direkt in der Umfeldrepräsentation berücksichtigt werden, indem z.B. bei ungenauen Sensoren mehr Rasterzellen erhöht werden.

Vorgestellt wurde die rasterbasierte Umfeldrepräsentation erstmals in [158]. Der Vorteil der rasterbasierten Repräsentation des Umfeldes liegt in der leichten Fusion der Messungen mehrerer Sensoren. Andererseits muss immer der gesamte Arbeitsraum in Rasterzellen eingeteilt werden. Die Wahl der Größe der Rasterzellen entspricht der gewünschten Auflösung der Umfeldrepräsentation und hat einen direkten Einfluss auf den benötigten Speicher, da jede Zelle explizit im Speicher reserviert wird. Der Zugriff auf die Zellen kann jedoch in linearer Zeit durchgeführt werden. Um den Nachteil auszugleichen, werden häufig keine regelmäßigen Rasterkarten verwendet, sondern auf Rasterkarten mit flexibler Rastergröße zurückgegriffen. Die Realisierung erfolgt durch hierarchische Datenstrukturen wie beispielsweise binäre Bäume (Quadrees für 2D-Umfeldrepräsentation und Octrees für 3D-Umfeldrepräsentation) [159].

Insgesamt sind rasterbasierte Umfeldrepräsentationen durch die Möglichkeit der einfachen Fusion von mehreren Sensoren und der direkten Detektion von statischen Objekten eine häufige Wahl zur Lokalisierung.

Thrun et al. [74, 103, 108, 160] präsentieren ein rasterbasiertes Verfahren zur Lokalisierung von autonomen Fahrzeugen. Es wurden mehrere Sensoren in einer rasterbasierten Umfeldrepräsentation fusioniert. Darauf aufbauend führen Levinson et al. in [15, 40, 161] sogenannte „probabilistische Rasterrepräsentationen“ ein. Die Rasterzellen werden entsprechend des Reflektionsgrades der Objekte aktualisiert. Es ergeben sich sogenannte „Spuren“ in der Rasterrepräsentation, wodurch eine robustere Lokalisierung möglich ist.

In [80] wird eine dreischichtige Architektur für selbstfahrende Kraftfahrzeuge in urbanen Bereichen vorgestellt. Die mittlere Schicht bildet die Fusionsebene, wobei für jeden Sensor ein eigenes, spezifisches Gridmodul erzeugt wird. Die Fusion erfolgt je nach Anwendung über eine zweckgebundene Abfrage der benötigten Gridmodule.

Der Einsatz von hierarchischen Belegungskarten für Fahrerassistenzsysteme wird in [162] gezeigt. In [163] werden probabilistische Belegungskarten für den Einsatz in Fahrerassistenzsystemen untersucht.

Abbildung 2.6 veranschaulicht exemplarisch unterschiedliche rasterbasierte Umfeldrepräsentationen. Je dunkler die Fläche einer Zelle, desto wahrscheinlicher ist sie belegt. Weiße Flächen geben freie Bereiche an. Im linken Teil ist eine äquidistante Rasterkarte veranschaulicht. Dagegen ist im rechten Teil eine Rasterkarte mit variabler Zellengröße abgebildet.



Abbildung 2.6: Exemplarisches Beispiel für Rasterkarten

### 2.3.3 Objektbasierte Umfeldrepräsentation

Sowohl punktbasierte als auch rasterbasierte Umfeldbeschreibungen basieren auf den direkten Messwerten der Sensorik. Im Gegensatz dazu beschreiben objektbasierte Umfeldrepräsentationen (auch topologische, vektorbasierte oder landmarkenbasierte Umfeldrepräsentation genannt) das jeweilige Objekt direkt über seine Position und weitere Eigenschaften wie Ausdehnung, Klassifikation oder Farbe. Alle Informationen des Objektes werden in einem Zustandsvektor gespeichert.

Die Objekte bzw. Landmarken sind prägnante Merkmale der Umgebung (Bäume, Pfeiler, Straßenmarkierungen, Wände, Kanten etc.), die wiedererkennbar und interpretierbar sind. Die korrekte und zuverlässige Wiedererkennung bzw. Detektion der Landmarken aus den Messwerten bildet die größte Schwierigkeit, da aufgrund von Einflüssen des Arbeitsraumes (vgl. Randbedingung R2) die zu erkennenden Objekte verdeckt, entfernt oder nicht vollständig sichtbar sein können.

Im Gegensatz zu rasterbasierten Repräsentationen, die direkt freie und belegte Flächen des Arbeitsraumes wiedergeben, sind objektbasierte Repräsentationen abhängig vom Anwendungsfall. Zur Lokalisierung sind beispielsweise statische Elemente des Arbeitsraumes notwendig, wohingegen zur Bahnplanung befahrbare Fahrwege relevant sind.

Der Zustand einer jeden Landmarke wird als Vektor mit Position und Objekteigenschaften in der lokalen sowie globalen Umfeldrepräsentation beschrieben. Objektbasierte Umfeldbeschreibungen haben deshalb eine effiziente Laufzeit, die sich aus der Anzahl enthaltener Elemente in der lokalen und globalen Umfeldrepräsentation ergibt. Ihr Speicherbedarf ist dabei gering. Das liegt unter anderem daran, dass nur Elemente des Arbeitsraumes betrachtet werden, die wiedererkennbar sind. Es ergeben sich meistens kompakte Umfeldbeschreibungen, die wenige Elemente enthalten. Daraus resultiert direkt der Nachteil einer solchen Darstellung. Prägnante Merkmale der Umgebung können nicht direkt aus den Sensorrohdaten abgeleitet werden, sondern müssen mit einer gesonderten Vorverarbeitung (Extraktion oder Detektion genannt) ermittelt werden. Es sind ggf. komplexe Algorithmen zur Sensordatenverarbeitung nötig. Sollen darüber hinaus die Informationen im lokalen Umfeldmodell aus verschiedenen Sensoren fusioniert werden, so sind Objektverfolgungs-, Korrespondenzbestimmungs- und Fusionsverfahren (vgl. Kapitel 2.4) nötig. Es werden deshalb häufig Mischformen verwendet.

In [16] wird eine globale, objektbasierte Umfeldrepräsentation gewählt. Sie wird in einem speziellen Vorverarbeitungsschritt während der Kartierung erstellt. Als Objekte werden Straßenmarkierungen verwendet, die mit einem hochwertigen Laserscanner detektiert werden. Die Punktwolke des Laserscanners wird in eine Rasterrepräsentation eingetragen. Anschließend erfolgt eine manuelle Bearbeitung und Überführung in die objektbasierte Umfeldrepräsentation (Linienkarte). In der Lokalisierung wird eine lokale punktbasierte Umfeldrepräsentation verwendet. Es werden die Straßenmarkierungen mit einer Stereokamera ermittelt und als Punktmenge repräsentiert. Zur Berechnung der Pose des Fahrzeugs wird die lokale punktbasierte Repräsentation in die globale linienbasierte Kartenrepräsentation mit einem „Nearest Neighbour“-Verfahren (NN) registriert.

Mit der Möglichkeit, die Struktur wahrgenommener Objekte der Umgebung durch geometrische Grundprimitive, beispielsweise durch Linien oder Polylinien, auszudrücken, sind in den vergangenen Jahren viele Verfahren mit linienbasierten (auch segmentbasierte) Repräsentationen für Innenszenarien entstanden. Aufgrund der hohen Datenkompressionsrate wird mit einer solchen Repräsentation eine kompakte Umgebungsdarstellung erreicht [23]. Eine derartige Repräsentation vereinfacht weitere Prozessschritte wie z.B. das Auffinden von Rechtecken in der Karte [164].

Für Innenarbeitsräume, hier speziell eine Industriehalle, zeigt Wulf in [20] die Lokalisierung eines autonomen Gabelstaplers mit punkt- und linienbasierten Landmarken. Es wird vor allem die vorhandene strukturierte Deckenkonstruktion herangezogen. Als Sensor wird ein 3D-Laserscanner verwendet, aus dessen Sensordaten die Landmarken detektiert werden können. Punktbasierte Landmarken sind über ihre eindeutigen Koordinaten beschrieben, während linienbasierte Landmarken jeweils über einen Start- und Endpunkt definiert sind.

Ein Verfahren zum linienbasierten Kartieren auf Basis von Laserscannerdaten wird in [3] vorgestellt. Die globale Karte wird durch sukzessives Zusammenfassen der Laserscannerpunkte

zu Polylinien erzeugt. Es werden Methoden zur Gruppierung, Vereinfachung und Zusammenfassung der Polylinien erläutert.

Damit eine linienbasierte Repräsentation kompakt bleibt, ist es notwendig, die verwalteten Objekte ständig zusammenzufassen. In der Arbeit von Veeck et al. [165] werden im Vergleich zu [3] weitere Fälle der Polylinienoptimierung aufgezeigt. Auf Basis des Bayesschen Informationskriteriums werden Heuristiken vorgeschlagen. So können die Polylinien geglättet, Überlappungen zusammengeführt und unnötige Punkte einer Polylinie entfernt werden.

Für SLAM wird in [166] ein Verfahren basierend auf Sonarsensorik vorgeschlagen. Die lokale Umgebungsrepräsentation wird rasterbasiert gewählt, während die erzeugte Karte linienbasiert ist. Die Ermittlung der einzelnen Liniensegmente aus der rasterbasierten Umgebungsrepräsentation erfolgt über eine Transformation der Datenpunkte in den Hough-Raum und einer anschließenden Distanzgruppierung. Der maximale Wert jeder Gruppe steht für eine Linie, die in die globale Karte eingetragen wird.

Lakaemper schlägt in [167] das Zusammenführen von Linien mit dem „Mean Shift Clustering“-Verfahren, das in [168] erstmalig vorgestellt wurde, vor. Es werden zuerst alle Beobachtungen als Linien in die Karte eingetragen und im zweiten Schritt zusammengehörige Linien mit dem Mean Shift Clustering gruppiert und zu einer Linie verschmolzen.

Das Aufbauen von linienbasierten Karten in einem Multi-Roboter-Szenario wird in [6] aufgezeigt. Insgesamt wird festgehalten, dass die entstehende Karte besonders kompakt und leicht verwaltbar ist. Darüber hinaus lassen sich die wahrgenommenen Objekte der Roboter über Netzwerke mit geringer Bandbreite effizient übertragen. Für das Zusammenführen der einzelnen Wahrnehmungen zu einer konsistenten Karte wird eine Korrespondenzmetrik für Polylinien vorgeschlagen.

Neuere Arbeiten konzentrieren sich auf die Verbesserung der Gruppierungsalgorithmen und der Korrespondenzbestimmungen zwischen den Linien. Sarkar et al. zeigen in [169] eine neue Formulierung zur Identifizierung und Zusammenführung von Linien. Sie führen eine dichtebasierte Gruppierung ein. Es werden die wahrgenommenen Linien in einer dreistufigen Baumhierarchie verwaltet. Die erste Ebene stellt den Zeitpunkt der Wahrnehmung dar, während die zweite Stufe die Linien nach ihrer Orientierung einteilt. Die letzte Ebene gruppiert die Linien anhand ihres räumlichen Abstandes. Die untersten Blätter des Baumes stellen alle Beobachtungen eines einzelnen linienbasierten Objektes dar. Zur Erzeugung einer konsistenten Karte wird abschließend über die Baumstruktur iteriert und die Linien in den Blättern zusammengefasst.

In [22] wird ein Ansatz zur linienbasierten Kartierung mit Ultraschallsensoren vorgestellt. Vor allem wird ein eigenes Distanzmaß für den Punkt-Linie-Abstand aufgestellt. Es wird das Integrieren der Wahrnehmungen in die Karte vereinfacht.

### 2.3.4 Bewertungsmetriken für Karten

Unabhängig von der gewählten Umgebungsrepräsentation müssen, durch die mobilen Systeme in den unterschiedlichen Fragestellungen der Lokalisierung, Karten erzeugt werden. Diese Karten sind, aufgrund der Gegebenheiten des Arbeitsraumes und der Sensorik im Allgemeinen unvollständig, verzerrt und mit einem Rauschen behaftet. Die quantitative Bewertung der Qualität einer generierten Karte ist daher von hohem Interesse. Die Kartenqualität stellt ein

quantitatives Maß für die Leistungsfähigkeit der Umgebungskartierung durch ein mobiles System dar. Mit Hilfe von Kartenmetriken können unterschiedliche Kartierungsverfahren, Effekte der Sensorik und die Wahl von Parametereinstellungen objektiv verglichen und beurteilt werden. Das Ziel der Metriken ist immer die Quantifizierung der Qualität der Karten. Die Bewertung der Qualität einer generierten Karte wird durch den Vergleich mit einer echten Wahrheit, einer Referenzkarte, ermittelt.

In der Literatur sind unterschiedliche Metriken zur Beurteilung der Kartenqualität diskutiert worden. Die häufige Wahl von raster- und punktbasierten Umgebungsrepräsentationen in der Robotik führt zu den meisten Metriken genau dieser Kartendarstellungen.

Varsadan et al. stellen in [170] eine Kartenmetrik für rasterbasierte Umgebungsdarstellungen vor. Sie basiert auf einer Ähnlichkeitsmetrik der Bildverarbeitung, die in [171] beschrieben wird. Die präsentierte Ähnlichkeitsfunktion wird als Summe der durchschnittlichen Manhattan-Distanzen über alle Pixelfarbwerte definiert, wobei zu einem Pixel mit Farbe  $c$  in Bild  $a$  der Pixel mit geringstem Abstand in Bild  $b$  mit Farbe  $c$  gesucht wird. Die Ähnlichkeitsfunktion übertragen Varsadan et. al in [170] auf rasterbasierte Karten, indem die Farbwerte dem Belegungsgrad in Rasterkarten entsprechen. Die Ähnlichkeit wird für jede belegte Zelle der Karte durch die Manhattan-Distanz zur nächsten belegten Zelle in der Referenzkarte beschrieben. Je größer der Abstand, desto unähnlicher ist die Karte. Diese Metrik wird mit der alternativen Ähnlichkeitsfunktion aus [172] verglichen und als effizienter berechenbar hervorgehoben.

In [173] wird eine andere Methode zur Bewertung von rasterbasierten Karten vorgestellt. Es wird von der Annahme ausgegangen, dass Regionen einer Karte lokal konsistent mit einer Referenzkarte sind, die Regionen jedoch relativ zueinander falsch sind. Es wird das „Maß der Gebrochenheit“ eingeführt, das die Anzahl solcher Regionen und ihre räumliche Beziehung durch den Vergleich mit einer Referenzkarte bewertet.

Methoden für die Bewertung von punktbasierten Karten werden in [174] vorgestellt. Es wird eine NN-Methode angewendet, in dem für jedes Element in der generierten Karte ein zulässiger Partner in der Referenzkarte gesucht wird. Die Qualität der Karte wird als Anzahl der korrekten Korrespondenzen definiert. Die Methode wurde auf diverse durch Roboter generierte Karten angewendet, die mit unterschiedlichen Verfahren erzeugt wurden.

Für Karten, die als strukturierte Graphen modelliert werden, wird eine Kartenbewertung in [21] eingeführt. Solche Karten dienen der Beschreibung von möglichen Fahrwegen und können aus einer rasterbasierten Umgebungsrepräsentation abstrahiert werden.

Wulf et al. [175] schlagen vor, die korrekte Lokalisierung eines Verfahrens als Indikator für die Kartenqualität zu nutzen. Es wird ein Referenzpfad erzeugt, gegen den der Fehler des Lokalisierungsverfahrens gemessen wird. Der Referenzpfad wird durch eine manuell überwachte MCL in eine Referenzkarte des Katasteramtes („Automatisierte Liegenschaftskarte“) durch Registrierung von 3D-Laserscandaten erzeugt.

Während für punkt- und rasterbasierte Darstellungen direkt Metriken der Bildverarbeitung verwendet werden können, sind für objektbasierte Umgebungsrepräsentationen andere Verfahren nötig.

In [176] wird ein Ähnlichkeitsmaß auf Basis der räumlichen Lage der Landmarken zueinander aufgestellt. Der Autor bildet sowohl in der generierten als auch der Referenzkarte zwischen einzelnen Objekten Dreiecke. Anschließend wird durch den Vergleich der Orientierung zwi-

schen den Dreiecken in der Referenzkarte und denen in der erzeugten Karte ein Abstandsmaß berechnet, welches die Kartenqualität beschreibt.

Die Arbeiten von Lakaemper et al. [19, 167, 177, 178] stellen Metriken für linienbasierte Karten vor. In [178] wird eine Referenzkarte mit einer generierten Karte verglichen. Dabei wird das Alignment der beiden Karten zueinander, also die Verschiebung und Drehung von Karte A, sodass sie bestmöglich in Karte B passt, als Qualitätsmaß herangezogen. Die Korrespondenzbestimmung der Liniensegmente erfolgt durch die in [167] vorgestellten Methoden, wobei sich der Abstand zwischen Liniensegmenten als Winkelabweichung und räumliche Distanz ergibt. Aufbauend darauf wird in [177] der Vergleich von zwei generierten Karten zueinander beschrieben.

## 2.4 Datenassoziiierung und Objektverfolgung

Zur Erzeugung einer konsistenten objektbasierten Umfeldrepräsentation (vgl. Kapitel 2.3.3) sind Verfahren zur Objektverfolgung, Korrespondenzbestimmung und Sensordatenfusion nötig. Korrespondenzbestimmungen (auch Datenassoziiierung genannt) spielen für die Korrektur der Vorhersage (auch Prädiktion genannt) in Markov-Lokalisierungen eine entscheidende Rolle.

Objektverfolgung (engl. Target Tracking) bezeichnet die Nachführung von beobachteten Elementen. Das Grundprinzip besteht aus der Vorhersage einer möglichst genauen zukünftigen Position und dem anschließenden Wiedererkennen desselben Objektes. Die beschriebenen Markov-Verfahren können für den Anwendungsfall des Trackings eingesetzt werden. Ziel des Trackings ist eine möglichst genaue Modellierung der Trajektorie des zu verfolgenden Objektes. Das interne Objekt (engl. Track) muss in jedem Zeitschritt nach der Prädiktion den aktuellen, neuen Objektmessungen des Arbeitsraumes zugeordnet und entsprechend aktualisiert werden. Die interne Repräsentation des Tracks kann als Zustandsvektor aufgefasst werden.

In [27, 179, 180] wird eine umfassende Übersicht über Tracking-Verfahren, Korrespondenzbestimmungen sowie Fusionsverfahren gegeben. Die hier genannten Verfahren bilden eine Zusammenfassung basierend auf [27, 180]. Ein aktueller Überblick über das Thema der Multisensordatenfusion ist in [181] zusammengefasst.

### 2.4.1 Datenassoziiierung

Laut [182] lassen sich heutige Verfahren zur Datenassoziiierung in vier Gruppen einteilen. Die Einteilung erfolgt durch die Repräsentation der zu verfolgenden Objekte, die sich in Punkte, einfache Formen (z.B. Rechtecke, Ellipsen), Konturen und Silhouetten sowie Skelettmodelle unterteilen lassen. Hierbei nimmt der Abstraktionsgrad stetig ab, wobei die Komplexität der Verfahren zunimmt.

Aufgrund der häufigen Verwendung von punktbasierter Objektrepräsentation im Kontext von selbstfahrenden Kraftfahrzeugen, wird nur dieser Aspekt beleuchtet. Abbildung 2.7 zeigt die Unterteilung des Punkt-Trackings in deterministische sowie probabilistische Single-Frame- und Multi-Frame-Verfahren.

Bei den deterministischen Assoziierungsverfahren werden „harte“ Entscheidungen getroffen, indem jedem Track eine Beobachtung fest zugewiesen wird. Die wichtigsten Vertreter sind

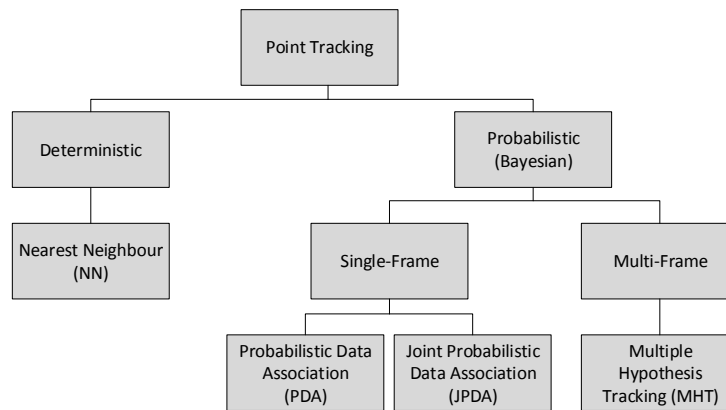


Abbildung 2.7: Übersicht der punktbasierten Tracking-Verfahren, basierend auf [27]

das „Nearest Neighbour“-Verfahren (NN) und „Global Nearest Neighbour“-Verfahren (GNN). Beim Nearest Neighbour (NN) wird einem Track genau das am nächsten liegende Messdatum, im Sinne von wahrgenommenen Objekten, zugewiesen und der Zustandsvektor entsprechend aktualisiert. Dahingegen wird beim Global Nearest Neighbour (GNN) ein globales Optimum der Korrespondenzzuweisung von allen Tracks zu allen Messungen gesucht. Bei beiden Verfahren wird eine Korrespondenzmatrix aufgebaut, die jedem Track eine Beobachtung zuordnet und deren jeweilige Distanz einträgt. Ein Beispiel ist in Tabelle 2.1 gegeben.

Tabelle 2.1: Exemplarische Darstellung einer Korrespondenzmatrix, wobei  $B_j$  den Beobachtungen und  $T_i$  den aktuell verwalteten Tracks entsprechen

$T_i/B_j$	$B_1$	$B_2$	$B_3$
$T_1$	0.2	0.5	<b>0.3</b>
$T_2$	0.6	<b>0.2</b>	0.4
$T_3$	<b>0.1</b>	0.3	0.2

Beim NN-Verfahren wird die kleinste Distanz der Matrix gesucht und als entsprechende Zuweisung verwendet. Beim GNN-Verfahren kann die Suche nach dem globalen Optimum durch die Ungarische Methode, auch Munkres-Algorithmus genannt, gelöst werden [27, 183]. Eine Berücksichtigung einer Fehlbestimmung der Korrespondenz, im Sinne einer Wahrscheinlichkeit, wird bei beiden Verfahren nicht ausgegeben. Es kann zu systematischen Fehllassoziiierungen kommen [27, 179].

Die probabilistischen Verfahren führen „weiche“ Entscheidungen während der Datenassoziiierung durch. Das erfolgt, indem mehrere Beobachtungen einem Track, entsprechend einem Wahrscheinlichkeitsmaß in Abhängigkeit zur Distanz, zugeordnet werden. Der Track wird dann mit allen ihm zugeordneten Beobachtungen aktualisiert. Ein Vertreter der probabilistischen Verfahren ist die „Probabilistic Data Association“-Methode (PDA). Die Methode nimmt eine unkorrelierte Datenzuordnung an, d.h. es gibt nur ein zu verfolgendes Objekt, dem der erzeugte Messdatensatz zugewiesen wird. Es werden alle Messungen zu einer gewichteten, multimodalen

Wahrscheinlichkeitsdichte verschmolzen. Anschließend wird der Track mit einem KF, entsprechend der Wahrscheinlichkeitsdichte, aktualisiert.

Eine Erweiterung der Probabilistic Data Association (PDA) bildet die „Joint Probabilistic Data Association“-Methode (JPDA). Das PDA-Verfahren wird generalisiert und um Mehrziel-Tracking ausgebaut. Eine unkorrelierte Datenzuordnung wird nicht mehr vorausgesetzt, da im Fall von dicht nebeneinander stehenden Objekten korreliertes Rauschen in den Messdaten entsteht. Deshalb berücksichtigt das Verfahren alle möglichen Zuordnungskombinationen zwischen den vorhandenen Tracks und den eingehenden Beobachtungen. Gemäß der PDA-Methode werden beim Joint Probabilistic Data Association (JPDA) alle Tracks mit allen Beobachtungen gewichtet und der Zustandsvektor der Tracks entsprechend aktualisiert. Es wird eine möglichst konfliktfreie Korrespondenzbestimmung erzielt. Die Grundannahme, dass jede Messung nur von einem echten Ziel stammt, wird beibehalten. Bei der Zuordnung von einer Beobachtung zu mehreren Tracks erfolgt eine schwächere Aktualisierung. PDA und JPDA können als Graphen dargestellt werden, in denen die Zuordnungen zwischen Beobachtungen und Tracks abgebildet sind.

Während bei den oben genannten Verfahren die Datenassoziiierung nur für die aktuell gültigen Messdaten (engl. Single-Frame) durchgeführt wird, baut und verwaltet das „Multi Hypothesis Tracking“-Verfahren (MHT) mehrere Hypothesen aus einer Menge von eingegangenen Messdaten (engl. Multi-Frame) auf [184]. Es gilt für neu eingehende Beobachtungen, dass sie zu einem verfolgten Objekt gehören, von einem neuen Objekt im Arbeitsraum stammen oder eine Fehlmessung sind. Das Multi Hypothesis Tracking (MHT) bewertet und verfolgt alle drei Möglichkeiten. Es generiert eine optimale Lösung, allerdings kann die Anzahl der Hypothesen exponentiell ansteigen [27]. Zur Minimierung des Rechenaufwands werden in [27, 180] Methoden zur Löschung unwahrscheinlicher oder zur Verschmelzung ähnlicher Hypothesen vorgestellt.

Die genannten Verfahren zur Datenassoziiierung finden direkt Anwendung in der Markov-Lokalisierung. Sie werden für die Registrierung der lokalen Umfeldrepräsentation in die globale Umfeldrepräsentation verwendet. Nachfolgend sollen die durchgeführten Untersuchungen und Verfahren kurz aufgezeigt werden.

In [185] wird der Vorteil von probabilistischen Zuordnungsverfahren gegenüber den deterministischen Verfahren untersucht und aufgezeigt. Dafür wurden die Verfahren auf einem mobilen Roboter in einer Büroumgebung mit einem Kamerasystem untersucht. Betrachtet wurde dabei das SLAM-Problem.

Vermaak et al. stellen in [186] eine Kombination von PF und JPDA vor, die als Monte Carlo Joint Probabilistic Data Association (MC-JPDA) bezeichnet wird.

In [126, 187–189] wird ein multimodales Sensormodell für Partikelfilter vorgestellt. Zuerst werden spezielle Gauß-Verteilungen mit einem „Expectation Maximization“-Algorithmus (EM) für den jeweiligen Sensor ermittelt. Es wird gezeigt, dass auf diese Weise die Likelihood-Funktion während der Lokalisierung robuster gestaltet werden kann. Ziel des Verfahrens ist es, ein „glattes“ und robustes Sensormodell für die Korrespondenzbestimmung zu erhalten. Diskontinuitäten in der Karte werden angenommen und können mit der Methode ausgeglichen werden.



## 2.4.2 Objektverwaltung

Allen Verfahren gleich ist die interne Verwaltung (engl. Track Management) der nachverfolgten Objekte. Die Tracks können neuen Beobachtungen zugeordnet werden oder aus neuen Beobachtungen entstehen. Es stellt sich die Frage, welche Tracks wahren Zielen entsprechen und bestätigt werden können und welche Tracks, die aufgrund von Fehlwahrnehmungen erzeugt wurden, gelöscht werden sollten. Für die Verwaltung werden statistische Tests verwendet [27], indem die beiden Hypothesen „Alle Beobachtungen stammen vom Ziel“ und „Keine Beobachtung stammt vom Ziel“ aufgestellt werden.

Der am häufigsten verwendete Ansatz ist der 1947 von A. Wald erstmals veröffentlichte Hypothesen-Entscheidungstest, der Sequential Probability Ratio Test (SPRT) [190–192]. Der Test prüft anhand aller bisher erfassten Beobachtungen, ob für oder wider einer Hypothese entschieden werden kann. Falls zum aktuellen Zeitpunkt nicht genügend Beobachtungen vorhanden sind, um eine Entscheidung zu treffen, wird der Test fortgesetzt. Da alle Beobachtungen unsicher sind, ist die getroffene Entscheidung des SPRT unsicher. Das führt zu Fehlentscheidungen. Mit Hilfe von festgelegten Signifikanzniveaus kann die Häufigkeit der Fehlentscheidungen gesteuert werden. Aufgrund der sequenziellen Arbeitsweise und der schnellen Entscheidungsfindung hat SPRT Einzug in viele Gebiete erhalten.

Innerhalb des Bereichs der Kartenerstellung und Lokalisierung wurden in [133, 193] Verfahren basierend auf SPRT zur Verwaltung mehrerer Lokalisierungshypothesen vorgestellt. Jede Hypothese wird durch ein EKF realisiert. Es wurde in beiden Arbeiten das SLAM-Problem behandelt.

Im Bereich der Objektverfolgung können die Arbeiten von [194] und [195] aufgezeigt werden. In [194] wurde ein SPRT-basiertes Track-Management vorgestellt. Die Verwendung von SPRT als Ergänzung zu Markov-Ketten wurde in [195] aufgezeigt. Es konnten begrenzte Markov-Ketten erzeugt werden, die zur Schätzung der Wahrscheinlichkeit des Ereignisses einer Track-Bestätigung sowie des zu erwartenden Zeitpunktes eines solchen Ereignisses dienen. Hasberg stellt in [196] ein Verfahren für die simultane Lokalisierung und Kartierung von spurgeführten Systemen vor und verwendet für die Entscheidung der nachzuverfolgenden Hypothesen SPRT.

Weitere Anwendungsgebiete sind das Identifizieren von Sprechern in einem verrauschten Signal [197], die Verbesserung des RANSAC-Algorithmus [198] sowie die Fehlererkennung in Stromversorgungssystemen [199].

Für die Nutzung von SPRT müssen spezielle Modellparameter der verwendeten Sensorik ermittelt werden. Während in [27] ein analytisches Verfahren vorgestellt wird, zeigen Cheng et al. [200] eine systematische Methode durch Verwendung einer Kreuzvalidierungstechnik aus dem Bereich des Maschinellen Lernens. Die präsentierte Methode steigert die Genauigkeit des SPRT-Verfahrens, da die ermittelten Modellparameter systematisch ermittelt werden.

Im Rahmen der Objektverfolgung und Multisensordatenfusion wurden in [201] unterschiedliche Methoden und Verfahren für die Verwendung in Kraftfahrzeugen untersucht. Es wurden die unterschiedlichen Techniken zur Korrespondenzbestimmung mit den diversen Verfahren zur Vorhersage (vgl. Bayes-Filter in [202]) kombiniert.

Pauwels et al. stellen ein Verfahren zur Posebestimmung von nachverfolgten Objekten in Kamerabildern vor [203]. Die Umgebung des Roboters wird punktbasiert modelliert. In [204]

wird für das Roboterbetriebssystem Robot Operating System (ROS) [205–207] ein generisches Modul zur Multisensordatenfusion vorgestellt. Das erzeugte Fusionsmodul kann durch eine zeitliche Angleichung der eingehenden Sensordaten mit unterschiedlichen Frequenzen und asynchronen Dateneingängen umgehen. Die notwendigen Parameter werden durch den Anwender als mathematische Beschreibung vorgegeben. Innerhalb des Moduls stehen unterschiedliche Verfahren der Sensordatenfusion zur Verfügung, die durch Verschachtelung frei kombiniert werden können.

## 2.5 Eingliederung der Arbeit

Abschließend wird in diesem Kapitel eine Abgrenzung des eigenen Ansatzes zu den bisherigen Ausführungen zum Stand der Forschung deutlich gemacht. Es werden im Weiteren die vorgestellten einzelnen Ansätze der vorhergehenden Unterkapitel herangezogen. Aufgrund der Randbedingungen R1 (Dezentrale Karte), R2 (Invariante, semi-persistente Umgebungsmerkmale in vielfältigen Außenszenarien) und R4 (Initiales Vorwissen) wird sich auf Verfahren der globalen Lokalisierung beschränkt.

Die vorgestellten Verfahren zur globalen Lokalisierung (vgl. Kapitel 2.2.2) verwenden punkt-basierte oder rasterbasierte Umfeldrepräsentationen (vgl. Kapitel 2.3.1 und Kapitel 2.3.2). Wird die Randbedingung R1 als Prämisse vorangestellt, so sind diese Modelle mit Nachteilen behaftet. In [3–6] wird gezeigt, dass der benötigte Speicherbedarf mit wachsendem Kartierungsbe-reich zunimmt. Die Verwendbarkeit der Modelle unterliegt in weiträumigen Gebieten Einschränkungen. Es werden vor allem resultierende Anforderungen aus der Randbedingung R1 in den aufgeführten Ansätzen nicht oder nur unzureichend berücksichtigt.

Linienbasierte Repräsentationen (vgl. Kapitel 2.3.3) räumen die Einschränkungen aus. Sie bieten kompakte Karten bei hoher Lokalisationsgenauigkeit [23]. In den Arbeiten von Saha und Sarkar [25, 26, 169] wird ein MCL-Verfahren zur Lokalisation für Innenszenarien vorgestellt. Es werden eine linienbasierte Karte sowie eine linienbasierte Umfeldwahrnehmung genutzt. Präsentiert wird für die Lokalisation ein Sensormodell auf Basis des Raytracing, das eine gute Korrespondenzbestimmung ermöglicht. In [138] wird ein weiteres MCL-Verfahren vorgestellt, in dem Wahrnehmungen eines 3D-Laserscanners in eine linienbasierte Gebäudeumrisskarte registriert werden. Zur Generierung der Karte wird die Liegenschaftskarte des Deutschen Katasteramtes vorgeschlagen [175]. Ein ähnliches Prinzip für Büroräume mit Ultraschallsensoren wird in [22] aufgezeigt.

In den genannten Arbeiten werden immer Karten mit kontinuierlichen Linienzügen, wie beispielsweise Wände in Innenräumen, Gebäudeumrisse in Außenszenarien oder Deckenstrukturen in Hallen, angenommen. Ebenso wird angenommen, dass das mobile System zu jedem Zeitpunkt Teile der kontinuierlichen Linienzüge wahrnimmt. Deshalb wird in [138] und [22] die Wahrnehmung während der Lokalisation punktbasiert gewählt und jede Messung in die Karte registriert. Die entwickelten Verfahren zielen auf den Einsatz in Umgebungen ab, die sich durch klare, kontinuierliche Strukturen modellieren lassen. In den Einsatzgebieten selbstfahrender Automobile kann eine solche Annahme nicht vollständig getroffen werden. Gebäudeumrisse sind durch die Verbauposition der tief integrierten Sensorik (vgl. Randbedingung R3 (Zweidimensionale, sensorische Umgebungswahrnehmung mit Seriensensorik) sowie Kapitel 3.1) und durch

Verdeckungen (z.B. parkende Fahrzeuge) nicht immer oder gar nicht sichtbar. Vor allem sind Fahrbahnmarkierungen nicht als derartige kontinuierliche Linienzüge interpretierbar.

Insgesamt kann deshalb auch nicht davon ausgegangen werden, dass eine einmalig erstellte Karte der Straßeninfrastruktur dauerhaft allgemeingültig ist. Das wird jedoch in vielen Verfahren zugrunde gelegt. Schreiber erzeugt in [16] durch Nutzung eines hochwertigen Laserscanners mit einer rasterbasierten Kartierung durch einen weiteren Verarbeitungsschritt eine linienbasierte Karte der Straßenmarkierungen. In der Lokalisation wird eine rasterbasiertes Umfeldmodell aufgebaut, in dem die Laserscanpunkte in das Raster eingetragen werden. Die Nutzung höherwertiger Sensorik mit spezieller Anordnung zur besseren Erfassung der benötigten Umgebungscharakteristiken in der Kartierung und die Verwendung einer punktbasierten oder rasterbasierten Repräsentation in der Lokalisation mit einem anderen Sensorikaufbau wird in vielen Ansätzen fokussiert [8, 11, 15, 18, 137, 157, 208].

Einem einheitlichen Verfahren zum Aufbau einer Linienkarte aus einem linienbasierten Umfeldmodell, sowohl in der Kartierung als auch der Lokalisierung, wird nicht Rechnung getragen. Deswegen wird in dieser Dissertation ein Umfeldmodell auf Basis von Objekten der Straßeninfrastruktur vorgeschlagen, deren Elemente als geometrische Grundprimitive (Punkte, Linien, Polylinien) modelliert werden. Das vorgeschlagene linienbasierte Umfeldmodell ist unabhängig von der Anzahl der eingesetzten Sensoren und deren Konstellation. Das Umfeldmodell erzeugt durch zeitliche Nachverfolgung und Fusion der unterschiedlichen Sensoreingänge ein konsistentes Abbild der Umfeldwahrnehmung und baut automatisiert eine Linienkarte auf. In Anlehnung an [154] wird ein dreistufiger Ansatz vorgestellt (siehe Kapitel 4.2). Die Fusion und Objektverfolgung wird direkt auf Landmarkenebene durchgeführt. Zur Verwaltung des Umfeldmodells wird SPRT (vgl. Kapitel 2.4.2) zur Anwendung mit geometrischen Grundprimitiven adaptiert und eingeführt. Für die Ermittlung der benötigten Modellparameter des SPRT wird hier erstmalig, im Gegensatz zu den Methoden der Literatur [27, 133, 193, 195, 200], ein systematisches, empirisches Verfahren vorgestellt. Es ist möglich, die benötigten Parameter je Sensorik reproduzierbar und korrekt zu ermitteln.

Insbesondere wird das Verfahren sowohl in der Kartierung als auch der Lokalisierung mit identischer Umfeldsensorik eingesetzt. Von einer zusätzlichen, teuren Umfeldwahrnehmung für die Kartierung wird abgesehen. Im Gegensatz zu den aufgeführten Methoden wird rein auf einer linienbasierten lokalen sowie globalen Umfeldrepräsentation gearbeitet. Das Resultat sind kompakte, dünn besetzte Karten, die auch während der Lokalisation erzeugt werden. Durch diese Vorgehensweise wird der Randbedingung R1 (Dezentrale Karte) Rechnung getragen, indem mit einem einheitlichen dünnen Umfeldmodell die Grundlagen für zukünftige inkrementelle Kartenaktualisierungen geschaffen wurden. Es sei hier angemerkt, dass die Aktualisierung der dezentralen Karte nicht Bestandteil der vorliegenden Dissertation ist.

Lokalisierungsansätze, die ein vorab erstelltes Umgebungsmodell verwenden, sind in komplexen Einsatzgebieten von Vorteil. Zudem bieten sie die gleiche Datengrundlage für alle mobilen Systeme. Entsprechend Kapitel 2.2 haben sich MCL-Verfahren zur Lösung der Lokalisierungsfrage durchgesetzt. Sie bieten durch den Ansatz von Partikelfiltern Vorteile wie hohe Parallelisierbarkeit und robuste Lokalisation durch Multihypothesen. Des Weiteren können multimodale Wahrscheinlichkeitsdichten durch die Partikelverteilung abgebildet werden. Bei dieser Methode

hängt die Lokalisationsqualität von der gewählten Korrespondenzbestimmung, also der Registrierung aktueller Beobachtungen in die Karte, ab (vgl. Kapitel 2.4).

Entsprechend den Ansätzen in [11, 15, 16, 137, 138] wird die Lageinformation des GPS zusammen mit der Eigenbewegung des Fahrzeugs und dem lokalen Umfeldmodell zur Lokalisierung in die gegebene Karte genutzt. Die Datenzuordnung in Partikelfiltern erfolgt im Sensormodell. Für linienbasierte Karten und rasterbasierte Umfeldmodelle werden Sensormodelle in [12, 15, 18] aufgeführt. Wird ein punktbasiertes Umfeldmodell gewählt, wird auf geeignete Sensormodelle in [16, 22, 138] verwiesen. Sensormodelle für linienbasierte Karten und Umfeldmodelle werden in [24–26] präsentiert. Es wird in [24] ein NN-Ansatz gewählt, der evtl. fehlerhafte Zuordnungen erlaubt. Die vorgeschlagene Methode aus [25, 26] legt die Annahme zugrunde, dass kontinuierliche Linienzüge in den Karten enthalten sind. Die Annahme lässt sich nicht auf das Einsatzgebiet von PKW übertragen.

Um die Nachteile der bisherigen Sensormodelle für linienbasierte Karten und Umfeldmodelle zu umgehen, wird ein neues Sensormodell formuliert. Es werden Distanzfunktionen für die verwendeten geometrischen Grundprimitive vorgestellt, die das Fehlermodell der Landmarkendetektion integrieren. Eine robuste und präzise Lokalisierung mit kompakten Landmarkenkarten wird ermöglicht (siehe Kapitel 4.3). Konträr zu den bisher vorgestellten Formulierungen wird ein effizientes Sensormodell, das als Summe von Gauß-Verteilungen (Sum of Gaussians (SoG)) interpretiert werden kann, eingeführt. Es wird eine implizite Korrespondenzbestimmung aller Kartenlandmarken zu allen Beobachtungen durchgeführt. Der Nachteil einer Verwaltung aller Korrespondenzhypothesen, wie bei den Datenzuordnungsmethoden PDA und JPDA, wird jedoch umgangen.

Um die neu entwickelten Ansätze zur linienbasierten Repräsentation bewerten zu können, wird ein neues Verfahren zur Kartenbewertung aufgezeigt (vgl. Kapitel 2.3.4). Im Vergleich zu [175] wird die Güte der verwendeten Karte nicht über die durchgeführte Lokalisierung beschrieben, sondern, im Sinne der Gleichheit bzw. Ähnlichkeit der erstellten Karten, über eine aufgestellte Kartenmetrik (siehe Kapitel 4.4). Es können direkt zwei Karten miteinander verglichen werden. In dem vorgestellten Verfahren wird im Gegensatz zu [178] eine orts aufgelöste Aussage der Kartenqualität erzeugt. Das Verfahren liefert eine Bewertung jedes geometrischen Grundtyps sowohl einzeln als auch kombiniert und kann für weitläufige Außenszenarien eingesetzt werden.

# Kapitel 3

## Rahmenbedingungen und Vorarbeiten

Im Rahmen dieser Arbeit werden Verfahren zur Erzeugung von lokalen und globalen objektbasierten Umfeldrepräsentationen zum Einsatz in einer übergreifenden Lokalisierungsarchitektur, der Landmarkenbasierten Lokalisierung (LbL), entwickelt und untersucht. Es werden Daten aus unterschiedlichen Sensorsystemen (Umfeldsensorik, globales Positionierungs- und Eigenbewegungssystem) genutzt. Entsprechend der Randbedingung R5 (Zweidimensionale Fahrzeugbewegung) sind die diversen Sensorsysteme vollständig in einem Versuchsträger integriert.

Das Kapitel 3 stellt die Sensorsysteme und deren Daten vor, die in Kapitel 5 zur Evaluierung der LbL verwendet werden. Zuerst wird in Teilkapitel 3.1 der Versuchsträger mit seiner integrierten Sensorik vorgestellt. Es werden sowohl der GPS-Empfänger als auch die genutzte Eigenbewegungsschätzung erläutert. Insbesondere wird die Landmarkendetektion beschrieben. Die herangezogenen Kamerasysteme stellen direkt die notwendigen Landmarken bereit. Für Landmarken aus dem Laserscanner wird ein im Rahmen dieser Arbeit entwickeltes Verfahren aufgezeigt. Es erfolgt die Einführung der aus den Sensoren abgeleiteten, vereinfachten Fehlermodelle für die definierten Landmarken.

Abschließend werden in Teilkapitel 3.2 die verwendeten Koordinatentransformationen erläutert.

### 3.1 Versuchsträger und Sensorik

Der verwendete Versuchsträger ist ein Audi A7 3.0 TFSI Quattro Sportback. Es handelt sich um ein seriennahes Kraftfahrzeug, dessen Sensorik von außen ohne weiteres Wissen kaum zu erkennen ist. Abbildung 3.1 zeigt den Versuchsträger.

Die Positionen der Sensoren sind zur besseren Verdeutlichung im rechten Teil der Abbildung 3.1 schematisch dargestellt. Zur Umfelderkennung werden zwei unterschiedliche Kamerasysteme verwendet. Es sind eine Front-Monokamera (2) und vier Fischaugenkameras (4-7) integriert. Die vier Fischaugenkameras sind um das Fahrzeug herum angebracht, sodass eine 360°-Wahrnehmung erfolgen kann. Zusätzlich wird ein in der Stoßstange angebrachter Laserscanner (engl. Laser Detection and Ranging (LaDAR) oder auch Light Detection and Ranging (LiDAR) genannt) verwendet (1).

Entsprechend der Beschreibung in Kapitel 1.3 (vgl. Abbildung 1.2), wird für die Kartierung zur Erzeugung der initialen Karte (Randbedingung R4) eine hochgenaue Ortungsreferenzin-




Abbildung 3.1: Versuchsfahrzeug Audi Piloted Driving Concept, mit vollständig ins Fahrzeug integrierter Sensorik entsprechend Randbedingung R5 [209] (links) und die schematische Darstellung der Verbaupositionen der integrierten Sensoren (rechts)

heit (3) genutzt. Die aufgezählte Sensorik zur Umfelderkennung, die Landmarkendetektion und deren Fehlermodelle werden in Unterkapitel 3.1.4 näher beschrieben, während auf die Ortungsreferenz in Teilkapitel 3.1.1 eingegangen wird.

Während der Lokalisierung wird über einen GPS-Empfänger eine globale Pose geschätzt und eine Eigenbewegung durch Fusion der im Fahrzeug verbauten Inertialsensorik und Odometrie realisiert. Die Verarbeitung der Daten geschieht in unterschiedlichen Modulen, die anschließend eine globale Pose und die Eigenbewegung bereitstellen. In dieser Arbeit werden diese Schätzungen direkt zur Lokalisierung verwendet. Eine Beschreibung des GPS-Empfängers wird in Teilkapitel 3.1.2 gegeben und das Verfahren zur Eigenbewegungsschätzung in Teilkapitel 3.1.3 erläutert.

Um die Daten der Sensorik im Fahrzeug an unterschiedliche Anwendungen, wie beispielsweise Lokalisierung, Bahnplanung oder Fahrfunktion, verteilen zu können, muss eine entsprechende Architektur gewählt werden. Es wurde im Versuchsträger ein Data Distribution Service (DDS) realisiert. Die Daten können im Sinne von Nachrichten aus den unterschiedlichen Sensoren bzw. Modulen (sogenannte „Publisher“) an ein zentrales Gateway gesendet und dort abgegriffen werden. Jede Nachricht hat eine eindeutige Kennzeichnung („Topic“ genannt). Die jeweiligen Anwendungen (sogenannte „Subscriber“) können die entsprechenden Nachrichten vom Gateway abrufen. Die eigentliche Kommunikation erfolgt über Ethernet. Zur Realisierung von echtzeitfähigen Anwendungen müssen die jeweiligen Daten mit einem gültigen Zeitstempel gekennzeichnet und die Computersysteme zeitlich synchronisiert sein. Als globale Systemzeit wird die GPS-Zeit aus den empfangenen GPS-Nachrichten verwendet. Über das Network Time Protocol (NTP) werden die Computersysteme synchronisiert. Die Sensordaten werden direkt an den verarbeitenden Rechnersystemen mit der aktuellen Zeit gestempelt. Latenzen, im Sinne der Datenübertragung vom Sensor zum jeweiligen Rechnersystem, müssen separat ermittelt und hinterlegt werden. In Anhang A.1 wird die beschriebene Architektur schematisch dargestellt.

Um die Positionen der Sensorik im Bezug zur Fahrzeughinterachse ermitteln zu können, müssen die Verbaupositionen vermessen werden. Der Schritt wird als Kalibrierung bezeichnet und stand zu Beginn der Arbeit zur Verfügung. Für die Kalibrierung des Fahrzeugs wurde ein Ansatz auf Basis von Markern der Firma ACION gewählt [210]. Der Vorteil des Verfahrens

liegt darin, dass sowohl die innere Orientierung als auch die äußere Orientierung der Kamerasysteme direkt mitbestimmt werden können. Zur Bestimmung der Orientierungen wird ein „Schachbrettmuster“ eingesetzt. Abbildung 3.2 zeigt das Verfahren beispielhaft auf.




Abbildung 3.2: Kalibrierung, von links nach rechts: AICON-Markersystem zur Vermessung, Schachbrettmuster für innere Orientierung der Kameras, Gesamtergebnis der ACION-Kalibrierung

### 3.1.1 Referenzlokalisierung

Als Ortungsreferenzeinheit, die sowohl zur Kartierung als auch zur späteren Auswertung der Güte des LbL-Lokalisierungsergebnisses herangezogen wird, kommt das Applanix Position and Orientation System for Land Vehicles (kurz: POS LV) 510 zur Verwendung. Die einzelnen Komponenten und technischen Daten des Systems sind in Anhang A.2 aufgeführt.

Durch die Verwendung von zwei GPS-Antennen wird die Orientierung des Fahrzeugs direkt aus dem Phasenunterschied der Signale ermittelt. Die IMU des Systems besteht aus einer hochwertigen Inertialsensorik (Gyrometer und Beschleunigungsmesser) sowie einem Prozessor zur direkten Verarbeitung. Mit einer Aufnahmeeinheit werden die Daten aufgezeichnet und anschließend aufbereitet.

Sowohl für die Kartierung als auch zur Auswertung der Lokalisierung wird das System mit Korrekturdaten betrieben und aufbereitet, um die höchste Genauigkeit von circa zwei Zentimetern zu erreichen. Die ermittelte Trajektorie wird als Referenz (engl. Ground Truth) verwendet.

### 3.1.2 Globale Poseschätzung

Für die Ermittlung der globalen Pose in WGS84 steht im Versuchsträger der GNSS-Empfänger „FlexPak-G2 OEMStar“ der Firma NOVATEL zur Verfügung. Eine Abbildung und die technischen Daten sind in Anhang A.3 gegeben.

Der Empfänger ist mit der serienmäßig verbauten Antenne für den GNSS-Empfang verbunden und kann GPS-, GLONASS- und „Satellite Based Augmentation System“-Signale (SBAS) (z.B. DGPS) verarbeiten. Um die angegebenen Genauigkeiten des Herstellers (vgl. Anhang A.3) zu validieren, wurden die Poseergebnisse des OEMStar gegen die Referenzeinheit (vgl. Anhang A.2) verglichen. Abbildung 3.3 zeigt die Resultate der Analyse auf. Der OEMStar erreicht den  $2\sigma$ -Wert longitudinal bei zwei Metern und lateral den  $1\sigma$ -Wert bei 1.6 Metern. Die Geschwindigkeitsschätzung schwankt um Null.




Abbildung 3.3: Genauigkeitsanalyse des OEMStar (links: Kumulative Verteilungsfunktion, rechts: Geschwindigkeitskorrektur)

### 3.1.3 Eigenbewegungsschätzung

Für die Schätzung der Bewegung des Fahrzeugs wird das in [124] vorgestellte „EgoMaster“-Verfahren eingesetzt. Die Eigenbewegung wird mit Hilfe der serienmäßig verbauten Sensorik ermittelt.

In einem KF werden physikalische Modelle der Karosseriefederung und Reifeneinfederung zusammen mit Daten aus einer IMU fusioniert. Die Eigenbewegung als Fahrzeugzustand wird zur Fahrbahnfläche modelliert. In Anhang A.4 ist ein Vergleich des EgoMasters zur Referenzeinheit gegeben. Der EgoMaster berechnet mit Hilfe von Geschwindigkeit und Gierwinkel eine Position im globalen, fahrzeugeigenen Koordinatensystem Origin Car Coordinate System (OCCS) (vgl. Kapitel 3.2.4).




Abbildung 3.4: Geschwindigkeitskorrektur der Eigenbewegungsschätzung (links: Positionsfehler in Abhängigkeit der Geschwindigkeit, rechts: Positionsfehler nach korrigierter Geschwindigkeitsschätzung)

Wird der Positionsfehler in Abhängigkeit von der Geschwindigkeit betrachtet, so ist zu sehen, dass eine zu langsame Schätzung der Geschwindigkeit erfolgt. Der Geschwindigkeitsfehler wird in dieser Arbeit ausgeglichen, indem eine Korrektur der Geschwindigkeitsschätzung des



EgoMasters mit der Geschwindigkeit aus der globalen Poseschätzung erfolgt. Abbildung 3.4 stellt den Fehler und die korrigierte Ausgabe der Geschwindigkeit dar.

Die Korrektur der Geschwindigkeit wird in allen Untersuchungen (siehe Kapitel 5) verwendet. Innerhalb der LbL (vgl. Kapitel 4.2 und Kapitel 4.3) wird die Eigenbewegungsschätzung zur Realisierung des Bewegungsmodells benötigt.

### 3.1.4 Umfeldsensorik

Für das in dieser Arbeit vorgestellte Verfahren zur Lokalisierung ist eine umfeldwahrnehmende Sensorik Kernbestandteil. Die verwendeten Sensoren erkennen Elemente der Straßeninfrastruktur wie Fahrbahnmarkierungen (gestrichelte Linien, durchgezogene Linien, Stopplinien sowie Pfeile) und säulenförmige Objekte (Pfähle, Pfosten etc.). Die Umgebungscharakteristiken werden entsprechend ihrer Geometrie als klassifizierte Landmarken zur Verfügung gestellt (siehe Kapitel 4.1.1). Es werden die Rohdaten der jeweiligen Sensorik in einem Vorverarbeitungsschritt, dem Detektor, ausgewertet. Das Ergebnis wird an die LbL weitergegeben (siehe Abbildung 1.3 sowie Kapitel 4.1). Für eine Übersicht aktuell verwendeter Sensorik und Verfahren zur Erkennung von Landmarken in der Straßeninfrastruktur sei auf [211] verwiesen.

Im Folgenden werden die Verfahren zur Landmarkenextraktion und die verwendete Sensorik vorgestellt. Die von den jeweiligen Sensoren gelieferten Landmarken sind in Tabelle 3.1 aufgelistet.

Tabelle 3.1: Auflistung der erkannten Landmarken pro verwendetem Sensor

Sensor	Gestrichelte Linien	Pfeile	Stopp- linien	Durchgezogene Linien	Säulenförmige Objekte
TopView-System	x	x	x	x	-
Front-Monokamera	x	x	x	x	-
Laserscanner	x	x	-	-	x

Für das in der LbL verwendete Verfahren zur Nachverfolgung und Fusion der Landmarken (TFM, siehe Kapitel 4.2) werden für jeden Sensor Sichtbereiche benötigt (engl. Field Of View (FOV)). Die FOV-Bereiche definieren je Sensor und pro Landmarke eine zugehörige Fläche, die innerhalb des Erfassungsbereichs der jeweiligen Sensorik liegt. Der FOV beschreibt den Bereich, in dem der Sensor eine Landmarke sicher erkennen sollte, und stellt die Region Of Interest (ROI) dar.

Für die Ermittlung des Sichtbereichs eines Sensors und der zugehörigen Landmarke wird die Fahrzeughinterachse über eine Fahrt als fest angenommen. Alle Detektionen der Sensorik der Fahrt werden in Bezug zur Fahrzeughinterachse projiziert. Das kann als Messdatenstreuung der jeweiligen Sensorik aufgefasst werden.

In den einzelnen Abschnitten werden die ermittelten Sichtbereiche aufgeführt. Abschließend sind die vereinfachten Fehlermodelle für die jeweiligen Sensoren, die in der LbL verwendet werden, aufgezeigt. Technische Daten der eingebundenen Sensoren sind in Anhang A.5 erläutert.

### 3.1.4.1 Laserscanner

Bei dem verwendeten Laserscanner handelt es sich um den Ibeo Scala B2 LiDAR [212]. Der Laserscanner ist ein seriennaher Sensor, der laut Herstellerangaben 2016 in Massenproduktion gehen soll [213]. Eine ausführliche Untersuchung des Verhaltens des Sensors wird in [214] durchgeführt. Die technischen Daten sind in Anhang A.5.1 wiedergegeben.

Der Laserscanner arbeitet nach dem Multibeam-Verfahren. Es werden vier Scanlinien durch einen rotierenden Spiegel, der fortlaufend horizontal abgelenkt wird, erzeugt. Die Abtastung der einzelnen Scanebenen erfolgt mit unterschiedlicher Frequenz. Abbildung 3.5 veranschaulicht die Funktionsweise schematisch. Für jeden Laserimpuls können bis zu drei Echosignale (Tiefenmessung) empfangen werden. Nach jedem Scanzzyklus stellt der Laserscanner eine Punktwolke mit den einzelnen Messpunkten zur Verfügung. Für weiterführende Informationen zur LiDAR-Technologie sei auf [215] verwiesen.




Abbildung 3.5: Schematische Darstellung der Laserstrahlen (Seitenansicht)

Jeder Messpunkt wird vom Sensor zusätzlich durch eine interne Verarbeitungseinheit klassifiziert. Es wird zwischen den Typen „Clutter“ (Störung, Streuung), „Dirt“ (atmosphärischer Einfluss), „Valid“ (Plausible) und „Ground“ (Bodenebene) unterschieden.

### Landmarkendetektion

Aufgrund des Einbauortes wurde ein spezielles Verfahren zur Landmarkendetektion entworfen und untersucht. Der entwickelte Detektor ist auf die Fahrbahnmarkierungen der gestrichelten Linien, Pfeile und säulenförmigen Objekte beschränkt. Die Verarbeitung erfolgt auf der vom Laserscanner gelieferten Messpunktwolke, wobei jeder Punkt einer Tiefenmessung entspricht. Aufgrund der Arbeitsweise eines Laserscanners (vgl. [215]) entstehen die Messdaten durch die Oberflächeneigenschaften, genauer der Reflexivität und Form, eines Objektes. Für die unterschiedlichen Reflexionen von verschiedenen Materialien sei hier auf [216] verwiesen. Durch die heutigen Anforderungen an Fahrbahnmarkierungen (z.B. Tagsichtbarkeit, Nachtsichtbarkeit und Griffbarkeit) enthält das Markierungsmaterial eingebettete Reflexperlen, wodurch ein Echosignal zu einem Laserimpuls erzeugt wird [82]. Eine Beschreibung der unterschiedlichen Reflexionsarten von Fahrbahnmarkierungen, deren Erfordernisse und Eigenschaften ist in [14] zu finden.

Heutige Verfahren zur Linienextraktion aus einer Punktwolke basieren entweder auf dem Prinzip der Hough-Transformation [217, 218] oder auf dem Abgleich von Histogrammen

[219, 220]. Wird eine rasterbasierte Umfeldrepräsentation gewählt, so können die Landmarken direkt extrahiert werden [12, 16, 82, 161, 208, 221]. In [222] wird für die in Amerika vorkommenden „Bott's Dots“ ein Detektionsverfahren aus der Fusion von Kamera und Laserdaten vorgestellt.

Im Gegensatz zu den genannten Methoden wird hier ein Verfahren auf der Principal Component Analysis (PCA) (dt. Hauptkomponentenanalyse) [223, 224] vorgeschlagen. Der Vorteil der Methode besteht darin, dass direkt Länge, Breite, Orientierung und Punktverteilung der Landmarken ermittelt werden.

Die Detektion erfolgt in den Prozessschritten „Akkumulierung und Filterung“, „Segmentierung“ und „Identifizierung“. Aufgrund des Einbauortes und der lediglich vier zur Verfügung stehenden Scanlinien, werden pro Scan nicht genügend Informationen gesammelt, um Landmarken zu detektieren. Eine Akkumulierung der Scandaten muss durchgeführt werden. Abbildung 3.6 zeigt das exemplarisch.

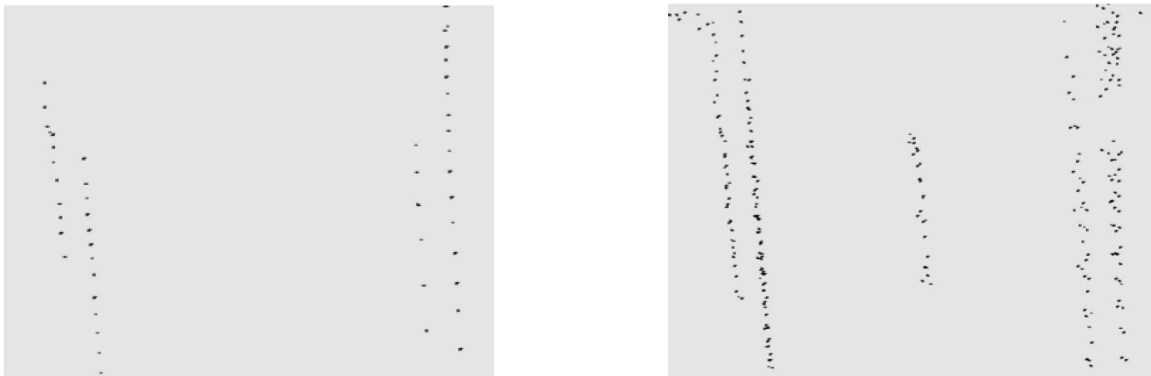


Abbildung 3.6: Straßenreflexionen mit und ohne Akkumulierung im Vergleich, jeweils als Draufsicht dargestellt (links: ein einzelner Scan, rechts: Ergebnis der Akkumulierung von 5 Scans in Folge)

Während der Filterung werden Messpunkte, die kein Bestandteil einer Landmarke darstellen, entfernt. Das sind vor allem die Messungen, denen kein Echo zugeordnet wurde (Punkte erhalten die Maximaldistanz vom Sensor zugewiesen). Darüber hinaus bilden bewegte Objekte durch die Akkumulierung linienförmige Strukturen, sogenannte „Spuren“. Es werden dynamische Objekte erkannt und aus den Messdatenpunkten herausgefiltert.

Nach dem Prozessschritt der „Akkumulierung und Filterung“ werden die Messdatenpunkte mit einem „Hierarchial Cluster Analysis“-Algorithmus (HCA; dt. Hierarchische Cluster Analyse) segmentiert. Eine Übersicht der möglichen Metriken zur Clusterbestimmung sind in [224–227] zu finden. Abschließend werden die einzelnen Cluster identifiziert. Es wird auf die jeweiligen Cluster die „Principal Component Analysis“-Methode (PCA) angewendet. Die genauen Maße (Länge, Breite, Orientierung und Punktverteilung) des jeweiligen Clusters werden so bestimmt, wobei für gestrichelte Straßenmarkierungen horizontale Linien und für säulenförmige Objekte vertikale Linien entstehen. Durch einen anschließenden Grenzwertabgleich werden die gefundenen Strukturen auf die geforderten Bedingungen überprüft. Es ergeben sich für gestrichelte Straßenmarkierungen die Grenzwerte direkt aus [228]. Für säulenförmige Objekte werden die in [229] vorgestellten Bedingungen verwendet. Die Ausgabe der Landmarken erfolgt entsprechend der Beschreibung in Kapitel 4.1.1.

### Sichtbereich des Laserscanners

Abbildung 3.7 stellt alle Detektionen der linienbasierten und punktbasierten Landmarken des Laserscanners dar. Die Rastergröße entspricht fünf Metern. Punktbasierte Landmarken sind in Rot und linienbasierte Landmarken in Olivgrün veranschaulicht. Das hellblaue Rechteck zeigt den gewählten FOV-Bereich an, der eine Breite von 10 Metern und eine Länge von 25 Metern besitzt.




Abbildung 3.7: Sichtbereich des Laserscanners (Rastergröße: 5 Meter)

#### 3.1.4.2 Kamerasysteme

Zusätzlich zu dem beschriebenen Laserscanner des vorherigen Abschnitts ist der Versuchsträger mit unterschiedlichen Kamerasystemen ausgestattet. Es sind vier Fischaugenkameras (im weiteren TopView-System genannt) und eine Front-Monokamera verbaut. Die jeweiligen Einbauorte sind in Abbildung 3.1 veranschaulicht und die einzelnen technischen Daten in Anhang A.5.2 wiedergegeben.

Auf die eigentliche Detektion der Landmarken aus den gelieferten Bildern wird hier nicht näher eingegangen. Für die genutzte Detektionsmethode zur Landmarkenerkennung wird für die Front-Monokamera auf [230–233] und für das TopView-System auf [234] verwiesen. Die verwendeten Kameras liefern Graustufenbilder und werden im Folgenden vorgestellt.

#### Front-Monokamera

Bei der in der Frontschutzscheibe eingesetzten Kamera handelt es sich um eine Monokamera der Firma Mobileye. Mobileye hat sich auf Fahrzeugkameras spezialisiert und bietet Kameras mit direkt integrierten Fahrerassistenzfunktionen an [235, 236]. Eine Abbildung der Kamera und deren technische Daten sind in Anhang A.5.2.1 zu finden.

Die Detektion der Landmarken erfolgt in der Bildebene mit dem in [232, 233] beschriebenen Verfahren. Die Grundlage der Landmarkendetektion bildet das Bild der Kamera, das beispielhaft in Abbildung 3.8 aufgezeigt ist. Detektierte Landmarken sind farblich hervorgehoben.



Abbildung 3.8: Ausgabe des Detektionsalgorithmus im Kamerabild

Nachdem die Landmarken im Bild detektiert worden sind, müssen sie vom Bildraum in den Objektraum transformiert werden. Da die Transformation bei einer Monokamera nicht ohne Weiteres möglich ist, wird die Fahrbahn im Detektionsbereich der Kamera als eben angenommen. Es entstehen deutlich vereinfachte Modelle für die Projektion eines Pixels auf die Fahrbahn.

### Sichtbereich der Front-Monokamera

Laut Tabelle 3.1 erkennt die Front-Monokamera nur linienbasierte und polylinienbasierte Landmarken. Abbildung 3.9 visualisiert alle detektierten Landmarken einer Fahrt als Draufsicht. In Olivgrün sind durchgezogene (polylinienbasierte Landmarken) und gestrichelte Straßenmarkierungen (linienbasierte Landmarken) abgebildet. Die türkisen Linien entsprechen den detektierten Stoppllinien (linienbasierte Landmarken). Als Rastergröße sind fünf Meter gewählt worden. Der zugehörige FOV ist in Hellblau markiert.




Abbildung 3.9: Landmarkendetektionen der Front-Monokamera in Bezug zur Fahrzeughinterachse, der gewählte Sichtbereich ist als Trapez in Hellblau eingezeichnet (Rastergröße: 5 Meter)

Erkennbar ist, dass der Sensor in weiter Entfernung Landmarken detektieren kann. Sie weisen jedoch eine hohe Ungenauigkeit (vgl. Teilkapitel 3.1.4.3) auf. Um Landmarken mit geringeren Unsicherheiten zu verwenden, wurde ein deutlich kleinerer Sichtbereich für den Sensor gewählt.

Der Sichtbereich ergibt sich durch das Abbildungsmodell der Kamera (vgl. Teilkapitel 3.1.4.3) als Trapez mit 25 Metern Länge und 10 bzw. 25 Metern Breite.

### TopView-System

Das TopView-System besteht aus vier Fischaugenkameras (dioptrische omnidirektionale Kamera), die um das Fahrzeug herum integriert sind und eine 360°-Rundumsicht erlauben. Landmarken in der direkten Nähe des Fahrzeugs werden in hoher Qualität wahrgenommen. In Anhang A.5.2.2 ist exemplarisch eine Kamera dargestellt und die zugehörigen technischen Daten des Systems sind angegeben.

Der große Öffnungswinkel der Kamera führt zu starken Verzerrungen in Richtung des Bildrandes. Abbildung 3.10 zeigt exemplarisch die gelieferten Bilder der Kameras, während Abbildung 3.11 die Vogelperspektive (engl. bird's eye view) für alle vier Kamerabilder wiedergibt.

Für die Extraktion der Straßenmarkierungen aus den Kamerabildern wird ein Kameramodell benötigt, das die Projektion von Weltpunkten auf die Bildebene beschreibt. Modelle für Fischaugenkameras sind in [237] zu finden. Wird die Fahrbahn vereinfacht als eben angenommen, so entspricht die Bildebene direkt der Bodenebene. Wird die Annahme für alle vier Kamerabilder festgelegt, entsteht eine Vogelperspektive.

Aus dem erzeugten, entzerrten und auf den Boden projizierten Bild werden die einzelnen Landmarken mit dem in [234] beschriebenen Verfahren detektiert und der LbL zur Verfügung gestellt. Die Ausgabe erfolgt für jede Kamera einzeln.




Abbildung 3.10: Ausgabe der Fischaugenkameras des TopView-Systems (im Uhrzeigersinn: rechts, hinten, links und vorne)



Abbildung 3.11: Vogelperspektive als Ergebnis der Projektion der 4 Fischaugenkameras auf die Bodenebene (erzeugt aus Abbildung 3.10)

### Sichtbereich des TopView-Systems

Für jede Fischaugenkamera des TopView-Systems wird ein eigener Sichtbereich ermittelt. Abbildung 3.12 zeigt für alle vier Kameras die wahrgenommenen Landmarken und die sich daraus ergebenden Sichtbereiche. Alle Detektionen der Landmarken (vgl. Tabelle 3.1) sind je Kamera einheitlich eingefärbt. Die Landmarken der vorderen Kamera sind in Grün, die der rechten Kamera Orange, die der hinteren Kamera in Rot und die der linken Kamera in Olivgrün dargestellt. Die Rastergröße entspricht einem Meter. Die einzelnen FOV-Bereiche sind mit hellblauen Rechtecken verdeutlicht.




Abbildung 3.12: Sichtbereiche der Fischaugenkameras des TopView-Systems (Rastergröße: 1 Meter)



Die jeweiligen FOV-Bereiche können direkt aus Abbildung 3.12 abgeleitet werden. Für die vordere Kamera ergibt sich eine Länge von sechs Metern und eine Breite von fünf Metern. Der Sichtbereich der hinteren Kamera wird mit sechs Metern Breite und sechs Metern Länge festgelegt. Die beiden FOV-Bereiche der seitlichen Kameras sind mit jeweils vierzehn Metern Länge und drei Metern Breite definiert.

Deutlich zu sehen sind die Überlappungen der einzelnen Kameras, was zu einer 360°-Wahrnehmung führt. Um Landmarken kontinuierlich tracken und fusionieren zu können, müssen auch die gewählten Sichtbereiche überlappen. Das ist durch die stärkere Färbung des FOV-Bereichs schematisch abgebildet.

### 3.1.4.3 Fehlermodell

Für die verwendete Sensorik soll jeweils ein vereinfachtes Fehlermodell zur Unsicherheitschätzung der erzeugten Landmarken erstellt werden. Es wird zwischen dem Fehlermodell für den Laserscanner und dem Fehlermodell für die Kameras differenziert.

Es gelten die im Anhang A gegebenen Sensoreigenschaften. Durch die Verarbeitung der Sensorrohdaten stehen nur detektierte Landmarken zur Verfügung, womit es keine Möglichkeit gibt, vorhandene systematische Fehler im Abbildungsmodell zu korrigieren. Die Annahme einer ebenen Fahrbahn im Abbildungsmodell führt zur Entstehung von Abbildungsfehlern. Die Größe der Fehler ist abhängig von Distanz und Winkel zum Fahrzeug. Durch diese Abbildungsfehler kann den Landmarken mit dem Einsatz der Varianzfortpflanzung [238] eine Genauigkeit zugeordnet werden. Die Genauigkeiten der Messungen werden beispielsweise aus Strecken- und Winkelbeobachtungen der Landmarkenkoordinaten berechnet. Da der funktionale Zusammenhang nicht linear ist, muss die Varianzfortpflanzung für nicht-lineare Funktionen verwendet werden.

Sei  $f(l_1, l_2)$  eine Funktion der Beobachtung, mit der die Parameter  $x$  und  $y$  berechnet werden, dann ergibt sich die Kovarianzmatrix der Beobachtung laut Gleichung (3.1). Gleichung (3.1) wird als bekannt vorausgesetzt.

$$\Sigma_{ll} = \begin{pmatrix} \sigma_{l_1}^2 & \sigma_{l_1 l_2} \\ \sigma_{l_1 l_2} & \sigma_{l_2}^2 \end{pmatrix} \quad (3.1)$$

Durch Bilden der partiellen Ableitungen nach den Beobachtungen wird die Forderung nach Linearisierung des funktionalen Zusammenhangs im allgemeinen Varianzfortpflanzungsgesetz erfüllt [238]. Es entsteht die in Gleichung (3.2) gezeigte Jacobi-Matrix  $J$ .

$$J = \begin{pmatrix} \frac{\partial f(l_1, l_2)}{\partial l_1} & \frac{\partial f(l_1, l_2)}{\partial l_2} \end{pmatrix} \quad (3.2)$$

Anschließend wird mit dem allgemeinen Varianzfortpflanzungsgesetz die Kovarianz des Parameters mit Gleichung (3.3) ermittelt.

$$\Sigma_{xy} = J \Sigma_{ll} J^T \quad (3.3)$$

Nachfolgend wird das beschriebene Fehlermodell auf die verwendeten Sensoren angewendet, um die Unsicherheiten der Landmarken zu ermitteln.



### Fehlermodell des Laserscanners

Auf der Datengrundlage, bestehend aus den detektierten Landmarken, werden Vereinfachungen im Fehlermodell durchgeführt. Es wird eine zweidimensionale Fahrzeugbewegung angenommen, wodurch alle Detektionen in 2D vorliegen und die Fahrbahn als eben modelliert wird. Die Winkel- und Distanzmessungen von der Sensorposition zur Messkoordinate  $(x, y)$  einer jeweiligen Detektion sind als Horizontalwinkel  $(\alpha)$  und -distanz  $(d)$  aufzufassen. Die Unsicherheit der detektierten Koordinate einer Landmarke setzt sich aus den Winkel- und Distanzmessungen zusammen. Der funktionale Zusammenhang zwischen einer Messung und der erhaltenen Größe einer Koordinate wird entsprechend Gleichung (3.4) formuliert.

$$\begin{aligned} f(l_1)_{\text{Lidar}} &:= y_{\text{detection}}^{\text{SRF}_{\text{Lidar}}} = d \cdot \cos(\alpha) \\ f(l_2)_{\text{Lidar}} &:= x_{\text{detection}}^{\text{SRF}_{\text{Lidar}}} = d \cdot \sin(\alpha) \end{aligned} \quad (3.4)$$

Die Berechnung der Kovarianz einer Detektion ist in Gleichung (3.5) gegeben. Wobei  $\Sigma_{ll}^{\text{Lidar}}$  und  $J_{\text{Lidar}}$  sich aus der Beschreibung in Gleichung (3.6) ergeben. Die Distanzgenauigkeiten für  $\Sigma_{ll}^{\text{Lidar}}$  können direkt den in Anhang A.5.1 aufgeführten technischen Sensordaten entnommen werden.

$$\Sigma_{\text{detection}}^{\text{SRF}_{\text{Lidar}}} = J_{\text{Lidar}} \Sigma_{ll}^{\text{Lidar}} (J_{\text{Lidar}})^T \quad (3.5)$$

$$\begin{aligned} J_{\text{Lidar}} &= \frac{\partial(f(l_1)_{\text{Lidar}}, f(l_2)_{\text{Lidar}})}{\partial(d, \alpha)} = \begin{pmatrix} \frac{\partial f(l_1)_{\text{Lidar}}}{\partial d} & \frac{\partial f(l_1)_{\text{Lidar}}}{\partial \alpha} \\ \frac{\partial f(l_2)_{\text{Lidar}}}{\partial d} & \frac{\partial f(l_2)_{\text{Lidar}}}{\partial \alpha} \end{pmatrix} = \begin{pmatrix} \cos \alpha & -d \cdot \sin(\alpha) \\ \sin(\alpha) & d \cdot \cos(\alpha) \end{pmatrix} \\ \Sigma_{ll}^{\text{Lidar}} &= \begin{pmatrix} \sigma_d^2 & \sigma_{d\alpha} \\ \sigma_{d\alpha} & \sigma_\alpha^2 \end{pmatrix} \end{aligned} \quad (3.6)$$

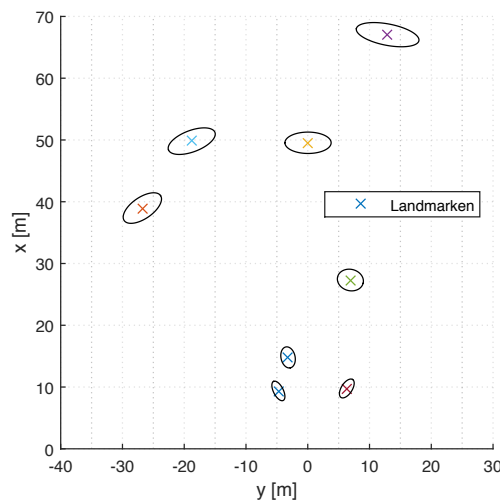


Abbildung 3.13: Ermittelte Kovarianzen des laserscannerbasierten Fehlermodells aus der Varianzfortpflanzung (50-fach vergrößert)

Abbildung 3.13 zeigt beispielhaft einige Detektionen im Sensor Reference Frame (SRF), zusammen mit den zugehörigen Kovarianzellipsen. Der Sensor befindet sich im Ursprung. Er-

kennbar ist, dass die Genauigkeit vom Abstand  $d$  zum Sensor abhängt. Durch die Winkelmessgenauigkeit vergrößert sich bei weit entfernten Objekten die Varianz der Detektionen orthogonal zum Messstrahl.

### Kamerabasiertes Fehlermodell

Nachfolgend wird das Fehlermodell für die Detektionen der Landmarken mit den Kamerasystemen des Fahrzeugs beschrieben. Die vorhandenen Abbildungsmodelle der eingesetzten Monokamera [232] und der vier Fischaugenkameras [237] (vgl. Teilkapitel 3.1.4.2) werden unverändert gelassen.

Für das verwendete Fehlermodell sind die Faktoren Kamerahöhe  $h$ , Kamerakonstante  $c$ , Position der Landmarke im Sensorkoordinatensystem sowie im Bild ausschlaggebend. Abbildung 3.14 verdeutlicht den Zusammenhang der einzelnen Faktoren zueinander. Aufgrund der Nutzung des vereinfachten Fehlermodells werden die nachfolgenden Berechnungsschritte für alle eingesetzten Kamerasysteme verwendet. Der funktionale Zusammenhang zwischen einem Bildpunkt  $(x_{\text{detection}}^{\text{cam}}, y_{\text{detection}}^{\text{cam}})$  und dem entsprechenden Punkt im Sensorkoordinatensystem  $(x_{\text{detection}}^{\text{srfCamera}}, y_{\text{detection}}^{\text{srfCamera}})$  lässt sich entsprechend Gleichung (3.7) beschreiben.




Abbildung 3.14: Schematische Darstellung des Zusammenhangs der genannten Faktoren im Fehlermodell für Kameras

$$\begin{aligned} f(l_1)_{\text{Camera}} &:= x_{\text{detection}}^{\text{cam}} = -\frac{hc}{y_{\text{detection}}^{\text{srfCamera}}} && \Rightarrow -\frac{hc}{y} \\ f(l_2)_{\text{Camera}} &:= y_{\text{detection}}^{\text{cam}} = -\frac{h}{y_{\text{detection}}^{\text{srfCamera}}} x_{\text{detection}}^{\text{srfCamera}} && \Rightarrow -\frac{h}{y} x \end{aligned} \quad (3.7)$$

Die Kovarianzen der Detektionen sind wieder mit dem allgemeinen Varianzfortpflanzungsgesetz zu bestimmen und in Gleichung (3.8) formuliert.

$$\Sigma_{\text{detection}}^{\text{srfCamera}} = J_{\text{Camera}} \Sigma_{ll}^{\text{Camera}} (J_{\text{Camera}})^{\top} \quad (3.8)$$

Der Term  $\Sigma_{ll}^{\text{Camera}}$  entspricht den Kovarianzen der Detektionen im Bild und muss für jede Kamera entsprechend ihrer Eigenschaften (gegeben in Anhang A.5.2.1 und Anhang A.5.2.2) ermittelt werden. Es wird für jedes Kamerasystem die Genauigkeit von einem Pixel festgelegt und die Genauigkeiten der Bildkoordinaten einer Detektion als unkorreliert und gleich angenommen. Für das kamerabasierte Fehlermodell ergibt sich damit die Jacobi-Matrix  $J_{\text{Camera}}$  und Detektionskovarianz  $\Sigma_{ll}^{\text{Camera}}$  aus Gleichung (3.9).

$$J_{\text{Camera}} = \frac{\partial(f(l_1)_{\text{Camera}}, f(l_2)_{\text{Camera}})}{\partial(x, y)} = \begin{pmatrix} \frac{\partial f(l_1)_{\text{Camera}}}{\partial x} & \frac{\partial f(l_1)_{\text{Camera}}}{\partial y} \\ \frac{\partial f(l_2)_{\text{Camera}}}{\partial x} & \frac{\partial f(l_2)_{\text{Camera}}}{\partial y} \end{pmatrix} = \begin{pmatrix} 0 & \frac{hc}{y^2} \\ -\frac{h}{y} & \frac{hx}{y^2} \end{pmatrix} \quad (3.9)$$

$$\Sigma_{ll}^{\text{Camera}} = \begin{pmatrix} \sigma_x^2 & \sigma_{yx} \\ \sigma_{yx} & \sigma_y^2 \end{pmatrix}$$

Abbildung 3.15 zeigt simulierte Beobachtungen im Bildraum mit zugehörigen Kovarianz-ellipsen der Detektionen. Sie sind auf die Fahrbahn projiziert dargestellt. Die Kamera befindet sich im Koordinatenursprung. Zur Visualisierung sind die Unsicherheiten 500-fach vergrößert abgebildet. Mit Hilfe dieses Modells können die berechneten Standardabweichungen der Genauigkeiten in Abhängigkeit zur Distanz der Beobachtungen gebracht werden. Es lässt sich festhalten, dass die Standardabweichungen der auf die Fahrbahn projizierten Detektionen quadratisch mit der Distanz zum Sensor und linear in lateraler Blickrichtung anwachsen (siehe Anhang A.5.2.3).

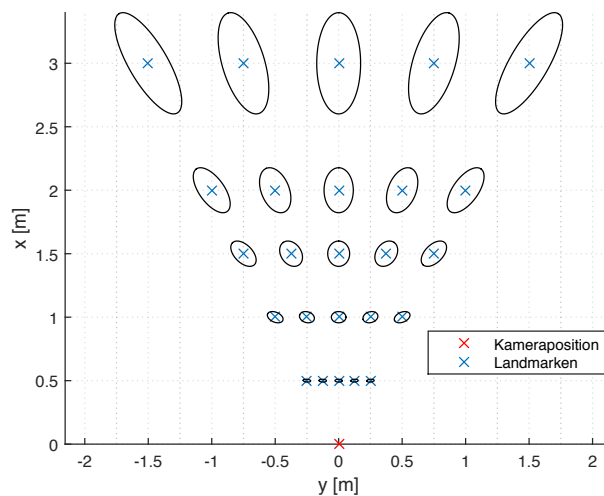


Abbildung 3.15: Ermittelte Kovarianzen des kamerabasierten Fehlermodells aus der Varianzfortpflanzung (500-fach vergrößert)

## 3.2 Koordinatensysteme

Für die in Kapitel 1.2 aufgeführte Randbedingung R1 (Dezentrale Karte) sind zahlreiche Koordinatensysteme notwendig. Sie werden in diesem Kapitel erläutert und deren Transformationen untereinander beschrieben. Die Ausführungen folgen den Beschreibungen in [12, 30, 89]. Abbildung 3.16 zeigt zusammengefasst die im Folgenden beschriebenen Koordinatensysteme.

### 3.2.1 World Geodetic System 1984

Die Erde kann näherungsweise als ein Rotationsellipsoid modelliert werden. Ein solches Modell wird als geodätisches Datum bezeichnet und parametrisiert die Lage und Länge der Halbachsen. Das „World Geodetic System 1984“-definierte (WGS84) definierte Erdmodell hat sich heutzutage als weltweiter Rotationsellipsoid für globale Positionierungssysteme etabliert.

Der Koordinatenursprung entspricht dem Mittelpunkt der Erde. Die Beschreibung des Ellipsoides erfolgt in geografischen Koordinaten über Längengrad (Longitude  $\lambda \in [-\pi, \pi)$ ), Breitengrad (Latitude  $\phi \in [-\frac{\pi}{2}, \frac{\pi}{2}]$ ) und der Höhe (Altitude  $h \in \mathbb{R}$ ). Die Longitudinalwerte geben dabei die Winkelabweichung nach Osten und Westen vom Nullmeridian an und die Latitudinalwerte stehen für die Abweichung vom Äquator aus nach Süden respektive Norden. Um Fallunterscheidungen in dieser Arbeit zu vermeiden, werden longitudinale Werte westlich des Nullmeridians sowie latitudinale Werte südlich des Äquators negativ angegeben. Aufgrund der untergeordneten Rolle der altitudinalen Werte in den Transformationsberechnungen und der Randbedingung R5 (Zweidimensionale Fahrzeugbewegung), wird die Höhe als Null angenommen.

Das WGS84-Koordinatensystem ist im Weiteren als  $\xi^{\text{wgs}}$  bezeichnet, wobei ein Punkt im Koordinatensystem in der Form  $p^{\text{wgs}} = (\lambda^{\text{wgs}}, \phi^{\text{wgs}}, h^{\text{wgs}})$  angegeben wird.

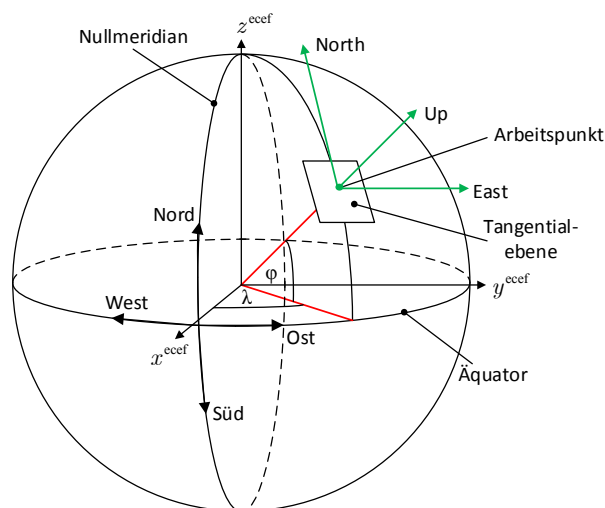


Abbildung 3.16: Übersicht der relevanten Koordinatensysteme

### 3.2.2 Earth-Centered, Earth-Fixed

Die geografischen Koordinaten im WGS84-Koordinatensystem lassen sich auch in einem erdfesten, dreidimensionalen, metrischen, euklidischen Koordinatensystem, dem Earth-Centered, Earth-Fixed (ECEF) genannten System, darstellen.

Der Nullpunkt liegt auf dem Erdmittelpunkt. Die  $x^{\text{ecef}}$ -Achse verläuft vom Erdmittelpunkt zum Schnittpunkt des Nullmeridians mit dem Äquator, die  $z^{\text{ecef}}$ -Achse entspricht der Erddrehachse und durchstößt den geographischen Nordpol und die  $y^{\text{ecef}}$ -Achse vervollständigt das rechtshändige System. Das ECEF-System wird mit  $\xi^{\text{ecef}}$  bezeichnet. Ein Punkt innerhalb des  $\xi^{\text{ecef}}$ -Systems wird mit  $p^{\text{ecef}} = (x^{\text{ecef}}, y^{\text{ecef}}, z^{\text{ecef}})$  beschrieben.

### 3.2.3 East-North-Up

Wird das WGS84-Erdmodell zugrunde gelegt, so kann für jeden Punkt der Erde eine tangentielle Hyperebene gefunden werden. Eine isometrische, also längentreue, Abbildung der Erdoberfläche in eine Ebene ist nicht möglich. Wird jedoch die Erdoberfläche lokal durch eine Tangentialebene approximiert, so sind Längenverzerrungen nahe des Berührungspunktes vernachlässigbar. Es wird an die gewünschte Position auf der Erdoberfläche, dem Arbeitspunkt, eine Tangentialebene angelegt und so parametrisiert, dass ihr Nullpunkt mit dem Berührungspunkt der Erdoberfläche zusammenfällt. Das so entstehende Koordinatensystem innerhalb der Tangentialebene wird als East-North-Up (ENU) bezeichnet. Die  $x^{\text{enu}}$ -Achse zeigt nach Osten, die  $y^{\text{enu}}$ -Achse nach Norden und die  $z^{\text{enu}}$ -Achse Richtung Weltall. Die  $x$ - $y$ -Ebene fällt mit der Tangentialebene zusammen und es entsteht ein metrisches, euklidisches System. Für einige Anwendungen wird analog ein Koordinatensystem definiert, in dem die Parametrisierung der Ebene anderes gewählt wird. Es entstehen die als North-East-Down (NED) bezeichneten Koordinaten. Die  $x^{\text{ned}}$ -Achse verläuft nach Norden, die  $y^{\text{ned}}$ -Achse nach Osten und die  $z^{\text{ned}}$ -Achse in Richtung Erdmittelpunkt. Wegen der ungünstigen Anschauung der reinen  $x$ - $y$ -Ebene dieses Koordinatensystems wird es in dieser Arbeit nicht verwendet.

Die ENU-Koordinaten werden als  $\xi^{\text{enu}}$  bezeichnet. Ein Punkt wird innerhalb des Systems mit  $p^{\text{enu}} = (x^{\text{enu}}, y^{\text{enu}}, z^{\text{enu}})$  vollständig beschrieben.

### 3.2.4 Lokale Koordinatensysteme

Das Fahrzeug selbst definiert einige weitere lokale Koordinatensysteme. Es handelt sich um rechtshändige dreidimensionale Koordinatensysteme, die fest mit dem Fahrzeug verbunden sind. Nachfolgend sind die einzelnen Systeme definiert und in Abbildung 3.17 visualisiert:

- Sensorkoordinatensystem:

Jeder Sensor im Fahrzeug hat sein eigenes, fest ausgerichtetes Koordinatensystem, das sogenannte Sensor Reference Frame (SRF). Es wird für jeden Sensor  $i$  mit  $\text{srf}_i$  angegeben und beschreibt die relative Position von wahrgenommenen Objekten eines Sensors. Der Ursprung des jeweiligen  $\text{srf}_i$  ist im Zentrum des Sensors angenommen. Das Koordinatensystem ist fest mit dem Sensor, also der Karosserie, verbunden und dreht sich gegenüber seinem Umfeld bei Nick- und Wankbewegungen des Fahrzeugs mit. Je Sensor ist die  $x^{\text{srf}_i}$ -Achse als aus der Sensorik heraus zeigend, die  $y^{\text{srf}_i}$ -Achse nach links und  $z^{\text{srf}_i}$ -Achse nach oben gerichtet definiert. Das SRF wird als  $\xi^{\text{srf}_i}$  bezeichnet und beschreibt einen Punkt mit  $p^{\text{srf}_i} = (x^{\text{srf}_i}, y^{\text{srf}_i}, z^{\text{srf}_i})$ .

- Fahrzeugkoordinatensystem:

Das Fahrzeugkoordinatensystem, hier Vehicle Reference Frame (VRF) genannt, bildet das Hauptkoordinatensystem des Fahrzeugs. Entsprechend dem SRF ist auch das VRF ein fest ausgerichtetes Koordinatensystem. Die Hinterachsenmitte, projiziert auf die Fahrbahn, ist als Ursprung definiert. Die  $x^{\text{vrf}}$ -Achse verläuft nach vorne, die  $y^{\text{vrf}}$ -Achse steht senkrecht auf der  $x^{\text{vrf}}$ -Achse und zeigt nach links. Beide Achsen liegen auf der Straßenoberfläche. Um das rechtshändige Koordinatensystem zu vervollständigen, steht die

$z^{\text{vrf}}$ -Achse senkrecht auf der Straßenebene und ist nach oben positiv definit.  $\xi^{\text{vrf}}$  beschreibt das Fahrzeugkoordinatensystem, wobei ein Punkt mit  $p^{\text{vrf}} = (x^{\text{vrf}}, y^{\text{vrf}}, z^{\text{vrf}})$  spezifiziert wird.

- Globales, fahrzeugeigenes Koordinatensystem:

Für das in Kapitel 4.2 beschriebene Tracking- & Fusionsmodell wird ein globales, fahrzeugeigenes Koordinatensystem benötigt, um zwischen zwei Zeitpunkten  $\tau$  und  $\tau - 1$  die wahrgenommenen Objekte im  $\xi^{\text{vrf}}$ -System entsprechend der durchgeführten Eigenbewegung zu transformieren. Zum Zeitpunkt des Einschaltens wird das Koordinatensystem definiert und bis zum Ausschalten des Fahrzeugs beibehalten. Es wird als Origin Car Coordinate System (OCCS) bezeichnet und entsprechend der ersten Eingangspose gleich der Achsdefinition des VRF festgelegt. Das OCCS bildet ein rechtshändiges Koordinatensystem mit dem Ursprung  $(0, 0, 0)$  zum Startzeitpunkt des Fahrzeugs und wird als  $\xi^{\text{occs}}$  bezeichnet. Ein Punkt im System wird entsprechend als  $p^{\text{occs}} = (x^{\text{occs}}, y^{\text{occs}}, z^{\text{occs}})$  deklariert.




Abbildung 3.17: Übersicht der genannten lokalen, fahrzeugeigenen Koordinatensysteme

## 3.2.5 Koordinatentransformationen

Abschließend werden in diesem Abschnitt die Umrechnungen zwischen den eingeführten Koordinatensystemen erläutert und die Transformationsbeschreibungen aufgestellt.

### 3.2.5.1 Koordinatentransformation von WGS84 in ECEF

Bei der Transformation vom  $\xi^{\text{wgs}}$ - in das  $\xi^{\text{ecef}}$ -System ist ein Koordinatenpunkt  $p^{\text{wgs}}$  in  $\xi^{\text{wgs}}$  gegeben und der korrespondierende Punkt  $p^{\text{ecef}}$  in  $\xi^{\text{ecef}}$  gesucht. Um eine Transformationsbeschreibung zwischen den beiden Systemen zu bestimmen, sind die Ellipsenkenngrößen des WGS84-Erdmodells notwendig [89]. Sie können der Tabelle in Anhang B.1 entnommen werden. Mit diesen Kenngrößen lassen sich die geografischen Koordinaten des Punktes  $p^{\text{wgs}}$  als kartesi-

sche Koordinaten des Punktes  $p^{\text{ecef}}$  ausdrücken. Die zu berechnenden Werte des Punktes  $p^{\text{ecef}}$  ergeben sich entsprechend Gleichung (3.10).

$$p^{\text{ecef}} = \begin{pmatrix} x^{\text{ecef}} \\ y^{\text{ecef}} \\ z^{\text{ecef}} \end{pmatrix} = \begin{pmatrix} (n(\phi^{\text{wgs}}) + h^{\text{wgs}}) \cdot \cos(\phi^{\text{wgs}}) \cdot \cos(\lambda^{\text{wgs}}) \\ (n(\phi^{\text{wgs}}) + h^{\text{wgs}}) \cdot \cos(\phi^{\text{wgs}}) \cdot \sin(\lambda^{\text{wgs}}) \\ (n(\phi^{\text{wgs}})(1 - e^2) + h^{\text{wgs}}) \cdot \sin(\phi^{\text{wgs}}) \end{pmatrix} \quad (3.10)$$

### 3.2.5.2 Koordinatentransformation von ECEF in WGS84

Um die entgegengesetzte Umrechnung der Koordinaten, also von  $\xi^{\text{ecef}}$  nach  $\xi^{\text{wgs}}$ , durchzuführen, muss prinzipiell nur Gleichung (3.10) nach den gesuchten Größen umgestellt werden. Durch die Nichtlinearität der Gleichung ist die Umstellung nicht ohne Weiteres möglich. Eine geschlossene Form findet sich jedoch in [89].

Die Rücktransformation kann auch mit Hilfe eines iterativen Algorithmus durchgeführt werden, der als Pseudocode in Anhang B.2 wiedergegeben ist [12]. Das beschriebene Verfahren konvergiert schnell, sodass nur wenige Iterationen benötigt werden, um eine hohe Genauigkeit zu erhalten.

### 3.2.5.3 Koordinatentransformation von ECEF in ENU

Bei der Transformation zwischen dem  $\xi^{\text{ecef}}$ -System in die Tangentialebene, dessen lokales kartesisches Koordinatensystem der  $\xi^{\text{enu}}$ -Definition folgt, muss jeweils ein Arbeitspunkt  $ap^{\text{wgs}} = (\lambda^{\text{wgs}}, \phi^{\text{wgs}})$  angegeben werden. An dem Arbeitspunkt berührt die Tangentialebene die Erde (vgl. Abbildung 3.16). Mit dieser Transformation können GPS-Positionsdaten in Bezug zum eigenen Fahrzeug gebracht werden.

Nach Definition der Systeme  $\xi^{\text{ecef}}$  und  $\xi^{\text{enu}}$  weisen die verwendeten Koordinatensysteme eine Drehung zueinander auf. Die  $x^{\text{ecef}}$ -Achse ist um den Winkel  $\alpha_x$  und die  $z^{\text{ecef}}$ -Achse um den Winkel  $\alpha_z$  verdreht. Aus dem im Teilkapitel 3.2.1 aufgeführten Wertebereich für den Längengrad  $\lambda \in [-\pi, \pi)$  und Breitengrad  $\phi \in [-\frac{\pi}{2}, \frac{\pi}{2}]$  ergeben sich die in Gleichung (3.11) gezeigten Drehwinkel.

$$\begin{aligned} \alpha_z &= \alpha_{\text{ost}} = \lambda^{\text{wgs}} + \pi, \text{ für Winkel östlich des Nullmeridians} \\ \alpha_z &= \alpha_{\text{west}} = \lambda^{\text{wgs}} - \pi, \text{ für Winkel westlich des Nullmeridians} \\ \alpha_x &= \alpha_{\text{nord}} = \frac{\pi}{2} - \phi^{\text{wgs}}, \text{ für Winkel auf der nördlichen Erdhalbkugel} \\ \alpha_x &= \alpha_{\text{süd}} = -\frac{\pi}{2} - \phi^{\text{wgs}}, \text{ für Winkel auf der südlichen Erdhalbkugel} \end{aligned} \quad (3.11)$$

Es ergeben sich die Rotationsmatrizen entsprechend der Ausführung in Anhang B.3. In Gleichung (3.12) ist die zugehörige vollständige Rotationsmatrix  $R_{zx}(\alpha_z, \alpha_x)$  gegeben.

$$\begin{aligned} R_{zx}(\alpha_z, \alpha_x) &= \begin{pmatrix} -\sin(\lambda^{\text{wgs}}) & \cos(\lambda^{\text{wgs}}) & 0 \\ -\sin(\phi^{\text{wgs}}) \cos(\lambda^{\text{wgs}}) & -\sin(\phi^{\text{wgs}}) \sin(\lambda^{\text{wgs}}) & \cos(\phi^{\text{wgs}}) \\ \cos(\phi^{\text{wgs}}) \cos(\lambda^{\text{wgs}}) & \cos(\phi^{\text{wgs}}) \sin(\lambda^{\text{wgs}}) & \sin(\phi^{\text{wgs}}) \end{pmatrix} \\ &=: R(\lambda^{\text{wgs}}, \phi^{\text{wgs}}) \end{aligned} \quad (3.12)$$

Wird weiter die Funktion  $f : [-\pi, \pi) \times [-\frac{\pi}{2}, \frac{\pi}{2}] \rightarrow \mathbb{R}^3$  als die Funktion definiert, welche  $\xi^{\text{wgs}}$  in  $\xi^{\text{ecef}}$  überführt, dann lässt sich die Transformation von  $p^{\text{ecef}}$  zu  $p^{\text{enu}}$  bzgl. eines Arbeitspunktes  $ap^{\text{wgs}}$  laut Gleichung (3.13) ausdrücken.

$$p^{\text{enu}} = R(ap^{\text{wgs}}) \cdot (p^{\text{ecef}} - f(ap^{\text{wgs}})) \quad (3.13)$$

### 3.2.5.4 Koordinatentransformation von ENU in ECEF

Gleichung (3.13) kann in Gleichung (3.14) für eine Rücktransformation eines Punktes  $p^{\text{enu}}$  im  $\xi^{\text{enu}}$ -System bzgl. eines Arbeitspunktes  $ap^{\text{wgs}}$  in einen korrespondierenden Punkt  $p^{\text{ecef}}$  im  $\xi^{\text{ecef}}$ -System umgestellt werden.

$$\begin{aligned} p^{\text{enu}} &= R(ap^{\text{wgs}}) \cdot (p^{\text{ecef}} - f(ap^{\text{wgs}})) \\ \Leftrightarrow p^{\text{ecef}} &= R(ap^{\text{wgs}})^{-1} \cdot p^{\text{enu}} + f(ap^{\text{wgs}}) \\ \Leftrightarrow p^{\text{ecef}} &= R(ap^{\text{wgs}})^{\top} \cdot p^{\text{enu}} + f(ap^{\text{wgs}}) \end{aligned} \quad (3.14)$$

### 3.2.5.5 Koordinatentransformation von VRF in ENU

Mit den oben beschriebenen Transformationen lässt sich eine gegebene Karte  $\mathcal{M}$  in  $\xi^{\text{wgs}}$  mit ihren Objekten in einem dreidimensionalen, euklidisch metrischen Koordinatensystem  $\xi^{\text{enu}}$  darstellen. Durch Randbedingung R3 (Zweidimensionale, sensorische Umgebungswahrnehmung mit Seriensensorik), der Modellierung des Fahrzeugs und seiner Objekte in einem zweidimensionalen Raum, kann die dritte Komponente von  $\xi^{\text{enu}}$  vernachlässigt werden. Liegen die vom Fahrzeug wahrgenommenen Beobachtungen im aktuellen Fahrzeugkoordinatensystem  $\xi^{\text{vrf}}$ , so müssen diese nach  $\xi^{\text{enu}}$  transformiert werden, um die Beobachtungen mit der Karte abzugleichen. Durch die Ausstattung des Fahrzeugs mit einem GPS kann die Fahrzeugpose im  $\xi^{\text{wgs}}$  als  $\varsigma^{\text{wgs}} = (\varsigma_{\lambda}^{\text{wgs}}, \varsigma_{\phi}^{\text{wgs}}, \theta^{\text{wgs}})$  definiert werden und lässt sich bzgl. eines gewählten Arbeitspunktes  $ap^{\text{wgs}}$  als Pose im  $\xi^{\text{enu}}$  mit  $\varsigma^{\text{enu}} = (\varsigma_x^{\text{enu}}, \varsigma_y^{\text{enu}}, \theta^{\text{enu}})$  ausdrücken. Die Pose  $\varsigma$  beschreibt in dem jeweiligen Koordinatensystem die aktuelle Position und Ausrichtung des Fahrzeugs.

Sei eine Beobachtung im  $\xi^{\text{vrf}}$  gegeben, die als  $p_{\text{objekt}}^{\text{vrf}} = (x_{\text{objekt}}^{\text{vrf}}, y_{\text{objekt}}^{\text{vrf}})$  beschrieben wird. Gesucht ist diese Beobachtung in  $\xi^{\text{enu}}$  mit  $p_{\text{objekt}}^{\text{enu}} = (x_{\text{objekt}}^{\text{enu}}, y_{\text{objekt}}^{\text{enu}})$ . Die gesuchte Position ergibt sich als Drehung um die Blickrichtung der Pose  $\theta^{\text{enu}}$  des Fahrzeugs im mathematisch negativen Sinne und einer Verschiebung um die Fahrzeugposition  $(\varsigma_x^{\text{enu}}, \varsigma_y^{\text{enu}})$ . Gleichung (3.15) zeigt die zugehörige Berechnung.

$$p_{\text{objekt}}^{\text{enu}} = \begin{pmatrix} \cos(\theta^{\text{enu}}) & \sin(\theta^{\text{enu}}) \\ -\sin(\theta^{\text{enu}}) & \cos(\theta^{\text{enu}}) \end{pmatrix} p_{\text{objekt}}^{\text{vrf}} + \begin{pmatrix} \varsigma_x^{\text{enu}} \\ \varsigma_y^{\text{enu}} \end{pmatrix} \quad (3.15)$$

### 3.2.5.6 Koordinatentransformation von SRF in VRF

Jeder im Fahrzeug verbaute Sensor  $i$  (vgl. Kapitel 3.1) arbeitet in seinem eigenen Koordinatensystem  $\xi^{\text{srf}_i}$ . Sowohl für das Tracking- & Fusionsmodell (TFM) als auch für die nachgelagerte Assoziierung der Beobachtungen in die Karte und der damit verbundenen Lokalisierung müssen alle Beobachtungen der Sensoren vom jeweiligen  $\xi^{\text{srf}_i}$  in das jeweils gültige  $\xi^{\text{vrf}}$  überführt werden. Die Orientierung des  $\xi^{\text{srf}_i}$  kann um alle drei Achsen gegenüber dem  $\xi^{\text{vrf}}$  verdreht sein. Mit



einem vorhergehenden Kalibrierungsschritt (vgl. Erläuterung 3.1) wird der Versatz zwischen  $\xi^{\text{srf}_i}$  und  $\xi^{\text{vrf}}$  bestimmt. Es handelt sich um eine Transformation mit 6-DOF (dt. Freiheitsgrade). Anhang B.4 stellt die benötigten Rotationsmatrizen dar und zeigt die resultierende, vollständige Rotationsmatrix  $R$  auf. Um die Objektpositionen in einem  $\xi^{\text{srf}_i}$  im  $\xi^{\text{vrf}}$  zu erhalten, ist zusätzlich zur Rotation auch die Translation zwischen beiden Systemen notwendig. Sie wird als  $\text{trans}(\xi^{\text{vrf}} - \xi^{\text{srf}_i})$  bezeichnet und ist durch den vorangegangenen Kalibrierungsschritt bekannt. Gleichung (3.16) gibt das beschriebene Vorgehen als affine Transformation an.

$$p_{\text{objekt}}^{\text{vrf}} = (R(\alpha, \beta, \gamma) \times \text{trans}(\xi^{\text{vrf}} - \xi^{\text{srf}_i})) \cdot p_{\text{objekt}}^{\text{srf}_i} \quad (3.16)$$

Vereinfacht und für den zweidimensionalen Raum veranschaulicht Abbildung 3.18 das Prinzip. Im linken Teil der Abbildung ist das  $\xi^{\text{vrf}}$  mit den Achsen  $x^{\text{vrf}}$  und  $y^{\text{vrf}}$  sowie das  $\xi^{\text{srf}_i}$  mit den zugehörigen Achsen  $x^{\text{srf}_i}$  und  $y^{\text{srf}_i}$  gezeigt. Ein wahrgenommenes Objekt ist mit einem Stern angedeutet, wobei  $\vec{p}^{\text{srf}_i}$  die Position des Objektes im  $\xi^{\text{srf}_i}$  System wiedergibt und  $\vec{p}^{\text{vrf}}$  die gesuchte Position im  $\xi^{\text{vrf}}$  ist. Der rechte Teil von Abbildung 3.18 gibt die Verdrehung beider Systeme zueinander mit  $\Delta\phi$  an. Der Vektor  $\vec{t}$  entspricht der beschriebenen Translation  $\text{trans}(\xi^{\text{vrf}} - \xi^{\text{srf}_i})$ .




Abbildung 3.18: Transformation von  $\xi^{\text{srf}_i}$  nach  $\xi^{\text{vrf}}$

### 3.2.5.7 Koordinatentransformation zwischen zwei Bewegungszeitpunkten im VRF

Abschließend muss die Transformationsberechnung zwischen zwei Zeitpunkten  $\tau$  und  $\tau - 1$  bestimmt werden. Zwischen den beiden Zeitpunkten hat sich das Fahrzeug entsprechend der Eigenbewegung fortbewegt. Laut Definition des Fahrzeugkoordinatensystems entstehen zu den Zeitpunkten  $\tau$  und  $\tau - 1$  die beiden Systeme  $\xi_{\tau}^{\text{vrf}}$  und  $\xi_{\tau-1}^{\text{vrf}}$ . Die Transformation zwischen den  $\xi^{\text{vrf}}$ -Systemen wird im  $\xi^{\text{occs}}$  ermittelt. Wahrgenommene Objekte werden mit der Transformation in das aktuell gültige  $\xi^{\text{vrf}}$ -Koordinatensystem überführt. Zum einen ist das notwendig, um im TFM (siehe Kapitel 4.2) ein konsistentes Landmarkenumfeldmodell zum jeweils aktuellen Zeitpunkt  $\tau$  aufzubauen, und zum anderen zur Verschiebung der Positionshypothesen im PLM (siehe Kapitel 4.3). Die Pose  $\zeta_{\tau}$  des Fahrzeugs ergibt sich aus der relativen Lage von  $\xi_{\tau}^{\text{vrf}}$

zum  $\xi^{\text{occs}}$ -System, wobei die Fahrzeugpose als Tripel  $\zeta_{\tau}^{\text{occs}} = (\zeta_{x,\tau}^{\text{occs}}, \zeta_{y,\tau}^{\text{occs}}, \theta_{\tau}^{\text{occs}})$  definiert ist. Abbildung 3.19 veranschaulicht das Vorgehen zur Berechnung der benötigten Transformation.

Im oberen Bereich der Abbildung, sind in Teil a die beiden  $\xi^{\text{vrf}}$  zu den Zeitpunkten  $\tau$  und  $\tau - 1$  zusammen mit dem  $\xi^{\text{occs}}$ -System des Fahrzeugs dargestellt. Der Pfeil von  $\xi_{\tau-1}^{\text{vrf}}$  nach  $\xi_{\tau}^{\text{vrf}}$  symbolisiert den Translationsvektor. Er ergibt sich aus der Position  $(\zeta_{x,\tau-1}^{\text{occs}}, \zeta_{y,\tau-1}^{\text{occs}})$  der Pose  $\zeta_{\tau-1}^{\text{occs}}$  und der Position  $(\zeta_{x,\tau}^{\text{occs}}, \zeta_{y,\tau}^{\text{occs}})$  der Pose  $\zeta_{\tau}^{\text{occs}}$ . Der angedeutete Winkel verdeutlicht genau die Blickrichtungsänderung zwischen  $\theta_{\tau-1}^{\text{occs}}$  und  $\theta_{\tau}^{\text{occs}}$ . Der Stern in Teil b deutet ein wahrgenommenes Objekt an und stellt die Fragestellung der Transformation klar: Wie sieht die Position des im  $\xi_{\tau-1}^{\text{vrf}}$  wahrgenommenen Objektes im  $\xi_{\tau}^{\text{vrf}}$ -System aus. Die gepunkteten Linien stellen die Koordinaten des Objektes im jeweiligen System dar. Im unteren Bereich der Abbildung sind die nötigen Rotationen der gesuchten Transformation angedeutet. In Teil c wird  $\xi_{\tau-1}^{\text{vrf}}$  entsprechend dem  $\xi^{\text{occs}}$ -System rotiert (entspricht gerade  $\theta_{\tau-1}^{\text{occs}}$ ). Die Translation zwischen beiden Systemen ist mit *trans* gekennzeichnet. Teil d zeigt abschließend die Rotation *rot* um die Blickwinkeldifferenz der beiden  $\xi^{\text{vrf}}$ -Systeme.

Die zugehörigen mathematischen Formulierungen sind in Anhang B.5 gegeben, wobei Gleichung (B.10) des Anhangs die beschriebene Transformation in affiner Formulierung zeigt. Im weiteren Verlauf wird die Bewegungsmatrix aus Gleichung (B.10) als Bewegungsschritt bezeichnet.




Abbildung 3.19: Veranschaulichung des Bewegungsschritts zwischen  $\xi_{\tau-1}^{\text{vrf}}$  und  $\xi_{\tau}^{\text{vrf}}$  innerhalb des  $\xi^{\text{occs}}$ -Systems

# Kapitel 4

## Landmarkenbasierte Lokalisierung

Grundlage jeder Anwendung, die im Kontext von selbstständig fahrenden PKW erstellt wird, ist die Lokalisierung. In der Lokalisierung wird die aktuelle Position und Ausrichtung (Pose) des Fahrzeugs ermittelt. Eine lokale Lokalisierung kann ein Fahrzeug in der Regel über seine Sensoren, wie z.B. Radodometrie, IMU, oder in Kombination mit ICP-Verfahren und umfeldwahrnehmenden Sensoren bestimmen. Für den Anwendungsfall selbstfahrender PKW wird eine globale Lokalisierung benötigt, um z.B. Daten zwischen Fahrzeugen oder einem Rechenzentrum auszutauschen (vgl. Randbedingung R1 (Dezentrale Karte) und R3 (Zweidimensionale, sensorische Umgebungswahrnehmung mit Seriensensorik)).

Für die globale Lokalisierung kann die Pose berechnet werden, indem aktuell wahrgenommene Beobachtungen in eine vorab bekannte Karte, unter Nutzung der relativen Fahrzeugbewegung, registriert werden. Gleichung (4.1) formuliert dies mathematisch.

$$\varsigma_{\tau} = f(z_{1:\tau}, u_{1:\tau}, \mathcal{M}) \quad (4.1)$$

Die zu berechnende Pose des Fahrzeugs zum Zeitpunkt  $\tau$  wird mit  $\varsigma_{\tau}$  bezeichnet. Sie lässt sich als Funktion aller wahrgenommenen Beobachtungen  $z_{1:\tau}$ , aller durchgeführten Bewegungen  $u_{1:\tau}$  und der statischen, vorab bekannten Karte  $\mathcal{M}$  beschreiben.

Aufbauend auf den in Kapitel 3 vorgestellten Rahmenbedingungen, wird in diesem Kapitel der entwickelte Lösungsansatz der Landmarkenbasierten Lokalisierung (LbL) im Detail vorgestellt. Im folgenden Kapitel 4.1 wird zuerst eine Gesamtübersicht des Lösungsverfahrens gegeben und im Teilkapitel 4.1.1 sind die verwendeten Landmarken mit ihrer zugehörigen Repräsentation aufgeführt. Die nachfolgenden Kapitel 4.2, 4.3 und 4.4 stellen die Bausteine der Gesamtlösung dar. In den Kapiteln werden die entwickelten Konzepte und Verfahren der erstmals vorgestellten Landmarkenbasierten Lokalisierung (LbL) eingeführt.

### 4.1 Gesamtarchitektur der Landmarkenbasierten Lokalisierung

Entsprechend der Abbildung 1.2 in Kapitel 1.3, handelt es sich bei der Ortungslösung LbL um einen zweiphasigen Prozess. Die erste Phase bildet die Kartierung einer Strecke. Die zweite Phase ist die anschließende Lokalisierung auf der erstellten Karte der ersten Phase. In bei-

den Phasen werden dieselbe Sensorik zur Umfeldwahrnehmung und das gleiche Verfahren zur Erzeugung eines konsistenten Landmarkenumfeldmodells sowie einer Karte verwendet. Die Architektur der LbL wird maßgeblich von den folgenden Randbedingungen (vgl. Kapitel 1.2), die als Einschränkungen des zur Verfügung stehenden Lösungsraums zu interpretieren sind, beeinflusst:

- Randbedingung R1: Dezentrale Karte
- Randbedingung R2: Invariante, semi-persistente Umgebungsmerkmale in vielfältigen Außenszenarien
- Randbedingung R3: Zweidimensionale, sensorische Umgebungswahrnehmung mit Seriensenorik
- Randbedingung R4: Initiales Vorwissen

Die wesentlichen Restriktionen sind durch die Randbedingung R1 vorgegeben und beeinflussen alle weiteren Randbedingungen. Entsprechend der Erläuterungen aus Kapitel 1.2, sind die folgenden wichtigen Einflussfaktoren der Randbedingung R1 aufzuführen: standardisiertes Kartenformat (NDS), globales, weitverbreitetes Koordinatensystem (WGS84) und daraus resultierend die Wahl der Repräsentation der verwendeten Landmarken. Diese Maßgaben sind schon während der Erzeugung des initialen Vorwissens in der Kartierungsphase (Randbedingung R4) einzuhalten und haben Einfluss auf die Wahl der Umgebungsmerkmale (Randbedingung R2, Randbedingung R3). Um die geforderten Randbedingungen zu erfüllen, unterscheiden sich die Daten der Bewegungsinformationen, sowohl lokal als auch global, in den beiden Phasen. In der Kartierungsphase wird zur Erzeugung hochgenauer Karten eine Ortungsreferenz (siehe Kapitel 3.1.1) als globale Poseschätzung und Eigenbewegungsschätzung verwendet (Randbedingung R4). Im Gegensatz dazu wird in der Lokalisierungsphase nur Seriensenorik für die Bewegungsinformationen des Fahrzeugs genutzt (siehe Kapitel 3.1.2 und 3.1.3, vgl. Randbedingung R5 (Zweidimensionale Fahrzeugbewegung) und Randbedingung R7 (Kosteneffiziente Realisierung und Serieneinsatz)). Während der Lokalisierung findet die Berechnung der präzisen Pose durch die Registrierung des erzeugten Landmarkenumfeldmodells in die vorab generierte Karte statt. Das erfolgt auf Grundlage des erstmalig in dieser Arbeit vorgestellten Sensormodells. Ausgelegt ist das Sensormodell für abstrakte Landmarken, die als geometrische Grundprimitive modelliert sind (vgl. Randbedingung R2 und R3). Die Lokalisierung aufgrund der Registrierung des Umfeldmodells in die Karte zur Berechnung einer präzisen Pose erfolgt im Partikelfilterbasierten Lokalisierungsmodell (PLM). Sowohl für das Verfahren zur Erzeugung eines konsistenten Landmarkenumfeldmodells als auch der Karte bildet das Tracking- & Fusionsmodell (TFM) die Klammer. Beide Methoden sind die Basis der LbL, des vorgestellten Ortungsverfahrens mit klassifizierten Elementen der Straßeninfrastruktur unter den aufgeführten Randbedingungen. Der beschriebene Zusammenhang ist in Abbildung 4.1 veranschaulicht.

Im unteren Teil der Abbildung sind die Eingangsdaten der LbL dargestellt. In das TFM gehen sowohl die Fahrzeugbewegungen (globale Poseschätzung und Eigenbewegungsschätzung) als auch die Ausgaben der Sensordatenverarbeitung ein. Innerhalb der Sensordatenverarbeitung werden aus der Umfeldsensorik (siehe Kapitel 3.1.4) die Landmarken der Straßeninfrastruktur

detektiert und als Messungen dem TFM zur Verfügung gestellt (als grüne Pfeile abgebildet, kapselt Randbedingung R2 und Randbedingung R3). Im Folgenden wird die Kombination aus Sensorik und zugehörigem Detektionsalgorithmus als Sensor bezeichnet. Sensor 1 bis Sensor 3 sind in Rot und Sensor n in Hellgrün visualisiert.

Das TFM hat die Aufgabe, aus den qualitativ unterschiedlichen, asynchronen Sensoreingängen zum einen ein konsistentes Landmarkenumfeldmodell und zum anderen eine Karte aufzubauen. Dadurch kann das Verfahren sowohl in der Kartierungsphase als auch der Lokalisierungsphase eingesetzt werden. Insgesamt ergeben sich im TFM drei verschiedene Abstraktionsgrade (Güteklassen) der Landmarken: Dateneingang, konsistentes Landmarkenumfeldmodell und die Karte. Um jeden Abstraktionsgrad sinnvoll verarbeiten zu können und ggf. verschiedene Verfahren je Abstraktionsgrad einzusetzen, wird für das TFM eine modulare dreischichtige Architektur vorgeschlagen. Jede Schicht entspricht einem Abstraktionsgrad der Landmarken. Zusätzlich bietet die Einteilung in drei Schichten den Vorteil, zukünftig weiterführende Verfahren, wie beispielsweise die Methoden aus [154] und [239], zu integrieren. In der ersten Schicht des TFM finden die sensor- und landmarkenspezifischen Vorverarbeitungen statt. Die zweite Schicht realisiert das neu eingeführte Tracking- & Fusionsverfahren dieser Arbeit. Dort wird das konsistente Landmarkenumfeldmodell aufgebaut. Abschließend wird in der dritten Schicht eine Landmarkenkarte erzeugt. Für die einzelnen Verarbeitungsschritte des TFM ist das Wissen über die Bewegung des Fahrzeugs notwendig. Die Informationen der Fahrzeugbewegung werden in einem Bewegungspuffer gespeichert. Das TFM stellt einerseits eine synchronisierte Ausgabe des Landmarkenumfeldmodells mit der zugehörigen Bewegungsinformation an das PLM zur Verfügung (orangefarbener Pfeil der zweiten TFM-Schicht an das PLM), andererseits wird eine Landmarkenkarte in globalen Koordinaten erzeugt (in der dritten TFM-Schicht). Sowohl die zweite als auch die dritte Schicht erfüllen die Anforderungen der Randbedingung R1. Zukünftig könnte – mit geeigneten Verfahren – die Ausgabe der dritten Schicht als inkrementelle Kartenaktualisierung über eine Luftschnittstelle an die dezentrale Karte zur Verfügung gestellt werden (visualisiert als gestrichelt-gepunkteter grauer Pfeil; nicht Bestandteil der vorliegenden Arbeit). Bei jeder Ausgabe des TFM an das PLM erfolgt auch die Übermittlung der zugehörigen globalen Pose an die dezentrale Karte über eine Luftschnittstelle (gestrichelter orangefarbener Pfeil). Die einzelnen Schichten des TFM und deren Verarbeitung sind in Kapitel 4.2 erläutert. Im PLM werden die Daten des TFM (zeitlich synchronisiert: konsistentes Landmarkenumfeldmodell aus der zweiten Schicht, Eigenbewegungsschätzung und globale Poseschätzung) in die erhaltene Landmarkenkarte (aus der dezentralen Karte, die in der Kartierungsphase generiert wurde) registriert und daraus eine präzise Pose berechnet. Um eine gültige Lokalisierung aus den Eingangsdaten des PLM zu bestimmen, wird der Partikelfilter von Thrun et al. [28] adaptiert und angepasst. Hierbei werden die gewonnenen Erkenntnisse aus den Arbeiten [25, 26, 139] berücksichtigt (vgl. Kapitel 2.5). Entsprechend den Ausführungen in Kapitel 2.2.2, dem Einsatzgebiet (reale Umgebungen in vielseitigen, weitläufigen Außenszenarien mit dynamischen Veränderungen und atmosphärischen Störungen) von selbstfahrenden PKW und durch die Einschränkungen der Randbedingungen R1 bis R7 (z.B. Modellierung der Landmarken, Ungenauigkeiten der globalen und lokalen Bewegungsschätzung), bietet der Partikelfilter als Vertreter der probabilistischen Verfahren die notwendigen Berechnungsschritte, um das übergeordnete Ziel einer präzisen Lokalisierung zu erreichen. Die Genauigkeit der ermittelten Pose eines Partikelfilters wird hauptsächlich durch das Bewegungsmodell, das Sen-

sormodell und das Resampling der Partikel festgelegt. Deshalb sind diese Verarbeitungsschritte im PLM an die Randbedingungen angepasst worden. Die Registrierung erfolgt im PLM mit dem in dieser Arbeit neu entwickelten Sensormodell für Landmarken, die als geometrische Grundprimitive modelliert sind. Das Sensormodell berechnet für jeden Partikel eine Wahrscheinlichkeit seiner Wahrnehmung des aktuellen Landmarkenumfeldmodells unter der Annahme, dass die Landmarkenkarte gültig ist. Jeder Partikel beschreibt eine mögliche Pose des Fahrzeugs. Über das Bewegungsmodell des PLM werden die Partikel, entsprechend der Fahrzeugbewegung, zwischen zwei Zeitschritten transformiert, während das Resampling die Anzahl und Streuung der benötigten Partikel steuert. Die Herleitungen und Adaptionen aller verwendeten Verarbeitungsschritte im PLM sind in Kapitel 4.3 aufgeführt.

Die verwendeten Landmarken innerhalb der LbL und deren Repräsentation in den einzelnen Güteklassen (grüne Pfeile der Sensordatenverarbeitung, orangefarbener Pfeil aus der zweiten TFM-Schicht zum PLM, gestrichelter blauer Pfeil aus der dezentralen Karte zum PLM bzw. die dritte Schicht im TFM) sind nachfolgend genauer beschrieben.




Abbildung 4.1: Architekturübersicht der LbL. Die LbL besteht aus den beiden Hauptkomponenten TFM und PLM. Eingangsdaten der LbL sind die Bewegungsinformationen (globale Poseschätzung und Eigenbewegungsschätzung) und die detektierten Landmarken der Sensordatenverarbeitung. Gestrichelte Linien symbolisieren Kommunikation über eine Luftschnittstelle.

### 4.1.1 Landmarkenbeschreibung

Sowohl für die Erstellung der Karte als auch zur Lokalisierung werden in der LbL Landmarken, also klassifizierte Umgebungscharakteristiken der Straßeninfrastruktur, verwendet. Die Landmarken lassen sich zum einen nach ihren geometrischen Grundprimitiven und zum anderen nach ihren Verarbeitungs- bzw. Güteklassen gruppieren. Tabelle 4.1 zeigt die verwendeten Landmarken auf (Spalte Beschreibung) und teilt sie entsprechend ihren geometrischen Grundprimitiven ein (Spalte Repräsentationstyp und Geometrie).

Tabelle 4.1: Zustandsvektordefinition der verwendeten Landmarken und deren Repräsentation

Repräsentationstyp	Geometrie	Zustandsvektor	Beschreibung	Detektor
Punktbasierte Landmarken	Punkt	$s^{\text{PO}}$	Pfähle, Pfosten, Säulen	LiDAR
Linienbasierte Landmarken	Linie	$s^{\text{DL}}$	Gestrichelte Linien, Pfeile, Stoppllinien	LiDAR, Kamera
Polylinienbasierte Landmarken	Polylinie	$s^{\text{PL}}$	Durchgezogene Linien	Kamera

Mit der Einteilung ergeben sich punktbasierete (PO), linienbasierte (DL) und polylinienbasierte (PL) Landmarken, die in der LbL zur Verfügung stehen. Die jeweiligen Zustandsvektoren  $s^{\text{PO}}$ ,  $s^{\text{DL}}$  und  $s^{\text{PL}}$  sind in Gleichung (4.2) definiert.

$$s^{\text{PO}} := \begin{pmatrix} p^{\text{vrf}} \\ \Sigma_p \\ p^{\text{wgs}} \\ \text{Durchmesser} \\ \text{Höhe} \\ \text{Zeitstempel} \\ \text{Sensor}^{\text{ID}} \\ \text{Belief} \\ \text{ID} \end{pmatrix} \quad
 s^{\text{DL}} := \begin{pmatrix} (p_1^{\text{vrf}}, p_2^{\text{vrf}}) \\ (\Sigma_{p_1}, \Sigma_{p_2}) \\ (p_1^{\text{wgs}}, p_2^{\text{wgs}}) \\ \text{Länge} \\ \text{Breite} \\ \text{Zeitstempel} \\ \text{Sensor}^{\text{ID}} \\ \text{Belief} \\ \text{ID} \end{pmatrix} \quad
 s^{\text{PL}} := \begin{pmatrix} (p_1^{\text{vrf}}, \dots, p_n^{\text{vrf}}) \\ (\Sigma_{p_1}, \dots, \Sigma_{p_n}) \\ (p_1^{\text{wgs}}, \dots, p_n^{\text{wgs}}) \\ \text{Länge} \\ \text{Breite} \\ \text{Zeitstempel} \\ \text{Sensor}^{\text{ID}} \\ \text{Belief} \\ \text{ID} \end{pmatrix} \quad (4.2)$$

Entsprechend der Definition der Zustandsvektoren werden punktbasierete Landmarken ( $s^{\text{PO}}$ ) über einen Punkt  $p^{\text{vrf}}$ , linienbasierte Landmarken ( $s^{\text{DL}}$ ) über jeweils einen Start- und Endpunkt  $(p_1^{\text{vrf}}, p_2^{\text{vrf}})$  und polylinienbasierte Landmarken ( $s^{\text{PL}}$ ) über einen Linienzug  $(p_1^{\text{vrf}}, \dots, p_n^{\text{vrf}})$  modelliert. Jeder Punkt wird als Triple  $p = (x, y, z)$  angegeben.

Die Zustandsvektoren der Landmarken in Karten sind identisch, ihre Punkte werden jedoch im  $\xi^{\text{wgs}}$ -System ausgedrückt, während Beobachtungen von Landmarken in der Lokalisierungsphase im  $\xi^{\text{vrf}}$ -System beschrieben werden. Die Unsicherheit  $\Sigma$  einer Landmarke wird für jeden Landmarkentyp als Unsicherheit seiner zugehörigen Punkte  $\Sigma_p$  beschrieben. Die Unsicherheit ergibt sich aus den sensorspezifischen Fehlermodellen (vgl. Teilkapitel 3.1.4.3).

Jeder Zustandsvektor  $s^{\text{PO}}$ ,  $s^{\text{DL}}$  und  $s^{\text{PL}}$  enthält statische Informationen der aktuell wahrgenommenen Landmarke. Zum einen ist der Zeitpunkt der Wahrnehmung als *Zeitstempel* im Zustandsvektor hinterlegt. Zum anderen sind direkte Eigenschaften der Landmarke, wie *Durchmesser* und *Höhe* bei säulenförmigen Objekten sowie *Länge* und *Breite* bei linienförmigen Objekten, enthalten. Die *Sensor<sup>ID</sup>* gibt im Zustandsvektor wieder, von welchem Sensor die Landmarke detektiert wurde und ermöglicht im TFM sensorspezifische Verarbeitungsschritte. Der *Belief*-Eintrag entspricht dem Konfidenzwert der Landmarke, der über das SPRT-Verfahren in der zweiten Schicht des TFM berechnet wird. Die *ID* wird in der zweiten Schicht des TFM gesetzt, um zusammengehörige Landmarken im Tracking und der Fusion verwalten zu können.

Bestimmte Einträge in den Zustandsvektoren der Landmarken werden in den jeweiligen Verarbeitungs- bzw. Güteklassen verwendet. Es lassen sich die verwendeten Zustandsvektoren der Landmarken nicht nur entsprechend ihrer Geometrie einteilen, sondern auch nach der Stufe der Verarbeitung. Im Folgenden werden die Landmarken zusätzlich noch in die Güteklassen Level-1, Level-2 und Level-3 eingeteilt. Die sogenannten Level-1-Landmarken beschreiben die direkt von der Sensorik detektierten und klassifizierten Objekte ohne weitere Verarbeitung. Diese Stufe, welche als Messung bezeichnet wird, bildet die Wahrnehmungsgrundlage der LbL, sowohl für die Kartierung als auch die Lokalisierung. In Abbildung 4.1 sind die Level-1-Landmarken der Sensordatenverarbeitung als grüne Pfeile des jeweiligen Sensors (Kombination aus Sensorik und Detektionsalgorithmus) dargestellt. Bei Level-2 handelt es sich um getrackte und fusionierte Landmarken (sogenannte Tracks) mit dem im TFM realisierten Verfahren. Alle Tracks zu einem Zeitpunkt entsprechen dem konsistenten Landmarkenumfeldmodell und sind sensorunabhängig. Ab diesem Verarbeitungsschritt werden die Einträge *Belief* und *ID* im Zustandsvektor einer Landmarke verwendet, während der Eintrag *Sensor<sup>ID</sup>* obsolet wird. Ein Rückschluss auf einen speziellen Sensor ist durch die Fusion nicht mehr möglich. Die Level-2-Ausgabe ist in Abbildung 4.1, als Ausgang der zweiten Schicht des TFM, als orangefarbener Pfeil visualisiert. Die letzte Verarbeitungsstufe bilden Level-3-Landmarken. Das sind die Level-2-Landmarken, die durch Tracking und Fusion einen solch hohen Konfidenzwert (*Belief*) erreicht haben, dass sie in der Landmarkenkarte (zum einen in der dezentrale Karte und zum anderen in der dritten Schicht des TFM) abgelegt werden. Die Level-2-Landmarken werden um ihre globalen Positionen im  $\xi^{\text{wgs}}$ -System erweitert. Mit einer gestrichelten blauen Linie sind die Level-3-Landmarken aus der dezentralen Karte in Abbildung 4.1 dargestellt.

Formal lassen sich die einzelnen Level entsprechend der Gleichung (4.3) ausdrücken. Die Menge aller Level-1-Landmarken wird mit  $\mathcal{B}$  bezeichnet. Eine einzelne Landmarke in der Menge wird entsprechend ihres Typs (vgl. Tabelle 4.1) mit  $b^{\text{sPO}}$ ,  $b^{\text{sDL}}$  oder  $b^{\text{sPL}}$  deklariert. Die Menge der Tracks (getrackte und fusionierte Level-1-Landmarken) wird mit  $\mathcal{T}$  gekennzeichnet. Analog zu den Level-1-Landmarken wird eine einzelne Landmarke in der Menge  $\mathcal{T}$  mit  $t^{\text{sPO}}$ ,  $t^{\text{sDL}}$  und  $t^{\text{sPL}}$  beschrieben. Die Menge der Landmarken in der Karte (Level-3-Landmarken) wird mit  $\mathcal{M}$  und die einzelnen Landmarken mit  $m^{\text{sPO}}$ ,  $m^{\text{sDL}}$  und  $m^{\text{sPL}}$  definiert. Die Indizes an den einzelnen Landmarken der jeweiligen Menge deuten den Zugriff auf eine spezielle Landmarke an. Die Summe aller Indizes einer Menge (Großbuchstabe des Indizes) gibt die Mächtigkeit (Anzahl aller Landmarken) der Menge an. Die hier eingeführte Nomenklatur soll im Weiteren verwendet werden.



$$\begin{aligned}
 \text{Level-1} &:= \mathcal{B} = \{b_h^{s^{PO}}, b_i^{s^{DL}}, b_k^{s^{PL}}\}_{h=1, i=1, k=1}^{H, I, K} \\
 \text{Level-2} &:= \mathcal{T} = \{t_r^{s^{PO}}, t_o^{s^{DL}}, t_l^{s^{PL}}\}_{r=1, o=1, l=1}^{R, O, L} \\
 \text{Level-3} &:= \mathcal{M} = \{m_f^{s^{PO}}, m_j^{s^{DL}}, m_g^{s^{PL}}\}_{f=1, j=1, g=1}^{F, J, G}
 \end{aligned} \tag{4.3}$$

Exemplarisch sind die verschiedenen Landmarken, in den jeweiligen Verarbeitungsstufen der unterschiedlichen Sensoren in Anhang C.1 aufgeführt. Es ist zu sehen, dass in Level-1 viele Fehlererkenntnisse enthalten sind. In Level-2 werden die Landmarken getrackt und beim Anschluss mehrerer Sensoren an das TFM fusioniert. Durch das TFM werden instabile Landmarken herausgefiltert. Für Level-1 und Level-2 sind alle Detektionen über den gesamten Zeit- und Streckenverlauf dargestellt. Im Gegensatz zu Level-2 wird für die Level-3-Repräsentation, also in der Karte  $\mathcal{M}$ , nur ein Vorkommen einer Landmarke gefordert. Aus den sich ergebenden Tracks (Menge aller Level-2-Landmarken) wird genau eine Landmarke, entsprechend der Konfidenzwertentwicklung und Schwellwertbetrachtung, nach Level-3 überführt.

## 4.2 Tracking- & Fusionsmodell

Um eine Pose im PLM (siehe Kapitel 4.3) zu berechnen, muss zum einen die Möglichkeit vorhanden sein, Landmarkenkarten (Level-3-Landmarken,  $\mathcal{M}$ ) zu erstellen, und zum anderen müssen die detektierten Landmarken der Sensorik zu einem konsistenten Landmarkenumfeldmodell (Level-2-Landmarken,  $\mathcal{T}$ ) zusammengeführt werden. Es müssen die asynchronen Eingangsdaten (Level-1-Landmarken,  $\mathcal{B}$ ) sowohl räumlich als auch zeitlich synchronisiert werden. Mögliche Fehldetektion sind zu erkennen und zu entfernen.




Abbildung 4.2: 3-Schichten-Architektur des Tracking- & Fusionsmodells (links) und schematische Darstellung der zugehörigen Landmarkenausgaben (rechts)

Um diese Anforderungen zu erfüllen, wird für das Nachverfolgen und Fusionieren der Landmarken erstmalig die hier vorgestellte modulare, 3-schichtige Architektur vorgeschlagen. Das Verfahren wird im sogenannten Tracking- & Fusionsmodell (TFM) durchgeführt, wobei die einzelnen Verarbeitungsebenen als Sensor-Management-Layer (SML), Track-Management-Layer (TML) und Map-Management-Layer (MML) bezeichnet werden. Jede Schicht des Filters korrespondiert mit der eingeführten Level-Definition der Landmarken. Abbildung 4.2 stellt im linken Teil die einzelnen Schichten mit deren Verarbeitungsschritten dar. Im rechten Teil werden die korrespondierenden Güteklassen der Landmarkenausgaben schematisch abgebildet. Der Bewegungspuffer innerhalb des TFM ist für alle drei Schichten zugänglich. Die in das Verfahren eingehenden globalen Poseschätzungen und Eigenbewegungsschätzungen werden dort vorgehalten. Jede Schicht kann zu beliebigen Zeitpunkten die gespeicherten Poseschätzungen und Eigenbewegungsschätzungen anfragen.




Abbildung 4.3: Datenverarbeitungsprozess des TFM, unterteilt nach den unterschiedlichen Eingangsdaten

Der Ablauf des TFM ist in Abbildung 4.3 schematisch aufgezeigt. Entsprechend der Erläuterung in Kapitel 4.1 nimmt das TFM Sensordaten (im Sinne der definierten Landmarken),

eine globale Poseschätzung und die Eigenbewegungsschätzung als Eingangsdaten entgegen. Je nach Dateneingang erfolgt die Bearbeitung in dem dargestellten Ablauf.

Der Verarbeitungsschritt „Sende Daten“ im rechten Teil der Abbildung entspricht dem orangefarbenen Pfeil aus der zweiten TFM-Schicht zum PLM in Abbildung 4.1. Es werden das konsistente Landmarkenumfeldmodell aus der zweiten Schicht mit der zugehörigen Eigenbewegungsschätzung und globalen Poseschätzung zeitlich synchronisiert ausgegeben. In Anhang C.4.1 sind Eingangs- und Ausgangsdaten des Verfahrens dargestellt.

Das in diesem Kapitel vorgestellte Verfahren des TFM detailliert die von Stess et al. [240] beschriebene Methode. Im Nachfolgenden sind die genannten Schichten SML, TML und MML sowie deren Verarbeitungsschritte erläutert.

### 4.2.1 Sensor-Management-Layer (SML)

Der SML ist für die ersten Verarbeitungsschritte auf Sensorbasis verantwortlich. Im SML, genauer gesagt im Teilbereich des Sensor-Data-Management (SDM), wird automatisiert für jeden angeschlossenen Sensor aus einer Konfigurationsdatei ein Sensor-Data-Object (SDO) erzeugt (dt. Sensordatenobjekt, siehe erste Schicht des TFM in Abbildung 4.2). Jedes SDO enthält alle spezifischen Informationen zur Parametrisierung von Tracking und Fusion der Landmarken des jeweiligen Sensors. Das ermöglicht es, dass das Verfahren des TFM auf beliebig viele Sensoren angewendet werden kann, sobald die Sensorik in der Konfigurationsdatei hinterlegt ist. Der Aufbau der Konfigurationsdatei ist in Anhang C.4.2 beschrieben.


Jeder Sensor liefert entsprechend seiner Ausgabefrequenz eine Menge von Level-1-Landmarken. Die Landmarken sind im Koordinatensystem des detektierenden Sensors  $i$  gegeben und müssen zur Verarbeitung in der zweiten Schicht vom Sensorkoordinatensystem  $\xi^{\text{srf}_i}$  in das Fahrzeugkoordinatensystem  $\xi^{\text{vrf}}$  transformiert werden. Diese Transformation wird durch jedes erzeugte SDO des zugehörigen Sensors durchgeführt. Der Vorgang wird als räumliche Synchronisierung bezeichnet. Durch die Konfigurationsdatei ist dem SDO der Versatz (Translation und Rotation) zwischen  $\xi^{\text{vrf}}$  und dem entsprechenden  $\xi^{\text{srf}_i}$  bekannt. Die Koordinatentransformation wird entsprechend der Beschreibung in Kapitel 3.2.5 durchgeführt.

Das statische Filtern der Eingangslandmarken bildet den letzten Verarbeitungsschritt im SML. Ziel ist die direkte Löschung von Level-1-Landmarken, die aufgrund festgelegter statischer Schwellwerte als Fehldetektion angesehen werden können. Hierbei wird für punktbasierte Landmarken ( $s^{\text{PO}}$ ) nach minimalem und maximalem Radius geprüft, linienbasierte Landmarken ( $s^{\text{DL}}$ ) werden anhand der minimalen und maximalen erlaubten Länge sowie Breite gefiltert und die polylinienbasierten Landmarken ( $s^{\text{PL}}$ ) werden nach einer minimalen Länge sowie minimalen und maximalen Breite aussortiert. Zusätzlich erfolgt eine Simplifizierung der polylinienbasierten Landmarken mit dem Ramer–Douglas–Peucker-Algorithmus [241].

Das Ergebnis ist eine Level-1-Landmarkenmenge  $\mathcal{B}$ , in der unzulässige Landmarken (zu kurz, zu lang, zu breit) entfernt, die Landmarken ins  $\xi^{\text{vrf}}$ -System transformiert und polylinienbasierte Landmarken vereinfacht wurden. Diese Landmarkenmenge  $\mathcal{B}$  wird von jedem SDO an die zweite Schicht des TFM weitergereicht.

## 4.2.2 Track-Management-Layer (TML)

Der TML hat die Hauptaufgabe, ein konsistentes Landmarkenumfeldmodell zu generieren und es dem nachgelagerten PLM zur Verfügung zu stellen. Um das zu erreichen, müssen die Level-1-Landmarken der unterschiedlichen Sensorik der ersten Schicht zusammengeführt (Fusion), nachverfolgt (Tracking) und nachgeführt werden. Zuständig sind innerhalb der Schicht die Verarbeitungsschritte Track-Management, Gating und Korrespondenzbestimmung sowie die Track-Innovation. Das Gerüst für alle nötigen Verarbeitungsschritte bildet das Konzept der zeitlichen Synchronisierung, das in Abbildung 4.4 veranschaulicht ist.



- $u_\tau$  : Bewegungszustand zum Zeitpunkt  $\tau$
- $\mathcal{B}_\tau^n$  : Menge der Landmarken vom  $n$ -ten SDO zum Zeitpunkt  $\tau$
- $\mathcal{T}_\tau$  : Menge der verwalteten getrackten und fusionierten Landmarken zum Zeitpunkt  $\tau$

Abbildung 4.4: Ablauf der zeitlichen Synchronisierung, basierend auf [240]

Die horizontalen Linien stellen die unterschiedlichen Sensoreingänge sowie die Menge der fusionierten und nachverfolgten Tracks dar. Die vertikalen, schwarz gestrichelten Linien  $u_\tau$  entsprechen den Bewegungsdaten aus der Eigenbewegungsschätzung des Fahrzeugs zum Zeitpunkt  $\tau$ . Die grauen gestrichelten Linien  $\mathcal{B}_\tau^n$  stellen die bereitgestellte Landmarkenmenge vom  $n$ -ten SDO zum Zeitpunkt  $\tau$  dar. Anlog sind die aktuell verwalteten Tracks zum Zeitpunkt  $\tau$  mit  $\mathcal{T}_\tau$  angegeben.

Seien also  $\tau - 1$  und  $\tau$  für  $\tau \in \mathbb{N}$  zwei aufeinanderfolgende Zeitschritte, so wird ein Bewegungsschritt laut Gleichung (4.4) formuliert.

$$\forall u_\tau, \mathcal{B}_\tau^n, \mathcal{T}_\tau \mid \tau \in \{\tau - 1, \tau\}, \text{ mit } 1 < \tau \in \mathbb{N} \quad (4.4)$$

Dabei gilt für  $\mathcal{B}_\tau^n$  und  $\mathcal{T}_\tau$  die Formulierung aus Gleichung (4.5).

$$\begin{aligned} \mathcal{B}_\tau^n &:= \{ b_{\tau,1}^n, b_{\tau,2}^n, \dots, b_{\tau,h}^n \}_{h=1,n=1}^{H,N} \quad \text{mit } b_{\tau,h}^n \in \{s^{\text{PO}}, s^{\text{DL}}, s^{\text{PL}}\} \\ \mathcal{T}_\tau &:= \{ t_{\tau,1}, t_{\tau,2}, \dots, t_{\tau,l} \}_{l=1}^L \quad \text{mit } t_{\tau,l} \in \{s^{\text{PO}}, s^{\text{DL}}, s^{\text{PL}}\} \end{aligned} \quad (4.5)$$

Mit  $b_{\tau,h}^n$  wird für  $h = 1, \dots, H$ , wobei  $H$  die Anzahl der Landmarken in  $\mathcal{B}_\tau^n$  wiedergibt, eine Landmarke vom Typ  $s^{\text{PO}}$ ,  $s^{\text{DL}}$  oder  $s^{\text{PL}}$  nach der Verarbeitung im SML zum Zeitpunkt  $\tau$  repräsentiert. Eine konkrete Landmarke aus  $\mathcal{T}_\tau$  wird mit  $t_{\tau,l}$  für  $l = 1, \dots, L$  und dem Typ  $s^{\text{PO}}$ ,  $s^{\text{DL}}$  oder  $s^{\text{PL}}$  angegeben. Mit  $L$  wird die Anzahl der aktuell verwalteten Landmarken angegeben. Die Zustandsbeschreibung der einzelnen Landmarkentypen  $s^{\text{PO}}$ ,  $s^{\text{DL}}$  und  $s^{\text{PL}}$  ist entsprechend Kapitel 4.1.1 definiert.

Zwischen zwei Zeitpunkten  $\tau - 1$  und  $\tau$  können durch die asynchrone Sensorik beliebig viele bis keine Landmarkenupdates  $\mathcal{B}_\tau$  erfolgen. Sobald ein aktueller Bewegungsdateneingang  $u_\tau$  erfolgt, wird die Bewegung auf die einzelnen  $\mathcal{B}_{\tau-1}$  und die verwalteten Tracks in  $\mathcal{T}_{\tau-1}$  angewendet. In Abbildung 4.4 wird das durch horizontale, gestrichelte Linien zwischen den erfolgten Bewegungen  $u_{\tau-1}$  und  $u_\tau$  veranschaulicht. Es müssen die wahrgenommenen Landmarken  $\mathcal{B}_{\tau-1}^n$  und verwalteten Tracks  $\mathcal{T}_{\tau-1}$  auf den aktuellen Bewegungszustand  $u_\tau$  transformiert werden. Das bedeutet, dass die Landmarken vom  $\xi_{\tau-1}^{\text{vrf}}$ - im  $\xi_\tau^{\text{vrf}}$ -System ausgedrückt werden müssen. Das Vorgehen wird als *Bewegungsschritt* bezeichnet und mit den in Kapitel 3.2.4 definierten Koordinatensystemen sowie deren beschriebenen Transformationen aus Kapitel 3.2.5 durchgeführt.

Nach dem Bewegungsschritt liegen alle Landmarken aus den Sensoreingängen  $\mathcal{B}_{\tau-1}^1$  bis  $\mathcal{B}_{\tau-1}^n$  und den Tracks  $\mathcal{T}_{\tau-1}$  im aktuell gültigen Koordinatensystem  $\xi_\tau^{\text{vrf}}$  zum Zeitpunkt  $\tau$  des Bewegungszustandes  $u_\tau$  vor (vgl. Abbildung 4.4). Anschließend erfolgen die weiteren Verarbeitungsschritte.

Zuerst werden die zugehörigen Korrespondenzen zwischen den einzelnen Landmarken aus  $\mathcal{B}_{\tau-1}^1$  bis  $\mathcal{B}_{\tau-1}^n$  und  $\mathcal{T}_\tau$  identifiziert. Um die Korrespondenzen zu berechnen, werden die in Kapitel 4.2.4 erstmals eingeführten Distanzfunktionen für die in Kapitel 4.1.1 beschriebenen Zustandsvektoren  $s^{\text{PO}}$ ,  $s^{\text{DL}}$  und  $s^{\text{PL}}$  der unterschiedlichen Landmarkentypen verwendet. Werden die Landmarken der Tracks  $\mathcal{T}_\tau$  und Messungen  $\mathcal{B}_\tau$  entsprechend den Landmarkentypen unterteilt, so lassen sich die Distanzfunktionen mit  $d^{\text{PO}}(\mathcal{B}_\tau^{\text{PO}}, \mathcal{T}_\tau^{\text{PO}})$  für punktbasierte Landmarken, mit  $d^{\text{DL}}(\mathcal{B}_\tau^{\text{DL}}, \mathcal{T}_\tau^{\text{DL}})$  für linienbasierte Landmarken und abschließend mit  $d^{\text{PL}}(\mathcal{B}_\tau^{\text{PL}}, \mathcal{T}_\tau^{\text{PL}})$  für polylinienbasierte Landmarken ausdrücken. In  $\mathcal{B}_\tau^{\text{PO}}$ ,  $\mathcal{B}_\tau^{\text{DL}}$ ,  $\mathcal{B}_\tau^{\text{PL}}$  und  $\mathcal{T}_\tau^{\text{PO}}$ ,  $\mathcal{T}_\tau^{\text{DL}}$ ,  $\mathcal{T}_\tau^{\text{PL}}$  sind genau die zugehörigen Landmarkentypen  $s^{\text{PO}}$ ,  $s^{\text{DL}}$  und  $s^{\text{PL}}$  enthalten. Mit der Aufteilung und den genannten Distanzfunktionen sind dann die Korrespondenzbestimmungen der Landmarken aus  $\mathcal{T}$  und  $\mathcal{B}$  zueinander berechenbar. Die konkreten Berechnungen für die einzelnen Distanzfunktionen sind in Kapitel 4.2.4 aufgeführt.

Bei einer positiven Korrespondenzbestimmung, also der Assoziierung einer vorhandenen Landmarke der Messung  $\mathcal{B}_\tau$  zu einer Track-Landmarke aus  $\mathcal{T}_\tau$ , wird der Verarbeitungsschritt

der Track-Innovation durchgeführt. In Kapitel 4.2.6 ist der Vorgang erläutert. Es werden erstmalig unterschiedliche Aktualisierungsmethoden für die beschriebenen Landmarkentypen vorgeschlagen.

Für den Verarbeitungsschritt Track-Management, in dem die Verwaltung der Track-Landmarken  $\mathcal{T}_\tau$  erfolgt, wird der Sequential Probability Ratio Test (SPRT) verwendet. Eine vollständige Beschreibung des Track-Management-Prinzips ist in Kapitel 4.2.5 gegeben. Es wird die Anwendung von SPRT auf Landmarkenebene formuliert und in dieser Arbeit eingeführt. Das vorgestellte SPRT-Track-Management-Verfahren entscheidet, welche Track-Landmarke bestätigt, gelöscht oder zu der keine weitere Aussage getätigt werden kann. Zusätzlich übernimmt dieser Verarbeitungsschritt die Berechnung eines Konfidenzwertes für jede Landmarke  $t_i$  aus  $\mathcal{T}_\tau$ . Der Konfidenzwert beschreibt die Glaubwürdigkeit einer Landmarke im Sinne einer Wahrscheinlichkeit und gibt an, ob es sich bei der erkannten Landmarke um eine echte handelt.

Nach der Durchführung der Schritte Track-Management und Track-Innovation, innerhalb des Gerüsts der zeitlichen Synchronisierung, liegt zum Zeitpunkt  $\tau$  eine aktualisierte Menge von Track-Landmarken  $\tilde{\mathcal{T}}_\tau$  vor. Die Ausgabe des TFM zum Zeitpunkt  $\tau$  enthält sowohl genau die aktualisierten Track-Landmarken  $\tilde{\mathcal{T}}_\tau$  (Level-2-Landmarken) als auch die zugehörige globale Pose- und Eigenbewegungsschätzung.

Die Ausgabedaten werden im nachgelagerten, neu vorgestellten Partikelfilterbasierten Lokalisierungsmodell (PLM) zur Berechnung einer präzisen globalen Pose herangezogen. Die Berechnung erfolgt durch einen Abgleich der erhaltenen Landmarkenkarte aus der dezentralen Karte. Das Verfahren wird in Kapitel 4.3 im Detail erläutert.

### 4.2.3 Map-Management-Layer (MML)

Entsprechend der Beschreibung in Kapitel 4.1 basiert die LbL auf zwei Phasen, der Kartenerstellung und der Lokalisierung. In beiden Phasen erfolgt die Kartengenerierung in der dritten Schicht des TFM, dem sogenannten MML. Während die zweite Schicht des TFM die Ausgabe der getrackten und fusionierten Track-Landmarken für die nachgelagerte Lokalisierung bereitstellt, baut der MML aus den Landmarken in  $\mathcal{T}$  eine konsistente Karte. In der Phase der Kartierung wird die Karte mit der globalen Poseschätzung und Eigenbewegungsschätzung aus der Ortungsreferenz (vgl. Kapitel 3.1.1) erzeugt und in der dezentralen Karte abgelegt. Während der Lokalisierung sind die Eingangsdaten des TFM die seriennahe globale Poseschätzung und Eigenbewegungsschätzung (siehe Kapitel 3.1.2 und 3.1.3). Die beobachteten Landmarken werden in beiden Phasen von derselben Sensorik zur Verfügung gestellt (vgl. Kapitel 3.1.4).

Es werden nur die durch das Track-Management bestätigten Track-Landmarken aus dem TML an den MML weitergegeben. Der MML hält diese Landmarken in einem internen Puffer solange vor, bis eine weitere Aktualisierung der Landmarke durch das TML erfolgt oder die Landmarke den Beobachtungshorizont, im weiteren Tracking-Horizont genannt, verlassen hat.

Steigt der Konfidenzwert einer bestätigten Landmarke im TML, so wurde diese Landmarke erneut wahrgenommen und eine Zuordnung zu einer zuvor erkannten Landmarke ist erfolgt. Besonders stabile Landmarken erreichen nach wenigen Zyklen der zeitlichen Synchronisierung einen hohen Konfidenzwert. Sie werden innerhalb des TML im Verarbeitungsschritt des Track-Managements (vgl. Kapitel 4.2.5) bestätigt und an den MML weitergereicht. Aufgrund der Sen-

sorgenaugkeiten (vgl. Kapitel 3.1.4) ist es sinnvoll, die Landmarken nicht direkt zum Zeitpunkt der Bestätigung in die Karte einzutragen, sondern zum Höchststand ihres Konfidenzwertes.

Das hat zur Folge, dass einmal bestätigte Landmarken des Track-Managements immer durch den MML Einzug in die erzeugte Karte erhalten. Selbst wenn der Konfidenzwert einer Landmarke nach einer Bestätigung im weiteren Verlauf des Trackings fällt, wird diese Landmarke mit dem zum Zeitpunkt der Bestätigung (Höchststand des Konfidenzwertes) übergebenen Werten (Unsicherheiten, Konfidenzwert, Position, Zeitpunkt) in die Karte übernommen. Das beschriebene Verhalten des MML wird in Abbildung 4.5 veranschaulicht, wobei der Konfidenzwert einer Landmarke  $i$  zum Zeitpunkt  $\tau$  mit  $LLR^i(\tau)$  bezeichnet wird.

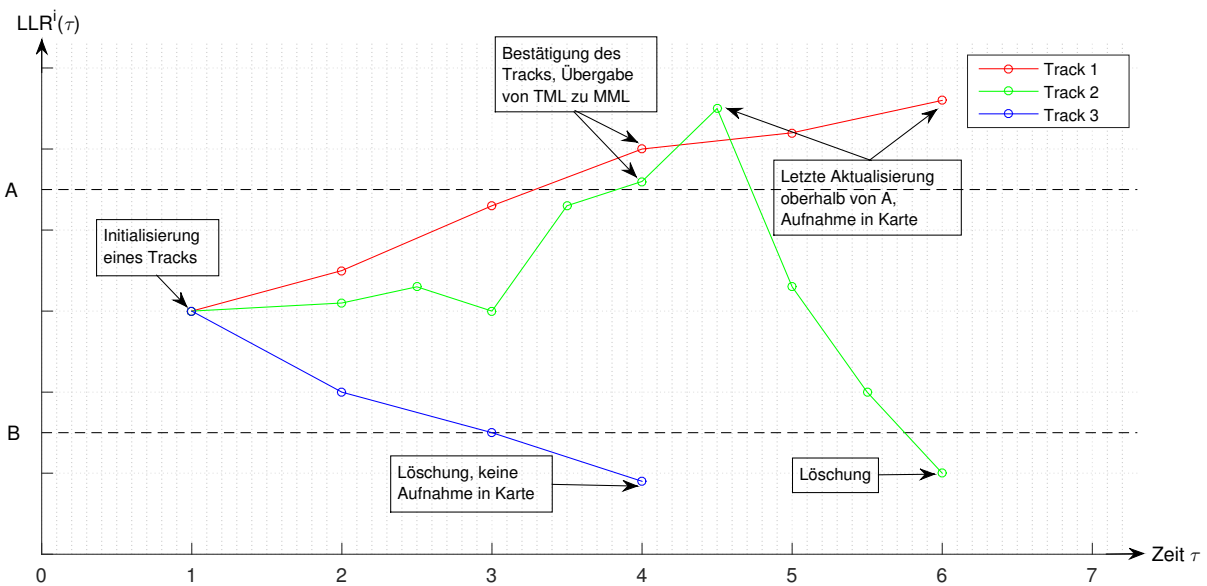


Abbildung 4.5: Ablauf der Kartengenerierung im MML in Abhängigkeit des Zeitverlaufs der Konfidenzwertentwicklung einer Landmarke. Track 1 (rot), Track 2 (grün) und Track 3 (blau) entsprechend drei unterschiedlichen Landmarken, die zum selben Zeitpunkt ( $\tau = 1$ ) wahrgenommen wurden. A verdeutlicht den Schwellwert einer Track-Bestätigung des TML und B den Schwellwert einer Track-Löschung.

Um generierte Landmarkenkarten unterschiedlicher Fahrzeuge oder unterschiedlicher Strecken in einem gemeinsamen Koordinatensystem zusammenzuführen, werden die Landmarken mit ihren zugehörigen WGS84-Koordinaten aus der globalen Poseschätzung abgelegt.

Innerhalb des MML wird ein Octree [159] zur Speicherung verwendet, wodurch eine komprimierte Karte entsteht, auf die bei Bedarf schnell zugegriffen werden kann. Die einzelnen Landmarken werden als Elemente der Geography Markup Language (GML) Version 2.0 [242] abgelegt.

Abschließend wird in Abbildung 4.6 ein Ausschnitt der hinterlegten Landmarken in einer Karte visualisiert. Die Landmarken liegen zur besseren Veranschaulichung über einem „OpenStreetMap“-Luftbild [242]. Die grün und blau markierten Elemente entsprechen linienbasierten Landmarken, die schwarz umrandeten, rot gefärbten Kreise stehen für punktbasierte Landmarken und die roten durchgezogenen Linien repräsentieren polylinienbasierte Landmarken.






Abbildung 4.6: Visualisierung der erzeugten Karte des TFM, Luftbild aus [242]

#### 4.2.4 Gating, Distanzfunktionen und Korrespondenzbestimmung

Für das in Kapitel 4.2.2 beschriebene Vorgehen der zweiten Schicht (TML) des TFM zur Erzeugung eines konsistenten Landmarkenumfeldmodells (Level-2-Landmarken) durch zeitliches Nachverfolgen und Fusionieren von detektierten Landmarken der Sensorik (Level-1-Landmarken) ist die Zuordnung der eingehenden Messungen ( $\mathcal{B}_{\tau-1}^1$  bis  $\mathcal{B}_{\tau-1}^n$ ) zu ihren zugehörigen Tracks ( $\mathcal{T}_{\tau}$ ) von entscheidender Rolle (siehe Abbildung 4.4). Dieses Zuordnungsproblem gehört zu den Fragestellungen der Datenassoziiierung, die in Kapitel 2.4 vorgestellt wurden. Für die hier verwendeten Landmarken und deren Repräsentation (siehe Kapitel 4.1.1) eignen sich je Landmarkentyp spezielle geometrische Abstandsfunktionen.

In den folgenden Unterkapiteln erfolgt eine detaillierte Vorstellung der entwickelten Distanzfunktionen für die genannten Landmarkentypen. Darauf aufbauend wird die entsprechende Korrespondenzermittlung von Messungen zu zugehörigen Tracks erläutert. Der Vollständigkeit halber wird zu Beginn das verwendete Gating-Verfahren, zur sinnvollen Vorauswahl von Landmarken, beschrieben.

##### 4.2.4.1 Gating

Durch das sogenannte Gating (dt. für Ausblendung) werden nur Landmarken der Messungen in einem bestimmten Bereich um Track-Landmarken zugelassen. Mit dem Gating wird eine Minimierung der zu berechnenden Distanzen und Korrespondenzbestimmungen erreicht, indem für



jede Messung außerhalb des Gating-Bereiches einer Track-Landmarke in der Korrespondenzmatrix ein maximaler Distanzwert eingetragen wird.

Für alle Landmarkentypen sind zwei Gating-Verfahren, das elliptische Gating und das rechteckige Gating, realisiert [27, 201, 243]. Abbildung 4.7 stellt die beiden beschriebenen Gating-Verfahren dar.

– Elliptisches Gating

Das elliptische Gating basiert auf der Mahalanobis-Distanz [244–246] zwischen zwei Punkten  $p_i, p_j$ , die in Gleichung (4.6) gegeben ist. Hierbei sei  $S^{-1}$  die inverse Kovarianzmatrix des Punktes  $p_i$ .

$$d(p_i, p_j) = \sqrt{(p_i - p_j)^\top \cdot S^{-1} \cdot (p_i - p_j)} \quad (4.6)$$

Falls der berechnete Wert der Mahalanobis-Distanz unter einem bestimmten Grenzwert  $\gamma$  liegt, befindet sich die Messung im Gate. Entsprechend den Beschreibungen in [27, 201, 243], ergibt sich der Grenzwert  $\gamma$  aus der inversen Chi-Quadrat-Verteilung ( $\chi^2$ ), wobei  $\gamma$  auch als  $\chi_{k,\alpha}^2$  bezeichnet wird, mit  $k$  Freiheitsgraden und Signifikanzniveau  $\alpha$ . Da sich die verwendeten Landmarkentypen als Grundrepräsentation auf einen Punkt im X-Y-Raum reduzieren lassen, ergeben sich für  $k$  zwei Freiheitsgrade. Das Signifikanzniveau  $\alpha$  beschreibt die Wahrscheinlichkeit, dass eine Messung des Ziels im Gate liegt, und wird als Probability Gate  $P_G$  bezeichnet. Grundsätzlich wird  $\alpha$  größer als 0.9 gewählt. In Anhang C.4.3 ist beispielhaft die inverse Chi-Quadrat-Verteilung  $\chi^2$  mit unterschiedlichen Freiheitsgraden und Signifikanzniveaus dargestellt.

Die Definition für das Gate ergibt sich als Akzeptanzregion, in der  $100(1 - \alpha)\%$  echte Messungen verworfen werden.

– Rechteckiges Gating

Beim rechteckigen Gating wird um die Track-Landmarken eine sogenannte Bounding Box (dt. Begrenzungsrechteck) mit fester Größe erzeugt. Nur Messungen innerhalb der Bounding Box sind für die aktuelle Track-Landmarke zur Korrespondenzbestimmung zugelassen. Alle anderen Messungen werden mit dem maximalen Distanzwert deklariert. Gleichung (4.7) [247] formuliert die Bedingung für das Gating im X-Y-Raum. Hier sind  $l_x$  und  $l_y$  die Grenzwerte der Bounding Box,  $t_j$  die Track-Landmarke und  $b_i$  die Messung. Weiterhin geben  $t_{j,x}, t_{j,y}$  die  $x$ - bzw.  $y$ -Koordinate des  $j$ -ten Tracks an. Für Messungen seien  $b_{i,x}, b_{i,y}$  ebenso definiert.

$$|t_{j,x} - b_{i,x}| < l_x \wedge |t_{j,y} - b_{i,y}| < l_y \quad (4.7)$$

Mit den Erläuterungen aus [247] wird das Verfahren des rechteckigen Gatings aus Gleichung (4.7) durch Sortierung beschleunigt und entsprechend Gleichung (4.8) formuliert. Die Berechnung der Grenzen  $h_{low,x}^j, h_{up,x}^j, h_{low,y}^j, h_{up,y}^j$  erfolgt nach Gleichung (4.9).

$$h_{low,x}^j < b_{i,x} < h_{up,x}^j \wedge h_{low,y}^j < b_{i,y} < h_{up,y}^j \quad (4.8)$$

$$\begin{aligned}
 h_{low,x}^j &= t_{j,x} - l_x, \\
 h_{up,x}^j &= t_{j,x} + l_x, \\
 h_{low,y}^j &= t_{j,y} - l_y, \\
 h_{up,y}^j &= t_{j,y} + l_y
 \end{aligned}
 \tag{4.9}$$




Abbildung 4.7: Elliptisches (a) und rechteckiges (b) Gating.  $l_1$  bis  $l_7$  visualisieren wahrgenommene Landmarken der Sensorik,  $t_1$  (rot),  $t_2$  (blau) und  $t_3$  (grün) sind vorhandene Track-Landmarken, deren Gating-Bereich entsprechend des Verfahrens eingezeichnet ist

#### 4.2.4.2 Distanzfunktionen für die Korrespondenzbestimmung zwischen Landmarken

In den folgenden Unterabschnitten sind die in Kapitel 4.2.2 genannten Distanzfunktionen  $d^{PO}(\mathcal{B}_\tau^{PO}, \mathcal{T}_\tau^{PO})$  für punktbasierte Landmarken,  $d^{DL}(\mathcal{B}_\tau^{DL}, \mathcal{T}_\tau^{DL})$  für linienbasierte Landmarken und  $d^{PL}(\mathcal{B}_\tau^{PL}, \mathcal{T}_\tau^{PL})$  für polylinienbasierte Landmarken im Detail beschrieben. Sie bilden die Grundlage der Korrespondenzbestimmung von Messungen (Level-1-Landmarken  $\mathcal{B}$ ) zu Tracks (Level-2-Landmarken  $\mathcal{T}$ ).

##### Distanzfunktion für punktbasierte Landmarken

Für punktbasierte Landmarken, wie beispielsweise Pfähle und Pfosten, wird die Mahalanobis-Distanz [244–246] (vgl. Gleichung (4.6)) als Abstandsfunktion verwendet. Entsprechend den Ausführungen in [248] sind Mahalanobis-basierte Distanzfunktionen besonders geeignet, um Zuordnungen von Messungen zu Tracks zu bestimmen.

Laut der Erläuterung in Kapitel 4.1.1 ist die Position zum Zeitpunkt  $\tau$  einer punktbasierten Landmarke im Zustandsvektor  $s^{PO}$  als Punkt  $p = (x, y, z)$  im  $\xi^{vrf}$  repräsentiert. Im linken Teil der Abbildung 4.8 ist exemplarisch jeweils eine punktbasierte Level-1- ( $b_h^{s^{PO}}$ ) und Level-2-Landmarke ( $t_r^{s^{PO}}$ ) dargestellt. Die zugehörige Position ist als Vektor im  $\xi^{vrf}$  mit  $\vec{p}_h$  und  $\vec{p}_r$  gekennzeichnet.

Für die Distanzbestimmung zwischen den zwei Landmarken wird zuerst  $\vec{z}_{p_r, p_h}$  berechnet. Abbildung 4.8 veranschaulicht die Berechnung schematisch im rechten Teil.




Abbildung 4.8: Abstandsberechnung zwischen 2 punktbasierten Landmarken

Anschließend wird die Mahalanobis-Distanz verwendet. Es folgt die Distanzfunktion  $d^{PO}$  für zwei punktbasierte Landmarken entsprechend Gleichung (4.10). Die inverse Kovarianzmatrix  $S^{-1}$  stammt aus der zugehörigen Track-Landmarke  $t_r^{sPO}$ .

$$d^{PO}(b_h^{sPO}, t_r^{sPO}) = \sqrt{(\vec{z}_{p_r, p_h})^\top \cdot S^{-1} \cdot \vec{z}_{p_r, p_h}} \quad (4.10)$$

### Distanzfunktion für linienbasierte Landmarken

Grundlage des Abstandes zweier linienbasierter Landmarken aus den Messungen  $b_i^{sDL} \in \mathcal{B}$  und den Tracks  $t_o^{sDL} \in \mathcal{T}$  ist ebenso die Mahalanobis-Distanz. Der Beschreibung aus Kapitel 4.1.1 folgend, werden linienbasierte Landmarken (z.B. gestrichelte Fahrbahnmarkierungen, Pfeile und Stopplinien) mit jeweils zwei Punkten ( $p_1, p_2$ ) im aktuell gültigen  $\xi^{vrf}$  modelliert. Es wird  $\vec{s}_i$  als Startpunkt und  $\vec{e}_i$  als Endpunkt der eingegangenen Messung, also der beobachteten Level-1-Landmarke  $b_i^{sDL}$ , festgelegt. Für die Track-Landmarke  $t_o^{sDL}$  gilt entsprechend  $\vec{s}_o$  als Startpunkt und  $\vec{e}_o$  als Endpunkt. Im linken Teil der Abbildung 4.9 ist die beschriebene Definition veranschaulicht.




Abbildung 4.9: Abstandsberechnung zwischen 2 linienbasierten Landmarken

Zur Entscheidung einer Korrespondenz, also der Zuordnung einer linienbasierten Level-1-Landmarke  $b_i^{s^{DL}}$  zu einer linienbasierten Level-2-Landmarke  $t_o^{s^{DL}}$ , wird die Distance of Quadratic Vertex Sum (DQVS) (dt. Distanz der quadratischen Vertex-Summe) eingeführt. Die DQVS ist als quadratisches Mittel der vier Mahalanobis-Distanzen  $\kappa_{s_o, s_i}$ ,  $\kappa_{e_o, e_i}$ ,  $\kappa_{s_o, e_i}$  und  $\kappa_{e_o, s_i}$  definiert. Gleichung (4.11) gibt die Berechnung der vier Distanzen formal wieder, während im rechten Teil von Abbildung 4.9 die Definition schematisch dargestellt ist. Die inverse Kovarianzmatrix  $S^{-1}$  gehört zur Level-2-Landmarke  $t_o^{s^{DL}}$ .

$$\begin{aligned}\kappa_{s_o, s_i} &= \sqrt{(\vec{s}_o - \vec{s}_i)^\top \cdot S^{-1} \cdot (\vec{s}_o - \vec{s}_i)}, \\ \kappa_{e_o, e_i} &= \sqrt{(\vec{e}_o - \vec{e}_i)^\top \cdot S^{-1} \cdot (\vec{e}_o - \vec{e}_i)}, \\ \kappa_{s_o, e_i} &= \sqrt{(\vec{s}_o - \vec{e}_i)^\top \cdot S^{-1} \cdot (\vec{s}_o - \vec{e}_i)}, \\ \kappa_{e_o, s_i} &= \sqrt{(\vec{e}_o - \vec{s}_i)^\top \cdot S^{-1} \cdot (\vec{e}_o - \vec{s}_i)}\end{aligned}\quad (4.11)$$

Aufbauend auf den vier Mahalanobis-Distanzen ergeben sich die beiden DQVS-Abstände  $DQVS_{ss,ee}$  und  $DQVS_{se,es}$ , als Abstandsmaß für die vier Kreuzverbindungen der Start- und Endpunkte, aus der gezeigten Berechnung in Gleichung (4.12).

$$\begin{aligned}DQVS_{ss,ee} &= \sqrt{\frac{(\kappa_{s_o, s_i})^2 + (\kappa_{e_o, e_i})^2}{2}} \\ DQVS_{se,es} &= \sqrt{\frac{(\kappa_{s_o, e_i})^2 + (\kappa_{e_o, s_i})^2}{2}}\end{aligned}\quad (4.12)$$

Die Formulierung der Abstandsfunktion  $d^{DL}$  für linienbasierte Landmarken ist abschließend in Gleichung (4.13) gegeben.

$$d^{DL}(b_i^{s^{DL}}, t_o^{s^{DL}}) = \min(DQVS_{ss,ee}, DQVS_{se,es}) \quad (4.13)$$

## Distanzfunktion für polylinienbasierte Landmarken

Durchgezogene Straßenmarkierungen werden als Polylinien, also Linienzüge, repräsentiert. Um eine Zuweisung zwischen einer polylinienbasierten Landmarke aus den wahrgenommenen Messungen  $b_k^{s^{PL}}$  zu einer polylinienbasierten Landmarke aus den Tracks  $t_l^{s^{PL}}$  ermitteln zu können, muss auch für diesen Landmarkentyp ein Abstandsmaß festgelegt werden.

Als Maß wird die Fläche zwischen den Landmarken herangezogen. Die Position bzw. der Verlauf polylinienbasierter Landmarken ist entsprechend Kapitel 4.1.1 als zusammenhängende Punktliste  $(p_1, p_2, \dots, p_n)$  modelliert (im  $\xi^{vrf}$ ). Teil a der Abbildung 4.10 stellt beispielhaft die zwei polylinienbasierten Landmarken  $b_k^{s^{PL}}$  und  $t_l^{s^{PL}}$ , mit ihrer zugehörigen Punktliste  $(p_1, p_2, \dots, p_i)$  bzw.  $(q_1, q_2, \dots, q_j)$ , dar. Mit dieser Repräsentation gelten die in Gleichung (4.14) aufgestellten Bedingungen.

$$\begin{aligned}(p_1, p_2, \dots, p_n) \forall n \in s^{PL} : \|s^{PL}\| &= n, \\ (p_1, p_2, \dots, p_n) \forall n \in s^{PL} : p_{y_1} \leq p_{y_2} \leq \dots \leq p_{y_n} &\rightarrow p_1 \leq p_2 \leq \dots \leq p_n\end{aligned}\quad (4.14)$$

Die erste Zeile der Gleichung (4.14) definiert die Mächtigkeit einer polylinienbasierten Landmarke  $\|s^{\text{PL}}\|$  als Anzahl der zugehörigen Punktmenge  $(p_1, p_2, \dots, p_n)$ . Die zweite Zeile gibt die Sortierung der zugehörigen Punktmenge an. Nach Definition des  $\xi^{\text{vrf}}$  (siehe Kapitel 3.2.4) sind die Landmarke modellierenden Punkte entsprechend ihrer  $y$ -Koordinate sortierbar. Alle zu einer polylinienbasierten Landmarke zugehörigen Punkte  $n$  sind entsprechend im Zustandsvektor  $s^{\text{PL}}$  abgelegt.

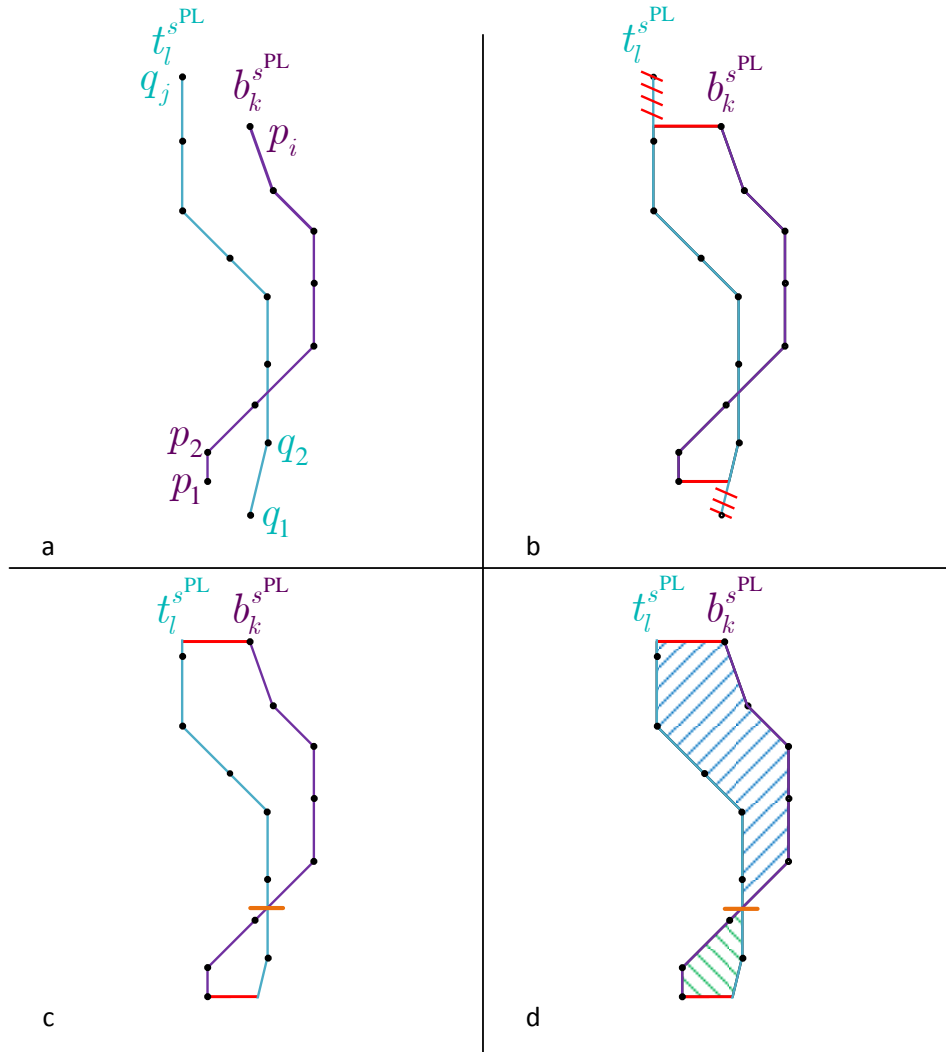


Abbildung 4.10: Abstandsberechnung zwischen zwei polylinienbasierten Landmarken

Zur Ermittlung der Fläche zwischen zwei polylinienbasierten Landmarken  $b_k^{\text{sPL}}$  und  $t_l^{\text{sPL}}$  werden die Landmarken zuerst beschnitten. Es wird im ersten Schritt  $b_k^{\text{sPL}}$  auf  $t_l^{\text{sPL}}$  projiziert und vice versa. Es erfolgt die Berechnung der zugehörigen Lotpunkte. Mit diesen Lotpunkten werden  $b_k^{\text{sPL}}$  und  $t_l^{\text{sPL}}$  so abgeschnitten, dass die gegenseitige Überlappung der beide Linienzüge aufeinander projizierbar ist. Teil b der Abbildung 4.10 zeigt den Schritt des Zuschneidens und Projizierens schematisch auf.

Das Beschneiden der Polylinien erfolgt über Iteration aller direkt benachbarten Punkte der Punktmenge  $(p_1, p_2, \dots, p_i)$  der Landmarke  $b_k^{\text{sPL}}$  und der Punktmenge  $(q_1, q_2, \dots, q_j)$  der Landmarke  $t_l^{\text{sPL}}$ , wobei für jedes Punktepaar der zugehörige Lotpunkt auf der anderen Landmarke gesucht wird. Das Verfahren ist in Anhang C.4.4 erläutert.

Nachdem die Lotpunkte berechnet sind, werden die Polylinien so zugeschnitten, dass sich beide Linien aufeinander abbilden. Teil b und c der Abbildung 4.10 veranschaulicht den Schritt.

Um anschließend den Flächeninhalt zwischen beiden Polylinien zu berechnen, wird die Gauß'sche-Trapezformel verwendet [249]. Für die Gültigkeit der Formel ist zu gewährleisten, dass die Polylinien ein nicht-selbst-kreuzendes Polygon bilden. Es muss geprüft werden, ob die beschnittenen, aufeinander projizierten Polylinien, entsprechend dem Beispiel aus Abbildung 4.10, Schnittpunkte aufweisen. Falls solche Schnittpunkte vorhanden sind, wird das durch die Polylinien aufgespannte Polygon in Subpolygone aufgeteilt. Teil c der Abbildung 4.10 deutet einen solchen Schnittpunkt mit der roten Linie an, während Teil d der Abbildung die Aufteilung am Schnittpunkt in zwei Subpolygone darstellt.

Zur Auffindung besagter Schnittpunkte im Polygon werden jeweils zwei direkte Nachbarpunkte  $(p_{h-1}, p_h)$  zu einem Segment zusammengefasst. Für alle anderen Segmente von Nachbarpunkten des Polygons wird geprüft, ob ein Schnittpunkt mit dem aktuellen Segment  $(p_{h-1}, p_h)$  vorliegt. Beim Auffinden eines Schnittpunktes wird das Polygon an dieser Stelle in zwei Subpolygone unterteilt und der Ansatz rekursiv für beide Subpolygone wiederholt. Der Vorgang wird so lange durchgeführt, bis kein neuer Schnittpunkt mehr gefunden wird. Ein selbst-kreuzendes Polygon wird mit diesem Verfahren in mehrere nicht-selbst-kreuzende Subpolygone unterteilt.

Anschließend wird die Gauß'sche-Trapezformel direkt auf jedes Subpolygon angewendet. Die Gesamtfläche des Polygons ergibt sich als Summe aller Subpolygonflächen. Teil d der Abbildung 4.10 zeigt den Berechnungsschritt der Methode auf.

Um sicherzustellen, dass kleine Überschneidungen von zwei Polylinien nicht bevorzugt werden, wird die berechnete Fläche des Polygons durch die Durchschnittslänge der beiden aufeinander projizierbaren Polylinien geteilt. Gleichung (4.15) formuliert die Distanzfunktion  $d^{\text{PL}}$  für zwei polylinienbasierte Landmarken. Im Nenner des Bruchs wird mit der inneren Summe die Gauß'sche-Trapezformel auf alle Punkte  $H$  eines Subpolygons angewendet und mit der äußeren Summe die Gesamtfläche über Summierung aller Subpolygonflächen  $G$  ermittelt. Im Zähler gibt  $|b_k^{s\text{PL}}|$  bzw.  $|t_l^{s\text{PL}}|$  die Länge der abgeschnittenen, aufeinander projizierten Landmarken an.

$$d^{\text{PL}}(b_k^{s\text{PL}}, t_l^{s\text{PL}}) = \frac{\overbrace{\sum_{g=0}^G \left\| \sum_{h=0}^H (y_h + y_{h+1})(x_h - x_{h+1}) \right\|}^{\text{Summe über alle Flächen der Subpolygone}}}{\underbrace{(|b_k^{s\text{PL}}| + |t_l^{s\text{PL}}|) \cdot 0.5}_{\text{Gauß'sche-Trapezformel für die Fläche eines Subpolygons}}} \quad (4.15)$$

Mittelwert der Länge der abgeschnittenen, aufeinander projizierten Landmarken

#### 4.2.4.3 Korrespondenzbestimmung von Messungen zu Tracks

Mit den vorgestellten Definitionen der Abstandsfunktionen für punktbasierte Landmarken  $d^{\text{PO}}$ , für linienbasierte Landmarken  $d^{\text{DL}}$  und für polylinienbasierte Landmarken  $d^{\text{PL}}$  sind Korrespondenzen für alle eingehenden Messungen  $\mathcal{B}$  der Landmarkentypen  $b_h^{s\text{PO}}$ ,  $b_i^{s\text{DL}}$  und  $b_k^{s\text{PL}}$  zu den Track-Landmarken  $\mathcal{T}$  mit den Landmarkentypen  $t_r^{s\text{PO}}$ ,  $t_o^{s\text{DL}}$  und  $t_l^{s\text{PL}}$  berechenbar.

Die jeweilig ermittelten Distanzwerte werden in der sogenannten Korrespondenzmatrix  $A$  (auch Assoziierungsmatrix genannt) je Landmarkentyp abgelegt. Der Zusammenhang ist in Gleichung (4.16) formuliert.

$$\begin{aligned} \forall h \ b_h^{s^{\text{PO}}} \in \mathcal{B}^{\text{PO}}, \quad \forall r \ t_r^{s^{\text{PO}}} \in \mathcal{T}^{\text{PO}} & : A_{h,r}^{\text{PO}} = d^{\text{PO}}(b_h^{s^{\text{PO}}}, t_r^{s^{\text{PO}}}), \\ \forall i \ b_i^{s^{\text{DL}}} \in \mathcal{B}^{\text{DL}}, \quad \forall o \ t_o^{s^{\text{DL}}} \in \mathcal{T}^{\text{DL}} & : A_{i,o}^{\text{DL}} = d^{\text{DL}}(b_i^{s^{\text{DL}}}, t_o^{s^{\text{DL}}}), \\ \forall k \ b_k^{s^{\text{PL}}} \in \mathcal{B}^{\text{PL}}, \quad \forall l \ t_l^{s^{\text{PL}}} \in \mathcal{T}^{\text{PL}} & : A_{k,l}^{\text{PL}} = d^{\text{PL}}(b_k^{s^{\text{PL}}}, t_l^{s^{\text{PL}}}) \end{aligned} \quad (4.16)$$

Die zugehörige Track-Landmarke  $t_r^{s^{\text{PO}}}$ ,  $t_o^{s^{\text{DL}}}$  oder  $t_l^{s^{\text{PL}}}$  aus den Tracks  $\mathcal{T}$  für eine gegebene Landmarke  $b_h^{s^{\text{PO}}}$ ,  $b_i^{s^{\text{DL}}}$  oder  $b_k^{s^{\text{PL}}}$  aus den Messungen  $\mathcal{B}$  wird über den geringsten Distanzwert entsprechend in  $A_{h,r}^{\text{PO}}$ ,  $A_{i,o}^{\text{DL}}$  oder  $A_{k,l}^{\text{PL}}$  bestimmt. Aufgrund nicht erlaubter doppelter Zuweisungen wird das „Greedy Nearest Neighbour“-Verfahren, zum Auffinden des geringsten Distanzwertes in der Korrespondenzmatrix, verwendet [27, 182, 201]. Gleichung (4.17) beschreibt den Vorgang formal.

$$d_{\text{opt}}^{\text{PO}}(b_h^{s^{\text{PO}}}, t_r^{s^{\text{PO}}}) = \min_r A_{h,r}^{\text{PO}}; \quad d_{\text{opt}}^{\text{DL}}(b_i^{s^{\text{DL}}}, t_o^{s^{\text{DL}}}) = \min_o A_{i,o}^{\text{DL}}; \quad d_{\text{opt}}^{\text{PL}}(b_k^{s^{\text{PL}}}, t_l^{s^{\text{PL}}}) = \min_l A_{k,l}^{\text{PL}} \quad (4.17)$$

Anschließend können die einzelnen Level-2-Landmarken  $t_r^{s^{\text{PO}}}$ ,  $t_o^{s^{\text{DL}}}$  und  $t_l^{s^{\text{PL}}}$ , der Track-Menge  $\mathcal{T}$ , entsprechend ihren zugehörigen Level-1-Landmarken  $b_h^{s^{\text{PO}}}$ ,  $b_i^{s^{\text{DL}}}$  und  $b_k^{s^{\text{PL}}}$ , aus den Messungen  $\mathcal{B}$ , aktualisiert werden.

### 4.2.5 Track-Management mit SPRT

Der Kern jedes Tracking-Verfahrens bildet das sogenannte Track-Management. Es ist dafür zuständig, die Verwaltung der aktuellen Tracks zu gestalten und beinhaltet die vier Aspekte Initialisierung von Tracks, Löschen von Tracks, Bestätigen von Tracks sowie Berechnung des Konfidenzwertes der einzelnen Landmarken. Das Track-Management ist Hauptbestandteil der vorgestellten zweiten TML-Schicht (vgl. Kapitel 4.2.2) im TFM.

Die Verwaltung der Tracks kann mit einem Hypothesen-Entscheidungstest, beispielsweise dem SPRT [190–192], durchgeführt werden [27]. In dem hier entwickelten Verfahren wird SPRT als Track-Management genutzt und zur Verwendung mit den definierten Landmarkentypen adaptiert. Zum einen wird mit Hilfe von SPRT für jede Landmarke ein entsprechender Konfidenzwert berechnet und zum anderen wird entschieden, wann Landmarken bestätigt oder gelöscht werden. Um SPRT zu nutzen, werden die Nullhypothese  $H_0$  und die Alternativhypothese  $H_1$  entsprechend Gleichung (4.18) definiert.

$$\begin{aligned} H_0 & : \text{Alle Beobachtungen stammen von falschen Detektionen} \\ H_1 & : \text{Alle Beobachtungen stammen von echten Detektionen} \end{aligned} \quad (4.18)$$

Der Likelihood-Quotient LR wird nach Gleichung (4.19) festgelegt. Es sind  $H_0$  und  $H_1$  die definierten Hypothesen, deren zugehörige Wahrscheinlichkeiten als  $P_F$  (Probability False für

$H_0$ ) und  $P_T$  (Probability True für  $H_1$ ) definiert sind. Die Eingangsdaten, die einer der beiden Hypothesen zugeordnet werden müssen, sind mit  $D$  bezeichnet.

$$\text{LR} = \frac{p(D | H_1)}{p(D | H_0)} = \frac{p(D | H_1)}{1 - p(D | H_1)} \triangleq \frac{P_T}{P_F} = \frac{P_T}{1 - P_T} \quad (4.19)$$

Im Folgenden werden zum besseren Verständnis des Verfahrens die einzelnen Landmarken  $t_\tau^{s^{\text{PO}}}, t_\tau^{s^{\text{DL}}}, t_\tau^{s^{\text{PL}}} \in \mathcal{T}_\tau$  zum Zeitpunkt  $\tau$  als Beobachtung  $z_\tau$  bezeichnet. Die Landmarken der Messungen  $\mathcal{B}_\tau$ , für die mit den oben definierten Distanzfunktionen keine Korrespondenzen in  $\mathcal{T}_\tau$  gefunden wurden, seien bereits als neue, potenzielle Tracks in  $\mathcal{T}_\tau$  aufgenommen. Die Menge aller Beobachtungen zum Zeitpunkt  $\tau$  wird mit  $\mathcal{Z}_\tau$  bezeichnet. Es repräsentiert  $z_\tau^i \in \mathcal{Z}_\tau$  die Beobachtung der  $i$ -ten Landmarke  $z$  zum Zeitpunkt  $\tau$ . Mit dieser Definition entspricht  $\mathcal{Z}_\tau$  den Eingangsdaten  $D$  zum Zeitpunkt  $\tau$ .

Wald [190–192] und Blackman [27] folgend, ist es möglich, Gleichung (4.19) in einer sequenziellen Schreibweise als Gleichung (4.20) auszudrücken.

$$\text{LR}^i(\tau) = L_0 \prod_{\tau=1}^{\tau} \frac{p(z_\tau^i | H_1)}{1 - p(z_\tau^i | H_1)}, \text{ mit } L_0 = \frac{p_0(H_1)}{p_0(1 - H_1)} = \frac{p(z_0^i | H_1)}{1 - p(z_0^i | H_1)} = \begin{cases} 1 \\ \frac{\beta_{NT}}{\beta_{FA}} \end{cases} \quad (4.20)$$

Die Initialisierungswahrscheinlichkeit beim ersten Dateneingang wird mit  $L_0$  ausgedrückt. Bei Verwendung dieser Notation wird für jede Beobachtung einer Landmarke  $i$  der Likelihood-Quotient  $\text{LR}^i(\tau)$  zum Zeitpunkt  $\tau$  berechnet. Nach Blackman [27] kann  $L_0$  entweder fest auf 1 gesetzt werden, wodurch beide Hypothesen gleich wahrscheinlich sind. Wird  $L_0$  auf 1 gesetzt, kann mit der ersten Beobachtung keine Entscheidung getroffen werden. Alternativ wird  $L_0$  mit  $\frac{\beta_{NT}}{\beta_{FA}}$  initialisiert, wobei  $\beta_{NT}$  (sogenannte New Target Rate) für die Wahrscheinlichkeit einer Detektion eines neuen Zieles in der aktuell gegebenen Menge der Beobachtungen  $\mathcal{Z}_\tau$  und  $\beta_{FA}$  (sogenannte False Alarm Rate) für die Wahrscheinlichkeit von wiedererkannten falschen Detektionen in der aktuell gegebenen Menge der Beobachtungen  $\mathcal{Z}_\tau$  steht. Mit dem zweiten Ansatz zur Festlegung von  $L_0$  sind die verschiedenen Landmarken der unterschiedlichen Sensorik mit spezifischen, sensorabhängigen Werten initialisierbar.

Es ist üblich, den Log-Likelihood-Quotienten LLR zu verwenden, um numerische Stabilität in der Berechnung des Konfidenzwertes zu erhalten. Mit der Umformung zum Log-Likelihood-Quotienten wird Gleichung (4.20) durch Gleichung (4.21) ausgedrückt.  $\text{LLR}^i(\tau)$  entspricht dem sogenannten Konfidenzwert der jeweiligen Landmarke  $z_\tau^i$  zum Zeitpunkt  $\tau$ .

$$\begin{aligned} \text{LLR}^i(\tau) &= \ln\left(L_0 \prod_{\tau=1}^{\tau} \frac{p(z_\tau^i | H_1)}{1 - p(z_\tau^i | H_1)}\right) \\ &= \ln(L_0) + \ln\left(\sum_{\tau=1}^{\tau} \frac{p(z_\tau^i | H_1)}{1 - p(z_\tau^i | H_1)}\right) \triangleq \text{LLR}_{\tau-1}^i + \ln\left(\frac{p(z_\tau^i | H_1)}{1 - p(z_\tau^i | H_1)}\right) \end{aligned} \quad (4.21)$$

Mit Hilfe von Gleichung (4.19) bis Gleichung (4.21) kann gezeigt werden, dass der Konfidenzwert  $\text{LLR}^i(\tau)$  einer Landmarke  $i$  zum Zeitpunkt  $\tau$  direkt in die Wahrscheinlichkeit der  $H_1$ -Hypothese ( $P_{T,\tau}^i$ ) umwandelbar ist.  $P_{T,\tau}^i$  gibt an, wie wahrscheinlich die Beobachtung der



$i$ -ten Landmarke einer echten Detektion entspricht. Die Umrechnung ist in Gleichung (4.22) gezeigt.

$$\begin{aligned} \text{LR}^i(\tau) &= \frac{P_{T,\tau}^i}{1 - P_{T,\tau}^i} \Rightarrow \text{LLR}^i(\tau) = \ln\left(\frac{P_{T,\tau}^i}{1 - P_{T,\tau}^i}\right) \Rightarrow \\ \exp\left(\text{LLR}^i(\tau)\right) &= \exp\left(\ln\left(\frac{P_{T,\tau}^i}{1 - P_{T,\tau}^i}\right)\right) = \frac{P_{T,\tau}^i}{1 - P_{T,\tau}^i} \Rightarrow P_{T,\tau}^i = \frac{\exp\left(\text{LLR}^i(\tau)\right)}{1 + \exp\left(\text{LLR}^i(\tau)\right)} \end{aligned} \quad (4.22)$$

Mit diesen Definitionen wird SPRT für das Tracking-Verfahren durch Gleichung (4.23) beschrieben.

$$B = \ln\left(\frac{\beta}{1 - \alpha}\right) \leq \ln(L_0) + \ln\left(\sum_{\tau=1}^{\tau} \frac{p(z_\tau^i | H_1)}{1 - p(z_\tau^i | H_1)}\right) \leq \ln\left(\frac{1 - \beta}{\alpha}\right) = A \quad (4.23)$$

Hierbei beschreibt  $B = \ln\left(\frac{\beta}{1 - \alpha}\right)$  das Signifikanzniveau, um  $H_0$  zu bestätigen, während  $A = \ln\left(\frac{1 - \beta}{\alpha}\right)$  das Signifikanzniveau zur Bestätigung von  $H_1$  festlegt. Die Werte für  $\alpha$  und  $\beta$  sind vordefinierte Systemdesignparameter, die entsprechend mit der Wahrscheinlichkeit der Bestätigung eines falschen Tracks ( $\alpha$ ) oder der Wahrscheinlichkeit der Löschung eines echten Tracks ( $\beta$ ) korrespondieren.

Gleichung (4.24) fasst das SPRT-Prinzip zusammen und Abbildung 4.11 stellt beispielhaft die mit SPRT berechnete Konfidenzwertfunktion dar (vgl. Abbildung 4.5 in Kapitel 4.2.3).

$$\begin{cases} \text{LLR}^i(\tau) \geq A & : \text{bestätige Track} \\ B < \text{LLR}^i(\tau) < A & : \text{setze Test fort} \\ \text{LLR}^i(\tau) \leq B & : \text{lösche Track} \end{cases} \quad (4.24)$$

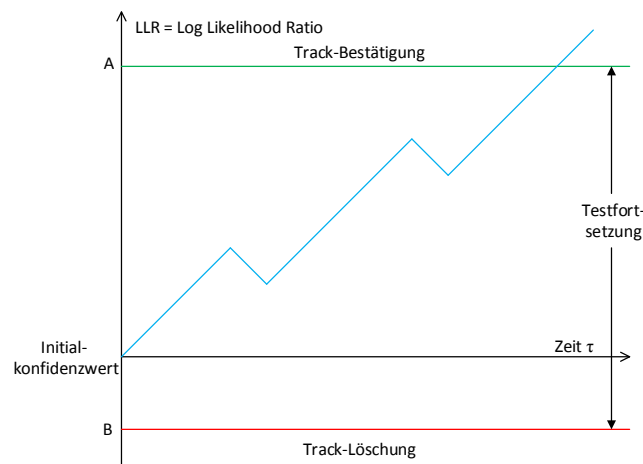


Abbildung 4.11: Verlaufsentwicklung des LLR im SPRT [27]

Die Berechnung des  $\text{LLR}^i(\tau)$  wird für eine positive Korrespondenzbestimmung (Zuweisung einer Messung  $b_h^{s\text{PO}}, b_i^{s\text{DL}}, b_k^{s\text{PL}} \in \mathcal{B}_\tau$  zu einem Track  $t_r^{s\text{PO}}, t_o^{s\text{DL}}, t_l^{s\text{PL}} \in \mathcal{T}_\tau$ ) oder eine negative Korrespondenzbestimmung (keine Zuweisung von Messung zu Track möglich), der Beschrei-

bung in Kapitel 4.2.4 folgend, separat berechnet. Nach [27] und [201] kann der  $\text{LLR}^i(\tau)$  für eine positive Korrespondenzbestimmung mit Gleichung (4.25) und für eine negative Korrespondenzbestimmung mit Gleichung (4.26) ermittelt werden.

$$\text{LLR}^i(\tau) = \text{LLR}_{\tau-1}^i + \ln\left(\frac{\overbrace{P_D \cdot p_{\tau;\tau-1}(z_\tau^i)}^{\text{Innovationsfunktion}}}{\beta_{FA}}\right),$$

wobei  $p_{\tau;\tau-1}(z_\tau^i) = \mathcal{N}(z_\tau^i | \hat{z}_{\tau;\tau-1}^i, \Sigma_{\tau;\tau-1}^i)$

$$= \frac{1}{\sqrt{2\pi^d \|\Sigma_{\tau;\tau-1}^i\|}} \exp\left(\frac{-1}{2} (v_{\tau;\tau-1}^i)^\top (\Sigma_{\tau;\tau-1}^i)^{-1} v_{\tau;\tau-1}^i\right)$$

$$\text{LLR}^i(\tau) = \text{LLR}_{\tau-1}^i + \ln(1 - P_D \cdot P_G) \mid 0 < P_D, P_G < 1 \quad (4.26)$$

Der Term  $p_{\tau;\tau-1}(z_\tau^i)$  in der Innovationsfunktion beschreibt die mit Gleichung (4.25) formulierte positive Korrespondenzbestimmung, den sogenannten Innovations-Likelihood. Innerhalb des Terms  $p_{\tau;\tau-1}(z_\tau^i)$  beschreibt der Ausdruck  $\hat{z}_{\tau;\tau-1}^i$  die vom Zeitpunkt  $\tau - 1$  in den Zeitpunkt  $\tau$  prädierte Landmarke  $z^i$  (Bewegungsschritt vgl. Kapitel 4.2.2 und Kapitel 3.2.5), wohingegen  $z_\tau^i$  die mit der Korrespondenzbestimmung zugewiesene Landmarke wiedergibt.  $\Sigma_{\tau;\tau-1}^i$  steht für die Kovarianzmatrix der prädierten Landmarke  $\hat{z}_{\tau;\tau-1}^i$ . Der Wert der Innovationsfunktion ergibt sich als Normalverteilung  $\mathcal{N}$  über die prädierte Landmarke, deren Kovarianzmatrix und der zugewiesenen Landmarke. Die Berechnung erfolgt entsprechend der letzten Zeile der Gleichung (4.25). Mit  $v_{\tau;\tau-1}^i$  sind die Messresiduen zwischen prädizierter und zugewiesener Landmarke beschrieben. Sie ergeben sich je Landmarkentyp direkt aus den definierten Distanzfunktionen des Kapitels 4.2.4.

Bei einer negativen Korrespondenzbestimmung wird die Aktualisierung des Konfidenzwertes nach Gleichung (4.26) durchgeführt. Hier steht  $P_D$  für die Detektionswahrscheinlichkeit, die sensorspezifisch ermittelt wird. Der Wert  $P_G$  gibt die Wahrscheinlichkeit für das elliptische Gating (vgl. Teilkapitel 4.2.4.1), abhängig vom Landmarkentyp und Sensor, wieder.

Mit diesen Funktionen wird für jede Track-Landmarke  $i$  der zugehörige  $\text{LLR}^i(\tau)$  zum Zeitpunkt  $\tau$  berechnet. Mit dieser Formulierung des SPRT für Landmarken wird entsprechend der Zusammenfassung in Gleichung (4.24) entschieden, wann eine Landmarke bestätigt, gelöscht oder aufgrund der bisherigen Beobachtungen keine Entscheidung abgeleitet werden kann. Es ergibt sich ein automatisches Track-Management, das mit der Formulierung für SPRT die korrekte Entscheidung in kürzester Zeit fällt.

## 4.2.6 Track-Innovation

Nachdem die Korrespondenzbestimmung von Tracks  $\mathcal{T}$  zu Messungen  $\mathcal{B}$  mit den beschriebenen Distanzfunktionen durchgeführt (vgl. Kapitel 4.2.4) und der Konfidenzwert der Track-Landmarken durch das SPRT-Track-Management (vgl. Kapitel 4.2.5) entsprechend aktualisiert wurde, erfolgt der Verarbeitungsschritt der Track-Innovation. Die Track-Innovation ist der letzte Verarbeitungsschritt des TML, um eine aktualisierte Menge von Track-Landmarken  $\tilde{\mathcal{T}}$  zu erhalten. Während der Track-Innovation werden die Positionen und Unsicherheiten der zu aktualisierenden Landmarken berechnet.

Für die Aktualisierung der einzelnen Landmarkentypen PO, DL und PL werden erstmals fünf unterschiedliche Verfahren vorgestellt, die im Weiteren näher beschrieben sind. Es wird, durch die systematischen Fehler der jeweiligen Sensorik (vgl. Kapitel 3.1.4 und Anhang C.1), die Aktualisierung von Position und Unsicherheit der Track-Landmarken separat berechnet.

Laut Definition in Gleichung (4.5) und Gleichung (4.4) (siehe Kapitel 4.2.2) stehen zum Zeitpunkt  $\tau$  die Landmarken der neuen Messung  $\mathcal{B}_\tau^n = \{b_h^{s^{PO}}, b_i^{s^{DL}}, b_k^{s^{PL}}\}_{h=1, i=1, k=1}^{H, I, K}$  des  $n$ -ten Sensors und alle vor der Aktualisierung gültigen, prädierten Track-Landmarken  $\hat{\mathcal{T}}_\tau = \{\hat{t}_r^{s^{PO}}, \hat{t}_o^{s^{DL}}, \hat{t}_l^{s^{PL}}\}_{r=1, o=1, l=1}^{R, O, L}$  zur Verfügung. Aus  $\mathcal{B}_\tau^n$  und  $\hat{\mathcal{T}}_\tau$  wird mit den Distanzfunktionen zur Korrespondenzbestimmung (siehe Kapitel 4.2.4) und dem anschließenden SPRT-basierten Track-Management (vgl. Kapitel 4.2.5) die Menge der aktualisierten Track-Landmarken  $\tilde{\mathcal{T}}_\tau = \{\tilde{t}_r^{s^{PO}}, \tilde{t}_o^{s^{DL}}, \tilde{t}_l^{s^{PL}}\}_{r=1, o=1, l=1}^{\tilde{R}, \tilde{O}, \tilde{L}}$  erzeugt. Die Anzahl  $\tilde{R}, \tilde{O}, \tilde{L}$  der einzelnen Landmarken in  $\tilde{\mathcal{T}}_\tau$  muss nicht zwingend gleich der Anzahl  $\dot{R}, \dot{O}, \dot{L}$  der aktualisierten Track-Landmarken in  $\hat{\mathcal{T}}_\tau$  sein. Das folgt durch die eventuelle Löschung oder Neuinitialisierung von Landmarken im Track-Management.

#### 4.2.6.1 Positionsaktualisierung

Die Aktualisierung der Position erfolgt nur für Track-Landmarken aus  $\hat{\mathcal{T}}_\tau$  mit einer positiven Korrespondenzbestimmung. Track-Landmarken mit einer negativen Korrespondenzbestimmung in  $\hat{\mathcal{T}}_\tau$ , die vom Track-Management nicht gelöscht wurden, wandern mit der prädierten Position aus der zeitlichen Synchronisierung direkt in die Menge der aktualisierten Tracks  $\tilde{\mathcal{T}}_\tau$ . Zum besseren Verständnis des Verfahrens wird im Weiteren mit  $\tilde{t}_k$  die  $k$ -te aktualisierte Landmarke bezeichnet, die sich aus der zugehörigen prädierten Landmarke  $\hat{t}_k$  ergibt. Die aus der Korrespondenzbestimmung ermittelte Landmarke für  $\hat{t}_k$  aus den Messungen  $\mathcal{B}_\tau^n$  sei  $b_l$ . Für die Positionsaktualisierung aller Landmarkentypen sind die folgenden fünf Varianten im TFM realisiert:

- Neueste Position

$$\tilde{t}_k = b_l \quad (4.27)$$

Es wird die Position der neuesten Messung übernommen, wobei davon ausgegangen wird, dass neuere Messungen des Ziels, aufgrund der Annäherung an das Fahrzeug, immer eine genauere Position der Landmarke liefern.

- Exponentielle Glättung

$$\tilde{t}_k = \alpha \cdot b_l + (1 - \alpha) \cdot \hat{t}_k, \text{ wobei } 0 < \alpha < 1 \quad (4.28)$$

Der Wert  $\alpha$  bezeichnet in Gleichung (4.28) den Glättungsfaktor. Dabei gelten für die Wertebereiche des Glättungsfaktors die beschriebenen Intervalle aus Gleichung (4.29).

$$\begin{cases} \alpha < 0.5 & : \text{stärkere Gewichtung der Track-Landmarken in } \hat{\mathcal{T}}_\tau \\ \alpha = 0.5 & : \text{gleiche Gewichtung der Landmarken aus } \hat{\mathcal{T}}_\tau \text{ und } \mathcal{B}_\tau \\ \alpha > 0.5 & : \text{stärkere Gewichtung der Landmarken aus den Messungen } \mathcal{B}_\tau \end{cases} \quad (4.29)$$

- Gleitender Mittelwert

$$\tilde{t}_k = \frac{1}{h} \cdot b_l + \left(1 - \frac{1}{h}\right) \cdot \hat{t}_k \quad (4.30)$$

Es wird die Anzahl der Sichtungen  $h$  als Gewichtung verwendet. Je häufiger die Track-Landmarke  $\hat{t}_k$  beobachtet werden konnte, desto stärker wird sie gewichtet.

- Arithmetischer Mittelwert

$$\tilde{t}_k = \hat{t}_k + \frac{b_l - \hat{t}_k}{h} \quad (4.31)$$

Es ergibt sich die Position der aktualisierten Track-Landmarke  $\tilde{t}_k$  als rekursiver arithmetischer Mittelwert (aus  $\tilde{t}_k$  wird beim nächsten Durchlauf  $\hat{t}_k$ ). Mit  $\frac{b_l - \hat{t}_k}{h}$  wird die neue Verschiebung der Landmarkenposition, gewichtet nach der Anzahl der Sichtungen  $h$ , zwischen Messung und prädzierter Track-Landmarke ermittelt.

- Längenbasierte Gewichtung für Positionsermittlung

$$\tilde{t}_k = \frac{(\hat{t}_k + w \cdot b_l)}{(1.0 + w)}, \text{ wobei } w = \frac{|\hat{t}_k|}{|b_l|} \quad (4.32)$$

Bei der längenbasierten Gewichtung bildet der Längenquotient (wobei die Länge der Landmarke mit  $|\hat{t}_k|$  respektive  $|b_l|$  in Gleichung (4.32) angegeben ist) zwischen Track-Landmarke und gemessener Landmarke das Gewicht  $w$ . Das Gewicht wird in die Positionsermittlung einbezogen. Es wird die längere Landmarke stärker gewichtet und trägt mehr zur Aktualisierung der Position bei.

Die genannten Positionsaktualisierungen werden gemäß der Landmarkenbeschreibung aus Kapitel 4.1.1 für die einzelnen Typen durchgeführt. Bei polylinienbasierten Landmarken wird die jeweilige Positionsaktualisierung im Überlappungsbereich ausgeführt. Anschließend werden die Überhänge hinzugefügt und die neu konstruierte Polylinie mit dem Ramer–Douglas–Peucker-Algorithmus [241] vereinfacht. Abbildung 4.12 zeigt die einzelnen Schritte des Verfahrens schematisch auf. Die Teilabbildungen a und b stellen die Berechnung des Überlappungsbereiches zweier polylinienbasierter Landmarken  $\hat{t}_k \in \hat{\mathcal{T}}_\tau$  und  $b_l \in \mathcal{B}_\tau^n$  (vgl. Beschreibung Abbildung 4.10 in Kapitel 4.2.4). In den Teilen c und d ist das Durchlaufen der Messlandmarke  $b_l$  zur Ermittlung von weiteren Punkten auf der Polylinie (angedeutet mit einem Kreis um jeden Punkt  $p_i \in b_l$  und deren Schnittpunkt mit  $b_l$ , die mit einem „x“ veranschaulicht sind) sowie die Berechnung zugehöriger Lotpunkte auf der assoziierten Track-Landmarke  $\hat{t}_k$  abgebildet (schwarze Linien zwischen den „x“-Markierungen von  $b_l$  nach  $\hat{t}_k$ ).

Die Lotpunktberechnung ist in Anhang C.4.4 gegeben. Abschließend zeigt Teil e die Berechnung eines neuen Punktes aus den Schnittpunkten und den zugehörigen Lotpunkten (schwarze Rechtecke), entsprechend den oben genannten Positionsaktualisierungen. In Teil f werden die abgeschnittenen Überhänge der Polylinien an die aktualisierte Landmarke  $\tilde{t}_k$  angefügt. Im Anschluss wird die neu konstruierte Polylinie mit dem Ramer–Douglas–Peucker-Algorithmus [241] simplifiziert.




Abbildung 4.12: Vorgehen der Positionsaktualisierung für polylinienbasierte Landmarken

#### 4.2.6.2 Unsicherheitsaktualisierung

Die Unsicherheit der aktualisierten Track-Landmarken ergibt sich aus der Unsicherheit des Bewegungsschrittes und der linearen Ausgleichung zwischen prädizierter Track-Landmarke und korrespondierender Landmarke aus den Messungen. Die Unsicherheit des Bewegungsschrittes wird empirisch (vgl. Beschreibung Kapitel 3.1) ermittelt. Die Unsicherheit wird mit der Anwendung des Bewegungsschrittes additiv auf die Unsicherheit der Track-Landmarken hinzugefügt. Das bildet die Unsicherheit einer prädizierten Track-Landmarke  $\hat{t}_k \in \hat{\mathcal{T}}_\tau$  vor der Aktualisierung. Bei der Aktualisierung der Landmarkenunsicherheit wird das Verfahren der linearen Ausgleichung, entsprechend der Beschreibung in [238], verwendet.

Die Berechnung der einzelnen Kovarianzeinträge zur Beschreibung der Unsicherheit einer Landmarke erfolgt für alle Punkte  $p_i$  einer Landmarke, entsprechend ihrer Definition aus Ka-

pitel 4.1.1. Resultierend ergibt sich der Beobachtungsvektor  $\varpi$  und die Kovarianzmatrix  $\Sigma_{ll}$ , entsprechend der Formulierung in Gleichung (4.33).

$$\varpi = \begin{pmatrix} \hat{t}_{k,x} \\ \hat{t}_{k,y} \\ b_{l,x} \\ b_{l,y} \end{pmatrix}, \Sigma_{ll} = \begin{pmatrix} \sigma_{\hat{t}_{k,x}}^2 & \sigma_{\hat{t}_{k,x},\hat{t}_{k,y}} & 0 & 0 \\ \sigma_{\hat{t}_{k,x},\hat{t}_{k,y}} & \sigma_{\hat{t}_{k,y}}^2 & 0 & 0 \\ 0 & 0 & \sigma_{b_{l,x}}^2 & \sigma_{b_{l,x},b_{l,y}} \\ 0 & 0 & \sigma_{b_{l,x},b_{l,y}} & \sigma_{b_{l,y}}^2 \end{pmatrix} = \begin{pmatrix} \Sigma_{\hat{t}_{k,p_i}} & 0 \\ 0 & \Sigma_{b_{l,p_j}} \end{pmatrix} \quad (4.33)$$

Hier steht  $(\hat{t}_{k,x}, \hat{t}_{k,y})$  für die  $(x, y)$ -Koordinaten des  $i$ -ten Punktes  $p_i$  der prädierten Track-Landmarke im  $\xi_{\tau}^{\text{vrf}}$ ,  $(b_{l,x}, b_{l,y})$  respektive für die aktuell detektierte Landmarke. Der funktionale Zusammenhang zwischen dem Beobachtungsvektor  $\varpi$  und den unbekanntem, zu bestimmenden Parametern  $\dot{X}_1, \dot{Y}_1$  ist in Gleichung (4.34) gegeben, womit der Parametervektor  $\dot{\chi}$  folgt.

$$\begin{aligned} \dot{X}_1 &= \hat{t}_{k,x} \\ \dot{Y}_1 &= \hat{t}_{k,y} \\ \dot{X}_1 &= b_{l,x} \\ \dot{Y}_1 &= b_{l,y} \end{aligned} \Rightarrow \dot{\chi} = \begin{pmatrix} \dot{X}_1 \\ \dot{Y}_1 \end{pmatrix} \quad (4.34)$$

Aus dem Beobachtungsvektor  $\varpi$  ergibt sich durch Bildung der partiellen Ableitungen die Jacobi-Matrix  $J$ . Im Falle der Positionen der Track- und Messlandmarke ergibt sich  $J$  entsprechend Gleichung (4.35).

$$\varpi = \begin{pmatrix} \hat{t}_{k,x} \\ \hat{t}_{k,y} \\ b_{l,x} \\ b_{l,y} \end{pmatrix} \Rightarrow J = \begin{pmatrix} \frac{\delta \hat{t}_{k,x}}{\delta x} & \frac{\delta \hat{t}_{k,x}}{\delta y} \\ \frac{\delta \hat{t}_{k,y}}{\delta x} & \frac{\delta \hat{t}_{k,y}}{\delta y} \\ \frac{\delta b_{l,x}}{\delta x} & \frac{\delta b_{l,x}}{\delta y} \\ \frac{\delta b_{l,y}}{\delta x} & \frac{\delta b_{l,y}}{\delta y} \end{pmatrix} = \begin{pmatrix} 1 & 0 \\ 0 & 1 \\ 1 & 0 \\ 0 & 1 \end{pmatrix} \quad (4.35)$$

Durch den linearen Zusammenhang zwischen Parameter- ( $\dot{\chi}$ ) und Beobachtungsvektor ( $\varpi$ ) wird die Kovarianzmatrix  $\Sigma_{xy}$  für jeden Punkt der aktualisierten Track-Landmarke  $\tilde{t}_k$  nach Gleichung (4.36) bestimmt [238].

$$\Sigma_{xy} = (J^T S^{-1} J)^{-1}, \text{ wobei } S^{-1} = (\Sigma_{ll})^{-1} \quad (4.36)$$

Wird die Gleichung (4.36) zur Gleichung (4.37) erweitert, so lassen sich direkt die neuen Positionen der aktualisierten Track-Landmarke, proportional zur Unsicherheit gewichtet, bestimmen. Der Parametervektor  $\dot{\chi}$  enthält dann die gesuchten Parameterwerte, in dem Falle die gesuchten  $(x, y)$ -Koordinaten der ausgeglichenen neuen Track-Landmarke aus dem prädierten Track und der korrespondierenden Messung.

$$\dot{\chi} = \begin{pmatrix} \dot{X}_1 \\ \dot{Y}_1 \end{pmatrix} = \underbrace{(J^T S^{-1} J)^{-1}}_{\Sigma_{xy}} J^T S^{-1} \varpi \quad (4.37)$$

Diese Methode liefert in nur einem Berechnungsschritt aktualisierte Positions- und Unsicherheitswerte der neuen Track-Landmarke. Sie eignet sich allerdings nur dann, wenn systematische

Fehler, beispielsweise Kalibrierungsfehler, weitestgehend ausgeschlossen sind und in den Messungen nur zufällige Fehler vorkommen. Mit der Veranschaulichung im Anhang C.1 wird deutlich, dass trotz des durchgeführten Kalibrierungsschrittes (vgl. Kapitel 3.1.4) systematische Fehler in den Detektionen nicht ausgeschlossen sind. Deshalb wird die Aktualisierung der Position und der Unsicherheit im Verarbeitungsschritt der Track-Innovation getrennt voneinander durchgeführt.

### 4.2.7 Sichtbereiche

Die Sichtbereiche, sogenannte Field Of View (FOV), definieren innerhalb des TML für jeden Sensor eine zugehörige Fläche, in der das Tracking und die Fusion, entsprechend der Beschreibung in Kapitel 4.2.5, stattfindet. Diese Sichtbereiche können als ROI interpretiert werden. Jeder FOV wird innerhalb der Konfigurationsdatei (siehe Anhang C.4.2) definiert. Dabei können für jeden Sensor beliebig viele Sichtbereiche festgelegt werden und den beobachtbaren Landmarken zugewiesen sein. Innerhalb der SML-Schicht werden im SDM die Sichtbereiche aus der Konfigurationsdatei ausgelesen und dem zugehörigen SDO zugewiesen.

Abbildung 4.13 zeigt exemplarisch mehrere Sichtbereiche für die einzelnen Sensoren des TFM, wobei die eingefärbten Rechtecke den jeweiligen Sichtbereichen entsprechen (in Hellblau für die vier Fischaugenkameras und in Hellbeige für den Laserscanner, vgl. Kapitel 3.1.4). Die Positionen der FOV-zugehörigen Sensoren sind mit schwarzen Punkten, entsprechend der Beschreibung aus Kapitel 3.1.4, dargestellt. Die roten Linien visualisieren polylinienbasierte Landmarken, die grünen Linien stellen linienbasierte und die roten Punkte die punktbasierten Landmarken dar. Die magentafarbene Linie hinter dem Fahrzeug symbolisiert den Tracking-Horizont (vgl. Erläuterung in Kapitel 4.2.3), hinter dem alle Landmarken aus dem Landmarkenumfeldmodell gelöscht werden.




Abbildung 4.13: Exemplarische Darstellung der Sichtbereiche (FOV)

Der Konfidenzwert der Track-Landmarken wird nur innerhalb der Sichtbereiche verändert. Das hat zur Folge, dass Track-Landmarken nur im Sichtbereich vom Track-Management bestätigt oder gelöscht werden. Verlässt eine Track-Landmarke den Sichtbereich, so erfährt sie weiterhin den Verarbeitungsschritt der Track-Innovation (Positions- und Kovarianzaktualisierung), jedoch bleibt der Konfidenzwert unverändert. Das gilt sowohl für positive als auch negative Korrespondenzbestimmungen. Verlassen die Landmarken den Tracking-Horizont, so werden sie aus dem Landmarkenumfeldmodell (zweite Schicht des TFM, dem TML, siehe Kapitel 4.2.2) entfernt.

Um ggf. erkannte Landmarken außerhalb des FOV nicht vollständig zu verwerfen, werden diese Landmarken in das Landmarkenumfeldmodell des TML integriert, jedoch nicht vom Track-Management bearbeitet (Konfidenzwert bleibt auf dem Initialisierungswert, siehe Kapitel 4.2.5). Richtig erkannte Landmarken eines Sensors werden mit diesem Ansatz vom TFM an das PLM weitergereicht. Allerdings erfolgt auch eine eventuelle Weitergabe von Fehlerkennungen.

Um das beschriebene Verfahren zu verwenden, erfolgt innerhalb der zeitlichen Synchronisierung für jede Landmarke eine Validierung. Diese Validierung prüft, ob sich eine Landmarke im Sichtbereich der Sensorik befindet. Jeder Sichtbereich eines Sensors wird als konvexes, einfaches Polygon definiert und darf beliebig viele Punkte besitzen. Zwingend erforderlich ist, dass die Punkte in mathematisch positivem Umlauf angegeben sind. Es kann für jedes Punktepaar  $(p_{i-1}, p_i)$  des konvexen Polygons der Vektor  $\vec{v}_{p_{i-1}p_i}$  und dessen Einheitsnormalenvektor  $\vec{n}_{p_{i-1}p_i}$  gebildet werden. Aufgrund des mathematisch positiven Umlaufs der Punkte, ergibt sich der Einheitsnormalenvektor als nach links zeigend. Abbildung 4.14 veranschaulicht die Beschreibung.




Abbildung 4.14: Mathematisch positiver Umlauf der Sichtbereichspunkte des konvexen Polygons und Bildung des Einheitsnormalenvektors je Punktepaar

Anschließend wird für die Start- und Endpunkte einer jeden Landmarke geprüft, ob sie innerhalb oder außerhalb des Polygons liegen. Es wird der Vektor  $\vec{\kappa}_j$  jeweils vom Start- und Endpunkt einer Landmarke  $t_k \in \{s^{\text{PO}}, s^{\text{DL}}, s^{\text{PL}}\}$  zu jedem Punkt  $p_i$  des Polygons gebildet. Das Ergebnis des Skalarprodukts zwischen diesem Vektor und dem zugehörigen Einheitsnormalenvektor beschreibt die relative Lage des Start- bzw. Endpunkts der Landmarke zu dem



gerade geprüften Punktepaar  $(p_{i-1}, p_i)$ . Gleichung (4.38) stellt die Ergebnisse der Prüfung dar, während Abbildung 4.15 den beschriebenen Vorgang veranschaulicht.

$$\begin{cases} a < 0 & : \text{ Start- bzw. Endpunkt der Landmarke liegt rechts von } (p_{i-1}, p_i) \\ a = 0 & : \text{ Start- bzw. Endpunkt der Landmarke liegt auf der Strecke } (p_{i-1}, p_i) \\ a > 0 & : \text{ Start- bzw. Endpunkt der Landmarke liegt links von } (p_{i-1}, p_i) \end{cases} \quad (4.38)$$




Abbildung 4.15: Vektorbildung  $\vec{k}_j$  von Start-/Endpunkt einer Landmarke zu einem Punkt des FOV und anschließende Berechnung des Skalarprodukts mit zugehörigem Einheitsvektor

Das Ergebnis des Skalarprodukts wird auf diese Weise für jede Kante mit Punktepaar  $(p_{i-1}, p_i)$  des konvexen Polygons geprüft und das Maximum aller Werte zurückgegeben. Falls der Wert positiv ist, liegt ein Punkt der Landmarke im Sichtbereich und die Landmarke wird als im Sichtbereich liegend behandelt, anderenfalls nicht.

### 4.3 Partikelfilterbasiertes Lokalisierungsmodell

Ziel der in Kapitel 4.1 vorgestellten Landmarkenbasierten Lokalisierung (LbL) ist die Ausgabe einer Pose  $\zeta_\tau^{\text{wgs}}$  des Fahrzeugs zum Zeitpunkt  $\tau$ , die den in Kapitel 1.2 genannten Randbedingungen gerecht wird. Dieses Ziel lässt sich, wie zu Beginn des Kapitels beschrieben, als Gleichung (4.39) ausdrücken.

$$\zeta_\tau = f(z_{1:\tau}, u_{1:\tau}, \mathcal{M}) \rightarrow \zeta_\tau^{\text{wgs}} = f(\mathcal{Z}_\tau, \mathcal{M}) \quad (4.39)$$

Die Berechnung der Pose  $\zeta^{\text{wgs}_\tau}$  erfolgt im hier vorgestellten Partikelfilterbasierten Lokalisierungsmodell (PLM). Diese Berechnung basiert auf der Registrierung des im TFM erzeugten Landmarkenumfeldmodells in die Landmarkenkarte  $\mathcal{M}$ . Das Landmarkenumfeldmodell besteht aus den Track-Landmarken  $\mathcal{T}_\tau = \{t_r^{\text{sPO}}, t_o^{\text{sDL}}, t_l^{\text{sPL}}\}_{r=1, o=1, l=1}^{R, O, L}$ , die zum aktuellen Zeitpunkt vom TFM verwaltet werden. Zum leichteren Verständnis der nachfolgenden Erläuterungen wird von Beobachtungen  $\mathcal{Z}_\tau$  der Landmarken  $z$  gesprochen. Es gilt  $\mathcal{Z}_\tau = \mathcal{T}_\tau$  sowie  $z_i \in \mathcal{Z}_\tau$  für die  $i$ -te Beobachtung einer Landmarke  $z$ .

Zur Durchführung der Registrierung bieten sich die in Kapitel 2.2 vorgestellten probabilistischen Verfahren für eine globale Lokalisierung an. Die Wahl zur Anwendung eines bestimmten Ansatzes kann aus den Eingangsdaten abgeleitet werden. Für das PLM werden die Eingangsdaten vom TFM (vgl. Kapitel 4.2) bereitgestellt. Das Verfahren des TFM nimmt detektierte Landmarken aus dem in Kapitel 3.1 genannten Sensorsatz entgegen und bildet durch Fusion und Nachverfolgung in der zweiten Schicht (TML, vgl. Kapitel 4.2.2) ein konsistentes Landmarkenumfeldmodell. Dieses Landmarkenumfeldmodell wird zusammen mit der Eigenbewegungsschätzung  $\zeta_\tau^{\text{vrf}}$  und der globalen Poseschätzung  $\zeta_\tau^{\text{wgs}}$  (siehe Kapitel 3.1 und Anhang A) zum Zeitpunkt  $\tau$  synchronisiert an das PLM übermittelt. Anhang C.5.1 zeigt die Eingangs- und Ausgangsdaten des Verfahrens schematisch auf.

Trotz der Bildung eines konsistenten Umfeldmodells aus den unterschiedlichen Detektionen der Sensoren (Fusion), der Stabilisierung durch Nachverfolgung der Landmarken (Tracking) und der Bereinigung von Fehldetektionen durch statisches Filtern enthält die Ausgabe der Level-2-Landmarken  $\mathcal{Z}$  eventuell fehlerhafte Informationen (engl. Clutter). Zusätzlich ist die globale Poseschätzung und die Eigenbewegungsschätzung mit Ungenauigkeiten behaftet, die z.B. durch Mehrwegausbreitungen sowie Abschattungen Störungen der globale Poseschätzung hervorrufen oder durch Schlupf und Drift die Eigenbewegungsschätzung mit Fehlern versehen. Obwohl die einzelnen Eingangsgrößen als voneinander unabhängig angenommen werden können, führen ihre Fehler in den Messmodellen zu Nichtlinearitäten. Weiterhin folgen aus falschen Korrespondenzbestimmungen zwischen Karte und Beobachtungen, beispielsweise durch repetitive Muster, multimodale Wahrscheinlichkeitsdichtefunktionen.

Der Partikelfilter als ein Vertreter der probabilistischen Methoden der Klasse der Markov-Lokalisierung approximiert die multimodale Verteilung durch eine Menge von Partikeln  $\mathcal{P}$ , die entsprechend Gleichung (4.40) definiert sind. Jeder Partikel  $s_{f,\tau}^{\text{Partikel}}$  repräsentiert eine mögliche Hypothese der Fahrzeugpose, auch Konfiguration genannt, zum aktuellen Zeitpunkt. Gleichung (4.40) definiert den Zustand eines Partikels. Der Term  $\zeta_{f,\tau}^{\text{wgs}}$  steht für die Pose des Partikels, während  $\omega_{f,\tau}$ , das sogenannte Gewicht des Partikels, die Wahrscheinlichkeit der angenommenen Pose beschreibt. Abbildung 4.16 veranschaulicht die Approximation einer Verteilung durch eine Menge von Partikeln.

$$\mathcal{P}_\tau = \{s_{f,\tau}^{\text{Partikel}}\}_{f=1}^F, \text{ wobei } s_{f,\tau}^{\text{Partikel}} = (\zeta_f^{\text{wgs}}, \omega_{f,\tau}) \quad (4.40)$$




Abbildung 4.16: Approximation einer Verteilung mit gewichteten Stichproben

Der Streubereich für die Partikelmenge wird aus dem Ungenauigkeitsbereich der globalen Poseschätzung abgeleitet. Die Beschreibung eines Partikelfilters folgt Gleichung (4.41) [28].

$$bel(s_{f,\tau}^{\text{Partikel}}) = \underbrace{bel(s_{f,\tau-1}^{\text{Partikel}})}_{\text{Zustandswahrscheinlichkeit zum Zeitpunkt } \tau-1}, \underbrace{p(s_{f,\tau}^{\text{Partikel}}|u_\tau, s_{f,\tau-1}^{\text{Partikel}})}_{\text{Bewegungsmodell}}, \underbrace{p(\mathcal{Z}_\tau|s_{f,\tau}^{\text{Partikel}}, \mathcal{M})}_{\text{Sensormodell}} \quad (4.41)$$

Der Ausdruck  $bel(s_{f,\tau}^{\text{Partikel}})$  drückt die Wahrscheinlichkeit aus, dass das Fahrzeug zum Zeitpunkt  $\tau$  im Zustand  $s_{f,\tau}^{\text{Partikel}}$  ist und setzt sich aus der Wahrscheinlichkeit des Zustandes  $s_{f,\tau-1}^{\text{Partikel}}$  aus dem vorherigen Zeitschritt  $\tau - 1$ , dem Bewegungsmodell sowie dem Sensormodell zusammen. Das Bewegungsmodell  $p(s_{f,\tau}^{\text{Partikel}}|u_\tau, s_{f,\tau-1}^{\text{Partikel}})$  beschreibt die Anwendung der durchgeführten Bewegung  $u_\tau$  des Fahrzeugs auf die Partikel  $s_{f,\tau-1}^{\text{Partikel}}$ . Es resultiert die Wahrscheinlichkeit der Vorhersage bzw. Prädiktion des Zustandes der Partikel im Zeitschritt  $\tau$ . Im Sensormodell wird die Aktualisierung der Zustandswahrscheinlichkeit der Partikel durch den Abgleich aus den aktuellen Beobachtungen  $\mathcal{Z}_\tau$  zur Karte  $\mathcal{M}$  durchgeführt. Im Bewegungsmodell  $p(s_{f,\tau}^{\text{Partikel}}|s_{f,\tau-1}^{\text{Partikel}})$  wird der Zustandsübergang mit Gleichung (4.42) und im Sensormodell  $p(\mathcal{Z}_\tau|s_{f,\tau}^{\text{Partikel}})$  der Messübergang mit Gleichung (4.43) ausgedrückt.

$$s_{f,\tau}^{\text{Partikel}} = F(s_{f,\tau-1}^{\text{Partikel}}) + d_\tau \quad (4.42)$$

$$\mathcal{Z}_\tau = H(s_{f,\tau}^{\text{Partikel}}) + v_\tau \quad (4.43)$$

In der Zustandsübergangsgleichung (4.42) steht  $d_\tau$  für das Prozessrauschen (auch Systemrauschen genannt) und modelliert die Unsicherheit der Fahrzeugbewegung. Das Messrauschen wird in der Messübergangsgleichung (4.43) mit  $v_\tau$  angegeben. Umgangssprachlich gibt die Messübergangsgleichung wieder, wie wahrscheinlich die aktuelle Beobachtung  $\mathcal{Z}_\tau$  unter der Annahme des Zustands  $s_{f,\tau}^{\text{Partikel}}$  wahrgenommen werden konnte.

Die Bestimmung bzw. konkrete Umsetzung des Bewegungsmodells und des Sensormodells aus Gleichung (4.41) und deren Übergangsbeschreibung aus den Gleichungen (4.42) und (4.43) stellt die Herausforderung des Verfahrens dar. Die Entwicklung des Sensormodells ist ausschlaggebend für die Güte des Partikelfilters. Für die verwendeten Landmarken wird erstmalig in dieser Arbeit eine neue Formulierung für das Sensormodell entwickelt, die in Kapitel 4.3.2 vorgestellt wird.

Abbildung 4.17 zeigt die einzelnen Schritte des PLM auf. Der Dateneingang beinhaltet die vom TFM bereitgestellten Datensätze. Beim ersten Dateneingang wird das PLM initialisiert (Streuung der Partikel um die erhaltene globale Poseschätzung, siehe Kapitel 4.3.6). Andernfalls sind bereits Partikel vorhanden, die entsprechend der durchgeführten Bewegung transformiert werden müssen (Anwendung des Bewegungsmodells, siehe Kapitel 4.3.1). Anschließend erfolgt die Korrespondenzbestimmung zwischen Beobachtungen und Karte für jeden prädierten Partikel (Ausführung im Sensormodell, siehe Kapitel 4.3.2) und die resultierende Gewichtung (siehe Kapitel 4.3.3). Um relative Schwankungen der Partikelgewichte zwischen zwei Zeitschritt zu verhindern, wird der Verarbeitungsschritt des Smoothing durchgeführt (siehe Kapitel 4.3.4). Abschließend erfolgen die parallelen Verarbeitungsschritte zur Poseberechnung aus der aktualisierten Partikelmenge (siehe Kapitel 4.3.5) und das Auswählen von neuen Partikeln für den nächsten Durchlauf (engl. Resampling, siehe Kapitel 4.3.6).




Abbildung 4.17: Datenverarbeitungsprozess des PLM

### 4.3.1 Bewegungsmodell

Die Partikelmenge  $\mathcal{P}$  beschreibt zu jedem Zeitpunkt  $\tau$  die möglichen Zustandshypothesen des Fahrzeugs. Durch die Eigenbewegung  $u$  des Fahrzeugs zwischen zwei Zeitschritten  $\tau - 1$  und  $\tau$  müssen die Partikel, entsprechend der Bewegung, transformiert werden. Diese Transformation wird generell als Bewegungsmodell innerhalb des Partikelfilters bezeichnet und mit Gleichung (4.44) ausgedrückt.

$$p(\mathcal{P}_\tau | u_\tau, \mathcal{P}_{\tau-1}) = p(s_{f,\tau}^{\text{Partikel}} | u_\tau, s_{f,\tau-1}^{\text{Partikel}}) \quad (4.44)$$

Laut Zustandsdefinition befindet sich jeder Partikel  $s_f^{\text{Partikel}}$  im  $\xi^{\text{wgs}}$ -System. Die Eigenbewegung wird im  $\xi^{\text{occs}}$ -System beschrieben (vgl. Kapitel 3.2). Beides muss in ein gemeinsames Koordinatensystem umgerechnet werden. Hierfür fällt die Wahl auf das  $\xi^{\text{enu}}$ -System. Mit Hilfe der in Kapitel 3.2.5 beschriebenen Umrechnungen zwischen den Systemen werden zum einen die Partikel  $\mathcal{P}_{\tau-1}$  im  $\xi^{\text{enu}}$ -System ausgedrückt, zum anderen wird die Eigenbewegung zwischen den beiden Zeitschritten in das  $\xi^{\text{enu}}$ -System überführt. Damit lässt sich die Eigenbewegung  $u_\tau$  direkt auf die Partikel  $\mathcal{P}_{\tau-1}$  anwenden und resultiert in der Prädiktion der Partikelmenge  $\mathcal{P}_\tau$  zum Zeitpunkt  $\tau$ .

Aufgrund von Fehlern (z.B. Schlupf und Drift) in der Eigenbewegungsschätzung des Fahrzeugs, ist es nötig, ein Rauschen (engl. noise) auf die Eigenbewegung  $u_\tau$  zu addieren. Dadurch wird sichergestellt, dass die Partikelwolke  $\mathcal{P}_\tau$  beim Durchführen des Bewegungsmodells „aufgeht“. Je höher dieses Rauschen ist, desto schneller zieht die Partikelwolke auseinander.

Die empirisch ermittelte Standardabweichung der Eigenbewegungsschätzung (vgl. Kapitel 3.1.3) wird als statisches Rauschen bei jedem Ausführen des Bewegungsmodells auf  $u_\tau$  addiert. Das Rauschen wird lediglich auf die  $x$ -Achse und die Blickrichtung  $\theta$  angewendet.

### 4.3.2 Sensormodell

Das Sensormodell wird anhand Gleichung (4.45) ausgedrückt. Innerhalb dieses Kapitels wird der Zeitindex  $\tau$  zur besseren Lesbarkeit nicht mitgeführt. Die Landmarken der Beobachtungen  $\mathcal{Z}$ , die Partikel  $\mathcal{P}$  und die Landmarkenkarte  $\mathcal{M}$  liegen immer gemeinsam zum aktuell gültigen Zeitpunkt  $\tau$  vor. Beobachtungen, Partikel und Karte sind entsprechend Gleichung (4.46) definiert.

$$p(\mathcal{Z}|\mathcal{P}, \mathcal{M}) \quad (4.45)$$

$$\begin{aligned} \mathcal{Z} &= \{z_i\}_{i=1}^N \\ \mathcal{M} &= \{m_j\}_{j=1}^M \\ \mathcal{P} &= \{s_f^{\text{Partikel}}\}_{f=1}^F \end{aligned} \quad (4.46)$$

Mit  $z_i \in \mathbb{R}^2$  wird die  $i$ -te Beobachtung einer Landmarke bezeichnet und  $m_j \in \mathbb{R}^2$  steht für die  $j$ -te Landmarke in der Karte. Der Zustand des  $f$ -ten Partikels ist mit  $s_f^{\text{Partikel}}$  angegeben. Die Indizes  $N, M, F$  geben die aktuelle Anzahl der enthaltenen Landmarken in der Menge der Beobachtungen  $\mathcal{Z}$ , in der Landmarkenkarte  $\mathcal{M}$  und in der Menge aller aktuellen Partikel  $\mathcal{P}$  an. Die Landmarken sind entsprechend Kapitel 4.1.1 definiert. Durch die Annahme der bedingten Unabhängigkeit zwischen den Beobachtungen wird Gleichung (4.45) mit Gleichung (4.47) ausgedrückt.

$$p(\mathcal{Z}|\mathcal{P}, \mathcal{M}) = \prod_{i=1}^N p(z_i|\mathcal{P}, \mathcal{M}) \quad (4.47)$$

Die Schwierigkeit bei der Berechnung des Terms ergibt sich zum einen aus der unbekanntenen Korrespondenz zwischen den beobachteten Landmarken und den Kartenlandmarken, zum anderen aus der geometrischen Beschreibung der Landmarken. Intuitiv gilt, dass Beobachtungen, die nah an Kartenlandmarken liegen, sehr wahrscheinlich von jenen erzeugt wurden. Im anderen Fall, falls eine Beobachtung weiter entfernt von einer Kartenlandmarke liegt, kann im

Sinne des Sensormodells erwartet werden, dass die Wahrscheinlichkeit der Erzeugung dieser Beobachtung von der Kartenlandmarke gering ist.

Das Lösen dieses Zuweisungsproblems wird in seiner Schwierigkeit erhöht, falls eine Beobachtung in der Mitte von zwei Kartenlandmarken liegt. Es ist fast unmöglich zu entscheiden, von welcher Kartenlandmarke die Beobachtung generiert wurde. Die Wahrscheinlichkeit einer Beobachtung, unter der Annahme mehrerer Kartenlandmarken, hängt zum einen von der Distanz zueinander und zum anderen von der Messungenauigkeit ab.

Zur Vermeidung der expliziten Zuweisung von Beobachtungen zu Level-3-Landmarken wird die Wahrscheinlichkeit der Generierung einer Beobachtung aus einer Level-3-Landmarke als Wahrscheinlichkeit der Erzeugung aus der ersten Kartenlandmarke *oder* aus der zweiten Kartenlandmarke *oder* aus der dritten usw. modelliert. Alle Level-3-Landmarken, die weit genug von der Beobachtung entfernt sind, liefern nur minimale Wahrscheinlichkeiten.

Sei nun  $A_{i,j}$  das Ereignis „Beobachtung  $z_i$  wurde von Kartenlandmarke  $m_j$  erzeugt“. Dann wird der Ausdruck des Sensormodells  $p(z_i|\mathcal{P}, \mathcal{M})$  durch Gleichung (4.48) ausgedrückt.

$$p(z_i|\mathcal{P}, \mathcal{M}) = p\left(\bigcup_{j=1}^M A_{i,j}\right) \quad (4.48)$$

Es wird erwartet, dass nur ein Wert des Terms  $A_{i,j}$  signifikant größer ist als 0, da sich eine Beobachtung meistens nur in der Nähe einer Kartenlandmarke befindet. Falls sich eine Beobachtung weit entfernt zu allen Kartenlandmarken befindet, sind alle Werte des Terms  $A_{i,j}$  nahe 0. Zusätzlich modelliert Gleichung (4.48) den Fall, dass eine Beobachtung sich in der Nähe von mehreren Kartenlandmarken befindet. Vor allem liefert diese Modellierung den Vorteil, dass keine explizite Zuweisung einer Beobachtung zu einer Kartenlandmarke durchgeführt wird. Das wird implizit erreicht.

Mit dem Prinzip der Inklusion und Exklusion lässt sich Gleichung (4.47) zu Gleichung (4.49) weiterentwickeln.

$$p\left(\bigcup_{j=1}^M A_{i,j}\right) = \sum_{q=1}^M \left( (-1)^{q+1} \sum_{\substack{I \subseteq \{1, \dots, M\} \\ |I|=q}} p\left(\bigcap_{p \in I} A_{i,p}\right) \right) \quad (4.49)$$

Zur Veranschaulichung der Regel soll ein einfaches Beispiel mit drei Ereignissen  $A_1$ ,  $A_2$  und  $A_3$  dienen. Diese Ereignisse können Gleichung (4.47) folgend aufgeschrieben und entsprechend der Gleichung (4.49) umformuliert werden. Gleichung (4.50) zeigt die genannten Schritte.

$$\begin{aligned} p(A_1 \cup A_2 \cup A_3) &= p(A_1) + p(A_2) + p(A_3) \\ &\quad - p(A_1 \cap A_2) - p(A_1 \cap A_3) - p(A_2 \cap A_3) \\ &\quad + p(A_1 \cap A_2 \cap A_3) \end{aligned} \quad (4.50)$$

Die Wahrscheinlichkeit der Vereinigung der Ereignisse  $A_1$ ,  $A_2$  und  $A_3$  ist gleich der Summe der Wahrscheinlichkeiten aller einzelnen Ereignisse minus der Wahrscheinlichkeit jeder Kombination der Schnittmenge von je zwei Ereignissen plus der Wahrscheinlichkeit der Schnittmenge aller drei Ereignisse. Die letzte Schnittmenge muss hinzugefügt werden, da sonst die Wahrscheinlichkeit von  $p(A_1 \cap A_2 \cap A_3)$  vollständig (dreimal hinzugefügt und dreimal abgezogen) entfernt werden würde.

In der Theorie erlaubt Gleichung (4.49) die Berechnung der gewünschten Wahrscheinlichkeit. Jedoch ist die Berechnung der Wahrscheinlichkeit der Schnittmenge von zwei oder mehreren Ereignissen nicht trivial berechenbar und die Anzahl der Summanden der inneren Summe steigt selbst für kleine Werte  $M$  mit  $\sum_{j=1}^M \binom{M}{j}$  sehr schnell an. Wird stochastische Unabhängigkeit zwischen den Landmarken angenommen, so wird die Berechnung der Wahrscheinlichkeiten der Schnittmengen von zwei Ereignissen ermöglicht. Mit dieser Annahme gilt für den inneren Term der inneren Summe aus Gleichung (4.49) mit  $I \subseteq \{1, \dots, M\}$  die Gleichung (4.51).

$$p\left(\bigcap_{p \in I} A_{i,p}\right) = \prod_{p \in I} p(A_{i,p}) \quad (4.51)$$

Das führt zu Gleichung (4.52), die durch Induktion über  $M$  bewiesen werden kann (siehe Anhang C.5.2).

$$p\left(\bigcup_{j=1}^M A_{i,j}\right) \approx \sum_{j=1}^M \left( p(A_{i,j}) \prod_{k=j+1}^M (1 - p(A_{i,k})) \right) \quad (4.52)$$

Es kann die Gleichung (4.47) mit Gleichung (4.53) approximiert werden.

$$p(\mathcal{Z}|\mathcal{P}, \mathcal{M}) \approx \prod_{i=1}^N \sum_{j=1}^M \left( p(A_{i,j}) \prod_{k=j+1}^M (1 - p(A_{i,k})) \right) \quad (4.53)$$

Praktisch ist es vorteilhaft, eine uniforme Verteilung mit einem Parameter  $\nu$  hinzuzunehmen. Es ermöglicht die Modellierung der Wahrscheinlichkeit, dass eine Beobachtung  $z_i$  von keiner Kartenlandmarke  $m_j$  zu erklären ist. Mit diesem Effekt wird Gleichung (4.53) zu Gleichung (4.54).

$$p(\mathcal{Z}|\mathcal{P}, \mathcal{M}) \approx \prod_{i=1}^N \max \left( \nu, \sum_{j=1}^M \left( p(A_{i,j}) \prod_{k=j+1}^M (1 - p(A_{i,k})) \right) \right) \quad (4.54)$$

Wird berücksichtigt, dass mehrere Kartenlandmarken den möglichen Ursprung einer Beobachtung bilden, so wird die Realität besser abgebildet als bei einer harten Zuweisung, die alle anderen Informationen vernachlässigt.

Die Herleitung des Sensormodells ist unabhängig von der spezifischen Wahl der Wahrscheinlichkeitsverteilung  $p(A_{i,j})$ . Für den hier genutzten Anwendungsfall wird die Normalverteilung  $\mathcal{N}(z_i|m_j, \Sigma_i)$  angenommen, wobei  $\Sigma_i$  die Kovarianzmatrix der Beobachtung  $z_i$  beschreibt (entsprechend der Definition der unterschiedlichen Typen von Level-2-Landmarken aus Kapitel 4.1.1). Als eine unimodale Verteilung erfüllt die Normalverteilung die geforderte Eigenschaft, dass nur Beobachtungen  $z_i$  nah an einer Kartenlandmarke  $m_j$  einen signifikanten Wahrscheinlichkeitswert beisteuern. Ergänzend fällt die Wahrscheinlichkeit weich um die Landmarke und ist immer positiv.

Aus Gründen der einfacheren Schreibweise ist im Folgenden der Parameter  $\nu$  aus Gleichung (4.54) zu 0 angenommen. Es ergibt sich das beschriebene Sensormodell entsprechend der Formulierung in Gleichung (4.55).

$$p(\mathcal{Z}|\mathcal{P}, \mathcal{M}) \approx \prod_{i=1}^N \sum_{j=1}^M \left( \mathcal{N}(z_i|m_{j,\mathcal{P}}, \Sigma_i) \prod_{k=j+1}^M (1 - \mathcal{N}(z_i|m_{k,\mathcal{P}}, \Sigma_i)) \right) \quad (4.55)$$

Der Term  $m_{j,\mathcal{P}}$  steht für die  $j$ -te Kartenlandmarke, transformiert in das jeweilige  $\xi^{\text{vrf}}$ , also das lokale Fahrzeugkoordinatensystem der aktuell betrachteten Hypothese eines Partikels. Das Ergebnis des Sensormodells wird Gewicht  $\omega$  eines Partikels  $s_f^{\text{Partikel}}$  genannt und gibt an, wie wahrscheinlich sich das Partikel an der aktuellen Pose befindet.

Innerhalb der Normalverteilung  $\mathcal{N}$  muss die Normalisierungskonstante  $\eta_i$  nicht explizit berechnet werden, da sie sich im Normalisierungsschritt innerhalb der Resampling-Prozedur aufhebt. Die Normalisierungskonstante  $\eta_i$  ist nicht von einer Zustandshypothese aus  $\mathcal{P}$  abhängig, weil die Beobachtungen  $z_i$  immer im aktuellen  $\xi^{\text{vrf}}$  des jeweiligen Partikels betrachtet wird.

Das entwickelte Sensormodell ist als Summe von Gauß-Verteilungen zu interpretieren und wird im Weiteren als Sum of Gaussians (SoG) bezeichnet. Es bietet den Vorteil einer effizienten Laufzeit mit  $\mathcal{O}(N \times M)$  (mit  $N$  als Anzahl der beobachteten Landmarken und  $M$  als die Anzahl der Kartenlandmarken) und die Berücksichtigung von Mehrdeutigkeiten.

Abbildung 4.18 stellt das beschriebene Verfahren des SoG-Sensormodells anschaulich dar. Die Rechtecke entsprechen den Beobachtungen  $z_i$  und die Kreise den Kartenlandmarken  $m_j$ . Der obere Teil des Bildes zeigt als Seitenansicht die angenommene Normverteilung  $\mathcal{N}$  über der jeweiligen Beobachtung  $z_i$  und die sich ergebenden Werte für die Kartenlandmarken  $m_j$ . Im unteren Teil ist die Draufsicht abgebildet, wobei die Normalverteilung von Rot nach Blau fällt. Je näher die Beobachtung an einer Kartenlandmarke ist, desto höher ist die Wahrscheinlichkeit, von der Kartenlandmarke generiert worden zu sein.




Abbildung 4.18: Exemplarische Veranschaulichung des SoG-Sensormodells

Abschließend wird die Berechnung des Ereignisses  $A_{i,j}$  erläutert. Mit  $A_{i,j}$  wird ein Abstandsmaß zwischen einer Landmarke  $i$  der Beobachtungsmenge  $\mathcal{Z}$  und der Kartenlandmarke  $j$  aus der Karte  $\mathcal{M}$  für die in Kapitel 4.1.1 eingeführten Landmarkentypen  $s^{\text{PO}}$ ,  $s^{\text{DL}}$  und  $s^{\text{PL}}$  beschrieben. Für die punktbasierten  $s^{\text{PO}}$  und linienbasierten  $s^{\text{DL}}$  Landmarken gelten die eingeführten Distanzfunktionen aus Kapitel 4.2.4.



Für polylinienbasierte Landmarken  $s^{\text{PL}}$  wird ein anderes Distanzmaß verwendet. Es werden die einzelnen Punkte der Landmarke entsprechend der Länge ihrer Nachbarsegmente gewichtet (vgl. Gleichung (4.14) aus Kapitel 4.2.4 und Gleichung (C.1) aus Anhang C.4.4). Anschließend wird für jeden Punkt der beobachteten polylinienbasierten Landmarke  $z_i^{s^{\text{PO}}}$  der nächste Punkt im zugehörigen Segment der polylinienbasierten Kartenlandmarke  $m_j^{s^{\text{PO}}}$  gesucht und die Distanz zwischen beiden Punkten entsprechend der Distanzfunktion für punktbasierte Landmarken berechnet. Die Summe der berechneten Punktabstände bildet das Abstandsmaß zwischen den polylinienbasierten Landmarken aus Beobachtung und Karte.

### 4.3.3 Gewichtung der Partikel

Sei nun  $\omega_f$  das mit dem Sensormodell  $p(\mathcal{Z}|\mathcal{P}, \mathcal{M})$  berechnete, nicht normalisierte Gewicht für jedes  $f$ -te Partikel aller vorhanden,  $F$ -Partikeln. Gleichung (4.56) formuliert den Zusammenhang.

$$\omega_f = p(\mathcal{Z}|\mathcal{P}_f, \mathcal{M}) = p(\mathcal{Z}|s_f^{\text{Partikel}}, \mathcal{M}) \quad (4.56)$$

Die Werte  $\omega_f$  können potenziell sehr klein werden (nahe 0), falls Beobachtungen weit entfernt von Kartenlandmarken liegen. Das führt zu numerischen Instabilitäten, die durch Anwendung des natürlichen Logarithmus auf die Gewichte umgangen werden. Gleichung (4.57) zeigt die Umformung. Im Folgenden wird der Vorgang als Normalisierungsschritt bezeichnet.

$$\begin{aligned} \ln \omega_f &= \ln p(\mathcal{Z}|\mathcal{P}_f, \mathcal{M}) \\ &= \sum_{i=1}^N \ln \sum_{j=1}^M \left( \mathcal{N}(z_i|m_{j,\mathcal{P}}, \Sigma_i) \prod_{k=j+1}^M (1 - \mathcal{N}(z_i|m_{k,\mathcal{P}}, \Sigma_i)) \right) \end{aligned} \quad (4.57)$$

Die gleiche numerische Instabilität würde im Normalisierungsschritt auftreten, wenn eine direkte Rückrechnung der Terme  $\omega_f$  mit  $\omega_f = \exp(\ln \omega_f)$  erfolgt. Um das zu verhindern, wird zuerst der sogenannte Regularisierungsschritt (Normierung der Werte zwischen 0 und 1) durchgeführt. Sei  $\omega_{\max} = \max(\omega_f)$ , dann gilt für den Regularisierungsschritt die Gleichung (4.58).

$$\ln(\tilde{\omega}_f) = \ln \omega_f - \ln \omega_{\max} = \ln\left(\frac{\omega_f}{\omega_{\max}}\right) \quad (4.58)$$

Damit beschreibt  $\ln(\tilde{\omega}_f)$  den Logarithmus des regularisierten Partikelgewichts. Das erlaubt die Wiederherstellung des Wertes  $\tilde{\omega}_f$  ohne das explizite Wissen über die Werte  $\omega_f$  und  $\omega_{\max}$ . Gleichung (4.59) stellt den Zusammenhang auf.

$$\tilde{\omega}_f = \exp\left(\ln\left(\frac{\omega_f}{\omega_{\max}}\right)\right) = \frac{\omega_f}{\omega_{\max}} \quad (4.59)$$

Jedes Gewicht  $\omega_f$  wird als Subtrahend genutzt, jedoch stellt die Verwendung von  $\omega_{\max}$  sicher, dass numerische Instabilitäten weniger häufig bei den großen und wichtigen Gewichten vorkommen (das Maximalgewicht kann zum Beispiel fest auf  $\omega_{\max} = 1$  gesetzt werden). Zusätzlich bleiben die Proportionen zwischen den Gewichten bezüglich des relativen Anteils gegenüber  $\omega_{\max}$  erhalten.

Der eigentliche Normalisierungsschritt muss nicht weiter angepasst werden und liefert die normalisierten Partikelgewichte  $\bar{\omega}$ . Der Schritt ist formal in Gleichung (4.60) gegeben.

$$\bar{\omega}_f = \frac{\tilde{\omega}_f}{\sum_{i=1}^F \tilde{\omega}_i} = \frac{\frac{\omega_f}{\omega_{\max}}}{\sum_{i=1}^F \frac{\omega_i}{\omega_{\max}}} = \frac{\omega_f}{\sum_{i=1}^F \omega_i} \quad (4.60)$$

### 4.3.4 Smoothing

Das entwickelte Sensormodell kann als „räumlich glatt“ beschrieben werden, da es implizit alle Kartenlandmarken jeder Beobachtung zuweist. Jedoch gibt es Situationen, in denen das Sensormodell nicht „zeitlich glatt“ ist. Anschaulich bedeutet es, dass die relativen Gewichte eines Partikels zwischen zwei Zeitschritten signifikant schwanken können. Solche Situation entstehen, wenn sich zwei aufeinanderfolgende Beobachtungen sehr stark voneinander unterscheiden. Hervorgerufen wird der Fall durch neue Beobachtungen, Fehldetektionen, Verdeckungen oder Beobachtungen, die den Sichtbereich des Sensors verlassen. Diese Situationen sind eine Herausforderung für Partikelfilter.

Um solche Situationen gut mit einem Partikelfilter zu bearbeiten, ist es nötig, die Partikelwolke zu stabilisieren und ein generelles „Wegspringen“ der Partikel zwischen zwei Zeitschritten zu verhindern. Es wurde hier eine einfache „Smoothing“-Strategie für die Partikelgewichte aus [28] adaptiert, die das schnelle Verändern der Partikelgewichte dämpft. Es wird erreicht, indem sich das Partikelgewicht  $\omega_{f,\tau}$  des Partikels  $f$  im Zeitschritt  $\tau$  nach Gleichung (4.61) berechnet.

$$\omega_{f,\tau} = \alpha \omega_{f,\tau} + (1 - \alpha) \omega_{f,\tau-1}. \quad (4.61)$$

Gleichung (4.61) beschreibt die Zusammensetzung des neuen Partikelgewichtes, wobei  $\alpha$  empirisch ermittelt wird und als Dämpfungsfaktor der Partikelgewichtung zwischen zwei Zeitschritten dient. Mit der Betrachtung eines größeren Zeitfensters wird eine deutlich optimiertere Herangehensweise erreicht.

### 4.3.5 Ergebnisberechnung

Für die Ausgabe des PLM muss aus den Partikeln eine wahrscheinliche Pose  $\zeta_{\tau}^{\text{wgs}}$  zum Zeitschritt  $\tau$  berechnet werden. Das erfolgt, indem die Partikel vom  $\xi^{\text{wgs}}$ - in das  $\xi^{\text{enu}}$ -System transformiert werden (vgl. Kapitel 3.2.5). Sobald die Partikel im  $\xi^{\text{enu}}$ -System vorliegen, werden für die gesamte Partikelwolke der Mittelwert, die Standardabweichung und die Kovarianzmatrix berechnet.

Die Ausgabeposition entspricht dem Mittelwert der Partikelwolke. Für die Berechnung der wahrscheinlichen Blickrichtung der Partikelwolke wird das in [250] vorgestellte Verfahren „Mean of circular quantities“ (dt. Mittelwert von rundumlaufenden Quantitäten) verwendet. Abbildung 4.19 verdeutlicht das Verfahren beispielhaft.




Abbildung 4.19: Verfahren „Mean of circular quantities“ zur Berechnung des Mittelwertes der Blickrichtung einer Partikelwolke

Abschließend wird die berechnete Ausgabe position von  $\xi^{\text{enu}}$  zurück in  $\xi^{\text{wgs}}$  transformiert. Für das Ergebnis der LbL ergibt sich die Ausgabe  $\Upsilon_\tau$  zum jeweils gültigen Zeitpunkt  $\tau$  entsprechend Gleichung (4.62).

$$\Upsilon_\tau = (\zeta_{\Upsilon_\tau}^{\text{wgs}}, \Sigma_{\Upsilon_\tau}) = (\lambda_{\Upsilon_\tau}, \phi_{\Upsilon_\tau}, \theta_{\Upsilon_\tau}^{\text{wgs}}, \Sigma_{\Upsilon_\tau}) \quad (4.62)$$

### 4.3.6 Sampling und Resampling

Mit Hilfe des Bewegungsmodells werden die Partikel entsprechend der Eigenbewegung propagiert, wobei sich die Partikelwolke durch das Rauschen weiter verteilt („aufgeht“). Mit dem Sensormodell werden diejenigen Partikel bestimmt, deren Zustandshypothese die beste Erklärung zwischen aktuellen Beobachtungen und der Karte liefert. Jene Partikel erhalten entsprechend dem Sensormodell ein hohes Gewicht. Damit nicht nach wenigen weiteren Iterationsschritten nur die Partikel mit hohem Gewicht übrig bleiben, sind weitere Maßnahmen notwendig. Es wird vom sogenannten Resampling gesprochen, das das Auswählen von Partikeln aus der aktuellen gewichteten Partikelwolke beschreibt. Innerhalb des Resamplings können weitere Verarbeitungsschritte zum Einsatz kommen, wie beispielsweise die Variation der Partikelanzahl und das Streuen von sogenannten Recovery-Partikeln (dt. Wiederherstellungspartikel). Unter Sampling wird die initiale Streuung der Partikel verstanden.

Nachfolgend sind die eingesetzten Methoden innerhalb der Verarbeitungsschritte Sampling und Resampling des hier verwendeten Partikelfilters beschrieben.

#### 4.3.6.1 Sampling

Mit dem Eingang des ersten Datenpakets aus dem TFM befindet sich das PLM im Initialisierungszustand. Es müssen um die GPS-Eingangspose zufällig Partikel gestreut werden. Diese Pose bildet das Streuzentrum, wobei der Streubereich über die Standardabweichung des GPS festgelegt ist (vgl. Kapitel 3.1.4). Gestreut wird um die in das  $\xi^{\text{enu}}$ -System überführte GPS-Pose, wobei Position  $(x, y)$  und Blickrichtung  $\theta$  separat für jedes Partikel festgelegt werden.

Für das zufällige Auswählen von Partikeln um das Streuzentrum der GPS-Pose sind zwei Zufallszahlengeneratoren im PLM wählbar. Die Zufallszahlen sind zum einen über den Halton-Sequenz-Zufallszahlengenerator [251] (deterministisch, engl. quasi random number) oder zum anderen den Gauß-verteiltern Zufallszahlengenerator [252] (nicht deterministisch, engl. random number) erzeugbar.

Die beiden Zufallsgeneratoren unterscheiden sich in der Streuung ihrer Zufallszahlen. Abbildung 4.20 zeigt die Streuunterschiede beider Verfahren für die gleiche Anzahl an Zufallszahlen auf.




Abbildung 4.20: Zufallsgenerator für Halton-Sequenz (links) und für Gauß-verteilte Zufallszahlen (rechts)

#### 4.3.6.2 Resampling

Seien zum Zeitpunkt  $\tau = 0$  mit dem ersten Dateneingang die Partikel, also die möglichen Fahrzeugzustandshypothesen, um die GPS-Pose erzeugt. Ab dem zweiten Dateneingang zum Zeitpunkt  $\tau = 1$  werden die Verarbeitungsschritte (Bewegungsmodell und Sensormodell) des PLM durchlaufen. Nach Ausgabe des berechneten Ergebnisses  $\Upsilon_\tau$  muss entschieden werden, wie viele und welche Partikel im nächsten Iterationszyklus zur Verfügung stehen.

Die Anzahl  $F$  der für den nächsten Iterationszyklus benötigten Partikel wird, im Gegensatz zu den in [187, 193, 253, 254] beschriebenen Verfahren, durch eine lineare Funktion zwischen minimaler ( $F_{\min}$ ) und maximaler ( $F_{\max}$ ) Partikelanzahl in Abhängigkeit der aktuellen Unsicherheit  $\Sigma_{\Upsilon_\tau}$  formuliert. Über die Eigenwerte der Kovarianzmatrix  $\Sigma_{\Upsilon_\tau}$  werden die Längen der Hauptachsen bestimmt. Entsprechend der Länge der langen Halbachse (größerer Eigenwert)  $a$  ergibt sich die neue Anzahl an Partikeln für den Zeitschritt  $\tau + 1$  nach Gleichung (4.63). Die Parameter  $\epsilon_{\min}$  und  $\epsilon_{\max}$  geben die festgelegten Schranken für  $a$  wieder.

$$\begin{cases} a \geq \epsilon_{\max} & : F = F_{\max} \\ \epsilon_{\min} < a < \epsilon_{\max} & : F = \frac{F_{\max} - F_{\min}}{\epsilon_{\max} - \epsilon_{\min}} \cdot (a - \epsilon_{\min}) + F_{\min} \\ a \leq \epsilon_{\min} & : F = F_{\min} \end{cases} \quad (4.63)$$

Nachfolgend muss aus den im Zeitschritt  $\tau$  vorhandenen gewichteten Partikeln  $\mathcal{P}_\tau = \{s_{f,\tau}^{\text{Partikel}}\}_{f=1}^{F_\tau}$  eine neue Population von Partikeln  $\mathcal{P}_{\tau+1} = \{s_{f,\tau+1}^{\text{Partikel}}\}_{f=1}^{F_{\tau+1}}$  für den Zeitschritt  $\tau + 1$  erzeugt werden, wobei die Menge der Partikel  $F_{\tau+1}$  nach Gleichung (4.63) bestimmt wird.

Es ist wichtig, dass Partikel aus  $\mathcal{P}_\tau$ , die ein hohes Gewicht besitzen, möglichst viele neue Partikel in  $\mathcal{P}_{\tau+1}$  generieren, wohingegen Partikel mit niedrigem Gewicht keine oder nur wenige weitere Partikel erzeugen. Trotzdem darf ein zu schnelles Konvergieren der Partikel gegen eine

Hypothese nicht stattfinden. Es bietet sich das sogenannte „low variance resampling“ (dt. stochastisch-universelles Ziehen) aus [28, 90] an.

Abbildung 4.21 veranschaulicht das Verfahren beispielhaft. Die aktuellen Partikelgewichte  $\omega_f$  der jeweiligen Partikel  $s_f^{\text{Partikel}}$  werden entsprechend ihres Gewichtes auf der äußeren Scheibe verteilt. Je größer das Gewicht, desto mehr Fläche erhält das entsprechende Partikel auf der Scheibe. Die Pfeile werden im äquidistanten Abstand auf dem Kreis verteilt, wobei die Anzahl der Pfeile der neuen Partikelanzahl entspricht. Abschließend erfolgt ein zufälliges Drehen der Scheibe, was direkt zur neuen Partikelpopulation führt.




Abbildung 4.21: Visualisierung des Verfahrens zum stochastisch-universellen Ziehen (engl. low variance resampling)

In der Literatur werden weitere Verfahren [24, 28, 29, 90] zum bedingten Resampling (auch Resampling Conditions genannt) aufgeführt. Solche Methoden beschreiben, wann ein Resampling durchgeführt werden soll. Innerhalb des hier verwendeten Partikelfilters werden Resampling Conditions nicht direkt eingesetzt. Stattdessen wird bei jeder Iteration ein Resampling durchgeführt. Die Ausnahmen bilden der Stillstand des Fahrzeugs (das sogenannte Zero Velocity Update), eine leere Menge der Beobachtungen  $\mathcal{Z}$  oder ein leerer Kartenausschnitt  $\mathcal{M}$ . In diesen Fällen wird auf ein Resampling verzichtet und für die Partikelwolke gilt  $\mathcal{P}_\tau = \mathcal{P}_{\tau+1}$ .

Um das Steckenbleiben des PLM in einem lokalen Minimum einer Hypothese zu vermeiden, werden in jedem Schritt sogenannte Recovery-Partikel (dt. „Genesungspartikel“) um die aktuelle GPS-Pose gestreut. Das Generieren der Recovery-Partikel erfolgt nach dem beschriebenen Verfahren des Sampling-Schritts. Die Anzahl dieser Partikel ergibt sich aus dem empirisch ermittelten Parameter  $\kappa$ , der den Anteil der zu streuenden Recovery-Partikel beschreibt. Die Anzahl der Recovery-Partikel  $F^{\text{Recovery}}$  folgt aus Gleichung (4.64).

$$F^{\text{Recovery}} = F \cdot \kappa \quad (4.64)$$

## 4.4 Verfahren zur SPRT-Parameterermittlung und Kartenbewertung

Für das SPRT-basierte Track-Management des TFM (siehe TML in Kapitel 4.2.5) sind sowohl zur Erzeugung des konsistenten Landmarkenumfeldmodells durch Fusion und zeitlicher Nachverfolgung von Landmarken als auch für die daraus entstehende Landmarkenkarte des MML

spezielle Verfahren notwendig. Zum einen müssen die den Landmarken zugehörigen SPRT-Parameter ermittelt werden und zum anderen müssen die generierten Karten bewertet werden können. Zur Erfüllung der Verfahren werden für die eingeführten Landmarkentypen (vgl. Kapitel 4.1.1) die bekannten Zählweisen aus dem Bereich der Mustererkennung (engl. pattern recognition) sowie der Informationsgewinnung (engl. information retrieval) für Genauigkeit (engl. Precision), Empfindlichkeit bzw. Trefferquote (engl. Recall) und dem daraus bestimmbareren F1-Score herangezogen [255]. Die Wahrscheinlichkeit für Genauigkeit und Empfindlichkeit ergibt sich entsprechend Gleichung (4.65).

$$\begin{aligned} \text{Genauigkeit} &:= P(\text{richtig positiv erkannt}|\text{positiv erkannt}) = \frac{r_p}{r_p+f_p} \\ \text{Empfindlichkeit} &:= P(\text{positiv erkannt}|\text{tatsächlich positiv}) = \frac{r_p}{r_p+f_n} \end{aligned} \quad (4.65)$$

Es bezeichnet  $r_p$  die sogenannten Richtig-Positiven (Landmarke ist vorhanden, und der Detektor hat sie richtig erkannt),  $f_p$  die Falsch-Positiven (Landmarke ist nicht vorhanden, der Detektor hat aber fälschlicherweise eine erkannt) und  $f_n$  die Falsch-Negativen (Landmarke ist vorhanden, der Detektor hat aber fälschlicherweise keine erkannt). Das harmonisches Mittel aus Genauigkeit und Empfindlichkeit bildet den F-Score, der in Gleichung (4.66) gegeben ist.

$$\text{F-Score} := 2 \cdot \frac{\text{Genauigkeit} \cdot \text{Empfindlichkeit}}{\text{Genauigkeit} + \text{Empfindlichkeit}} \quad (4.66)$$

Aufbauend auf den Definitionen, ist in Kapitel 4.4.1 das Verfahren zur Ermittlung der SPRT-Parameter und in Kapitel 4.4.2 das Verfahren zur Kartenbewertung erläutert. Die zugehörigen Zählweisen der Landmarken sind in den Kapiteln verdeutlicht. Mit dem Verfahren zur SPRT-Parameterermittlung wird direkt eine Aussage über die Qualität der landmarkenbereitstellenden Sensorik geliefert und mit dem Verfahren zur Kartenbewertung sowohl eine quantitative als auch qualitative Beurteilung zweier unterschiedlicher Karten zur Verfügung gestellt. Insbesondere ermöglicht das Kartenbewertungsverfahren Rückschlüsse auf die Robustheit, die Ähnlichkeit und die räumliche Verteilung der Landmarken.

#### 4.4.1 SPRT-Parameterermittlung

Den Erläuterungen in Kapitel 4.2.5 folgend, sind für die Verwendung des SPRT-basierten Verfahrens im TFM die Parameter  $P_D$ ,  $\beta_{NT}$  und  $\beta_{FA}$  für jeden Landmarkentyp je Sensorik zu ermitteln. Diese Parameter bestimmen die Berechnung des Konfidenzwertes LLR einer verwalteten Track-Landmarke im Landmarkenumfeldmodell. Das erfolgt mit den vorgestellten Gleichungen (4.25) für die positive Korrespondenzbestimmung und (4.26) für die negative Korrespondenzbestimmung beim Eingang einer neuen Messung. Tabelle 4.2 fasst die Beschreibung der SPRT-Parameter und deren Definition zusammen.

Zur Bestimmung der benötigten Parameter  $P_D$ ,  $\beta_{NT}$  und  $\beta_{FA}$  wird die Zählweise für Genauigkeit und Empfindlichkeit angewendet. Der Parameter  $P_D$  entspricht direkt der Definition der Genauigkeit. Folglich wird  $\beta_{NT}$  als Genauigkeit der neuen möglichen Ziele und  $\beta_{FA}$  als Empfindlichkeit aller falsch wiedererkannten Ziele aufgefasst.

Sei nun  $\mathcal{G}$  eine Referenzkarte (engl. Ground Truth) sowie  $\mathcal{B}_{\tau-1}^n$  und  $\mathcal{B}_{\tau}^n$  zwei aufeinanderfolgende Messungen des  $n$ -ten Sensors zu den Zeitpunkten  $\tau - 1$  und  $\tau$ . Die Mengen  $\mathcal{G}$ ,  $\mathcal{B}_{\tau-1}^n$

Tabelle 4.2: Beschreibung der SPRT-Parameter

Parameter	Name	Beschreibung
$P_D$	Probability Detection	Wahrscheinlichkeit, dass in einer Messung ein echtes Ziel enthalten ist
$\beta_{NT}$	New Target Rate	Wahrscheinlichkeit, dass in einer Messung ein neues Ziel enthalten ist
$\beta_{FA}$	False Alarm Rate	Wahrscheinlichkeit, dass in einer Messung ein falsches Ziel enthalten ist

und  $\mathcal{B}_\tau^n$  enthalten entsprechend der Beschreibung in Kapitel 4.1.1 die jeweiligen Landmarken. Es werden zu jedem Zeitpunkt  $\tau$  die Parameter  $P_{\tau,D}$ ,  $\beta_{\tau,NT}$  und  $\beta_{\tau,FA}$  durch Vergleichen und Zählen der Landmarken zwischen der Referenzkarte  $\mathcal{G}$  und der erhaltenen Messung  $\mathcal{B}_\tau^n$ , also die Menge der detektierten Landmarken, ermittelt. Die Menge  $\mathcal{B}_\tau^n$  wird in die Mengen  $\mathcal{D}_\tau$ ,  $\mathcal{D}_{\tau,NT}$  und  $\mathcal{D}_{\tau,FA}$  entsprechend Gleichung (4.67) unterteilt. Der Laufindex  $k$  steht für die Karenzzeit (den betrachteten Horizont).

$$\mathcal{D}_\tau = \mathcal{B}_\tau^n; \quad \mathcal{D}_{\tau,NT} = \mathcal{B}_\tau^n \setminus \left( \bigcup_{i=1}^{k-1} \mathcal{B}_i^n \right); \quad \mathcal{D}_{\tau,FA} = \left( \bigcup_{i=1}^{k-1} (\mathcal{B}_\tau^n \cap \mathcal{B}_{\tau-i}^n) \right) \setminus \mathcal{G} \quad (4.67)$$

Der Term  $\mathcal{D}_\tau$  entspricht der Menge aller Landmarken einer eingegangenen Messung und wird direkt zur Berechnung des Parameters  $P_{\tau,D}$  (der Genauigkeit) verwendet. Die Menge  $\mathcal{D}_{\tau,NT}$  enthält alle neuen möglichen Ziele und  $\mathcal{D}_{\tau,FA}$  alle falsch wiedererkannten Landmarken. Diese Mengen führen durch Anwendung der Zählweisen für Genauigkeit und Empfindlichkeit zu den gesuchten Werten der Parameter  $\beta_{\tau,NT}$  und  $\beta_{\tau,FA}$ . Gleichung (4.68) formuliert die definierte Zählweise.

$$\begin{aligned} P_{\tau,D} &:= P(\text{richtig positiv erkannt} | \text{positiv erkannt}) \\ &= r_p / (r_p + f_p), \text{ wobei } r_p, f_p \text{ aus } \mathcal{D}_\tau \\ \beta_{\tau,NT} &:= P(\text{richtig positiv-neu erkannt} | \text{positiv-neu erkannt}) \\ &= r_p / (r_p + f_p), \text{ wobei } r_p, f_p \text{ aus } \mathcal{D}_{\tau,NT} \\ \beta_{\tau,FA} &:= P(\text{positiv falsch wiedererkannt} | \text{tatsächlich positiv falsch}) \\ &= r_p / (r_p + f_n), \text{ wobei } r_p, f_n \text{ aus } \mathcal{D}_{\tau,FA} \end{aligned} \quad (4.68)$$

Diese spezielle Zählweise wird je Messdateneingang, also sequenziell in einem Vorverarbeitungsschritt mit Hilfe der Referenzkarte  $\mathcal{G}$ , durchgeführt. Die Parameter  $P_{\tau,D}$ ,  $\beta_{\tau,NT}$  und  $\beta_{\tau,FA}$  werden je Zeitschritt  $\tau$  für jeden Landmarkentyp pro Sensorik ermittelt. Um die gesuchten Werte für  $P_D$ ,  $\beta_{NT}$  und  $\beta_{FA}$  aus den einzelnen Zeitschritten zu erhalten, wird der Bereich vor dem Fahrzeug in  $i$  Intervalle, Bins genannt, aufgeteilt. Die Aufteilung erfolgt auf Basis der ermittelten Sichtbereiche der Sensoren (vgl. Kapitel 3.1.4). Das ermöglicht es, die Parameterwerte in Beziehung zur Entfernung zu setzen. Die berechneten und in ihre zugehörigen Bins eingeteilten Parameterwerte  $P_{\tau,D}$ ,  $\beta_{\tau,NT}$  und  $\beta_{\tau,FA}$  der einzelnen Landmarken sind nachfolgend mit  $P_{\tau,D}^i$ ,  $\beta_{\tau,NT}^i$  und  $\beta_{\tau,FA}^i$  bezeichnet.

Die Parameterwerte  $P_D^i$ ,  $\beta_{NT}^i$  und  $\beta_{FA}^i$  für den  $i$ -ten Bin ergeben sich aus dem Durchschnitt der einsortierten Werte des Bins. Abschließend berechnen sich  $P_D$ ,  $\beta_{NT}$  und  $\beta_{FA}$  als Durchschnitt über alle Bins. Gleichung (4.69) zeigt den beschriebenen Berechnungsschritt, während Abbildung 4.22 das aufgeführte Verfahren schematisch aufgezeigt.

$$\begin{aligned}
 P_D &= \underbrace{\left( \sum_{i=0}^I \underbrace{\left[ \left( \sum_{t=0}^T P_{\tau,D}^i \right) / T \right]}_{\text{Durchschnittsberechnung aller } P_{\tau,D}^i\text{-Werte des } i\text{-ten Bins zu } P_D^i} \right)}_{\text{Berechnung von } P_D \text{ über den Durchschnitt aller } P_D^i} / I \\
 \beta_{NT} &= \underbrace{\left( \sum_{i=0}^I \underbrace{\left[ \left( \sum_{t=0}^T \beta_{\tau,NT}^i \right) / T \right]}_{\text{Durchschnittsberechnung aller } \beta_{\tau,NT}^i\text{-Werte des } i\text{-ten Bins zu } \beta_{NT}^i} \right)}_{\text{Berechnung von } \beta_{NT} \text{ über den Durchschnitt aller } \beta_{NT}^i} / I \\
 \beta_{FA} &= \underbrace{\left( \sum_{i=0}^I \underbrace{\left[ \left( \sum_{t=0}^T \beta_{\tau,FA}^i \right) / T \right]}_{\text{Durchschnittsberechnung aller } \beta_{\tau,FA}^i\text{-Werte des } i\text{-ten Bins zu } \beta_{FA}^i} \right)}_{\text{Berechnung von } \beta_{FA} \text{ über den Durchschnitt aller } \beta_{FA}^i} / I
 \end{aligned} \tag{4.69}$$

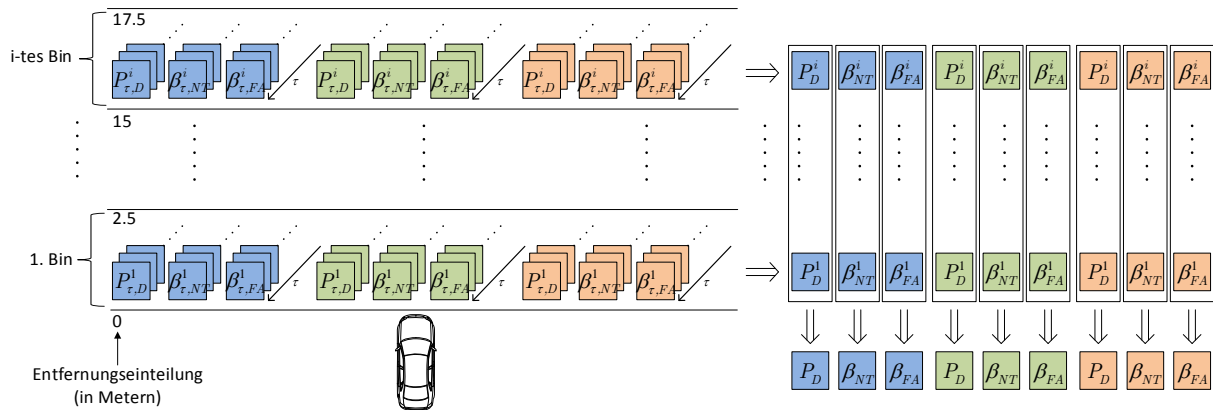


Abbildung 4.22: Schematische Darstellung des Verfahrens zur SPRT-Parameterermittlung für verschiedene Landmarkentypen je Messung (farblich gekennzeichnet)

Gleichung (4.69) gibt mit  $I$  die Anzahl der Bins und mit  $T$  die Anzahl der Messungen an. Die unterschiedlichen Landmarkentypen sind in Abbildung 4.22 farblich codiert (punktbasierte Landmarken hellblau, linienbasierte Landmarken hellgrün und polylinienbasierte Landmarken hellorange). Im linken Teil ist die Aufteilung des Sichtbereiches in  $i$  Bins visualisiert (horizontale Linien vor dem Fahrzeug). Jedes Rechteck entspricht einem berechneten Parameterwert für  $P_{\tau,D}^i$ ,  $\beta_{\tau,NT}^i$  und  $\beta_{\tau,FA}^i$  einer Messung zum Zeitpunkt  $\tau$ . Im rechten Teil sind die sich aus  $P_{\tau,D}^i$ ,  $\beta_{\tau,NT}^i$  und  $\beta_{\tau,FA}^i$  über den gesamten Zeitverlauf  $\tau$  ergebenden spezifischen Parameter-



werte  $P_D^i$ ,  $\beta_{NT}^i$  und  $\beta_{FA}^i$  je Bin aufgezeigt (vertikale rechteckige Kästen). Die Pfeile zu den Parameterwerten  $P_D$ ,  $\beta_{NT}$  und  $\beta_{FA}$  stellen die abschließende Durchschnittsberechnung für jeden Landmarkentyp dar.

Die Berechnung von  $r_p, f_p$  und  $f_n$  in den einzelnen erzeugten Mengen  $\mathcal{D}_\tau, \mathcal{D}_{\tau,NT}$  und  $\mathcal{D}_{\tau,FA}$  erfolgt für die punktbasierten, linienbasierten und polylinienbasierten Landmarken durch Korrespondenzermittlung zu den jeweiligen Landmarken in der Referenzkarte  $\mathcal{G}$ . Das erfolgt in jedem Bin mit den Distanzfunktionen aus Kapitel 4.2.4. Für punktbasierte und linienbasierte Landmarken ist das direkt möglich. Bei polylinienbasierten Landmarken erfolgt eine Stückelung sowohl der Kartenlandmarken als auch der Landmarken in den Messungen für die einzelnen Bins. Im Anschluss wird die Korrespondenzbestimmung entsprechend der Distanzfunktion in jedem Bin durchgeführt.

## 4.4.2 Kartenbewertung

Werden für die Kartenerzeugung und die Lokalisierung die genannten klassifizierten Charakteristika der Straßeninfrastruktur verwendet, sind die Landmarken auf ihre Tauglichkeit zu untersuchen. Die Tauglichkeit beschreibt im Kontext selbstfahrender PKW die Robustheit, die räumliche Verteilung und die Wiedererkennung der Landmarken in dem dynamischen Arbeitsraum.

Die Tauglichkeit könnte direkt aus dem Ergebnis der Lokalisierung abgeleitet werden. Jedoch beantwortet eine präzise Lokalisierung nicht direkt die Fragestellung der räumlichen Verteilung und der Robustheit der Kartenlandmarken. Vor allem in Hinblick auf die Randbedingung der dezentralen Karte (R1) kann mit einem solchen Vorgehen keine Aussage getroffen werden. Deshalb wird in dieser Arbeit, auf Basis von Genauigkeit, Empfindlichkeit und dem F1-Score, eine neue Methode vorgestellt, um die Gleichheit von zwei erzeugten Karten zu beurteilen.

Es besteht die Herausforderung, bei zwei gegebenen Karten eine Aussage über deren Gleichheit bzw. Ähnlichkeit zu treffen. Von besonderem Interesse sind die Aspekte der räumlichen Verteilung der Kartenlandmarken, deren Wiedererkennung und Robustheit im Hinblick auf z.B. infrastrukturelle Veränderungen oder Verdeckungen. Um die Fragestellungen zu beantworten, ermöglicht das vorgestellte Verfahren eine orts aufgelöste Aussage der zu vergleichenden Karten.

Die Eingangsdaten des Verfahrens ergeben sich aus zwei Karten und einer Trajektorie. Die Trajektorie beschreibt den zu untersuchenden Teilbereich bzw. die zu untersuchende Teilstrecke der Karten. Entlang der Trajektorie wird schrittweise durch beide Karten gegangen und an jeder Stelle ein kreisförmiger Bereich der Karten ausgeschnitten. Die Schrittweite  $x$  und der Radius  $y$  des Kreisausschnittes sind zu Beginn des Verfahrens frei wählbar. Beide Parameter beschreiben die „Auflösung“ der Methode. Abbildung 4.23 stellt das Verfahren exemplarisch dar. Die Trajektorie ist blau eingefärbt und die Landmarken in den einzelnen Vergleichsbereichen sind grün dargestellt. Die Vergleichsbereiche sind als einzelne schwarze Kreise abgebildet, wobei der aktuell betrachtete Kreis ausschnitt rot eingefärbt ist. Alle anderen Landmarken in den Karten, die nicht in einen der Vergleichsbereiche fallen, sind entsprechend ihres Typs andersfarbig veranschaulicht (orange für gestrichelte Linien, gelb für Pfeile und magenta für durchgezogene Linien).




Abbildung 4.23: Exemplarische Unterteilung der Fahrzeugtrajektorie durch Kreisabschnitte

In jedem Kreisabschnitt werden die Landmarken der beiden Karten verglichen. Der Vergleich, also die Korrespondenzbestimmung, wird mit den bereits eingeführten Distanzfunktionen vollzogen (siehe Kapitel 4.2.4). Für das Verfahren wird die erste Karte als „Referenz“ verwendet, auf deren Grundlage die Richtig-Positiven ( $r_p$ ), Falsch-Positiven ( $f_p$ ) und Falsch-Negativen ( $f_n$ ) Landmarken gezählt werden. Anschließend werden für jeden Kreisabschnitt die Genauigkeit und Empfindlichkeit entsprechend Gleichung (4.65) berechnet.

Abbildung 4.24 zeigt die beschriebene Methode schematisch auf. Im linken Teil ist die erste Karte und im rechten Teil die zweite Karte dargestellt. Die Landmarken, unabhängig vom jeweiligen Typ, sind in der ersten Karte mit A und in der zweiten Karte mit B gekennzeichnet. Zusätzlich sind zwei Kreisabschnitte als die Bereiche, in denen der Vergleich stattfindet, skizziert. Es symbolisiert der durchgezogene Kreisabschnitt  $i$  den aktuell betrachteten Vergleichsbereich und der gestrichelte Kreisabschnitt  $i + 1$  den um die Schrittweite  $x$  verschobenen nächsten Vergleichsbereich. Für jeden dieser Kreisbereiche werden die Genauigkeit und die Empfindlichkeit nach dem oben beschriebenen Vorgehen ermittelt.




Abbildung 4.24: Schematische Darstellung des Kartenvergleiches je Kreisabschnitt

Die ermittelte Genauigkeit gibt an, wie viel Prozent der Landmarken aus der zweiten Karte den Landmarken der ersten Karte zugeordnet sind. Die Empfindlichkeit hingegen sagt aus, wie viel Prozent der Landmarken aus der ersten Karte einer Landmarke aus der zweiten Karte

zugewiesen sind. Es wird, falls in beiden Karten keine Landmarken vorhanden sind, der Wert 0 für Genauigkeit und Empfindlichkeit verwendet. Das verhindert eine fälschlicherweise zu gute Bewertung des Vergleichsbereiches.

Als Ähnlichkeitsmaß beider verglichenen Karten dient direkt der F1-Score (harmonisches Mittel aus Genauigkeit und Empfindlichkeit, siehe Gleichung (4.66)). Der F1-Score wird je Kreisausschnitt berechnet und entlang der Trajektorie visualisiert. Es ergibt sich eine orts aufgelöste, farbcodierte Aussage für die Ähnlichkeit und räumliche Verteilung der Kartenlandmarken. Abbildung 4.25 visualisiert das Prinzip.




Abbildung 4.25: Schematische Darstellung der orts aufgelösten Ähnlichkeitsanalyse zweier Karten

Jeder Beurteilungsparameter (Genauigkeit, Empfindlichkeit und Ähnlichkeit) nimmt einen Wertebereich zwischen 0 und 1 an. Eine geringe Ähnlichkeit korrespondiert mit einem kleinen Wert und eine hohe Ähnlichkeit mit einem großen Wert. Ein Ähnlichkeitswert von 1 spiegelt eine vollständige Deckungsgleichheit wider, wohingegen ein Wert von 0 bedeutet, dass es überhaupt keine Übereinstimmung zwischen beiden Karten gibt. Wird die Differenz der Landmarkenanzahl je Kreisausschnitt gebildet und entsprechend der Ähnlichkeit visualisiert, sind Aussagen über Anzahl und räumliche Verteilung der Landmarken gegeben.

Mit dem beschriebenen Verfahren zur Ermittlung von Genauigkeit, Empfindlichkeit, Ähnlichkeit und Landmarkenanzahl werden sowohl direkt qualitative als auch quantitative Aussagen über Wiedererkennbarkeit, räumliche Verteilung und Ähnlichkeit von zwei unterschiedlichen Karten abgeleitet. Die verschiedenen Landmarkentypen sind mit dem Verfahren auf ihre Robustheit und Nutzbarkeit für die LbL überprüfbar. Insbesondere ermöglicht das Verfahren, eine Karte hinsichtlich ihrer Qualität zu beurteilen, falls die erste Karte eine echte Referenzkarte hoher Qualität ist.

## 4.5 Zusammenfassung

In diesem Kapitel wurden die entwickelten Verfahren dieser Arbeit detailliert vorgestellt. Zuerst wurde in Kapitel 4.1 eine Übersicht der Landmarkenbasierten Lokalisierung (LbL) gegeben

und die Repräsentationsform der verwendeten klassifizierten Objekte der Straßeninfrastruktur beschrieben. Im Gegensatz zu anderen Verfahren sind die Landmarken entsprechend ihrer geometrischen Form modelliert. Aufbauend auf der eingeführten Architektur der LbL, sind die beiden neuen Verfahren, das Tracking- & Fusionsmodell (TFM) und das Partikelfilterbasierte Lokalisierungsmodell (PLM), in Kapitel 4.2 und Kapitel 4.3 erläutert.

Das TFM erzeugt durch Fusion der Landmarken aus unterschiedlichen Sensoren und zeitliche Nachverfolgung sowohl ein konsistentes Landmarkenumfeldmodell als auch eine Karte. Entsprechend den Abstraktionsgraden der Landmarken (Eingangsdaten der Sensoren, Landmarkenumfeldmodell durch Fusion und zeitliche Nachverfolgung sowie Kartenerzeugung; vgl. Kapitel 4.1.1) ist das TFM in drei Schichten eingeteilt. Die Landmarken werden in allen drei Ebenen in den geometrischen Grundprimitiven Punkt, Linie und Polylinie repräsentiert sowie verarbeitet (erfüllt Randbedingung R2 (Invariante, semi-persistente Umgebungsmerkmale in vielfältigen Außenszenarien) und R3 (Zweidimensionale, sensorische Umgebungswahrnehmung mit Seriensensorik)). Das TFM arbeitet sowohl unabhängig von den verwendeten Bewegungsinformationen (globale Poseschätzung und Eigenbewegungsschätzung) als auch von den Sensoreingängen. Es erzeugt während der Kartierungs- und der Lokalisierungsphase eine Karte, in der die eingetragenen Landmarken WGS84-referenziert sind. Es bildet den Grundbaustein der Randbedingungen R1 (Dezentrale Karte) und R4 (Initiales Vorwissen). Der effiziente Ansatz des statistischen Tests, dem Sequential Probability Ratio Test (SPRT), wird als Track-Management eingesetzt. Das SPRT-Verfahren wurde so angepasst, dass es für die beschriebenen Landmarken einsetzbar ist. Zum Aufbau des konsistenten Landmarkenumfeldmodells sind die benötigten Distanzfunktionen zur Korrespondenzbestimmung aufgestellt und erläutert worden.

Für die präzise Lokalisierung im PLM wurde das probabilistische Verfahren eines Partikelfilters angewendet. Durch Variation der Partikelanzahl im PLM kann die Randbedingung R6 (Zeitstempel und Zeitverhalten) erfüllt werden. Es wurde ein neues Sensormodell für die Zuordnung von Kartenlandmarken zu Beobachtungen aufgestellt, das die Einschränkungen aus den Randbedingungen R2 und R3 berücksichtigt. Im Gegensatz zu bisherigen Assoziierungsverfahren führt dieses Sensormodell eine effiziente, implizite Datenzuordnung zu allen Elementen durch. Im Vergleich zu z.B. NN- oder GNN-Ansätzen bietet es den Vorteil, dass keine explizite Eins-zu-Eins-Zuweisung erfolgt. Zusätzlich zum neu aufgestellten Sensormodell sind Verfahren des Bewegungsmodells (zur Einhaltung der Randbedingung R5 (Zweidimensionale Fahrzeugbewegung)), Resamplings und Samplings für die Verwendung in selbstfahrenden Kraftfahrzeugen adaptiert worden.

Abschließend ist in Kapitel 4.4 ein empirisches Verfahren, auf Basis von Genauigkeit und Empfindlichkeit, zur Ermittlung der benötigten SPRT-Parameter vorgestellt worden. Es liefert nicht nur die gesuchten Parameter für die sensorspezifische Fusion der Landmarken im TFM, sondern stellt auch die zu erwartende Zuverlässigkeit der Sensorik dar. Ebenso wurde in diesem Kapitel eine Methode vorgestellt, mit der erzeugte Karten auf Ähnlichkeit zueinander vergleichbar sind. Diese Methode quantifiziert die Qualität der verglichenen Karten in einer orts aufgelösten Darstellung, womit Fragestellungen nach räumlicher Verteilung oder Anzahl der wiedererkannten Landmarken beantwortet werden können.

Die vorgestellte Architektur der LbL mit den beiden Verfahren TFM und PLM trägt den aufgestellten Randbedingungen R1 bis R7 Rechnung und ermöglicht eine präzise Lokalisierung.

# Kapitel 5

## Experimentelle Untersuchungen und Ergebnisse

Nachdem in Kapitel 4 die Landmarkenbasierte Lokalisierung (LbL) vorgestellt wurde, wird der Ansatz in diesem Kapitel anhand einiger Experimente überprüft und seine Verwendbarkeit herausgearbeitet. Der Schwerpunkt liegt auf dem Nachweis der präzisen Lokalisierung anhand des Verfahrens aus Kapitel 4.3 mit einer erstellten Karte entsprechend des Ansatzes aus Kapitel 4.2.

Dieses Kapitel unterteilt sich in drei Unterkapitel. Zuerst wird in Unterkapitel 5.1 das Experiment zur Ermittlung der benötigten SPRT-Parameter für das Tracking- & Fusionsmodell (TFM) vorgestellt. Im Anschluss wird die eingeführte LbL in Unterkapitel 5.2 untersucht. Zuerst wird das betrachtete Szenario beschrieben. Nachfolgend wird in Teilkapitel 5.2.2 die durchgeführte Kartierung mit dem Bewertungsverfahren aus Kapitel 4.4 diskutiert. Im darauffolgenden Teilkapitel 5.2.3 erfolgt die Auswertung der Lokalisierung. Das letzte Experiment des Unterkapitels 5.3 dient als unabhängige Untersuchung eines Teilaspektes zur Optimierung der Sichtbereiche und Analyse ihrer Auswirkungen auf die Lokalisierung.

Die durchgeführten Experimente sind Praxisversuche mit realen Daten und unter realen Bedingungen. Es wurde der in Kapitel 3.1 vorgestellte Versuchsträger verwendet. Es kam die beschriebene Sensorik zum Einsatz, deren genaue Spezifikationen sowohl in Kapitel 3.1 als auch im zugehörigen Anhang A aufgeführt sind. Lediglich im Unterkapitel 5.3 wurde aus Gründen der Reproduzierbarkeit eine Simulation zur Parameteroptimierung und Evaluierung eingesetzt. Insgesamt wurde jedes Experiment mehrmals durchgeführt. Im Folgenden sind exemplarisch die Ergebnisse dezidierter Versuche der Experimente aufgezeigt, da sich die einzelnen Ergebnisse der separaten Versuche gleichbleibend verhalten. Sind mehrere Versuche eines Experimentes zusammengefasst, wird im Text darauf hingewiesen. Ebenso werden ggf. spezielle Sensorik-konfigurationen oder der Ausschluss bestimmter Sensorik in jedem Experiment angegeben. Weiterführende Informationen sind in Anhang D aufgeführt. Entsprechende Verweise sind an den benötigten Stellen im Text gegeben. Zum Vergleich der Kartengrößen für die erläuterten Versuchsstrecken sei hier bereits auf Kapitel 5.2.4 verwiesen.

Mit den durchgeführten Experimenten erfolgt eine anschauliche und systematische Überprüfung des vorgestellten Verfahrens zur Kartierung und Lokalisierung von selbstfahrenden Kraftfahrzeugen in realen Szenarien. Es werden wertvolle Informationen über die Einsetzbarkeit der entwickelten Verfahren gegeben und ein Beitrag zur experimentellen Robotik geliefert.

## 5.1 SPRT-Parameterermittlung

In diesem Experiment werden mit dem empirischen Verfahren aus Kapitel 4.4 die benötigten SPRT-Parameter  $P_D$ ,  $\beta_{NT}$  und  $\beta_{FA}$  ermittelt. Das erfolgt für jeden Sensor und seine detektierbaren Landmarken (vgl. Tabelle 3.1 und Tabelle 4.1). Die hier ermittelten Parameter bilden die Grundlage sowohl zur Erzeugung des konsistenten Landmarkenumfeldmodells als auch der Kartengenerierung im TFM. Diese Parameter werden in den nachfolgenden Experimenten weiterverwendet.

Zuerst wird die Durchführung des Experimentes beschrieben. Im Anschluss folgt die Präsentation und Erläuterung der Ergebnisse. Eine kurze Zusammenfassung der Untersuchung bildet den Abschluss.

### 5.1.1 Durchführung

Die Durchführung der Parameterbestimmung folgt dem Verfahren aus Kapitel 4.4. Es wird die eingeführte Zählweise für die Parameter Probability Detection ( $P_D$ , Genauigkeit einer Detektion), New Target Rate ( $\beta_{NT}$ , Erkennungsrate von neuen Zielen) und False Alarm Rate ( $\beta_{FA}$ , Wiedererkennungsrage von falschen Zielen) verwendet. Um die Zählweise durchzuführen, muss eine „absolute Wahrheit“ (engl. Ground Truth) bekannt sein. Nur so lassen sich die wahrgenommenen Landmarken als Richtig-Positive, Falsch-Positive und Falsch-Negative einteilen.

Da im Gegensatz zu Gebäudeumrissen, die beispielsweise in Liegenschaftskarten des Katasteramtes hinterlegt sind, keine Referenzkarte der Straßeninfrastruktur für Fahrbahnmarkierungen und säulenförmige Objekte kommerziell erstanden werden kann, wurde eine solche Referenzkarte im Rahmen des Experimentes erzeugt. Es wurde eine Versuchsstrecke definiert und durch hochgenaue georeferenzierte Luftbilder [256] eine Ground Truth erzeugt. Die Elemente der Straßeninfrastruktur wurden aus den georeferenzierten Luftbildern „abgeklickt“ und in das benötigte Kartenformat umgewandelt. Bei der Versuchsstrecke handelt es sich um den in Abbildung 5.1 dargestellten städtischen Abschnitt. Der Abschnitt startet bei Punkt A mit den WGS84-Koordinaten (52.423416, 10.748314) und endet bei Punkt B mit den Koordinaten (52.424257, 10.717625). Insgesamt hat die Versuchsstrecke eine Länge von 2.3 Kilometern. Sie beinhaltet drei Kreuzungsbereiche, mehrere Kurven, sowohl einspurige als auch zweispurige Straßenabschnitte. Eine Brückenüberfahrt mit Steigung und Gefälle ist ebenso Bestandteil der Versuchsstrecke. In Anhang D.1 ist eine genauere Beschreibung mit einer separaten Darstellung der einzelnen Streckenabschnitte gegeben. Insgesamt wird eine Vielzahl von unterschiedlichen Gegebenheiten durch die Strecke abgedeckt. Abbildung 5.2 zeigt exemplarisch die erzeugte Referenzkarte mit dem zugehörigen Luftbild auf. Der dargestellte Abschnitt entspricht der Straßeninfrastruktur um die WGS84-Position (52.4235947, 10.7483416). Die unterschiedlichen Landmarken sind in verschiedenen Farben visualisiert. Durchgezogene Linien (polylinienbasierte Landmarken) sind in Hellgrün dargestellt. Den linienbasierten Landmarken (Pfeile, gestrichelte Linien und Haltelinien) sind die Farben Orange/Rot (je nach Pfeiltyp), Türkis (gestrichelte Linien) und Lila (Haltelinien) zugeordnet. Säulenförmige Objekte (Pfähle und Pfosten) sind mit gelben Rechtecken veranschaulicht.



Abbildung 5.1: Urbane Versuchsstrecke für die SPRT-Parameterermittlung, Luftbild aus [257]




Abbildung 5.2: Ausschnitt der erzeugten Referenzkarte (unten) aus dem georeferenzierten Luftbild (oben)

Mit der erzeugten Referenzkarte wird die beschriebene Zählung der Landmarken aus Kapitel 4.4 durchgeführt. Die Strecke wurde vom Startpunkt A zum Endpunkt B abgefahren und jede eingehende Messung mit der Referenzkarte verglichen. Die Landmarken wurden entsprechend ihrer Entfernung in  $i$  Abstandsintervalle eingeteilt. Die entsprechenden Zähler ( $P_{\tau,D}^i$ ,  $\beta_{\tau,NT}^i$  und  $\beta_{\tau,FA}^i$ ) der Parameter  $P_D$ ,  $\beta_{NT}$  und  $\beta_{FA}$  sind mit jeder Messung aktualisiert worden. Nach Abschluss der Fahrt wurde der Durchschnitt in jedem Abstandsintervall gebildet.

Damit während der Fahrt keine fehlerhaften Korrespondenzbestimmungen zwischen Messungen und Referenzkarte durch ungenaue Fahrzeugposen erfolgen, wird als Eigenbewegungsschätzung und globale Poseschätzung die Ortungsreferenzeinheit (vgl. Kapitel 3.1) eingesetzt. Da lediglich die Sensorik mit dem Verfahren bewertet wird, ist die Herangehensweise nötig, um andere Fehlerquellen auszuschließen.



## 5.1.2 Ergebnisse

Nachfolgend sind die ermittelten Ergebnisse präsentiert. Die aufgeführten Resultate sind ein exemplarischer Auszug einer Fahrt auf der genannten Versuchsstrecke. Insgesamt erfolgten zehn Fahrten (jeweils von A nach B und zurück), deren Auswertung dem exemplarischen Auszug gleicht. Die Fahrten wurden unter realen Bedingungen durchgeführt, wobei bei jeder Fahrt auf ähnliche Konstellationen geachtet wurde (Trockenheit, leicht bewölkter Himmel, mittleres Verkehrsaufkommen).

Aufgrund der Parameterermittlung je Landmarkentyp pro Sensor werden die Ergebnisse der einzelnen Sensoren im Folgenden separat aufgezeigt. Die Resultate je Abstandsintervalle, also  $P_D^i$ ,  $\beta_{NT}^i$  und  $\beta_{FA}^i$ , sind jeweils mit einem Stern pro  $i$ -tem Intervall gekennzeichnet. Die Werte sind jeweils in Abhängigkeit zur Entfernung vom Sensor angegeben. Für alle nachfolgenden Abbildungen gilt, dass im linken Teil der ermittelte Verlauf des Parameters Probability Detection ( $P_D$ , Genauigkeit einer Detektion), im mittleren Teil die New Target Rate ( $\beta_{NT}$ , Erkennungsrate von neuen Zielen) und im rechten Teil die False Alarm Rate ( $\beta_{FA}$ , Wiedererkennungsrates von falschen Zielen) veranschaulicht ist.

### 5.1.2.1 Laserscanner

Bei der eingesetzten Detektionsmethode handelt es sich um das in dieser Arbeit entwickelte und in Teilkapitel 3.1.4.1 beschriebene Verfahren. Durch die Definition der SPRT-Parameter sind deren Werte direkt als Maß für die Güte der Sensorik interpretierbar. In Bezug auf das Detektionsverfahren des Laserscanners ist das von besonderem Interesse, da so eine Bewertungsgrundlage für die entwickelte Landmarkenerkennung zur Verfügung steht.

Der Laserscanner liefert mit jeder Messung linienbasierte und punktbasierte Landmarken (vgl. Tabelle 4.1). Werden die erhaltenen Messungen entsprechend des Verfahrens zur Parameterermittlung verarbeitet, ergeben sich für die punktbasierten und linienbasierten Landmarken die in Abbildung 5.3 gezeigten Resultate.




Abbildung 5.3: SPRT-Parameter des Laserscanners (links: Probability Detection, mittig: New Target Rate, rechts: False Alarm Rate)

Im ersten Diagramm ist deutlich zu sehen, dass die Genauigkeit für linienbasierte Landmarken fast kontinuierlich bei ca. 0.7 liegt und unabhängig vom Abstand zum Sensor ist, während bei punktbasierten Landmarken die Genauigkeit mit zunehmender Entfernung schlechter wird.



Aufgrund der Repräsentation punktbasierter Landmarken wird die Verschlechterung auf mögliche Winkelfehler zurückgeführt.

Das mittlere Diagramm gibt die Verläufe der Erkennungsrate für mögliche neue Ziele wieder. Die linienbasierten Landmarken zeigen wiederum einen sehr stabilen Verlauf bei einem Wert von ca. 0.7. Sie sind, unabhängig von der Entfernung zum Sensor, in jeder neuen Messung gut detektierbar. Die Rate der Erkennung von neuen Zielen punktbasierter Landmarken wird in Abhängigkeit der Entfernung schlechter. Es werden also mit steigender Entfernung weniger punktbasierte Landmarken detektiert.

Das rechte Diagramm zeigt die Wiedererkennungsraten von falschen Zielen, also fehlerhafte Detektionen, die in mehreren Messungen vorhanden sind. Während für punktbasierte Landmarken ein leichter Anstieg der Fehlerquote erkennbar ist, sind linienbasierte Landmarken näherungsweise konstant bei einer Rate von ca. 0.3.

### 5.1.2.2 Front-Monokamera

Für die verwendete Front-Monokamera ergeben sich die in Abbildung 5.4 ermittelten Resultate der Parameterbestimmung für linienbasierte und polylinienbasierte Landmarken.




Abbildung 5.4: SPRT-Parameter der Front-Monokamera (links: Probability Detection, mittig: New Target Rate, rechts: False Alarm Rate)

Direkt sichtbar ist, dass die einzelnen Werte in den drei Diagrammen für polylinienbasierte Landmarken deutlich größere Streuungen und keinen einheitlichen Verlauf wiedergeben. Es ist grob eine Abnahme der einzelnen Raten in Abhängigkeit der Entfernung erkennbar. Dieses Verhalten kann durch die Repräsentation der durchgezogenen Linien erklärt werden. Entsprechend der Beschreibung des Verfahrens zur Ermittlung der SPRT-Parameter, werden die erhaltenen polylinienbasierten Landmarken in die jeweiligen Abstandsintervalle aufgeteilt. Das erfolgt durch Aufstückelung der einzelnen Landmarken. In der verwendeten Referenzkarte ist bei einem Vorhandensein einer durchgezogenen Linie jedes Abstandsintervall entsprechend der realen Länge der Linie befüllt. Aufgrund der Detektion unter realen Bedingungen können in einzelnen Abstandsintervallen unterschiedliche Raten entstehen, die zu der visualisierten Diversität führen. Vor allem ist dieser Landmarkentyp stark von Verdeckungen betroffen. Sei hier beispielhaft eine zweispurige Straße angenommen (vgl. Beschreibung der Versuchsstrecke in Kapitel 5.1.1 und Anhang D.1). Befindet sich das Versuchsfahrzeug auf der linken Fahrspur und ein weiteres Fahrzeug auf der rechten Fahrspur, so führt diese Situation zur Verdeckung

der durchgezogenen Fahrbahnmarkierung auf der rechten Seite. Fahren zudem beide Kraftfahrzeuge mit gleicher Geschwindigkeit, so wird in dem Abstandsintervall der Verdeckung die Landmarke nie erkannt. Beim anschließenden Vergleich mit der Referenzkarte ergibt sich eine niedrige Rate.

Für linienbasierte Landmarken ist in den Diagrammen eine deutliche Korrelation der jeweiligen Rate zur Entfernung erkennbar. Sowohl die Genauigkeit als auch die Erkennung von neuen Zielen nimmt mit der Entfernung zum Sensor ab. Das kann eine Folge des vereinfachten Abbildungsmodells sein, indem durch eine ungenaue Transformation der detektierten Landmarke aus der Bildebene in die Bodenebene ein Verzerrungsfehler addiert wird. Für die Landmarke ergibt sich bei der Korrespondenzbestimmung zur Referenzkarte eine hohe Distanz, sodass die Beobachtung nicht als Richtig-Positiv gezählt wird.

### 5.1.2.3 Fischaugenkameras

Abschließend sind die Ergebnisse der vier Fischaugenkameras des Versuchsträgers aufgezeigt. Das bildgebende System stellt linienbasierte und polylinienbasierte Landmarken zur Verfügung. Abbildung 5.5 zeigt die Experimentresultate für die vordere Kamera und Abbildung 5.7 für die hintere Kamera. Die Diagramme für die linke und rechte Kamera sind in Abbildung 5.6 und Abbildung 5.7 dargestellt.




Abbildung 5.5: SPRT-Parameter der vorderen Fischaugenkamera des TopView-Systems (links: Probability Detection, mittig: New Target Rate, rechts: False Alarm Rate)




Abbildung 5.6: SPRT-Parameter der linken Fischaugenkamera des TopView-Systems (links: Probability Detection, mittig: New Target Rate, rechts: False Alarm Rate)




Abbildung 5.7: SPRT-Parameter der hinteren Fischaugenkamera des TopView-Systems (links: Probability Detection, mittig: New Target Rate, rechts: False Alarm Rate)




Abbildung 5.8: SPRT-Parameter der rechten Fischaugenkamera des TopView-Systems (links: Probability Detection, mittig: New Target Rate, rechts: False Alarm Rate)

Aufgrund der hohen Auflösung und des geringen Sichtbereichs (vgl. Anhang A und Kapitel 3.1.4) werden sehr hohe Genauigkeitsraten bei allen vier Kameras erreicht. Im Vergleich zu der Front-Monokamera kommt eine Streuung der Werte bei polylinienbasierten Landmarken nicht vor. Das kann auf den eingeschränkten Sichtbereich der Sensorik zurückgeführt werden. Im Gegensatz zur Front-Monokamera schauen die Fischaugenkameras nicht in die Ferne, sondern sind Richtung Boden ausgerichtet. Zusätzlich wird wegen des Abbildungsmodells nur der Bereich nahe am Fahrzeug betrachtet und vom Detektor ausgewertet (aufgrund von Verzerrungseffekten der Kameralinse). Problematiken, wie sie bei der Front-Monokamera entstehen, treten weniger stark auf.

Sowohl für linienbasierte als auch für polylinienbasierte Landmarken sind klare Verläufe sichtbar. Die Erkennung von polylinienbasierten Landmarken ist bei allen Kameras schlechter als bei linienbasierten Landmarken. Vor allem werden falsche Landmarken mit einer hohen Rate wiedererkannt, was unvorteilhaft ist.

### 5.1.3 Zusammenfassung

Entsprechend der Beschreibung des Verfahrens in Kapitel 4.4 zur SPRT-Parameterermittlung, sind in den oben gezeigten Diagrammen die berechneten Werte je Abstandsintervalle über alle Zeitschritte aufgezeigt. Sie stellen die Raten der Genauigkeit, der Erkennung von neuen Zielen und der Wiedererkennung von falschen Zielen in Abhängigkeit der Entfernung zum

Sensor dar. Für die benötigten Parameter  $P_D$ ,  $\beta_{NT}$  und  $\beta_{FA}$  zur Verwendung im TFM wird der Durchschnitt je Landmarkentyp über alle Abstandsintervalle gebildet. Es ergibt sich ein absoluter Wert, der das Verhalten der jeweiligen Sensorik bzw. des Detektors beschreibt. Ein direkter Vergleich auf Landmarkenebene der unterschiedlichen Sensorik wird so ermöglicht. Tabelle 5.1 listet die berechneten Werte für  $P_D$ ,  $\beta_{NT}$  und  $\beta_{FA}$  auf.

Tabelle 5.1: Auflistung der SPRT-Parameter je Landmarkentyp pro Sensorik

Sensorik	Landmarkentyp	SPRT-Parameter		
		Probability Detection $P_D$	New Target Rate $\beta_{NT}$	False Alarm Rate $\beta_{FA}$
Laser-scanner	Linienbasierte Landmarken	0.73	0.698	0.254
	Punkt-basierte Landmarken	0.696	0.459	0.26
Vordere Fischaugen-kamera	Linienbasierte Landmarken	0.81	0.767	0.16
	Polylinienbasierte Landmarken	0.75	0.584	0.325
Rechte Fischaugen-kamera	Linienbasierte Landmarken	0.812	0.752	0.19
	Polylinienbasierte Landmarken	0.736	0.624	0.321
Hintere Fischaugen-kamera	Linienbasierte Landmarken	0.837	0.77	0.244
	Polylinienbasierte Landmarken	0.767	0.601	0.343
Linke Fischaugen-kamera	Linienbasierte Landmarken	0.846	0.784	0.224
	Polylinienbasierte Landmarken	0.735	0.704	0.334
Front-Monokamera	Linienbasierte Landmarken	0.569	0.46	0.381
	Polylinienbasierte Landmarken	0.548	0.566	0.313

Für alle weiteren Auswertungen werden die hier angegebenen Parameter verwendet. Vor allem bei den Untersuchungen zur Kartierung und Lokalisierung im nachfolgenden Kapitel 5.2 sind die Parameterwerte von Bedeutung. Die angegebenen Werte werden im SPRT-Verfahren des TFM zur Fusion und Konfidenzwertberechnung verwendet (vgl. Kapitel 4.2). Es werden eine sensor-landmarken-spezifische Fusion und Konfidenzwertberechnung erreicht. Der Konfidenzwert legt direkt fest, welche Landmarke in die Karte geschrieben wird.

## 5.2 Untersuchung der Kartierung und Lokalisierung

In diesem Unterkapitel wird der eingeführte Lösungsansatz der Landmarkenbasierten Lokalisierung (LbL) untersucht. Der Nachweis zur Verwendbarkeit des vorgestellten Kartierungs- und Lokalisierungsverfahrens für selbstfahrende Kraftfahrzeuge steht im Vordergrund. Die beiden Phasen der Kartierung und Lokalisierung werden voneinander getrennt untersucht.

Die Lokalisierungsgenauigkeit hängt direkt von der zuvor erstellten Karte ab. Deshalb wird in Teilkapitel 5.2.2 zuerst die durchgeführte Kartierung thematisiert. Es werden erzeugte Karten unterschiedlicher Fahrten mit dem in Kapitel 4.4 vorgestellten Verfahren bewertet. Insbesondere wird die Verwendbarkeit der herangezogenen Straßeninfrastrukturelemente betrachtet und Fragestellungen nach räumlicher Verteilung, Wiedererkennung und Robustheit beantwortet.

Im Anschluss wird in Teilkapitel 5.2.3 die Lokalisierung untersucht und die resultierenden Erkenntnisse werden präsentiert. Im Fokus steht die Genauigkeit der berechneten WGS84-Pose der LbL.

Um die vorgestellten Untersuchungen zur Kartierung und Lokalisierung direkt miteinander zu vergleichen, wird für beide Phasen ein einheitliches Szenario gewählt. Die Beschreibung des Szenarios ist in Teilkapitel 5.2.1 gegeben.

Den Abschluss des Unterkapitels bildet Teilkapitel 5.2.4 mit einer Zusammenfassung der Untersuchungen und gewonnenen Erkenntnisse.

### 5.2.1 Szenario- und Konfigurationsbeschreibung

Für die Untersuchungen zur Kartierung und Lokalisierung wurde ein vielseitiger, realer Straßenverlauf als Versuchsstrecke festgelegt. Es ist wichtig, die entwickelten Verfahren unter realen Bedingungen zu prüfen. Nur so sind Aussagen über deren Verwendbarkeit zu ermitteln. Abbildung 5.9 stellt die ausgewählte Strecke dar.

Die Strecke beginnt am Punkt A mit den WGS84-Koordinaten (52.366835, 10.720672) und endet bei Punkt B mit den Koordinaten (52.275511, 10.535634). Insgesamt hat die Strecke eine Länge von 20.0 Kilometern. Sie beinhaltet unterschiedliche Fahrbahnbeschaffenheiten, was die sensorische Wahrnehmung beeinflusst und sich direkt auf die Detektion der Landmarken auswirkt. Ebenso treten verschiedene Umgebungssituationen auf. Sie reichen von ein- und zweispurigen Landstraßen, diversen Ortsdurchfahrten (Lehre (52.328179, 10.667450), Dibbesdorf (52.300311, 10.607100), Volkmarode (52.288736, 10.595856) und Gliesmarode (52.281097, 10.574413)), Autobahnauf- und -abfahrten (52.309945, 10.628634) bis zum dichten urbanen Bereich (Braunschweig (52.275415, 10.535668)). Innerhalb der Bereiche werden unterschiedlich komplexe Kreuzungen, 30er-Zone mit sehr wenigen bis keinen Fahrbahnmar-



kierungen und Kurvenfahrten abgedeckt. Zur genaueren Betrachtung der Versuchsstrecke sei hier auf Anhang D.2 verwiesen.




Abbildung 5.9: Versuchsstrecke für die durchgeführten Untersuchungen der Kartierung und Lokalisierung, Luftbild aus [257]

Insgesamt wurden auf der beschriebenen Versuchsstrecke 20 Fahrten (jeweils Hin- und Rückfahrt) durchgeführt. Erfolgt sind die Versuche bei unterschiedlichen Bedingungen. Das beinhaltet vor allem Fahrten bei Regen und Nässe sowie verschiedenen Helligkeiten der Umgebung (von direkter Sonneneinstrahlung bis hin zu einer einheitlichen Bewölkung). Des Weiteren erfolgten die durchgeführten Versuchsfahrten zu unterschiedlichen Tageszeiten. Es konnten verschiedene Verkehrsaufkommen berücksichtigt werden. Fahrten bei Dunkelheit wurden nicht durchgeführt.

Durch die Beschaffenheit der Versuchsstrecke und die verschiedenen Versuchsfahrten wird eine Vielzahl von typischen Gegebenheiten abgedeckt. Die Experimente eignen sich im besonderen Maße zur Beurteilung des entwickelten Ortungsverfahrens. In den nachfolgenden Teilkapiteln wird das Verhalten der LbL an einzelnen Fahrten exemplarisch aufgezeigt und die Vor- und Nachteile daran herausgearbeitet. Die gezeigten Ergebnisse sind für alle durchgeführten Versuchsfahrten repräsentativ.

Entsprechend der Abbildung 1.2 in Kapitel 1.3 unterscheidet sich die Konfiguration des Versuchsträgers während der Kartierung und Lokalisierung. In der Kartierungsphase wird die Ortungsreferenzeinheit (siehe Kapitel 3.1.1 und Anhang A.2) für die Eigenbewegungsschätzung

und globale Poseschätzung verwendet. In der Lokalisierung kommt die vorgestellte Seriensen-  
soriik (für die Eigenbewegungsschätzung siehe Kapitel 3.1.3 und Anhang A.4, für die globale  
Poseschätzung siehe Kapitel 3.1.2 und Anhang A.3) zum Einsatz.

Das TFM wird sowohl in der Kartierung als auch in der Lokalisierung unverändert ein-  
gesetzt. Vor allem wird in beiden Phasen die identische Umfeldsensorik (vgl. Kapitel 3.1.4  
und Anhang A.5) verwendet. Für die durchzuführende Fusion der Landmarken werden als  
SPRT-Parameter die ermittelten Werte aus dem Experiment des Unterkapitels 5.1 angewen-  
det (siehe Tabelle 5.1). Aufgrund der besonders schlechten Raten der Front-Monokamera (vgl.  
Tabelle 5.1) wird dieser Sensor nicht in den Experimenten zur Kartierung und Lokalisierung  
eingesetzt.

## 5.2.2 Kartenbewertung

Ziel der Versuchsreihe zur Kartenbewertung ist es, die Robustheit und das Kartierungsergebnis  
der verschiedenen Landmarkentypen zu untersuchen. Darüber hinaus wird die Qualität der  
erstellten Karten zueinander evaluiert. Die Verwendung identischer Umfeldsensorik im TFM, die  
sowohl während der Kartierungs- als auch der Lokalisierungsphase eingesetzt wird, ermöglicht  
anhand der durchgeführten Untersuchungen Aussagen über die Nutzbarkeit und die Robustheit  
jedes Landmarkentyps.

Für die Untersuchungen wurde das erläuterte Bewertungsverfahren für Karten (vgl. Kapi-  
tel 4.4) ausgeführt. Mit dem Verfahren wird zum einen ein qualitativer, ortsaufgelöster Kar-  
tenvergleich und zum anderen eine quantitative Betrachtung der Kartenähnlichkeiten durchge-  
führt. Es wird die Anzahl der Kartenlandmarken, die Genauigkeit, die Empfindlichkeit und die  
Ähnlichkeit von je zwei verschiedenen Karten untersucht. Das erfolgt für jeden Landmarkentyp,  
sowohl einzeln als auch kombiniert. Das Verfahren wird mit einer Schrittweite von 50 Metern  
und einem Radius der Kreisausschnitte von 75 Metern parametrisiert.

Die präsentierten Ergebnisse zeigen jeweils den Vergleich von zwei generierten Karten aus  
zwei verschiedenen Hin- und Rückfahrten der in diesem Kapitel beschriebenen Versuchsstrecke.  
Die linke Seite der nachfolgenden Auswertungen zeigt das Ergebnis des Kartenvergleiches aus  
den Hinfahrten, die rechte Seite aus den Rückfahrten.

Zur besseren Einordnung der aufgeführten qualitativen und quantitativen Kartenauswertun-  
gen sei hier wiederum auf die detaillierte Beschreibung der Versuchsstrecke in Anhang D.2 und  
auf die zugehörigen visualisierten Kartierungsausschnitte in Anhang D.3 hingewiesen.

### 5.2.2.1 Qualitative Kartenauswertung

Jeder Kartierungsvorgang hat das Ziel, ein möglichst präzises Abbild der realen Umgebung zu  
generieren. Neben der visuellen Inspektion der Kartierungsergebnisse sind weitere Kriterien zur  
Beurteilung der Kartengüte notwendig.

Mit dem eingeführten Bewertungsverfahren für Karten wird eine ortsaufgelöste, qualitative  
Aussage der Landmarken je Vergleichsbereich gegeben. Das bietet den Vorteil, dass divergente  
Abschnitte in den Karten direkt sichtbar werden. Diese Abschnitte können nachfolgend tiefer  
gehend analysiert werden, um eventuelle Fehlerquellen der Kartierung zu erkennen. Insbeson-

dere sind Auswertungen über die konstante räumliche Verteilung und Wiedererkennung der verwendeten Landmarken ermittelbar.

Im Folgenden werden zuerst die reinen punktbasierten, linienbasierten und polylinienbasierten Karten betrachtet und Aussagen über deren ausschließliche Verwendbarkeit gegeben. Abschließend werden alle Landmarkentypen kombiniert in einer Karte betrachtet.

### Qualitative Auswertung der punktbasierten Kartenlandmarken

Abbildung 5.10 stellt die orts aufgelösten Landmarkendifferenzen zwischen zwei Karten dar. Eine gleichbleibende Anzahl der Landmarken je Vergleichspunkt ist feststellbar (grüne Bereiche). Es sei darauf hingewiesen, dass auch ein Nichtvorhandensein von Kartenlandmarken zu einer Landmarkendifferenz von 0 führt. Vor allem führen Landstraßenabschnitte ohne Leitpfosten an den Fahrbahnrändern zu dem dargestellten Ergebnis. Werden die Stellen mit den hohen Differenzen mit der Versuchsstrecke verglichen, ist erkennbar, dass es sich bei diesen Bereichen gerade um Ortsdurchfahrten und Kreuzungen handelt. Mit dem zeitlichen Versatz der jeweiligen Kartierungsfahrt erklären sich diese Unterschiede durch Verdeckungen wie z.B. parkende Fahrzeuge.




Abbildung 5.10: Ortsaufgelöste Visualisierung der Landmarkenunterschiede in punktbasierten Kartenlandmarken (links: Hinfahrt, rechts: Rückfahrt)

Das in Abbildung 5.10 gezeigte Resultat der Landmarkenanzahl je Vergleichspunkt gibt lediglich eine orts aufgelöste Information über die Menge der Kartenlandmarken in den beiden Karten. Es kann noch keine Schlussfolgerung darüber getroffen werden, ob es sich um identische Elemente handelt. Entsprechend der beschriebenen Vorgehensweise zur Berechnung der Kartenähnlichkeit, wird die Ermittlung zugehöriger Landmarken durch Korrespondenzbestimmungen an den Vergleichspunkten durchgeführt. Als Ergebnis dieses Schrittes folgen die orts aufgelösten Aussagen für Genauigkeit, Empfindlichkeit und Ähnlichkeit zwischen den verglichenen Karten. Abbildung 5.11 präsentiert die ermittelten Ergebnisse.

Es ist zu sehen, dass sowohl die Genauigkeit als auch die Empfindlichkeit, und damit direkt verbunden die Ähnlichkeit, sehr niedrige Werte besitzen. Das gilt für die Hinfahrt und für die Rückfahrt gleichermaßen. Festzuhalten ist die Erkenntnis, dass entsprechend Abbildung 5.10 weitestgehend die gleiche Anzahl an Landmarken vorhanden ist, jedoch nach Abbildung 5.11






Abbildung 5.11: Qualitative Betrachtung von Genauigkeit, Empfindlichkeit und Ähnlichkeit der punktbasierten Kartenlandmarken (links: Hinfahrt, rechts: Rückfahrt)

für die Landmarken aus den beiden Kartenvergleichsbereichen nicht zwingend eine erfolgreiche Assoziation stattfindet. Es sei hier angemerkt, dass für Vergleiche von leeren Kartenausschnitten 0 als Wert für Genauigkeit, Empfindlichkeit und Ähnlichkeit gesetzt wird. Des Weiteren ist erkennbar, dass sowohl um die Bereiche (52.33, 10.67) als auch (52.28, 10.57) leicht erhöhte Landmarkendifferenzen bei guten Ähnlichkeiten (ca. 0.8) vorliegen. Bei beiden Bereichen handelt es sich um urbane, dichte Bereiche.

Als Schlussfolgerung lässt sich festhalten, dass die Kartierung von punktbasierten Landmarken bei einer geringen Landmarkenanzahl zu unterschiedlichen Karten führt. In Bereichen mit einer höheren Landmarkenanzahl (z.B. urbanen Gebieten) ergeben sich gesteigerte Ähnlichkeiten. In diesen Gebieten sind vermehrt einander zuweisbare punktbasierte Landmarken in den einzelnen Karten vorhanden.

### Qualitative Auswertung der linienbasierten Kartenlandmarken

Abbildung 5.12 stellt die Unterschiede der linienbasierten Kartenlandmarken dar. Direkt erkennbar ist, dass in den Karten die gleiche Anzahl an Landmarken vorhanden ist. Die beiden Karten der Rückfahrten weisen wesentlich weniger Unterschiede in der Anzahl der Landmarken auf als die Karten der Hinfahrten. Jedoch ist der maximale Unterschied zwischen der Landmarkenanzahl mit über 50 (im Bereich (52.28, 10.57)) bei der Rückfahrt im Vergleich zur Differenz von 16 in der Hinfahrt deutlich größer. Dagegen ist die Häufigkeit der Unterschiede bei der Rückfahrt geringer.




Abbildung 5.12: Ortsaufgelöste Visualisierung der Landmarkenunterschiede in linienbasierten Kartenlandmarken (links: Hinfahrt, rechts: Rückfahrt)

Die Vergleiche der Karten in Hinblick auf Genauigkeit, Empfindlichkeit und Ähnlichkeit sind in Abbildung 5.13 aufgezeigt. Es zeigt sich, dass dieselben linienbasierten Landmarken in beiden Karten vorhanden sind. Der hohe Ähnlichkeitswert spiegelt das wider. Das spricht für eine robuste Erkennung der gleichen Objekte in den einzelnen Kartierungsfahrten. Vor allem bedeutet das, dass mit der Korrespondenzbestimmungsfunktion die gleichen kartierten Objekte einander zugeordnet werden.

Interessant sind auch die Bereiche mit einer geringen Ähnlichkeit. In den Vergleichen der Hinfahrt und Rückfahrt sind die Abschnitte um (52.36, 10.71), (52.33, 10.67) und (52.27, 10.55) auffällig. Der Abschnitt (52.36, 10.71) ist der Startpunkt bei Hinfahrten und der Endpunkt bei Rückfahrten. Dieses Teilstück enthält eine Kreuzung, die durch sehr viele undeutliche („abgetragene“) Fahrbahnmarkierungen charakterisiert ist. Zusätzlich sind ebenso abgenutzte durchgezogene Linien (polylinienbasierte Landmarken) vorhanden. Diese durchgezogenen Linien werden von der verwendeten Sensorik häufig inkorrekt als gestrichelte Linien erkannt, was zu Fehlern führt (falsche Korrespondenzbestimmung). Der zweite Abschnitt bei den Koordina-




Abbildung 5.13: Qualitative Betrachtung von Genauigkeit, Empfindlichkeit und Ähnlichkeit der linienbasierten Kartenlandmarken (links: Hinfahrt, rechts: Rückfahrt)

ten (52.33, 10.67) ist die Ortsdurchfahrt Lehre. Der Bereich zeichnet sich durch eine sehr große Teilstrecke ohne Fahrbahnmarkierungen und mit seitlich parkenden Fahrzeugen aus. In die Karte eingetragene Fehldetektionen der Landmarken wirken sich in den Werten der Genauigkeit, Empfindlichkeit und der daraus folgenden Ähnlichkeit aus. Die Koordinaten (52.27, 10.55) beschreiben den Streckenabschnitt in Braunschweig. Das urbane Teilstück besteht aus einer zweiseitigen Straße in beide Fahrtrichtungen. Die niedrigen Werte sind eine Folge der Wahl

unterschiedlicher Fahrstreifen in den einzelnen Kartierungsfahrten, wodurch nicht zwingend die gleichen Landmarken in den erzeugten Karten eingetragen sind.

Abschließend wird festgehalten, dass trotz der genannten komplexen Straßenführung linienbasierte Landmarken eine sehr hohe Ähnlichkeit in den einzelnen Karten aufweisen.

### Qualitative Auswertung der polylinienbasierten Kartenlandmarken

Die Unterschiede der Landmarkenanzahl für polylinienbasierte Karten sind in Abbildung 5.14 visualisiert. Es liegt eine gleichmäßige Anzahl der Landmarken in den Karten vor. Weder in der Hinfahrt noch in der Rückfahrt sind große Veränderungen feststellbar.




Abbildung 5.14: Ortsaufgelöste Visualisierung der Landmarkenunterschiede in polylinienbasierten Kartenlandmarken (links: Hinfahrt, rechts: Rückfahrt)

Ähnlich der Untersuchung bei punktbasierten Kartenlandmarken sind die polylinienbasierten Landmarken in den einzelnen Karten nicht gleichbleibend. Abbildung 5.15 stellt die Resultate der Genauigkeit, Empfindlichkeit und Ähnlichkeit der Karten zueinander dar.

Beobachtbar ist, dass polylinienbasierte Karten keine nennenswerten hohen oder niedrigen Werte der Genauigkeit, Empfindlichkeit und Ähnlichkeit erreichen. In den aufgezeigten Analysen sticht kein Bereich der Versuchsstrecke hervor. Im Vergleich zu den sehr guten Werten der linienbasierten und den sehr schlechten Werten der punktbasierten Kartenlandmarken bilden die polylinienbasierte Landmarken die Mitte.

Das Verhalten wird auf die geometrische Modellierung der durchgezogenen Fahrbahnmarkierungen zurückgeführt. Es ist nicht möglich, eine durchgezogene Fahrbahnmarkierung kontinuierlich mit der Sensorik während der Kartierung zu erfassen. Gründe für diese Einschränkung sind Verdeckungen durch andere Verkehrsteilnehmer, fehlerhafte Detektion oder Klassifizierung, aber auch die Unstetigkeit (z.B. Verformungen der Straße oder Abnutzungen) der realen Markierung. Diese Fehler unterscheiden sich mit jeder Kartierungsfahrt. Folglich werden polylinienbasierte Landmarken Lücken aufweisen. Wird auf solchen lückenhaften Karten das beschriebene Bewertungsverfahren ausgeführt, so sind die aufgezeigten Resultate zu erwarten. Mit den ortsaufgelösten Korrespondenzberechnungen zwischen den Landmarken der einzelnen Karten wirken sich solche Lücken direkt auf die Genauigkeits- und Empfindlichkeitsberechnung aus. Die Folge ist eine unmittelbare Beeinflussung des aufgestellten Ähnlichkeitsmaßes.




Abbildung 5.15: Qualitative Betrachtung von Genauigkeit, Empfindlichkeit und Ähnlichkeit der polylinienbasierten Kartenlandmarken (links: Hinfahrt, rechts: Rückfahrt)

### Qualitative Auswertung der kombinierten Landmarkentypen

Die bisher gezeigten Kartenvergleiche für reine punkt-basierte, linienbasierte und polylinienbasierte Karten stellen die jeweilige Robustheit, im Sinne der Wiedererkennung, als orts aufgelöste Aussage dar. Entsprechend den aufgeführten Ergebnissen sind alle einzelnen Landmarkentypen mit Nachteilen behaftet.

Punktbasierte Kartenlandmarken besitzen die gleiche Anzahl an Elementen je Auswertungsschritt, jedoch sind die Landmarken einander nicht direkt zuzuordnen. Das führt zu niedrigen Ähnlichkeitswerten.

Sehr hohe Ähnlichkeiten zwischen zwei Karten sind bei linienbasierten Landmarken zu beobachten. Über weite Teile der Versuchsstrecke stimmten die Elemente in den Karten überein. Jedoch sind gestrichelte Fahrbahnmarkierungen nicht überall vorhanden (Ortsdurchfahrt Lehre), was zu herausfordernden Abschnitten in der Lokalisierung führt.

Eine kontinuierliche mittlere Ähnlichkeit der Karten zueinander ist bei polylinienbasierten Landmarken feststellbar. Den vorherigen Erläuterung folgend, ergeben sich die mittelmäßigen Werte dieses Landmarkentyps durch die geometrische Modellierung und die resultierenden Problematiken (z.B. Verdeckungen).

Offen bleibt die Frage, ob die Nachteile der einzelnen Karten durch eine kombinierte Karte mit allen Landmarkentypen verbessert werden oder weitere negative Einflüsse auftreten. Abbildung 5.16 zeigt die orts aufgelösten Differenzen zwischen allen Landmarkentypen zweier Karten.




Abbildung 5.16: Ortsaufgelöste Visualisierung der Landmarkenunterschiede in einer kombinierten Kartenlandmarken (links: Hinfahrt, rechts: Rückfahrt)

Entsprechend den bisher gezeigten orts aufgelösten Analysen der einzelnen Landmarkentypen ist auch bei der kombinierten Karte das gleiche Verhalten beobachtbar. Im oberen rechten Teil der Versuchsstrecke treten leichte Unterschiede in der Landmarkenanzahl auf. Wird Abbildung 5.16 mit den einzelnen Auswertungen aus Abbildung 5.10, Abbildung 5.12 und Abbildung 5.14 verglichen, so ist festzustellen, dass die Differenzen bei linienbasierten Landmarken nicht mehr in der gleichen Intensität auftreten. Ebenso ist im unteren Teil, im Bereich der Koordinaten (52.28, 10.59), ein Abschnitt mit erhöhtem Unterschied an Kartenelementen feststellbar. Interessant ist, dass dieser Bereich bei allen Landmarkentypen zu erhöhten Unterschieden führt.

Abbildung 5.17 präsentiert abschließend die Auswertungen der Genauigkeit, Empfindlichkeit und Ähnlichkeit. Es lässt sich festhalten, dass sich die gleichen Teilabschnitte bei dem Kartenvergleich der Hin- und Rückfahrten als unähnlich herausstellen. Besonders hebt sich der obere Bereich der Versuchsstrecke, die Ortsdurchfahrt Lehre (der Abschnitt um die Koordinaten (52.33, 10.67)) und der untere, urbane Teil in Braunschweig ab. Die in den oben






Abbildung 5.17: Qualitative Betrachtung von Genauigkeit, Empfindlichkeit und Ähnlichkeit mit kombinierten Kartenlandmarken (links: Hinfahrt, rechts: Rückfahrt)

aufgeführten Auswertungen geschilderten Eigenschaften der Versuchsstrecke führen weiterhin zu inkonsistenten Karten. Jedoch zeigt der Vergleich mit den vorhergehenden Ähnlichkeitsauswertungen der einzelnen Landmarken deutlich, dass die Kombination aller Landmarkentypen zu einer Verbesserung der Ähnlichkeit führt. Erkennbar ist vor allem, dass die genannten schwierigen Teilabschnitte höhere Werte im Bewertungsverfahren aufweisen, als es bei einer Einzelbetrachtung der Landmarkentypen der Fall ist.

### 5.2.2.2 Quantitative Kartenauswertung

Mit der qualitativen Bewertung der zueinander verglichenen Karten sind orts aufgelöste Analysen zur Genauigkeit, Empfindlichkeit und Ähnlichkeit durchgeführt worden. Es wurden interessante, inkonsistente Kartenbereiche der verschiedenen Kartierungen identifiziert und erläutert.

Allerdings kann aus den qualitativen Auswertungen kein zählbarer Rückschluss getroffen werden. Aus diesem Grund wird im Folgenden eine quantitative Kartenbewertung vorgestellt. Die Verteilung der Bewertungen steht bei dieser Untersuchung im Fokus. Um die aufgeführten Auswertungen den vorhergehenden qualitativen Ergebnissen zuzuordnen und sie vergleichen zu können, sind die quantitativen Auswertungen in der gleichen Reihenfolge präsentiert.

#### Quantitative Auswertung der punktbasierten Kartenlandmarken

Abbildung 5.18 zeigt die Häufigkeit der Differenzbildung zwischen der Landmarkenanzahl der beiden punktbasierten Karten für jeden Vergleichsschritt des Bewertungsverfahrens auf. In Korrespondenz zur qualitativen Darstellung ist deutlich zu sehen, dass die häufigsten Unterschiede in der Anzahl der Kartenlandmarken zwischen 0 und 5 liegen. Bereiche, in denen eine Karte deutlich mehr Landmarken enthält als die andere, treten sehr selten auf. Eine Landmarkendifferenz von 0 entsteht auch ohne ein Vorkommen einer Landmarke in den Karten. Für die quantitative Bewertung bedeutet dieser Sachverhalt, dass punktbasierte Karten mit hoher Häufigkeit Lücken besitzen. Insgesamt lässt sich festhalten, dass sowohl bei Kartierungsfahrten der Hin- als auch der Rückrichtung ähnlich viele Landmarken wahrgenommen und in die Karten eingetragen wurden.




Abbildung 5.18: Häufigkeit der Landmarkenunterschiede in punktbasierten Kartenlandmarken (links: Hin-fahrt, rechts: Rück-fahrt)

Die quantitativen Ergebnisse für Genauigkeit, Empfindlichkeit und Ähnlichkeit sind in Abbildung 5.19 visualisiert. Entsprechend den Erwartungen aus der qualitativen Auswertung ergeben sich für die quantitative Analyse hohe Häufigkeiten mit einer niedrigen Bewertung. Bei leeren Vergleichsausschnitten, also Kartenbereichen ohne Landmarken, wird den herangezogenen Metriken der Genauigkeit, Empfindlichkeit und Ähnlichkeit laut Bewertungsverfahren der Wert 0






Abbildung 5.19: Quantitative Betrachtung von Genauigkeit, Empfindlichkeit und Ähnlichkeit der punktbasierten Kartenlandmarken (links: Hin-fahrt, rechts: Rück-fahrt)

zugewiesen. Leere Kartenbereiche erfüllen zwar das definierte Ähnlichkeitsmaß, wirken sich aber negativ auf die Lokalisierung aus und erhalten deswegen den schlechtesten Bewertungswert.

Interessant ist, dass Genauigkeit und Empfindlichkeit der Hin-fahrt im mittleren Bereich (um den Bewertungswert 0.5) eine höhere Häufigkeit aufweisen als bei der Rück-fahrt. Insgesamt waren in der ersten Karte der Hin-fahrt 737 Landmarken und in der zweiten 805 Landmarken vorhanden. Die erste Karte der Rück-fahrt enthielt 664 und die zweite Karte 801 Landmarken. Die deutlich niedrigere Landmarkenanzahl in der ersten Karte der Rück-fahrt erklärt den dar-

gestellten Unterschied. Tabelle 5.2 listet die Testergebnisse der Korrespondenzbestimmungen zwischen den Karten auf. Die absoluten Bewertungen für Genauigkeit, Empfindlichkeit und Ähnlichkeit sind in Tabelle 5.3 zusammengefasst.

Tabelle 5.2: Wahrheitsmatrix des Vergleichs von punktbasierten Kartenlandmarken

Testergebnis	Hinfahrt		Rückfahrt	
	Positive Landmarken	Negative Landmarken	Positive Landmarken	Negative Landmarken
Positiv	454	283	398	296
Negativ	351	0	403	0

Tabelle 5.3: Absolute Bewertung des vollständigen punktbasierten Kartenvergleiches

Bewertungsart	Hinfahrt	Rückfahrt
Genauigkeit	0.5640	0.4969
Empfindlichkeit	0.6160	0.5994
Ähnlichkeit	0.5989	0.5433

### Quantitative Auswertung der linienbasierten Kartenlandmarken

Die qualitativen orts aufgelösten Vergleiche der Landmarkendifferenzen zwischen den Karten aus Abbildung 5.12 sind als quantitative Auswertung in Abbildung 5.20 veranschaulicht. Die häufigsten Vorkommen der Differenzen in der Landmarkenanzahl liegen im Intervall von 0 bis 5 Stück. Die Anzahl der Landmarken je Vergleichsschritt ist gleichbleibend. Das spricht für ein robustes Kartierungsverfahren und für eine kontinuierliche Wahrnehmung der Objekte. Die Rückfahrt enthält einige wenige hohe Abweichungen zwischen den Karten. Wird diese Erkenntnis mit der qualitativen Darstellung verglichen, so ergeben sich die Bereiche um die Koordinaten (52.28, 10.54) und (52.28, 10.58) als entsprechende Fehlerquellen.

Beide Abschnitte entsprechen der Strecke durch Braunschweig. Vor allem der Bereich um (52.28, 10.58) zeichnet sich durch eine zweisepurige Straße in beide Richtungen aus. Die Fahrrichtungen sind durch Schienen der Straßenbahn voneinander getrennt. Zurückführen lässt sich das kurzzeitige hohe Aufkommen an Landmarkendifferenzen auf sensorische Fehldektionen in der komplexen Umgebung.

Die einzelnen Bewertungsarten sind in Abbildung 5.21 aufgeführt. Alle drei Bewertungsarten, Genauigkeit und Empfindlichkeit sowie das daraus definierte Ähnlichkeitsmaß, weisen sehr hohe Raten auf. Die besonders guten Werte von 0.7, 0.8, 0.9 und 1 treten am häufigsten auf, wobei der Wert 1 für einen vollständig identischen Kartenbereich steht. Die hohen Werte spiegeln




Abbildung 5.20: Häufigkeit der Landmarkenunterschiede in linienbasierten Kartenlandmarken (links: Hinfahrt, rechts: Rückfahrt)

die Robustheit von gestrichelten Fahrbahnmarkierungen bei der Kartierung wider. Fälle mit niedrigen Raten ( $\leq 0.4$ ) sind in einer sehr gering Häufigkeit zu beobachten.

In der ersten generierten Karte der Hinfahrt sind 2244 Landmarken vorhanden. Die zweite Karte der Hinfahrt enthält 2374 Objekte. Bei den Rückfahrten sind in der ersten Karte 2240 und in der zweiten Karte 2559 Landmarken vorhanden. Tabelle 5.4 und Tabelle 5.5 geben nachfolgend die Testergebnisse der Korrespondenzbestimmung zwischen den Kartenlandmarken sowie die absoluten Bewertungen wieder.

Tabelle 5.4: Wahrheitsmatrix des Vergleichs von linienbasierten Kartenlandmarken

Testergebnis	Hinfahrt		Rückfahrt	
	Positive Landmarken	Negative Landmarken	Positive Landmarken	Negative Landmarken
Positiv	1873	500	1642	716
Negativ	371	0	398	0

Tabelle 5.5: Absolute Bewertung des vollständigen linienbasierten Kartenvergleiches

Bewertungsart	Hinfahrt	Rückfahrt
Genauigkeit	0.8347	0.8223
Empfindlichkeit	0.7833	0.7201
Ähnlichkeit	0.8113	0.7670




Abbildung 5.21: Quantitative Betrachtung von Genauigkeit, Empfindlichkeit und Ähnlichkeit der linienbasierten Kartenlandmarken (links: Hinfahrt, rechts: Rückfahrt)

### Quantitative Auswertung der polylinienbasierten Kartenlandmarken

Als letzte einzelne Betrachtung werden die quantitativen Auswertungen für polylinienbasierte Kartenlandmarken vorgestellt. Abbildung 5.22 präsentiert den Sachverhalt der Landmarkendifferenzen zwischen den einzelnen Karten aus den Hin- und Rückfahrten.

Auch in den reinen polylinienbasierten Karten sind nur sehr geringe Unterschiede zwischen der Landmarkenanzahl feststellbar. Sowohl beim Vergleich der Karten aus den Hinfahrten als




Abbildung 5.22: Häufigkeit der Landmarkenunterschiede in polylinienbasierten Kartenlandmarken (links: Hinfahrt, rechts: Rückfahrt)

auch den Karten der Rückfahrten sind die Unterschiede und deren Häufigkeit nahezu identisch. Die Differenz von einer Landmarke je Vergleichsausschnitt hat das häufigste Vorkommen.

Weiterführend ist in Abbildung 5.23 die differenzierte Betrachtung der Ergebnisse der einzelnen Bewertungsarten dargestellt. Festzuhalten ist, dass polylinienbasierte Landmarken die gesamte Bandbreite der Bewertungsskala abdecken. Trotz allem ist die Bewertung mit 1, also identischen Kartenausschnitten, sehr oft in den Karten vorhanden. Im Vergleich mit den punktbasierten Auswertungen ist die schlechteste Bewertung mit 0 weniger häufig vorhanden, kommt jedoch öfter vor als bei reinen linienbasierten Landmarken.

Die Verteilung über die gesamte Bewertungsskala wird, entsprechend der Argumentation in der qualitativen Betrachtung, auf die geometrische Modellierung und der damit verbundenen Wahrnehmung der Landmarken zurückgeführt. Aufgrund des dynamischen Arbeitsraumes ist es kaum möglich, durchgezogene Linien einheitlich, vollständig und kontinuierlich in jeder Kartierungsfahrt sensorisch zu erfassen. Allein durch Verdeckungen in urbanen Bereichen werden diese Landmarken gestückelt wahrgenommen. Da im Bewertungsverfahren keine Mehrfachzuordnungen von Landmarken erlaubt sind, wirkt sich eine gestückelt detektierte durchgezogene Linie direkt auf die Berechnung von Genauigkeit, Empfindlichkeit und Ähnlichkeit aus.

Tabelle 5.6 listet abschließend die Testergebnisse auf. Insgesamt waren bei den Hinfahrten 431 Kartenlandmarken in der ersten Karte und 574 Kartenlandmarken in der zweiten Karte enthalten. Die Karten der Rückfahrten enthielten jeweils 425 und 492 polylinienbasierte Landmarken. Das Vorkommen der Landmarken wurde jeweils in den einzelnen Karten gezählt. Wird eine durchgezogene Linie kontinuierlich erfasst, z.B. auf der Landstraße, so erstreckt sich das Element ggf. über mehrere Kilometer. In der Karte wird eine solche Landmarke als ein Objekt eingetragen und entsprechend gezählt. Wird jedoch eine durchgezogene Linie immer wieder unterbrochen wahrgenommen (z.B. in urbanen Bereichen durch vorbeifahrende oder parkende Verkehrsteilnehmer), entspricht jedes Stück einer neuen Landmarke.

Werden Länge und Straßenart der Versuchsstrecke zusammen mit der Anzahl hinterlegter polylinienbasierter Landmarken in den Karten betrachtet, ergibt sich eine sehr gute, durchgängige Modellierung der durchgezogenen Fahrbahnmarkierungen. Das spricht für eine gute




Abbildung 5.23: Quantitative Betrachtung von Genauigkeit, Empfindlichkeit und Ähnlichkeit der polylinienbasierten Kartenlandmarken (links: Hinfahrt, rechts: Rückfahrt)

Sensordatenfusion der Detektionen aus den vier Fischaugenkameras im TFM zur Erzeugung der Karte.

Die Testergebnisse der Korrespondenzbestimmung und die absoluten Bewertungen der Kartenvergleiche sind in Tabelle 5.6 und Tabelle 5.7 gegeben. Obwohl die Verteilung der Häufigkeiten bei polylinienbasierten Karten besser ist im Vergleich zu den punktbasierten Karten, sind die Ergebnisse der absoluten Betrachtung nahezu gleich.

Tabelle 5.6: Wahrheitsmatrix des Vergleichs von polylinienbasierten Kartenlandmarken

Testergebnis	Hinfahrt		Rückfahrt	
	Positive Landmarken	Negative Landmarken	Positive Landmarken	Negative Landmarken
Positiv	274	300	223	259
Negativ	157	0	202	0

Tabelle 5.7: Absolute Bewertung des vollständigen polylinienbasierten Kartenvergleiches

Bewertungsart	Hinfahrt	Rückfahrt
Genauigkeit	0.6357	0.5247
Empfindlichkeit	0.4774	0.4627
Ähnlichkeit	0.5453	0.4917

### Quantitative Auswertung der kombinierten Landmarkentypen

Äquivalent zur durchgeführten qualitativen Betrachtung einer kombinierten Karte mit allen Landmarkentypen, wird nachfolgend die quantitative Auswertung aufgeführt. Interessant ist vor allem, wie sich die Häufigkeiten in der kombinierten Karte entwickeln. Abbildung 5.24 veranschaulicht die ermittelten Landmarkendifferenzen zwischen den Karten.




Abbildung 5.24: Häufigkeit der Landmarkenunterschiede in einer kombinierten Karte mit allen Landmarkentypen (links: Hinfahrt, rechts: Rückfahrt)

Die hohe Anzahl der Landmarkendifferenz aus den reinen punktbasierten und linienbasierten Karten ist auch in der kombinierten Karte wiederzufinden. Festzuhalten ist, dass beim Vergleich der beiden kombinierten Karten aus den zwei Rückfahrten Bereiche mit mehr Differenzen als bei der Betrachtung mit den einzelnen Landmarkentypen entstanden sind. Wird die qualitative

Auswertung herangezogen, so ist diese Beobachtung den urbanen Teilstrecken zuzuordnen. Die geringen Unterschiede sind bis ca. 10 Landmarken zwischen den Karten annähernd mit den Einzelbetrachtungen identisch. Ein signifikant Anstieg in der Häufigkeit dieser Differenzen ist nicht feststellbar.




Abbildung 5.25: Quantitative Betrachtung von Genauigkeit, Empfindlichkeit und Ähnlichkeit einer kombinierten Karte mit allen Landmarkentypen (links: Hinfahrt, rechts: Rückfahrt)

Abbildung 5.25 stellt die Ergebnisse der Analysen für Genauigkeit, Empfindlichkeit und Ähnlichkeit dar. Es lässt sich erkennen, dass beim Vergleich von kombinierten Karten sehr gute



Ähnlichkeiten zueinander hervortreten. Vor allem die bei linienbasierten Karten festgestellte hohe Bewertung wird durch die hinzukommenden Landmarken nicht wesentlich verschlechtert. Die sehr niedrige Bewertung bei reinen punktbasierten Landmarken wird verbessert. Das untermauert die Beobachtung der auftretenden Lücken (Kartenausschnitte ohne Landmarken) in reinen punktbasierten Karten, die zur entsprechenden niedrigen Bewertung geführt haben. Durch die gleichmäßige räumliche Erkennung der linienbasierten und polylinienbasierten Landmarken, enthält die kombinierte Karte kontinuierlich Landmarken. Das führt zur Kompensierung der Lücken in den punktbasierten Karten und spiegelt sich in den Ergebnissen wider. Insgesamt kommen niedrige Bewertungen nur in geringer Häufigkeit vor. Sowohl die Karten der Hin- als auch der Rückfahrten weisen ein gleich gutes (Ähnlichkeit  $\geq 0.7$ ) Verhalten in den Bewertungen auf.

Die kombinierten Karten enthalten jeweils 3049 Landmarken in der ersten und 3110 Landmarken in der zweiten Hinfahrt. Die erste Karte der Rückfahrt beinhaltet 3041 und die zweite 3222 Landmarken. Die Resultate der Korrespondenzbestimmung sind in Tabelle 5.8 aufgelistet. Tabelle 5.9 gibt die absoluten Bewertungen wieder. Die Ähnlichkeit beim Vergleich von kombinierten Karten liegt im Durchschnitt bei 0.73. Die durchschnittliche Ähnlichkeit bei reinen linienbasierten Karten liegt bei 0.79. Das ist eine geringe Verschlechterung, die zu Gunsten der gesteigerten Landmarkenanzahl sinnvoll ist. Mit dem Zuwachs der Landmarken wird eine bessere räumliche Abdeckung erreicht.

Tabelle 5.8: Wahrheitsmatrix des Vergleichs der kombinierten Kartenlandmarken

Testergebnis	Hinfahrt		Rückfahrt	
	Positive Landmarken	Negative Landmarken	Positive Landmarken	Negative Landmarken
Positiv	2327	793	2240	982
Negativ	722	0	801	0

Tabelle 5.9: Absolute Bewertung des vollständigen kombinierten Kartenvergleiches

Bewertungsart	Hinfahrt	Rückfahrt
Genauigkeit	0.7632	0.7366
Empfindlichkeit	0.7492	0.6952
Ähnlichkeit	0.7556	0.7153

### 5.2.2.3 Zusammenfassung der Kartenauswertung

In den vorangegangenen Teilkapiteln wurde erstmalig eine qualitative und quantitative Untersuchung der Kartierung von Fahrbahnmarkierungen und säulenförmigen Objekten der Stra-

Beninfrastruktur auf einer realen Strecke vorgestellt. Die Landmarkentypen sind sowohl einzeln als auch abschließend kombiniert analysiert worden und die gewonnenen Erkenntnisse wurden erläutert. Die Teilabschnitte der Versuchsstrecke, die Lücken in den Karten aufweisen (keine Landmarken vorhanden oder keine Korrespondenzbestimmung zwischen den kartierten Landmarken aus zwei Fahrten), wurden identifiziert. Erreicht wurde diese Identifizierung, indem die Unterschiede der Landmarkenanzahl, die Genauigkeit sowie die Empfindlichkeit ermittelt und abschließend die Betrachtung des definierten Ähnlichkeitsmaßes auf den generierten Karten durchgeführt wurde. Die qualitative Auswertung stellte orts aufgelöste Bewertungen zur Verfügung, während die quantitative Analyse die zugehörigen Bewertungshäufigkeiten veranschaulicht.

Bei den vorgestellten Auswertungen wurden jeweils zwei generierte Karten miteinander verglichen. Der Vergleich einer generierten Karte gegen eine Referenzkarte ist mit dem beschriebenen Vorgehen aus Kapitel 4.4 ebenso möglich, jedoch bei den verwendeten Landmarken nicht zielführend. Das liegt an der ständigen Veränderung des Umfeldes durch äußere Einflüsse. Im Vergleich mit Linienkarten für Innenszenarien der Robotik kann eine Referenzkarte mit Objekten der Straßeninfrastruktur nicht ohne Weiteres erzeugt werden. Während die Generierung von Referenzkarten für Innenszenarien aus Gebäudegrundrissen möglich ist, gibt es für Straßeninfrastrukturcharakteristika (Fahrbahnmarkierung und säulenförmige Objekte) keine Datengrundlage, die direkt bezogen werden kann. Ebenso zu beachten ist die Kartierung von fehlerhaften Landmarken, wie z.B. Teernarben, die jedoch bei einer weiteren Kartierung wiedererkannt werden. In diesem Fall würde eine niedrige Bewertung beim Vergleich der erzeugten Karte mit einer Referenzkarte entstehen, was unerwünscht ist. Beim Vergleich zweier generierter Karten erfolgt keine Abstufung der Bewertung, falls fehlerhafte Landmarken wiedererkannt und miteinander assoziiert werden.

### 5.2.3 Lokalisierungsbewertung

Das übergeordnete Ziel der vorliegenden Arbeit ist, eine präzise Lokalisation selbstfahrender PKW zu erreichen. Die in Kapitel 1.2 genannten Randbedingungen sind zu berücksichtigen. Die Lokalisierung wird durch Ermittlung der WGS84-Pose des Fahrzeugs anhand der Registrierung des linienbasierten Umfeldmodells in eine linienbasierte Karte durchgeführt.

Zuerst werden das initiale Vorwissen und die Versuchsdurchführung beschrieben. Anschließend erfolgt die Herleitung der benötigten Lokalisierungsgenauigkeit, gefolgt von einer qualitativen und quantitativen Bewertung der Landmarkenbasierten Lokalisierung (LbL). Es findet eine differenzierte Betrachtung der berechneten Position nach longitudinalen, lateralen und absoluten Fehlern statt. Die Verteilung der einzelnen Fehler wird aufgezeigt und Bereiche identifiziert, die von besonderem Interesse sind.

#### 5.2.3.1 Initiales Vorwissen und Durchführung

Das Verfahren der LbL ist in Abbildung 1.2 aus Kapitel 1.3 als Registrierung der wahrgenommenen Beobachtungen in eine gegebene Karte visualisiert. Die notwendige Karte wird im vorgelagerten Schritt der Kartierung erzeugt und steht während der Lokalisierung zur Verfügung.

In Kapitel 5.2.1 ist die Versuchsstrecke beschrieben und in Abbildung 5.9 visualisiert. Während der Lokalisierung wird der korrigierte EgoMaster als Eigenbewegungsschätzung (vgl. Kapitel 3.1.3 und Anhang A.4) verwendet. Die globale Poseschätzung wird durch den GPS-Empfänger OEMStar (vgl. Kapitel 3.1.2 und Anhang A.3) in WGS84 bereitgestellt.

Als Referenz werden die Posen des Applanix-Systems (siehe Kapitel 3.1.1 und Anhang A.2) verwendet. Diese Posen dienen als „Ground Truth“-Grundlage zur Auswertung der Lokalisierungsfehler der LbL. Es werden die longitudinalen, lateralen und absoluten Abweichungen der LbL ermittelt. Das ermöglicht eine orts aufgelöste Bewertung der Fehler.

Für den Vergleich zwischen der Kartierungsauswertung und der Lokalisierungsauswertung, wird die Evaluierung der Lokalisation für eine Hinfahrt und eine Rückfahrt durchgeführt. Als initiale Karte für die Hin- bzw. Rückrichtung wird jeweils die Karte der ersten Hin- bzw. Rückfahrt aus Kapitel 5.2.2 verwendet. Als Lokalisierungsfahrt dient die zweite Hin- bzw. Rückfahrt mit den oben genannten Seriensensoren.

Entsprechend den Erkenntnissen aus der Kartierungsauswertung in Kapitel 5.2.2, werden für die Lokalisation mit der LbL alle Landmarkentypen (punktbasierte, linienbasierte und polylinienbasierte Landmarken) kombiniert verwendet. Eine Einzelbetrachtung der Lokalisierung mit nur einem dezidierten Landmarkentyp erfolgt nicht.

### 5.2.3.2 Herleitung der Genauigkeitsanforderung




Abbildung 5.26: Ermittlung der Genauigkeitsanforderung in Querrichtung für Ortungslösungen selbstfahrender Kraftfahrzeuge [258]

Die benötigte Genauigkeit für die Lokalisierung selbstfahrender PKW lässt sich aus der Fahrstreifenbreite des jeweilig betrachteten Straßentyps und der Fahrzeugbreite ermitteln [258]. In Deutschland ergibt sich eine minimale Fahrstreifenbreite von 3.05 Metern [258, 259]. Wird eine durchschnittliche Fahrzeugbreite von 1.6 Metern (ohne Fahrzeugaußenspiegel) angenommen und von der Fahrstreifenmitte ausgegangen, folgt ein Toleranzbereich für den Querversatz von  $\pm 0.725$  Metern (maximale Bewegung des Fahrzeugs innerhalb des Fahrstreifens nach links bzw. rechts von der Fahrstreifenmitte, um nicht auf die Gegenfahrbahn zu geraten). Für die Genauigkeit der Fahrlängsrichtung wird die gleiche Größenordnung wie für Querfehler gefordert [258, 260]. Aus Längsfehlern entstehen z.B. in Abbiegesituationen sehr schnell Querfehler.

Abbildung 5.26 zeigt die abgeleitete Genauigkeitsanforderung. Die gepunktete Linie verdeutlicht die Fahrstreifenmitte, die Fahrstreifenbreite wird mit  $a$ , die Fahrzeugbreite mit  $b$  und der Toleranzbereich (bezogen auf die Fahrstreifenmitte) mit  $c$  angegeben.

### 5.2.3.3 Qualitative Lokalisierungsauswertung

Neben der genannten Genauigkeitsanforderung von  $\pm 0.725$  Metern an die Lokalisierung, ist auch deren Streuung und Schiefe ein wichtiges Gütekriterium. Eine Aussage über die Streuung und Schiefe der berechneten Position der LbL wird pro Ausgabe durch einen Vergleich im  $\xi^{\text{vrf}}$ -Koordinatensystem erreicht. Zum Zeitpunkt der Positionsausgabe der LbL wird die gültige Referenzposition des Applanix-Systems als Ursprung 0/0 verwendet. Der absolute Fehler zwischen der LbL-Position und der Referenzposition des Quer- und des Längsversatzes (Lateral- und Longitudinalversatz) wird pro Ausgabe in das  $\xi^{\text{vrf}}$ -Koordinatensystem eingetragen. Abbildung 5.27 visualisiert den beschriebenen Ansatz und stellt die zugehörigen Fehler der LbL dar. Der Fehler jeder Positionsausgabe ist mit einem blauen Punkt abgebildet.




Abbildung 5.27: Streuung und Schiefe der LbL (links: Hin- und Rückfahrt, rechts: Rückfahrt)

Hervorzuheben ist, dass die berechnete Position mittelwertfrei um den Ursprung veraussacht ist. Im Vergleich zwischen der Hin- und Rückfahrt ist deutlich zu erkennen, dass in der Hin- und Rückfahrt die ausgegebene Position in Längsrichtung eine größere Streuung besitzt. Das deutet auf eine schlechtere Eigenbewegungsschätzung hin, in der die Geschwindigkeit des Fahrzeugs entweder zu langsam oder zu schnell ausgegeben wird. Eine Streuung im Querversatz ist bei der Hin- und Rückfahrt kaum vorhanden. Insgesamt bewegen sich die Lokalisierungsfehler im Bereich der geforderten Genauigkeitsanforderung. Bei der Rückfahrt ist der Längsfehler deutlich kleiner und eine stärkere Ansammlung der Datenpunkte um den Ursprung ist zu beobachten. Jedoch sind auch geringe Abweichungen der Position „nach rechts“ zu erkennen. Zurückzuführen ist das auf Fehllokalisierungen des Partikelfilters, also der kurzfristigen Wahl einer stärker gewichteten Positionshypothese. Ebenso sind kleine Ausreißer „nach vorne“ sichtbar.

Während Abbildung 5.27 die Auswertung der Streuung und Schiefe der Positionsausgabe im  $\xi^{\text{vrf}}$ -Koordinatensystem zeigt und eine qualitative Veranschaulichung der Fehler der LbL bezogen auf den festen Ursprung im Vergleich zur Referenz darstellt, sind orts aufgelöste Informationen der Fehler und deren Häufigkeit aus der Abbildung nicht zu ziehen. Abbildung 5.28 visualisiert die orts aufgelösten Positionsfehler zwischen der LbL und der Referenz im WGS84-Koordinatensystem über der Trajektorie. Die Fehler sind in die Fehlergruppen absolut, lateral und longitudinal eingeteilt.

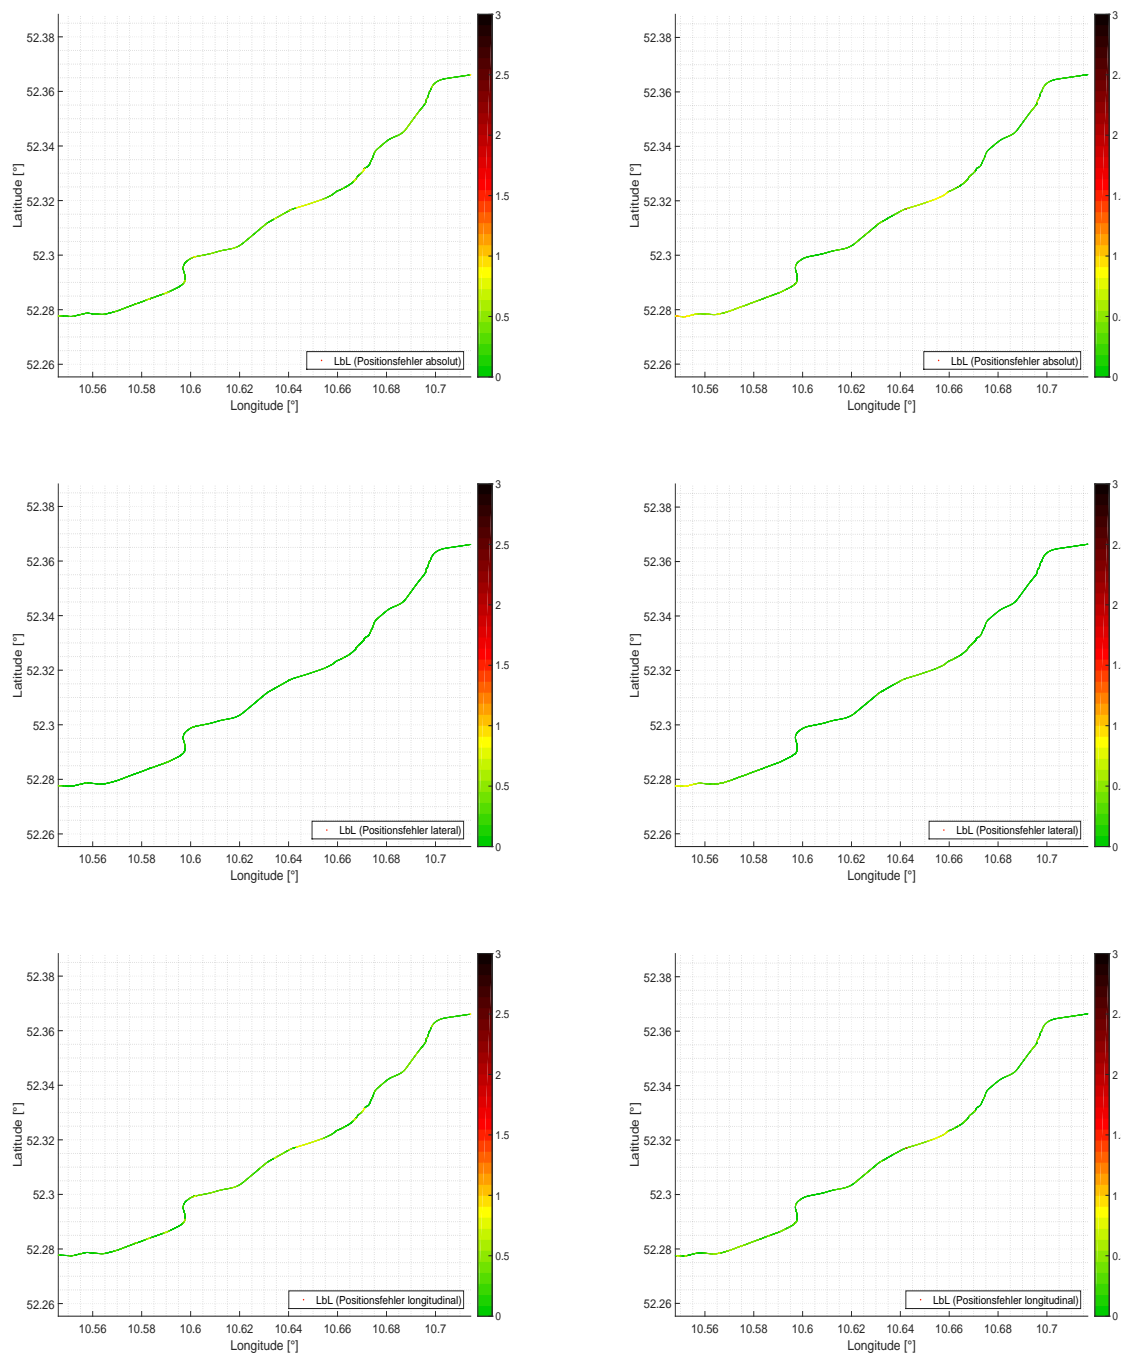


Abbildung 5.28: Visualisierung der Fehler der LbL zur Referenz über der Trajektorie (links: Hinfahrt, rechts: Rückfahrt)

Jede Positionsausgabe der LbL wird entsprechend ihrer absoluten Abweichung zur zugehörigen Referenzposition eingefärbt. Die Farbcodierung gibt den Fehler in Metern wieder und ist in jedem Diagramm auf der rechten Seite abgebildet. Mit Grün sind Abweichungen zwischen 0 und ca. 0.6 Metern eingefärbt. In Orange sind Abweichungen zwischen 0.7 und 1.3 Metern koloriert, alle weiteren Abweichungen größer 1.3 Metern sind stufenweise mit einem dunkler werdenden Rotton veranschaulicht.

Wird die orts aufgelöste Fehlerauswertung der Lokalisierung in Abbildung 5.28 betrachtet, ist zu erkennen, dass die lateralen Abweichungen zwischen Referenz und LbL durchgängig unter einem Meter liegen. Bei den longitudinalen Abweichungen fällt der Abschnitt um die Koordinaten (52.32, 10.66) auf. Entsprechend der Szenariobeschreibung (siehe Kapitel 5.2.1) handelt es sich um die Ortsdurchfahrt Lehre. Wird zusätzlich die kombinierte Kartenauswertung aus Kapitel 5.2.2.1 herangezogen, ist feststellbar, dass sich dort die Landmarken stark unterscheiden. Insgesamt sind dort wenig Umgebungscharakteristiken enthalten. Das schlägt sich direkt in der Lokalisierung nieder. Trotz der wenigen Landmarken in diesem Abschnitt, wird durch das PLM eine Lokalisation um ca.  $\pm 1$  Meter erreicht. Das Lokalisierungsverfahren ist in der Lage, Bereiche mit wenigen Landmarken zu überbrücken. Mit dem gewählten Partikelfilteransatz (PLM) wird direkt nach einem leeren Bereich wieder eine präzise Pose ausgegeben. Erreicht wird das durch ein „Aufgehen“ der Partikelwolke in dünn besetzten Arealen sowie ein schnelles „Zusammenziehen“ auf eine einzelne Hypothese, sobald genug Landmarken vorhanden sind.

Im Gegensatz zur Hinfahrt ist bei der Rückfahrt im unteren Bereich um die Koordinaten (52.28, 10.56) eine Abweichung der Lokalisierung von bis zu  $\pm 1$  Meter erkennbar. Beim genannten Abschnitt handelt es sich um den urbanen Teil in Braunschweig. Während bei der Hinfahrt mit einer präzisen Lokalisierung in den Bereich eingefahren wird und lediglich die Positionshypothese im PLM durch Registrierung der beobachteten Umgebungscharakteristiken in die Karte aufrechterhalten werden muss, befindet sich bei der Rückfahrt der Startpunkt in diesem Abschnitt. Das bedeutet, dass zum Startzeitpunkt (Initialisierungsphase) des PLM mit einer durch Mehrwegeausbreitung und Abschattung beeinflussten globalen Poseschätzung begonnen wird. Durch die unsichere globale Poseschätzung wird die Partikelwolke am Anfang aufgebläht, was zu mehreren Hypothesen führt. Zurückführen lassen sich diese Abweichungen in der genannten Situation auf die Berechnung der Ausgabepose des PLM (vgl. Kapitel 4.3.5).

#### 5.2.3.4 Quantitative Lokalisierungsauswertung

Die durchgeführte qualitative Auswertung der Lokalisierung zur Ermittlung der Streuung und Schiefe in Abbildung 5.27 sowie die orts aufgelöste Fehlerbetrachtung über der Trajektorie in Abbildung 5.28 zeigen das Verhalten der Landmarkenbasierten Lokalisierung (LbL) auf. Es wird deutlich, dass das Verfahren mittelwertfrei ist und auf der gezeigten Versuchsstrecke gute Lokalisierungsergebnisse (Fehler zur Referenzlokalisierung ist  $\leq 0.725$  Metern) liefert. Die beschriebene Genauigkeitsanforderung wird erreicht. Die betrachteten Evaluierungen geben jedoch keine Auskunft über die Häufigkeit der Fehler und deren zeitliches Verhalten. Diese Fälle werden im Rahmen der quantitativen Lokalisierungsauswertung betrachtet. Abbildung 5.29 stellt die Abweichungen der absoluten, lateralen und longitudinalen Positionsbestimmungen zur Referenz über dem Zeitverlauf dar. In Blau sind die absoluten, in Rot die longitudinalen und in Grün die lateralen Fehler visualisiert.

Insgesamt sind die Fehler über dem Zeitverlauf, sowohl für die Hin- als auch die Rückfahrt, im Bereich der Genauigkeitsanforderung bei  $\pm 0.725$  Meter. Die Fehlerschwankung ist bei der Hinfahrt geringer als bei der Rückfahrt. Beobachtbar ist die bereits in der qualitativen Auswertung angesprochene Initialisierungsphase des PLM in der Rückfahrt (hohe Abweichungen der Positionsfehler am Beginn der Lokalisierungsfahrt (bis ca. Zeitstempel 4.698 im rechten Dia-




Abbildung 5.29: Fehler der LbL zur Referenz über dem Zeitverlauf (links: Hinfahrt, rechts: Rückfahrt)

gramm)). Durch die schlechtere erste globale Poseschätzung in der urbanen Startumgebung sind zu Beginn der Rückfahrt größere Abweichungen der LbL-Pose zur Referenz zu verzeichnen. Zusätzlich sind bei der Rückfahrt auch drei Ausschläge der Positionsfehler festzustellen (ca. Zeitstempel 4.703, 4.704 und 4.708). Diese Ausschläge deuteten auf eine kurzzeitige höhere Gewichtung einer falschen Hypothese im PLM hin. Der Grund für ein solches Verhalten sind Fehlassoziiierungen zwischen Beobachtungen und Kartenlandmarken.

Um eine Aussage über die Häufigkeit der Ausschläge bzw. die generelle Häufigkeit der einzelnen Fehlerabweichungen zu erhalten, wurden die Fehler entsprechend ihres Vorkommens in einem Histogramm visualisiert. Analog zu den bisherigen Auswertungen wird die Einteilung in absolut, lateral und longitudinal beibehalten. Abbildung 5.30 führt die einzelnen Histogramme der Hin- und Rückfahrt für die genannten Positionsabweichungen auf. Auf der  $x$ -Achse ist die Klasseneinteilung der Fehler und auf der  $y$ -Achse die Fehlerhäufigkeit aufgetragen.

Tabelle 5.10 stellt vergleichend die absoluten Fehlerbetrachtungen in Metern für die Hin- und Rückfahrt auf. Als Gegenüberstellung ist die Güte des verwendeten GPS-Empfängers OEMStar mit aufgeführt. Anhang D.4 führt zusätzlich weitere Auswertungen wie z.B. den Geschwindigkeitsfehler, den Blickrichtungsfehler und den Gierfehler zur besseren Eingliederung des Lokalisierungsergebnisses der LbL auf.

Tabelle 5.10: Absolute Fehlerbetrachtung der LbL (in Metern)

Fehlerbetrachtung	Hinfahrt LbL	Rückfahrt LbL	GPS
Maximalabweichung	1.13	2.00	8.103
Durchschnittsabweichung	0.297	0.384	1.535
Standardabweichung	0.193	0.269	0.903

Insgesamt ist festzuhalten, dass es eine sehr geringe Fehlerhäufigkeit von großen Positionsabweichungen ( $\leq 0.5$  Metern) zwischen der LbL-Positionslösung und der Referenz gibt. Bei der Hinfahrt sind die meisten Fehler der Absolutposition sowie des lateralen und longitudinalen

Versatzes unter 0.5 Metern (vgl. Abbildung 5.30). Das gilt auch für die Rückfahrt, wobei hier jedoch geringe Fehlerhäufigkeiten bei 1 Meter Versatz festzustellen sind. Werden diese Auswertungen der orts aufgelösten Evaluierung der qualitativen Auswertung gegenübergestellt, folgen die Fehlerhäufigkeiten aus der Initialisierungsphase im urbanen Bereich. Das spiegelt sich in den absoluten Fehlerangaben der LbL aus Tabelle 5.10 wider.




Abbildung 5.30: Häufigkeit der Abweichung der LbL zur Referenz (links: Hinfahrt, rechts: Rückfahrt)



### 5.2.3.5 Zusammenfassung der Lokalisierungsauswertung

Abschließend sollen die durchgeführten Evaluierungen der Lokalisierungsauswertung zusammengefasst werden. Das Lokalisierungsergebnis der LbL wurde auf der festgelegten Versuchsstrecke untersucht. Die initial benötigte Karte ist mit einer separaten Kartierungsfahrt erzeugt worden. Die Lokalisierung erfolgte zeitlich später, womit keine Korrelation der Daten zwischen Kartierungsfahrt und Lokalisierungsfahrt vorliegt. Für die Auswertungen wurden beide Fahrrichtungen untersucht. Die Positionsergebnisse sind sowohl qualitativ mit einer Untersuchung der Streuung und Schiefe sowie einer orts aufgelösten Fehlerauswertung als auch quantitativ mit einer Fehlerbetrachtung über den Zeitverlauf und einer Fehlerhäufigkeitsanalyse beleuchtet worden. Insgesamt hat das Verfahren sehr gute Lokalisierungsergebnisse aufgezeigt (die meisten Fehler  $\leq \pm 0.725$  Meter). Abbildung 5.31 und Abbildung 5.32 fassen die Ergebnisse in zwei verschiedenen Darstellungen zusammen.




Abbildung 5.31: Kumulative Verteilung der LbL-Positionsfehler (links: Hinfahrt, rechts: Rückfahrt)




Abbildung 5.32: Boxplot der LbL-Positionsfehler (links: Hinfahrt, rechts: Rückfahrt)

Alle Positionsfehler als kumulative Verteilungsfunktion sind in Abbildung 5.31 dargestellt. Im Gegensatz zur Wahrscheinlichkeitsfunktion werden nicht die Einzelwahrscheinlichkeiten betrachtet, sondern die Summe aller Wahrscheinlichkeiten, die kleiner oder gleich einer angegebenen Ausprägung sind. Es wird die Wahrscheinlichkeit ermittelt, in wie viel Prozent der Fälle die Positionsfehler kleiner oder größer sind als ein bestimmter Wert. Wird für die Positionsfehler eine Standardnormalverteilung als Grundlage gewählt, gibt die dreifache Standardabweichung an, wie viel Prozent der Ausprägung im Intervall  $\mu \pm 3\sigma$  liegen. Die jeweiligen Standardabweichungen  $1\sigma$ ,  $2\sigma$  und  $3\sigma$  sind bei 68.3%, 95.5% und 99.7% gestrichelt in das Diagramm eingezeichnet [261, 262]. Schneidet die Kurve der Positionsfehler (absolut, lateral oder longitudinal) die gestrichelte  $3\sigma$ -Linie, so heißt das, dass 99.7% aller Positionsfehler kleiner oder gleich der betrachteten Ausprägung sind. Für die Hinfahrt schneidet der absolute Positionsfehler den  $3\sigma$ -Wert bei 0.95 Metern, der longitudinale Fehler bei 0.9 Metern und der laterale Fehler bei 0.4 Metern. Bei der Rückfahrt ermitteln sich die  $3\sigma$ -Werte für die Positionsfehler bei 1.15 Metern für die absolute Positionsgenauigkeit, 1.1 Meter für den longitudinalen und 0.9 Meter für den lateralen Versatz. Die ungenauere Lokalisierung bei der Rückfahrt folgt aus den erläuterten erschwerten Startbedingungen der Umgebung (vgl. Kapitel 5.2.2 und Anhang D.2). Tabelle 5.11 fasst die Werte aus Abbildung 5.31 zusammen.

Tabelle 5.11: Auflistung der  $1\sigma$ -,  $2\sigma$ - und  $3\sigma$ -Werte der LbL-Positionsfehler (in Metern)

$\sigma$ -Werte	Hinfahrt			Rückfahrt		
	Absolut	Longitudinal	Lateral	Absolut	Longitudinal	Lateral
$1\sigma$	0.35	0.3	0.1	0.45	0.35	0.2
$2\sigma$	0.75	0.75	0.2	0.9	0.75	0.75
$3\sigma$	0.95	0.9	0.4	1.15	1.1	0.9

In Ergänzung zur kumulativen Verteilung sind die Positionsfehler in einem Boxplot entsprechend Abbildung 5.32 veranschaulicht. Im Gegensatz zur statistischen Analyse der kumulativen Verteilung stellt der Boxplot die Darstellung des Medians, die Streuung und Schiefe der Fehler sowie die Spannweite der Häufigkeitsverteilung in den Mittelpunkt. Das blaue Rechteck (Box) enthält die mittleren 50% der Positionsfehler und wird durch das obere und untere Quartil (jeweiliges Ende der Box) begrenzt. Die Größe der Box ist ein Maß für die Streuung der Daten. Die rote Linie innerhalb der Box gibt den Median der Daten an und stellt die Schiefe der Verteilung dar. Die außerhalb der Box liegenden Werte werden über die sogenannten Whisker dargestellt, die den schwarzen Linien über und unter dem blauen Rechteck entsprechen. Innerhalb der Whisker-Grenzen liegen 95% der Daten. Alle Ausreißer sind als rote Punkte über und unter den beiden Whiskern visualisiert. Tabelle 5.12 fasst die Werte aus Abbildung 5.32 zusammen.

Tabelle 5.12: Auflistung der Boxplot-Werte der LbL-Positionsfehler (in Metern)

Boxplot- Werte	Hinfahrt			Rückfahrt		
	Absolut	Lateral	Longitudinal	Absolut	Lateral	Longitudinal
Oberes Quartil	0.3747	0.129	0.375	0.525	0.248	0.3757
Unteres Quartil	0.1875	-0.06	-0.0125	0.13	-0.01	0.87
Median	0.25	0.11	0.1875	0.27	0.0625	0.2
Oberer Whisker	0.8725	0.26	0.8729	1.06	0.562	0.4
Unterer Whisker	0	-0.0625	-0.4875	0	-0.3749	-0.3753

#### 5.2.4 Zusammenfassung und Kartengröße

Im Rahmen dieses Kapitels sind sowohl die Kartierung als auch die Lokalisierung qualitativ und quantitativ untersucht worden. Grundlage der Untersuchungen bildet eine festgelegte Versuchsstrecke, die eine Vielzahl unterschiedlicher Gegebenheiten beinhaltet. Sie reichen von ein- und zweispurigen Landstraßen, diversen Ortsdurchfahrten bis hin zu dichten urbanen Bereichen. Zusätzlich deckt die gewählte Strecke unterschiedlich komplexe Kreuzungen, Abschnitte mit sehr wenigen bis keinen Fahrbahnmarkierungen und verschiedene Kurvenfahrten ab. Die aufgezeigten Auswertungen basieren auf realen Daten. In diesem Zusammenhang wurden zuerst die erzeugten Karten der Kartierung aus dem TFM evaluiert. Es wurde erstmalig eine orts aufgelöste Bewertung der Ähnlichkeit zweier Karten vorgestellt. Für die modellierten Landmarken mit den drei geometrischen Grundprimitiven erfolgten die Analysen sowohl einzeln als auch kombiniert. Im Sinne der Anzahl und der räumlichen Verteilung sind Bereiche der Versuchsstrecke identifiziert worden, in denen es zu signifikanten Unterschieden bei den Kartierungsergebnissen kam. Insgesamt wurde gezeigt, dass mit dem entwickelten Verfahren zur linienbasierten Kartenerzeugung durch Fusion und zeitliche Nachverfolgung Karten entstehen, die eine hohe Deckungsähnlichkeit besitzen. Das Ergebnis belegt, dass die verwendeten Landmarken in ihrer Modellierung robust sind. Anschließend wurde die Lokalisierung auf der Versuchsstrecke untersucht. Es wurde eine generierte Karte des TFM als initiales Vorwissen verwendet (Kartierungsphase). Für die Modellierung des Umfeldmodells während der Lokalisierung ist ebenfalls das TFM eingesetzt worden. Im PLM wurde das linienbasierte Umfeldmodell in die linienbasierte Karte registriert und eine Pose ermittelt. Als Ortungsreferenzeinheit diente das vorgestellte Applanix-System. In den vorgestellten Auswertungen ist die berechnete Pose des PLM mit der Pose der Referenzeinheit verglichen worden. Insgesamt ist in der Bewertung der LbL gezeigt worden, dass trotz der äußeren Gegebenheiten eine präzise Lokalisierung mit den gewählten Landmarken und den entwickelten Methoden erreicht wird.

Abschließend sind im Folgenden exemplarisch für die in den Experimenten (siehe Kapitel 5) beschriebenen Versuchsstrecken die Kartengrößen aufgelistet. Das erfolgt sowohl für die Versuchsstrecke der LbL (siehe Abbildung 5.9 in Kapitel 5.2.1) als auch für die Strecke zur SPRT-Parameterermittlung (siehe Abbildung 5.1 in Kapitel 5.1.1). Die LbL-Versuchsstrecke ist in Anhang D.2 und die SPRT-Parameterermittlungsstrecke in Anhang D.1 genau beschrieben. Zusätzlich sind in Anhang D.3 die zur LbL-Versuchsstrecke zugehörigen Kartierungsergebnisse aus den Hin- und Rückfahrten wiedergegeben. Tabelle 5.13 gibt die Kartengrößen für die LbL-Versuchsstrecke an und Tabelle 5.14 listet die Größenangaben für die SPRT-Strecke auf. Die Angaben aus Tabelle 5.13 gehören zu den in Anhang D.3 visualisierten Kartierungen. Hinfahrt A und Hinfahrt B gehören zu den grün und lila eingefärbten Kartenlandmarken. Respektive bezieht sich Rückfahrt A und Rückfahrt B auf die türkis und rot markierten Kartenlandmarken. In den Tabellen sind sowohl die resultierende Kartengröße für eine kombinierte Karte (erste Spalte) mit allen drei Landmarkentypen als auch die Kartengrößen mit nur einem jeweiligen Landmarkentyp (linienbasierte Karte, polylinienbasierte Karte und punktbasierte Karte) aufgelistet. Es wird immer die zugehörige Gesamtgröße und die Durchschnittsgröße pro Kilometer angegeben. Die Gesamtgröße bezieht sich auf die zurückgelegte Kartierungsstrecke (LbL-Versuchsstrecke: 20 Kilometer, SPRT-Versuchsstrecke: 2.3 Kilometer). Die Kartengrößen werden für drei unterschiedliche Formate angegeben, die durch eine horizontale gestrichelte Linie getrennt sind. Der obere Block enthält die Größenangaben von Karten, die im kommaseparieren Format (CSV-Dateien, engl. Comma Separated Values) gespeichert wurden. Ist die erzeugte Karte dagegen im GML-Format [242] abgelegt, sind die zugehörigen Kartengrößen im mittleren Block der Tabelle aufgeführt. Der unterste Block enthält die Größenangaben für die im NDS-Format [35] (siehe Randbedingung R1 (Dezentrale Karte)) gespeicherten Karten. Alle Angaben erfolgen in Kilobyte.

Für eine kombinierte Karte mit allen drei Landmarkentypen aus dem TFM folgt eine durchschnittliche Kartengröße von 235.52 Kilobyte pro Kilometer (für NDS-Karten aller Versuchsfahrten). Trotz dieser kompakten Umgebungsdarstellung ist eine präzise Lokalisierung im PLM möglich. Die geringe Größe des lokalen und globalen Umfeldmodells wird den resultierenden Anforderungen aus den Randbedingungen R1 (Dezentrale Karte), R4 (Initiales Vorwissen) sowie R7 (Kosteneffiziente Realisierung und Serieneinsatz) in Form von kompakten Datenbanken und einer geringen Buslast beim Austausch notwendiger Informationen gerecht. Im Vergleich zu entsprechenden Ansätzen in der Literatur kann der benötigte Speicherbedarf als gering angesehen werden. Bei den in Kapitel 2.3 genannten rasterbasierten Verfahren, wie z.B. in [12, 14, 18] verwendet, ergibt sich die Kartengröße aus der Zellenanzahl, den modellierten Zellenzuständen und der Zellengröße. Wird wie in [14] eine Auflösung von  $512 \times 512$  Zellen mit einer Zellengröße von 0.2 Metern und drei Zuständen pro Zelle angenommen, ergibt sich für eine Strecke von einem Kilometer eine Kartengröße von circa 1 Megabyte. Bei einer Steigerung der Auflösung oder dem Ablegen weiterer Informationen bzgl. der Zellenzustände, wie z.B. texturierte 3D-Gebäudeinformationen in [29] oder eine Unsicherheitsmodellierung entsprechend [161], erhöht sich der benötigte Speicherbedarf. Bei Nutzung von 3D-Daten liegt selbst bei der Verwendung effizienter Baumstrukturen der Speicherbedarf bei mehreren Megabyte [263]. Bei punktbasierten Karten kann die durchschnittliche Kartengröße mehrere Gigabyte erreichen (in Abhängigkeit der abgelegten Punkte und deren Zustandsinformationen, vgl. [8, 21, 90, 264]).

Tabelle 5.13: Exemplarische Auflistung der Kartengrößen für die Versuchsstrecke der LbL (oberer Block CSV-Format, mittlerer Block GML-Format, unterer Block NDS-Format), alle Werte in Kilobyte

Fahrt	Kombinierte Karte		Linienbasierte Karte		Polylinienbasierte Karte		Punktbasierte Karte	
	Gesamtgröße	Ø pro Kilometer	Gesamtgröße	Ø pro Kilometer	Gesamtgröße	Ø pro Kilometer	Gesamtgröße	Ø pro Kilometer
Hinfahrt A	2896.0	144.8	642.0	32.1	2007.0	100.35	238.0	11.9
Hinfahrt B	3220.0	161.0	684.0	34.2	2307.0	115.35	216.0	10.8
Rückfahrt A	3035.0	151.75	622.0	31.1	2167.0	108.35	232.0	11.6
Rückfahrt B	3060.0	153.0	705.0	35.4	2143.0	107.15	197	9.85
Hinfahrt A	13056.0	652.8	2822.0	141.1	9187.0	459.35	1050.0	52.5
Hinfahrt B	14524.0	726.2	3012.0	150.6	10559.0	527.95	952.0	47.6
Rückfahrt A	13671.0	683.55	2734.0	136.7	9914.0	495.7	1021.0	51.05
Rückfahrt B	13809.0	690.45	3110.0	155.55	9828.0	491.4	869	34.45
Hinfahrt A	4713.0	235.65	1043.0	52.15	3391.0	169.55	276.0	13.8
Hinfahrt B	5269.0	263.45	1114.0	55.7	3901.0	195.05	251.0	12.55
Rückfahrt A	4943.0	247.15	1011.0	50.55	3660.0	183.0	269.0	13.45
Rückfahrt B	5010.0	250.5	1150.0	57.5	3629.0	181.45	228	11.4

Tabelle 5.14: Exemplarische Auflistung der Kartengrößen für die Versuchsstrecke zur SPRT-Parameterbestimmung (oberer Block CSV-Format, mittlerer Block GML-Format, unterer Block NDS-Format), alle Werte in Kilobyte

Fahrt	Kombinierte Karte		Linienbasierte Karte		Polylinienbasierte Karte		Punktbasierte Karte	
	Gesamtgröße	Ø pro Kilometer	Gesamtgröße	Ø pro Kilometer	Gesamtgröße	Ø pro Kilometer	Gesamtgröße	Ø pro Kilometer
Hinfahrt D	307.0	133.47	118.0	51.3	145.0	63.04	39.0	16.9
Hinfahrt E	289.0	125.65	115.0	50	132.0	57.39	37.0	16.08
Rückfahrt D	330.0	143.47	147.0	63.9	149.0	64.7	30.0	13.0
Rückfahrt E	349.0	151.7	139.0	60.4	178.0	77.39	30.0	13.0
Hinfahrt D	1377.0	598.69	521.0	226.5	670.0	291.3	176.0	76.5
Hinfahrt E	1295.0	563.0	511.0	222.17	610.0	265.2	163.0	70.86
Rückfahrt D	1477.0	642.17	650.0	282.6	685.0	297.8	135.0	58.69
Rückfahrt E	1564.0	680	614.0	266.95	821.0	356.95	136.0	59.13
Hinfahrt D	489.0	212.6	191.0	83.0	246.0	106.95	45.0	19.56
Hinfahrt E	460.0	200.0	187.0	81.3	223.0	96.95	42.0	18.26
Rückfahrt D	530.0	230.43	239.0	103.91	251.0	109.13	35.0	15.2
Rückfahrt E	562.0	244.34	225.0	110.86	301.0	130.86	35.0	15.2

## 5.3 Witterungsbasierte Lokalisierungsoptimierung

Aufgrund der in Kapitel 5.1 ermittelten schlechten SPRT-Parameterwerte für die Front-Monokamera (siehe Tabelle 5.1) wurde der Sensor in den Untersuchungen der Kartierung und Lokalisierung aus Kapitel 5.2 nicht verwendet. Durch die Verbauposition und den Wahrnehmungsbereich der Front-Monokamera (siehe Kapitel 3.1.4) ist dieser Sensor im Vergleich zu der restlichen Sensorik deutlich stärker den das Fahrzeug umgebenden Bedingungen ausgesetzt. Diese äußeren Bedingungen entstehen vor allem durch den realen, sich kontinuierlich verändernden und weitläufigen Arbeitsraum der Kraftfahrzeuge. Entsprechend der Randbedingung R2 (Invariante, semi-persistente Umgebungsmerkmale in vielfältigen Außenszenarien) können sich zum einen Landmarken selbst durch einen direkten Eingriff in die Straßeninfrastruktur verändern. Zum anderen kann die sensorische Wahrnehmung der Landmarken aufgrund von atmosphärischen Störungen eingeschränkt sein. Als atmosphärische Störungen können hier witterungsbedingte Grenzsituationen wie Regen, Nebel, Schnee oder Helligkeitsunterschiede genannt werden. Die Witterungsbedingungen haben eine direkt Auswirkung auf die Wahrnehmung der Landmarken und schlagen sich in der Lokalisierungsgüte nieder.

In [14] wurde gezeigt, dass Gegenlichtblendungen sogenannte „Geistermarkierungen“ erzeugen können oder die Erkennung von vorhandenen Landmarken verhindern. Die Autoren von [156] hoben hervor, dass Änderungen der Jahreszeiten sich auf die Lokalisierungsgüte auswirken. Aufgrund dessen werden viele Lokalisierungsverfahren, wie beispielsweise in [14] und [32], auf spezielle Szenarien und Bedingungen begrenzt. Levinson et al. zeigen in [161], dass LiDAR-Reflektionen auf nassen Straßen nicht die gleichen Ergebnisse erzeugen wie auf trockenen Straßen. Das führt zu unterschiedlichen Kartierungsergebnissen. Zur Verbesserung wird eine Normalisierung der Helligkeitswerte vorgeschlagen. Der Ansatz ist jedoch nicht unter allen atmosphärischen Störungen robust. Dass eine kamerabasierte Landmarkenerkennung unter günstigen Witterungsbedingungen gute Ergebnisse liefert, jedoch sehr stark von Regen beeinflusst wird, wurde in [265] aufgeführt. Eine kamerabasierte Wetterklassifizierung wurde eingeführt, um die Erkennung zu verbessern. Weitere Verfahren zur Regendetektion sind in [266–268] präsentiert. Hasirlioglu et al. stellen in [269] ein Verfahren vor, um für LiDAR-Sensoren bei unterschiedlichen Regensituationen passende physikalische Modelle zu ermitteln. Mit einem Aufbau zur Regensimulation werden diverse bekannte Regenszenarien simuliert und das Verhalten der LiDAR-Sensoren verglichen.

Im Rahmen dieses Teilkapitels wird exemplarisch ein unabhängiges Experiment durchgeführt. Es gilt zu prüfen, inwiefern eine Verbesserung der LbL für dezidierte Witterungsszenarien erreicht werden kann. Für diese Untersuchung wird die Front-Monokamera (vgl. Kapitel 3.1.4) als Sensor fokussiert. Ziel ist es, den trapezförmigen Sichtbereich des Sensors an die drei Witterungskategorien Regen, Nässe und Trockenheit anzupassen. Es soll die Hypothese überprüft werden, ob mit einem speziellen Sichtbereich je Witterungsszenario eine verbesserte Lokalisierung erreicht werden könnte. Im Gegensatz zu den beiden Unterkapiteln 5.1 und 5.2 sind die hier aufgezeigten Ergebnisse auf Basis einer Simulation ermittelt. Lediglich die verwendete Umgebungswahrnehmung der Front-Monokamera zur Sichtbereichsoptimierung repräsentiert eingefahrene Daten. Die folgenden Untersuchungsdurchführungen und Auswertungen basieren auf dem in [270] vorgestellten Verfahren, das als Teil dieser Arbeit entstand.

### 5.3.1 Durchführung

Ziel der Untersuchung ist es herauszufinden, inwiefern unterschiedliche Witterungsbedingungen die LbL in ihrer Lokalisierungsgenauigkeit beeinflussen. Der Fokus liegt auf den drei Kategorien Regen, Nässe (ohne Regen) und Trockenheit. Exemplarisch zeigt Abbildung 5.33 die unterschiedliche Wahrnehmungsqualität der für die Experimente verwendeten Front-Monokamera auf.



Abbildung 5.33: Umgebungswahrnehmung je Kategorie mit der Front-Monokamera (oben: Regen, mittig: Nässe, unten: Trockenheit; links: um die WGS84-Koordinaten (52.422850, 10.733267), rechts: um die WGS84-Koordinaten (52.424780, 10.727473))

Alle drei Kamerabilder zeigen die gleiche Szene der Versuchsstrecke in den unterschiedlichen Kategorien. Im oberen Bild ist die Wahrnehmung in der Kategorie Regen, im mittleren Teil bei Nässe und in der unteren Abbildung bei Trockenheit präsentiert. Die zum Zeitpunkt der Aufnahme ermittelten Landmarken des Sensors sind in Grün, Orange und Rot im Bild eingezeichnet. Die Farbe korrespondiert mit dem vom TFM ermittelten Konfidenzwert der Landmarke. Festzuhalten ist, dass der Kontrast von Trockenheit zu Regen abnimmt. Mit abnehmendem Kontrast wird die Erkennung der Fahrbahnmarkierungen im Bild erschwert. Außerdem ist zu erkennen, dass im oberen Bild die in [14] beschriebenen „Geistermarkierungen“ durch Gegenlichtblendungen auftreten. Sie entstehen durch Spiegelungen der Scheinwerfer entgegenkommender PKW auf der Fahrbahn und werden vom Sensor teilweise als Landmarken erkannt.



Die gezeigten Szenen sind Teil der in Kapitel 5.1 und Anhang D.2 vorgestellten Versuchsstrecke, die für die durchgeführten Untersuchungen verwendet wurde. Insgesamt sind sechs Fahrten bei Nässe, sieben bei Regen und neun bei Trockenheit erfolgt. Alle Fahrten fanden bei realen Verkehrsbedingungen und ähnlichem Verkehrsaufkommen statt. Die Klassifizierung und Einteilung der Witterungsgegebenheiten ist manuell auf Basis meteorologischer Daten einer Wetterstation durchgeführt worden. Die LbL wurde für die Versuchsfahrten lediglich mit der Front-Monokamera als umgebungswahrnehmender Sensor betrieben. Zur Bewertung der Lokalisierungsgenauigkeit wurde die Ortungsreferenz genutzt.

Der Field Of View (FOV) der Front-Monokamera wird durch ein gleichschenkliges symmetrisches Trapez aufgespannt, das vor dem Fahrzeug auf dem Boden liegt (vgl. Kapitel 3.1.4). Aufgrund des festen Kamerawinkels  $\alpha$  ist die Distanz  $h_{\text{fix}}$  zu den unteren Eckpunkten des Trapezes bekannt. Die unteren Eckpunkte, äquivalent zu den unteren Eckpunkten des Kamerabildes, sind ebenso fest. Die oberen Eckpunkte sind jedoch adaptierbar. Abbildung 5.34 stellt den beschriebenen Zusammenhang schematisch dar. Der FOV ist mit roten Linien innerhalb des Trapezes visualisiert.




Abbildung 5.34: Schematische Darstellung des Sichtbereichs der Front-Monokamera

Im Rahmen der Untersuchung wird die Hypothese aufgestellt, dass der FOV für jede einzelne Kategorie der Witterungsbedingungen optimiert werden kann und bei der Verwendung des optimierten FOV in der zugehörigen Kategorie eine verbesserte Lokalisierungsgenauigkeit der LbL erreicht wird. Für jede Kategorie muss ein optimales Parameterset zur Beschreibung eines gleichschenkligen symmetrischen Trapezes gefunden werden. Das Trapez wird, der Erläuterung aus [270] folgend, über das Parameterset aus Höhe ( $h = h_{\text{trapez}} + h_{\text{fix}}$ ) und Breitenvariation  $w$  beschrieben. Als erster modifizierbarer Parameter ergibt sich Höhe  $h_{\text{trapez}}$ . Wird dieser Parameter gesetzt, sind die oberen beiden Ecken  $W_{\text{Pos}}(h)$  und  $W_{\text{Pos}}(h)$  als Funktion der Höhe  $h$  des Trapezes berechenbar. Im Anschluss wird die gesamte obere Breite  $W(h)$  des Trapezes berechnet. Mit dem zweiten modifizierbaren Parameter  $w$  ist die ermittelte Breite veränderbar

[270]. Abbildung 5.35 stellt exemplarisch vier Sichtbereiche mit dem beschriebenen Variationsverfahren dar. In Blau sind die Fahrbahnmarkierungen visualisiert. Das grüne Rechteck mit dem Pfeil symbolisiert das Fahrzeug. Das Trapez vor dem Fahrzeug steht für eine Ausprägung des FOV.




Abbildung 5.35: Exemplarische Darstellung unterschiedlicher Sichtbereichsvierungen (Angaben in Metern)

Die Generierung und Bewertung unterschiedlicher Parametersets für die FOV einer Kategorie erfolgt mit einem Simulationsverfahren. Es werden Start-, End-, und Schrittwerte für die Parameter festgelegt und sukzessiv alle Parameterkombinationen getestet. Überlappende Trapeze mit sich kreuzenden Kanten werden nicht betrachtet. Um ein optimales Parameterset für eine Witterungskategorie zu ermitteln, wird der Effekt des aktuell betrachteten FOV auf die Lokalisierungsqualität der LbL bezogen. Die Lokalisierungsqualität wird als durchschnittlicher absoluter Abstand zwischen der LbL-Pose und der Ortungsreferenz definiert. In vorangegangenen Untersuchungen [14, 161, 265] ist gezeigt, dass verschiedene Witterungsbedingungen einen negativen Einfluss auf die Lokalisierungsgenauigkeit haben. Es wird die Hypothese auf-

gestellt, dass die Verwendung eines optimalen FOV für eine spezielle Witterungsbedingung die Lokalisierungsqualität im Vergleich zu einem allgemeingültigen FOV verbessert.

Zur Berechnung der Lokalisierungsqualität wird in jeden Simulationsdurchlauf mit einer FOV-Variation ein Vektor  $D$  erzeugt. Jeder Eintrag  $D_i$  in  $D$  steht für die euklidische absolute Distanz zwischen der LbL und der Ortungsreferenz. Nach Abschluss des Simulationsdurchlaufs wird der Durchschnitt  $\mu$  über alle Einträge in  $D$  berechnet, was der definierten Lokalisierungsqualität mit dem geprüften FOV entspricht. Die formale Beschreibung der Berechnung ist in [270] gegeben. Aufgrund der Kontinuität der Witterungsbedingungen führen einige FOV-Parametersets zu ähnlichen Lokalisierungsqualitäten. Aus diesem Grund ist es vorteilhaft, sinnige Regionen von Parametersets zu identifizieren. Das Parameterset mit dem kleinsten  $\mu$  (beste Lokalisierungsqualität) muss in der Auswahl enthalten sein. Zur Identifizierung dieser Parametersets muss die Fluktuation (Standardabweichung des Mittelwertes) des kleinsten  $\mu$  berechnet werden. Jedes Parameterset, dessen  $\mu$  innerhalb der Fluktuation liegt, ist Teil der Region. Alle anderen Parametersets werden verworfen. Zur Berechnung der Fluktuation wird jeder Wert  $i$  von  $D$  in einen von zehn Bins einsortiert. Das erfolgt durch die Zuweisung des Wertes  $i$  in den  $i \bmod 10$ -ten Bin. Für jeden Bin wird der Durchschnitt  $\mu_i$  berechnet und anschließend die Standardabweichung  $\sigma$  über alle zehn  $\mu_i$  ermittelt (vgl. Anhang D.5). Mit dem beschriebenen Verfahren aus [270] wird für jede Fahrt einer Kategorie eine Sammlung von sinnigen Parametersets generiert. Wird zusätzlich jedes Parameterset  $k$  mit  $\frac{1}{\mu_k}$  gewichtet, wobei  $\mu_k$  der Lokalisierungsqualität des  $k$ -ten Parametersets entspricht, ergibt sich ein optimales Parameterset für eine Fahrt. Abschließend wird über alle optimalen Parametersets der Durchschnitt gebildet und der FOV für eine Witterungskategorie bestimmt.

Nachdem für jede Witterungskategorie die einzelnen Versuchsfahrten durchgeführt und die Daten aufgezeichnet wurden, erfolgt die FOV-Parameteroptimierung auf einem Simulationsrechner. Jede Fahrt ist mehrfach mit unterschiedlichen FOV-Parametern, die mit dem oben beschriebenen Verfahren adaptiert wurden, ausgeführt worden. Die Sichtweite, also die Höhe des Trapezes, ist beginnend von 10 Metern bis 60 Meter mit einer Schrittgröße von 0.5 Metern verändert worden. Die Sichtbreitenversätze reichen von -23.5 Metern bis 2 Meter und wurden mit einer Schrittgröße von 0.5 Metern adaptiert.

Damit jeder Simulationsdurchlauf mit den gleichen Grundvoraussetzungen für die LbL erfolgt und die Versuchsreihen reproduzierbar bleiben, wurde die Ortungsreferenz verrauscht. Für das Verrauschen der Ortungsreferenz wird die Unsicherheit der globalen Poseschätzung (vgl. Anhang A.3) festgelegt. Für die Verrauschung wird eine normalverteilte Zufallsvariable mit einer Standardabweichung von 0.75 Metern für die Quer- und Längsrichtung verwendet. Die Blickrichtung wird mit einer Standardabweichung von 0.5 Grad verrauscht. Die Methode ist in Anhang D.6 genauer erläutert. Das verrauschte Signal der Ortungsreferenz dient als Eingangssignal (Eigenbewegungsschätzung und globale Poseschätzung) für die Verfahren TFM und PLM. Mit diesem Ansatz wird für jede Fahrt ermittelt, wie sich eine Veränderung des FOV auf die Lokalisierungsqualität auswirkt.

### 5.3.2 Ergebnisse und Aussage

Mit dem beschriebenen Vorgehen lässt sich der Zusammenhang zwischen den unterschiedlichen Witterungskategorien und den berechneten optimalen Sichtbereichen aufstellen. Für die

Auswertung wird zuerst jede Messfahrt einer Kategorie einzeln betrachtet. Anschließend wird das Verhalten aller Messfahrten der Kategorie aggregiert, um eine Aussage für die bestimmte Witterungsbedingung zu erhalten.

Für die Einzelbetrachtung jeder Fahrt in den einzelnen Kategorien wird der Zusammenhang zwischen Lokalisierungsqualität und Sichtbereich als 3D-Graph visualisiert. Abbildung 5.36 zeigt jeweils einen solchen Graph exemplarisch für eine Fahrt aus der Kategorie Trockenheit (oben), Nässe (mittig) und Regen (unten) auf. In der unteren Ebene, der  $x$ - und  $y$ -Achse, sind alle Parametervariationen der Sichtweite (Höhe des FOV-Trapezes) und der Sichtbreite (Breite des FOV-Trapezes) aufgeführt. Auf der  $z$ -Achse wird die Lokalisierungsqualität (durchschnittlicher absoluter Abstand zwischen der ermittelten LbL-Pose und der nicht verrauschten Ortungsreferenz) wiedergegeben und als farblich codierte Skala auf der rechten Seite hinterlegt. Der ursprünglich gewählte Sichtbereich ist mit einem schwarzen Kreis gekennzeichnet. Die geringsten Abstände zur Ortungsreferenz bilden einen „Gebirgszug“, auf dessen Spitze der berechnete optimale Sichtbereich mit einem schwarzen Dreieck für die gerade betrachtete Fahrt eingezeichnet ist. Mit dieser Auswertung sind die einzelnen Fahrten einer Kategorie miteinander vergleichbar. Bei den durchgeführten Messfahrten ergibt sich eine Übereinstimmung der dreidimensionalen Formen der 3D-Graphen in den einzelnen Kategorien. Das zeigt, dass ähnliche Witterungsbedingungen zu vergleichbaren Ergebnissen führen.

Zur Ermittlung eines optimalen Sichtbereichs für eine Kategorie wird nicht nur eine spezielle Fahrt herangezogen, sondern entsprechend dem beschriebenen Vorgehen aus Kapitel 5.3.1 vorgegangen. Aufbauend auf den ermittelten Zusammenhängen aller Parametervariationen der Messfahrten einer Kategorie (vgl. Abbildung 5.36), wird das optimale Parameterset einer Witterungskategorie berechnet, indem nicht nur die optimalen Parameterkombinationen genutzt werden, sondern alle Parameterkombinationen, deren mittlerer Abstand zur Ortungsreferenz innerhalb zweier Standardabweichungen des Optimums liegen. Schwankungen und Ungenauigkeiten (z.B. Startzeitpunkte der einzelnen Fahrten und damit verbundene Helligkeitsunterschiede aufgrund eines anderen Sonnenstandes und Bewölkungsgrades, verschiedene Fahrstile mit unterschiedlichen Geschwindigkeiten auf gleichen Streckenabschnitten) der einzelnen Messfahrten einer Kategorie werden mit diesem Ansatz indirekt berücksichtigt. Eine direkte Betrachtung der Einflüsse findet nicht statt. Mit dem gewählten Vorgehen wird jedoch das Betrachtungsspektrum für die optimale Parameterkombination eines FOV in einer Kategorie erweitert.

Abbildung 5.37 visualisiert das resultierende Ergebnis für jede Witterungskategorie. Auf der  $y$ -Achse ist die Sichtbreitenvariation aufgetragen. Die  $x$ -Achse gibt die jeweilige Sichtweite an. Da innerhalb zweier Standardabweichungen des optimalen Mittelwertes je Fahrt nur Sichtweiten bis maximal 38 Meter und Sichtbreitenvariationen von mindestens -15 Metern auftreten, sind die Achsen der Abbildung angepasst dargestellt. Die roten Kreise zeigen die in Betracht gezogenen und ermittelten Parameterkombinationen. Die Kreisradien sind antiproportional zum jeweiligen Mittelwert der absoluten Entfernung der berechneten LbL-Pose zur Ortungsreferenz. Ein größerer Kreis entspricht einem besseren Ergebnis (geringere absolute Entfernung zwischen LbL-Pose und Ortungsreferenz). Die schwarzen Rechtecke stellen die gewichtete, optimale Parameterkombination einer Fahrt der Kategorie dar. Der schwarze Stern zeigt die resultierende Parameterkombination für die jeweilige Witterungskategorie, die aus einer gewichteten Durchschnittsbildung der schwarzen Rechtecke folgt. Zu erkennen ist, dass sich eine Flügelform

für die möglichen Parameterkombinationen ergibt. Im oberen Diagramm, das die Parameterkombinationen für Fahrten bei trockener Fahrbahn zeigt, ist im Vergleich zu den anderen Diagrammen eine kompaktere Anordnung der Punkte zu sehen. Die unsicheren Ränder mit kleinen Kreisen kommen seltener vor. Die gewichteten, optimalen FOV-Parameter der einzelnen Fahrten liegen im Bereich der Sichtweite von 14 Metern und 17 Metern. Die Sichtbreite schwankt jedoch stark. In dieser Kategorie folgt eine optimale Sichtweite von ca. 15.43 Metern und eine Einschränkung der Sichtbreite von ca. 1.16 Metern. Das mittlere Diagramm zeigt die Resultate bei Nässe. Es zeigt, dass bei geringerer Sichtweite größere Sicherheiten als bei Regen erreicht werden, jedoch nicht so stark wie bei Trockenheit. Eine Bewegung zu kleineren Einschränkungen der Sichtbreiten im Vergleich zum unteren Diagramm bei Regen ist festzustellen. Allerdings sind die FOV-Parameter der einzelnen Fahrten deutlich weiter verstreut. Für die Witterungsbedingung Nässe liegt die optimale FOV-Parameterkombination bei 16.41 Metern Sichtweite und 1.41 Metern Sichtbreitenvariation. Für Regen ergibt sich das untere Diagramm. Die Kreisradien sind hier am kleinsten, was einer schlechten Lokalisierungsqualität entspricht. Die Sichtweite liegt bei ca. 16.16 Metern und die Sichtbreitenvariation beträgt ca. -2.63 Meter.

Zur abschließenden Evaluierung der Auswirkung auf die Lokalisierung wurden zwei Messfahrten je Witterungskategorie verwendet, die nicht im Trainingsdatensatz zur Ermittlung des optimierten FOV für ein Witterungsszenario enthalten waren. Auf Basis dieser Daten erfolgte eine stichprobenartige Prüfung der Auswirkung der ermittelten Sichtbereiche auf die LbL in einem dezidierten Witterungsszenario innerhalb einer Simulation. Als Eingangsdaten für die LbL wurde zum einen die aufgezeichnete Umfeldwahrnehmung der jeweiligen Messfahrt verwendet und zum anderen die entsprechend der Methode in Anhang D.6 verrauschten Bewegungsinformationen (Eigenbewegungsschätzung und globale Poseschätzung der Ortungsreferenz) genutzt. Tabelle 5.15 gibt die ermittelten Ergebnisse wieder. Die Einträge in der Tabelle entsprechen dem Mittelwert der absoluten Durchschnittsabweichung (in Metern) der Fahrten eines Witterungsszenarios bei Verwendung der verschiedenen FOV. Die jeweilige Witterungskategorie ist vertikal in der ersten Spalte der Tabelle aufgeführt, wohingegen der verwendete Sichtbereich horizontal in der ersten Zeile angegeben ist. Das Lokalisierungsergebnis des passenden Sichtbereichs zur zugehörigen Witterungskategorie ist entsprechend hervorgehoben. Zusätzlich sind in der letzten Spalte die Lokalisierungsergebnisse wiedergegeben, die mit dem Standardsichtbereich (vgl. Teilkapitel 3.1.4.2) erzielt wurden.

Insgesamt lässt sich festhalten, dass in jeder Kategorie mit dem optimierten Sichtbereich eine Verbesserung der Lokalisierungsqualität von ca. 0.15 Metern erreicht wird. Jedoch sind die Unterschiede zwischen den optimierten Sichtbereichen gering.

Tabelle 5.15: Ergebnisse der gemittelten absoluten Durchschnittsabweichung der LbL (in Metern) in unterschiedlichen Witterungsszenarien bei verschiedenen Sichtbereichen

Witterungsszenario	Trocken-FOV	Nässe-FOV	Regen-FOV	Standard-FOV
Trockenheit	<b>0.68</b>	0.8	0.82	0.89
Nässe	0.79	<b>0.73</b>	0.76	0.84
Regen	0.9	0.81	<b>0.77</b>	1.02




Abbildung 5.36: Parameteroptimierung einer Fahrt in einer Kategorie (oben: Trockenheit, mit-  
tig: Nässe, unten: Regen)




Abbildung 5.37: Ermittelte Parameterkombinationen je Kategorie (oben: Trockenheit, mittig: Nässe, unten: Regen)

### 5.3.3 Zusammenfassung

In diesem Experiment wurde die Auswirkung des eingestellten Sichtbereichs der Front-Monokamera auf die Lokalisierungsqualität der LbL in drei verschiedenen Witterungskategorien untersucht. Die Untersuchung zeigt, dass sich mit höherer Sichtweite eine geringere Einschränkung der Sichtbreite ergibt. Es geht hervor, dass mit steigender Erfassung von falsch-positiven Landmarken der Sichtbereich zum Fluchtpunkt der Fahrbahn angepasst wird. Der Grund für diese Entwicklung sind viele Fehldetektionen von Landmarken, die sich nicht auf der Fahrbahn befinden.

Abbildung 5.38 illustriert schematisch die beschriebenen optimalen Sichtbereiche für die drei Kategorien aus Abbildung 5.37. Die gestrichelte schwarze Linie zeigt den ermittelten Sichtbereich bei Trockenheit, die blaue Linie den für Nässe und die rote Linie den für Regen. Das grüne Rechteck stellt das Fahrzeug dar. In Anlehnung an Abbildung 5.34 sind die Parameter  $h_{\text{fix}}$  und  $h_{\text{trapez}}$  eingezeichnet. Tabelle 5.16 führt die ermittelten Daten der FOV-Parameter explizit auf.




Abbildung 5.38: Schematische Darstellung der optimierten Sichtbereiche für jede Kategorie (schwarz: Trockenheit, blau: Nässe, rot: Regen), aus [270]

Tabelle 5.16: Ermittelte Sichtbereiche (FOV) in jeder Witterungskategorie

Kategorie	FOV-Parameter		
	Breite [Meter]	Höhe [Meter]	Fläche [Quadratmeter]
Trockenheit	9.7	15.4	113.96
Nässe	10	16.4	123.82
Regen	7.3	16.1	99.82

Abschließend wurden in jeder Kategorie zwei neue Messfahrten durchgeführt und das aus dem Trainingsdatensatz ermittelte FOV eingesetzt. Die Auswertung erfolgte in einer Simulation und zeigte eine durchschnittliche Verbesserung der Lokalisierung von ca. 0.15 Metern im Vergleich zum Standardsichtbereich. Da es sich nur um eine stichprobenartige Prüfung handelt, bleibt die Frage nach statistischer Signifikanz offen. Ebenso sind die Unterschiede der Lokalisierungsqualität zwischen den optimierten Sichtbereichen gering. Es bleibt weiterhin zu untersuchen, wie sich die Lokalisierungsqualität bei einer realen Messfahrt verhält und ob ein aus den drei optimierten Sichtbereichen gemitteltes FOV ähnliche Ergebnisse erzielt.



# Kapitel 6

## Bewertung und Diskussion

Das Ziel der experimentellen Evaluation dieser Arbeit war die Untersuchung der entwickelten Verfahren auf die Eignung zum Einsatz in selbstfahrenden Personenkraftwagen. Im Vordergrund stand die Auswertung der Lokalisierung und die Verwendbarkeitsanalyse der einbezogenen Umgebungscharakteristiken. Auf der gewählten Versuchsstrecke konnte mit der qualitativen und quantitativen Betrachtung der Kartierungs- und Lokalisierungsergebnisse nachgewiesen werden, dass die entwickelten Ansätze im realen Umfeld einsetzbar sind. Entsprechend der Randbedingung R2 „Invariante, semi-persistente Umgebungsmerkmale in vielfältigen Außenszenarien“ wurde keine zusätzliche Infrastruktur zur Lokalisierung des PKWs im Arbeitsraum benötigt. Der Randbedingung R3 „Zweidimensionale, sensorische Umgebungswahrnehmung mit Seriensenso-rik“ folgend, waren alle zur Umgebungserfassung notwendigen Sensoren direkt im Fahrzeug integriert. Der gewählte Ansatz im TFM zur Erzeugung des Umfeldmodells und der Karte ist von der eingesetzten Sensorkonfiguration unabhängig. Das gilt auch für das entwickelte Sensormodell zur Registrierung der Wahrnehmung in die Karte im PLM. Die Verfahren wurden auf dem vorgestellten Versuchsträger mit Standard-Hardware (siehe Anhang A.1) eines integrierten Fahrzeugrechners ausgeführt (vgl. Randbedingung R6 (Zeitstempel und Zeitverhalten) und R7 (Kosteneffiziente Realisierung und Serieneinsatz)).

### Experiment 1: SPRT-Parameterermittlung

Als Framework zum Tracking, zur Fusion und der Kartengenerierung mit den Umgebungscharakteristiken im TFM wurde in dieser Arbeit SPRT gewählt. Es mussten für jede definierte Umgebungscharakteristik (vgl. Kapitel 4.1) die zugehörigen SPRT-Parameter ermittelt werden. Ein Verfahren zur SPRT-Parameterermittlung für die gewählten Umgebungscharakteristiken wurde in Kapitel 4.4 vorgestellt.

Mit dem ersten Experiment (Kapitel 5.1) konnte gezeigt werden, dass das vorgestellte Verfahren SPRT-Parameter ermittelt und bereitstellt. Die Methode arbeitet rein mit den aufgezeichneten Daten und kann somit auf einen breiten Trainingsdatensatz angewendet werden. Die erzeugten und vorgestellten Ergebnisse spiegeln das durch visuelle Inspektion wahrgenommene Sensorikverhalten numerisch in den drei SPRT-Parameterwerten wider. Gegenüber bisherigen Ansätzen können mit dem Verfahren einfach, effizient und systematisch die benötigten Parameterwerte für Landmarken berechnet werden. Zusätzlich können mit den gewonnenen sensorspezifischen Parametern für die jeweilige Umgebungscharakteristik die einzelnen Sensoren

gegeneinander verglichen und bewertet werden. Die berechneten sensorspezifischen Parameter aus dieser Untersuchung waren für alle weiteren Experimente die Grundlage zur Kartenerstellung und für den Aufbau des Umfeldmodells. Als Ergebnis des Experiments lässt sich festhalten, dass die vier Fischaugenkameras des TopView-Systems (vgl. Anhang A.5.2) und der Laserscanner (vgl. Anhang A.5.1) die jeweiligen Landmarken mit einer sehr hohen Genauigkeit und geringen Fehlerrate erkennen. Die Fischaugenkameras zeigen sowohl für linienbasierte als auch polylinienbasierte Landmarken eine durchschnittliche Genauigkeitsrate von ca. 0.786 und eine durchschnittliche Fehlerrate von 0.267. Der Laserscanner erkennt linienbasierte Landmarken mit einer Genauigkeitsrate von 0.73 und einer Fehlerrate von 0.25, während punktbasierte Landmarken mit einer Genauigkeitsrate von 0.69 und einer Fehlerrate von 0.25 detektiert werden. Die eingesetzte Front-Monokamera arbeitet am unzuverlässigsten und liefert sowohl für linienbasierte als auch polylinienbasierte Landmarken eine Genauigkeitsrate von ca. 0.5 und eine Fehlerrate von ca. 0.3. Eine genaue Auflistung aller ermittelten Werte ist in Tabelle 5.1 gegeben. Aufgrund der hohen Unzuverlässigkeit bei der Landmarkendetektion eignet sich die eingesetzte Front-Monokamera nicht für die Kartierung und Lokalisierung mit der LbL.

Als Nachteil des Verfahrens kann die Diskretisierung der ermittelten Parameter angesehen werden. Mit dem aktuellen Vorgehen wird ein Wert unabhängig vom Abstand der Landmarke zum Fahrzeug festgelegt. Die Nutzung der einzelnen Werte pro Entfernungsintervall könnte eine feinere Betrachtung ermöglichen. Hierbei kann auch eine Spline-Funktion durch die Werte der Entfernungsintervalle gelegt werden. So wird eine kontinuierliche Aussage in Abhängigkeit des Abstandes erreicht. Innerhalb des TFM kann ein solches SPRT-Parametermodell für eine genauere zeitliche Nachverfolgung und Fusion verwendet werden. Die im TFM durchgeführte Konfidenzwertberechnung wird somit verbessert. Das führt zu verfeinerten Umfeldmodellen und Karten.

Der verwendete Trainingsdatensatz zur Ermittlung der SPRT-Parameter wurde in dieser Arbeit allgemeingültig gehalten und einmalig bestimmt. Er beinhaltet Fahrten bei ähnlicher Konstellation (Trockenheit, leicht bewölkter Himmel, mittleres Verkehrsaufkommen). Obwohl die Generierung des Landmarkenumfeldmodells und der Karte im TFM mit den ermittelten SPRT-Werten für die einzelnen Sensoren zu guten Ergebnissen führt (siehe Kapitel 5.2 zur Untersuchung der Kartierung und Lokalisierung), bleibt die Frage offen, ob mit einer situationsspezifischen Auflösung (z.B. Ermittlung spezifischer SPRT-Parameter für unterschiedliche Witterungsszenarien) der SPRT-Werte eine Verbesserung der Kartierung und Lokalisierung erreicht werden kann. Als weiterer offener Punkt ist die Fragestellung, ob durch eine ständige Nachführung der Parameter eine Steigerung der Kartierungs- und Lokalisierungsqualität bewerkstelligt werden kann.

## **Experiment 2: Untersuchung der Kartierung und Lokalisierung**

Das zweite Experiment (Kapitel 5.2) untersucht die entwickelten Verfahren der LbL zur präzisen Lokalisierung und Kartierung. Es bildet den Schwerpunkt der durchgeführten Analysen.

Im Rahmen der Experimente erfolgte eine qualitative und quantitative Betrachtung der erstellten Karten (siehe Kartenbewertung in Kapitel 5.2.2) sowie der erzielten Lokalisierungsgenauigkeit (siehe Lokalisierungsbewertung in Kapitel 5.2.3). Es wurde eine vielseitige, weitläufige Versuchsstrecke verwendet. Sie beinhaltet sowohl dichte urbane Gebiete als auch ländliche

Teilabschnitte. Es konnte belegt werden, dass die erzeugten linienbasierten Karten robust gegen Veränderungen (Verdeckungen, Verschmutzung etc.) sind und eine präzise Lokalisierung möglich ist. Entsprechend den Erläuterungen in Kapitel 1 und Kapitel 2.5, wird rein auf einer linienbasierten lokalen sowie globalen Umfeldrepräsentation gearbeitet. Es ergeben sich kompakte, dünn besetzte Karten, die auch während der Lokalisation erzeugt werden. Diese Vorgehensweise zur Verwendung eines einheitlichen dünnen Umfeldmodells ist der Grundbaustein für zukünftige inkrementelle Kartenaktualisierungen der Randbedingung R1 (Dezentrale Karte). Verfahren und Problemstellungen bei einer Aktualisierung der dezentralen Karte, wie zum Beispiel der Umgang mit Inkonsistenzen, sind jedoch nicht Bestandteil der vorliegenden Dissertation und wurden in den Experimenten nicht untersucht.

## Kartierung

Die Fragestellung zur Verwendbarkeit und Robustheit der herangezogenen Umgebungscharakteristiken der Straßeninfrastruktur ist Fokus der Untersuchungen in Kapitel 5.2.2. Alle drei verwendeten Landmarkentypen (in den geometrischen Grundprimitiven: punktbasierte, linienbasierte und polylinienbasierte Landmarken) sind sowohl einzeln als auch kombiniert untersucht worden, indem jeweils Karten aus unterschiedlichen Kartierungen miteinander verglichen wurden. Durch die orts aufgelöste Analyse (siehe Kapitel 4.4) von Genauigkeit, Empfindlichkeit und Ähnlichkeit der Karten konnten direkt Aussagen über die einzelne und kombinierte Verwendung der Landmarkentypen gegeben werden. Es sind Bereiche identifiziert worden, in denen eine stärkere Diskrepanz der Kartenähnlichkeit auftritt, die weitergehend betrachtet wurden. Es zeigt sich, dass reine punktbasierte Karten die schlechteste Ähnlichkeit (durchschnittliche Rate aus Hinfahrt und Rückfahrt von 0.565) besitzen, jedoch die Kombination aller Landmarkentypen zu Karten mit hohen Ähnlichkeiten (durchschnittliche Rate aus Hinfahrt und Rückfahrt von 0.735) bei geringen Speichergrößen führt. Bei reinen punktbasierten Karte im NDS-Kartenformat ergibt sich eine durchschnittliche Kartengröße von 12.8 Kilobyte pro Kilometer (bei einer Anzahl von insgesamt durchschnittlich 752 Landmarken) und bei einer kombinierten Karte (punktbasierte, linienbasierte und polylinienbasierte Landmarken) eine durchschnittliche Kartengröße von 249.18 Kilobyte pro Kilometer (bei einer Anzahl von insgesamt durchschnittlich 3106 Landmarken). Kapitel 5.2.4 führt die unterschiedlichen Kartengrößen in diversen Kartenformaten auf. Es zeigt sich, dass die Kombination der untersuchten Straßeninfrastrukturcharakteristiken robuste Karten erzeugt. Insgesamt konnten mit dem SPRT-Verfahren, aufgrund der unterschiedlichen Sensorparametrisierung für die einzelnen Landmarken, hohe Kartenqualitäten (Ähnlichkeit  $\geq 0.7$ ) erreicht werden. Die verwendeten SPRT-Parameter wurden einmalig in einem großen Trainingsdatensatz bestimmt und anschließend für alle Kartierungen unverändert verwendet. Bislang ist dem Autor nicht bekannt, dass eine solch intensive orts aufgelöste Betrachtung der herangezogenen Straßeninfrastrukturcharakteristiken in der Literatur zu finden ist.

Nachteilig auf den vorgestellten Kartenvergleich wirkt sich die Nichtbeachtung der dynamischen (z.B. fahrende Fahrzeuge) bzw. semi-statischen Objekte (z.B. parkende Fahrzeuge) innerhalb des TFM aus. Durch dynamische und semi-statische Objekte können Landmarken während der ersten Kartierung durch die Sensorik fehlerhaft erkannt und in der Karte abgelegt worden sein. In der zweiten Kartierung werden diese Fehlerkennungen evtl. nicht mehr wahrge-

nommen (parkendes Fahrzeug nicht mehr da) oder es entstehen neue, falsche Karteneintragen. Durch die Integration der Wahrnehmung von dynamischen und semi-statischen Objekten, wie beispielsweise anderen PKW, innerhalb des TFM kann dieser Diskrepanz entgegengewirkt werden. Das kann durch eine schwächere Konfidenzwertberechnung (vgl. Kapitel 4.2.5) der Landmarken im Bereich um die dynamischen bzw. semi-statischen Objekte erfolgen. Der Vorteil einer solch differenzierten SPRT-Konfidenzwertberechnung innerhalb des TFM führt zu harmonischeren Karten, in denen weniger Fehlerkennungen eingetragen sind. Dadurch wird die Ähnlichkeit der einzeln erzeugten Karten weiter gesteigert.

Die offenen Fragestellungen der vorhergehenden Diskussion zum Experiment der SPRT-Parameterermittlung können hier direkt aufgegriffen und eingebracht werden. Da im TFM die SPRT-Werte sowohl zur Fusion und zeitlichen Nachverfolgung der Landmarken als auch zur Kartengenerierung verwendet werden, wirkt sich deren Veränderung unmittelbar auf die Ergebnisse der Kartierung aus.

Als weitere Schwäche der durchgeführten Auswertung kann der fehlende Vergleich der Karten zu einer definierten Referenzkarte aufgefasst werden. Die Fragestellungen, welche Landmarken in einer solchen Referenzkarte enthalten sein müssen und wie die Landmarken erzeugt werden, spielen entscheidende Rollen. Sowohl in der Literatur als auch in dieser Arbeit (vgl. Kapitel 5.1) werden solche Referenzkarten durch manuelles Erfassen der definierten Landmarken aus Luftbildern erstellt. Zum einen ist das Vorgehen für weitläufige Streckenabschnitte ungeeignet und zum anderen könnten Landmarken in die Referenzkarte aufgenommen werden, die durch die Sensorik nicht wahrnehmbar sind. Deshalb liefert ein solcher Vergleich der generierten Karten zu einer Referenzkarte, im Hinblick auf die Randbedingung R1 „Dezentrale Karte“, nicht zwingend aussagekräftige Ergebnisse.

## Lokalisierung

Der zweite Untersuchungsteil umfasste die Lokalisierungsbewertung (vgl. Kapitel 5.2.3). Mit einer qualitativen und quantitativen Auswertung wurde gezeigt, dass mit dem entwickelten Verfahren, der LbL, eine präzise Lokalisierung (durchschnittlicher  $3\sigma$ -Wert aus Hinfahrt und Rückfahrt für den absoluten Positionsfehler  $\leq 1.025$  Meter) möglich ist. Es wurde belegt, dass ein selbstfahrender PKW, der lediglich über die unscharfe Lageinformation des GPS, seine Eigenbewegungsschätzung und eine linienbasierte Karte verfügt, nun die Fähigkeit besitzt, sich zum einen präzise in Weltkoordinaten zu lokalisieren (siehe Kapitel 4.3), und zum anderen in der Lage ist, durch seine sensorischen Umgebungsinformationen kombiniert ein Umfeldmodell sowie eine Karte aufzubauen (siehe Kapitel 4.2). Die LbL erreichte in den durchgeführten Experimenten auf der vorgestellten Versuchsstrecke eine absolute Genauigkeit von ca. einem Meter ( $3\sigma$ -Wert, d.h. für 99.7% aller Positionsfehler) in WGS84-Koordinaten. Für die Registrierung des Umfeldmodells in die Karte im PLM wurden 1000 Partikel verwendet. Die Genauigkeit wurde durch das präsentierte neue Sensormodell SoG (siehe Kapitel 4.3.2) ermöglicht. Die benötigte Rechenzeit und der benötigte Speicherbedarf sind im Vergleich zu herkömmlichen MCL-Ansätzen als gering einzustufen. Das liegt an der Abstraktion der Sensordaten, also der Modellierung der verwendeten Umgebungscharakteristiken als geometrische Grundprimitive und dem effizienten Sensormodell des PLM.

Die geforderte Genauigkeit von  $\pm 0.725$  Metern für den Querversatz (lateral Fehler) wurde lediglich bei der Hinfahrt erreicht ( $3\sigma$ -Wert von 0.4 Metern für den lateralen Positionsfehler). Die betrachtete Rückfahrt erzielte lediglich einen  $3\sigma$ -Wert von 0.9 Meter beim lateralen Positionsfehler. Wird die qualitative und quantitative Auswertung der Lokalisierung herangezogen, ist ersichtlich, dass vor allem bei der Initialisierungsphase der Rückfahrt große Ungenauigkeiten (longitudinale und laterale Positionsfehler  $\geq 0.7$  Meter) auftreten. Erklärt werden kann das Verhalten mit einem Kaltstart der Messfahrt, wodurch sich Abschattungen und Mehrwegausbreitungen der GPS-Pose direkt auf die LbL-Pose auswirken. Trotz der verwendeten ungenauen globalen Pose- und Eigenbewegungsschätzung (siehe Kapitel 3.1.2 und Kapitel 3.1.3) ist festzuhalten, dass Blickrichtungs-, Geschwindigkeits- und Gierwinkelfehler der LbL-Pose mittelwertfrei um 0 schwanken (vgl. Anhang D.4).

Deutlicher Nachteil des entwickelten LbL-Ansatzes ist die fehlende Redundanz und die in der Vergangenheit liegende Poseausgabe. Unter fehlender Redundanz ist zu verstehen, dass die LbL ein einzelnes, abgeschlossenes System bildet. Für selbstfahrende PKW wird ein solches System alleine nicht ausreichen. Obwohl die LbL z.B. beim Wegfall von Landmarken über einige Zeit hinweg eine präzise Pose liefert, ist das für komplexe Fahrmanöver nicht mehr ausreichend. Um das sicherzustellen, ist die Fusion von mehreren Lokalisationsquellen nötig. Mit graphbasierten Ansätzen wie dem g2o-Framework [271] kann diese Herausforderung gelöst werden. Durch die zuverlässige und gute Poseausgabe eignet sich die LbL in besonderem Maße als Eingangsquelle einer solchen Fusion. Mit der Nutzung von [271] kann die in der Vergangenheit liegende Pose der LbL zum aktuellen Zeitpunkt prädiert und mit weiteren Posen sinnvoll fusioniert werden.

Eine weitere Einschränkung der LbL ist die Verwendung der aufgeführten Umgebungscharakteristiken der Straßeninfrastruktur. Bei der Verwendung solcher abstrakter Datenobjekte rückt die Frage nach der durchgängigen Verfügbarkeit der Charakteristiken in den Mittelpunkt. Die LbL ist nur dann zu einer präzisen Lokalisierung fähig, wenn die genutzten Umgebungscharakteristiken der Straßeninfrastruktur zum einen in der Karte vorhanden sind und zum anderen aktuell wahrgenommen werden. Fahrten in Bereiche ohne die Charakteristiken (z.B. in einer Tiefgarage oder auf einem Parkplatz) führen zu Drifts und dem Verlust des richtigen Lokalisierungsergebnisses der LbL. Um dem entgegenzuwirken und zur Steigerung der Verlässlichkeit der LbL, sollten weitere Charakteristiken, zum Beispiel Häuserfassaden, die als geometrisches Grundprimitiv „Fläche“ modellierbar sind, ergänzend hinzugenommen werden.

### **Experiment 3: Witterungsbasierte Lokalisierungsoptimierung**

Kamerabasierte Verfahren zur Erkennung der verwendeten Umgebungscharakteristiken sind mit Nachteilen behaftet, die sich durch atmosphärische Störungen (z.B. Jahreszeiten, Wetterveränderungen und Lichteffekte) ergeben [14, 211, 265]. Mit dem letzten Experiment (Kapitel 5.3) wurde untersucht, ob sich die Nachteile durch eine Optimierung der LbL in einzelnen Situationsgruppen ausgleichen lassen. Bei der Betrachtung der Qualität der Lokalisierung und den erstellten Karten zeigt sich, dass insbesondere bei Zunahme der Sensorfehler in Qualität und Quantität eine stärkere Abnahme der Lokalisierungs- und Kartenqualität hervorgerufen wird. Als Sensor wurde die Front-Monokamera herangezogen. Es wurde gezeigt, dass die Reduktion der Sensorfehler in den Situationsgruppen Regen, Nässe und Trockenheit durch einen angepassten Sichtbereich im TFM zu einer verbesserten Lokalisierung führt (durchschnittli-

che Verbesserung der Lokalisierung um ca. 0.15 Meter). Für diesen Nachweis der Korrelation wurde der verwendete Sichtbereich in jeder Situationsgruppe variiert und die erzielte Lokalisierungsgenauigkeit der LbL mit der Referenzlokalisierung verglichen. Für jede Situationsgruppe konnten optimierte Sichtbereiche ermittelt und präsentiert werden, die im Vergleich zu einem Standardsichtbereich bessere Lokalisierungsgenauigkeiten in der jeweiligen Gruppe erreichen.

Das durchgeführte Experiment kann als erster Ansatz für eine adaptiv nachgeführte Parametrisierung innerhalb der LbL aufgefasst werden. Es behandelt jedoch lediglich den Teilaspekt der Optimierung des Sichtbereichs zur Vermeidung von Sensorfehlern und der Verbesserung des Umfeldmodells im TFM. Andere Aspekte wie die aktuelle Erfassung der äußeren Situation (Regen, Nebel etc.) oder andere Optimierungsgegenstände wurden nicht untersucht. Zur Erfassung der äußeren Situation wird hier auf die in [266–268] vorgestellten Verfahren verwiesen. Die offene Frage nach weiteren Optimierungsparametern und der Diskretisierung der verwendeten Situationsgruppen kann als Einschränkung des Verfahrens gewertet werden. Wird die gewählte Methode ausgebaut, sind Fragen zur Optimierung der Partikelstreuung, der Partikeldämpfung oder der SPRT-Parameterbestimmung für eine jeweilige Situationsgruppe beantwortbar. In einem abschließenden Vergleich können die ermittelten Parameterkombinationen festgehalten werden und während der Lokalisierung Verwendung finden.

# Kapitel 7

## Zusammenfassung und Ausblick

Für den zuverlässigen und robusten Einsatz in aktuellen wie zukünftigen Anwendungsszenarien selbstfahrender PKW sind Verfahren zur Lokalisation und Kartierung unabdingbare, fundamentale Voraussetzungen. Eine Herausforderung für die präzise Lokalisierung ist vor allem der Arbeitsraum, die reale Umgebung, in der vielfältige dynamische Veränderungen (natürliche Wachstumsvorgänge, künstliche infrastrukturelle Änderungen, atmosphärische Störungen etc.) auftreten. Der weitläufige und fortlaufend veränderte Arbeitsraum erlaubt die Integration zusätzlicher spezieller Infrastruktur (z.B. Reflektorfolie, Magneträger) nicht. Die zuverlässige und präzise Lokalisierung der mobilen Systeme muss ohne Anpassungen der Arbeitsumgebung und trotz der auftretenden dynamischen Veränderungen ermöglicht werden.

Zur Erfüllung der Voraussetzung unter den genannten Herausforderungen werden in der Literatur Lokalisierungsverfahren eingesetzt, die aufgrund der aktuellen Eigenbewegungs- sowie Umgebungswahrnehmung die Position und Orientierung des mobilen Systems innerhalb einer vorab bekannten Karte ermitteln. Die Grundlage für die Erstellung des Kartenmodells und der Lokalisierung bildet die sensorische Umgebungswahrnehmung, deren populärste Vertreter Laserscanner und Kameras sind. In den bislang existierenden Verfahren werden die Kartierung und Lokalisierung jedoch getrennt voneinander betrachtet. Es wird mit gesonderten Methoden und Sensoren die zur Lokalisation benötigte Karte erstellt und eine fortlaufende Gültigkeit der Karte angenommen. Als Folge dessen sind nicht alle während der Lokalisierung wahrgenommenen Objekte in der Karte enthalten und umgekehrt wird nicht jedes in der Karte enthaltene Objekt wahrgenommen. Der zuverlässige und robuste Einsatz der Karte ist deshalb nicht durchgängig möglich. Die Problematik kann nur gelöst werden, indem zukünftig die Karte während der Lokalisierung ständig aktualisiert wird (vgl. Erläuterungen der Randbedingungen R1 (Dezentrale Karte) und R4 (Initiales Vorwissen)). Mit den bisherigen Ansätzen der Literatur ist das aufgrund der unterschiedlichen Sensorkonstellationen, Umfeldrepräsentationen und daraus resultierenden Kartengrößen durch die getrennte Betrachtung der Phasen Lokalisierung und Kartierung nicht möglich. Der erste notwendige Schritt zur Ermöglichung von Kartenaktualisierungen ist sowohl ein einheitliches dünnes Umfeldmodell (geringe Anzahl an Elementen und evtl. Lücken, engl. sparse map), das eine präzise Lokalisierung erlaubt, als auch die kombinierte Betrachtung von Kartenerstellung und Lokalisierung.

Deshalb wurde im Rahmen dieser Arbeit zur Lösung der Problematik die Ortungsarchitektur Landmarkenbasierte Lokalisierung (LbL, siehe Kapitel 4.1) vorgestellt und untersucht.

Die zentrale Grundidee der vorgestellten Architektur ist eine im Rechenzentrum bereitgestellte dezentrale Karte. So wird die Möglichkeit geschaffen, einen bidirektionalen Austausch über eine Luftschnittstelle zwischen PKW und Rechenzentrum mit den jeweils benötigten Kartendaten durchzuführen. Der resultierenden Notwendigkeit, Bandbreiten, Datenbanken und Umfeldrepräsentationen kompakt zu halten, trägt das vorgestellte Verfahren Rechnung, indem ein linienbasiertes lokales und globales Umfeldmodell verwendet wird. Um robust gegen die dynamischen Veränderungen des Einsatzgebietes zu sein und gleichzeitig eine präzise Lokalisierung zu gewährleisten, werden charakteristische Elemente der Straßeninfrastruktur herangezogen. Die Charakteristika stehen als abstrakte, klassifizierte sowie aggregierte Sensordaten der verwendeten Sensorik zur Verfügung und sind als geometrische Grundprimitive modelliert. Unter Einhaltung der in Kapitel 1.2 aufgestellten Randbedingungen (R1 bis R7), die als Einschränkung des Lösungsraums der Ortungsarchitektur dienen, konnte das Hauptziel der präzisen Lokalisierung in der LbL erreicht werden. Die Herausforderungen und Problemstellungen einer kontinuierlichen Aktualisierung der dezentralen Karte sind jedoch nicht Bestandteil der vorliegenden Dissertation und wurden nicht untersucht.

Im ersten Schritt der Arbeit wurden die zu verwendenden charakteristischen Straßeninfrastrukturelemente des Arbeitsraums selbstfahrender PKW ausgewählt. Es galt, invariante und semi-persistente Umgebungscharakteristika in vielfältigen Außenszenarien zu definieren, die eine präzise Lokalisierung bei geringer Karten- und Umfeldmodellgröße ermöglichen. Zu den herangezogenen Charakteristika gehören Fahrbahnmarkierungen (gestrichelte und durchgezogene Linien sowie Haltelinien und Pfeile) und säulenförmige Objekte (Stangen bzw. Pfosten von Ampelanlagen, Straßenschildern oder Litfaßsäulen). Für eine einheitliche dünne Umgebungsrepräsentation in der Karte und im Umfeldmodell während der Lokalisierung wird eine linienbasierte Repräsentation eingeführt. Eine Modellierung der verwendeten Merkmale (Landmarken) in den drei geometrischen Grundprimitiven Linie, Polylinie (Linienzug) und Punkt wird aufgestellt (siehe Kapitel 4.1.1).

Im Anschluss an die Definition und Modellierung der Landmarken erfolgt die Entwicklung der neuen Verfahren zur Kartierung (dem Tracking- & Fusionsmodell (TFM), siehe Kapitel 4.2) und zur Lokalisierung (dem Partikelfilterbasierten Lokalisierungsmodell (PLM), siehe Kapitel 4.3).

Für das TFM wird eine dreischichtige Architektur, resultierend aus den drei Abstraktionsgraden der Landmarken (Dateneingang, konsistentes Landmarkenumfeldmodell und die Karte), präsentiert. Durch Fusion der Landmarken aus mehreren unterschiedlichen Sensoren sowie zeitliche Nachverfolgung entsteht ein konsistentes linienbasiertes Umfeldmodell und daraus wird kontinuierlich eine linienbasierte Karte erzeugt. Die dreischichtige, modulare Architektur ermöglicht es, sowohl flexibel und effizient weitere neue Landmarken in das Verfahren zu integrieren als auch verschiedene Verarbeitungsmethoden je Abstraktionsgrad einzusetzen. Als mathematische Grundlage zur zeitlichen Nachverfolgung und Fusion der Landmarken wird der statistische Test Sequential Probability Ratio Test (SPRT) zur Anwendbarkeit mit den modellierten Landmarken adaptiert. SPRT wird als Track-Management und zur Berechnung eines Konfidenzwertes für jede Landmarke eingesetzt. Es wurde in der Arbeit gezeigt, dass sowohl unterschiedliches Zeitverhalten (Asynchronitäten) als auch verschiedene Qualitäten sowie Quantitäten der Eingangsdaten vom TFM bearbeitet werden und eine möglichst korrekte Umgebungsrepräsentation generiert wird. Auf dieser Grundlage wird das TFM in beiden Phasen,



sowohl in der Kartierung als auch in der Lokalisierung zum kombinierten Aufbau des Umfeldmodells und einer Karte, mit jeweils der gleichen umfeldwahrnehmenden Sensorik eingesetzt. Im Vergleich zu bisherigen Ansätzen der Literatur, die auf punktbasierte oder rasterbasierte Umgebungsmodelle setzen, wird eine einheitliche dünne Karten- und Umfeldrepräsentation ermöglicht.

Zur Erreichung einer präzisen und robusten Lokalisierung unter Einbeziehung der dezentralen Karte, des aktuellen Umfeldmodells, der Eigenbewegungsschätzung und einer globalen Poseschätzung wurde das probabilistische Verfahren eines Partikelfilters modifiziert. Daraus entstand der hier neu entwickelte PLM-Ansatz zur globalen Lokalisation mit einer linienbasierten Karten- und Umfeldrepräsentation. Kern des PLM ist das neue Sensormodell Sum of Gaussians (SoG) für die Zuordnung von Kartenlandmarken zu Beobachtungen. Mit dem aufgestellten Sensormodell wird eine besonders effiziente, implizite Datenzuordnung aller Elemente durchgeführt. Im Gegensatz zu bisherigen Assoziierungsverfahren, z.B. den NN- oder GNN-Ansätzen, ist keine explizite Eins-zu-Eins-Zuweisung notwendig. Den Vorteil des SoG bildet die genauere Beschreibung der Zuordnung zwischen Kartenlandmarken zu Beobachtungen. Vor allem Mehrdeutigkeiten bei repetitiven Mustern werden korrekt wiedergegeben. Neben dem neu aufgestellten Sensormodell sind im PLM die Verfahren der dynamischen Partikelstreuung, des Bewegungsmodells, des Resamplings und Samplings modifiziert worden. Das führt im PLM zu einem prädestinierten Ansatz der Lokalisierung von selbstfahrenden Kraftfahrzeugen.

Sowohl im TFM als auch im PLM werden Distanzfunktionen zur Korrespondenzbestimmung benötigt. Im TFM müssen zur zeitlichen Nachverfolgung die neuen Eingangsdaten dem Umfeldmodell zugeordnet werden, während im PLM die Assoziierung des erhaltenen Umfeldmodells zu den Kartenlandmarken durchgeführt wird. Abstandsmetriken für die in dieser Arbeit festgelegte Modellierung der Landmarken in den drei geometrischen Grundprimitiven sind bisher nicht vorhanden. Daher sind neue Abstandsmetriken zur Korrespondenzbestimmung entwickelt und formal eingeführt worden.

In Kapitel 5 wurden die neu entwickelten Ansätze auf ihre Anwendbarkeit in einem selbstfahrenden PKW unter realen Bedingungen auf einer komplexen, vielfältigen Versuchsstrecke untersucht. Die vorgestellten Verfahren zur Kartierung und Lokalisierung sind auf einem realen System einsetzbar sowie speicher- und recheneffizient. Zur Bewältigung der Gegebenheiten der Einsatzumgebung wurde eine Multisensor-Umfeldwahrnehmung zur Erkennung ausreichend vieler Landmarken eingesetzt. Es konnte gezeigt werden, dass mit den festgelegten Straßeninfrastrukturmerkmalen und deren Modellierung in geometrischen Grundprimitiven bei Verwendung der entwickelten Verfahren TFM und PLM eine präzise, robuste Lokalisierung erreicht wird. Die Wahl der linienbasierten Repräsentation zur Kartierung zeichnet sich gegenüber anderen Verfahren dadurch aus, dass zum einen geringerer Speicherplatz benötigt und zum anderen eine zuverlässige, korrekte Karte erstellt wird. Die Lokalisierung resultiert in einer präzisen, robusten Pose trotz evtl. ungünstiger Bedingungen (z.B. Lücken, wenige Landmarken) in der Karte oder dem Umfeldmodell. Ein Nachteil des Systems liegt derzeit in der nicht präzisierten Pose des PLM (Ausgabe liegt zur aktuellen Zeit in der Vergangenheit (vgl. Randbedingung R6 (Zeitstempel und Zeitverhalten))). Ein weiteres Defizit ergibt sich aus der fehlenden Poseredundanz innerhalb der LbL-Gesamtarchitektur. Es wird lediglich die berechnete Pose des PLM ausgegeben, eine Redundanz für einen Ausfall oder eine Fehlberechnung der PLM-Pose ist in der LbL nicht vorhanden. Durch Integration und Fusion weiterer Lokalisationsquellen mit

dem in [271] beschriebenen Vorgehen könnte dieser Mangel in einem nachgelagerten Verarbeitungsschritt behoben werden.

Insgesamt bildet die LbL einen vielversprechenden Ansatz zur Lokalisierung selbstfahrender PKW. Sie bietet eine Architektur, in der zukünftig jeder PKW zu einem Messfahrzeug werden könnte, um eine dezentrale Karte mit inkrementellen Aktualisierungen stets auf dem neuesten Stand zu halten. Zur Erreichung dieser Vision müssen die Aspekte von kontinuierlichen Kartenaktualisierungen innerhalb der LbL untersucht werden. Zur weiterführenden Untersuchung dieser Thematik bietet es sich an, die vorgestellten Methoden aus [154] oder [157, 264] zu integrieren. Ermöglicht wird das durch ein einheitliches Verfahren zur Erstellung von Karte und Umfeldmodell, wodurch insbesondere dieselbe Repräsentation der Elemente beibehalten wird. Gleichzeitig erreicht die LbL eine präzise und robuste Lokalisierung.

Gegenstand zukünftiger Forschungen sollten zum einen die in Kapitel 6 diskutierten Einschränkungen der LbL sein und zum anderen der in dieser Arbeit nicht betrachtete Aspekt der Integration der vom TFM erzeugten inkrementellen Kartenaktualisierungen für die dezentrale Karte während der Lokalisierung. Erste Ansätze einer solch dezentral lernenden Karte sind in [31–34] beschrieben. Bislang existiert jedoch keine umfassende Untersuchung des geschlossenen Verfahrens. Als weitere vielversprechende Fragestellung ergibt sich die Verbindung unterschiedlicher Umweltrepräsentationen im TFM. Solche hybride Repräsentationsformen sind bereits in [272] diskutiert worden und bringen den Vorteil, dass je nach Vorhandensein ausreichend vieler Umgebungscharakteristiken unterschiedliche Repräsentationen verwendet werden können.

Das in Kapitel 4.4 erläuterte Verfahren zur SPRT-Parameterbestimmung kann in weiteren Untersuchungen um die in [200] beschriebene Methode der Cross-Evaluierung erweitert werden. Zu prüfen ist, ob eine genauere Bestimmung der SPRT-Parameter erfolgt.

Die verwendeten generalisierten Fehlermodelle basieren auf der Verwendung von detektierten Landmarken (siehe Kapitel 3.1.4). Die Möglichkeit, vorhandene systematische Fehler im Abbildungsmodell korrigieren zu können, besteht daher nicht. Die Annahme einer ebenen Fahrbahn im Modell führt zu Abbildungsfehlern, deren Größe abhängig von der Distanz des Fahrzeugs ist. Es fließen nicht alle Abbildungsfehler in das Fehlermodell ein. In weiteren Arbeiten sollte das bestehende Fehlermodell erweitert und vor allem durch sensorspezifische Abbildungsmodelle ergänzt werden. Auf Basis dessen kann sich von der Annahme einer ebenen Fahrbahn gelöst werden und ein Höhenmodell, entsprechend des Ansatzes in [30], integriert werden. Die durchgeführten Optimierungen sollten zur Verbesserung der Lokalisierung führen.

Selbstfahrende PKW werden in natürlichen Arbeitsumgebungen eingesetzt und sind deshalb direkt atmosphärischen Störungen ausgesetzt. Statisch implementierte Algorithmen mit einmalig ermittelten Parametersätzen sind nicht in der Lage, sich adaptiv auf geänderte äußere Umgebungsbedingungen einzustellen. Nur mit einer adaptiven Nachführung der Parametersätze können die mobilen Systeme auf veränderte Bedingungen, wie z.B. Nebel, Regen oder Schnee, reagieren. Erste Untersuchungen und Vorschläge zur adaptiven Nachführung, um die Lokalisierung in einzelnen Situationsgruppen zu verbessern, wurden in Kapitel 5.3 und [270] bereits erbracht. Eine Diskussion und ein Ausblick zur Erweiterung der hier verwendeten Ansätze wurde in Kapitel 6 (vgl. Experiment 1: SPRT-Parameterermittlung und Experiment 3: Witterungsbasierte Lokalisierungsoptimierung) aufgeführt. Aufbauend darauf, können weitere

---

Verfahren entwickelt werden, um eine situationsbedingte, sensorspezifische Parametrisierung zur adaptiven Nachführung in der LbL zu integrieren. Dadurch wäre der selbstfahrende PKW in der Lage, sich den Veränderungen der atmosphärischen Umgebung anzupassen.

Insgesamt sind die in Kapitel 1.1 aufgestellten Ziele und deren wissenschaftlicher Beitrag in der vorliegenden Arbeit erbracht worden. Es wurden die folgenden Kernpunkte aufgezeigt, erläutert und diskutiert:

- Untersuchung auf Eignung der beschriebenen Landmarken zur Kartierung und Lokalisierung
- Vorstellung des entwickelten Verfahrens, des Partikelfilterbasierten Lokalisierungsmodells (PLM) zur präzisen Lokalisierung, das durch Korrespondenzbestimmung zwischen linienbasiertem Umfeldmodell und einer linienbasierten Karte die Pose des Fahrzeugs ermittelt
- Vorstellung des entwickelten einheitlichen Verfahrens für die Kartierung und Lokalisierung, des Tracking- & Fusionsmodells (TFM) das effizient und modular die Fusion sowie zeitliche Nachverfolgung der Landmarken aus unterschiedlichen Sensoren ermöglicht
- Durchführung der experimentellen Evaluation und Prüfung der Landmarkenbasierten Lokalisierung (LbL) auf die Eignung für den Einsatz in selbstfahrenden Personenkraftwagen

# Anhang A

## Versuchsträger und Sensorik

Nachfolgend ist der verwendete Versuchsträger und dessen Sensorik weiterführend beschrieben, um zusätzliche Informationen zur besseren qualitativen Einordnung bereitzustellen. Eine Übersicht des Versuchsträgers und der einzelnen Sensoren ist in Kapitel 3.1 gegeben.

### A.1 Architektur des Versuchsträgers

Abbildung A.1 veranschaulicht schematisch die beschriebene „Data Distribution Service“-Architektur (DDS) des Versuchsträgers (vgl. Kapitel 3.1). Es ist eine Übersicht der Architektur im Sinne der Vernetzung der Systeme im Versuchsträger aufgezeigt. Die Linien mit den Pfeilen zeigen die Kommunikationsrichtung an. Die beiden rot und blau eingefärbten dicken Linien stellen den Hauptstrang des jeweiligen Systems dar. Die roten Komponenten bilden die Sensorik (Umfeldwahrnehmung, Eigenbewegungsschätzung und globale Poseschätzung). Das Ortungsreferenzsystem mit seinen Teilkomponenten (vgl. Kapitel 3.1.1 und Anhang A.2) ist blau eingefärbt. Die Rechnersysteme (das DDS-Gateway, der LbL-PC und der Datenaufzeichner) sind orange visualisiert. Alle Rechnersysteme verwenden Standard-Hardware (Intel Core i7 3.2 GHz, 8 GB Arbeitsspeicher, 120 GB SSD Festplatte, Windows 7 Embedded 64Bit Betriebssystem).

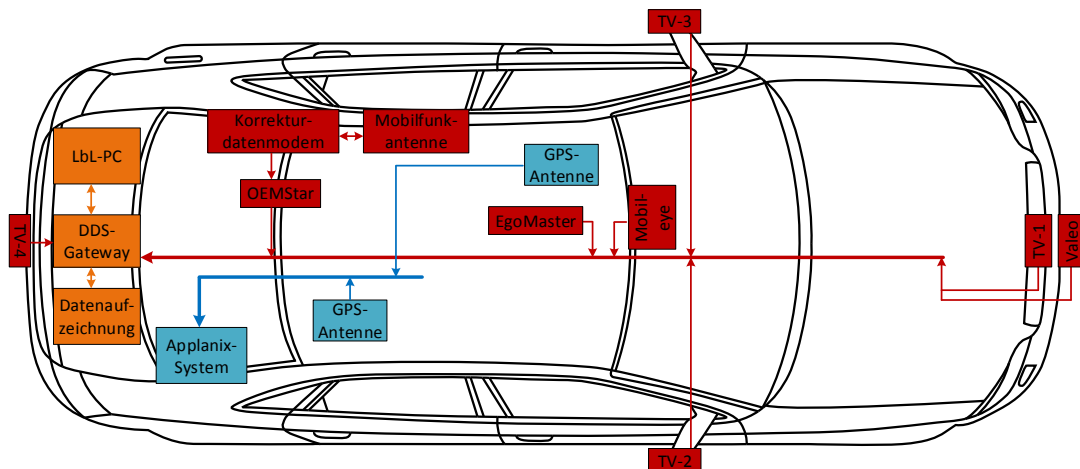


Abbildung A.1: Architektur des Versuchsträgers

## A.2 Beschreibung und technische Daten der Ortungsreferenz

Abbildung A.2 stellt die einzelnen Komponenten des „Applanix POS LV 510“-Systems dar. Die Tabellen A.1 und A.2 listen die Daten zur Genauigkeit des Systems laut Herstellerangaben auf [273]. Die Ausgabefrequenz der Applanix liegt bei 200 Hertz.



Abbildung A.2: Komponenten der verwendeten Ortungsreferenz „Applanix POS LV 510“ [274] (links: Zwei Antennen zum GPS-Empfang, mittig: IMU, rechts: Rechen- und Aufnahmeeinheit)

Tabelle A.1: Genauigkeiten des „Applanix POS LV 510“-Systems mit GNSS [273]

POS LV 510	PP <sup>1</sup>	IARTK <sup>2</sup>	DGPS <sup>3</sup>
X,Y-Position <sup>4</sup> (Meter)	0.020	0.035	0.300
Z-Position <sup>4</sup> (Meter)	0.050	0.050	0.500
Nick- und Rollwinkel <sup>4</sup> (Grad)	0.005	0.008	0.008
Gierwinkel <sup>4</sup> (Grad)	0.015	0.020	0.020

Tabelle A.2: Genauigkeiten des „Applanix POS LV 510“-Systems ohne GNSS [273]

POS LV 510	PP <sup>1</sup>	IARTK <sup>2</sup>	DGPS <sup>3</sup>
X,Y-Position <sup>4</sup> (Meter)	0.100	0.300	0.420
Z-Position <sup>4</sup> (Meter)	0.070	0.0100	0.530
Nick- und Rollwinkel <sup>4</sup> (Grad)	0.005	0.008	0.008
Gierwinkel <sup>4</sup> (Grad)	0.015	0.020	0.020

<sup>1</sup>Post-Processed

<sup>2</sup>Inertially Aided Real-Time Kinematic

<sup>3</sup>Differential Global Positioning System

### A.3 Beschreibung und technische Daten der globalen Poseschätzung

Abbildung A.3 zeigt den verwendeten GPS-Empfänger „FlexPak-G2 OEMStar der Firma NOVATEL“ auf.



Abbildung A.3: Verwendeter GPS-Empfänger OEMStar zur globalen Poseschätzung [275]

Tabelle A.3 fasst die vom Hersteller bereitgestellten technischen Angaben zusammen [275]. Die Ausgabefrequenz wird mit 10 Hertz angegeben, die Zeit bis zur ersten Poseausgabe beträgt laut Hersteller bei einem Kaltstart 65 Sekunden und circa 35 Sekunden bei einem Warmstart. Alle weiteren Daten können [275] entnommen werden. Eine qualitative Einordnung der Genauigkeit ist in Abbildung A.4 aufgeführt. Es wird der Fehler des OEMStar zur Applanix über eine Versuchsfahrt dargestellt.

Tabelle A.3: Technische Angaben zum OEMStar [275]

	Single Point	GPS	DGPS
Positionsgenauigkeit <sup>4</sup> (Meter)	1.5	0.7	0.5
Zeitgenauigkeit <sup>4</sup> (Nanosekunden)	-	20	40
Geschwindigkeitsgenauigkeit <sup>4</sup> (Meter/Sekunde)	-	0.05	0.05




Abbildung A.4: Genauigkeitsanalyse des OEMStar

<sup>4</sup>Alle Angaben als Root Mean Square (RMS)

## A.4 Beschreibung und technische Daten der Eigenbewegungsschätzung

Das als „EgoMaster“ bezeichnete Verfahren zur Eigenbewegungsschätzung liefert eine Positionsschätzung des Fahrzeugs auf Basis von Geschwindigkeit und Gierwinkel in Bezug zum globalen, fahrzeugeigenen Koordinatensystem OCCS. Zur Bestimmung der Eigenbewegung werden die Sensordaten aus dem Fahrwerk des Fahrzeugs in einem KF fusioniert. Diese Eigenbewegungsschätzung wird direkt, nach der in Kapitel 3.1.3 vorgestellten Geschwindigkeitskorrektur, in der LbL verwendet.

Das Verfahren erzeugt eine Ausgabe in 100 Hertz und stellt nur eine lokale Lokalisierung (Koppelnavigation) dar, was zur Aufsummierung von Drift- und Schlupffehlern führt. Abbildung A.5 zeigt zur qualitativen Einordnung einen Vergleich des verwendeten Verfahrens zur Referenz auf. Im linken Teil der Abbildung ist die Genauigkeit vor der beschriebenen Geschwindigkeitskorrektur wiedergegeben. Der rechte Teil visualisiert die erreichte Genauigkeit nach der Korrektur. Als Ortungsreferenz wurde das Applanix-System verwendet (siehe Kapitel 3.1.1 und Anhang A.2).




Abbildung A.5: Genauigkeitsvergleich der Eigenbewegungsschätzung

## A.5 Beschreibung und technische Daten der Umfeldsensoren

Nachfolgend sind die technischen Daten und Abbildungen der einzelnen Sensoren des Versuchsträgers aus Kapitel 3.1.4 aufgeführt.

### A.5.1 Laserscanner

Abbildung A.6 stellt den beschriebenen Laserscanner aus Kapitel 3.1.4.1 dar. Bei dem Sensor handelt es sich um einen Multibeam-Laserscanner, dessen maximale Reichweite mit 200 Metern (abhängig vom Einbauort) angegeben wird, jedoch effektiv auf 70 Meter begrenzt ist.

Die technischen Daten sind in Tabelle A.4 gegeben. Eine schematische Veranschaulichung des Abtastbereichs ist in Abbildung A.7 und Abbildung 3.5 aufgeführt.



Abbildung A.6: Schematische Darstellung des Laserscanners (links) und die Integration im Versuchsträger (rechts)

Tabelle A.4: Technische Daten des „Ibeo Scala B2“-Laserscanners

Eigenschaft	Wert
Öffnungswinkel horizontal/vertikal (Grad)	145 / 2.4
Vertikale Layeranzahl	4
Scanauflösung horizontal/vertikal (Grad)	0.25 / 0.8
Scanfrequenz (Hertz)	25.0 / 1.5
Reichweite (Meter)	0.3<...<200 (eff. 75)
Messpunkte pro Scan	1743
Distanzauflösung (Zentimeter)	4.0
Einbauhöhe (Zentimeter)	30
Messprinzip	Time-of-Flight <sup>5</sup>
Latenz (Millisekunden)	45

Die Messunsicherheit wird als Standardabweichung angegeben, wobei für die Distanzmessung  $\sigma_d = 10$  Zentimeter und für den horizontalen Winkel  $\sigma_\phi = 3$  Grad gilt.

<sup>5</sup>Signallaufzeitmessung






Abbildung A.7: Schematische Darstellung der Laserstrahlen (Draufsicht)

## A.5.2 Kamersysteme

### A.5.2.1 Front-Monokamera

Abbildung A.8 stellt den verwendeten Sensor dar und Tabelle A.5 listet dessen technische Daten auf.




Abbildung A.8: Darstellung der Front-Monokamera (links) und deren Integration im Versuchsträger (rechts)

Tabelle A.5: Technische Daten der Front-Monokamera

Eigenschaft	Wert
Frequenz (Frames per second)	36
Auflösung (Pixel)	1080 x 960
Helligkeitsunterschiede (Bit)	16
Öffnungswinkel (Grad)	40
Reichweite (Meter)	40
Pixelgröße ( $\mu$ -Meter)	6
Einbauhöhe (Meter)	1.3
Latenz (Millisekunden)	85

#### A.5.2.2 TopView-System

Nachfolgend ist in Abbildung A.9 eine der vier verwendeten Fischaugenkameras visualisiert. Tabelle A.6 gibt die technischen Daten der Fischaugenkamera wieder.




Abbildung A.9: Exemplarische Abbildung einer eingesetzten Fischaugenkamera des TopView-Systems

Tabelle A.6: Technische Daten einer Fischaugenkamera des TopView-Systems

Eigenschaft	Wert
Frequenz (Frames per second)	30
Auflösung (Pixel)	1280 x 800
Öffnungswinkel horizontal (Grad)	190
Öffnungswinkel vertikal (Grad)	123.8
Pixelgröße ( $\mu$ -Meter)	6
Einbauhöhe seitlich (Zentimeter)	97
Einbauhöhe vorne/hinten (Zentimeter)	52.5/78.5
Latenz (Millisekunden)	50

### A.5.2.3 Zusammenhang der Fehlerfortpflanzung

Für das in Teilkapitel 3.1.4.3 erläuterte Fehlermodell der Kamerasysteme ist in Abbildung A.10 ein exemplarischer Verlauf der Fehlerfortpflanzung in Abhängigkeit zur Distanz zum Fahrzeug aufgezeigt. Es werden der Längs- und der Querfehler (longitudinaler und lateraler Fehler) der Landmarkenposition einzeln abgebildet. Es wird deutlich, dass vor allem der Längsfehler mit dem Abstand zum Fahrzeug zunimmt.




Abbildung A.10: Schematischer Zusammenhang der lateralen und longitudinalen Fehlerfortpflanzung der Kamerasysteme

# Anhang B

## Koordinatensysteme und Koordinatentransformationen

In diesem Anhang sind für die aus Kapitel 3.2 eingeführten Koordinatensysteme und beschriebenen Koordinatentransformationen sowohl die notwendigen mathematischen Parameter als auch die Herleitungen der gezeigten Transformationen aufgeführt.

### B.1 Parameter des Erdmodells

Tabelle B.1: Parameter des WGS84-Erdmodells [89]

Bezeichnung	Symbol	Wert
Große Halbachse des Ellipsoids:	a	6378137.0 Meter
Kleine Halbachse des Ellipsoids:	b	$a(1 - f) = 6356752.3142$ Meter
Abflachung des Ellipsoids:	f	$\frac{a-b}{a} \approx \frac{1}{298.257223565}$
Exzentrizität des Ellipsoids:	e	$\sqrt{f(2 - f)} \approx 0.0818191908426$
Länge der Normalen:	$n(\phi^{\text{wgs}})$	$\frac{a}{\sqrt{1 - e^2 \sin^2(\phi^{\text{wgs}})}}$

### B.2 Iterativer Algorithmus zur Rücktransformation von ECEF nach WGS84

Der Algorithmus B.1 zeigt in Pseudocode ein iteratives Vorgehen zur Umrechnung eines Punktes aus dem  $\xi^{\text{ecef}}$ -System in das  $\xi^{\text{wgs}}$ -System. Das Verfahren nimmt als Eingabedaten sowohl den Punkt  $p^{\text{ecef}}$  als auch die maximal erlaubten Fehler  $\epsilon_\phi$  und  $\epsilon_N$  entgegen, um iterativ die konvergierenden Werte  $\phi_{p,i+1}$  und  $N_{i+1}$  zu berechnen. Die Zeilen 2 bis 5 beschreiben die Initialisierung, die Zeilen 7 bis 10 die Konvergenzberechnung und die Zeilen 13 bis 15 geben abschließend die Koordinatenberechnung des Punktes  $p^{\text{wgs}}$  an.

Die Werte für  $a$  und  $e$  sind entsprechend den Angaben in Tabelle B.1 definiert. Die Funktion  $\text{atan2}(y, x)$  in Zeile 13 liefert den Winkel zwischen den Vektoren  $(1, 0)$  und  $(y, x)$  für  $(y, x) \neq (0, 0)$ . Falls  $y \geq 0$ , dann erhält der Winkel ein positives Vorzeichen, andernfalls ein negatives.

---

**Algorithmus B.1** : Transformation eines Punktes  $p^{\text{ecef}}$  in  $\xi^{\text{ecef}}$  nach  $p^{\text{wgs}}$  in  $\xi^{\text{wgs}}$ 


---

**Daten** :  $p^{\text{ecef}} = (x^{\text{ecef}}, y^{\text{ecef}}, z^{\text{ecef}})$ ,  $\epsilon_\phi, \epsilon_N$   
**Ergebnis** :  $p^{\text{wgs}} = (\lambda^{\text{wgs}}, \phi^{\text{wgs}}, h^{\text{wgs}})$

- 1
- 2  $N_0 := a$
- 3  $p := \sqrt{(x^{\text{ecef}})^2 + (y^{\text{ecef}})^2}$
- 4  $\phi_0 := 0$
- 5  $i := 1$
- 6
- 7 **solange**  $|\phi_{i+1} - \phi_i| > \epsilon_\phi$  &  $|N_{i+1} - N_i| > \epsilon_N$  **tue**
- 8      $\phi_{i+1} = \text{atan2}(z^{\text{ecef}} + e \cdot \sin(\phi_i), p)$
- 9      $N_{i+1} = \frac{a}{\sqrt{1 - (e^2 \cdot \sin(\phi_{i+1})^2)}}$
- 10     $i = i + 1$
- 11 **Ende**
- 12
- 13  $\lambda^{\text{wgs}} := \text{atan2}(y^{\text{ecef}}, x^{\text{ecef}})$
- 14  $\phi^{\text{wgs}} := \phi_{i+1}$
- 15  $h^{\text{wgs}} := \frac{p}{\cos(\phi_{i+1})} - N_i$
- 16
- 17 **zurück**  $p^{\text{wgs}}$

---

## B.3 Drehmatrizen zur Transformation von ECEF nach ENU

Mit dem in Gleichung (3.11) gezeigten Drehwinkel ergibt sich eine Drehung der  $z^{\text{ecef}}$ -Achse nach Osten und der  $x^{\text{ecef}}$ -Achse nach Norden. Die gesuchte Drehung wird mit den folgenden Rotationsmatrizen aus Gleichung (B.1) und Gleichung (B.2) um den Arbeitspunkt  $ap^{\text{wgs}} = (\lambda^{\text{wgs}}, \phi^{\text{wgs}})$  realisiert. Beide Drehmatrizen werden zu einer vollständigen Rotationsmatrix zusammengefasst, die laut Gleichung (3.12) formuliert wird.

$$\begin{aligned}
 R_z(\alpha_z) &= \begin{pmatrix} \cos(\alpha_z) & \sin(\alpha_z) & 0 \\ \sin(\alpha_z) & \cos(\alpha_z) & 0 \\ 0 & 0 & 1 \end{pmatrix} = \begin{pmatrix} \cos(\lambda^{\text{wgs}} + \frac{\pi}{2}) & \sin(\lambda^{\text{wgs}} + \frac{\pi}{2}) & 0 \\ -\sin(\lambda^{\text{wgs}} + \frac{\pi}{2}) & \cos(\lambda^{\text{wgs}} + \frac{\pi}{2}) & 0 \\ 0 & 0 & 1 \end{pmatrix} \\
 &= \begin{pmatrix} -\sin(\lambda^{\text{wgs}}) & \cos(\lambda^{\text{wgs}}) & 0 \\ -\cos(\lambda^{\text{wgs}}) & -\sin(\lambda^{\text{wgs}}) & 0 \\ 0 & 0 & 1 \end{pmatrix} \tag{B.1}
 \end{aligned}$$

$$\begin{aligned}
R_x(\alpha_x) &= \begin{pmatrix} 1 & 0 & 0 \\ 0 & \cos(\alpha_x) & \sin(\alpha_x) \\ 0 & \sin(\alpha_x) & \cos(\alpha_x) \end{pmatrix} = \begin{pmatrix} 1 & 0 & 0 \\ 0 & \cos(\frac{\pi}{2} - \phi^{\text{wgs}}) & \sin(\frac{\pi}{2} - \phi^{\text{wgs}}) \\ 0 & -\sin(\frac{\pi}{2} - \phi^{\text{wgs}}) & \cos(\frac{\pi}{2} - \phi^{\text{wgs}}) \end{pmatrix} \\
&= \begin{pmatrix} 1 & 0 & 0 \\ 0 & \sin(\phi^{\text{wgs}}) & \cos(\phi^{\text{wgs}}) \\ 0 & -\cos(\phi^{\text{wgs}}) & \sin(\phi^{\text{wgs}}) \end{pmatrix}
\end{aligned} \tag{B.2}$$

## B.4 Rotationsmatrix für 6-DOF-Drehungen

Für die Transformation von einem  $\xi^{\text{srf}_i}$ -System in das  $\xi^{\text{vrf}}$ -System ist eine Rotation um alle drei Achsen nötig. Die Parameter der Verdrehung sind über einen Kalibrierungsschritt zu ermitteln. Anschließend muss die gültige Rotationsmatrix aufgestellt werden.

Eine Rotation mit 6-DOF besteht aus der Drehung um die  $z^{\text{srf}_i}$ -Achse mit dem Winkel  $\alpha$ , der Drehung um die  $y^{\text{srf}_i}$ -Achse mit dem Winkel  $\beta$  sowie der Drehung um die  $x^{\text{srf}_i}$ -Achse mit dem Winkel  $\gamma$ . Es ergeben sich die Rotationsmatrizen  $R_z(\alpha)$ ,  $R_y(\beta)$  und  $R_x(\gamma)$ , die entsprechend Gieren (engl. yaw), Nicken (engl. pitch) und Rollen (engl. roll) genannt werden. Abbildung B.1 zeigt den beschriebenen Sachverhalt, während Gleichung (B.3) bis Gleichung (B.5) die zugehörigen Rotationsmatrizen wiedergeben. Gleichung (B.6) formuliert die resultierende Rotationsmatrix um alle Winkel.




Abbildung B.1: Übersicht der Rotationen im  $\mathbb{R}^3$

$$R_z(\alpha) = \begin{pmatrix} \cos \alpha & -\sin \alpha & 0 \\ \sin \alpha & \cos \alpha & 0 \\ 0 & 0 & 1 \end{pmatrix} \tag{B.3}$$

$$R_y(\beta) = \begin{pmatrix} \cos \beta & 0 & \sin \beta \\ 0 & 1 & 0 \\ -\sin \beta & 0 & \cos \beta \end{pmatrix} \tag{B.4}$$

$$R_x(\gamma) = \begin{pmatrix} 1 & 0 & 0 \\ 0 & \cos \gamma & -\sin \gamma \\ 0 & \sin \gamma & \cos \gamma \end{pmatrix} \tag{B.5}$$

$$R(\alpha, \beta, \gamma) = R_z(\alpha)R_y(\beta)R_x(\gamma)$$

$$\Leftrightarrow \cos \begin{pmatrix} \cos \alpha \cos \beta & \cos \alpha \sin \beta \sin \gamma - \sin \alpha \cos \gamma & \cos \alpha \sin \beta \cos \gamma + \sin \alpha \sin \gamma \\ \sin \alpha \cos \beta & \sin \alpha \sin \beta \sin \gamma + \cos \alpha \cos \gamma & \sin \alpha \sin \beta \cos \gamma - \cos \alpha \sin \gamma \\ -\sin \beta & \cos \beta \sin \gamma & \cos \beta \cos \gamma \end{pmatrix} \quad (\text{B.6})$$

## B.5 Transformationen zwischen zwei Bewegungszeitpunkten im VRF

Der in Teilkapitel 3.2.5.7 beschriebene Zusammenhang zwischen zwei Bewegungszeitpunkten ( $\tau - 1$  und  $\tau$ ) der Fahrzeugbewegung und den sich daraus ergebenden  $\xi_{\tau-1}^{\text{vrf}}$ - und  $\xi_{\tau}^{\text{vrf}}$ -Koordinatensystemen im Bezug zum  $\xi^{\text{occs}}$ -System ist schematisch in Abbildung B.2 aufgezeigt. Die jeweiligen  $\xi_{\tau}^{\text{vrf}}$ -Systeme entsprechen der Trajektorie des Fahrzeugs und bilden in der relativen Betrachtung zum  $\xi^{\text{occs}}$  die Fahrzeugpose zum aktuellen Zeitpunkt  $\tau$ , die als  $\zeta_{\tau}^{\text{occs}} = (\zeta_{x,\tau}^{\text{occs}}, \zeta_{y,\tau}^{\text{occs}}, \theta_{\tau}^{\text{occs}})$  definiert ist.




Abbildung B.2:  $\xi_{\tau}^{\text{vrf}}$ -Positionen im  $\xi^{\text{occs}}$

Für die Durchführung der Transformation von  $\xi_{\tau-1}^{\text{vrf}}$  nach  $\xi_{\tau}^{\text{vrf}}$  muss zuerst die Translation zwischen den beiden Systemen ermittelt werden. Die Translation ergibt sich aus der Positionsdifferenz zwischen  $\xi_{\tau}^{\text{vrf}}$  und  $\xi_{\tau-1}^{\text{vrf}}$ , wobei  $\xi_{\tau-1}^{\text{vrf}}$  entsprechend dem  $\xi^{\text{occs}}$  rotiert werden muss. Gleichung (B.7) beschreibt das mathematische Vorgehen zur Ermittlung der benötigten Translation.

$$\begin{aligned}
trans &= R(\theta_{\tau-1}^{\text{occs}}) \times \Delta t = R(\theta_{\tau-1}^{\text{occs}}) \times (\zeta_{x,\tau}^{\text{occs}} - \zeta_{x,\tau-1}^{\text{occs}}, \zeta_{y,\tau}^{\text{occs}} - \zeta_{y,\tau-1}^{\text{occs}})^\top \\
&= \begin{pmatrix} \cos(\frac{\pi}{2} - \theta_{\tau-1}^{\text{occs}}) & \sin(\frac{\pi}{2} - \theta_{\tau-1}^{\text{occs}}) & 0 \\ -\sin(\frac{\pi}{2} - \theta_{\tau-1}^{\text{occs}}) & \cos(\frac{\pi}{2} - \theta_{\tau-1}^{\text{occs}}) & 0 \\ 0 & 0 & 1 \end{pmatrix} \times \begin{pmatrix} \Delta x \\ \Delta y \\ 0 \end{pmatrix} \\
&= \begin{pmatrix} \cos(\theta_{\tau-1}^{\text{occs}} - \frac{\pi}{2}) & -\sin(\theta_{\tau-1}^{\text{occs}} - \frac{\pi}{2}) & 0 \\ \sin(\theta_{\tau-1}^{\text{occs}} - \frac{\pi}{2}) & \cos(\theta_{\tau-1}^{\text{occs}} - \frac{\pi}{2}) & 0 \\ 0 & 0 & 1 \end{pmatrix} \times \begin{pmatrix} \Delta x \\ \Delta y \\ 0 \end{pmatrix} \quad (\text{B.7}) \\
&= \begin{pmatrix} \sin(\theta_{\tau-1}^{\text{occs}}) & \cos(\theta_{\tau-1}^{\text{occs}}) & 0 \\ -\cos(\theta_{\tau-1}^{\text{occs}}) & \sin(\theta_{\tau-1}^{\text{occs}}) & 0 \\ 0 & 0 & 1 \end{pmatrix} \times \begin{pmatrix} \Delta x \\ \Delta y \\ 0 \end{pmatrix} \\
&= \begin{pmatrix} \sin(\theta_{\tau-1}^{\text{occs}}) \cdot \Delta x + \cos(\theta_{\tau-1}^{\text{occs}}) \cdot \Delta y \\ -\cos(\theta_{\tau-1}^{\text{occs}}) \cdot \Delta x + \sin(\theta_{\tau-1}^{\text{occs}}) \cdot \Delta y \\ 0 \end{pmatrix}
\end{aligned}$$

Die Verdrehung der  $\xi^{\text{vrf}}$ -Systeme folgt aus der Differenz zwischen den beiden Blickrichtungswerten  $\theta_{\tau}^{\text{occs}}$  und  $\theta_{\tau-1}^{\text{occs}}$  der jeweiligen Pose  $\zeta_{\tau}^{\text{occs}}$  und  $\zeta_{\tau-1}^{\text{occs}}$ . Gleichung (B.8) gibt die Rotationsmatrix  $R(\theta_{\tau}^{\text{occs}} - \theta_{\tau-1}^{\text{occs}})$  an.

$$\begin{aligned}
rot &= R(\theta_{\tau}^{\text{occs}} - \theta_{\tau-1}^{\text{occs}}) = R(\Delta\theta_{\tau,\tau-1}^{\text{occs}}) \\
&= \begin{pmatrix} \sin(\Delta\theta_{\tau,\tau-1}^{\text{occs}}) & \cos(\Delta\theta_{\tau,\tau-1}^{\text{occs}}) & 0 \\ -\cos(\Delta\theta_{\tau,\tau-1}^{\text{occs}}) & \sin(\Delta\theta_{\tau,\tau-1}^{\text{occs}}) & 0 \\ 0 & 0 & 1 \end{pmatrix} \quad (\text{B.8})
\end{aligned}$$

Mit Gleichung (B.7) und Gleichung (B.8) wird die Transformation von  $\xi_{\tau-1}^{\text{vrf}}$  nach  $\xi_{\tau}^{\text{vrf}}$  als affine Transformation mit einer Matrix, hier Bewegungsschritt genannt, formuliert und durchgeführt. Gleichung (B.9) fasst die Berechnung aus Rotation und Translation zur Bewegungsmatrix des Bewegungsschritts zusammen und Gleichung (B.10) zeigt die Anwendung der Bewegungsmatrix auf eine Beobachtung  $p_{\text{objekt},\tau-1}^{\text{vrf}}$ .

$$\begin{aligned}
&\begin{pmatrix} \sin(\Delta\theta_{\tau,\tau-1}^{\text{occs}}) & \cos(\Delta\theta_{\tau,\tau-1}^{\text{occs}}) & 0 \\ -\cos(\Delta\theta_{\tau,\tau-1}^{\text{occs}}) & \sin(\Delta\theta_{\tau,\tau-1}^{\text{occs}}) & 0 \\ 0 & 0 & 1 \end{pmatrix} \times \begin{pmatrix} \sin(\theta_{\tau-1}^{\text{occs}}) \cdot \Delta x + \cos(\theta_{\tau-1}^{\text{occs}}) \cdot \Delta y \\ -\cos(\theta_{\tau-1}^{\text{occs}}) \cdot \Delta x + \sin(\theta_{\tau-1}^{\text{occs}}) \cdot \Delta y \\ 0 \end{pmatrix} \\
&:= (rot \times trans) = \begin{pmatrix} rot & trans \\ 0 & 1 \end{pmatrix} \quad (\text{B.9})
\end{aligned}$$

$$\begin{pmatrix} rot & trans \\ 0 & 1 \end{pmatrix} \begin{pmatrix} p_{\text{objekt},\tau-1}^{\text{vrf}} \\ 1 \end{pmatrix} = \begin{pmatrix} rot(p_{\text{objekt},\tau-1}^{\text{vrf}} + trans) \\ 1 \end{pmatrix} = \begin{pmatrix} p_{\text{objekt},\tau}^{\text{vrf}} \\ 1 \end{pmatrix} \quad (\text{B.10})$$



# Anhang C

## Lösungsansatz Landmarkenbasierte Lokalisierung

Nachfolgend sind weiterführende Herleitungen und Veranschaulichungen der Verfahren gegeben, die innerhalb der LbL verwendet werden. Die beschriebenen Methoden und durchgeführten Schritte aus Kapitel 4 werden beleuchtet. Zur Verdeutlichung sind exemplarische Visualisierungen der Verfahren und deren Ergebnissen aufgezeigt.

### C.1 Darstellung der Landmarken in den unterschiedlichen Leveln

In diesem Abschnitt sind exemplarisch die Eingangsdaten und Ausgaben der jeweiligen Schicht des TFM verdeutlicht. Es werden vor allem die eingeführten Gütestufen Level-1, Level-2 und Level-3 visuell veranschaulicht. Um ebenso einen Eindruck über die Qualität der Landmarken in den Gütestufen aus den diversen Sensorsystemen zu erhalten, sind nachfolgend die Ausgaben für jede Sensorik separat und abschließend in der fusionierten Variante aufgeführt. Es werden die detektierten Landmarken der jeweiligen Sensorik auf einem georeferenzierten Luftbild dargestellt. Abbildung C.1 zeigt die Landmarken aus der Front-Monokamera, Abbildung C.2 führt die detektierten Landmarken des Laserscanners auf und Abbildung C.3 stellt die Ausgabe des TopView-Systems dar. In allen Abbildungen gibt das oberste Bild (Darstellung der Landmarken in Türkis) die von der jeweiligen Sensorik detektierten Landmarken wieder. Die türkisen Landmarken sind die Eingangsdaten des TFM und werden als Level-1-Landmarken bezeichnet (vgl. Sensor-Management-Layer (SML) in Kapitel 4.2.1). Abbildung C.4 führt alle Landmarken der gesamten Sensorik auf einmal auf. Die mittlere Abbildung (Darstellung der Landmarken in Orange) zeigt die zeitlich nachverfolgten und fusionierten (bei Verwendung von mehreren Sensoren im TFM) Landmarken in der zweiten Schicht (vgl. Track-Management-Layer (TML) in Kapitel 4.2.2) des TFM. Hierbei wird von der Gütestufe Level-2 gesprochen. In der untersten Abbildung (Darstellung der Landmarken in Grün) sind die Landmarken abgebildet, die vom TFM in die Karte (vgl. Map-Management-Layer (MML) in Kapitel 4.2.3) übernommen wurden. Kartenlandmarken entsprechen dem Level-3. Ein reales Objekt soll in der Karte von genau einer Landmarke beschrieben werden.




Abbildung C.1: Darstellung der Landmarken aus der Front-Monokamera in jeder Gütestufe (von oben nach unten: Level-1, Level-2 und Level-3)



Abbildung C.2: Darstellung der Landmarken des Laserscanners in jeder Gütestufe (von oben nach unten: Level-1, Level-2 und Level-3)





Abbildung C.3: Darstellung der Landmarken aus dem TopView-System in jeder Gütestufe (von oben nach unten: Level-1, Level-2 und Level-3)



Abbildung C.4: Darstellung der Landmarken aus der Fusion im TFM in jeder Gütestufe (von oben nach unten: Level-1, Level-2 und Level-3)



## C.2 Beispieldarstellung eines Tracks

Der Begriff des Tracks, also einer zeitlich nachverfolgten und fusionierten Landmarke in der zweiten Schicht des TFM, ist visualisiert. Abbildung C.5 stellt exemplarisch drei verschiedene Tracks in den Farben Blau, Orange und Grün dar.

Ein Track setzt sich aus seiner zeitlichen Historie und den aktuell wahrgenommenen Beobachtungen des jeweiligen Objektes (durch die Sensorik) zusammen. Wird eine neue wahrgenommene Beobachtung einem bisherigen Track zugeordnet (z.B. über geeignete Distanzfunktionen entsprechend Kapitel 4.2.4), so ist dieser Track mit der zugeordneten Beobachtung zu aktualisieren (siehe Kapitel 4.2.6). Die Beobachtung wird der Historie des Tracks hinzugefügt. Andernfalls, d.h. wenn keine Zuordnung möglich ist, initialisiert die Beobachtung einen neuen Track.




Abbildung C.5: Darstellung eines Tracks

## C.3 Beispieldarstellung der Fusion

Abbildung C.6 verdeutlicht exemplarisch den Mehrwert der Landmarkenfusion aus unterschiedlichen Sensoren im TFM. Es sind zwei verschiedene Abschnitte einer Versuchsstrecke als georeferenzierte Luftbilder gegeben. Die linke Seite zeigt Kartenausschnitt A und die rechte Seite Kartenausschnitt B. Abgebildet sind Level-3-Landmarken. Im oberen Abschnitt der Abbildung sind nur die Landmarken aufgeführt, die bei einer Kartierung mit dem Laserscanner in die Karte eingetragen werden. In der Mitte ist das Ergebnis einer Kartierung mit Landmarken aufgeführt, die ausschließlich von der Front-Monokamera zur Verfügung gestellt werden. Zu sehen ist, dass sich die beiden Sensoren ergänzen und zur Erzeugung einer vollständigen Karte beitragen. Die gleichzeitige Verwendung von mehreren Sensoren zur Detektion von Landmarken ist bei Nutzung des TFM zur Umfeldmodellierung und Kartierung vorteilhaft.

Im unteren Teil der Abbildung ist das Resultat der Fusion der Landmarken aus dem Laserscanner und der Front-Monokamera mit dem TFM für beide Kartenausschnitte präsentiert. Erkennbar ist, dass die erzeugte Karte aus der Fusion eine bessere Abdeckung der Umgebungscharakteristiken bietet als die Karten aus einem einzelnen Sensor.




Abbildung C.6: Beispiel der Fusion (oben: Kartierung nur mit Laserscanner, mittig: Kartierung nur mit Front-Monokamera, unten: Kartierung der Fusion aus Laserscanner und Front-Monokamera)

## C.4 Tracking- & Fusionsmodell

In diesem Abschnitt werden für ein besseres Verständnis des TFM zusätzliche Beschreibungen und Abbildungen aufgeführt.

### C.4.1 Schematische Darstellung der Eingangs- und Ausgangsdaten des TFM

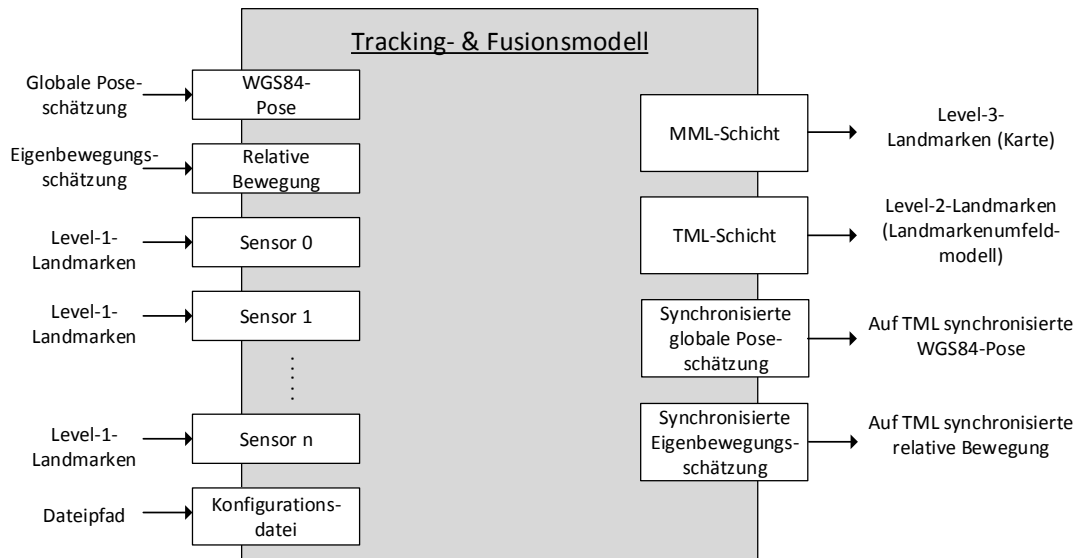


Abbildung C.7: Eingangs- und Ausgangsdaten für das TFM

### C.4.2 Schematische Darstellung der Konfigurationsdatei

Entsprechend der Beschreibung in Kapitel 4.2.1, wird ein Sensor-Data-Object (SDO) mit den Parametervorgaben aus einer Konfigurationsdatei erzeugt. Abbildung C.8 gibt den Aufbau und die hinterlegten Informationen dieser Konfigurationsdatei visuell wieder. Realisiert ist die Konfigurationsdatei als Baumstruktur in Extensible Markup Language (XML). Die dargestellten Rechtecke korrespondieren mit Knotenelementen und die Ellipsen mit Blätterelementen. Für jeden Sensor wird der Wurzelknoten „Sensor“ mit den Attributen „ID (Identifikationsnummer)“, „Name“ und zugehöriger „Latenz“ erzeugt. Der Wurzelknoten unterteilt sich in die drei Kinderknoten „Sensor-Position“ (die bekannte Verbauposition in Bezug zur Fahrzeughinterachse aus dem Kalibrierungsschritt, siehe Kapitel 3.1), „Sensor-FOV“ und „Beobachtbare-Landmarken-Daten“.

Im Kindknoten „Sensor-FOV“ ist der Sichtbereich (FOV) des jeweiligen Sensors hinterlegt. Das Attribut „Typ“ gibt den festgelegten Sichtbereichstyp wieder. Der darunterliegende Knoten enthält die Positionen des Sichtbereichs. Die Sichtbereiche sind in Kapitel 4.2.7 genauer erläutert. Der letzte Kindknoten, „Beobachtbare-Landmarken-Daten“, listet alle beobachtbaren Landmarkentypen eines Sensors auf. Für jede Landmarke der Sensorik sind spezifische Werte für die Knoten „SPRT“, „Kovarianz“ und „Statische Grenzwerte“ hinterlegt. Die verwendeten Blätter im Knoten „SPRT“ werden in Kapitel 4.2.5 zusammen mit dem Verfahren des



SPRT erläutert. Die Ermittlung dieser Werte folgt der Beschreibung des Kapitels 4.4. Unter dem Knoten „Kovarianz“ ist die Sensorgenauigkeit (vgl. Teilkapitel 3.1.4.3) für die jeweilige Landmarke abgelegt. Der letzte Unterknoten gibt die statischen Grenzwerte für die Filterung im SML wieder.

Diese Informationen stellen dem TFM alle nötigen Informationen zur Verfügung, um sowohl spezifisch nach Sensor als auch dem jeweiligen Landmarkentyp Tracking und Fusion durchzuführen.




Abbildung C.8: Struktur der Konfigurationsdatei

### C.4.3 Abbildung der Chi-Quadrat-Verteilung

Im linken Teil von Abbildung C.9 ist die Dichtefunktion der Chi-Quadrat-Verteilung  $\chi^2$  für unterschiedliche Freiheitsgrade  $k$  gegeben. Zusätzlich ist im rechten Teil die inverse Chi-Quadrat-Verteilung  $(\chi^2)^{-1}$  mit unterschiedlichen Freiheitsgraden  $k$  und Signifikanzniveaus  $0.9 \leq \alpha \leq 0.99$  abgebildet.




Abbildung C.9: Abbildung der Dichtefunktion der Chi-Quadrat-Verteilung (links) und der inversen Chi-Quadrat-Verteilung (rechts)

### C.4.4 Verfahren zur Berechnung von Lotpunkten

Für die in Kapitel 4.2.4 beschriebene Distanzfunktion  $d^{\text{PL}}$  der polylinienbasierten Landmarken ist es notwendig, die Landmarken aufeinander zu projizieren. Gegebenenfalls müssen die polylinienbasierten Landmarken so beschnitten werden, dass sie sich gegenseitig abbilden. Für diese Projektion der Landmarken aufeinander müssen die Lotpunkte der zugehörigen Start- und Endpunkte der Polylinien bestimmt werden. Aufbauend auf den formulierten Bedingungen in Gleichung (4.14), wird die weitere Bedingung aus Gleichung (C.1) aufgestellt.

$$\forall (p_{j-1}, p_j) \mid p_{j-1} \leq p_j \ \& \ (p_{j-1}, p_j) \in s^{\text{PL}} : \vec{v}_j(\lambda) = \vec{H}_j + \lambda \cdot \vec{R}_j, \quad (\text{C.1})$$

wobei  $\vec{H}_j = \vec{p}_{j-1}$ ,  $\vec{R}_j = (p_j - p_{j-1})$ ,  $j = 2, \dots, I$

Gleichung (C.1) beschreibt die Bildung eines Vektors  $\vec{v}_j(\lambda)$  aus dem Segment zweier direkt benachbarter Punkte  $(p_{j-1}, p_j)$  der Punktmenge  $(p_1, p_2, \dots, p_n)$  einer polylinienbasierten Landmarke  $s^{\text{PL}}$ . Durch die definierte Reihenfolge der Punktmenge  $(p_1, p_2, \dots, p_n)$  (vgl. Gleichung (4.14)) bildet  $\vec{H}_j$  den Stützvektor, während  $\vec{R}_j$  den Richtungsvektor des Segments beschreibt. Der Linienparameter sei  $\lambda$ . Abbildung C.10 visualisiert den beschriebenen Sachverhalt anschaulich für zwei Landmarken  $t_l^{s^{\text{PL}}}$  und  $b_k^{s^{\text{PL}}}$ . Der gesuchte Lotpunkt ist als  $\vec{p}_{\text{Lot}}$  angegeben.

Zur Berechnung der Lotpunkte und um die Polylinien so zuzuschneiden, dass sich beide Linien aufeinander projizieren lassen, wird nach Gleichung (C.1) über alle Vektoren  $\vec{v}_j(\lambda)$  der Landmarke  $b_k^{s^{\text{PL}}}$  iteriert und für alle Punkte der Landmarke  $t_l^{s^{\text{PL}}}$  geprüft, ob ein Lotpunkt

auf  $\vec{v}_j(\lambda)$  vorhanden ist. Anschließend wird das Verfahren für die weiteren Landmarken im Sichtbereich durchgeführt.




Abbildung C.10: Schematische Darstellung der Lotpunktberechnung für die Projektion von zwei Polylinien

Entsprechend Gleichung (C.1) bildet in Abbildung C.10  $\vec{p}_{j-1}$  den Stützvektor  $\vec{H}_j$  und  $(p_{j-1} - p_j)$  den Richtungsvektor  $\vec{R}_j$  der Landmarke  $b_k^{sPL}$ . Damit ist der Vektor  $\vec{v}_j(\lambda)$  für das betrachtete Beispielsegment  $(p_{j-1}, p_j)$  beschrieben. Der Punkt  $p_{q-1}$  der Polylinie  $t_l^{sPL}$  sei als Vektor  $\vec{Z}_u$  definiert. Eine Projektion von  $\vec{Z}_u$  auf  $\vec{v}_j(\lambda)$  liefert den gesuchten Lotpunkt  $\vec{p}_{Lot}$ . Der Lotpunkt wird durch die Ermittlung des Linienparameters  $\lambda$  auf  $\vec{v}_j(\lambda)$  bestimmt.

Die Berechnung dieses Lotpunktes kann entsprechend Gleichung (C.2) formuliert werden.

$$\vec{p}_{Lot} = \vec{Z}_u - \vec{H}_j + \lambda \cdot \vec{R}_j \quad (C.2)$$

Mit dem Skalarprodukt folgt Gleichung (C.3).

$$(\vec{Z}_u - \vec{H}_j + \lambda \cdot \vec{R}_j) \cdot \vec{R}_j = 0 \quad (C.3)$$

Der Linienparameter  $\lambda$  wird direkt durch Auflösung von Gleichung (C.3) ermittelt. Gleichung (C.4) formuliert die nötigen Rechenschritte.

$$\begin{aligned} a &= (R_{j,x} \cdot (H_{j,x} - Z_{u,x})) + (R_{j,y} \cdot (H_{j,y} - Z_{u,y})) + (R_{j,z} \cdot (H_{j,z} - Z_{u,z})), \\ b &= ((R_{j,x})^2 + (R_{j,y})^2 + (R_{j,z})^2), \\ \lambda &= \frac{a}{b} \end{aligned} \quad (C.4)$$

## C.5 Partikelfilterbasiertes Lokalisierungsmodell

In diesem Abschnitt wird die Funktionsweise des PLM aufgezeigt und die mathematische Herleitung des Sensormodells gegeben.

### C.5.1 Schematische Darstellung der Eingangs- und Ausgangsdaten des PLM




Abbildung C.11: Eingangs- und Ausgangsdaten des PLM

### C.5.2 Beweis zur Umformung innerhalb des Sensormodells

Nachfolgend ist der Beweis der Umformulierung des Sensormodells aus Kapitel 4.3.2 (Gleichung (4.49) bis Gleichung (4.51)) mit vollständiger Induktion gezeigt.

#### Lemma C.5.1.

Seien die probabilistischen Ereignisse  $A_1, \dots, A_M$  gegeben. Unter der Annahme der stochastischen Unabhängigkeit zwischen den Ereignissen (vgl. Beschreibung Gleichung (4.51)) gilt Gleichung (C.5).

$$p\left(\bigcup_{j=1}^M A_j\right) = \sum_{j=1}^M \left( p(A_j) \prod_{k=j+1}^M (1 - p(A_k)) \right) \quad (\text{C.5})$$

*Beweis.*

Induktion über  $M$ , mit Induktionsanfang  $M = 1$ :

$$p\left(\bigcup_{j=1}^1 A_j\right) = p(A_1) = \sum_{j=1}^1 \left( p(A_j) \prod_{k=j+1}^1 (1 - p(A_k)) \right), \text{ weil } \prod_{i=a}^b x_i = 1 \text{ für } a > b \quad (\text{C.6})$$

Induktionsschritt für  $M > 1$ :

$$\begin{aligned}
p\left(\bigcup_{j=1}^M A_j\right) &= p\left(\left(\bigcup_{j=1}^{M-1} A_j\right) \cup A_M\right) \\
&= p\left(\bigcup_{j=1}^{M-1} A_j\right) + p(A_M) - p\left(\bigcup_{j=1}^{M-1} A_j\right)p(A_M) \\
&= p\left(\bigcup_{j=1}^{M-1} A_j\right)(1 - p(A_M)) + p(A_M) \\
&= \sum_{j=1}^{M-1} \left( p(A_j) \prod_{k=j+1}^{M-1} (1 - p(A_k)) \right) (1 - p(A_M)) + p(A_M) \\
&= \sum_{j=1}^{M-1} \left( p(A_j) \prod_{k=j+1}^M (1 - p(A_k)) \right) + p(A_M) \\
&= \sum_{j=1}^{M-1} \left( p(A_j) \prod_{k=j+1}^M (1 - p(A_k)) \right) + p(A_M) \prod_{k=M+1}^M (1 - p(A_k)) \\
&= \sum_{j=1}^M \left( p(A_j) \prod_{k=j+1}^M (1 - p(A_k)) \right)
\end{aligned} \tag{C.7}$$

□

### C.5.3 Dynamisches Resampling

Abbildung C.12 zeigt exemplarisch das dynamische Resampling. In der  $x, y$ -Ebene ist die Trajektorie der SPRT-Versuchsstrecke in WGS84 gegeben. Die  $z$ -Achse gibt die Anzahl der Partikel des PLM an. Jede Position ist mit dem absoluten Abstand zur Ortungsreferenz angegeben und farblich markiert. Die Korrelation von Partikelanzahl zu Lokalisierungsfehler wird aufgezeigt.




Abbildung C.12: Exemplarische Darstellung des dynamischen Resamplings

### C.5.4 Exemplarisches Verhalten des Partikelfilters

Nachfolgend sind die unterschiedlichen Zustände des Partikelfilterbasierten Lokalisierungsmodells (PLM) aufgezeigt. Abbildung C.13 verdeutlicht diese Zustände an einzelnen Beispielen.




Abbildung C.13: Exemplarische Darstellung der einzelnen Phasen des Partikelfilterbasierten Lokalisierungsmodells

# Anhang D

## Experimente

In diesem Anhang sind weiterführende Veranschaulichungen der Experimente aus Kapitel 5 aufgezeigt. Es sind zuerst die beiden verwendeten Versuchsstrecken detailliert visualisiert. Anschließend sind zusätzliche Auswertungen zur Kartierung und Lokalisierung aufgeführt.

### D.1 Überblick der Versuchsstrecke zur SPRT-Parameterbestimmung

Die urbane Versuchsstrecke zur SPRT-Parameterbestimmung aus Kapitel 5.1 (siehe Abbildung 5.1) ist nachfolgend genauer vorgestellt. Den Startpunkt bildet die Kreuzung „Heinrich-Nordhoff-Straße“ Ecke „Major-Hirst-Straße“ um die WGS84-Koordinaten (52.423416, 10.748314). Abbildung D.1 markiert den Startpunkt mit A. Der Streckenverlauf ist in den folgenden Abbildungen gelb dargestellt.

Die erste Hälfte der Strecke besitzt zwei Spuren in jede Fahrtrichtung. Im ersten Streckenviertel wird eine Autobahnbrücke bei den Koordinaten (52.423071, 10.737805) unterquert. Abbildung D.2 gibt den Abschnitt visuell wieder. Im mittleren Streckenabschnitt, um die Koordinaten (52.423835, 10.731273), wird eine Brücke überquert. Es gibt sowohl eine Rechts- als auch eine Linkskurve, die jeweils eine Steigung aufweisen. Vor und nach der Brückenüberfahrt sind Ampeln vorhanden. Abbildung D.3 führt den Sachverhalt auf. Abbildung D.4 zeigt den letzten Abschnitt der Versuchsstrecke. Der Streckenverlauf führt durch ein Industriegebiet mit einer breiten Straßenführung und jeweils einer Fahrspur pro Fahrbahn. Es gibt in diesem Streckenteil vermehrt parkende Personenkraftwagen und Lastkraftwagen an den Straßenrändern. Der Endpunkt B befindet sich bei den WGS84-Koordinaten (52.424257, 10.717625).



Abbildung D.1: Beginn der Versuchsstrecke, Luftbild aus [257]





Abbildung D.2: 2. Abschnitt der Versuchsstrecke, Luftbild aus [257]



Abbildung D.3: 3. Abschnitt der Versuchsstrecke, Luftbild aus [257]



Abbildung D.4: Ende der Versuchsstrecke, Luftbild aus [257]

## D.2 Überblick der Versuchsstrecke zur Kartierung und Lokalisierung

Nachfolgend wird die Versuchsstrecke für die Kartierung und Lokalisierung aus Kapitel 5.2 (siehe Abbildung 5.9) vertiefend vorgestellt. Ziel ist es, einen Eindruck von dem Verlauf und der Komplexität der Strecke zu erzeugen. Es werden über den gesamten Streckenverlauf einzelne Bereiche aufgezeigt und erläutert. Vor allem soll eine objektive Betrachtung der vorgestellten Untersuchungen und Ergebnisse aus Kapitel 5.2.2 sowie Kapitel 5.2.3 ermöglicht werden. Zum besseren Verständnis der beschriebenen Erkenntnisse kann ein Abgleich mit dem gezeigten Streckenverlauf durchgeführt werden. Ein Anspruch auf Vollständigkeit der gesamten Strecke wird hier vorausgesetzt. Für einen detaillierten und umfassenden Überblick des Streckenverlaufs sei auf [257] verwiesen. Die grundsätzliche Trajektorie ist schematisch in Blau verdeutlicht. Die Erläuterung der Versuchsstrecke erfolgt exemplarisch aus Sicht einer Hinfahrt.



Abbildung D.5 zeigt den Startpunkt für Hinfahrten und den Endpunkt bei Rückfahrten (verdeutlicht mit Punkt A). Visualisiert ist der Bereich um die WGS84-Koordinaten (52.366835, 10.720672). Die abgebildete Kreuzung wird durch eine Ampelanlage geregelt und enthält eine Vielzahl von Fahrbahnmarkierungen. Die Kreuzung geht in die Landstraße B248 über, der in Richtung Braunschweig (links unten) gefolgt wird. Entsprechend des Luftbildes verengt sich, von der Kreuzung kommend, der Straßenverlauf, was durch eine Schraffierung mit Querlinien zwischen zwei durchgezogenen Linien verdeutlicht ist.

Bei Hinfahrten enthält der erste Abschnitt zuerst nur durchgezogene Fahrbahnmarkierungen und geht im Anschluss in den typisch einspurigen Landstraßenverlauf über (rechte Seite durchgezogene Fahrbahnmarkierung, linke Seite gestrichelte Fahrbahnmarkierungen). Bei den Rückfahrten wird der Straßenverlauf breiter und bietet durch die drei Abbiegespuren (links, geradeaus, rechts) mehr Landmarken.



Abbildung D.5: Streckenabschnitt beim Beginn (Hinfahrt) und beim Ende (Rückfahrt) der Versuchsstrecke, Luftbild aus [257]

Wird der Landstraße B248 in Richtung Braunschweig für ca. fünf Kilometer gefolgt, muss der Ort Lehre durchfahren werden. Der Landstraßenverlauf bis Lehre enthält einige Abzweigungen und Einmündungen, die ggf. kurzzeitig einen zusätzlichen Abbiegestreifen bzw. Auffahrstreifen enthalten. Die Landstraße ist in diesem Abschnitt einspurig in beide Richtungen befahrbar. Es sind mittig gestrichelte Fahrbahnmarkierungen enthalten und als äußere Fahrbahnbegrenzung sind durchgezogene Linien angebracht. Ein Standstreifen ist nicht vorhanden. Bis Lehre durchquert die Straße kein urbanes Gebiet.

Abbildung D.6 stellt die Einfahrt nach Lehre (linker Teil) und die Ortsdurchfahrt (rechter Teil) dar. Die linke Abbildung zeigt den Bereich um die Koordinaten (52.331078, 10.670761) und die rechte Abbildung den Bereich um (52.329028, 10.668359). Bereits die Einfahrt nach Lehre enthält Abschnitte mit nur sehr wenigen Fahrbahnmarkierungen. Die im linken Teil sichtbare Kreuzung der „Berliner Straße“ mit der „Campenstraße“ ist der Übergang zwischen der Einfahrt und der eigentlichen Ortsmitte. Die Stücke vor und nach der Kreuzung enthalten kaum Fahrbahnmarkierungen, wohingegen die Kreuzung mit Haltelinien und gestrichelten Linien versehen ist. Das Vorkommen von wenigen Fahrbahnmarkierungen gilt insbesondere für die gesamte Ortsdurchfahrt, wie in der rechten Abbildung präsentiert. Trotz einer geringen Anzahl an Fahrbahnmarkierungen in diesem Bereich ist eine Kartierung und Lokalisierung möglich, da säulenförmigen Objekte wie Straßenschilder, Ampelanlagen oder Teile von Bushaltestellen zur Verfügung stehen.



Abbildung D.6: Streckenabschnitt der Einfahrt nach Lehre (links) und deren Ortsdurchfahrt (rechts), Luftbild aus [257]

Der gesamte Ort Lehre weist eine Länge von ca. 2.5 Kilometer auf. Von der Einfahrt bis zur Durchfahrt der Ortsmitte werden etwa 1.8 Kilometer zurückgelegt, ab dann beginnt die Ortsausfahrt. Abbildung D.7 zeigt die Ortsausfahrt um die Koordinaten (52.323729, 10.660656). Es wird deutlich, dass nach der Ortsdurchfahrt hin zur Ortsausfahrt, die gestrichelten Fahrbahnmarkierungen wieder vermehrt vorhanden sind. Durchgezogene Fahrbahnmarkierungen begrenzen die Fahrbahn durchgängig.

Nach der Ortsausfahrt führt die Landstraße B248 durch ein ca. 1.5 Kilometer langes Waldstück, sodass die Fahrbahn links und rechts von Bäumen gesäumt ist. Die „Berliner Straße“ wird zur „Berliner Heerstraße“. Der Abschnitt endet an der Kreuzung „Berliner Heerstraße“ mit der Straße „Im Oberdorf“ an den WGS84-Koordinaten (52.316117, 10.639918). Nach weiteren 0.7 Kilometern werden die Ein- und Ausfahrten der Autobahn A2 erreicht. Es wird an der Kreuzung „Berliner Heerstraße“ mit der Straße „In den Lohbalken“ an den Koordinaten (52.312936, 10.633597) auch ein Autobahnrasthof gekreuzt.





Abbildung D.7: Streckenabschnitt der Ausfahrt aus Lehre, Luftbild aus [257]




Abbildung D.8: Streckenabschnitt des Autobahnzubringers, Luftbild aus [257]



Aufgrund des Autobahnrasthofs gibt es an der Kreuzung eine hohe Verkehrsdichte mit unterschiedlichen Verkehrsteilnehmern, außerdem sind viele Umgebungscharakteristiken vorhanden. Vor allem durch große Lastkraftwagen wird die Umgebungswahrnehmung jedoch stark eingeschränkt. Abbildung D.8 visualisiert den beschriebenen Teilabschnitt.

Das rechte obere Teilstück der Abbildung D.9 ist das Verbindungsstück zur linken unteren Ecke der Abbildung D.8. Der Autobahnzubringer unterquert in diesem Bereich die Autobahnbrücke der A2. Das Teilstück zeichnet sich sowohl durch die Brücke als auch durch die Auf- und Abfahrten der A2 aus. Abbildung D.9 zeigt zum beschriebenen Bereich das Luftbild der Strecke um die Koordinaten (52.309824, 10.628584). An den Auf- und Abfahrten kommen alle verwendeten Landmarken vor. Trotzdem ist der genannte Abschnitt sehr komplex. Das liegt zum einen an dem hohen Verkehrsfluss, der sich in vielen, stark abgenutzten Landmarken widerspiegelt. Zum anderen sind beide Autobahnzufahrten durch eine Schraffierung mit Querlinien zwischen zwei durchgezogenen Linien kenntlich gemacht, was mit einer Verbreiterung der Straßenführung einhergeht.




Abbildung D.9: Auf- und Abfahrt der Autobahn A2, Luftbild aus [257]



Nach dem Teilabschnitt der Auf- und Abfahrten der Autobahn A2 führt die Landstraße für etwa 1.5 Kilometer durch Wald und landwirtschaftliches Gebiet. Die Landstraße ist in beide Richtungen einspurig befahrbar. Beide Fahrtrichtungen werden durch gestrichelte Fahrbahnmarkierungen voneinander getrennt und der Straßenrand ist mit durchgezogenen Markierungen gekennzeichnet.

Nach diesen 1.5 Kilometern verläuft die Landstraße neben dem Ort Dibbesdorf. Die Einfahrt nach Dibbesdorf von der Landstraße B248 wird durch die Kreuzung „Berliner Heerstraße“ mit „Alte Schulstraße“ ermöglicht. Um Abbiegevorgänge an der Kreuzung effizient zu ermöglichen, erhält die Landstraße kurz vor dem Kreuzungsbereich zusätzliche Fahrstreifen in beide Fahrtrichtungen. Der Bereich wird durch eine Ampelanlage gesteuert. Eine Übersicht des Straßenverlaufs der Landstraße um den Ort Dibbesdorf ist im oberen Teil der Abbildung D.10 aufgezeigt. Der untere Ausschnitt vergrößert den beschriebenen Kreuzungsbereich. Die Luftbilder zeigen das Gebiet um die WGS84-Koordinaten (52.299106, 10.600892).



Abbildung D.10: Streckenverlauf der Landstraße um Dibbesdorf (oben) und Vergrößerung des Kreuzungsbereichs (unten), Luftbild aus [257]

Wird die Landstraße weiter in Richtung Braunschweig verfolgt, beginnt hinter der Kreuzung bei Dibbesdorf nach ca. 1.2 Kilometern die Einfahrt nach Volkmarode. Ab hier beginnt eine dichte urbane Bebauung. Passagen durch Wald oder landwirtschaftliches Gebiet kommen nicht mehr vor und der Straßenverlauf wird komplexer. Die einzelnen Teilbereiche der Streckenführung durch Volkmarode und Gliesmarode bis zum Endpunkt (Hinfahrt) bzw. Startpunkt (Rückfahrt) der Versuchsfahrten sind nachfolgend aufgeführt.

Abbildung D.11 zeigt die Ortseinfahrt nach Volkmarode an der Kreuzung „Berliner Heerstraße“ zur Straße „Ziegelkamp“. Die WGS84-Koordinaten des dargestellten Ausschnitts lauten (52.290335, 10.597556). Der Streckenabschnitt zeichnet sich durch viele Einmündungen und Abzweigungen von der „Berliner Heerstraße“ aus. In beiden Fahrtrichtungen ist das Parken am Straßenrand erlaubt, wodurch ggf. säulenförmige Umgebungscharakteristiken nicht wahrgenommen werden können und durchgezogene Fahrbahnmarkierungen zur Begrenzung des Straßenrandes nicht vorhanden sind.




Abbildung D.11: Ortseinfahrt nach Volkmarode und Beginn des urbanen Streckenverlaufs bis Braunschweig, Luftbild aus [257]



Die Durchfahrt der Ortsmitte von Volkmarode ist in Abbildung D.12 um die Koordinaten (52.285547, 10.588222) präsentiert. Das Parken am Straßenrand ist hier nicht mehr erlaubt, da in regelmäßigen Abständen Bushaltestellen (gekennzeichnet durch Zickzack-Markierungen auf der Straße) vorhanden sind. An diesen Stellen ist die Straßenführung breiter, sodass links an den Haltestellen vorbeigefahren werden kann. Die Abzweigungen zu und von der „Berliner Heerstraße“ sind ampelanlagenfrei.



Abbildung D.12: Ortsmitte von Volkmarode, Luftbild aus [257]




Abbildung D.13: Zufahrt Volkmarode nach Gliesmarode, Luftbild aus [257]

Bei den WGS84-Koordinaten (52.283802, 10.582943) beginnt die Zufahrt von Volkmarode nach Gliesmarode. Abbildung D.13 visualisiert diesen Bereich. Es ist zu beobachten, dass nach der Ortsausfahrt von Volkmarode die Fahrbahnen des Straßenzugs je Fahrtrichtung voneinander baulich getrennt sind (rechter oberer Teil in Abbildung D.13, hier wird die „Berliner Heerstraße“ wieder zur „Berliner Straße“). Die bauliche Trennung erfolgt durch Straßenbahnschienen und die dort befindliche Straßenbahnstation „Braunschweig Moorhüttenweg“. Zusätzlich erweitert sich die Straße auf zwei Fahrbahnen je Fahrtrichtung. Die abgebildete Kreuzung wird durch eine Ampelanlage reguliert.

Der zweispurige, baulich getrennte Straßenverlauf wird bis zum Endpunkt in Braunschweig beibehalten. Die beiden nächsten großen Kreuzungen („Berliner Straße“ mit „Petzvalstraße“, „Berliner Straße“ mit „Messeweg“) folgen im Abstand von jeweils rund 0.7 Kilometern.

Die erste Kreuzung hat die Koordinaten (52.281755, 10.576743) und ist in Abbildung D.14 wiedergegeben (entspricht der Abbildung 4.6 in Kapitel 4.2.3). Die zweite Kreuzung ist in Abbildung D.15 aufgeführt und zeigt das Gebiet um die Koordinaten (52.278812, 10.567433). Beide Kreuzungen liegen in Gliesmarode. Der Straßenverlauf zwischen den Kreuzungen ist in beide Richtungen durch die Straßenbahnstationen „Braunschweig Petzvalstraße“ (erste Kreuzung) sowie „Braunschweig Messeweg“ (zweite Kreuzung) getrennt. Ampelanlagen und zusätzliche Abbiegespuren kommen in beiden Bereichen vor.

Nach dem Abschnitt, der in Abbildung D.15 gezeigt ist wird der Vorort Gliesmarode verlassen und in Braunschweig eingefahren. Der urbane Bereich wird hierbei nicht verlassen. Die Braunschweiger Kreuzung „Berliner Straße“ mit der „Querumer Straße“ wird anschließend nach weiteren 0.7 Kilometern erreicht. Abbildung D.16 zeigt das Luftbild der Kreuzung um die Koordinaten (52.278658, 10.558150).

Im Gegensatz zu den bisherigen Kreuzungen, enthält die Kreuzung eine zusätzliche leichte Biegung. Gleichbleibend ist die Fahrbahntrennung durch Straßenbahnschienen. Die Komplexität der Markierungen ist hier deutlich erhöht, da die „Querumer Straße“ baulich getrennte Fahrbahnen je Fahrtrichtung hat. Des Weiteren sind im Kreuzungsbereich diverse Schraffierungen mit Querlinien zwischen verbundenen durchgezogenen Linien vorhanden.

Nach der Kreuzung „Querumer Straße“ geht die „Berliner Straße“ in die „Hans-Sommer-Straße“ über und erreicht nach etwa 1.6 Kilometern den Endpunkt der Hinfahrt (bei der Rückfahrt ist das entsprechend der Startpunkt) in Braunschweig. Der End- bzw. Startpunkt markiert den Kreuzungsbereich zwischen der „Hans-Sommer-Straße“, dem „Rebenring“, der „Brucknerstraße“ und dem „Hagenring“. Abbildung D.17 visualisiert den Streckenabschnitt um die WGS84-Koordinaten (52.275511, 10.535634).

Insgesamt handelt es sich um einen großen Kreuzungsbereich, in dem mehrere Fahrbahnen je Fahrtrichtung vorhanden sind. Der Kreuzungsverkehr wird durch eine Ampelanlage gesteuert. Im Vergleich zu den bisher gezeigten Kreuzungen ist hier keine Straßenbahnlinie zwischen den Fahrtrichtungen vorhanden. Vor allem ist festzuhalten, dass die Zufahrt zum Kreuzungsbereich keine bauliche Trennung auf der „Hans-Sommer-Straße“ beinhaltet. Durch die Größe des Kreuzungsbereichs sind auch in der Kreuzungsmitte gestrichelte und durchgezogene Fahrbahnmarkierungen zur Straßenverlaufsführung vorhanden. Die Ampelanlage ermöglicht zusätzlich die Wahrnehmung von säulenförmigen Objekten.






Abbildung D.14: Durchfahrt Gliesmarode an der Kreuzung „Petzvalstraße“, Luftbild aus [257]



Abbildung D.15: Durchfahrt Gliesmarode an der Kreuzung „Messeweg“, Luftbild aus [257]



Abbildung D.16: Braunschweig - Kreuzung „Querumer Straße“, Luftbild aus [257]





Abbildung D.17: Streckenabschnitt in Braunschweig beim Ende (Hinfahrt) und Beginn (Rückfahrt) der Versuchsstrecke, Luftbild aus [257]

### D.3 Visualisierung der Kartierungsergebnisse der LbL

In Anlehnung an den beschriebenen Streckenverlauf aus Anhang D.2 werden in diesem Abschnitt dedizierte Ausschnitte der generierten Karten entlang der Versuchsstrecke aufgezeigt. Es erfolgt sowohl die Vorstellung der Ergebnisse des Kartierungsverfahrens als auch eine Präsentation der Kartengüte.

Zur besseren Einordnung der in Kapitel 5.2.2 erläuterten Auswertungen werden die dort verwendeten Karten herangezogen und hier entsprechend den beschriebenen Abschnitten visualisiert. Die Landmarken der ersten Hinfahrt sind in Grün und die Kartenlandmarken der zweiten Hinfahrt in Lila aufgezeigt. Die Kartenlandmarken der ersten Rückfahrt sind in Türkis eingefärbt, während die Landmarken der zweiten Rückfahrt rot sind. Die säulenförmigen Objekte der Straßeninfrastruktur sind als Punkte abgebildet, während linienbasierte und polyliniensbasierte Landmarken entsprechend als gestrichelte oder durchgezogene Linien visualisiert sind.

In den Streckenabschnitten, in denen starke Kurven oder eine bauliche Trennung der Fahrtrichtungen vorzufinden sind (vgl. Anhang D.2), werden zusätzlich zur getrennten Betrachtung der Hin- und Rückfahrt ggf. alle vier generierten Karten gleichzeitig präsentiert. Das soll vor allem die gegenseitige Komplementierung in der dezentralen Karte aufzeigen und einen Eindruck darüber vermitteln, wie gut die Karten zueinander passen.

Entsprechend der Abbildung D.5 sind in Abbildung D.18 die zugehörigen Ausschnitte der Kartierungsfahrten visualisiert. Im oberen Teil der Abbildung sind die beiden generierten Karten aus den Hinfahrten und im unteren Teil die beiden Karten aus den Rückfahrten dargestellt. Aufgrund der Querlinienschraffierung und der Straßenverbreiterung zum Kreuzungsbereich hin, sind die einzelnen Fahrtrichtungen gut voneinander zu trennen. Erkennbar ist auch, dass die Querlinienschraffierung grundsätzlich keinem der definierten Landmarkentypen (vgl. Kapitel 4.1.1) entspricht und somit auch von den verwendeten Detektoren nur unzusammenhängend erkannt wird.




Abbildung D.18: Kartenlandmarken der Versuchsstrecke beim Start- bzw. Endpunkt (Hinfahrten oben, Rückfahrten unten)

Dem Anhang D.2 folgend, wird in Abbildung D.6 die Einfahrt nach Lehre sowie die Ortsdurchfahrt gezeigt (der linke bzw. rechte Teil der genannten Abbildung). Abbildung D.19 zeigt die zugehörigen erzeugten Karten der Ortsdurchfahrt Lehre. Der rechte Teil visualisiert die Karten aus den Hinfahrten und der linke Teil die Karten aus den beiden Rückfahrten. Der abgebildete Bereich entspricht den WGS84-Koordinaten um (52.331078, 10.670761).

Abbildung D.20 führt die Kartenlandmarken der Ortsdurchfahrt Lehre auf. Die Kartenausschnitte zeigen den Bereich um die Koordinaten (52.329028, 10.668359). Ebenso sind hier im linken Teil die Karten aus den Hinfahrten und im rechten Teil die Karten aus den Rückfahrten aufgeführt.

Klar zu sehen ist, dass keine gestrichelten Fahrbahnmarkierungen vorhanden sind. Die durchgezogenen Linien sind durchgängig und weitestgehend zusammenhängend erkannt und in die Karte eingetragen worden. Insbesondere zeichnet sich dieser Ortsabschnitt durch die vielen säulenförmigen Objekte aus. Sowohl in der Hinfahrt als auch in der Rückfahrt sind einige der punktbasierten Landmarken gleichbleibend erkannt worden (unter anderem durch die Clusterbildung und Verteilung der Objekte erkennbar).

Abbildung D.7 gibt den Fahrbahnverlauf der Ortsausfahrt aus Lehre wieder. Die erfolgte Kartierung dieses Streckenbereichs ist in Abbildung D.21 präsentiert. Im oberen Teil ist das Ergebnis der Hinfahrten und im unteren Teil das Resultat der Rückfahrten wiedergegeben. Visualisiert ist der Kartenausschnitt um die Koordinaten (52.323729, 10.660656). Entsprechend der Beschreibung des vorherigen Kapitels, ist in den Karten erkennbar, dass die gestrichelten Fahrbahnmarkierungen zur Ortsausfahrt wieder vorkommen und beim Eintreten der Landstraße B248 regelmäßig vorhanden sind.




Abbildung D.19: Kartierung der Ortseinfahrt Lehre (Hinfahrten links, Rückfahrten rechts)




Abbildung D.20: Kartenlandmarken der Ortsdurchfahrt Lehre (Hinfahrten links, Rückfahrten rechts)




Abbildung D.21: Kartierungsergebnisse der Ortsausfahrt Lehre (Hinfahrten oben, Rückfahrten unten)

Der weiterführende Streckenverlauf mit seinen Eigenschaften ist in den Luftbildern Abbildung D.8 und Abbildung D.9 dargestellt. Zuerst wird der Zubringer zur Autobahn mit dem Autobahnrasthof durchquert und im Anschluss der Bereich mit den Auf- und Abfahrten der Autobahn passiert. Abbildung D.22 zeigt den Bereich (Zubringer zur Autobahn) um die WGS84-Koordinaten (52.312936, 10.633597). Der obere Kartenausschnitt präsentiert die Kartierungen der beiden Hinfahrten. In der Mitte sind die Kartierungen aus den Rückfahrten wiedergegeben. Aufgrund der erhöhten Straßenbreite, die durch die Kreuzung „Berliner Heerstraße“ mit der Straße „In den Lohbalken“ entsteht, sind im unteren Teil alle vier Kartierungsfahrten übereinander visualisiert. Abbildung D.23 präsentiert die Kartierungen der Auf- und Abfahrten der Autobahn um die Koordinaten (52.309824, 10.628584).




Abbildung D.22: Zufahrt zur Autobahn A2 an der Kreuzung „Berliner Heerstraße“ mit der Straße „In den Lohbalken“ (Hinfahrten oben, Rückfahrten mittig, alle vier Fahrten gleichzeitig unten)




Abbildung D.23: Die Kartierungen des Streckenabschnitts mit den Auf- und Abfahrten der Autobahn A2 (Hinfahrten oben, Rückfahrten unten)

Es folgt der Streckenverlauf aus Abbildung D.10 um Dibbesdorf. Abbildung D.24 visualisiert einen Bereich der Landstraße des oberen Teils der Abbildung D.10. Der untere Teil der Abbildung D.10, die Vergrößerung des Kreuzungsbereichs mit der Einfahrt nach Dibbesdorf, ist entsprechend der Koordinaten (52.299106, 10.600892) in Abbildung D.25 wiedergegeben.




Abbildung D.24: Kartierung der Landstraße um Dibbesdorf (Hinfahrten oben, Rückfahrten unten)




Abbildung D.25: Karte der Kreuzung zur Einfahrt nach Dibbesdorf (oben Hinfahrten, unten Rückfahrten)



Im Anschluss an die Ortsumfahrt Dibbesdorf geht der Streckenverlauf in die Ortseinfahrt nach Volkmarode über. Abbildung D.11 stellt das Luftbild dar und Abbildung D.26 visualisiert den zugehörigen Kartenausschnitt der Kreuzung „Berliner Heerstraße“ zur Straße „Ziegelkamp“ um die Koordinaten (52.290335, 10.597556). Im linken Teil ist die Kartierung aus den Hinfahrten und im rechten Teil die der Rückfahrten aufgeführt.

Anschließend folgt die Durchfahrt der Ortsmitte von Volkmarode (vgl. Abbildung D.12). Abbildung D.27 präsentiert das Resultat der Kartierung zu den WGS84-Koordinaten (52.285547, 10.588222). Die Kartierungen der beiden Hinfahrten sind im oberen Teil und die der beiden Rückfahrten im unteren Teil aufgeführt.




Abbildung D.26: Kartierung der Ortseinfahrt nach Volkmarode (Hinfahrten links, Rückfahrten rechts)




Abbildung D.27: Kartierungsergebnisse der Ortsmitte Volkmarode (Hinfahrten links, Rückfahrten rechts)

Der Streckenverlauf geht nach der Ortsmitte Volkmarode in die Zufahrt nach Gliesmarode über. Das zugehörige Luftbild ist in Abbildung D.13 dargestellt und die Kartierung des Bereiches um die WGS84-Koordinaten (52.283802, 10.582943) ist für die Hinfahrten (oberer Teil) und die Rückfahrten (mittiger Teil) in Abbildung D.28 präsentiert.

Aufgrund der baulich getrennten Fahrbahnen werden im unteren Teil der Abbildung D.28 alle vier Kartierungen (beide Hinfahrten und beide Rückfahrten) gleichzeitig visualisiert. In Ergänzung zu dem Luftbild der Streckenbeschreibung aus Anhang D.2 in Abbildung D.28 ist die Komplexität der Kreuzung im unteren Teil der Abbildung D.28 erkennbar. Es wird deutlich, dass säulenförmige Umgebungscharakteristiken sowohl in den Hinfahrten als auch in den Rückfahrten wahrgenommen werden.

Nachfolgend sind die beiden Kreuzungen „Petzvalstraße“ und „Messeweg“ (jeweils in Braunschweig), die noch zum Vorort Gliesmarode gehören, in Abbildung D.29 (Auszug der Karte um die Koordinaten (52.278812, 10.567433)) und Abbildung D.30 (Auszug der Karte um die Koordinaten (52.278812, 10.567433)) wiedergegeben. Die Luftbilder sind im vorangegangenen Kapitel in Abbildung D.14 und Abbildung D.15 präsentiert. Bei beiden Kreuzungen ist der Straßenverlauf in beide Richtungen durch Bebauung getrennt (Straßenbahnschienen, vgl. mit den genannten Luftbildern). Zur Regelung der Kreuzungen werden Ampelanlagen und zusätzliche Abbiegespuren eingesetzt. Die Straßeninfrastrukturkomplexität spiegelt sich in den Karten wider.

In den folgenden Abbildungen ist die Kartierung des Straßenverlaufs dargestellt. Oben sind die Hinfahrten, mittig die Rückfahrten und unten alle Fahrten gleichzeitig aufgezeigt.




Abbildung D.28: Karte der Zufahrt von Volkmarode nach Gliesmarode (Hinfahrten oben, Rückfahrten mittig, alle vier Fahrten gleichzeitig unten)




Abbildung D.29: Karte der Ortsdurchfahrt Gliesmarode an der Kreuzung „Petzvalstraße“ (Hinfahrten oben, Rückfahrten mittig, alle vier Fahrten gleichzeitig unten)




Abbildung D.30: Durchfahrt Gliesmarode an der Kreuzung „Messeweg“ (Hinfahrten oben, Rückfahrten mittig, alle vier Fahrten gleichzeitig unten)




Abbildung D.31: Braunschweig - Kreuzung „Querumer Straße“ (Hinfahrten oben, Rückfahrten mittig, alle vier Fahrten gleichzeitig unten)

Als letzte Teilstücke der Versuchsstrecke führt Abbildung D.31 das Ergebnis der Kartierung der Kreuzung „Querumer Straße“ in Braunschweig um die Koordinaten (52.278658, 10.558150) auf. Abbildung D.32 stellt den Endpunkt (bei Hinfahrten) und den Startpunkt (bei Rückfahrten) der Versuchsstrecke dar. Die abgebildete Karte visualisiert den Ausschnitt um die WGS84-Koordinaten (52.275511, 10.535634). Die Luftbilder zu den Kartenausschnitten sind in Abbildung D.16 und Abbildung D.17 gegeben. Während Abbildung D.32 im oberen Teil die Hinfahrten und im unteren Teil die Rückfahrten aufgezeigt, präsentiert Abbildung D.31 im unteren Teil die Kartierung als Überlagerung aller Fahrten.




Abbildung D.32: Streckenabschnitt in Braunschweig beim Ende (Hinfahrt) bzw. Beginn (Rückfahrt) der Versuchsstrecke (Hinfahrten oben, Rückfahrten unten)

## D.4 Weiterführende Lokalisierungsergebnisse der LbL

Zusätzlich zu den gezeigten qualitativen und quantitativen Auswertungen der Lokalisierung aus Kapitel 5.2, werden hier zum besseren Einblick in das Verhalten der Landmarkenbasierten Lokalisierung (LbL) weitere Auswertungen präsentiert. In Anlehnung an die bisher aufgeführten Untersuchungen sind die Ergebnisse der Hin- und Rückfahrt gegeben.

Abbildung D.33 zeigt den absoluten lateralen Fehler (oben), den absoluten longitudinalen Fehler (mittig) und den Gierfehler (unten) zwischen der LbL und dem Referenzortungssystem.




Abbildung D.33: Visualisierung von Fehlern und Standardabweichung der LbL im Vergleich zur Ortungsreferenz für den lateralen und longitudinalen Versatz sowie den Gierwinkel (Hinfahrt links, Rückfahrt rechts)

Der Fehler ist über den Zeitverlauf abgebildet und in Rot eingefärbt. Zusätzlich ist in Blau die ausgegebene Standardabweichung der LbL dargestellt. Die Unsicherheit einer Poseausgabe wird als empirische Standardabweichung über alle Partikel ermittelt. Um die Wahrscheinlichkeit eines Partikels zu berücksichtigen, werden die Partikelwahrscheinlichkeiten (vgl. Kapitel 4.3.3) als Gewichtung einbezogen. Es ist zu sehen, dass die aus der Partikelmenge des PLM ausgegebene Unsicherheit mit den Positionsfehlern korrespondiert.




Abbildung D.34: Visualisierung der Blickrichtungs-, Geschwindigkeits- und Gierwinkel Fehler der LbL gegenüber der Referenz (Hinfahrt links, Rückfahrt rechts)

Abbildung D.34 gibt oben den Fehler für die Blickrichtung (engl. Heading), in der Mitte den Geschwindigkeitsfehler und unten den Fehler für den Gierwinkel wieder. Der Blickrichtungsfehler ist über den Zeitverlauf dargestellt, während die Geschwindigkeits- und Gierwinkel Fehler in Abhängigkeit der Geschwindigkeit in Längsrichtung aufgeführt sind. Die einzelnen Fehlerpunkte sind in Blau abgebildet und wurden über den Vergleich zur Ortungsreferenz bestimmt. Für den Geschwindigkeits- und Gierwinkel Fehler ist in Rot die Ausgleichsgerade der Fehlerpunkte



ingezeichnet. Festzuhalten ist, dass sowohl Blickrichtungs-, Geschwindigkeits- als auch Gierwinkelfehler um 0 schwanken. Das zeigt, dass die Ausgabe der LbL Bias-frei ist.

## D.5 Algorithmus zur Bestimmung der Standardabweichung für den Mittelwert

Durch die Einteilung der Distanzwerte des Vektors  $D$ , entsprechend der Beschreibung in Kapitel 5.3, lässt sich die Standardabweichung des Mittelwertes von  $D$  abschätzen. Algorithmus D.1 zeigt die verwendete Methode. In den Zeilen 5 bis 11 werden die zehn Mittelwerte aus der Gesamtmenge der Distanzen des Vektors  $D$  gebildet (vgl. [270]). Die Zeilen 15 bis 19 berechnen die Varianz. Die Wurzel der Varianz wird in Zeile 21 gezogen und die Standardabweichung als gewünschter Rückgabewert ausgegeben.

---

**Algorithmus D.1** : Bestimmung der Standardabweichung für den Mittelwert über alle absoluten Distanzen.

---

**Daten** : Vektor  $D$   
**Ergebnis** : Standardabweichung für den Mittelwert

```

1
2 Initialisiere Vektor Anzahl Mittelwerte mit dem Wert 0 in 10 Feldern
3 Initialisiere Vektor Mittelwerte mit dem Wert 0 in 10 Feldern
4
5 für  $a = 0$ ;  $a < \text{Größe}(D)$ ;  $a++$  tue
6   |  $\text{Anzahl Mittelwerte}[a\%10]++$ 
7   |  $\text{Mittelwerte}[a\%10]+ = D[a]$ 
8 Ende
9 für  $a = 0$ ;  $a < 10$ ;  $a++$  tue
10  |  $\text{Mittelwerte}[a]/ = \text{Anzahl Mittelwerte}[a]$ 
11 Ende
12
13  $\text{Mittelwert Gesamt} = \text{Summe}(\text{Mittelwerte})$ 
14
15  $\text{Varianz} = 0$ 
16 für  $a = 0$ ;  $a < 10$ ;  $a++$  tue
17  |  $\text{Varianz}+ = \text{Mittelwerte}[a]^2$ 
18 Ende
19  $\text{Varianz} = \frac{\text{Varianz}}{10} - \text{Mittelwert Gesamt}^2$ 
20
21 zurück  $\text{Wurzel}(\text{Varianz})$ 
```

---

## D.6 Verrauschen der Applanix

Für die in Kapitel 5.3 durchgeführte Untersuchung wird zur Schaffung von variierbaren und wiederholbaren Experimentierbedingungen das Verrauschen der Eingangspose benötigt. Das hier vorgestellte Verfahren ist aus [276] entnommen. Es wird angenommen, dass die Genauigkeit der Pose einem Gauß'schen-Prozess unterliegt. Zur Verrauschung werden normalverteilte

Zufallszahlen verwendet. Zur Erreichung von Vergleichbarkeit und Reproduzierbarkeit wird ein Zufallszahlengenerator (vgl. Kapitel 4.3.6) zum Simulationsstart immer gleich initialisiert.

Für das Verrauschen der Eingangspose werden drei Zufallsvariablen (jeweils für die Längs- und Querrichtung sowie für die Blickrichtung) erzeugt. Der Mittelwert jeder Verteilung ist 0. Das Setzen der Standardabweichung kann separat erfolgen. Das bringt den Vorteil mit sich, dass Unsicherheiten der verschiedenen Achsen und der Blickrichtung verschieden verrauscht werden können. Für die Verfahren der LbL (vgl. Kapitel 4) werden die Eigenbewegungsschätzung (siehe Kapitel 3.1.3) und die globale Poseschätzung (siehe Kapitel 3.1.2) benötigt. Beide Eingangsgrößen müssen verrauscht werden (relative und absolute Pose). Es sei darauf hingewiesen, dass nur die Position und Blickrichtung verrauscht werden. Die verrauschte Pose wird in einem eigenen Datensatz ausgegeben. Alle anderen Daten, wie z.B. Geschwindigkeit und Beschleunigung, bleiben erhalten. Sie werden in den neu erzeugten Datensatz übernommen.

Die neue verrauschte absolute Position wird für ein festgelegtes Intervall  $I$  erzeugt. Die Intervallgröße von  $I$  gibt an, wie viele absolute Posen eingegangen sein müssen, bis eine neue verrauschte Pose berechnet wird. Die normalverteilte Positionsabweichung bleibt innerhalb des Intervalls konstant. Das beschriebene Verfahren zum Verrauschen der absoluten Position ist in Abbildung D.35 illustriert. Das Eingangssignal der Ortungsreferenz (siehe Kapitel 3.1.1) ist in Grün dargestellt. Bis zum Erreichen der Intervallgrenze bewegt sich die verrauschte, absolute Pose äquivalent zur Ortungsreferenz. In der Abbildung ist das bei den ersten drei Punkten durch Pfeile von den grünen Punkten zu den roten Punkten angedeutet. Die einzelnen roten Punkte entsprechen den verrauschten Positionen vor der Intervallgrenze  $I$ . Wird die Intervallgrenze erreicht, werden neue Zufallszahlen generiert und eine neue verrauschte absolute Position wird erzeugt (in Blau verdeutlicht). Wird die Intervallgrenze wieder erreicht, wiederholt sich der Prozess.




Abbildung D.35: Absolutes Verrauschen der Ortungsreferenz um die Intervallgrenze  $I$ , aus [276]

Zur Erzeugung einer verrauschten Eigenbewegungsschätzung wird im Gegensatz zur absoluten Position eine Sprungfreiheit gefordert. Es wird bei jedem Eingangssignal eine neue verrauschte relative Position berechnet. Die Sprungfreiheit wird durch eine große Intervallgrenze  $I$  der absoluten Position ermöglicht. Die relative Position bewegt sich zwischen der letzten und der aktuellen absoluten Position. Es wird zwischen der verrauschten alten und der verrauschten neuen absoluten Position gewichtet interpoliert. Das Gewicht wird aus dem Anteil der von der verrauschten relativen Position zurückgelegten Strecke zwischen der alten und der neuen absoluten Position bestimmt. Abbildung D.36 stellt die Methode dar. In Grün ist das nicht verrauschte Eingangssignal abgebildet. Die verrauschte neue absolute Position  $r_{neu}$  ist in Blau und die vorhergehende  $r_{alt}$  in Rot abgebildet. Bei jedem Eingangssignal bewegt sich die relative verrauschte Position von der alten zur neuen absoluten Position. Die Bewegung ist in Orange eingezeichnet. Zu Beginn und Ende wird leicht gedämpft. Zur Verdeutlichung der Dämpfung dient die orange interpolierte Linie zwischen den verrauschten relativen Positionen.




Abbildung D.36: Relatives Verrauschen der Ortungsreferenz, aus [276]

Die Dämpfung berechnet sich durch die Gewichtsfunktion  $g_R(a)$  und ist in Gleichung (D.1) gegeben. Das Gewicht entspricht dem Quotienten aus der Anzahl der eingegangenen Positionen seit Intervallbeginn  $a$  und der Intervallgröße  $|I|$ .

$$g_R(a) = \frac{a}{|I|} \quad (\text{D.1})$$

In der Interpolationsfunktion  $F_{\text{Interpolation}}$  wird die Schrittgröße, wenn  $a$  nahe der oberen oder unteren Intervallgrenze ist, gedämpft. Ein Zurückschnellen bei Erreichen der neuen absoluten Position wird vermieden. Gleichung (D.2) formuliert die Interpolationsfunktion. Der

Eingangsparameter  $r_{alt}$  beschreibt die verrauschte alte absolute Position,  $r_{neu}$  die neue verrauschte absolute Position und  $g_R(a)$  die beschriebene Gewichtsfunktion.

$$F_{\text{Interpolation}}(r_{alt}, r_{neu}, g_R(a)) = r_{alt} + \left( g_R(a)^2 \cdot (3 - 2 \cdot g_R(a)) \right) \cdot (r_{neu} - r_{alt}) \quad (\text{D.2})$$

Zur Ermittlung einer verrauschten Pose muss zusätzlich zu den Verrauschungen der absoluten und relativen Positionen auch die Blickrichtung mit einem Rauschen versehen werden. Zu beachten ist, dass die Blickrichtung auf  $\pm 180$  Grad eingeschränkt ist.

# Stichwortverzeichnis

- Ähnlichkeitsmaß für Karten, 109
- Applanix, *siehe* Ortungsreferenzeinheit
- Assoziierungsmatrix, *siehe* Korrespondenzmatrix
- Bayes-Filter, *siehe* Markov-Lokalisierung
- Beidou, 21
- Belegungskarten, *siehe* Rasterbasierte Umfeldrepräsentation
- Bewegungsmatrix, *siehe* Bewegungsschritt
- Bewegungsmodell, 94
- Bewegungsschritt, 60, 71, 84, 94, 186
- Binäre Bäume, *siehe* Hierarchische Datenstrukturen
- Bounding Box, 75
- Chi-Quadrat-Verteilung, 75, 196
- Data Distribution Service (DDS), 40, 174
- Datenassoziiierung, 32
- Dead Reckoning, *siehe* Lokale Lokalisierung
- Degrees Of Freedom (DOF), 19, 59, 184
- Detektionswahrscheinlichkeit, *siehe* Probability Detection ( $P_D$ )
- Differential Global Positioning System (DGPS), 21
- Distance of Quadratic Vertex Sum (DQVS), 78
- Distanzfunktionen, 76
- Dynamische Partikelstreuung, 102
- Earth-Centered, Earth-Fixed (ECEF), 54
- East-North-Up (ENU), 55
- EgoMaster, *siehe* Eigenbewegungsschätzung
- Eigenbewegung, *siehe* Lokale Lokalisierung
- Eigenbewegungsschätzung, 43, 177
- Elemente der Straßeninfrastruktur, *siehe* Landmarken
- Empfindlichkeit, 104
- Empirische Standardabweichung, 225
- Ergebnispose der LbL, 100
- Expectation Maximization (EM), 34
- Extended Kalman Filter (EKF), 17
- Extensible Markup Language (XML), 194
- F1-Score, 104, 109
- False Alarm Rate ( $\beta_{FA}$ ), 82, 104, 112
- Features from Accelerated Segment Test (FAST), 19
- Fehlermodell, 50
- Field Of View (FOV), *siehe* Sichtbereiche
- Fischaugenkamera, *siehe* TopView-System
- Front-Monokamera, 46, 179
- Fusion, 32, 70, 192
- Galileo, 21
- Gating, 74
- Gauß'sche-Trapezformel, 80
- Gauß-verteilter Zufallsgenerator, 101, 228
- Genauigkeit, 104
- Geography Markup Language (GML), 73
- Global Navigation Satellite System (GNSS), 21
- Global Navigation Satellite System (GLONASS), 21
- Global Nearest Neighbour (GNN), 33
- Global Positioning System (GPS), 20
- Globale Lokalisierung, 16
- Globale Poseschätzung, 41, 176
- Grid, *siehe* Raster
- Gridmap, *siehe* Rasterbasierte Umfeldrepräsentation
- Halton-Sequenz-Zufallsgenerator, 101
- Hierarchical Cluster Analysis (HCA), 45
- Hierarchische Datenstrukturen, 27, 194
- Ibeo Scala B2, 44, 177
- Inertial Measurement Unit (IMU), 18, 61

- Initialisierungszustand des PLM, *siehe* Sampling
- Innovations-Likelihood, 84
- Iterative Closest Point (ICP), 19, 61
- Joint Probabilistic Data Association (JPDA), 34
- Kalibrierungsschritt, 41, 59, 184, 194
- Kalman-Filter (KF), 17
- Konfidenzwert, 81
- Konfigurationsdatei, 69, 194
- Konsistentes Landmarkenumfeldmodell, 9, 62, 67, 70, 92
- Koppelortung, *siehe* Lokale Lokalisierung
- Korrespondenzbestimmung, *siehe* Datenassoziiierung
- Korrespondenzmatrix, 33, 75, 81
- Landmarken, 65
- Landmarkenbasierte Lokalisierung (LbL), 9, 61, 187
- Landmarkenbasierte Umfeldrepräsentation, *siehe* Objektbasierte Umfeldrepräsentation
- Landmarkendetektion, 44, 46, 48
- Laser Detection and Ranging (LaDAR), 39, 44
- Level-1-Landmarken, 66, 69, 187
- Level-2-Landmarken, 66, 70, 187
- Level-3-Landmarken, 66, 72, 187
- Light Detection and Ranging (LiDAR), 39, 44
- Linienbasierte Umfeldrepräsentation, *siehe* Objektbasierte Umfeldrepräsentation
- Log-Likelihood-Quotienten (LLR), *siehe* Konfidenzwert
- Lokale Lokalisierung, 16
- Low variance resampling, *siehe* Resampling
- Mahalanobis-Distanz, 75
- Map-Management-Layer (MML), 68, 72, 187
- Markov-Lokalisierung, 17
- Maximally Stable Extremal Regions (MSER), 19
- Mean of circular quantities, 100
- Mobileye, 46
- Monte Carlo Joint Probabilistic Data Association (MC-JPDA), 34
- Multi Hypothesis Tracking (MHT), 34
- Navigation Data Standard (NDS), 5, 62
- Navigation System using Time and Ranging (NAVSTAR), 20
- Nearest Neighbour (NN), 33
- Network Time Protocol (NTP), 40
- New Target Rate ( $\beta_{NT}$ ), 82, 104, 112
- Normalisierungsschritt, 98, 99
- Normalverteilung, 18, 97
- North-East-Down (NED), 55
- Null- & Alternativhypothese, 81
- Objektbasierte Umfeldrepräsentation, 28
- Objektverfolgung, *siehe* Tracking
- Octree, *siehe* Hierarchische Datenstrukturen
- OEMStar, *siehe* Globaler Poseschätzer
- Origin Car Coordinate System (OCCS), 56
- Ortungsreferenzeinheit, 41, 175
- Partikelfilter (PF), 17, 23, 91, 200
- Partikelfilterbasiertes Lokalisierungsmodell (PLM), 9, 62, 91, 197, 200
- Personenkraftwagens (PKW), 1
- Precision, *siehe* Genauigkeit
- Principal Component Analysis (PCA), 45
- Probabilistic Data Association (PDA), 33
- Probabilistische Datenassoziiierung, *siehe* Datenassoziiierung
- Probabilistische Lokalisierung, 17
- Probability Detection ( $P_D$ ), 84, 104, 112
- Probability Gate ( $P_G$ ), 75, 84
- Pseudo Random Noise (PRN), 20
- Punkt-basierte Umfeldrepräsentation, 26
- Quadtree, *siehe* Hierarchische Datenstrukturen
- Räumliche Synchronisierung, 69
- Ramer–Douglas–Peucker-Algorithmus, 69, 86
- Randbedingung R1: Dezentrale Karte, 4, 36, 53, 61, 62, 109, 165
- Randbedingung R2: Invariante, semi-persistente Umgebungsmerkmale in vielfältigen Außenszenarien, 5, 36, 62, 109, 153
- Randbedingung R3: Zweidimensionale, sensorische Umgebungswahrnehmung mit Seriensensorik, 6, 36, 58, 61, 62, 109
- Randbedingung R4: Initiales Vorwissen, 7, 36, 62, 109, 169
- Randbedingung R5: Zweidimensionale Fahrzeugbewegung, 8, 39, 54, 62, 109

- Randbedingung R6: Zeitstempel und Zeitverhalten, 8, 109, 163, 171
- Randbedingung R7: Kosteneffiziente Realisierung und Serieneinsatz, 8, 62, 109, 163
- Random Sample Consensus (RANSAC), 35
- Raster, 27
- Rasterbasierte Umfeldrepräsentation, 27
- Rasterkarten, *siehe* Rasterbasierte Umfeldrepräsentation
- Recall, *siehe* Empfindlichkeit
- Recovery-Partikel, 101, 103
- Region Of Interest (ROI), 43, 89
- Regularisierungsschritt, 99
- Resampling, 98, 101, 199
- Root Mean Square (RMS), 176
- Sampling, 101
- Satellite Based Augmentation System, *siehe* Differential Global Positioning System
- Scale Invariant Feature Transform (SIFT), 19, 24
- Sensor Reference Frame (SRF), 55
- Sensor-Data-Management (SDM), 69
- Sensor-Data-Object (SDO), 69, 194
- Sensor-Management-Layer (SML), 68, 69, 187
- Sensordatenfusion, *siehe* Fusion
- Sensormodell, 38, 95
- Sequential Probability Ratio Test (SPRT), 9, 22, 35, 37, 81, 163
- Sichtbereiche, 43, 89, 155
- Simultaneous Localisation and Mapping (SLAM), 17, 24
- Smoothing, 100
- Speeded Up Robust Features (SURF), 19, 24
- Sum of Gaussians (SoG), *siehe* Sensormodell
- Topologische Umfeldrepräsentation, *siehe* Objektbasierte Umfeldrepräsentation
- TopView-System, 48, 180
- Track, 32, 35, 70, 192
- Track-Innovation, 90
- Track-Management, 35, 70, 81, 90
- Track-Management-Layer (TML), 68, 70, 187
- Tracking, 32, 70, 187
- Tracking- & Fusionsmodell (TFM), 9, 62, 68, 194
- Tracking-Horizont, 72, 89
- Unscented Kalman Filter (UKF), 17
- Vehicle Reference Frame (VRF), 55
- Vektorbasierte Umfeldrepräsentation, *siehe* Objektbasierte Umfeldrepräsentation
- World Geodetic System 1984 (WGS84), 5, 54, 62
- Zeitliche Synchronisierung, 70, 90
- Zero Velocity Update, 103





# Literaturverzeichnis

- [1] IFR Statistical Department, „Executive summary of World Robotics“, 2010. [Online]. Adresse: [www.worldrobotics.org](http://www.worldrobotics.org) (aufgerufen am 01.02.2016).
- [2] —, „Executive summary of World Robotics“, 2015. [Online]. Adresse: [www.worldrobotics.org](http://www.worldrobotics.org) (aufgerufen am 01.02.2016).
- [3] L. J. Latecki, R. Lakaemper, X. Sun und D. Wolter, „Building polygonal maps from laser range data“, in *International Cognitive Robotics Workshop (CogRob)*, IEEE, Bd. 10, 2004, S. 56–62.
- [4] E. Brunskill und N. Roy, „SLAM using incremental probabilistic PCA and dimensionality reduction“, in *International Conference on Robotics and Automation (ICRA)*, IEEE, 2005, S. 342–347.
- [5] E. Zalama, G. Candela, J. Gómez und S. Thrun, „Concurrent mapping and localization for mobile robots with segmented local maps“, in *International Conference on Intelligent Robots and Systems (IROS)*, IEEE, Bd. 1, 2002, S. 546–551.
- [6] F. Amigoni, G. Fontana und F. Garigiola, „A method for building small-size segment-based maps“, in *Distributed Autonomous Robotic Systems*, Bd. 7, Springer, 2006, S. 11–20.
- [7] B. Kitt, A. Geiger und H. Lategahn, „Visual odometry based on stereo image sequences with RANSAC-based outlier rejection scheme“, in *Intelligent Vehicles Symposium (IV)*, IEEE, 2010, S. 486–492.
- [8] H. Lategahn, M. Schreiber, J. Ziegler und C. Stiller, „Urban localization with camera and inertial measurement unit“, in *Intelligent Vehicles Symposium (IV)*, IEEE, 2013, S. 719–724.
- [9] H. Lategahn und C. Stiller, „Videobasierte Kartierung und Lokalisierung für hochautomatisiertes Fahren“, in *Braunschweiger Symposium – Automatisierungssysteme, Assistenzsysteme und eingebettete Systeme für Transportmittel (AAET)*, ITS Niedersachsen e.V., 2014, S. 18.

- [10] H. Lategahn und C. Stiller, „Experimente zur hochpräzisen landmarkenbasierten Eigenlokalisierung in unsicherheitsbehafteten digitalen Karten“, in *Workshop Fahrerassistenzsysteme Walting*, 2012, S. 39–46.
- [11] J. Ziegler, P. Bender, M. Schreiber, H. Lategahn, T. Strauss, C. Stiller *et al.*, „Making bertha drive - an autonomous journey on a historic route“, *IEEE Intelligent Transportation Systems Magazine*, Jg. 6, Nr. 2, S. 8–20, 2014.
- [12] T.-T. Weiss, „Hochgenaue Positionierung und Kartographie mit Laserscannern für Fahrerassistenzsysteme“, Dissertation, Universität Ulm, 2011.
- [13] J. M. Wille, F. Saust und M. Maurer, „Stadtpilot: Driving autonomously on Braunschweig’s inner ring road“, *IEEE Intelligent Vehicles Symposium (IV)*, S. 506–511, 2010.
- [14] F. Homm, „Fahrzeugeigenlokalisierung im Kontext hochautomatisierter Fahrfunktionen“, Dissertation, Technische Universität München, 2012.
- [15] J. Levinson und S. Thrun, „Robust vehicle localization in urban environments using probabilistic maps“, in *International Conference on Robotics and Automation (ICRA)*, IEEE, 2010, S. 4372–4378.
- [16] M. Schreiber, C. Knoppel und U. Franke, „Laneloc: Lane marking based localization using highly accurate maps“, in *Intelligent Vehicles Symposium (IV)*, IEEE, 2013, S. 449–454.
- [17] A. Ranganathan, D. Ilstrup und T. Wu, „Light-weight localization for vehicles using road markings“, in *International Conference on Intelligent Robots and Systems (IROS)*, IEEE, 2013, S. 921–927.
- [18] D. Fassbender, M. Kusenbach und H.-J. Wuensche, „Landmark-based navigation in large-scale outdoor environments“, in *International Conference on Intelligent Robots and Systems (IROS)*, IEEE, 2015, S. 4445–4450.
- [19] J. Elseberg, R. T. Creed und R. Lakaemper, „A line segment based system for 2D global mapping“, in *International Conference on Robotics and Automation (ICRA)*, IEEE, 2010, S. 3924–3931.
- [20] O. Wulf, D. Lecking und B. Wagner, „Robust self-localization in industrial environments based on 3D ceiling structures“, in *International Conference on Intelligent Robots and Systems (IROS)*, IEEE, 2006, S. 1530–1534.
- [21] S. Schwertfeger, „Robotic Mapping in the Real World: Performance Evaluation and System Integration“, Dissertation, Jacobs University, 2012.

- [22] C. Jin, H. Qing und Z. Yong, „Construction method of line segment based map with sonar sensor“, in *Chinese Control Conference (CCC)*, IEEE, 2015, S. 5819–5823.
- [23] D. Sack und W. Burgard, „A comparison of methods for line extraction from range data“, in *Symposium on Intelligent Autonomous Vehicles (IAV)*, IFAC, Bd. 33, 2004, S. 6.
- [24] N. Mattern, R. Schubert und G. Wanielik, „High-accurate vehicle localization using digital maps and coherency images“, in *Intelligent Vehicles Symposium (IV)*, IEEE, 2010, S. 462–469.
- [25] S. Saha, B. Sarkar und P. K. Pal, „Monte Carlo-based Pose Tracking on Maps Represented with Line Segments“, in *Conference on Advances In Robotics (AIR)*, ACM, 2015, S. 1–6.
- [26] B. Sarkar, S. Saha und P. K. Pal, „A novel method for computation of importance weights in Monte Carlo localization on line segment-based maps“, *Robotics and Autonomous Systems*, Jg. 74, S. 51–65, 2015.
- [27] S. Blackman und R. Propoli, *Design and Analysis of Modern Tracking Systems*. London: Artech House, 1999.
- [28] S. Thrun, W. Burgard und D. Fox, *Probabilistic Robotics*. MIT Press, 2005.
- [29] K. Schönherr, „Kopplung von Sensorinformationen und Geodaten zur modellbasierten Lokalisierung und Kartierung im Automobil“, Dissertation, Technische Universität München, 2011.
- [30] A. Sasse, „Robuste Fahrzeugortung zur Anwendung in sicherheitsrelevanten Fahrerassistenzsystemen“, Dissertation, Technischen Universität Carolo-Wilhelmina zu Braunschweig, 2011.
- [31] M. Kerper und A. Sasse, „Big Loop : Die vernetzte Karte für das automatische Fahren“, in *VDI-Wissensforum*, 2013, S. 151–167.
- [32] S. Rauch, M. Aeberhard, M. Ardelt und N. Kämpchen, „Autonomes Fahren auf der Autobahn - eine Potentialstudie für zukünftige Fahrerassistenzsysteme“, in *Tagung Fahrerassistenz*, Technische Universität München, Bd. 5, 2012, S. 13.
- [33] R. Dubitzky, „Das Fahrzeug als Sensor - Kooperatives Wahrnehmen und Lernen für automatisiertes Fahren“, *ATZ Elektronik*, Jg. 10, Nr. 2, S. 38–43, 2015.
- [34] C. K. H. Wilson, S. Rogers und S. Weisenburger, „The Potential of Precision Maps in Intelligent Vehicles“, in *International Conference on Intelligent Vehicles*, IEEE, 1998, S. 419–422.

- [35] R. Behrens, T. Kleine-Besten, W. Pöchmüller und A. Engelsberg, „Digitale Karten im Navigation Data Standard Format“, in *Handbuch Fahrerassistenzsysteme*, Springer, 2015, S. 513–523.
- [36] B. Dornieden, P. Pascheka *et al.*, „Anticipatory energy-efficient longitudinal vehicle control“, *ATZ worldwide*, Jg. 114, Nr. 3, S. 24–29, 2012.
- [37] M. Röckl, J. Gacnik und J. Schomerus, „Integration of Car-2-Car communication as a virtual sensor in automotive sensor fusion for advanced driver assistance systems“, *Springer Automotive Media Proceedings*, 2008.
- [38] P. Robertson, M. Röckl und M. Angermann, „Advances in multi-sensor data fusion for ubiquitous positioning: novel approaches for robust localization and mapping“, in *VDE-Kongress*, VDE-Verlag GmbH, 2010, S. 5.
- [39] M.-O. Löwner, A. Sasse und P. Hecker, „Needs and potential of 3D city information and sensor fusion technologies for vehicle positioning in urban environments“, in *Developments in 3D Geo-Information Sciences*, Springer, 2010, S. 143–156.
- [40] J. S. Levinson, S. Thrun, D. Koller und M. Levoy, *Automatic laser calibration, mapping, and localization for autonomous vehicles*. Stanford University, 2011.
- [41] M. Montemerlo, J. Becker, S. Bhat, H. Dahlkamp, D. Dolgov, S. Ettinger, D. Haehnel, T. Hilden, S. Thrun *et al.*, „Junior: The Stanford Entry in the Urban Challenge“, *Journal of field Robotics*, Jg. 25, Nr. 9, S. 569–597, 2008.
- [42] UMTS Forum, „Mobile traffic forecasts 2010-2020 report“, *White Paper*, 2011. [Online]. Adresse: <http://www.umts-forum.org>.
- [43] Cisco Systems, „Visual Networking Index: Global Mobile Data Traffic Forecast Update, 2015 - 2020“, *White Paper*, S. 1–39, 2016. [Online]. Adresse: <http://www.cisco.com/c/en/us/solutions/service-provider/index.html>.
- [44] G. P. Fettweis, „A 5G wireless communications vision“, *Microwave Journal*, Jg. 55, Nr. 12, S. 24–36, 2012.
- [45] L. Gavrilovska, V. Rakovic und V. Atanasovski, „Visions towards 5G: Technical requirements and potential enablers“, *Wireless Personal Communications*, Jg. 87, Nr. 3, S. 731–757, 2016.
- [46] D. Soldani und A. Manzalini, „Horizon 2020 and beyond: on the 5G operating system for a true digital society“, *IEEE Vehicular Technology Magazine*, Jg. 10, Nr. 1, S. 32–42, 2015.
- [47] G. Liu und D. Jiang, „5G: Vision and Requirements for Mobile Communication System towards Year 2020“, *Chinese Journal of Engineering*, 2016.

- [48] NGMN Alliance, „Next Generation Mobile Networks“, *White Paper*, 2015. [Online]. Adresse: [http://ngmn.org/uploads/media/NGMN\\_5G\\_White\\_Paper\\_V1\\_0.pdf](http://ngmn.org/uploads/media/NGMN_5G_White_Paper_V1_0.pdf).
- [49] P. Pirinen, „A brief overview of 5G research activities“, in *International Conference on 5G for Ubiquitous Connectivity (5GU)*, IEEE, 2014, S. 17–22.
- [50] A. Gohil, H. Modi und S. K. Patel, „5G technology of mobile communication: A survey“, in *International Conference on Intelligent Systems and Signal Processing (ISSP)*, IEEE, 2013, S. 288–292.
- [51] M. Eriksson und J. van de Beek, „Is anyone out there? 5G, rural coverage and the next 1 billion“, *IEEE ComSoc Technology News (CTN)*, 2015.
- [52] R. Ratasuk, A. Prasad, Z. Li, A. Ghosh und M. A. Uusitalo, „Recent advancements in M2M communications in 4G networks and evolution towards 5G“, in *International Conference on Intelligence in Next Generation Networks (ICIN)*, IEEE, 2015, S. 52–57.
- [53] N. Michailow, R. Datta, S. Krone, M. Lentmaier und G. Fettweis, „Generalized frequency division multiplexing: a flexible multi-carrier modulation scheme for 5th generation cellular networks“, *IEEE Transactions on Communications*, S. 1–18, 2014.
- [54] R. Di Taranto, S. Muppisetty, R. Raulefs, D. Slock, T. Svensson und H. Wymeersch, „Location-aware communications for 5G networks: How location information can improve scalability, latency, and robustness of 5G“, *IEEE Signal Processing Magazine*, Jg. 31, Nr. 6, S. 102–112, 2014.
- [55] TomTom International B.V., „TomTom Homepage“, 2015. [Online]. Adresse: [www.tomtom.com/de\\_de](http://www.tomtom.com/de_de) (aufgerufen am 11. 04. 2016).
- [56] ZEIT ONLINE, „BMW, Daimler und Audi kaufen Kartendienst Here“, 2015. [Online]. Adresse: [www.zeit.de/digital/2015-08/bmw-audi-daimler-kauf-here-nokia](http://www.zeit.de/digital/2015-08/bmw-audi-daimler-kauf-here-nokia) (aufgerufen am 11. 04. 2016).
- [57] S. Coppens, „Mapping the world with LiDAR“, *Netherlands Geodetic Commission (NCG KNAW)*, S. 69, 2010.
- [58] G. Goth, „Where It’s At: Mapping Battle Highlights New Era of Revenue and Development Models“, *IEEE Internet Computing*, Nr. 1, S. 7–9, 2013.
- [59] NavInfo Co., „NavInfo Homepage“, 2015. [Online]. Adresse: [www.navinfo.com/en](http://www.navinfo.com/en) (aufgerufen am 11. 04. 2016).
- [60] European Commission’s Directorate General for Communications Networks, Content & Technology (DG CONNECT), „eCall in all new cars from April 2018“,

2015. [Online]. Adresse: [www.ec.europa.eu/digital-single-market/en/news/ecall-all-new-cars-april-2018](http://www.ec.europa.eu/digital-single-market/en/news/ecall-all-new-cars-april-2018) (aufgerufen am 11. 04. 2016).
- [61] A. Zapp, „Automatische Straßenfahrzeugführung durch Rechnersehen“, Dissertation, Universität der Bundeswehr München, 1988.
- [62] F. Panik, „The Prometheus Vision“, Europe General Assembly, 2007. [Online]. Adresse: [www.channelingreality.com](http://www.channelingreality.com) (aufgerufen am 30. 01. 2016).
- [63] C. Voy, F. Panik, D. Reister und L. Hamm, „PROMETHEUS, ein europäisches Forschungsprojekt zur Gestaltung des Straßenverkehrs der Zukunft“, *Automobil-Industrie*, Jg. 32, Nr. 2, 1987.
- [64] E. D. Dickmanns, R. Behringer, D. Dickmanns, T. Hildebrandt, M. Maurer, F. Thomanek und J. Schiehlen, „The seeing passenger car 'VaMoRs-P'“, in *Intelligent Vehicles Symposium (IV)*, IEEE, 1994, S. 68–73.
- [65] D. Reichardt, „Kontinuierliche Verhaltenssteuerung eines autonomen Fahrzeugs in dynamischer Umgebung“, Dissertation, Universität Kaiserslautern, 1996.
- [66] K.-H. Siedersberger, „Komponenten zur automatischen Fahrzeugführung in sehenden (semi-) autonomen Fahrzeugen“, Dissertation, Universität der Bundeswehr München, 2003.
- [67] F. Flemisch, S. Meier, J. Neuhöfer, M. Baltzer, E. Altendorf und E. Özyurt, „Kognitive und kooperative Systeme in der Fahrzeugführung: Selektiver Rückblick über die letzten Dekaden und Spekulation über die Zukunft“, *International Conference on Cognitive Systems (CogSys)*, Jg. 5, 2012.
- [68] G. Reichart und W. Huber, „Forschungsprogramm MoTiv. Status und weitere Perspektiven“, *VDI-Berichte*, Nr. 1372, 1998.
- [69] D. Ehmanns und A. Hochstädter, „Driver-model of lane change maneuvers“, in *World Congress on Intelligent Transport Systems*, Bd. 7, 2000, S. 1–8.
- [70] E. Hipp, „INVENT - Intelligenter Verkehr und nutzergerechte Technik“, *Internationales Verkehrswesen*, Jg. 55, 2003.
- [71] W. Scholl, „INVENT-Online“, 2005. [Online]. Adresse: [www.invent-online.de](http://www.invent-online.de) (aufgerufen am 10. 10. 2016).
- [72] —, „AKTIV -Online“, 2006. [Online]. Adresse: [www.aktiv-online.org](http://www.aktiv-online.org) (aufgerufen am 10. 10. 2016).
- [73] H. Kimmerle, „AKTIV - gemeinsam die Zukunft erfahren. Forschungsinitiative AKTIV stellte Ergebnisse für sicheren und möglichst störungsfreien Strassenverkehr vor“, *POLIZEI VERKEHR + TECHNIK*, Jg. 56, 2011.

- [74] S. Thrun, M. Montemerlo, H. Dahlkamp, D. Stavens, A. Aron, J. Diebel, P. Fong, J. Gale, M. Halpenny, G. Hoffmann *et al.*, „Stanley: The robot that won the DARPA Grand Challenge“, *Journal of Field Robotics*, Jg. 23, Nr. 9, S. 661–692, 2006.
- [75] C. Urmson, J. A. Bagnell, C. R. Baker, M. Hebert, A. Kelly, R. Rajkumar, P. E. Rybski, S. Scherer, R. Simmons, S. Singh *et al.*, „Tartan Racing: A Multi-Modal Approach to the DARPA Urban Challenge“, Robotics Institute, Tech. Rep. CMU-RI-TR, 2007.
- [76] C. Urmson, J. Anhalt, D. Bagnell, C. Baker, R. Bittner, M. N. Clark, J. Dolan, D. Duggins, M. Taylor *et al.*, „Autonomous Driving in Urban Environments: Boss and the Urban Challenge“, *Journal of Field Robotics*, Jg. 25, S. 425–466, 2008. DOI: 10.1002/rob.
- [77] C. Berger und B. Rumpel, „Autonomes Fahren - Erkenntnisse aus der DARPA Urban Challenge (Autonomous Driving—Insights from the DARPA Urban Challenge)“, *IT-Information Technology*, Jg. 50, Nr. 4, S. 258–264, 2008.
- [78] A. Reschka, J. Gacnik, K. Frank, M. Wille und M. Maurer, „Development of Software for Open Autonomous Automotive Systems in the Stadtpilot-Project“, in *International Workshop on Intelligent Transportation (WIT)*, DLR, Bd. 8, 2011, S. 6.
- [79] T. Nothdurft, P. Hecker, S. Ohl, F. Saust, M. Maurer, A. Reschka und J. R. Böhmer, „Stadtpilot: First fully autonomous test drives in urban traffic“, in *International Conference Intelligent Transportation Systems (ITSC)*, IEEE, 2011, S. 919–924.
- [80] S. Ohl, R. Matthaei, M. Müller und M. Maurer, „Softwarearchitektur der gitterbasierten Sensordatenfusion des Projekts Stadtpilot“, in *Braunschweiger Symposium – Automatisierungssysteme, Assistenzsysteme und eingebettete Systeme für Transportmittel (AAET)*, ITS Niedersachsen e.V., 2011, S. 280–298.
- [81] S. Ulbrich, T. Nothdurft, M. Maurer und P. Hecker, „Graph-based context representation, environment modeling and information aggregation for automated driving“, in *Intelligent Vehicles Symposium (IV)*, IEEE, 2014, S. 541–547.
- [82] F. Himm, N. Kaempchen und D. Burschka, „Fusion of laserscanner and video based lanemarking detection for robust lateral vehicle control and lane change maneuvers“, in *Intelligent Vehicles Symposium (IV)*, IEEE, 2011, S. 969–974.
- [83] T. Grünweg, „BMW Forschungsprojekt: Entspannung durch Chauffeur Computer“, 2011. [Online]. Adresse: [www.spiegel.de/auto/aktuell/bmw-forschungsprojekt-entspannung-durch-chauffeur-computer-a-783577](http://www.spiegel.de/auto/aktuell/bmw-forschungsprojekt-entspannung-durch-chauffeur-computer-a-783577) (aufgerufen am 22.07.2016).

- [84] —, „Selbststeuernder Wagen: Ausfahrt mit Autopilot“, 2013. [Online]. Adresse: [www.spiegel.de/auto/aktuell/autonomes-fahren-unterwegs-mit-einer-s-klasse-auf-autopilot-a-920803](http://www.spiegel.de/auto/aktuell/autonomes-fahren-unterwegs-mit-einer-s-klasse-auf-autopilot-a-920803) (aufgerufen am 22.07.2016).
- [85] J. Schmieder, „Autonomes Fahren: Guck’ mal - freihändig“, 2015. [Online]. Adresse: [www.sueddeutsche.de/auto/autonomes-fahren-guck-mal-freihaendig-1.2291962](http://www.sueddeutsche.de/auto/autonomes-fahren-guck-mal-freihaendig-1.2291962) (aufgerufen am 22.07.2016).
- [86] J. Markoff, „Google Cars Drive Themselves, in Traffic“, 2010. [Online]. Adresse: [www.nytimes.com/2010/10/10/science/10google.html?\\_r=0](http://www.nytimes.com/2010/10/10/science/10google.html?_r=0) (aufgerufen am 30.01.2016).
- [87] E. Guizzo, „How googles self-driving car works“, *IEEE Spectrum Online*, Jg. 18, 2011.
- [88] A. Fisher, „Inside Googles Quest to Popularize Self-Driving Cars“, 2013. [Online]. Adresse: [www.popsci.com/cars/article/2013-09/google-self-driving-car](http://www.popsci.com/cars/article/2013-09/google-self-driving-car) (aufgerufen am 16.04.2016).
- [89] J. Wendel, *Integrierte Navigationssysteme: Sensordatenfusion, GPS und Inertiale Navigation*. Walter de Gruyter, 2011, S. 346.
- [90] J. Hertzberg, K. Lingemann und A. Nüchter, *Mobile Roboter*. eXamen.press, 2011.
- [91] J. Borenstein, H. R. Everett, L. Feng und D. Wehe, „Mobile Robot Positioning – Sensors and Techniques“, *Journal of Robotic Systems*, Jg. 14, Nr. 4, S. 231–249, 1997.
- [92] J. Borenstein und L. Feng, „Measurement and correction of systematic odometry errors in mobile robots“, *IEEE Transactions on Robotics and Automation*, Jg. 12, Nr. 6, S. 869–880, 1996.
- [93] P. G. Mattos, „Integrated GPS and dead reckoning for low-cost vehicle navigation and tracking“, in *Vehicle Navigation and Information Systems Conference*, 1994, S. 569–574.
- [94] H. Durrant-Whyte und T. Bailey, „Simultaneous Localization and Mapping: Part I“, *IEEE Robotics & Automation Magazine*, Jg. 13, Nr. 2, S. 99–110, 2006.
- [95] T. Bailey und H. Durrant-Whyte, „Simultaneous Localization and Mapping (SLAM): Part II“, *IEEE Robotics & Automation Magazine*, Jg. 13, Nr. 3, S. 108–117, 2006.
- [96] F. Lu und E. Milius, „Globally consistent range scan alignment for environment mapping“, *Autonomous robots*, Jg. 4, Nr. 4, S. 333–349, 1997.
- [97] S. Thrun, „Robotic Mapping: A Survey“, *Exploring artificial intelligence in the new millennium*, Jg. 1, S. 1–35, 2002.



- [98] R. E. Kalman, „A new approach to linear filtering and prediction problems“, *Journal of basic Engineering*, Jg. 82, Nr. 1, S. 35–45, 1960.
- [99] R. E. Kalman und R. S. Bucy, „New results in linear filtering and prediction theory“, *Journal of Basic Engineering*, Jg. 83, Nr. 1, S. 95–108, 1961.
- [100] G. L. Smith, S. F. Schmidt und L. A. McGee, *Application of statistical filter theory to the optimal estimation of position and velocity on board a circumlunar vehicle*. National Aeronautics und Space Administration, 1962.
- [101] H. W. Sorenson, *Kalman Filtering: Theory and Application*. IEEE Press, 1985.
- [102] S. J. Julier und J. K. Uhlmann, „A new extension of the Kalman filter to nonlinear systems“, in *International Symposium AeroSense*, International Society for Optics und Photonics, 1997, S. 182–193.
- [103] S. Thrun, D. Fox, W. Burgard und F. Dellaert, „Robust Monte Carlo localization for mobile robots“, *Artificial Intelligence*, Jg. 128, S. 99–141, 2001.
- [104] E. A. Wan und A. T. Nelson, „Dual extended Kalman filter methods“, *Kalman Filtering and Neural Networks*, S. 123–173, 2001.
- [105] E. A. Wan und R. Van Der Merwe, „The unscented Kalman filter for nonlinear estimation“, in *Adaptive Systems for Signal Processing, Communications, and Control Symposium*, IEEE, 2000, S. 153–158.
- [106] D. Fox, W. Burgard, F. Dellaert und S. Thrun, „Monte Carlo Localization: Efficient Position Estimation for Mobile Robots“, in *Conference on Artificial Intelligence*, AAAI, 1999, S. 343–349.
- [107] F. Dellaert, D. Fox, W. Burgard und S. Thrun, „Monte carlo localization for mobile robots“, in *International Conference on Robotics and Automation (ICRA)*, IEEE, Bd. 2, 1999, S. 1322–1328.
- [108] S. Thrun, „Probabilistic Algorithms in Robotics“, *AAAI AI Magazine*, Jg. 21, Nr. 4, S. 93–109, 2000.
- [109] J.-S. Gutmann, W. Burgard, D. Fox und K. Konolige, „An experimental comparison of localization methods“, in *International Conference on Intelligent Robots and Systems (IROS)*, IEEE, Bd. 2, 1998, S. 736–743.
- [110] C. F. Olson, „Probabilistic self-localization for mobile robots“, *IEEE Transactions on Robotics and Automation*, Jg. 16, Nr. 1, S. 55–66, 2000.
- [111] J.-S. Gutmann und D. Fox, „An experimental comparison of localization methods continued“, in *International Conference on Intelligent Robots and Systems (IROS)*, IEEE, Bd. 1, 2002, S. 454–459.

- [112] R. Schubert, E. Richter und G. Wanielik, „Comparison and evaluation of advanced motion models for vehicle tracking“, in *International Conference on Information Fusion*, IEEE, 2008, S. 1–6.
- [113] D. G. Lowe, „Distinctive image features from scale-invariant keypoints“, *International Journal of Computer Vision*, Jg. 60, Nr. 2, S. 91–110, 2004.
- [114] H. Bay, T. Tuytelaars und L. Van Gool, „Surf: Speeded up robust features“, in *European Conference on Computer Vision (ECCV)*, Springer, 2006, S. 404–417.
- [115] H. Bay, A. Ess, T. Tuytelaars und L. Van Gool, „Speeded-up robust features (SURF)“, *Computer Vision and Image Understanding*, Jg. 110, Nr. 3, S. 346–359, 2008.
- [116] J. Matas, O. Chum, M. Urban und T. Pajdla, „Robust wide-baseline stereo from maximally stable extremal regions“, *Image and Vision Computing*, Jg. 22, Nr. 10, S. 761–767, 2004.
- [117] E. Rosten und T. Drummond, „Machine learning for high-speed corner detection“, in *European Conference on Computer Vision*, ECCV, 2006, S. 430–443.
- [118] S. Rusinkiewicz und M. Levoy, „Efficient variants of the ICP algorithm“, in *International Conference on 3D Digital Imaging and Modeling*, IEEE, 2001, S. 145–152.
- [119] F. Lu und E. Milios, „Robot pose estimation in unknown environments by matching 2D range scans“, *Journal of Intelligent and Robotic Systems*, Jg. 18, Nr. 3, S. 249–275, 1997.
- [120] M. Magnusson, „The three-dimensional normal-distributions transform: an efficient representation for registration, surface analysis, and loop detection“, Dissertation, Örebro Universitet, 2009.
- [121] M. Magnusson, A. Nüchter, C. Lörken, A. J. Lilienthal und J. Hertzberg, „Evaluation of 3D registration reliability and speed - A comparison of ICP and NDT“, in *International Conference on Robotics and Automation (ICRA)*, IEEE, 2009, S. 3907–3912.
- [122] O. Pink, F. Moosmann und A. Bachmann, „Visual features for vehicle localization and ego-motion estimation“, in *Intelligent Vehicles Symposium (IV)*, IEEE, 2009, S. 254–260.
- [123] J. Kelly, S. Saripalli und G. Sukhatme, „Combined visual and inertial navigation for an unmanned aerial vehicle“, in *International Conference on Field and Service Robotics (FSR)*, IFRR, 2008, S. 255–264.

- [124] M. Baer, M. E. Bouzouraa, C. Demiral, U. Hofmann, S. Gies und K. Diepold, „EgoMaster: A central ego motion estimation for driver assist systems“, in *International Conference on Control and Automation (ICCA)*, IEEE, 2009, S. 1708–1715.
- [125] R. Lakaemper, L. J. Latecki, X. Sun und D. Wolter, „Geometric robot mapping“, in *International Conference on Discrete Geometry for Computer Imagery (DGCI)*, IAPR, 2005, S. 11–22.
- [126] P. Pfaff, R. Triebel, C. Stachniss, P. Lamon, W. Burgard und R. Siegwart, „Towards mapping of cities“, in *International Conference on Robotics and Automation (ICRA)*, IEEE, 2007, S. 4807–4813.
- [127] A. Nüchter und J. Hertzberg, „Towards semantic maps for mobile robots“, *Robotics and Autonomous Systems*, Jg. 56, Nr. 11, S. 915–926, 2008.
- [128] W. Mansfeld, *Satellitenortung und Navigation: Grundlagen und Anwendung globaler Satellitennavigationssysteme*. Springer-Verlag, 2013.
- [129] T. Nishizawa, A. Ohya und S. Yuta, „An implementation of on-board position estimation for a mobile robot-EKF based odometry and laser reflector landmarks detection“, in *International Conference on Robotics and Automation (ICRA)*, IEEE, Bd. 1, 1995, S. 395–400.
- [130] P. Bonnifait, P. Bouron, P. Crubille und D. Meizel, „Data fusion of four ABS sensors and GPS for an enhanced localization of car-like vehicles“, in *International Conference on Robotics and Automation (ICRA)*, IEEE, Bd. 2, 2001, S. 1597–1602.
- [131] P. Jensfelt und S. Kristensen, „Active global localization for a mobile robot using multiple hypothesis tracking“, *IEEE Transactions on Robotics and Automation*, Jg. 17, Nr. 5, S. 748–760, 2001.
- [132] N. M. Kwok und G. Dissanayake, „An efficient multiple hypothesis filter for bearing-only SLAM“, in *International Conference on Intelligent Robots and System (IROS)*, IEEE, Bd. 1, 2004, S. 736–741.
- [133] N. M. Kwok, G. Dissanayake und Q. P. Ha, „Bearing-only SLAM using a SPRT based gaussian sum filter“, in *International Conference on Robotics and Automation (ICRA)*, IEEE, 2005, S. 1109–1114.
- [134] K. Lingemann, A. Nüchter, J. Hertzberg und H. Surmann, „High-speed laser localization for mobile robots“, *Robotics and Autonomous Systems*, Jg. 51, Nr. 4, S. 275–296, 2005.

- [135] T. Scheide, M. Escher, H.-G. Büsing und P. Hecker, „Integrierte Fahrzeugortung für zukünftige Fahrerassistenzsysteme“, 2011. [Online]. Adresse: [www.digisrv-1.biblio.etc.tu-bs.de](http://www.digisrv-1.biblio.etc.tu-bs.de) (aufgerufen am 01.09.2015).
- [136] Z. Tao, P. Bonnifait, V. Fremont und J. Ibanez-Guzman, „Mapping and localization using GPS, lane markings and proprioceptive sensors“, in *International Conference on Intelligent Robots and Systems (IROS)*, IEEE, 2013, S. 406–412.
- [137] I. Miller, M. Campbell und D. Huttenlocher, „Map-Aided Localization in Sparse Global Positioning System Environments Using Vision and Particle Filtering“, *Journal of Field Robotics*, Jg. 28, Nr. 5, S. 619–643, 2011.
- [138] M. Hentschel, O. Wulf und B. Wagner, „A GPS and laser-based localization for urban and non-urban outdoor environments“, in *International Conference on Intelligent Robots and Systems (IROS)*, IEEE, 2008, S. 149–154.
- [139] M. Hentschel und B. Wagner, „Autonomous robot navigation based on OpenStreetMap geodata“, in *International Conference on Intelligent Transportation Systems (ITSC)*, IEEE, 2010, S. 1645–1650.
- [140] S. Pendleton, T. Uthaicharoenpong, Z. J. Chong, G. M. J. Fu, B. Qin, W. Liu, X. Shen, Z. Weng, C. Kamin, M. A. Ang *et al.*, „Autonomous golf cars for public trial of mobility-on-demand service“, in *International Conference on Intelligent Robots and Systems (IROS)*, IEEE, 2015, S. 1164–1171.
- [141] Z. J. Chong, B. Qin, T. Bandyopadhyay, M. H. Ang, E. Frazzoli und D. Rus, „Synthetic 2D LIDAR for precise vehicle localization in 3D urban environment“, in *International Conference on Robotics and Automation (ICRA)*, IEEE, 2013, S. 1554–1559.
- [142] O. Wulf, K. O. Arras, H. I. Christensen und B. Wagner, „2D mapping of cluttered indoor environments by means of 3D perception“, in *International Conference on Robotics and Automation (ICRA)*, IEEE, Bd. 4, 2004, S. 4204–4209.
- [143] R. Toledo-Moreo, D. Bétaille, F. Peyret und J. Laneurit, „Fusing GNSS, dead-reckoning, and enhanced maps for road vehicle lane-level navigation“, *IEEE Journal on Selected Topics in Signal Processing*, Jg. 3, Nr. 5, S. 798–809, 2009.
- [144] R. W. Wolcott und R. M. Eustice, „Visual localization within LIDAR maps for automated urban driving“, in *International Conference on Intelligent Robots and Systems (IROS)*, IEEE, 2014, S. 176–183.
- [145] M. Montemerlo und S. Thrun, *FastSLAM: A scalable method for the simultaneous localization and mapping problem in robotics*. Springer, 2007, Bd. 27.
- [146] D. Hähnel, „Mapping with mobile robots“, Dissertation, University of Freiburg, 2005.

- [147] A. Gil, O. Reinoso, O. M. Mozos, C. Stachniss und W. Burgard, „Improving Data Association in Vision-based SLAM“, in *International Conference on Intelligent Robots and Systems (IROS)*, IEEE, 2006, S. 2076–2081.
- [148] N. Tomatis, I. Nourbakhsh und R. Siegwart, „Simultaneous localization and map building: A global topological model with local metric maps“, in *International Conference on Intelligent Robots and Systems (IROS)*, IEEE, Bd. 1, 2001, S. 421–426.
- [149] H. Lategahn, A. Geiger und B. Kitt, „Visual SLAM for autonomous ground vehicles“, in *International Conference on Robotics and Automation (ICRA)*, IEEE, 2011, S. 1732–1737.
- [150] N. Sünderhauf, „Robust Optimization for Simultaneous Localization and Mapping“, Dissertation, Technische Universität Chemnitz, 2012.
- [151] —, „Optimieren statt Filtern: Neue robuste Algorithmen für SLAM und Sensorfusion“, *Regelungstechnisches Kolloquium*, Jg. 47, 2013.
- [152] M. Magnusson, H. Andreasson, A. Nüchter und A. J. Lilienthal, „Automatic appearance-based loop detection from three-dimensional laser data using the normal distributions transform“, *Journal of Field Robotics*, Jg. 26, Nr. 11-12, S. 892–914, 2009.
- [153] B. Kuipers, J. Modayil, P. Beeson, M. MacMahon und F. Savelli, „Local metrical and global topological maps in the hybrid spatial semantic hierarchy“, in *International Conference on Robotics and Automation (ICRA)*, IEEE, Bd. 5, 2004, S. 4845–4851.
- [154] M. Hentschel, „Langzeitnavigation mobiler Roboter in teilstrukturierten Umgebungen auf Basis eines raum- und zeitvarianten Umgebungsmodells“, Dissertation, Gottfried Wilhelm Leibniz Universität Hannover, 2012.
- [155] R. Drouilly, P. Rives und B. Morisset, „Hybrid metric-topological-semantic mapping in dynamic environments“, in *International Conference on Intelligent Robots and Systems (IROS)*, IEEE, 2015, S. 5109–5114.
- [156] P. Muehlfellner, P. Furgale, W. Derendarz und R. Philippsen, „Evaluation of fisheye-camera based visual multi-session localization in a real-world scenario“, in *Intelligent Vehicles Symposium (IV)*, IEEE, 2013, S. 57–62.
- [157] P. Mühlfellner, M. Bürki, M. Bosse, W. Derendarz, R. Philippsen und P. Furgale, „Summary maps for lifelong visual localization“, *Journal of Field Robotics*, 2015.
- [158] R. Siegwart, I. R. Nourbakhsh und D. Scaramuzza, *Introduction to Autonomous Mobile Robots*. MIT Press, 2004.

- [159] R. Sedgewick, K. D. Wayne und K. D. Wayne, *Algorithmen: Algorithmen und Datenstrukturen*. Pearson Studium, 2014.
- [160] S. Thrun, Y. Liu, D. Koller, A. Y. Ng, Z. Ghahramani und H. Durrant-Whyte, „Simultaneous localization and mapping with sparse extended information filters“, *The International Journal of Robotics Research*, Jg. 23, Nr. 7-8, S. 693–716, 2004.
- [161] J. Levinson, M. Montemerlo und S. Thrun, „Map-Based Precision Vehicle Localization in Urban Environments“, in *Robotics: Science and Systems*, RSS Foundation, Bd. 4, 2007, S. 352.
- [162] M. R. Schmid, „Umgebungserfassung für Fahrerassistenzsysteme mit hierarchischen Belegungskarten“, Dissertation, Universität der Bundeswehr München, 2012.
- [163] S. Steinmeyer, „Probabilistische Fahrzeugumfeldschätzung für Fahrerassistenzsysteme“, Dissertation, Technischen Universität Carolo-Wilhelmina zu Braunschweig, 2014.
- [164] D. Lagunovsky und S. Ablameyko, „Fast line and rectangle detection by clustering and grouping“, in *International Conference Computer Analysis of Images and Patterns (CAIP)*, Springer, 1997, S. 503–510.
- [165] M. Veeck und W. Burgard, „Learning polyline maps from range scan data acquired with mobile robots“, in *International Conference on Intelligent Robots and Systems (IROS)*, IEEE, Bd. 2, 2004, S. 1065–1070.
- [166] J. P. Lorenzo, R. Vazquez-Martin, P. Nunez, E. J. Pérez und F. Sandoval, „A Hough-based method for concurrent mapping and localization in indoor environments“, in *Conference on Robotics, Automation and Mechatronics*, IEEE, Bd. 2, 2004, S. 840–845.
- [167] R. Lakaemper, „Simultaneous multi-line-segment merging for robot mapping using mean shift clustering“, in *International Conference on Intelligent Robots and Systems (IROS)*, IEEE, 2009, S. 1654–1660.
- [168] K. Fukunaga und L. Hostetler, „The estimation of the gradient of a density function, with applications in pattern recognition“, *IEEE Transactions on Information Theory*, Jg. 21, Nr. 1, S. 32–40, 1975.
- [169] B. Sarkar, P. K. Pal und D. Sarkar, „Building maps of indoor environments by merging line segments extracted from registered laser range scans“, *Robotics and Autonomous Systems*, Jg. 62, Nr. 4, S. 603–615, 2014.
- [170] I. Varsadan, A. Birk und M. Pfungsthorn, „Determining map quality through an image similarity metric“, in *Robot Soccer World Cup*, Springer, 2008, S. 355–365.

- [171] A. Birk, „Learning geometric concepts with an evolutionary algorithm“, in *Conference on Evolutionary Programming*, MIT Press, Bd. 5, 1996, S. 83–90.
- [172] H. Moravec und M. Blackwell, „Learning sensor models for evidence grids“, *Robotics Institute Research Review*, 1992.
- [173] A. Birk, „A quantitative assessment of structural errors in grid maps“, *Autonomous Robots*, Jg. 28, Nr. 2, S. 187–196, 2010.
- [174] A. I. Wagan, A. Godil und X. Li, „Map quality assessment“, in *Workshop on Performance Metrics for Intelligent Systems*, ACM, 2008, S. 278–282.
- [175] O. Wulf, A. Nüchter, J. Hertzberg und B. Wagner, „Ground truth evaluation of large urban 6D SLAM“, in *International Conference on Intelligent Robots and Systems (IROS)*, IEEE, 2007, S. 650–657.
- [176] T. Yairi, „Covisibility-based map learning method for mobile robots“, in *Pacific Rim International Conference on Artificial Intelligence (PRICAI)*, Springer, 2004, S. 703–712.
- [177] R. Lakaemper, „A Confidence Measure for Segment Based Maps“, in *Workshop on Performance Metrics for Intelligent Systems*, ACM, 2009, S. 211–216.
- [178] R. Lakaemper und R. Madhavan, „Towards evaluating world modeling for autonomous navigation in unstructured and dynamic environments“, in *Performance Metrics for Intelligent Systems Workshop*, ACM, Bd. 10, 2010, S. 355–360.
- [179] Y. Bar-Shalom, *Tracking and Data Association*. Academic Press Professional, 1987.
- [180] —, „Multitarget-Multisensor Tracking: Applications and Advances. Volume III“, *Artech House*, 2000.
- [181] B. Khaleghi, A. Khamis, F. O. Karray und S. N. Razavi, „Multisensor data fusion: A review of the state-of-the-art“, *International Journal on Multi-Sensor, Multi-Source Information Fusion*, Jg. 14, Nr. 1, S. 28–44, 2013.
- [182] A. Yilmaz, O. Javed und M. Shah, „Object tracking: A survey“, *ACM Computing Surveys (CSUR)*, Jg. 38, Nr. 4, 2006.
- [183] J. Munkres, „Algorithms for the Assignment and Transportation Problems“, *Journal of the society for industrial and applied mathematics*, Jg. 5, Nr. 1, S. 32–38, 1957.
- [184] D. Reid, „An algorithm for tracking multiple targets“, *IEEE Transactions on Automatic Control*, Jg. 24, Nr. 6, S. 843–854, 1979.

- [185] J. Neira und J. D. Tardós, „Data association in stochastic mapping using the joint compatibility test“, *IEEE Transactions on Robotics and Automation*, Jg. 17, Nr. 6, S. 890–897, 2001.
- [186] J. Vermaak, S. J. Godsill und P. Perez, „Monte carlo filtering for multi target tracking and data association“, *IEEE Transactions on Aerospace and Electronic Systems*, Jg. 41, Nr. 1, S. 309–332, 2005.
- [187] P. Pfaff, W. Burgard und D. Fox, „Robust monte-carlo localization using adaptive likelihood models“, in *European Robotics Symposium*, Springer, 2006, S. 181–194.
- [188] P. Pfaff, C. Plagemann und W. Burgard, „Gaussian mixture models for probabilistic localization“, in *International Conference on Robotics and Automation (ICRA)*, IEEE, 2008, S. 467–472.
- [189] P. Pfaff, C. Stachniss, C. Plagemann und W. Burgard, „Efficiently learning high-dimensional observation models for Monte-Carlo localization using Gaussian mixtures“, in *International Conference on Intelligent Robots and Systems (IROS)*, IEEE, 2008, S. 3539–3544.
- [190] A. Wald, „Sequential tests of statistical hypotheses“, in *Breakthroughs in Statistics*, Springer, 1992, S. 256–298.
- [191] A. Wald und J. Wolfowitz, „Optimum character of the sequential probability ratio test“, *The Annals of Mathematical Statistics*, S. 326–339, 1948.
- [192] A. Wald, *Sequential Analysis*. Courier Corporation, 1973.
- [193] C. Kwok, D. Fox und M. Meila, „Adaptive real-time particle filters for robot localization“, in *International Conference on Robotics and Automation (ICRA)*, IEEE, Bd. 2, 2003, S. 2836–2841.
- [194] X. R. Li, N. Li und V. P. Jilkov, „SPRT-based track confirmation and rejection“, in *International Conference on Information Fusion*, IEEE, Bd. 2, 2002, S. 951–958.
- [195] G. W. Pulford, „Markov Chain Analysis of the Sequential Probability Ratio Test for Automatic Track Maintenance“, in *International Conference of Information Fusion*, ISIF, 2003, S. 1258–1265.
- [196] C. Hasberg, „Simultane Lokalisierung und Kartierung spurgeführter Systeme“, Dissertation, Karlsruher Institut für Technologie, 2011.
- [197] H. Noda und E. Kawaguchi, „Adaptive speaker identification using sequential probability ratio test“, in *International Conference on Pattern Recognition*, IEEE, Bd. 3, 2000, S. 262–265.



- [198] J. Matas und O. Chum, „Randomized RANSAC with sequential probability ratio test“, in *International Conference on Computer Vision (ICCV)*, IEEE, Bd. 2, 2005, S. 1727–1732.
- [199] X. R. Li und L. Wang, „Fault detection using sequential probability ratio test“, in *Power Engineering Society Winter Meeting*, IEEE, Bd. 2, 1999, S. 938–943.
- [200] S. Cheng und M. Pecht, „Using cross-validation for model parameter selection of sequential probability ratio test“, *Expert Systems with Applications*, Jg. 39, Nr. 9, S. 8467–8473, 2012.
- [201] C. Lundquist, „Sensor fusion for automotive applications“, Dissertation, Linköping University, 2011.
- [202] F. Liu, „Objektverfolgung durch Fusion von Radar- und Monokameradaten auf Merkmalsebene für zukünftige Fahrerassistenzsysteme“, Dissertation, Karlsruher Institut für Technologie, 2010.
- [203] K. Pauwels und D. Kragic, „Simtrack: A simulation-based framework for scalable real-time object pose detection and tracking“, in *International Conference on Intelligent Robots and Systems (IROS)*, IEEE, 2015, S. 1300–1307.
- [204] D. Ratasich, B. Fromel, O. Hoftberger und R. Grosu, „Generic sensor fusion package for ROS“, in *International Conference on Intelligent Robots and Systems (IROS)*, IEEE, 2015, S. 286–291.
- [205] Robot Operating System (ROS) Foundation, „ROS Homepage“, 2014. [Online]. Adresse: [www.ros.org](http://www.ros.org) (aufgerufen am 19. 04. 2016).
- [206] M. Quigley, K. Conley, B. Gerkey, J. Faust, T. Foote, J. Leibs, R. Wheeler und A. Y. Ng, „ROS: An Open-Source Robot Operating System“, in *International Conference on Robotics and Automation (ICRA)*, IEEE, Bd. 3, 2009, S. 5.
- [207] Robot Operating System (ROS) Foundation, „ROS Documentation - Introduction“, 2014. [Online]. Adresse: [www.ros.org](http://www.ros.org) (aufgerufen am 19. 04. 2016).
- [208] H. Deusch, J. Wiest, S. Reuter, D. Nuss, M. Fritzsche und K. Dietmayer, „Multi-sensor self-localization based on maximally stable extremal regions“, in *Intelligent Vehicles Symposium (IV)*, IEEE, 2014, S. 555–560.
- [209] AUDI AG, „Audi Piloted Driving“, 2015. [Online]. Adresse: [blog.audi.de/tag/piloted-driving/](http://blog.audi.de/tag/piloted-driving/) (aufgerufen am 10. 02. 2016).
- [210] R. Godding, „Geometrische Kalibrierung und Orientierung digitaler Bildaufnahme-systeme“, 2002. [Online]. Adresse: [www.aicon.de](http://www.aicon.de) (aufgerufen am 10. 02. 2016).

- [211] A. B. Hillel, R. Lerner, D. Levi und G. Raz, „Recent progress in road and lane detection: A survey“, *Machine Vision and Applications*, Jg. 25, Nr. 3, S. 727–745, 2014.
- [212] Ibeo Automotive Systems GmbH, „Ibeo Scala B2 Spezifikation“, 2015. [Online]. Adresse: [www.autonomoustuff.com/ibeo-scala](http://www.autonomoustuff.com/ibeo-scala) (aufgerufen am 07.08.2016).
- [213] —, „Ibeo.ADAS“, 2015. [Online]. Adresse: [www.ibeo-as.com/ibeoadas](http://www.ibeo-as.com/ibeoadas) (aufgerufen am 07.08.2016).
- [214] J. Zeisler und H. Maas, „Analysis of the Performance of a Laser Scanner for Predictive Automotive Applications“, *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, Jg. 1, S. 49–56, 2015.
- [215] H. J. Eichler und J. Eichler, *Laser: Bauformen, Strahlführung, Anwendungen*. Springer-Verlag, 2015.
- [216] G. Heritage und A. Large, *Laser Scanning for the Environmental Sciences*. John Wiley & Sons, 2009.
- [217] C. Lipski, B. Scholz, K. Berger, C. Linz, T. Stich und M. Magnor, „A fast and robust approach to lane marking detection and lane tracking“, in *Southwest Symposium on Image Analysis and Interpretation (SSIAI)*, IEEE, 2008, S. 57–60.
- [218] K. Dietmayer, N. Kaempchen, K. Fuerstenberg, J. Kibbel, W. Justus und R. Schulz, „Roadway detection and lane detection using multilayer laserscanner“, in *Advanced Microsystems for Automotive Applications*, Springer, 2005, S. 197–213.
- [219] A. Hata und D. Wolf, „Road marking detection using LIDAR reflective intensity data and its application to vehicle localization“, in *International Conference on Intelligent Transportation Systems (ITSC)*, IEEE, 2014, S. 584–589.
- [220] H. Guan, J. Li, Y. Yu, M. Chapman und C. Wang, „Automated Road Information Extraction From Mobile Laser Scanning Data“, *IEEE Transactions on Intelligent Transportation Systems*, Jg. 16, Nr. 1, S. 194–205, 2015.
- [221] S. Kammel und B. Pitzer, „Lidar-based lane marker detection and mapping“, in *Intelligent Vehicles Symposium (IV)*, IEEE, 2008, S. 1137–1142.
- [222] T. T. Nguyen, J. Spehr, T.-H. H. Lin und D. Lipinski, „Fused Raised Pavement Marker Detection Using 2D-Lidar and Mono Camera“, in *International Conference on Intelligent Transportation Systems (ITSC)*, IEEE, 2015, S. 2346–2351.
- [223] K. Peason, „On lines and planes of closest fit to systems of point in space“, *Philosophical Magazine*, Jg. 2, S. 559–572, 1901.

- [224] T. Hastie, R. Tibshirani und J. Friedman, *The elements of statistical learning: data mining, inference, and prediction*. Springer, 2011.
- [225] R. M. C. de Souza, F. d. A. de Carvalho, C. P. Tenório und Y. Lechevallier, „Dynamic cluster methods for interval data based on Mahalanobis distances“, in *Classification, Clustering, and Data Mining Applications*, Springer, 2004, S. 351–360.
- [226] A. K. Jain, M. N. Murty und P. J. Flynn, „Data Clustering: A Review“, *ACM Computing Surveys (CSUR)*, Jg. 31, Nr. 3, S. 264–323, 1999.
- [227] D. L. Davies und D. W. Bouldin, „A cluster separation measure“, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Nr. 2, S. 224–227, 1979.
- [228] D. John, „DSGS-Jahrbuch Fahrbahnmarkierung 2004/2005“, *Die Deutsche Studiengesellschaft für Straßenmarkierungen e.V. (DSGS)*, 2005.
- [229] C. Brenner, „Extraction of features from mobile laser scanning data for future driver assistance systems“, in *Advances in GIScience*, Springer, 2009, S. 25–42.
- [230] M. Felisa und P. Zani, „Robust monocular lane detection in urban environments“, in *Intelligent Vehicles Symposium (IV)*, IEEE, 2010, S. 591–596.
- [231] J. Spehr, „On hierarchical models for visual recognition and learning of objects, scenes, and activities“, Dissertation, Universität Braunschweig, 2013.
- [232] D. Töpfer, J. Spehr, J. Effertz und C. Stiller, „Efficient Road Scene Understanding for Intelligent Vehicles Using Compositional Hierarchical Models“, *IEEE Transactions on Intelligent Transportation Systems*, Jg. 16, Nr. 1, S. 441–451, 2015.
- [233] D. Töpfer, „On Compositional Hierarchical Models for holistic Lane and Road Perception in Intelligent Vehicles“, Dissertation, Karlsruher Institut für Technologie, 2014.
- [234] Z. Kim, „Robust lane detection and tracking in challenging scenarios“, *IEEE Transactions on Intelligent Transportation Systems*, Jg. 9, Nr. 1, S. 16–26, 2008.
- [235] G. Stein, O. Mano und A. Shashua, „Vision-based ACC with a single camera: bounds on range and range rate accuracy“, in *Intelligent Vehicles Symposium (IV)*, IEEE, 2003, S. 120–125.
- [236] I. Gat, M. Benady und A. Shashua, „A monocular vision advance warning system for the automotive aftermarket“, SAE International World Congress & Exhibition, Tech. Rep. 2005.
- [237] D. Scaramuzza, „Omnidirectional vision: From calibration to Robot motion estimation“, Dissertation, Eidgenössische Technische Hochschule Zürich, 2008.

- [238] W. Niemeier, *Ausgleichsrechnung*. de Gruyter, 2001.
- [239] S. Tomforde, M. Steffen, J. Hähner und C. Müller-Schloer, „Towards an organic network control system“, in *International Conference on Autonomic and Trusted Computing*, Springer, 2009, S. 2–16.
- [240] M. Stess, C. Schildwächter, V. Mersheeva, F. Ortmeier und B. Wagner, „Multi-sensor tracking with SPRT in an autonomous vehicle“, in *Intelligent Vehicles Symposium (IV)*, IEEE, 2016, S. 252–257.
- [241] D. H. Douglas und T. K. Peucker, „Algorithms for the reduction of the number of points required to represent a digitized line or its caricature“, *Cartographica: The International Journal for Geographic Information and Geovisualization*, Jg. 10, Nr. 2, S. 112–122, 1973.
- [242] R. Lake, „GML 2.0—Enabling the Geo-spatial Web“, *Geospatial Solutions*, Jg. 11, Nr. 7, S. 38–41, 2001.
- [243] A. K. Dwivedi, S. N. Dwivedi, S. Deo, R. Shukla und E. Kopras, „Statistical models for predicting number of involved nodes in breast cancer patients“, *Health*, Jg. 2, Nr. 7, S. 641–651, 2010.
- [244] P. C. Mahalanobis, „On the generalized distance in statistics“, *Proceedings of the National Institute of Sciences*, Jg. 2, S. 45–55, 1936.
- [245] —, „On Large-Scale Sample Surveys“, *Philosophical Transactions of the Royal Society: Biological Sciences*, Jg. 231, Nr. 584, S. 329–451, 1944.
- [246] —, „A Method of Fractile Graphical Analysis“, *Econometrica: Journal of the Econometric Society*, Jg. 28, Nr. 2, S. 325–351, 1960.
- [247] V. D. Nguyen und T. Claussen, „Reducing Computational Complexity of Gating Procedures Using Sorting Algorithms“, in *International Conference on Information Fusion*, IEEE, 2013, S. 1707–1713.
- [248] R. Altendorfer und S. Wirkert, „Why the association log-likelihood distance should be used for measurement-to-track association“, in *Intelligent Vehicles Symposium (IV)*, IEEE, 2016, S. 258–265.
- [249] B. Braden, „The surveyor’s area formula“, *The College Mathematics Journal*, Jg. 17, Nr. 4, S. 326–337, 1986.
- [250] C. Bishop und N. Nasrabadi, *Pattern Recognition and Machine Learning*. Springer, 2006.
- [251] J. H. Halton, „Algorithm 247: Radical-inverse quasi-random point sequence“, *Communications of the ACM*, Jg. 7, Nr. 12, S. 701–702, 1964.

- [252] H. Niederreiter, „Quasi-Monte Carlo methods and pseudo-random numbers“, *Bulletin of the American Mathematical Society*, Jg. 84, Nr. 6, S. 957–1041, 1978.
- [253] D. Fox, „KLD-sampling: Adaptive particle filters“, in *Advances in Neural Information Processing Systems (NIPS)*, MIT Press, 2001, S. 713–720.
- [254] —, „Adapting the Sample Size in Particle Filters Through KLD-Sampling“, *The International Journal of Robotics Research*, Jg. 22, Nr. 12, S. 985–1003, 2003.
- [255] R. Baeza-Yates, B. Ribeiro-Neto *et al.*, *Modern Information Retrieval*. ACM Press, 1999.
- [256] Aerowest GmbH, „Aerowest Homepage“, 2014. [Online]. Adresse: [www.aerowest.de](http://www.aerowest.de) (aufgerufen am 22. 04. 2016).
- [257] Microsoft Corporation, „Bing Maps“, 2015. [Online]. Adresse: [www.bing.com/maps](http://www.bing.com/maps) (aufgerufen am 22. 04. 2016).
- [258] D. Schmidt und H. Winner, „Kombination von Fahrdynamiksenor- und globalen Navigations satellitensystemdaten zur Performanceverbesserung von Fahrerassistenzsystemen“, in *Symposium Positionierung und Navigation*, DGON, 2007, S. 1–18.
- [259] Forschungsgesellschaft für Strassen und Verkehrswesen, „Richtlinien für die Anlage von Strassen (RAS), Teil Querschnitte (RAS-Q 96)“, 1996. [Online]. Adresse: [www.fgsv.de](http://www.fgsv.de) (aufgerufen am 10. 02. 2016).
- [260] M. Mages, H. Winner und M. Hopstock, „Aktive Sicherheit durch Kreuzungsassistentz Erkennung von Gefahrensituationen, Auswahl von Warnstrategien und Ableitung von Sensoranforderungen“, *VDI-Berichte*, 2007.
- [261] H. Schmid und A. Huber, „Measuring a Small Number of Samples, and the 3v Fallacy: Shedding Light on Confidence and Error Intervals“, *IEEE Solid-State Circuits Magazine*, Jg. 6, Nr. 2, S. 52–58, 2014.
- [262] D. E. Knuth, *Art of Computer Programming, Volume 1-4*. Addison-Wesley Professional, 2013.
- [263] A. Hornung, K. M. Wurm, M. Bennewitz, C. Stachniss und W. Burgard, „OctoMap: An efficient probabilistic 3D mapping framework based on octrees“, *Autonomous Robots*, Jg. 34, Nr. 3, S. 189–206, 2013.
- [264] P. Mühlfellner, „Lifelong Visual Localization for Automated Vehicles“, Dissertation, Halmstad University, 2015.
- [265] M. Roser und F. Moosmann, „Classification of weather situations on single color images“, in *Intelligent Vehicles Symposium (IV)*, IEEE, 2008, S. 798–803.

- [266] H. Kurihata, T. Takahashi, I. Ide, Y. Mekada, H. Murase, Y. Tamatsu und T. Miyahara, „Rainy weather recognition from in-vehicle camera images for driver assistance“, in *Intelligent Vehicles Symposium (IV)*, IEEE, 2005, S. 205–210.
- [267] D. Fitzner, M. Sester, U. Haberlandt und E. Rabiei, „Rainfall Estimation with a Geosensor Network of Cars - Theoretical Considerations and First Results“, *Photogrammetrie, Fernerkundung, Geoinformation*, Jg. 2013, Nr. 2, S. 93–103, 2013.
- [268] M. Roser, „Modellbasierte und positionsgenaue Erkennung von Regentropfen in Bildfolgen zur Verbesserung von videobasierten Fahrerassistenzfunktionen“, Dissertation, Karlsruher Institut für Technologie, 2012.
- [269] S. Hasirlioglu, I. Doric, C. Lauerer und T. Brandmeier, „Modeling and simulation of rain for the test of automotive sensor systems“, in *Intelligent Vehicles Symposium (IV)*, IEEE, 2016, S. 286–291.
- [270] M. Stess, M. Schlichte und B. Wagner, „Camera-Based Field of View Parameter Optimization“, *International Journal of Mechanical Engineering and Robotics Research*, Jg. 4, Nr. 4, S. 293–298, 2015.
- [271] R. Kümmerle, G. Grisetti, H. Strasdat, K. Konolige und W. Burgard, „g2o: A general framework for graph optimization“, in *International Conference on Robotics and Automation (ICRA)*, IEEE, 2011, S. 3607–3613.
- [272] K. M. Wurm, C. Stachniss und G. Grisetti, „Bridging the gap between feature- and grid-based SLAM“, *Robotics and Autonomous Systems*, Jg. 58, Nr. 2, S. 140–148, 2010.
- [273] Applanix, „Applanix POS LV Specifications“, 2015. [Online]. Adresse: [www.applanix.com/products/poslv.htm](http://www.applanix.com/products/poslv.htm) (aufgerufen am 10.02.2016).
- [274] —, „Applanix Homepage“, 2016. [Online]. Adresse: [www.applanix.com](http://www.applanix.com) (aufgerufen am 10.02.2016).
- [275] NOVATEL Inc., „NOVATEL Specifications FlexPak-G2 OEMStar“, 2015. [Online]. Adresse: [www.novatel.com/products/gnss-receivers/enclosures/flexpak-g2-with-oemstar](http://www.novatel.com/products/gnss-receivers/enclosures/flexpak-g2-with-oemstar) (aufgerufen am 10.07.2016).
- [276] M. Schlichte, „Untersuchung einer landmarkenbasierten Ortungsfusion von Kraftfahrzeugen unter Witterungseinflüssen“, Masterarbeit, Humboldt-Universität zu Berlin, 2014, S. 103.

# Disclaimer

Die Ergebnisse, Meinungen und Schlüsse dieser Dissertation sind nicht notwendigerweise die der Volkswagen AG.

The results, opinions and conclusions expressed in this thesis are not necessarily those of Volkswagen AG.





# Danksagung

Die vorliegende Arbeit entstand während meiner Tätigkeit als Forschungsmitarbeiter bei der Volkswagen AG in den Jahren 2013 bis 2016 und der wissenschaftlichen Betreuung durch das Fachgebiet Echtzeitsysteme des Instituts für Systems Engineering an der Leibniz Universität Hannover unter der Leitung von Herrn Prof. Dr.-Ing. Bernardo Wagner.

Mein ganz besonderer Dank gilt daher Herrn Prof. Dr.-Ing. Bernardo Wagner, der mir diese externe Promotion ermöglichte und mich über die gesamte Zeit engagiert betreut hat. Sein motivierendes Interesse für das Thema, seine Ratschläge und Anregungen haben maßgeblich zum erfolgreichen Gelingen der Arbeit beigetragen. Mit seinen Kritikpunkten konnte meine Arbeit stets um neue Facetten erweitert werden und ermöglichte mir neue Blickrichtungen.

Ein Dank gilt ebenso Herrn Prof. Dr.-Ing. Christian Müller-Schloer für die Übernahme des Koreferates.

Meinen ehemaligen Kollegen bei Volkswagen danke ich sehr herzlich für das angenehme Arbeitsklima. Für die zahlreichen konstruktiven fachlichen Diskussionen und die stetige Hilfsbereitschaft möchte ich einen besonderen Dank an Herrn Dr.-Ing. Björn Mennenga, Herrn Dr.-Ing. Thorsten Hehn und Herrn Christian Merfels aussprechen. Dieser Dank gebührt vor allem auch Herrn Dr.-Ing. Moritz Schack, der mich während der gesamten Zeit unterstützt hat.

Ich danke auch den drei Studierenden, die ihre Diplom-, Bachelor- und Studienarbeit unter meiner Betreuung geschrieben haben und auf diese Weise zu meiner Arbeit beitragen. Insbesondere möchte ich mich bei Herrn Michael Schlichte für die wertvollen Latex-Tipps bedanken.

Bei den wissenschaftlichen Mitarbeitern des Fachgebietes Echtzeitsysteme möchte ich mich für die wertvollen und motivierenden Diskussionen rund um das Thema Robotik bedanken. Trotz meiner seltenen Anwesenheit am Institut waren die Kollegen stets hilfs- und diskussionsbereit. Herrn Dr.-Ing. Marco Langerwisch danke ich für die kritische Durchsicht meines Manuskriptes.

Schließlich gehört mein größter Dank meiner Familie und meiner Freundin Laura Rieche, die mich während dieser anstrengenden Zeit ständig aufgebaut und unterstützt haben. Ohne den zugesprochenen Mut, ihr Verständnis und ihre tatkräftige Unterstützung wäre diese Arbeit niemals möglich gewesen.

Hannover, im August 2017



# Liste der Veröffentlichungen

## Autor

M. Stess, M. Schlichte und B. Wagner, „Camera-Based Field of View Parameter Optimization“, in *4th International Journal of Mechanical Engineering and Robotics Research (IJMERR)*, Bd. 4, Nr. 4, S. 293, 2015.

M. Stess, M. Schlichte und B. Wagner, „Camera-Based Field of View Parameter Optimization“, in *2nd International Conference on Robotics and Mechatronics (ICROM)*, Juli 20-21, Madrid, Spanien, 2015. **Excellent Oral Presentation Award**

M. Stess, C. Schildwächter, V. Mersheeva, F. Ortmeier und B. Wagner, „Multi-sensor tracking with SPRT in an autonomous vehicle“, in *IEEE Intelligent Vehicles Symposium (IV)*, S. 252 - 257, Juli 19 - 22, Götheburg, Schweden, 2016.

## Patente im Rahmen der wissenschaftlichen Tätigkeit

M. Stess, „Verfahren und System zum Erfassen eines Verkehrsumfeldes einer mobilen Einheit“, in *Deutsches Patent- und Markenamt*, Nr. DE102016214030.2, 2016.

M. Stess, „Verfahren und System zum Erfassen von Landmarken in einem Verkehrsumfeld einer mobilen Einheit“, in *Deutsches Patent- und Markenamt*, Nr. DE102016214027.2, 2016.

M. Stess, „Verfahren und Vorrichtung zur Erzeugung einer Umfeldkarte sowie zur Lokalisierung eines Fahrzeugs“, *Deutsches Patent- und Markenamt*, Nr. DE102016212774.8, 2016.

M. Stess, „Verfahren und Vorrichtung zum Vergleichen zweier Karten mit darin hinterlegten Landmarken“, in *Deutsches Patent- und Markenamt*, Nr. DE102016207089.4, 2016.

M. Stess und C. Merfels, „Verfahren und System zum Erfassen eines Verkehrsumfeldes einer mobilen Einheit“, in *Deutsches Patent- und Markenamt*, Nr. DE102016214470.7, 2016.

M. Stess und F. Richter, „Verfahren, Vorrichtungen und Computerprogramme zum Bestimmen eines Zustands zumindest eines Fahrbahnrandobjekts“, in *Deutsches Patent- und Markenamt*, Nr. DE102016211751.3, 2016.

M. Stess, C. Mefels, M. Schack und F. Meysel, „Verfahren und System zum Bestimmen einer Position einer mobilen Einheit“, in *Deutsches Patent- und Markenamt*, Nr. DE102016214028.0, 2016.

# Liste der betreuten Arbeiten

Michael Schlichte, „Untersuchung einer landmarkenbasierten Ortungsfusion von Kraftfahrzeugen unter Witterungseinflüssen“, Humboldt-Universität zu Berlin, Mathematisch-Naturwissenschaftliche Fakultät, Diplomarbeit, 2014.

Niklas Koch, „Landmarkendetektion auf der Basis von Laserscannerdaten“, Ostfalia Hochschule für angewandte Wissenschaften, Fakultät Fahrzeugtechnik, Studienarbeit, 2015.

Christian Schildwächter, „Implementierung und Auswertung einer Sensorfusion zur Erzeugung von Landmarkenkarten“, Otto-von-Guericke Universität, Fakultät für Informatik, Bachelorarbeit, 2015.



# Selbstständigkeitserklärung

Hiermit erkläre ich, dass ich die vorliegende Dissertation selbständig verfasst habe. Alle benötigten Hilfsmittel sind vollständig angegeben. Die Dissertation wurde nicht als Diplom-, Master- oder ähnliche Prüfungsarbeit verwendet und weder Dissertation oder Teile sind vorher veröffentlicht worden. Frühere Promotionsgesuche habe ich nicht eingereicht. Es wurden keine kommerziellen Promotionsberater in Anspruch genommen.

Hannover, 07. August 2017



.....

Marek Stess





# Über den Autor

Name: Marek Stess  
Geburtsdatum: 26. Juni 1985  
Geburtsort: Kattowitz (Oberschlesien, Polen)

## Ausbildung

2009 - 2012 Studium der Informatik  
an der Gottfried Wilhelm Leibniz Universität Hannover  
Abschluss Master of Science  
2005 - 2009 Studium der Informatik  
an der Gottfried Wilhelm Leibniz Universität Hannover  
Abschluss Bachelor of Science  
1991 - 2005 Allgemeine Schulausbildung  
Abitur am Technischem Gymnasium Sigmaringen

## Wissenschaftliche Arbeit

2013 - 2016 Mitarbeiter in der Forschung und Entwicklung  
bei der Volkswagen AG, Abteilung Fahrzeuginformationssysteme  
Bereich Ortung und Kommunikation

## Berufliche Tätigkeit

seit Mai 2016 Entwicklungsingenieur für Gewerbliche Mobile Online Dienste  
bei der Volkswagen AG

