

Hochgenaue und robuste odometriebasierte Lokalisierung in einem Parkvorgang

Zur Erlangung des akademischen Grades eines
Doktors der Ingenieurwissenschaften (Dr.-Ing.)

von der KIT-Fakultät für Maschinenbau des
Karlsruher Instituts für Technologie (KIT)

genehmigte
Dissertation
von

Alexander Brunker, M. Sc.

Tag der mündlichen Prüfung: 17. Mai 2024
Hauptreferent: Prof. Dr. rer. nat. Frank Gauterin
Korreferent: Prof. Dr.-Ing. J. Marius Zöllner

Kurzfassung

Im Rahmen der vorliegenden Arbeit wird ein neues, spezielles Fahrzeugbewegungsmodell entwickelt, das den Anforderungen zukünftiger Parkanwendungen gerecht wird. Es nutzt nur das aktuell in Serie verbaute Sensorset und benötigt keine nennenswerten zusätzlichen Rechenressourcen auf dem Steuergerät. Durch die Anwendung bewährter Methoden der Robotik zur Schätzung von Zuständen und Parametern sowie neu entwickelten Filtererweiterungsverfahren wird ein hohes Maß an Genauigkeit und Robustheit gewährleistet.

Der entwickelte adaptive Lokalisierungsfilter basiert auf einem Informationsfilter, der ein hohes Maß an Robustheit gegen systematische und unsystematische Fehler bietet. Die besondere Filterstruktur ermöglicht es, die vier kalibrierten Radgeschwindigkeiten, die korrigierten Schwimmwinkel und die kalibrierte Gierrate als redundante Bewegungsinformationen zu verwenden. Überdies werden Radschlupf und Rollrichtung geschätzt und sicher verarbeitet. Die Fahrzeugparameter und Sensorfehler werden auch unter schwierigen Bedingungen zuverlässig im Fahrzeugbetrieb kalibriert. Die Erreichung eines besonders hohen Maßes an Robustheit wird durch die Verwendung von fahrzustandsabhängigen Anpassungen speziell für das Parken in Verbindung mit der Optimierung der Filtereinstellungen mittels Monte-Carlo-Simulationen erzielt.

Die Ergebnisse anhand realer Parkszenarien zeigen, dass dieser selbstkalibrierende, adaptive und fahrzustandsabhängige Lokalisierungsfilter die Genauigkeit und Robustheit der odometriebasierten Lokalisierung für Parkanwendungen im Vergleich zu den konventionellen Fahrzeugbewegungsmodellen deutlich steigert und damit die Parkqualität signifikant erhöht.

Abstract

In the present work, a new dedicated vehicle motion model is developed to meet the requirements of future parking applications with the current sensor set installed in series production cars. A high degree of accuracy and robustness is ensured by applying proven methods from robotics for estimating states and parameters, as well as newly developed filter expansion techniques.

The developed adaptive localization filter is based on an information filter that provides a high degree of robustness against systematic and unsystematic errors. The filter structure allows the four calibrated wheel velocities, the corrected sideslip angles, and the calibrated yaw rate to be used as redundant motion information. Moreover, wheel slip and roll direction are estimated and safely processed. Vehicle parameters and sensor errors are reliably calibrated in vehicle operation even under difficult conditions. Achieving a particularly high level of robustness is achieved by using driving condition-dependent adjustments specifically for parking and the optimization of filter settings using Monte Carlo simulations.

Results based on real-world parking scenarios show that this self-calibrating, adaptive and driving condition-dependent localization filter significantly increases the accuracy and robustness of odometry-based localization for parking applications compared to classical vehicle motion models, thus significantly improving parking quality.

Danksagung

Ich fühle mich zutiefst geehrt, diese Arbeit während meiner Tätigkeit als Doktorand bei der Mercedes-Benz Group AG im Bereich Parksysteme sowie als Doktorand am Institut für Fahrzeugsystemtechnik des Karlsruher Institut für Technologie verfassen zu dürfen.

Mein besonderer Dank gilt meinem Doktorvater Prof. Dr. rer. nat. Frank Gauterin, dessen methodische Disziplin und professionelle Beratung mir entscheidend geholfen haben, auch komplexe Themen zu lösen. Auch Prof. Dr.-Ing. J. Marius Zöllner danke ich von ganzem Herzen für seine freundliche Übernahme des Korreferats und Prof. Dr.-Ing. Kai Furmans für seinen engagierten Vorsitz während der Prüfung.

Ich bin außerdem Dr.-Ing. Michael Frey für seine kompetente und großartige Unterstützung während der gesamten Promotion zu tiefstem Dank verpflichtet. Seine Fähigkeit, kritische Fragen zu stellen und gleichzeitig eine positive Atmosphäre zu schaffen, hat mich immer wieder motiviert, hart für den Erfolg zu kämpfen. Auch meinem Teamleiter Dipl.-Ing. Thomas Wohlgemuth möchte ich für sein Vertrauen in mich und sein ständiges Interesse an der Thematik meinen tiefsten Dank aussprechen.

Ich schätze auch meine ehemaligen Teamkollegen sehr für das wunderbare Arbeitsumfeld, das sie geschaffen haben. Die von mir betreuten Studenten, darunter Razvan-Marcel Mates, Alexander Zajonz, Marcel Pfeleiderer, Albin Remäng, Matthias Greiner, Fabian Stein, Sven Hänle, Jochen Spengler und Moritz Karl Paul, haben einen entscheidenden Beitrag zu dieser Arbeit geleistet und verdienen meinen aufrichtigen Dank für ihre hervorragende Zusammenarbeit.

Schließlich möchte ich mich bei meiner Familie und meinen Freunden bedanken. Besonders danken möchte ich Dr. rer. pol. Wolfgang Gerhard Köhler, Dr.-Ing. Tobias Schürmann und Patrick Harz für ihre unermüdliche Unterstützung, auch außerhalb der Arbeitszeit.

Ich bin zutiefst dankbar für die Unterstützung und die Beiträge aller, die

zu diesem Projekt beigetragen haben. Mein aufrichtiger Dank gilt jedem Einzelnen von Ihnen!

Karlsruhe, im Mai 2024

Alexander Brunker

Inhaltsverzeichnis

1	Einleitung	1
1.1	Die Rolle der Odometrie im Parksysteem	2
1.2	Stand des Wissens: Fahrzeuglokalisierung und Odometrie . .	4
1.3	Forschungsfrage und Zielsetzung	7
1.4	Forschungsansatz	7
1.5	Inhalt und Gliederung der Arbeit	8
2	Beschreibung des Versuchsfahrzeugs	13
2.1	Begriffsdefinitionen	13
2.2	Fahrzeugparameter	15
2.2.1	Abrollumfang	15
2.2.2	Radaufstandspunkt (RAP)	22
2.2.3	Spurweite	26
2.2.4	Geometrische Fahrachse	27
2.3	Fahrzeugsensorik	28
2.3.1	Raddrehzahlsensor	29
2.3.2	Achslenkwinkelsensor	32
2.3.3	Schwimmwinkelbestimmung	32
2.3.4	Radlenkwinkelbestimmung	40
2.3.5	Inertialsensorik	42
2.3.6	Global-Navigation-Satellite-System (GNSS)	45
2.4	Referenzmesssystem	46

3	Adaptiver Lokalisierungsfilter	53
3.1	Bewegungsmodell	53
3.2	Fahrzeugbewegungsmodelle	56
3.2.1	Kinematisches Zweispurmodell	57
3.2.2	Kinematisches Einspurmodell	60
3.2.3	Kinematisches Gierratenmodell	63
3.3	Aufbau des Lokalisierungsfilters	63
3.3.1	Filteralgorithmen	64
3.3.2	Modellierung	68
3.3.3	Filtereinstellungen	72
3.4	Adaptive Filtererweiterung	73
3.4.1	Bewegungszustandsabhängige Anpassung	75
3.4.2	Radschlupfabhängige Anpassung	78
3.4.3	Fahrzeugbewegungsmodellabhängige Anpassung	82
3.5	Validierung des Lokalisierungsfilters	83
3.5.1	Beurteilung des Rechenressourcenbedarfs	84
3.5.2	Vergleich der Filteralgorithmen	86
3.5.3	Beurteilung der Lokalisierungsleistung	87
3.5.4	Sensitivitätsanalyse zur Lokalisierungsleistung	92
3.5.5	Untersuchung der Streuung mit Statistikfahrten	97
4	Fahrzeugparameterschätzung	101
4.1	Stand des Wissens: Fahrzeugparameterschätzung	101
4.2	Konzept: Fahrzeugparameterschätzung	103
4.3	Adaptiver Achsparameterkalibrierfilter SA-AKPE	105
4.3.1	Achsparameterkalibrierfilter AKPE	105
4.3.2	Filtererweiterungen	110
4.4	Gierratenfehlerkalibrierfilter YRPE	122

5	Sichere Rollrichtungsschätzung	129
5.1	Rollrichtungsschätzung	129
5.1.1	Wheel-Counter-Pattern-Algorithm (WPA)	130
5.1.2	Kräftegleichgewicht-Rollrichtung	132
5.2	Dual-Lokalisierungsfilter-Erweiterung	135
6	Automatisierte Optimierung des Lokalisierungsfilters	145
6.1	Konzept: Verfahren zur automatisierten fahrzustandsabhän- gigen Optimierung	145
6.2	Automatisierte Fahrzustandsklassifikation	147
6.3	Automatisierte Optimierung der Filtereinstellung	156
6.3.1	Monte-Carlo-Simulation (MCS)	156
6.3.2	Optimierung	159
6.4	Ergebnis der automatisierten fahrzustandsabhängigen Opti- mierung	160
7	Zusammenfassung	169
7.1	Wissenschaftlicher Beitrag	172
7.2	Ausblick	173
A	Anhang	175
A.1	Graphical-User-Interface (GUI)	175
A.2	Filteralgorithmen	175
A.2.1	Extended-Kalman-Filter (EKF)	175
A.2.2	Unscented-Kalman-Filter (UKF)	176
A.2.3	Extended-Information-Filter (EIF)	178
A.2.4	Unscented-Information-Filter (UIF)	179
	Abkürzungs- und Symbolverzeichnis	183

Literaturverzeichnis	188
Eigene Veröffentlichungen	196
Eigene Offenlegungen	198
Betreute Abschlussarbeiten	202

1 Einleitung

Automatische Parksysteme sind gefragt und gehören zu den am weitesten verbreiteten Fahrerassistenzsystemen in Europa [1]. Die Akzeptanz dieser Systeme hat in den vergangenen Jahren zugenommen [2], da sie erhöhte Sicherheit, vereinfachte Bedienung und Automatisierung bieten. Allerdings gibt es immer noch Rückmeldungen, die Verbesserungen in der Parkqualität fordern [3–6]. Die Parkqualität ist ein Maß dafür, wie genau und reproduzierbar das Parkergebnis beim Ein- und Ausparken ist. Kunden erwarten, dass ein komplett ausgestattetes Neufahrzeug die gleiche Parkqualität bietet wie ein fünf Jahre altes Basisfahrzeug mit abgenutzten Reifen. Da die meisten Kunden die physikalischen Grenzen der Sensoren und Algorithmen nicht kennen, können sie nicht verstehen, warum das Fahrzeug manchmal schief auf dem Parkplatz steht. Wenn der Bordstein berührt und die Felge beschädigt wird, kann dies das Kundenerlebnis nachhaltig beeinträchtigen und das Vertrauen in das System und den Fahrzeughersteller beschädigen.

Die wichtigste Grundlage für eine gute Parkqualität ist das eingesetzte kinematische Fahrzeugbewegungsmodell, das speziell für die Anforderungen des Parkvorgangs ausgelegt sein muss. Herkömmliche Fahrzeugbewegungsmodelle stoßen aufgrund der niedrigen Geschwindigkeiten, großen Radlenkwinkel und Richtungsänderungen bei Parkmanövern an ihre Grenzen. Hinzu kommen neue Anforderungen, wie Fahrzeuge mit Hinterachslenkung und einer wachsenden Variantenvielfalt. Um die Systeme in Zukunft kostengünstiger und breiter anbieten zu können, dürfen keine zusätzlichen Kosten für Sensoren oder extra Hardware entstehen. Allerdings müssen mit den bisher verwendeten Fahrzeugbewegungsmodellen und deren Einstellungen große Toleranzen eingehalten werden, was zu großen Fehlern in der Lokalisierung führen kann.

Bei der Betrachtung der möglichen Toleranzen und Fehlerarten kann zwischen systematischen und unsystematischen Fehlern unterschieden werden. Systematische Fehler treten aufgrund einer festen Ursache im Messprozess auf und führen zu einer systematischen Abweichung von den wahren Werten. Unsystematische Fehler, auch zufällige Fehler genannt, entstehen durch

zufällige Abweichungen im Messprozess und führen zu einer Streuung der Messwerte. Es ist wichtig, sowohl systematische als auch unsystematische Fehler zu minimieren, um eine präzise und genaue Lokalisierung zu gewährleisten.

In dieser Arbeit werden Methoden der Robotik eingesetzt, um Zustände und Parameter zu schätzen und das Kundenerlebnis zukünftiger Parksyste­me zu verbessern. Durch die Entwicklung von Filtererweiterungstechniken wird ein spezielles Fahrzeugbewegungsmodell aufgebaut, das auf die besonderen Anforderungen von Parkanwendungen zugeschnitten ist und mit einem aktuellen Seriensensorset ein hohes Maß an Genauigkeit und Robustheit gewährleistet.

1.1 Die Rolle der Odometrie im Parksystem

Das Fahrzeugbewegungsmodell wird zur kontinuierlichen Bestimmung der Position des Fahrzeugs verwendet, wobei die Position in Bezug auf einen definierten Fixpunkt ermittelt wird. Die Koppelnavigation (engl. DEAD-RECKONING) ist ein Oberbegriff für die indirekte Bestimmung der Position eines sich bewegenden Objekts anhand der Richtung und Geschwindigkeit der Bewegung. Der Teilbereich der Odometrie verwendet Informationen aus dem Fahrwerk, der Lenkung und den Trägheitssensoren. Die Odometrie wird konventionellerweise für Parkanwendungen eingesetzt, da sie trotz ihrer Einfachheit und den Einschränkungen der Sensoren ausreichend gute Werte liefert. Um einen Überblick über den aktuellen Stand der Nutzung der Odometrie als Lokalisierungsmethode innerhalb des Parksystems zu geben, wird in Abbildung 1.1 der Trajektorienregelkreis veranschaulicht. Folgende Schritte werden während eines Parkvorgangs vereinfacht durchlaufen:

1. *Umwelterfassung*: Erfassung der Umgebung durch Nahumfeldsensoren (Ultraschall-, Kamera-, Lidarsensoren etc.) [7–9].
2. *Karte*: Klassifizierung verschiedener Objekte (Bordstein, Auto, Linie, Person etc.) [10, 11] und Extrahieren von Parklücken aus der Lage und Art der Objekte [12, 13].
3. *Trajektorienregler*: Berechnung der Soll-Trajektorie mit vereinfachten Fahrzeugbewegungsmodellen [14, 15]. Steuern der Soll-Trajektorie des Fahrzeugs über die Quer- und die Längsfahrschnittstelle.

4. *Odometrie*: Berechnung der Ist-Trajektorie des Fahrzeugs durch das Fahrzeugbewegungsmodell [16–20].
5. *Trajektorienregler*: Regeln der Soll-Trajektorie. Hat das Fahrzeug das Ende der Soll-Trajektorie erreicht und ist die Abweichung zur Ist-Zielposition zu groß, werden weitere Korrekturtrajektorien berechnet.

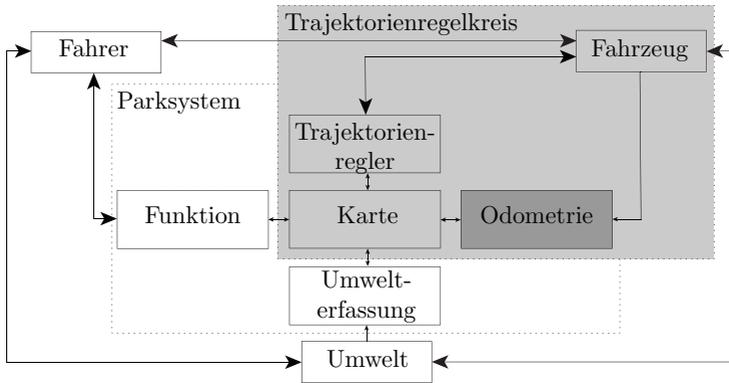


Abbildung 1.1: Einordnung des Odometrie-Moduls des Parksystems und des Trajektorienregelkreises in das Wirksystem Fahrer-Fahrzeug-Umwelt.

Im Trajektorienregelkreis wird die Positioniergenauigkeit des Fahrzeugs auf dem Parkplatz hauptsächlich durch die Genauigkeit der Umgebungserfassung und die Erfassung der tatsächlichen (Ist-)Trajektorie durch das Fahrzeugbewegungsmodell im Odometriemodul bestimmt. Eine Korrektur der odometrie-basierten Trajektorie durch die Umwelterfassung bei gleichzeitiger Korrektur der Karte durch das Fahrzeugbewegungsmodell wird als Simultaneous Localization and Mapping (SLAM)-Ansatz beschrieben und existiert bereits in diversen Forschungsarbeiten [21–23]. In Einsteiger-Parksystemen werden nur kostengünstige Ultraschallsensoren zur Erfassung der Umgebung eingesetzt. Da die Genauigkeit dieser Sensoren begrenzt ist und die entwickelten Methoden auch für Einsteiger-Parksysteme geeignet sein sollen, wurde der SLAM-Ansatz in dieser Arbeit nicht berücksichtigt.

1.2 Stand des Wissens: Fahrzeuglokalisierung und Odometrie

Es wurden bereits aus dem verfügbaren Sensorset verschiedene odometrie-basierte Fahrzeugbewegungsmodelle entwickelt. Das Sensorset setzt sich aus den Sensoren des Fahrwerks, der Lenkung und den Trägheitssensoren zusammen, die Teil des Elektronisches-Stabilitätsprogramm (ESP) sind und in jedem Fahrzeug verpflichtend vorhanden sind. Aufgrund ihres sicherheitsrelevanten Einsatzes funktionieren sie äußerst zuverlässig. Für die Modellierung der Fahrzeuge werden kinematische Ansätze verwendet, da das Steuergerät diese leichter und somit in Echtzeit verarbeiten kann. Dynamische Ansätze, die die Kräfte berücksichtigen, sind in der Regel nicht sinnvoll, da sie einen hohen Modellierungsaufwand erfordern und viele Annahmen beinhalten. Es wurden drei verschiedene kinematische Fahrzeugbewegungsmodelle für Parkanwendungen abgeleitet, die sich in ihrer Art der Bewegungserkennung unterscheiden:

- In Parksyste-men wird konventionell das aus der Robotik stammende *kinematische Zweispurmodell* (Odo2Track) verwendet [17], welches die Bewegung des Fahrzeugs anhand der Geschwindigkeiten der nicht gelenkten Hinterachse durch die Methode des Geschwindigkeits-Differentials berechnet. Dieses Modell liefert eine gute Beschreibung der Bewegung, wenn die Räder nicht durchdrehen und die Fahrzeugparameter präzise bekannt sind. Allerdings führt einzelner Radschlupf zu einer deutlichen Abweichung des Modells von der tatsächlichen Trajektorie [24]. Als Erweiterung wird in der Arbeit von Vietinghoff [25] ein *nichtlineare Zweispurmodell* beschrieben, welches alle vier Räder als unabhängige Eingänge verwendet. Aus diesem Modell kann in der vorliegenden Arbeit das *erweiterte kinematische Zweispurmodell* (OdoExt2Track) abgeleitet werden, welches als Eingangsparameter alle veränderlichen Radlenkwinkel verwendet. Im Vergleich zum Odo2Track können für die Radpaare sechs mögliche Geschwindigkeitsdifferentialiale gebildet werden.
- Das gebräuchlichste Fahrzeugbewegungsmodell ist das *lineare Einspurmodell* aus dem Bereich des ESP [26], welches die Bewegung des Fahrzeugs im Schwerpunkt durch kinematische und dynamische Größen beschreibt. Aus diesem Modell lässt sich für Parkanwendungen das *kinematische Einspurmodell* (Odo1Track) ableiten [17], das

für die translatorische Bewegung die Durchschnittsgeschwindigkeit der Hinterräder und für die Rotationsbewegung die Achslenkwinkel verwendet. Dieses Modell reagiert äußerst sensibel auf Fehler in den Radlenkwinkeln und funktioniert nicht für große Winkel und Rückwärtsfahrten, da Radstellungsfehler aufgrund von Ackermann-Fehlern [27] und rollrichtungsabhängig wirkenden Elastokinematiken auftreten [28]. In dieser Arbeit kann daher das *korrigierte kinematische Einspurmodell* (Odo1Track*) verwendet werden, das die korrigierten Schwimmwinkel verwendet. Die Schwimmwinkel ergeben sich aus den Achslenkwinkeln und den Achsschräglaufwinkeln. Sie sind nicht unmittelbar messbar, jedoch lassen sie sich indirekt mithilfe eines Referenzmesssystems bestimmen.

- Aus dem Bereich der Trägheitsnavigation kommt das *Inertialsensormodell*, das die translatorische Bewegung aus der doppelten Integration der Beschleunigung und die Rotation aus der einfachen Integration der Gierrate bestimmt. Für Parkanwendungen wird das *kinematische Gierratenmodell* (OdoYawRate) konstruiert [29, 30]. Dieses verwendet nicht die Werte des Beschleunigungssensors, sondern ebenfalls die Durchschnittsgeschwindigkeit der Hinterräder, da die Messwerte des Beschleunigungssensors bei niedrigen Geschwindigkeiten relativ große Fehler aufweisen, die durch die doppelte Integration nochmals verstärkt werden. Für die Rotationsbewegung wird die gemessene Gierrate verwendet, was einen großen Vorteil gegenüber den anderen Fahrzeugbewegungsmodellen darstellt, da diese eine unabhängige Rotationsmessung ist. Der Gierratensensor weist, ebenso wie die Beschleunigungssensoren, systematische Fehler auf, die durch eine Kalibrierung abgeschätzt werden können.

Um die Fahrzeugbewegungsmodelle weniger anfällig für systematische und unsystematische Fehler zu machen, wurden bereits verschiedene Fahrzeugbewegungsmodelle mithilfe von Bayes-Filtern fusioniert [18, 29, 31, 32]. Der Bayes-Filter fungiert als eine Art gewichteter Mittelwertschätzer, der das Gleichungssystem für die Multisensordatenfusion löst und Informationen der vorherigen Zustände berücksichtigt. Damit ist er weniger anfälliger gegenüber systematischen und unsystematischen Fehlern. Bisher gibt es noch keine Arbeit, die eine Fusion der für Parkanwendungen geeigneten Fahrzeugbewegungsmodelle untersucht, insbesondere die Fusion des in dieser Arbeit eingeführten *erweiterten kinematischen Zweispurmodells* und des

korrigierten kinematischen Einspurmodells. Ebenfalls gibt es bei den bisherigen Ansätzen keine aktive Adaption der Messeingänge, z. B. bei erkanntem Radschlupf. Bisher wurden schlupfende Räder im Kontext der Lokalisierung überhaupt nicht berücksichtigt, in ESP dient die Erkennung von schlupfenden Rädern hauptsächlich der Erkennung kritischer Fahrsituationen [33].

Seit April 2018 steht in jedem neuzugelassenen Fahrzeug in Europa aufgrund des gesetzlich verpflichtenden eCall-Systems ein GNSS zur Verfügung [34]. Aufgrund der eingeschränkten Verfügbarkeit z. B. in Parkhäusern und der niedrigen Positioniergenauigkeit ist es nicht möglich, das Fahrzeug während des Parkvorgangs allein mithilfe von GNSS zu lokalisieren [35]. Jedoch bietet ein GNSS aufgrund des geringen absoluten Fehlers bei längeren Kalibrierfahrten hohe Potenziale, da die absolute Position von GNSS zur Kalibrierung eines relativen Fahrzeugbewegungsmodells verwendet werden kann [36]. Die Genauigkeit des Einparkergebnisses hängt von der Kenntnis der genauen Fahrzeugparameter ab, z. B. kann der Abrollumfang beim Radwechsel stark variieren. Um den Einfluss dieser systematischen Fehler gezielt zu reduzieren, nutzt die Robotik schon seit längerem Ansätze zur Kalibrierung odometriebasierter Fahrzeugbewegungsmodelle [19, 37–39]. Der Abschnitt 4.1 befasst sich noch einmal tiefer mit dem aktuellen Stand des Wissens für die Fahrzeugparameterschätzung.

Kamerabasierte Lokalisierungsmethoden bieten eine vielversprechende Alternative zu odometriebasierten Fahrzeugbewegungsmodellen und haben ein breites Anwendungsspektrum im Bereich der Fahrzeugsicherheit. Die Bewegungserfassung in diesen Methoden wird meist durch fluss-basierte visuelle Odometrie [40] und objektbasierte Tracking-Verfahren [41, 42] durchgeführt. Diese Methoden finden vorwiegend Verwendung bei Fußgängerbrems- und Verkehrszeichenerkennungssystemen, bilden jedoch ein eigenständiges System und werden in dieser Arbeit nicht behandelt.

Ein weiteres Thema betrifft die Einstellung von Bayesschen Filtern, die in der Praxis oft auf empirische Weise erfolgt. Bayessche Filter fungieren als gewichtete Mittelwertschätzer, bei denen es wichtig ist, die Gewichte richtig einzustellen. Obwohl es Ansätze für eine automatische Anpassung der Filterparameter gibt, wie die von Akesson [43] und Rajamani [44] zeitgleich entwickelte Autocovariance-Least-Squares (ALS)-Technik, welche das Prozessrauschen aus dem Messrauschen durch Lösung eines Minimierungsproblems berechnet, sowie die Arbeit von Stellet [45], die ein Maximierungsproblem

nutzt, verwenden diese Methoden keine Referenzinformationen und sind nur nützlich, wenn wenige Informationen über das jeweilige System bekannt sind. Eine automatische Einstellung eines Bayes-Filters zur Lokalisierung in Parkanwendungen wurde bisher noch nicht untersucht.

Maschinennlernende Methoden zur Lokalisierung oder Adaption des Fahrzeugbewegungsmodelles wurden in dieser Arbeit nicht berücksichtigt, weil die Herausforderung bei der Integration in Serienfahrzeuge darin besteht, dass sie nicht ausreichend erprobt sind und hohen Sicherheits- und Zuverlässigkeitsstandards genügen müssen. Außerdem erfordern maschinelle Lernmethoden oft große Datenmengen und komplexe Algorithmen, was erhebliche Rechenressourcen erfordert. Allerdings könnten maschinelle Lernmethoden für die Fahrzustandsklassifikation geeignet sein.

1.3 Forschungsfrage und Zielsetzung

In Parksysteemen werden die konventionellen Fahrzeugbewegungsmodelle zur Lokalisierung genutzt. Allerdings nutzen sie das verfügbare Sensorset nicht vollständig aus und können aufgrund von unbekanntem Fahrzeugparametern und einer Vielzahl möglicher Fehlerquellen nur eingeschränkt hohe Parkqualität gewährleisten. Die Forschungsfrage lautet daher:

„Können bewährte Methoden aus der Robotik genutzt werden, um ein spezielles Fahrzeugbewegungsmodell für Parkanwendungen zu entwickeln, das eine deutliche Verbesserung der Parkqualität bietet, ohne dass zusätzliche Sensoren und erhöhte Rechenressourcen erforderlich sind?“

1.4 Forschungsansatz

Um eine präzise und robuste Lokalisierung bei Parkanwendungen zu gewährleisten, wird in dieser Arbeit ein spezielles Fahrzeugbewegungsmodell entwickelt, welches anhand eines adaptiven Lokalisierungsfilters mehrere erweiterte Fahrzeugbewegungsmodelle miteinander fusioniert. Um eine höhere Lokalisierungsleistung für Parkanwendungen zu erzielen, sollen neue Filtererweiterungen entwickelt werden. Das Konzept des Lokalisierungsfilters einschließlich der Filtererweiterungen ist in Abbildung 1.2 dargestellt. Zur Bewertung des Gesamtkonzepts wird der Lokalisierungsfilter in realen Testfahrten mit einem hochpräzisen Referenzmesssystem validiert. Die

Verbesserung der Parkqualität wird allein anhand der Lokalisierungsleistung beurteilt, da eine direkte Integration in ein Parksystem nicht möglich ist. Eine Sensitivitätsanalyse wird durchgeführt, um die Auswirkungen von Änderungen der systematischen und unsystematischen Fehler auf die Lokalisierungsleistung zu bewerten.

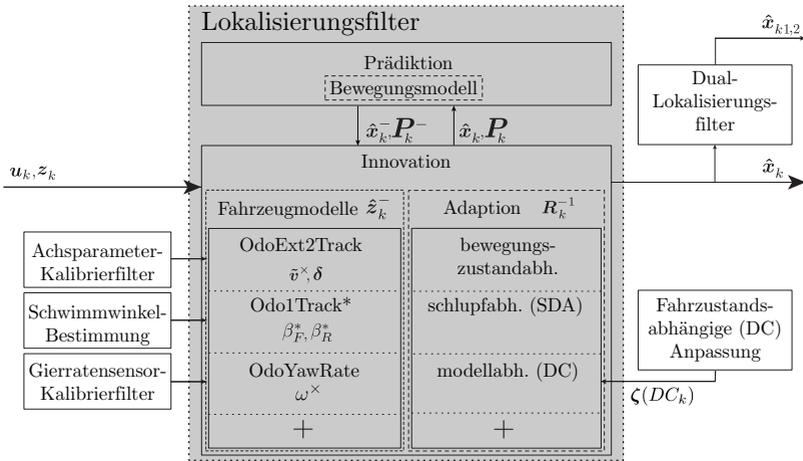


Abbildung 1.2: Konzept des speziellen Fahrzeugbewegungsmodells, bestehend aus dem adaptiven Lokalisierungsfilter und diversen Filtererweiterungen.

1.5 Inhalt und Gliederung der Arbeit

Das neu entwickelte Konzept zur odometriebasierten Lokalisierung mittels adaptiver Lokalisierungsfilter und Filtererweiterungen wurde modular mit der Software MATLAB/Simulink entwickelt. Zu diesem Zweck wurde ein Rahmenwerk aufgebaut, das alle Algorithmen des vollständig ausführbaren Odometriemoduls für ein Parksystem enthält und dank Integration und Graphical-User-Interface (GUI) (vgl. Anhang A.1) live im Fahrzeug ausführbar ist. Die GUI dient dazu, die Parameter der Algorithmen im Fahrzeug komfortabel zu ändern und eine Auswertung in Echtzeit vorzunehmen. Die neu entwickelten Algorithmen können somit direkt im Fahrzeug beurteilt werden. Die Auswertung und die Abbildungen in dieser Arbeit wurden

automatisiert durch entsprechende Auswertungsskripte erzeugt. Die Gliederung der Arbeit entspricht dem Aufbau des Rahmenwerks. Am Ende der thematischen Abschnitte werden die Ergebnisse in grauen Ergebnisboxen zusammengefasst.

Bei der Entwicklung der einzelnen Aufgabenpakete wurden zahlreiche Abschlussarbeiten von Studierenden einbezogen, deren Ergebnisse in enger Zusammenarbeit erarbeitet wurden. Die in dieser Arbeit vorgestellten Konzepte und Methoden wurden entsprechend weiterentwickelt und im Gesamtkontext des Rahmenwerks validiert. Im Folgenden wird kurz beschrieben, welche Vorarbeiten durchgeführt wurden, welche Methoden bereits veröffentlicht wurden und wo der Unterschied zu den in dieser Arbeit vorgestellten Methoden liegt.

Zunächst wird in Kapitel 2 das Versuchsfahrzeug detailliert beschrieben. Dabei werden sowohl die Fahrzeugparameter als auch die Sensormessungen genauer untersucht. Ein besonderer Fokus wird dabei auf die Auswirkungen verschiedener Fahrzeugvarianten auf die Fahrzeugparameter und deren Toleranzen gelegt. Zudem werden die Sensormessungen sorgfältig analysiert und die entscheidenden Sensormodelle für die Modellierung entwickelt. Im weiteren Verlauf wird das verwendete Referenzmesssystem eingehend erläutert, welches aus zwei Differential-Global-Navigation-Satellite-System (DGNSS)-Antennen und einer Inertial-Measurement-Unit (IMU) besteht. Gemeinsam liefern sie eine verlässliche Referenz für den Bewegungszustand bei Parkanwendungen.

In Kapitel 3 wird der Lokalisierungsfilter vorgestellt. Die Idee für einen solchen Lokalisierungsfilter zur hochgenauen und robusten Fahrzeugpositionsbestimmung für Parkanwendungen wurde bereits in den Offenlegungen [O1] und [O2] beschrieben. Um eine robuste und genaue Abschätzung der Fahrzeugposition zu ermöglichen, werden verschiedene Bayes-Filteralgorithmen für die Sensorfusion vorgestellt und verglichen. Eine erste Extended-Kalman-Filter (EKF)-Implementierung zur Multisensordatenfusion wurde während der Masterarbeit von Remäng [A1] ins Rahmenwerk implementiert, welche die vier Radgeschwindigkeiten aus dem *erweiterten kinematischen Zweispurmodell* OdoExt2Track und die Gierrate fusionierte. Aufbauend darauf hat Stein [A2] in seiner Masterarbeit einen Unscented-Kalman-Filter (UKF) ins Rahmenwerk implementiert, der DGNSS-korrigierte Schwimmwinkel verwendet und radschlupfbasiert eine Radgeschwindigkeit ausblenden kann.

In der Veröffentlichung [V1] wurde die Extended-Information-Filter (EIF)-Implementierung vorgestellt. In dieser Arbeit werden alle gängigen Implementierungen vorgestellt und bewertet, dies umfasst auch eine Unscented-Information-Filter (UIF)-Implementierung. Der in dieser Arbeit entwickelte Lokalisierungsfilter fusioniert die für Parkanwendungen abgeleiteten Modelle: das *erweiterte kinematische Zweispurmodell* OdoExt2Track, das *korrigierte kinematische Einspurmodell* Odo1Track* und das *kinematische Gierratensmodell* OdoYawRate. Weiterhin enthält er eine Adaptionsfiltererweiterung, die sicherstellt, dass der Lokalisationsfilter mittels Koeffizientenmatrix auf aktiv geschaltet werden kann. Dadurch kann er seine Parameter anpassen, indem er Bewegungszustände, Messunsicherheiten, z. B. Radschlupf, und Fahrzustände beobachtet. Der Lokalisierungsfilter ist so aufgebaut, dass die Eingabe nur während der Innovationsphase durch das entsprechende nicht-lineare Messmodell erfolgt, sodass die Anzahl der Messungen angepasst werden kann, ohne den Betrieb des Systemmodells zu beeinträchtigen. Daher ist es möglich, wie in der Offenlegung [O3] beschrieben, die Anzahl der Messungen zu erweitern, wenn sich das Sensorset und damit das Messmodell erweitern.

In Kapitel 4 werden die adaptiven Kalibrierfilter vorgestellt, mit denen die unbekannt Fahrzeugparameter im Fahrbetrieb geschätzt werden können. Die Abrollumfänge und Spurweite werden durch einen Axle-Kinematic-Parameter-Estimator (AKPE) geschätzt. In der Offenlegung [O4] wurden die Idee und in der Veröffentlichung [V2] die Umsetzung und Erweiterung des Konzepts des selbstadaptiven Hinterachsparmeterschätzers auf Basis eines EKF vorgestellt. Dieser verwendet als Systemmodell das *kinematische Zweispurmodell* Odo2Track und als Messmodell die GNSS-Messungen. Zusätzlich werden die Auswirkungen von dynamischen Signalverschiebungen durch einen Signal-Shift-Algorithm (SSA) sowie jene von adaptiven Modellfehlern und Messunterbrechungen durch Filtererweiterung minimiert. In dieser Arbeit wird eine verallgemeinerte Formulierung verwendet, die auch die Vorderachsparmeter schätzen kann und zusätzlich eine Geschwindigkeitsabhängigkeit des Abrollumfangs berücksichtigt. Anschließend wird der Yaw-Rate-Parameter-Estimator (YRPE) vorgestellt, der den Gierratensensor mithilfe des vorher kalibrierten *kinematischen Zweispurmodells* Odo2Track und eines einfachen Fehlermodells kalibriert.

Im Kapitel 5 wird erläutert, wie eine genaue und frühzeitige Schätzung der Rollrichtung des Fahrzeugs erreicht werden kann. Dazu werden neue Metho-

den zur frühen Rollrichtungsschätzung vorgestellt, deren Idee bereits in der Offenlegung [O5] und [O6] vorgestellt wurde. Um auch bei falscher Rollrichtungsschätzung einen robusten Lokalisierungsfilter zu erhalten, wurde in der Offenlegung [O7] das Konzept eines Dual-Lokalisierungsfilters vorgestellt. In der Veröffentlichung [V3] konnte dann das Potenzial des Konzepts gezeigt werden. Im Rahmen dieser Arbeit wird das Konzept mit dem adaptiven Lokalisierungsfilters demonstriert und bewertet.

In Kapitel 6 wird eine automatisierte Optimierung des Lokalisierungsfilters beschrieben, um die Robustheit zu steigern. Die Idee des Verfahrens wurde in der Offenlegung [O8] vorgestellt. Paul hat in seiner Masterarbeit [A3] die Fahrzustandsklassifizierung entwickelt und durch ein statistisches Fehlermodell optimiert. In [V4] wurde das Verfahren überarbeitet und um ein statistisches Koeffizientenmodell erweitert. In dieser Arbeit wird das Verfahren auf symmetrische Parkmanöver auf der linken und rechten Straßenseite angewendet und die Ergebnisse in erweiterter Form ausgewertet.

2 Beschreibung des Versuchsfahrzeugs

Um die Ausarbeitungen der entwickelten Methoden darstellen zu können, werden in diesem Kapitel zunächst die Begriffsdefinitionen erläutert. Weiterhin werden das Versuchsfahrzeug mit den entsprechenden Fahrzeugparametern und Sensormessungen beschrieben und die Einschränkungen ausgearbeitet. Schließlich wird das Referenzmesssystem erläutert.

2.1 Begriffsdefinitionen

Definition des Versuchsfahrzeugs

Als Versuchsfahrzeuge werden aktuelle Mittelklasse-Limousinen mit Heckantrieb (fortan abgekürzt als 4x2) und Allradantrieb (4x4) eines speziellen Typs bzw. einer Baureihe eingesetzt. Diese Fahrzeuge wurden ausgewählt, weil hier der Einsatz eines Parksystems den größten Nutzen bringt und es eine hohe Verbaurate gibt. Weiterhin ist die Auswahl an konfigurierbaren Ausstattungen und Rädern am größten. Bei den Versuchsfahrzeugen handelt es sich um handelsübliches Serienfahrzeuge mit zusätzlichem Messabgriff, um den Fahrzeugbus aufzuzeichnen. Weiterhin wurde ein hochgenaues Referenzmesssystem im Fahrzeug installiert (vgl. Abschnitt 2.4).

Für die in dieser Arbeit formulierten Zusammenhänge wird eine zeitdiskrete Beschreibung mit dem Index k gewählt. Für alle Räder des Versuchsfahrzeugs wird der Index $i \in \{FL, FR, RL, RR\}$ (engl. FRONT LEFT, FRONT RIGHT, REAR LEFT, REAR RIGHT) und für die jeweilige Achse der Index $j \in \{F, R\}$ (engl. FRONT, REAR) verwendet. Sensormessungen bzw. aus dem Sensormodell abgeleitete Größen werden mit \times und empirisch korrigierte Größen mit $*$ dargestellt. Der Index REF wird für die vom Referenzmesssystem ermittelten Referenzwerte verwendet.

Definition der Koordinatensysteme

Abbildung 2.1 zeigt schematisch das Versuchsfahrzeug mit den Fahrzeugparametern und Sensormessungen¹ im Referenzkoordinatensystem K^{REF} , im Fahrzeugkoordinatensystem K^{VEH} und im Radkoordinatensystem $K^{\text{WHL,FL}}$ des vorderen linken Rades².

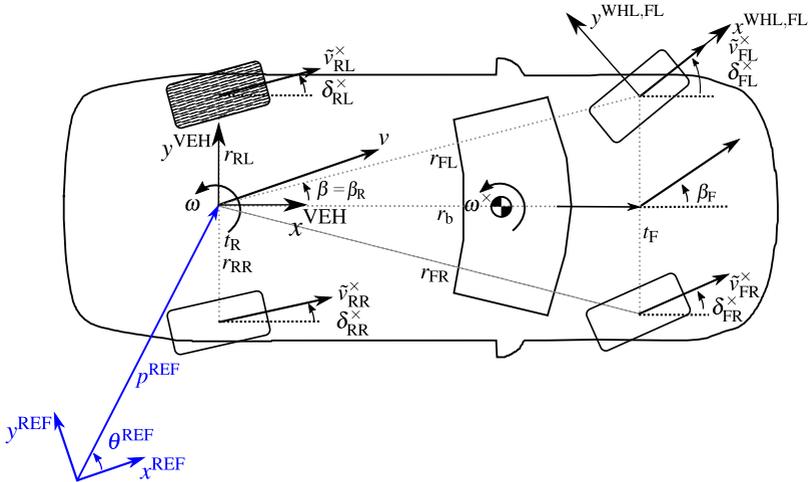


Abbildung 2.1: Übersicht der Fahrzeugparameter (siehe Tabelle 2.1), Sensormessungen (siehe Tabelle 2.3) und Koordinatensysteme.

Das Referenzkoordinatensystem K^{REF} wird in einem Fixpunkt zu Beginn der Messung definiert und beschreibt fortlaufend die Bewegung des Fahrzeugs im fahrzeugfesten Ursprung des Fahrzeugkoordinatensystems K^{VEH} .

Das Fahrzeugkoordinatensystem K^{VEH} befindet sich mittig auf der Hin-

¹ Alle Fahrzeugparametern und Sensormessungen werden zuerst positiv definiert und eingezeichnet.

² Um eine bessere Unterscheidung zwischen den Koordinatensystemen und den Variablen zu ermöglichen und um lange Bezeichnungen zu vermeiden, werden hochgestellte Indizes für die Koordinatensysteme und deren Ursprung und tiefgestellte Indizes für die Unterscheidung der Variablen selbst verwendet.

terachse in Achshöhe³. Das Koordinatensystem ist mit der x^{VEH} -Achse in Fahrzeugrichtung, mit der y^{VEH} -Achse in Fahrzeug-Linksrichtung und mit der z^{VEH} -Achse in Fahrzeug-Hochrichtung ausgerichtet.

Das Radkoordinatensystem K^{WHL} hat seinen Ursprung im Radaufstandspunkt (RAP) mit Ausrichtung der x^{WHL} -Achse in Radrollrichtung vorwärts und der y^{WHL} -Achse orthogonal zur Radhalbierenden.

2.2 Fahrzeugparameter

Für die Fahrzeugbewegungsmodelle sind eine Reihe von Fahrzeugparametern relevant, deren Toleranzen für die spätere Modellierung des Lokalisierungsfilters entscheidend sind. Tabelle 2.1 gibt einen Überblick über die Fahrzeugparameter, deren Erwartungswert μ und die Standardabweichung σ unter Annahme der Gaußschen-Normalverteilung (GNV). Die Werte wurden im Rahmen dieser Arbeit erarbeitet und werden in den folgenden Absätzen näher erläutert.

2.2.1 Abrollumfang

Der Abrollumfang eines Rades⁴ hängt von verschiedenen Einflüssen ab. Beim Parkvorgang entspricht der tatsächlich gemessene Abrollumfang⁵ c_i nicht dem vom Hersteller angegebenen dynamischen Abrollumfang c_D . Der Gesetzgeber erlaubt sogar eine Abweichung von $\pm 4\%$ ohne Tachooanpassung (vgl. §57 StVZO). Um ein besseres Verständnis der verschiedenen Faktoren, die den Abrollumfang beeinflussen, zu erhalten, werden diese im Folgenden näher erläutert.

³ Im Bereich der Konstruktion wird in der Regel der Punkt mittig der Vorderachse als Fahrzeugkoordinatenursprung gewählt, da die Position des Motors somit für verschiedene Fahrzeugbauformen fest definiert ist. Um die Trajektorie des Fahrzeugs zu erfassen, wird hingegen die Mitte der Hinterachse gewählt, da die Trajektorie für diesen Punkt am besten der Bogenform folgt. Das gilt insbesondere für Fahrzeuge ohne Hinterachslenkung, da der kürzeste Abstand zwischen der Fahrzeughalbierenden und dem Momentanpol der Fahrzeugbewegung auf Höhe der Hinterachse liegt.

⁴ Für die Kombination aus Rad und Reifen wird hier vereinfacht der Begriff "Rad" verwendet.

⁵ Der gemessene Abrollumfang wird mit der manuellen Methode zur Bestimmung des Abrollumfangs gemessen, wobei das Fahrzeug bei einer niedrigen Geschwindigkeit 10 Radumdrehungen geradeaus gefahren und die zurückgelegte Strecke gemessen wird.

Tabelle 2.1: Übersicht der relevanten Fahrzeugparameter.

Bezeichnung	Parameter	μ	σ	Einheit
Abrollumfang	c_i	2,080	-0,040	m
			+0,030	m
Radimpulse pro Umdrehung	w_{\max}	96	-	-
Maximaler Zählerwert	En_{\max}	255	-	-
Vordere Achsbreite (Flansch)	$b_{\text{Axle,F}}$	1,678	-	m
Hintere Achsbreite (Flansch)	$b_{\text{Axle,R}}$	1,684	-	m
Felgen-Einpresstiefe	ET_j	43	-10	mm
			+11	m
Radstand	r_b	2,939	-	m
Radaufstandpunkt in x^{VEH}	$r_{i,x}$	-	-	m
Radaufstandpunkt in y^{VEH}	$r_{i,y}$	-	-	m
Vordere Spurweite	t_F	1,589	-0	m
			+0,021	m
Hintere Spurweite	t_R	1,604	-0,020	m
			+0,016	m
Geo. Fahrachse	β_0	0	$\pm 0,05$	°

2.2.1.1 Einfluss der Raddimension

Tabelle 2.2 zeigt eine Übersicht über die relevanten Fahrzeugparameter der für das Versuchsfahrzeug angebotenen Räder.

Tabelle 2.2: Relevante Fahrzeugparameter verschiedener Raddimensionen W_{type} für eine Mittelklasse-Limousine.

W_{type}	Reifen	ET_j	t_F	t_R	c_D	c_i
in/in	mm/mm	mm	m	m	m	m
7Jx16	205/65	32	1,620	1,626	2,050	2,058
7,5Jx17	225/55	40	1,604	1,610	2,075	2,083
8Jx18	245/45	43	1,589	1,604	2,065	2,090
9Jx18	275/40	53	-	1,584	2,065	2,079
8Jx19	245/40	43	1,589	1,604	2,070	2,095
9Jx19	275/35	53	-	1,584	2,060	2,074
8Jx20	245/35	43	1,589	1,604	2,075	2,089
9Jx20	275/30	53	-	1,584	2,055	2,069

Der dynamische Abrollumfang c_D kann sich vom tatsächlich gemessenen Umfang c_i abhängig von der Raddimension um bis zu $\Delta c_{D,\max}(W_{\text{type}}) =$

25 mm unterscheiden. Für die Applikation des Fahrzeugbewegungsmodells⁶ wird daher in der Praxis ein entsprechender Erwartungswert ermittelt. Dabei werden sowohl die Verbaurate als auch das Toleranzband sorgfältig in Betracht gezogen und zur oberen Hälfte hin abgeschätzt. Dies minimiert das Risiko von Bordsteinkontakten der Felge, besonders in Längsparklücken, da das Fahrzeug, bei einem zu groß angenommenen Abrollumfang weniger weit in den Parkraum einfährt. Für den Abrollumfang des Versuchsfahrzeugs wird ein Erwartungswert von $c = 2,080$ m definiert.

2.2.1.2 Einfluss der Fertigungstoleranz

Die European Tyre and Rim Technical Organisation (ETRTO) definiert und normiert die Toleranzen für die Reifenhersteller [46]. Sie gibt den dynamischen Abrollumfang c_D für 60 km/h mit einer Toleranz von $-2,5\%$ bis $+1,5\%$ an, an denen sich die Reifenhersteller orientieren. Aufgrund der Fertigungstoleranz ergibt sich eine unsymmetrische Abrollumfangsänderung von $\Delta c_{D,\max}(\Delta r_{\text{tol}}) = -52$ bzw. $+31$ mm. Oft liegen die Entwicklungsreifen und die Reifen aus der ersten Charge im oberen Toleranzband. Im Laufe der Produktion werden die Reifen immer wirtschaftlicher ausgerüstet, sodass es nicht selten dazu kommt, dass der Austauschreifensatz einen kleineren Abrollumfang aufweist und im unteren Toleranzband liegt.

2.2.1.3 Einfluss des Profilverschleißes

Der dynamische Abrollumfang berechnet sich aus $c_D = 2\pi \cdot r_D$, wobei der dynamische Rollradius r_D laut Definition der ETRTO zu $2/3$ von dem unbelasteten Rollradius r_0 und zu $1/3$ von dem statischen Rollradius r_S abhängt:

$$r_D \approx \frac{2}{3} r_0 + \frac{1}{3} r_S. \quad (2.1)$$

Der Profilverschleiß wirkt sich in erster Linie auf den unbelasteten Rollradius r_0 aus, da sich die Lauffläche des Reifens abnutzt und damit der Abstand zwischen Radmitte und Radaußenkante abnimmt. Im Gegensatz dazu ändert sich der statische Rollradius r_S geringfügig, da die Reifenlatschverformung

⁶ Bei der Applikation des Fahrzeugbewegungsmodells werden die Grundparameter für den jeweiligen Typ, genauer gesagt die jeweilige Baureihe, ermittelt. Diese werden dann im Steuergerät gespeichert und für alle Fahrzeuge dieser Baureihe verwendet.

im belasteten Zustand dazu führt, dass der Teilumfang vor und nach dem Profilverschleiß im zusammengedrückten Reifen ähnlich bleibt. Der statische Rollradius r_S wird hauptsächlich von Faktoren wie der Fahrzeugbeladung und dem Reifenfülldruck beeinflusst. Für einen Verschleiß⁷ von $\Delta r_{ab} = 6$ mm ergibt sich somit eine Abrollumfangsänderung von $\Delta c_D, \max(\Delta r_{ab}) = 25$ mm:

$$\Delta c_D(\Delta r_{ab}) = 2\pi \cdot \frac{2}{3} \cdot \Delta r_{ab}. \quad (2.2)$$

2.2.1.4 Einfluss des Fülldrucks

Der Fülldruck des Reifens p verändert nur den statischen Rollradius r_S , daher ist der Einfluss auf den Abrollumfang deutlich geringer. Messungen im Rahmen dieser Arbeit zeigten eine Änderung des Rollumfangs von $\Delta c_D = 10$ mm bei $\Delta p = 1$ bar für die Rad-Reifen-Kombination 245/45 R18 (Sommer). Dazu wurde der Abrollumfang mit der manuellen Methode zur Abrollumfangsermittlung bei $p = 2$ bar und $p = 3$ bar gemessen, indem zwischen den Messungen der Fülldruck reduziert wurde.

2.2.1.5 Einfluss der Geschwindigkeit

Des Weiteren ist eine Geschwindigkeitsabhängigkeit des Abrollumfangs vorhanden. Abbildung 2.2 zeigt die mit einem Referenz-Abrollumfangsschätzer⁸ bestimmten Abrollumfänge c_i abhängig von der jeweiligen Geschwindigkeit. Obwohl physikalisch eine quadratische Abhängigkeit zu erwarten wäre, scheint im Rahmen der betrachteten Messmethode eine lineare Näherung ausreichend. Für die spätere Modellierung dieses geschwindigkeitsabhängigen Einflusses wird daher ein linearer Zusammenhang angenommen, bei dem die Geschwindigkeitsproportionalitätskonstante $\mu_v = 0,1$ mm/km/h verwendet wird:

$$\Delta c_D(v) = \mu_v \left[\frac{\text{mm}}{\text{km/h}} \right] \cdot v [\text{km/h}]. \quad (2.3)$$

⁷ Ein neuer Sommerreifen hat ca. 8–9 mm Profil und es wird empfohlen, dieses nur bis zu einer Profiltiefe von 3 mm abzufahren, wobei in Europa für Pkw-Sommerreifen eine gesetzliche Mindestprofiltiefe von 1,6 mm gilt.

⁸ Die Messungen wurden mit einem Referenz-Abrollumfangsschätzer durchgeführt, der dem in Kapitel 4 vorgestellten Axle-Kinematic-Parameter-Estimator (AKPE) gleicht. Dazu wurden hochgenaue DGNSS-Positionsmessung verwendet und verschiedene konstante Geschwindigkeiten gefahren.

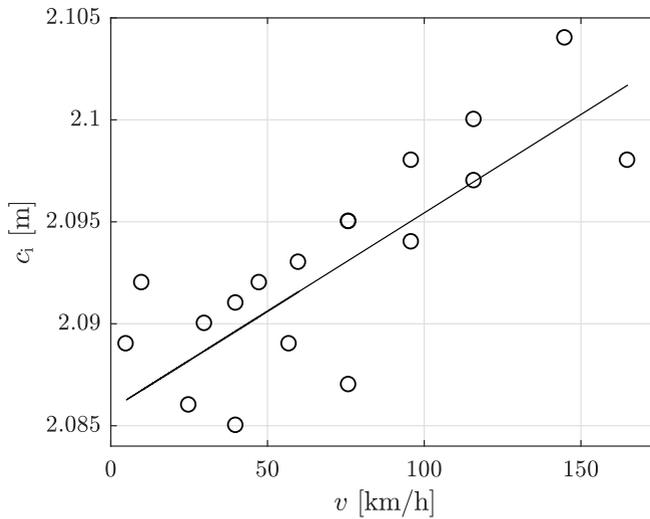


Abbildung 2.2: Geschwindigkeitsproportionalität bei der Abrollumfangbestimmung.

Es gibt auch einen Einfluss der Radlast in Verbindung mit der Geschwindigkeit, der aber in den Grenzen, in denen sich die Radlast aufgrund von Beladungsänderungen verändert, vergleichsweise gering sein dürfte. Aus diesem Grund wird dieser Einfluss hier nicht gesondert analysiert.

2.2.1.6 Gesamteinfluss

Ein Fehler im Abrollumfang führt zu einem systematischen Fehler in den Radgeschwindigkeitsmessungen (vgl. Gleichung (2.14)). In Abbildung 2.3 werden die theoretisch möglichen Schwankungsbereiche der Abrollumfänge dargestellt.

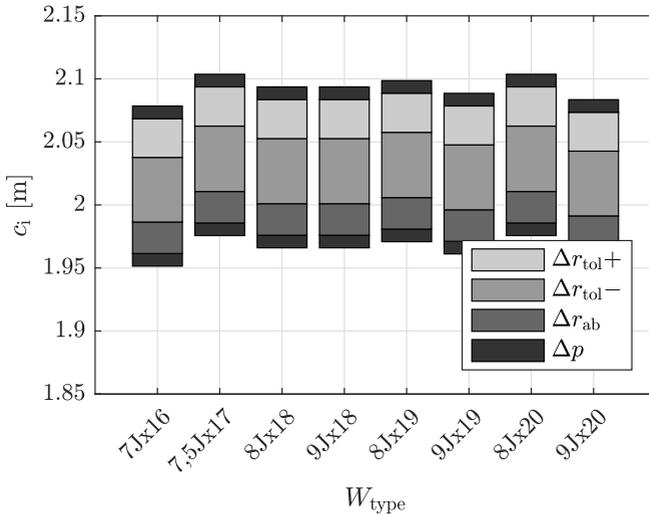


Abbildung 2.3: Bereiche der theoretisch möglichen Abrollumfänge ohne Geschwindigkeitseinfluss (-6 mm).

Es wird deutlich, dass die Reifendimension W_{type} einen relativ geringen Einfluss hat und sich der Abrollumfang c_i für jeden Radsatz aufgrund verschiedener Einflussgrößen unterscheiden kann. Ebenso variieren die Abmessungen von Sommer- und Winterreifen oft stark und der Radsatz kann am Fahrzeug saisonbedingt mindestens zweimal jährlich wechseln. Der Abrollumfang kann für einen neuen Radsatz unter Berücksichtigung aller Einflüsse theoretisch um $-11,9$ bis $+3,4$ cm vom Erwartungswert abweichen. In der Praxis werden für das Versuchsfahrzeug keine Abrollumfänge < 2 m erreicht, da sich die Faktoren gegenseitig beeinflussen. Es hat sich gezeigt, dass eine Standardverteilung des Abrollumfangsfehlers von $\Delta c_i = -4$ und $+3$ cm für das Versuchsfahrzeug realistisch ist. Dies entspricht einem Geschwindigkeitsfehler von $-1,9$ bis $+1,4$ % und ist daher laut Gesetzgeber zulässig. Bei einem

Einparkmanöver in eine Längsparklücke kann dadurch ein Positionsfehler in y^{REF} -Richtung von -10 bis $+7$ cm resultieren, weshalb Parksysteme in der Praxis so eingestellt werden, dass ein Sicherheitsabstand von ± 15 cm zum Bordsteinabstand toleriert wird. Mit einem kalibrierten Abrollumfang kann eine deutliche Verringerung der Toleranz des Bordsteinabstandes verwirklicht werden. In dieser Arbeit wird daher der Abrollumfang der einzelnen Räder $\Delta c_i(W_{\text{type}}, \Delta r_{\text{tol}}, \Delta r_{\text{ab}}, \Delta p)$ gemäß dem folgenden Fehlermodell angenommen und in Absatz 4.3.1 durch den *Achsparemeterkalibrierfilter* AKPE berechnet:

$$c_i := c_{\text{default}} + \mu_v \cdot v + \Delta c_i(W_{\text{type}}, \Delta r_{\text{tol}}, \Delta r_{\text{ab}}, \Delta p). \quad (2.4)$$

Die Reifendruckmessung durch aktive Reifendruckkontrollsysteme wird aufgrund hoher Ungenauigkeiten von $\sigma = \pm 0,1$ bar, ungenauer Beladungsmessungen im Fahrzeug und dem niedrigen Einfluss des statischen Rollradius r_s auf den Abrollumfang, nicht berücksichtigt.

Ergebnisse hinsichtlich der Untersuchung des **Abrollumfangs**:

- Die ETRTO definiert den dynamischen Abrollumfang c_D für 60 km/h mit einer Toleranz von $-2,5$ % bis $+1,5$ %. Laut dem Gesetzgeber kann der Abrollumfang sogar um ± 4 % variieren (vgl. §57 StVZO).
- Für die Applikation wird ein Applikationsrad mit einem Erwartungswert definiert, der sich an der Verbraurate und dem Durchschnitt orientiert.
- Der Radsatz und damit der Abrollumfang können sich aufgrund unterschiedlicher Sommer- und Winterreifen mindestens $2 \times$ pro Jahr ändern.
- Das Toleranzband des Abrollumfangs ist trotz der bekannten Raddimension theoretisch 11 cm groß. Die maximale Änderung bezüglich der Raddimension beträgt 2,5 cm.
- In der Praxis kann der gemessene Abrollumfang vom Erwartungswert um -4 bis $+3$ cm abweichen, was zu einem Geschwindigkeitsfehler von $-1,9$ bis $+1,4$ % führt.

- Die Abrollumfänge können durch das beschriebene Fehlermodell kalibriert werden. Die Geschwindigkeitsproportionalität $\mu_v = 0,1 \text{ mm/km/h}$ wird dabei berücksichtigt.
- Die Berücksichtigung des Fülldrucks ist aufgrund geringer Abrollumfangsänderung nicht sinnvoll.

2.2.2 Radaufstandspunkt (RAP)

Der kinematische RAP wird geometrisch definiert als der Schnittpunkt zwischen der Radmittelebene, der senkrecht auf die Fahrbahnebene projizierten Raddrehachse und der Fahrbahnebene selbst, auf den sich die Radgeschwindigkeit nach Gleichung (2.14) bezieht. Die Lage der RAPE in x^{VEH} -Richtung hängt hauptsächlich vom Radstand r_b und in y^{VEH} -Richtung von der Achsbreite bis zum Flansch $b_{\text{Axle},j}$ sowie der Felgen-Einpresstiefe der jeweiligen Achse ET_j ab. Zusätzlich kommt jeweils ein Anteil aus der Achskinematik $\Delta x^{\text{VEH}}, \Delta y^{\text{VEH}}$ dazu, abhängig vom Radlenkwinkel $\delta_{i,k}$:

$$\begin{aligned} r_{i,x,k} &= r_b + \Delta x^{\text{VEH}}(\delta_{i,k}), \\ r_{i,y,k} &= \frac{b_{\text{Track},j}}{2} - ET_j + \Delta y^{\text{VEH}}(\delta_{i,k}). \end{aligned} \quad (2.5)$$

Im Folgenden wird der Einfluss des radlenkwinkelabhängigen RAP untersucht, da dieser für das in dieser Arbeit entwickelte *erweiterte kinematische Zweispurmodell* OdoExt2Track benötigt wird. Dabei werden Messungen aus der Starrkinematiksimulation aus der Arbeit von Zajonz [A4] und empirische Messungen zum Einfluss der Reifenlatschverformung berücksichtigt.

2.2.2.1 Betrachtung der Starrkinematik

Die Starrkinematik beschreibt die lastfreie Bewegung der Achsen abhängig von Fahrzeugniveau und Radlenkwinkel, wobei das Rad als starre Scheibe angenommen wird. Bei einem Fahrzeug mit Vorderachs- (2x4) und Allradantrieb (4x4) unterscheidet sich die Kinematik der Vorderachse von einem Fahrzeug mit Hinterradantrieb (4x2), da die maximalen Radlenkwinkel aufgrund der Antriebswellen in der Regel kleiner sind. Werte von $\Delta\delta_F = 1-2^\circ$

sind hierbei üblich. Der RAP bewegt sich auf der Fahrbahnoberfläche mit dem Lenkradius um die Lenkachse (Abbildung 2.4).

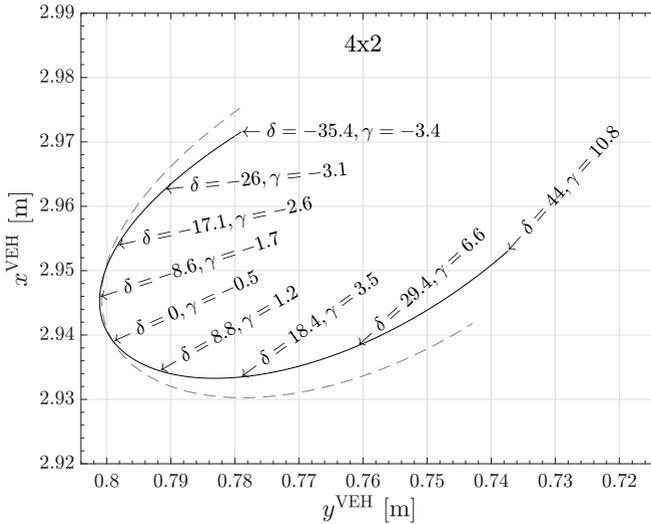


Abbildung 2.4: Verlauf des RAP des vorderen linken Rades (FL) in Abhängigkeit von Radlenkwinkel δ und Radsturz γ für ein 4x2-Fahrzeug (schwarz) im Vergleich zu einem 4x4-Fahrzeug (gestrichelt).

Für ein 4x2-Fahrzeug wird ein maximaler Radlenkwinkel $\delta_{\text{FL}} = 44^\circ$ und ein Radsturz $\gamma_{\text{FL}} = 10,8^\circ$ erreicht. Bei einer Linkskurve verschiebt sich der RAP für das kurveninnere Rad um bis zu 2 cm in x^{VEH} und $-6,5$ cm in y^{VEH} -Richtung. Dabei wird nur der Anteil der RAP-Verschiebung orthogonal auf der Kreisbahn um den Momentanpol, d. h. in $y_{\text{FL}}^{\text{WHL}}$ -Richtung, im Bewegungsmodell (vgl. Abschnitt 3.1) berücksichtigt, da die Verschiebung des Geschwindigkeitspunktes tangential auf der Kreisbahn um den Momentanpol keine Auswirkung hat.

2.2.2.2 Betrachtung der Reifenlatschverformung

Um eine sachgerechte Betrachtung der RAP-Verschiebung zu generieren, wird zusätzlich eine empirische Berechnung der Reifenlatschverformung

verwendet. Aus der Arbeit von Gnadler [47] ist eine Näherungsformel für die Verschiebung des Radlastangriffspunktes $LATDISPW$ in Abhängigkeit vom Radsturz γ bekannt. Bei Parkmanövern wird angenommen, dass die Seitenkräfte am Reifen gering sind, sodass sich die Gleichung aus Tabelle 5.3/1 in der Arbeit von Gnadler [47] für die Rad-Reifen-Kombination 255/55 R18 (Sommer) bei $p = 3$ bar folgendermaßen vereinfachen lässt:

$$LATDISPW = (0,09802 \cdot \gamma_1^2 - 5,2601 \cdot \gamma_1 - 2,2127) \cdot 10^{-3} [\text{m}]. \quad (2.6)$$

2.2.2.3 Betrachtung der Gesamtverformung

Abbildung 2.5 zeigt die Werte der RAP-Verschiebung in y^{WHL} -Richtung für die Starrkinematik $RIDIGKIN$, die Reifenlatschverformung $LATDISPW$ und für die Betrachtung beider Effekte $RIDIGKIN + LATDISPW$.

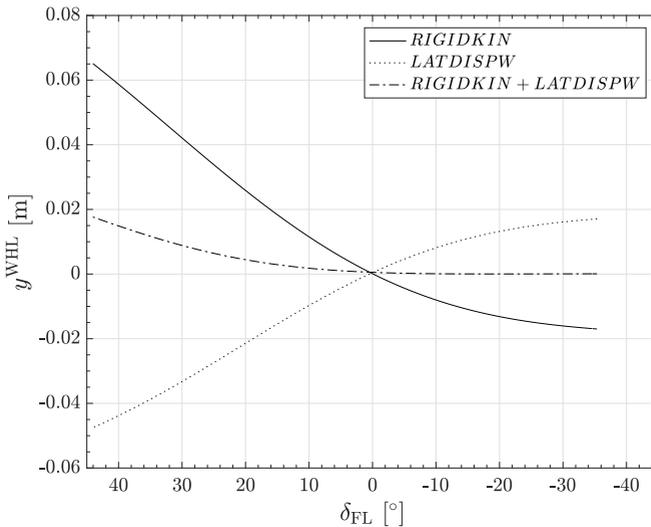


Abbildung 2.5: Einfluss der Starrkinematik $RIDIGKIN$ und der Reifenlatschverformung $LATDISPW$ auf die Verschiebung des RAP in y^{WHL} -Richtung im Radkoordinatensystem abhängig vom Radlenkwinkel δ_{FL} .

Die durch die Verformung der Reifenlatsch verursachte RAP-Verschiebung wirkt der starrkinematischen Verschiebung entgegen, die durch den Radsturz verursacht wird. Dies ist auf den Effekt zurückzuführen, dass die Kraft nicht wie bei der Starrkinematik an einem Punkt auf der Reifenscheibe, sondern an einem deformierbaren Reifen in einem flächigen Bereich (Flächenpressung) angreift. Damit ist die RAP-Verschiebung vernachlässigbar. Die RAP-Verschiebung in y^{VEH} -Richtung in Gleichung (2.5) wird daher mit der Kleinwinkelnäherung $\Delta y^{\text{WHL}}(\delta) \ll c_i/2\pi$ für kleine Radsturzwinkel γ vereinfacht. Zusätzlich wird zur weiteren Vereinfachung der Zusammenhang für ungelenkte Achsen $\gamma_{j,k} := \gamma_i(\delta_j = 0) = \gamma_{j,0}$ verwendet, um für die Fahrzeugbewegungsmodelle einen statischen RAP zu erhalten, der nur einen Grundradsturz der Achse $\gamma_{j,0}$ berücksichtigt:

$$\Delta y^{\text{VEH}}(\delta_{i,k}) := \Delta y^{\text{WHL}}(\gamma_{i,k}) \cdot \cos(\delta_{i,k}) \approx \frac{c_i}{2\pi} \cdot \gamma_{i,k} \cdot \cos(\delta_{i,k}) \approx -\frac{c_i}{2\pi} \cdot \gamma_{j,0}. \quad (2.7)$$

Häufig wird ein negativer Grundradsturz eingestellt, um eine höhere maximale Seitenführungskraft in Kurven zu erzielen. Das Versuchsfahrzeug hat einen Grundradsturz von $\gamma_{F,0} = \gamma_{R,0} = -0,5^\circ$, was jeweils einer RAP-Verschiebung von 3 mm entspricht. Die statischen RAP in y^{VEH} -Richtung berechnen sich somit wie folgt:

$$\begin{aligned} r_{\text{FL},y} = -r_{\text{FR},y} &:= \frac{b_{\text{Axle,F}}}{2} - ET(W_{\text{type}}) + 0,003\text{m}, \\ r_{\text{RL},y} = -r_{\text{RR},y} &:= \frac{b_{\text{Axle,R}}}{2} - ET(W_{\text{type}}) + 0,003\text{m}. \end{aligned} \quad (2.8)$$

Theoretisch wäre es auch möglich, die RAP während des Parkvorgangs mit Messfelgen zu bestimmen. Messfelgen können die Kräfte in der Felge durch mehrere Kraftmessdosen direkt messen. Durch ein Kräfte- und Momentengleichgewicht ist es möglich, den Punkt auf der Fahrbahnoberfläche zu bestimmen, an dem sich die Drehmomente aufheben und nur eine Kraft in Bewegungsrichtung wirkt. Aufgrund des hohen Anschaffungspreises dieser Messfelgen ist es jedoch nicht möglich, Messungen mit Messfelgen in dieser Arbeit zu berücksichtigen.

Ergebnisse zur Untersuchung der **Radaufstandspunkte (RAPe)**:

- Die Achskinematik bzw. eine radlenkwinkel- und radsturzabhängige Änderung der RAPe wird nicht berücksichtigt, da der Effekt für die Lokalisierung vernachlässigbar ist.
- Die Reifenlatschverformung wirkt der Verschiebung des RAP durch die starrkinematische Betrachtung entgegen.
- Um den genauen Verlauf der RAP-Verschiebung beim Parkvorgang zu bestimmen, können Messfelgen verwendet werden.

2.2.3 Spurweite

Die Spurweite einer Achse t_j ist definiert als der y^{VEH} -Abstand zwischen den beiden RAPen der Achse. Durch die verschiedenen Raddimensionen W_{type} kann die Spurweite mit dem Spurweitenfehler Δt_j in einem Fehlermodell wie folgt definiert werden:

$$\begin{aligned} t_F &:= r_{FR,y}(W_{\text{type}}) - r_{FL,y}(W_{\text{type}}) := r_{FL,y} - r_{FR,y} + \Delta t_F, \\ t_R &:= r_{RR,y}(W_{\text{type}}) - r_{RL,y}(W_{\text{type}}) := r_{RL,y} - r_{RR,y} + \Delta t_R. \end{aligned} \quad (2.9)$$

Tabelle 2.2 zeigt, dass die Spurweite an der Vorderachse $\Delta t_F(W_{\text{type}})$ um -0 bis $+2,1$ cm und an der Hinterachse $\Delta t_R(W_{\text{type}})$ um -2 bis $+1,6$ cm variieren kann. Das entspricht einer Spuränderung von $1,3\%$ an der Vorderachse und $1,2\%$ an der Hinterachse. Ein breiteres Rad reduziert die Spurweite und verschiebt den RAP in Richtung Fahrzeugmitte, da die Position der Außenkante des Rades durch die Kontur des Fahrzeugs begrenzt wird. Die Räder dürfen nicht aus der Fahrzeugkontur herausragen, um Steinschlag für das nachfolgende Fahrzeug zu vermeiden. Absatz 4.3.1 zeigt, wie die Spurweiten zusammen mit den Abrollumfängen im Fahrbetrieb mit dem *Achspanometerkalibrierfilter* AKPE geschätzt werden können.

Ergebnisse zur Untersuchung der **Spurweiten**:

- Der neg. Grundradsturz verbreitert die Spurweite um 6 mm.

- Ein breiteres Rad verkleinert die Spurweite.
- Die Spurweite kann an der Vorderachse um -0 bis $+2,1$ cm und an der Hinterachse um -2 bis $+1,6$ cm variieren, was eine Spuränderung der Vorderachse von bis zu $1,3\%$ und der Hinterachse von bis zu $1,2\%$ bedeutet.
- Die Spurweite kann durch das beschriebene Fehlermodell kalibriert werden.

2.2.4 Geometrische Fahrachse

Die geometrische Fahrachse beschreibt die Grundausrichtung des Fahrzeugs und sollte bei einem symmetrischen Fahrzeug gleich 0 sein. Die geometrische Achse wird in dieser Arbeit durch den konstanten kinematischen Schwimmwinkel β_0 beschrieben:

$$\beta_0 := \beta_R = \Delta\delta_R. \quad (2.10)$$

Auch ohne Hinterachslenkung können falsch eingestellte Spurstangen dazu führen, dass sich ein hinterer Achslenkwinkel einstellt. Neufahrzeuge werden grundsätzlich auf einer Achsvermessungsanlage eingestellt. Die zulässige Toleranz für die geometrische Fahrachse von Neufahrzeugen liegt bei $\beta_0 = \pm 0,05^\circ$.

Ergebnisse hinsichtlich der Untersuchung der **geometrischen Fahrachse**:

- Falsch eingestellte Spurstangen können zu einer geometrischen Fahrachse $\neq 0$ führen.
- Mögliche Fehler durch eine geometrische Fahrachse $\neq 0$ werden durch Fehler im Schwimmwinkel berücksichtigt.
- Die Toleranz der geometrischen Fahrachse von Neufahrzeugen liegt bei $\beta_0 = \pm 0,05^\circ$ und ist damit vernachlässigbar.

2.3 Fahrzeugsensorik

Die für die Fahrzeugbewegungsmodelle relevanten Sensormessungen werden von den Sensoren des ESP und des GNSS auf dem Fahrzeugbus bereitgestellt. Zusätzlich ergeben sich durch die in dieser Arbeit vorgestellten neuen Methoden weitere Sensormessungen innerhalb des Parksystems, die mit ODO gekennzeichnet sind. Tabelle 2.3 zeigt einen Überblick über alle relevanten Sensormessungen mit der jeweiligen Standardabweichung σ und der Abtastfrequenz f_S .

Tabelle 2.3: Übersicht über die relevanten Messgrößen der Fahrzeugsensorik. Kurzformen: Delta-Wheel-Pulse-Count (DWPC), Geometrische-Präzisionsverdünnung (GDOP).

Bezeichnung	System	Messwerte	σ	Einheit	f_S [Hz]
DWPC	ESP	$w_{i,k}^\times$	-	-	50
Radrollrichtung	ESP	$d_{i,k}^\times$	-	-	50
Radgeschwindigkeit	ESP	$\tilde{v}_{i,k}^\times$	$\pm 0,181$	m/s	50
Achsenlenkwinkel	ESP	$\delta_{F,k}^\times$	± 1	°	50
Längsbeschleunigung	ESP	$a_{x,k}^\times$	$\pm 0,7$	m/s ²	100
Querbeschleunigung	ESP	$a_{y,k}^\times$	$\pm 0,7$	m/s ²	100
Gierrate	ESP	$\omega_{ESP,k}^\times$	$\pm 3,5$	°/s	100
Breitengrade	GNSS	φ_k^\times	NA	°	1
Längengrad	GNSS	λ_k^\times	NA	°	1
geodätische Höhe	GNSS	h_k^\times	NA	m	1
Positionsbestimmung	GNSS	$p_{GNSS,k}$	± 2	m	1
GDOP	GNSS	$GDOP_k^\times$	-	-	1
Verfolgte Satelliten	GNSS	$TrackSat_k^\times$	-	-	1
Rollrichtung	ODO	$d_{i,k}^*$	-	-	50
Vorderer Schwimmwinkel	ODO	$\beta_{F,k}^*$	$\pm 0,4$	°	50
Hinterer Schwimmwinkel	ODO	$\beta_{R,k}^*$	$\pm 0,4$	°	50
Radlenkwinkel	ODO	$\delta_{i,k}^\times$	± 1	°	50
Kalibrierte Gierrate	ODO	ω_k^\times	$\pm 0,7$	°/s	100
x-Position	ODO	$x_{GNSS,k}^\times$	± 2	m	1
y-Position	ODO	$y_{GNSS,k}^\times$	± 2	m	1

2.3.1 Raddrehzahlsensor

Raddrehzahlsensoren werden in aktive und passive Sensoren unterteilt. Derzeit werden fast nur aktive Raddrehzahlsensoren verbaut, die auch im Versuchsfahrzeug verwendet werden. Diese messen mit dem anisotropen magneto-resistiven (AMR)-Effekt die Orientierungen des Magnetfeldes des Polrings. Früher wurden auch induktive passive Sensoren verwendet, die die zeitliche Magnetfeldänderung gemessen haben. Aktive Raddrehzahlsensoren haben den Vorteil, auch kleine Geschwindigkeiten zu messen und jede Magnetfeldänderung zu detektieren. Weitere Informationen zu AMR-Sensoren und Raddrehzahlsensoren finden sich im Buch „Mechatronik. Komponenten – Methoden – Beispiele“ von Heimann [48].

2.3.1.1 Geschwindigkeitsmessung

Mit den AMR-Sensoren kann für jedes Rad der Radimpulszählerwert bzw. der DWPC $w_{i,k}^\times$ ermittelt werden. Der Sensor zählt den Zählerwert $En_{i,k}^\times$ kontinuierlich bis zum maximalen Zählerwert $En_{\max} = 255$ hoch und fängt dann wieder beim Zählerwert 1 an. Um den DWPC zu berechnen, wird eine Fallunterscheidung gemacht. Wenn der Zählerwert im nächsten Zeitschritt k kleiner geworden ist und die Zähler subtraction negativ ist, wurde während des Zeitschritts der maximale Zählerwert En_{\max} überschritten und es wird die Modulo-Operation⁹ verwendet:

$$w_{i,k}^\times := \begin{cases} En_{i,k}^\times - En_{i,k-1}^\times, & \text{wenn } En_{i,k}^\times - En_{i,k-1}^\times \geq 0 \\ \text{mod} \left[\left(En_{i,k-1}^\times - En_{i,k}^\times \right), En_{\max} \right], & \text{wenn } En_{i,k}^\times - En_{i,k-1}^\times < 0 \end{cases} \quad (2.11)$$

⁹ Die Modulo-Operation $\text{mod}[x, y]$ gibt den Rest aus der Division von der negativen Zähler subtraction x und dem maximale Zählerwert y aus. Ein mehrfaches Überschreiten des maximale Zählerwert $En_{\max} = 255$ ist nicht möglich, da bei einem Abtastzeitabstand von $\Delta t = 0,02$ s, einem maximalen Zählerwert $En_{\max} = 255$, einem Abrollumfang von $c = 2$ m und der Anzahl der Magnet-Polpaare des Polrings von $w_{\max} = 100$ eine Geschwindigkeit von 255 m/s = 918 km/h erreicht werden müsste.

Die maximale Anzahl der DWPCs pro Umdrehung bzw. ergibt sich aus der Anzahl der Magnet-Polpaare des Polrings n_{Pol} oder der Auflösung des Raddrehzahlsensors A_{WHL} :

$$w_{\text{max}} = 2 \cdot n_{\text{Pol}} = \frac{1}{A_{\text{WHL}}}. \quad (2.12)$$

Der gefahrene Weg $\Delta s_{i,k}$ ergibt sich aus dem abgerollten Winkel $\Delta \phi_{i,k}$ und dem Radius des Rades r_i bzw. aus dem DWPC $w_{i,k}^\times$, der Auflösung des Raddrehzahlsensors A_{WHL} und dem Abrollumfang c_i zu:

$$\Delta s_{i,k} = \Delta \phi_{i,k} \cdot r_i = 2\pi \cdot w_{i,k}^\times \cdot A_{\text{WHL}} \cdot \frac{c_i}{2\pi} = \frac{w_{i,k}^\times \cdot c_i}{w_{\text{max}}}. \quad (2.13)$$

Mithilfe der Radrollrichtung $d_{i,k}^\times \in \{-1, 0, 1\}$, dem konstanten Abtastzeitabstand $\Delta t = 1/f_s$ und des Einheitsvektors in Geschwindigkeitsrichtung $\vec{v}_{i,k}$ lässt sich die Radumfangsgeschwindigkeit $\tilde{v}_{i,k}^\times$ folgendermaßen berechnen:

$$\tilde{v}_{i,k}^\times = \frac{ds}{dt} = \frac{\Delta s_{i,k}}{\Delta t} \cdot \vec{v}_{i,k} = \frac{w_{i,k}^\times \cdot c_i \cdot d_{i,k}^\times}{w_{\text{max}} \cdot \Delta t}. \quad (2.14)$$

Da die AMR-Sensoren jede Drehrichtungsumkehr der Magnetpole detektieren, ist hier für die Geschwindigkeitsmessung nur der Quantisierungsfehler durch die Auflösung ausschlaggebend. Durch den Quantisierungsfehler der DWPCs wird angenommen, dass maximal ein DWPC falsch berechnet wird. Es hat sich gezeigt, dass dieser Fehler mit einer einseitigen GNV von 3σ , also zu $1/6$, angenommen werden kann, was einem Geschwindigkeitsfehler von $2,090 \text{ m}/96/0,02 \text{ s} / 6 = \pm 0,181 \text{ m/s}$ entspricht. Bei einem Rad, das rutscht oder blockiert, kann die Geschwindigkeitsmessung nicht zur Lokalisierung verwendet werden, da es schwierig ist, den Anteil der Relativgeschwindigkeit der Fahrzeugbewegung zu bestimmen. Um die Geschwindigkeitsmessung der schlupfenden Räder zu ignorieren, wird daher im Abschnitt 3.4.2 eine Methode zur Radschlupferkennung und zur Anpassung des Lokalisierungsfilters vorgestellt.

2.3.1.2 Radrollrichtungsmessung

Aktive Raddrehzahlsensoren können auch Radrollrichtungen detektieren. Die Radrollrichtungen dieser AMR+-Sensoren können mit zwei leicht verdrehten

Polringen durch eine Signalverschiebung erkannt werden. Bei Fahrzeugen mit nur einer angetriebenen Achse wird aus Kostengründen meist nur die nicht angetriebene Achse mit AMR+-Sensoren ausgestattet. Bei Fahrzeugen mit zwei angetriebenen Achsen werden in der Regel alle vier Räder mit AMR+-Sensoren ausgestattet. Die Radrollrichtung kann positiv, negativ oder undefiniert sein und wird wie folgt definiert:

$$d_{i,k}^{\times} \in \{-1, 0, 1\}. \quad (2.15)$$

Die Spezifikation des AMR+-Sensors gibt an, dass er bis zu vier Änderungen im Magnetfeld erkennen muss, bevor er eine gültige Radrollrichtung liefern kann, wenn das Fahrzeug anfährt. Da das Fahrzeugbewegungsmodell eine Echtzeit-Positionsbestimmung erfordert, muss in dieser Arbeit die Rollrichtung frühzeitig geschätzt werden. In Abschnitt 5.1 werden deshalb neue und schnellere Methoden zur Schätzung der Rollrichtung präsentiert.

Ergebnisse hinsichtlich der Untersuchung der **Raddrehzahlsensoren**:

- Die Geschwindigkeitsmessung mit anisotropen magnetoresistiven (AMR)-Sensoren ist robust, da jeder auflösbare Delta-Wheel-Pulse-Count (DWPC) erkannt wird.
- Der Geschwindigkeitsfehler beträgt aufgrund des Quantisierungsfehlers $\pm 0,181$ m/s.
- Wenn das Rad rutscht oder blockiert, soll die Geschwindigkeitsmessung nicht zur Lokalisierung verwendet werden.
- AMR+-Sensoren liefern zusätzlich eine Radrollrichtung.
- Es kann vorkommen, dass bis zu vier DWPCs erkannt werden, ohne dass eine Radrollrichtung definiert ist.
- Um die DWPCs echtzeitfähig zu verarbeiten, muss eine Rollrichtung frühzeitig geschätzt werden.

2.3.2 Achslenkwinkelsensor

Für das ESP wird der vordere Achslenkwinkel δ_F^\times als Eingang für das *lineare Einspurmodell* auf dem Fahrzeugbus bereitgestellt. Er wird indirekt aus der Zahnstangenposition $x_{Z,k}^\times$ und der Lenkinematik durch die Lenkinematiktafel $\delta_{F,k} = f_{\text{Achs}}(x_{Z,k})$ in der Electric-Power-Steering (EPS) berechnet. Die mittlere Zahnstangenposition, die als Nullpunkt für einen relativen Sensor dient, kann durch Verstellen der beiden Spurstangen, die jeweils die Zahnstange mit den Radträgern verbinden, oder durch Fertigungstoleranzen verschoben werden. Der Versatz der Zahnstangenposition Δx_Z wirkt sich als systematischer Fehler auf den Achslenkwinkel aus. Durch Toleranzen bei der Fertigung der Zahnstange kann es beim Versuchsfahrzeug zu einem Versatz der Spurstange von $\sigma_{x_{Z,k}} = \pm 0,75$ mm der Zahnstangenposition kommen. Dies führt durch die Lenkinematik zu einem Versatz des Achslenkwinkels von $\Delta \delta_F = \pm 1^\circ$. Der Achslenkwinkel wird mit folgendem Fehlermodell definiert als:

$$\delta_{F,k}^\times = f_{\text{Achs}}(x_{Z,k} + \Delta x_Z) := f_{\text{Achs}}(x_{Z,k}) + \Delta \delta_F. \quad (2.16)$$

Der Quantisierungsfehler, der sich durch die Auflösung A_{lenk} vom Zahnstangenmotor zum Achslenkwinkel ergibt, ist $\Delta \delta_F = 0,004^\circ$ groß und kann deshalb vernachlässigt werden.

Ergebnisse hinsichtlich der Untersuchung des **Achslenkwinkelsensor**:

- Der Achslenkwinkel kommt vom Elektronischen-Stabilitätsprogramm (ESP) und wird aus den beiden Radlenkwinkeln einer Achse gemittelt.
- Der mögliche Fehler des Achslenkwinkels durch Toleranzen in der Spurstange beträgt $\pm 1^\circ$.
- Der Quantisierungsfehler des Achslenkwinkelsensors kann vernachlässigt werden.

2.3.3 Schwimmwinkelbestimmung

Für große Radlenkwinkel und Rückwärtsfahrten ist der Achslenkwinkel δ_F^\times vom Fahrzeugbus und damit das *kinematische Einspurmodell* besonders un-

genau. Denn statt des Geschwindigkeitswinkels der Vorderachse wird nur der mittlere Radlenkwinkel verwendet. Abbildung 2.6 zeigt die stationären Kreisfahrmessungen eines 4x2- und eines 4x4-Fahrzeugs während der Vorwärts- und Rückwärtsfahrt bei konstantem Achslenkwinkel.

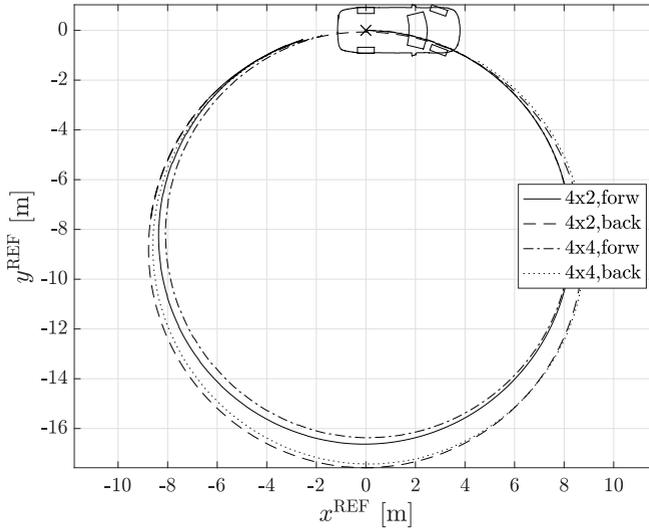


Abbildung 2.6: Stationäre Kreisfahrmessungen bei Vorwärts- und Rückwärtsfahrt mit konstantem Achslenkwinkel $\delta_F = -20^\circ$ und konstanter absoluter Geschwindigkeit $\|v\| = 5 \text{ km/h}$ für ein 4x2- und ein 4x4-Fahrzeug.

Die Trajektorien der stationären Kreisfahrmessungen zeigen je nach Antriebskonzept und Rollrichtung unterschiedliche Durchmesser, obwohl der gleiche Achslenkwinkel vorliegt. Um den Winkel der Geschwindigkeit zu beschreiben, wird daher der Schwimmwinkel β definiert, der sich bei Vorwärts- und Rückwärtskurvenfahrten unterscheidet. Dieses Phänomen beruht auf Radstellungsfehlern, die zum einen durch Ackermannfehler [27] verursacht werden. Zusätzlich wirken je nach Rollrichtung unterschiedliche Kräfte auf die elastokinematischen Achsbauteile. Der Achslenkwinkel δ_j und der Achsschräglaufwinkel α_j bilden den Schwimmwinkel $\beta_j = \delta_j + \alpha_j$. Um die Achslenkwinkel auch bei großen Kurven und Rückwärtsfahrten verwenden zu können, wird in dieser Arbeit das *korrigierte kinematische Einspurmodell*

entwickelt. Dafür werden die korrigierten Schwimmwinkel β_j^* benötigt. Im nächsten Absatz wird daher ein Verfahren entwickelt, das die rollrichtungsabhängigen Schwimmwinkel bestimmt.

2.3.3.1 Schwimmwinkeldefinition

Bei einem Parkvorgang wird angenommen, dass der Eigenlenkgradient¹⁰ $EG \approx 0$ ist und sich der Schwimmwinkel des Fahrzeugs nur aus der geometrischen Fahrachse β_0 (vgl. Gleichung (2.10)) und einem kinematischen Schwimmwinkel β_{kin} aufgrund von Radstellungsfehlern zusammensetzt:

$$\beta = \beta_0 + \beta_{\text{kin}} + \underbrace{\beta_{\text{dyn}}(EG)}_{\approx 0}. \quad (2.17)$$

Der Achslenkwinkel δ_j und der Achsschräglaufwinkel α_j bilden den Schwimmwinkel $\beta_j = \delta_j + \alpha_j$. Dabei besteht der Achslenkwinkel aus dem gemessenen Achslenkwinkel δ_j^\times und einem Elastokinematikwinkel $\Delta\delta_j$. Der Achsschräglaufwinkel und der Elastokinematikwinkel ändern sich abhängig von der Rollrichtung und unterscheiden sich entsprechend der Antriebsart. Daher werden die Schwimmwinkel β_j mit dem folgenden Fehlermodell definiert als:

$$\beta_j = \delta_j^\times + \Delta\delta_j(\delta_F^\times, \delta_R^\times, d^\times, An_{\text{Konz}}) + \alpha_j(\delta_F^\times, \delta_R^\times, d^\times, An_{\text{Konz}}). \quad (2.18)$$

Die Schwimmwinkel β_j sind somit abhängig von den gemessenen Achslenkwinkeln δ_j^\times , der Rollrichtung d^\times und dem Antriebskonzept An_{Konz} . Der Zusammenhang ist allerdings ungeklärt und bedarf weitergehender Forschung im Gebiet der Kräfteübertragung im Lenkungssystem und zwischen Reifen und Fahrbahn. Um den Schwimmwinkel trotzdem zu verwenden, wird ein Verfahren entwickelt, das eine Korrektur des Achslenkwinkels in Abhängigkeit von Antriebskonzept und Rollrichtung bestimmt.

¹⁰ Der Eigenlenkgradient ist ein Maß für das stationäre Eigenlenkverhalten eines zweispurigen Fahrzeugs. Er beschreibt qualitativ die Fahrstabilität. $EG > 0$: Fahrzeug verhält sich untersteuernd, $EG = 0$: Fahrzeug verhält sich neutral, $EG < 0$: Fahrzeug verhält sich übersteuernd.

2.3.3.2 Verfahren zur Bestimmung der Schwimmwinkel

Zur Bestimmung der Schwimmwinkel wurde ein neues Verfahren entwickelt, welches inkl. Algorithmus¹¹ in der Offenlegung [O9] beschrieben wurde. In dieser Arbeit wird daher nur eine Zusammenfassung gezeigt. In dem Verfahren werden empirische Schwimmwinkel β_j^* durch DGNSS-Positionsmessungen des Referenzmesssystem (vgl. Abschnitt 2.4) erzeugt:

$$\beta_j = \delta_j^\times + \Delta\delta_j + \alpha_j \approx \beta_j^*(\delta_F^\times, \delta_R^\times, d^\times, An_{Konz}). \quad (2.19)$$

Zur Bestimmung der empirischen Schwimmwinkel β_j^* werden rollrichtungsabhängige stationäre Kreisfahrtmessungen verwendet. Die Messfahrten werden mithilfe eines selbstentwickelten schnittstellenbasierten Fahrroboters¹² durchgeführt, der konstante Achslenkwinkel, Richtungswechsel und konstante Geschwindigkeiten von +5 und -5 km/h fahren kann. Abbildung 2.7 zeigt die Trajektorie des 4x2-Versuchsfahrzeugs der gesamten Messfahrt. Alle Achslenkwinkel werden in 5°-Schritten vorwärts und rückwärts gefahren. In der Abbildung sind deutlich die unterschiedlichen Trajektorien bei Vorwärts- und Rückwärtsfahrten zu erkennen¹³. Für die stationäre Kreisfahrtmessung wird eine ebene Testfläche von etwa 1 ha benötigt. Um alle stationären Kreisfahrtmessungen durchzuführen, benötigt der Fahrroboter etwa 60 min.

2.3.3.3 Ermitteln der Momentanpole durch das Referenzmesssystem

Zuerst werden die Momentanpole M_{Ref} der Fahrzeugbewegung für ein Kreisfahrtsegment bezüglich einer festgelegten Zeitspanne bestimmt. Die DGNSS-Positionsmessungen werden als Kreisgleichung in einem linearen Optimie-

¹¹ In der Offenlegung [O9] wurde eine abweichende Nomenklatur verwendet. In dieser Arbeit wird α für den Schräglaufwinkel, β für den Schwimmwinkel und γ für den Radsturz verwendet, um einer allgemeineren Nomenklatur der Fahrzeugtechnik zu entsprechen.

¹² Der für die Messfahrten verwendete schnittstellenbasierte Fahrroboter wurde speziell für diesen Zweck entwickelt und nutzt die Fahrzeugbuskommunikationsschnittstelle, um mit der EPS und dem ESP zu kommunizieren. Er ermöglicht es, einen Achslenkwinkel von $\pm 0,01^\circ$ und eine Geschwindigkeit von $\pm 0,2$ km/h für die stationäre Kreisfahrt einzustellen.

¹³ Die Trajektorien beschreiben die Bewegung der Hinterachse und stellen daher lediglich einen Teil des Wendekreisradius dar. Für die Wendekreisradiusmessung wird zusätzlich der Abschnitt bis zur vorderen Außenecke des Kotflügels oder Stoßfängers im Fahrzeugkoordinatensystem berücksichtigt. Für eine Mittelklasselimosine ergibt sich aus dieser Berücksichtigung ein Wendekreisradius von bis zu 12 m.

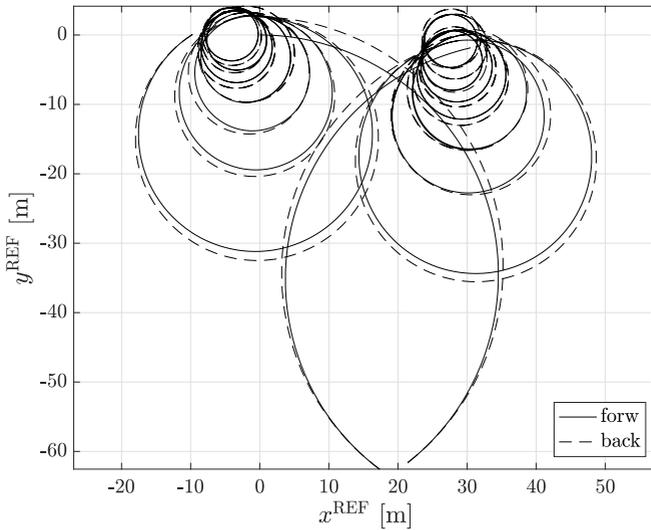


Abbildung 2.7: Trajektorien des 4x2-Versuchsfahrzeugs bei der stationären Kreisfahrtmessung.

rungsproblem aufgestellt. Dieses wird dann mit der Kreisformung nach Pratt [49] gelöst. Als Ergebnis resultieren Momentanpole, die vom Referenzkoordinatensystem K^{REF} in das Fahrzeugkoordinatensystem K^{VEH} transformiert und über $n = 20$ Messungen gemittelt werden. Abbildung 2.8 zeigt die durch das Referenzmesssystem generierten Momentanpole M_{Ref} für die Vorwärts- und Rückwärtsfahrten im Fahrzeugkoordinatensystem K^{VEH} .

Auffällig ist, dass sich der Momentanpol bei Vorwärtsfahrten vor die Hinterachse und bei Rückwärtsfahrten dahinter verschiebt. Das bedeutet, dass das Fahrzeug beim Vorwärtsfahren mehr in die Kurve hinein- und beim Rückwärtsfahren mehr aus dieser herauslenkt. Dieses Ergebnis deckt sich mit dem beschriebenen Phänomen aus Abbildung 2.6.

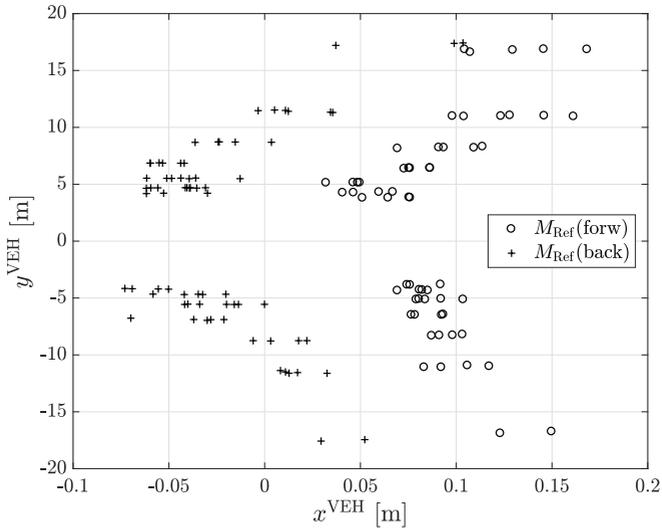


Abbildung 2.8: Referenzmomentanpole des 4x2-Versuchsfahrzeugs bei der stationären Kreisfahrtmessung.

2.3.3.4 Ermittlung der empirischen Schwimmwinkel

Mithilfe der Momentanpole werden die Schwimmwinkel berechnet. Anschließend wird die Korrekturkurve durch das folgende Polynom angenähert:

$$\beta_j^* = a_{5,d^\times, \text{AnKonz}} \cdot (\beta_j^\times)^5 + a_{3,d^\times, \text{AnKonz}} \cdot (\beta_j^\times)^3 + a_{1,d^\times, \text{AnKonz}} \cdot \beta_j^\times. \quad (2.20)$$

Es hat sich gezeigt, dass ein Polynom fünften Grades für den Anwendungsfall den besten Kompromiss zwischen Komplexität und Approximation der Messwerte liefert. Da die Lenkung symmetrisch ist, gibt es keine Nullpunktverschiebung¹⁴ $a_{0,d^\times, \text{AnKonz}} = 0$.

¹⁴ Wenn die Korrekturkurven eine Nullpunktverschiebung aufweisen, könnte dies aufgrund von Faktoren wie der falschen Positionierung des Referenzmesssystems oder einer geometrischen Fahrachse $\beta_0 \neq 0$ liegen. Es sollte daher darauf geachtet werden, dass das Versuchsfahrzeug zuvor sorgfältig auf einem Referenz-Achsmessungsprüfstand ausgerichtet wird, was die Wahrscheinlichkeit solcher Fehler minimiert. Darüber hinaus kann die Messung potenziell verwendet werden, um eventuelle Ausrichtungsfehler zu kalibrieren, wie in der Offenlegung [O10] beschrieben wird. Da die Nullpunktverschiebung direkt mit dem Ausrichtungsfehler

2.3.3.5 Ergebnis der Schwimmwinkelbestimmung

Als Ergebnis der Schwimmwinkelbestimmung ergeben sich die Schwimmwinkeldifferenzwerte $\Delta\beta_F$ und $\Delta\beta_R$. Für ein Fahrzeug mit starrer, un gelenkter Hinterachse $\delta_R^\times = 0$ gilt:

$$\begin{aligned} \beta_F &= \delta_F^\times + \Delta\delta_F + \alpha_F = \delta_F^\times + \Delta\beta_F, \\ \beta_R &= \alpha_R = \Delta\beta_R. \end{aligned} \quad (2.21)$$

Abbildung 2.9 zeigt die Schwimmwinkeldifferenzwerte $\Delta\beta_F$ und $\Delta\beta_R$ für die Vorwärts- und Rückwärtsfahrt in Abhängigkeit vom Achslenkungswinkel δ_F^\times und der Antriebsart 4x2 bzw. 4x4. Zusätzlich werden die approximierten Ausgleichskurven gezeichnet, die später im Fahrzeugbewegungsmodell durch die Koeffizienten des Polynoms gespeichert und im Fahrbetrieb abgerufen werden können.

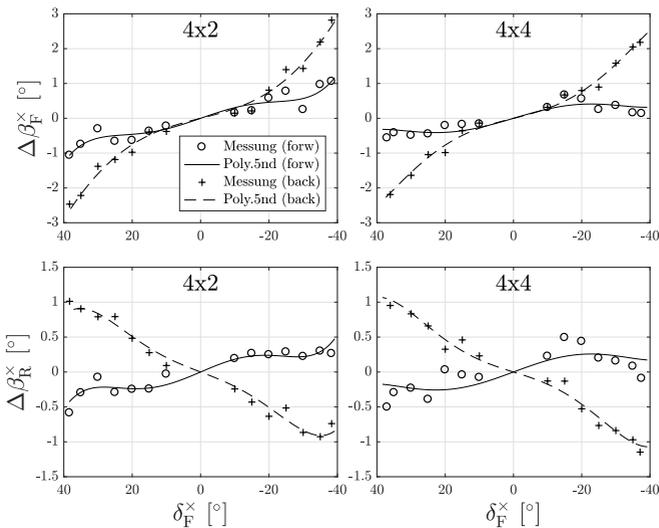


Abbildung 2.9: Schwimmwinkeldifferenzkurven des 4x2- und des 4x4-Versuchsfahrzeugs.

zusammenhängt, könnte die Prozedur erneut mit der korrigierten Ausrichtung durchgeführt werden.

Die Schwimmwinkeldifferenzwerte betragen bis zu $\pm 3^\circ$ an der Vorderachse und bis zu $\pm 1^\circ$ an der Hinterachse. Die Kurve der Schwimmwinkeldifferenz für das Versuchsfahrzeug mit 4x2- und 4x4-Antrieb sind leicht verändert, es zeigt sich aber ein ähnlicher Verlauf. Bei Rückwärtsfahrten sind die Werte größer als bei Vorwärtsfahrten. Die Auswirkung der Momentanpole mit unterschiedlichen Vorzeichen beim Vorwärts- und Rückwärtsfahren zeigt sich auch hier an den Werten der Hinterachse. Diese wechseln ihr Vorzeichen zwischen einer Vorwärts- und einer Rückwärtsfahrt. Die Standardabweichung der einzelnen Messungen zu den Ausgleichskurven liegt für das Verfahren mit der Verwendung des Polynoms fünften Grades bei unter $0,2^\circ$.

Eine mögliche Weiterentwicklung des Lokalisierungsfilters befasst sich mit der detaillierten Modellierung der Schwimmwinkel. Dies geschieht durch Berücksichtigung eines Reifenmodells, wie es in der Offenlegung [O11] beschrieben ist, oder durch die zusätzliche Berücksichtigung von Wetterdaten, wie in der Offenlegung [O12] dargestellt. Die Offenlegung [O13] beschreibt die Idee für ein Verfahren zur Korrektur von Achslenkwinkeln durch Messfahrten, die mit einem Referenzmesssystem durchgeführt werden, indem die Korrekturparameter für die gesamte Trajektorie der Messfahrten ermittelt werden. Dieses Verfahren würde mehr Aufwand erfordern. Eine Erweiterung könnte zukünftig dafür sorgen, dass die Schwimmwinkelkorrekturwerte auf Basis von Kraft- und Drehmomentgleichgewichten modelliert werden.

Ergebnisse hinsichtlich der **Schwimmwinkelbestimmung**:

- Für eine bessere Modellierung werden für das *korrigierte kinematische Einspurmodell* Odo1Track* die Schwimmwinkel β_j benötigt.
- Die korrigierten Schwimmwinkel β_j^* ($\delta_F^\times, \delta_R^\times, d^\times, An_{Konz}$) können mit dem entwickelten Verfahren automatisiert durch die stationären Kreisfahrtmessungen eines Fahrroboters mit einem Referenzmesssystem bestimmt werden.
- Die Schwimmwinkeldifferenzwerte werden für die jeweilige Antriebsart (4x2, 4x4) und rollrichtungsabhängig bestimmt.
- Zur Verwendung der Schwimmwinkel müssen im Fahrzeugbewegungsmodell nur die Koeffizienten der Ausgleichskurven hinterlegt werden.

- Die Standardabweichung der Schwimmwinkeldifferenzwerte liegt unter $0,2^\circ$.
- Die Schwimmwinkeldifferenz gilt nur für den untersuchten Fall. Bei Steigungen gelten andere Kräfte auf die Achse. Die Schwimmwinkeldifferenzwerte bzw. das Odo1Track* wird daher nur bei Steigungen von $\leq 5\%$ im Lokalisierungsfilter verwendet.
- Das Verhältnis zwischen dem Schwimmwinkel und dem Achslenkwinkel wurde empirisch bestimmt. Um dies zu berechnen, sind weitere Untersuchungen auf dem Gebiet der Kraftübertragung im Lenksystem sowie zwischen Reifen und Fahrbahn erforderlich.

2.3.4 Radlenkwinkelbestimmung

Für das in dieser Arbeit entwickelte *erweiterte kinematische Zweispurmodell* OdoExt2Track werden die Radlenkwinkel δ_i benötigt, da die genaue Richtung der Geschwindigkeitsmessung verwendet wird. Um sicherzustellen, dass die Räder auch bei Kurvenfahrten in Rollrichtung abrollen, wurden die Achsschenkellenkung bzw. die nach dem Erfinder benannte Ackermannlenkung [27] entwickelt. Bei der Ackermannlenkung werden die Räder der gelenkten Achse unterschiedlich geführt; durch die mechanische Anordnung in einem Lenktrapez wird das kurveninnere Rad stärker und das kurvenäußere Rad schwächer gelenkt. Die Ackermannradlenkwinkel $\delta_{FL,Ack,k}$, $\delta_{FR,Ack,k}$ werden wie folgt berechnet:

$$\begin{aligned} \delta_{FL,Ack,k} &= \arctan \left(\frac{r_b}{\frac{r_b}{\tan(\delta_{F,k}^\times)} - \frac{l_F}{2}} \right), \\ \delta_{FR,Ack,k} &= \arctan \left(\frac{r_b}{\frac{r_b}{\tan(\delta_{F,k}^\times)} + \frac{l_F}{2}} \right). \end{aligned} \quad (2.22)$$

Die mechanische Konstruktion der Ackermannradlenkwinkel ist gerade bei großen Radlenkwinkeln schwierig und teuer, es resultieren Ackermannfehler $\Delta\delta_{i,Ack}$. Obwohl theoretisch die Vorspur zu einem erhöhten Radschräglauf-

winkel und somit zu einer verstärkten Seitenkraft am äußeren Rad in Kurven führen kann, erfordert die Fahrzeugauslegung oft einen Kompromiss, um ein übersteuerndes Fahrverhalten zu verhindern. Daher sind moderne Fahrzeuge häufig so konzipiert, dass sie aus fahrdynamischen Gründen eher untersteuern und die inneren Radlenkwinkel mehr in Vorspur ausgerichtet sind, was potenziell zusätzliche Ackermannfehler verursacht. Durch die Achskinematik $f_{\text{Achs},j}$ können die Radlenkwinkel $\delta_{i,k}$ mit dem folgenden Fehlermodell definiert werden:

$$\delta_{i,k}^{\times} := f_{\text{Achs},j}(x_{Z,k}) = \delta_{i,\text{Ack},k} + \Delta\delta_{i,\text{Ack},k}. \quad (2.23)$$

Um den Ackermannfehler in Abhängigkeit vom Achslenkwinkel δ_F zu ermitteln, werden Achslenkwinkelmessungen durchgeführt. Hierbei werden die Radlenkwinkel δ_i ohne Krafteinwirkung auf einer hochgenauen Achsvermessungsanlage in Abhängigkeit vom Zahnstangenweg x_Z vermessen. Abbildung 2.10 zeigt den Ackermannfehler $\Delta\delta_{i,\text{Ack}}$ für die beiden Vorderäder in Abhängigkeit vom Achslenkwinkel δ_F^{\times} für ein 4x2-Fahrzeug. Die Kurve des 4x4-Fahrzeugs ist bis auf die Endanschläge identisch mit der des 4x2-Fahrzeugs, weshalb sie nicht zusätzlich dargestellt wird.

Das kurveninnere Rad lenkt bis zu 3° weniger und das kurvenäußere Rad bis zu $1,4^\circ$ mehr ein als der über den Achslenkwinkel und die Ackermann-Bedingung hergeleitete Radlenkwinkel.

Ergebnisse hinsichtlich der **Radlenkwinkelbestimmung**:

- Die tatsächlichen Radlenkwinkel können durch den Winkel des Ackermannfehlers von den idealen Ackermannradlenkwinkeln abweichen.
- Die Radlenkwinkel lassen sich durch Prüfstandsmessungen in Abhängigkeit des Achslenkwinkels bestimmen, wobei der nichtlineare Ackermannfehler berücksichtigt wird.
- Die Prüfstandsmessungen zur Bestimmung der Radlenkwinkel gelten nur für den lastfreien Fall ohne Seitenkräfte. Um genauere Messergebnisse zu erhalten, können Messfelgen eingesetzt werden.

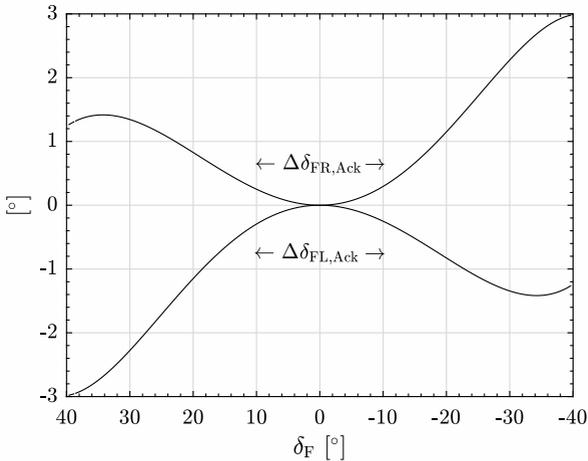


Abbildung 2.10: Ackermannfehler der Vorderräder in Abhängigkeit vom Achslenkwinkel, lastfrei gemessen auf einer Achsvermessungsanlage für ein 4x2-Fahrzeug.

2.3.5 Inertialsensorik

Die serienmäßig verbaute Inertialsensorik (engl. INERTIAL-MEASUREMENT-UNIT (IMU)) besteht aus einem Sensorcluster, das nahe dem Schwerpunkt und dem Drehpol des Fahrzeugs liegt. Letzterer besteht aus Kostengründen meist nur aus einem Längsbeschleunigungs-, einem Querschleunigungs- und einem Gierratensensor. Bei Cabrios ist zusätzlich ein Hochbeschleunigungssensor verbaut, um im Falle eines Überschlags die aktive Überrollvorrichtung zu betätigen. Diese Sensoren bestehen aus Micro-Electro-Mechanical-Systems (MEMS) und haben charakteristische Fehlergrößen. Neben Quantisierungsfehlern und einem mittelwertfreien Signalrauschen sind für Inertialsensoren folgende statischen Fehlertypen charakteristisch: Nullpunktdrift, Sensitivitäts- (bzw. Empfindlichkeits-), Linearitäts- und Hysteresefehler. Überdies sind die Sensoren empfindlich gegenüber Temperaturschwankungen sowie Alterung und zeigen beim Start einen Anlaufdrift. Zusätzlich können Kreuzkorrelationsabhängigkeiten auftreten, d. h. die Sensoren beeinflussen sich bei großen Ausschlägen gegenseitig. Eine detaillier-

tere Beschreibung der Inertialsensoren findet sich im Buch "Mechatronik – Komponenten, Methoden, Beispiele" von Heimann [48].

2.3.5.1 Beschleunigungssensoren

Der Beschleunigungssensor besteht aus einem MEMS, in dem sich eine seismische Masse entlang einer Messachse bewegt. Es zeigt in x^{VEH} -Richtung für den Längsbeschleunigungssensor und in y^{VEH} -Richtung für den Querschleunigungssensor. Bei normalen Parkmanövern treten Längs- und Querschleunigungen von $a_{x,\text{max}}^{\times} = a_{y,\text{max}}^{\times} = \pm 0,5 \text{ m/s}^2$ auf. Aus der Sensorspezifikation wird deutlich, dass die charakteristischen Fehlergrößen größer sind als die zu messenden Sensorauschläge. Die Verwendung der Beschleunigungssensoren zur Trägheitsnavigation ist daher ungeeignet. Ferner werden die Fehler durch die doppelte Integration verstärkt, da zur Lokalisierung Weginformationen benötigt werden.

2.3.5.2 Gierratensensor

Der Gierratensensor besteht aus zwei MEMS, die im Gegentakt schwingend angeregt werden. Bei einer Drehbewegung wirkt die Corioliskraft und es kann eine Beschleunigung gemessen werden. Die Drehgeschwindigkeit errechnet sich aus der Beschleunigung und der konstant geregelten Schwingungsgeschwindigkeit der MEMS. Die Gierrate entspricht der Drehgeschwindigkeit um die Hochachse des Fahrzeugs. Bei normalen Parkmanövern treten Gierraten von $\omega_{\text{max}}^{\times} = \pm 7^{\circ}/\text{s}$ auf. Die Sensorspezifikation zeigt, dass die charakteristischen Fehlergrößen im Bereich der Messung liegen und nicht vernachlässigt werden können. Die Verwendung der direkt gemessenen Gierrate hat den Vorteil, dass die Drehung direkt gemessen wird, und kann die anfälligen indirekten Messungen über den Radlenkwinkel erheblich verbessern. In Abschnitt 4.4 wird daher eine Kalibrierung der Gierratensensorfehler mithilfe eines vereinfachten Fehlermodells durch den *Gierratenfehlerkalibrierfilter* YRPE untersucht. Das Fehlermodell berücksichtigt einen Sensitivitätsfehler $Sens_{\omega}(T, A, \Delta t_0)$ sowie einen Gierraten-Nullpunktdrift $Drift_{\omega}(T, A, \Delta t_0)$ (auch Bias genannt) und ist wie folgt definiert:

$$\omega_{\text{ESP},k}^{\times} = [\omega_k^{\times} \cdot Sens_{\omega}(T, A, \Delta t_0)] + Drift_{\omega}(T, A, \Delta t_0). \quad (2.24)$$

Die Linearitäts- und Hysteresefehler sind komplex und schwer zu bestimmen. Da diese Fehler um den Nullpunkt herum klein sind und zu einer Offsetverschiebung führen, kann davon ausgegangen werden, dass sie im Fehlermodell indirekt durch den Nullpunktdrift berücksichtigt werden. Zusätzlich gilt das Fehlermodell nur für den eingeschwungenen Zustand, d. h. wenn das Fahrzeug nach längerer Standzeit, z. B. über Nacht, wieder gestartet wird und sich die Temperatur deutlich geändert hat, muss es neu kalibriert werden. Zusätzlich muss eine Anlaufzeit von $\Delta t_0 = 5$ min abgewartet werden, bis der Anlaufdrift abgeklungen ist. Daher ist eine kalibrierte Gierrate nicht für den sofortigen Ausparkvorgang nach dem Start geeignet. Für die Fehler- und Sensitivitätsberechnung des Lokalisierungsfilters wird zur Vereinfachung ein konstanter Gierraten-Versatz $\Delta\omega = \pm 0,7^\circ/\text{s}$ angenommen, um die Berechnungen für die Sensitivität-Evaluation zu vereinfachen. Es gilt:

$$\begin{aligned}\omega_k^\times &= [\omega_{\text{ESP},k}^\times - \text{Drift}_\omega(T, A, \Delta t_0)] \cdot \frac{1}{\text{Sens}_\omega(T, A, \Delta t_0)} \\ &:= \omega_{\text{ESP},k}^\times + \Delta\omega.\end{aligned}\tag{2.25}$$

Ergebnisse hinsichtlich der Untersuchung der serienmäßig verbauten **Inertialsensoren**:

- Die Beschleunigungsmessungen eignen sich aufgrund der Sensorspezifikation und der Integrationsfehler nicht für die Lokalisierung.
- Die Gierrate kann durch ein Gierratenfehlermodell kalibriert werden.
- Das Gierratenfehlermodell berücksichtigt die Effekte von Zeit, Temperatur und Alterung. Nach einer größeren Zeit- oder Temperaturänderung muss eine Neukalibrierung durchgeführt werden. Es gilt nicht für größere Sensorausschläge.
- Wegen des Anlaufdrifts kann die Gierrate erst nach einer Verweildauer verwendet werden.

2.3.6 Global-Navigation-Satellite-System (GNSS)

Seit April 2018 ist das gesetzlich verbindliche eCall-System [34], das ein Global-Navigation-Satellite-System (GNSS) beinhaltet, in jedem neuzugelassenen Fahrzeug in Europa verfügbar. Das GNSS benutzt Satelliteninformationen für die absolute Positionsbestimmung. Dazu übertragen die Satelliten ihre exakte Satellitenposition im Orbit sowie die von einer Atomuhr gemessene Zeit an einen Empfänger auf der Erde. Die Differenz zwischen der Empfangszeit und dem Zeitstempel der Nachricht bestimmt über die Lichtgeschwindigkeit die sog. Pseudo-Distanz zwischen Satellit und Empfänger. Die Pseudo-Distanz beinhaltet bspw. Fehler durch Signalverzögerungen in der Ionosphäre und Mehrwegfehler durch Reflexionen an Gebäuden. Es sind theoretisch mindestens vier Satelliten nötig, um über Triangulation den Ort und den Latenzfehler zu bestimmen. Das wohl bekannteste GNSS ist das amerikanische Global Positioning System (GPS), gefolgt vom russischen GLONASS, dem europäischen Galileo und dem chinesischen Beidou. Die Positionsdaten werden als Breitengrade (Latitude) φ_k und Längengrade (Longitude) λ_k sowie als elliptische Höhe (Height) h_k bereitgestellt und beziehen sich auf das geodätische Koordinatensystem:

$$\begin{bmatrix} x_{\text{GNSS},k}^{\times} \\ y_{\text{GNSS},k}^{\times} \end{bmatrix} := f(\varphi_k^{\times}, \lambda_k^{\times}, h_k^{\times}, \mathbf{p}_{\text{GNSS}/\text{VEH}}). \quad (2.26)$$

Die Umrechnung und Transformierung des kartesischen Koordinatensystems in eine x - und y -Position wird später in Abschnitt 2.4 für das Referenzmesssystem genauer vorgestellt.

Die Berechnung der Genauigkeit vom GNSS stellt eine besondere Herausforderung dar. Um eine höhere Genauigkeit zu garantieren, wird die Anzahl der Satelliten erhöht. Beim GPS stehen daher bis zu 24 Satelliten zur Verfügung. Das GNSS des Versuchsfahrzeugs bietet eine Standardabweichung von $\sigma_{\text{PGNSS}} = \pm 2 \text{ m}$ für die Positionsbestimmung bei besten Bedingungen. Um bessere Informationen über die Genauigkeit der Positionsmessung zu erhalten, muss die Anzahl der verfolgten Satelliten $\text{TrackSat}_k^{\times}$ mindestens sechs betragen, um die GDOP verwenden zu können. GDOP_k^{\times} ist ein Maß für die Streuung der Messwerte [50]. Sie gibt die Abhängigkeit der relativen Positionen der Satelliten zueinander und zum Beobachter an. Die laufen-

de Standardabweichung $\sigma_{p,\text{GNSS},k}$ kann abhängig von der GDOP wie folgt berechnet werden:

$$\sigma_{p,\text{GNSS},k} = \sigma_{\text{PGNSS}} \cdot \text{GDOP}_k^{\times}. \quad (2.27)$$

Das GNSS ist aufgrund seiner begrenzten Verfügbarkeit z. B. in Parkhäusern und der höheren Standardabweichung nicht für eine reine Lokalisierung während des Parkvorgangs selbst geeignet. Allerdings können die Positionsmessungen von GNSS für die Kalibrierfilter in Kapitel 4 verwendet werden.

Ergebnisse hinsichtlich der Untersuchung des **Global-Navigation-Satellite-System (GNSS)**:

- Die Lokalisierung mit GNSS ist für Parksysteeme nicht möglich. Stattdessen eignen sich die GNSS-Positionsmessungen als Eingangsvariablen für die Kalibrierfilter.
- Die geodätischen Koordinaten des GNSS müssen ins Fahrzeugkoordinatensystem transformiert werden.
- Die Anzahl der verfolgten Satelliten kann verwendet werden, um Informationen darüber zu erhalten, wann eine Kalibrierung durchgeführt werden kann.
- Die Genauigkeit der Positionsmessung kann durch die Geometrische-Präzisionsverdünnung (GDOP) berechnet werden.

2.4 Referenzmesssystem

Um die in dieser Arbeit entwickelten Methoden zu evaluieren, ist der Referenzmessaufbau aus Abbildung 2.11 erforderlich.

Die Fahrzeugsensoren werden über den Fahrzeugbus und die Referenzmesstechnik an ein Interface der Firma Vector Informatik GmbH angeschlossen, welches mit einem Messtechnikbus verbunden ist. Die Software CANoe interpretiert die Daten aus dem Fahrzeug und der Referenzmesstechnik und stellt sie mit einem definierten Zeitstempel der Simulationssoftware MATLAB/Simulink zur Verfügung. CANoe ist in der Lage, Daten in Echtzeit

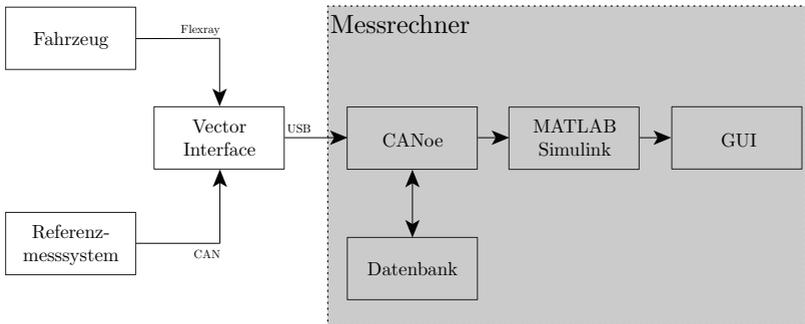


Abbildung 2.11: Messaufbau des Rahmenwerks zur Live-Simulation und zur Datengenerierung.

zu übermitteln, Messaufzeichnungen zu generieren und wieder abzuspielen. Die Ergebnisse des Rahmenwerks können live im Fahrzeug über die GUI (vgl. Anhang A.1) angezeigt werden. Außerdem können die Modelle und Parameter direkt angepasst werden, um Algorithmen für den Live-Betrieb im Fahrzeug zu optimieren.

Referenzmesstechnik

Als Referenzmesstechnik wird ein doppeltes Differential-Global-Navigation-Satellite-System (DGNSS) verwendet, gekoppelt mit einer hochgenauen IMU der Firma iMAR Navigation GmbH (Bezeichnung: iNAT-M200/SLN). Die primäre GNSS-Antenne wird für die absolute Positionsbestimmung auf der Erde, die sekundäre GNSS-Antenne für die exakte Berechnung der Fahrzeugausrichtung verwendet. Über die LTE-Antenne werden Differentialdaten für einen Real-Time-Kinematic (RTK)-Abgleich empfangen. Die IMU wird für die Berechnung der relativen Eigenbewegung verwendet. Durch die Datenfusion kann eine absolute Genauigkeit der Position von ± 2 cm und der Ausrichtung von $\pm 0,03^\circ$ bei einer Abtastrate von $f_s = 500$ Hz erreicht werden. Die Referenzmesstechnik transformiert alle Messdaten in einen definierten Messpunkt, der mittig der IMU liegt. Die Positionsdaten werden dabei als geodätische Koordinaten zur Verfügung gestellt und müssen im Simulationsmodell in kartesische Koordinaten auf den Referenzpunkt mittig der Hinterachse transformiert werden. Die Messungen mit der Refe-

renzmess-technik wurden unter besten Bedingungen, d. h. mit ausreichend genauem GNSS- und LTE-Empfang, durchgeführt. Das montierte System ist in Abbildung 2.12 dargestellt.

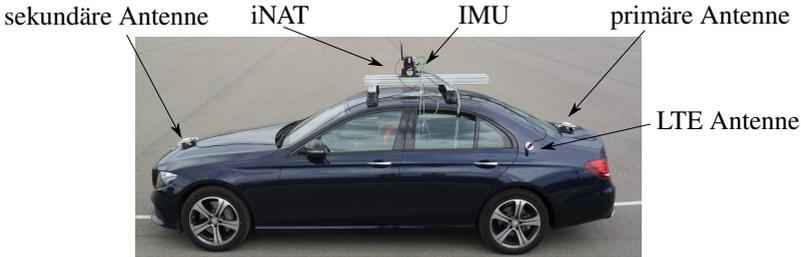


Abbildung 2.12: Aufbau des Referenzmesssystems auf dem Versuchsfahrzeug.

Die Antennen werden mithilfe von Saugnäpfen am Fahrzeug befestigt, während die IMU durch ITEM-Profile sicher mit dem Dachträger verbunden wird. Obwohl sich die IMU in dieser Anordnung nicht in der Nähe des Schwerpunkts oder des Drehpunkts des Fahrzeugs befindet, liefert die Referenzmesstechnik hochpräzise Messwerte. Um viele Testfahrten durchführen zu können, sind der mobile Einsatz und die schnelle Montage des Referenzmesssystems von entscheidender Bedeutung. Das Referenzmesssystem liefert die in Tabelle 2.4 aufgeführten Messgrößen und die durch die Koordinatentransformation berechneten Referenzwerte.

Koordinatentransformation

Um das Referenzmesssystem als Referenz für die Positionsmessung nutzen zu können, müssen die Positionsdaten des Messsystems transformiert werden. Dazu werden sie vom geodätischen Koordinatensystem¹⁵ K^{LLH} zuerst in das globale kartesische Koordinatensystem¹⁶ K^{ECEF} und dann in das lokale

¹⁵ LLH: geodätisches Koordinatensystem, LLH steht für Breitengrad (engl. LATITUDE), Längengrad (engl. LONGITUDE) und ellipsoidische Höhe (engl. HEIGHT). Die ellipsoidische Höhe beschreibt die Höhe der Erdoberfläche hinsichtlich einer Bezugsellipsoide mit Parametern des *World Geodetic System 1984* (WGS84).

¹⁶ ECEF: globales kartesisches Koordinatensystem (engl. EARTH-CENTERED-FIXED), liegt im Schwerpunkt der Erde, die Gravitationsbeschleunigung weist auf den Ursprung des Koordinatensystems.

Tabelle 2.4: Messgrößen und Referenzwerte des Referenzmesssystems.

Bezeichnung	Messwert	σ	Einheit	f_S [Hz]
Breitengrad	φ_k	NA	°	500
Längengrad	λ_k	NA	°	500
Geodätische Höhe	h_k	NA	m	500
Gierwinkel in NED	θ_k	$\pm 0,03$	°	500
Nickwinkel in NED	ψ_k	$\pm 0,26$	°	500
Rollwinkel in NED	ϕ_k	$\pm 0,33$	°	500
Geschwindigkeiten	v_k^{REF}	$\pm 0,04$	m/s	500
Drehraten	ω_k^{REF}	$\pm 0,07$	°/s	500
Position in x	$x_{\text{Ref},k}$	$\pm 0,020$	m	500
Position in y	$y_{\text{Ref},k}$	$\pm 0,020$	m	500
Ausrichtung	$\theta_{\text{Ref},k}$	$\pm 0,03$	°	500
Schwimmwinkel	$\beta_{\text{Ref},k}$	-	°	500
Längsgeschwindigkeit	$v_{\text{Ref},k}$	$\pm 0,04$	m/s	500
Gierrate	$\omega_{\text{Ref},k}$	$\pm 0,07$	°/s	500

kartesische Koordinatensystem¹⁷ K^{NED} nach Stevens [51] transformiert. Um die Referenz-Position \mathbf{p}^{REF} im Referenzkoordinatensystem K^{REF} zu erhalten, werden die NED-Koordinaten $\mathbf{p}^{\text{NED}}(t)$ zum jeweiligen Zeitpunkt t ins Fahrzeugkoordinatensystem K^{VEH} transformiert. Abbildung 2.13 zeigt die Zusammenhänge zwischen den Koordinatensystemen.

Um die Größen des Referenzmesssystems mit den Simulationsmodellen zu vergleichen, werden folgende Größen als Referenz-Bewegungszustände in einer zeitdiskreten Formulierung zusammengefasst:

$$\mathbf{x}_{\text{Ref},k} = \begin{bmatrix} x_{\text{Ref},k} \\ y_{\text{Ref},k} \\ \theta_{\text{Ref},k} \\ \beta_{\text{Ref},k} \\ v_{\text{Ref},k} \\ \omega_{\text{Ref},k} \end{bmatrix} = \begin{bmatrix} x_{\text{Ref}}^{\text{REF}}(t) - x_{\text{Ref}}^{\text{REF}}(t_0) \\ y_{\text{Ref}}^{\text{REF}}(t) - y_{\text{Ref}}^{\text{REF}}(t_0) \\ \theta_{\text{Ref}}^{\text{REF}}(t) - \theta_{\text{Ref}}^{\text{REF}}(t_0) \\ - \\ \sqrt{v_{\text{Ref},x}^{\text{VEH}}(t)^2 + v_{\text{Ref},y}^{\text{VEH}}(t)^2} \\ \omega_{\text{Ref},z}^{\text{VEH}}(t) \end{bmatrix}. \quad (2.28)$$

¹⁷ NED: lokales kartesisches Koordinatensystem (engl. NORTH-EAST-DOWN), fixiert in einen zu definierenden lokalen Referenzpunkt $\mathbf{p}^{\text{ECEF}}(t_0)$.

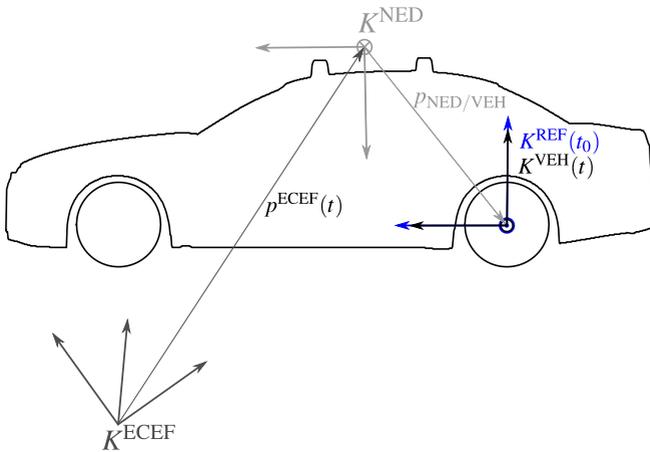


Abbildung 2.13: Zusammenhänge zwischen dem ECEF-, dem NED-, dem VEH- und dem REF-Koordinatensystem.

Beim Parkvorgang herrschen zu kleine Geschwindigkeiten, um den Schwimmwinkel über die Geschwindigkeiten durch $\arctan(v_{\text{Ref},y}/v_{\text{Ref},x})$ zu bestimmen. Es gibt kein zusätzliches Referenzmesssystem, mit dem der Schwimmwinkel direkt bestimmt werden kann, weshalb in diesem Beitrag kein Referenzschwimmwinkel $\beta_{\text{Ref},k}$ gebildet wird.

Abbildung 2.14 zeigt den Referenz-Bewegungszustand mit der Referenz-Position $\mathbf{p}_{\text{Ref},k}$, der Referenz-Ausrichtung $\theta_{\text{Ref},k}$, der Referenz-Geschwindigkeit in Richtung der Fahrzeuglängsachse $v_{\text{Ref},k}$ und der Referenz-Gierate $\omega_{\text{Ref},k}$. In der Abbildung sind zusätzlich die begrenzenden Fahrzeuge in Grau, der Bordstein dunkelgrau und eine Schneefläche hellgrau schraffiert. Diese wurden mit einer zusätzlichen mobilen DGNSS-Antenne vermessen und dienen der besseren Darstellung des Szenarios.

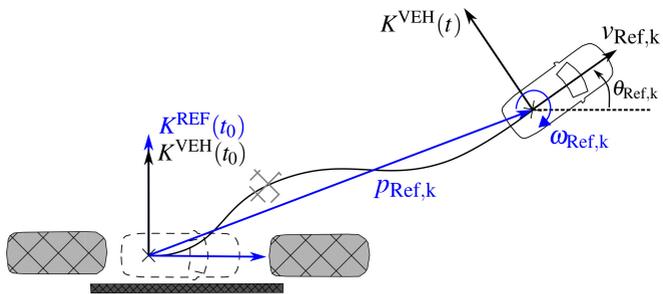


Abbildung 2.14: Zusammenhang zwischen dem VEH- und dem REF-Koordinatensystem.

3 Adaptiver Lokalisierungsfilter

Der in diesem Kapitel entwickelte adaptive Lokalisierungsfilter bildet den Kern des speziellen Fahrzeugbewegungsmodells für Parkanwendungen. Um diesen Filter zu beschreiben, werden der Bewegungszustand und die Differentialgleichung der Bewegung hergeleitet. Anschließend werden die verwendeten Fahrzeugbewegungsmodelle ausführlich erläutert und der Aufbau des Filters mit den Filteralgorithmen und Filtererweiterungen vorgestellt. Schließlich wird der Lokalisierungsfilter validiert und seine Lokalisierungsleistung beurteilt.

3.1 Bewegungsmodell

Zur Fahrzeuglokalisierung wird ein Bewegungszustand \mathbf{x}_k definiert, der die Bewegung des Fahrzeugs zum Zeitschritt k beschreibt¹⁸. Dieser beinhaltet die Trajektorie (häufig als Bahnkurve bezeichnet), bestehend aus der Position $\mathbf{p}_k = [x_k \ y_k]^T$ und der Ausrichtung θ_k in Bezug auf das Referenzkoordinatensystem K^{REF} . Zusätzlich wird im Bewegungszustand der kinematische Schwimmwinkel β_k , die Geschwindigkeit v_k und die Drehgeschwindigkeit ω_k des Fahrzeugs in Bezug auf das Fahrzeugkoordinatensystem K^{VEH} zusammengefasst. Der Bewegungszustand ergibt sich in der zeitdiskreten Formulierung wie folgt:

$$\mathbf{x}_k = \begin{bmatrix} x_k & y_k & \theta_k & \beta_k & v_k & \omega_k \end{bmatrix}^T \in \mathbb{R}^6. \quad (3.1)$$

Differentialgleichung der Bewegung

Um die Trajektorie des Fahrzeugs zu beschreiben, wird zunächst die Differentialgleichung der Bewegung hergeleitet. Abbildung 3.1 zeigt zur besseren

¹⁸ Im Folgenden werden Vektoren und Matrizen in Fettschrift dargestellt. Variablen mit einem darüberliegenden Strich bedeutet, dass alle Gleichungen mit allen Vektoren oder Matrizen gemittelt werden.

Veranschaulichung den Bewegungszustand und die Trajektorie des Fahrzeugs vom Zeitschritt k bis $k+1$.

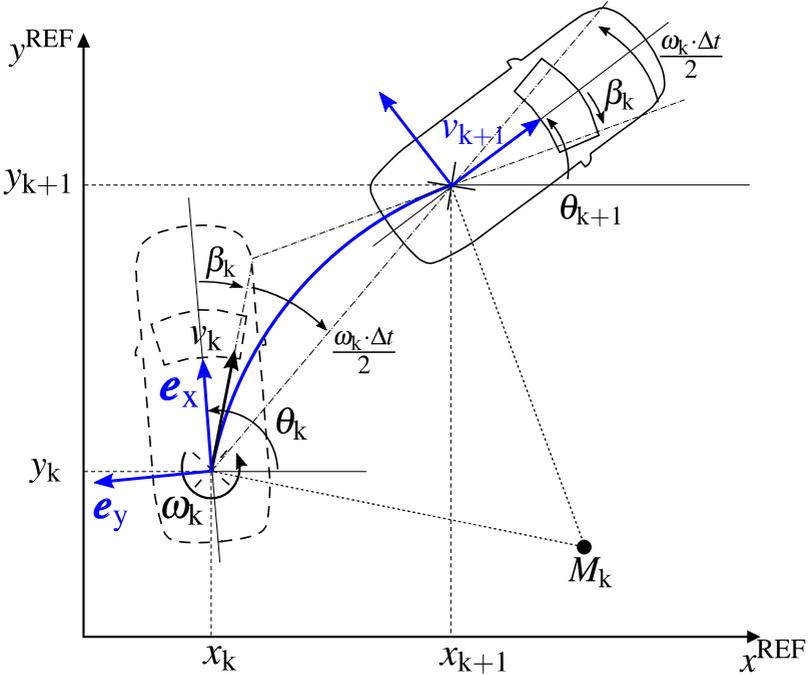


Abbildung 3.1: Bewegungszustand vom Zeitschritt k bis $k+1$.

Für das Bewegungsmodell wird die Position \mathbf{p} zunächst in einer zeitkontinuierlichen Formulierung $\mathbf{p}(t)$ hergeleitet und vereinfacht, anschließend wird sie in ein zeitdiskretes Zustandsraummodell \mathbf{p}_k transformiert. Im Referenzkoordinatensystem K^{REF} wird die Fahrzeugposition durch die Basisvektoren $\mathbf{e}_x, \mathbf{e}_y$ bestimmt. Diese befinden sich im Ursprung des Fahrzeugkoordinatensystems K^{VEH} und können durch die Ausrichtung des Fahrzeugs θ wie folgt beschrieben werden:

$$\mathbf{e}_x = \begin{bmatrix} \cos(\theta) \\ \sin(\theta) \end{bmatrix}, \quad \mathbf{e}_y = \begin{bmatrix} -\sin(\theta) \\ \cos(\theta) \end{bmatrix}. \quad (3.2)$$

Des Weiteren können die Basisvektoren verwendet werden, um den Geschwindigkeitsvektor \mathbf{v} zu bestimmen. Dieser wird um den kinematischen Schwimmwinkel β im Fahrzeugkoordinatensystem K^{VEH} gedreht und zeigt immer in Richtung der tatsächlichen Fahrzeugbewegung:

$$\begin{aligned}\mathbf{v} &= v_x \cdot \mathbf{e}_x + v_y \cdot \mathbf{e}_y \\ &= v \cdot \cos(\beta) \cdot \mathbf{e}_x + v \cdot \sin(\beta) \cdot \mathbf{e}_y\end{aligned}\quad (3.3)$$

$$= v \cdot \begin{bmatrix} \cos(\beta + \theta) \\ \sin(\beta + \theta) \end{bmatrix}.\quad (3.4)$$

Die Position \mathbf{p} lässt sich nun durch das Integral des Geschwindigkeitsvektors \mathbf{v} bestimmen:

$$\mathbf{p}(t) = \underbrace{p(t=0)}_{\mathbf{p}_0} + \underbrace{\int_{\tau=0}^{t'} \mathbf{v}(\tau) \cdot d\tau}_{\mathbf{p}' } + \underbrace{\int_{\tau=t'}^t \mathbf{v}(\tau) \cdot d\tau}_{\Delta \mathbf{p}}.\quad (3.5)$$

Für die Lösung des Integrals wird angenommen, dass die Bewegung während eines kleinen Zeitraums $\Delta t = t - t'$, also in $\tau \in [t', t)$, als konstante Kreisbahn, d. h. mit konstanter Geschwindigkeit und konstanter Winkelgeschwindigkeit, beschrieben werden kann. Für die Lösung des Integrals werden folgende Annahmen getroffen:

$$\begin{aligned}\beta(\tau) &= \beta = \text{const.}, \\ v(\tau) &= v = \text{const.}, \quad \dot{v}(\tau) = a(\tau) = 0, \\ \theta(\tau) &= \theta(t') + \omega \cdot \tau = \theta' + \omega \cdot \tau, \quad \dot{\theta}(\tau) = \omega = \text{const.}\end{aligned}\quad (3.6)$$

Die Positionsänderung $\Delta \mathbf{p}$ zwischen t' und t kann mithilfe des Geschwindigkeitsvektors \mathbf{v} und der Annahmen wie folgt berechnet werden:

$$\Delta \mathbf{p} = \int_{\tau=0}^{\Delta t} v \cdot \begin{bmatrix} \cos(\beta + \theta' + \omega \cdot \tau) \\ \sin(\beta + \theta' + \omega \cdot \tau) \end{bmatrix} \cdot d\tau.\quad (3.7)$$

Des Weiteren lässt sich die Positionsänderung $\Delta \mathbf{p}$ mithilfe von trigonometrischen Beziehungen und dem Bogen-Sehne-Faktor¹⁹ $B \approx 1$ wie folgt zusammenfassen:

$$\begin{aligned}
 \Delta \mathbf{p} &= \frac{v}{\omega} \cdot \begin{bmatrix} \sin(\beta + \theta' + \omega \cdot \Delta t) - \sin(\beta + \theta') \\ -\cos(\beta + \theta' + \omega \cdot \Delta t) + \cos(\beta + \theta') \end{bmatrix} \\
 &= v \cdot \begin{bmatrix} \cos(\beta + \theta' + \frac{\omega \cdot \Delta t}{2}) \\ \sin(\beta + \theta' + \frac{\omega \cdot \Delta t}{2}) \end{bmatrix} \cdot \frac{2 \cdot \sin(\frac{\omega \cdot \Delta t}{2})}{\omega} \\
 &= v \cdot \Delta t \cdot \begin{bmatrix} \cos(\beta + \theta' + \frac{\omega \cdot \Delta t}{2}) \\ \sin(\beta + \theta' + \frac{\omega \cdot \Delta t}{2}) \end{bmatrix} \cdot \underbrace{\frac{2 \cdot \sin(\frac{\omega \cdot \Delta t}{2})}{\Delta t \cdot \omega}}_B \\
 &\approx v \cdot \Delta t \cdot \begin{bmatrix} \cos(\beta + \theta' + \frac{\omega \cdot \Delta t}{2}) \\ \sin(\beta + \theta' + \frac{\omega \cdot \Delta t}{2}) \end{bmatrix}. \tag{3.8}
 \end{aligned}$$

Schließlich führt die Transformierung in eine zeitdiskrete Formulierung zu der folgenden Bewegungsgleichung, mit der die Fahrzeugbewegung beschrieben werden kann:

$$\begin{bmatrix} x_{k+1} \\ y_{k+1} \\ \theta_{k+1} \end{bmatrix} = \begin{bmatrix} x_k \\ y_k \\ \theta_k \end{bmatrix} + \begin{bmatrix} v_k \cdot \Delta t \cdot \cos(\beta_k + \theta_k + \frac{\omega_k \cdot \Delta t}{2}) \\ v_k \cdot \Delta t \cdot \sin(\beta_k + \theta_k + \frac{\omega_k \cdot \Delta t}{2}) \\ \omega_k \cdot \Delta t \end{bmatrix}. \tag{3.9}$$

3.2 Fahrzeugbewegungsmodelle

Durch Ableiten der Differentialgleichung der Bewegung lassen sich verschiedene Fahrzeugbewegungsmodelle ableiten, die den Bewegungszustand auf ihre spezifische Art und Weise berechnen. In dieser Arbeit werden diese Fahrzeugbewegungsmodelle als Messmodelle im Lokalisierungsfilter eingesetzt und dienen gleichzeitig als Vergleichsmodelle für den aktuellen Stand des Wissens.

¹⁹ Der Bogen-Sehne-Faktor B wird als das Verhältnis zwischen Kreissehne und Kreisbogen definiert. Bei einer Winkelgeschwindigkeit von 0,5 rad/s und einem Abtastzeitabstand von $\Delta t = 0,02$ s, was einer Kreisfahrt mit 36 km/h mit einem Durchmesser von 5 m entspricht, beträgt $B \approx 1,00000104 \approx 1$. Für $B = 1$ ist die Bewegungsgleichung für $\omega = 0$ wohldefiniert.

3.2.1 Kinematisches Zweispurmodell

Das *kinematische Zweispurmodell* Odo2Track wird als erstes Fahrzeugbewegungsmodell in dieser Arbeit hergeleitet. Dabei handelt es sich um ein kinematisches Zweispurmodell, das ausschließlich die beiden Radgeschwindigkeiten der starren Hinterachse zur Bestimmung der Position und Ausrichtung des Fahrzeugs nutzt. Diese Methode basiert auf dem Geschwindigkeitsdifferential, welches aus dem Bereich der Robotik [16–20] stammt und üblicherweise für die Berechnung der Fahrzeugbewegung in Parksystemen verwendet wird. Als Erweiterung wird in dieser Arbeit das *erweiterte kinematische Zweispurmodell* OdoExt2Track entwickelt, das von dem *nichtlinearen Zweispurmodell* aus der Arbeit von Vietinghoff [25] abgeleitet werden kann und alle vier unabhängigen Räder des Fahrzeugs verwendet. Durch Gleichsetzung der Geschwindigkeitsdifferentialen für alle sechs möglichen Radpaare²⁰ wird ein echtes Vierrad-Fahrzeugbewegungsmodell erzeugt. Abbildung 3.2 zeigt die Zusammenhänge zwischen dem bekannten Bewegungszustand \mathbf{x}_{k-1} und den Radgeschwindigkeiten $\bar{\mathbf{v}}_i$, die als maßgebliche Eingänge für das Fahrzeugbewegungsmodell verwendet werden.

Zur Herleitung wird zuerst der Geschwindigkeitsvektor eines einzelnen Rades $\bar{\mathbf{v}}_i$ im RAP $r_{i,x}, r_{i,y}$ durch den Zusammenhang zwischen dem Geschwindigkeitsvektor $\mathbf{v} \in \mathbb{R}^3$ und dem Drehratenvektor $\boldsymbol{\omega} \in \mathbb{R}^3$ des Fahrzeugs im Fahrzeugkoordinatensystem beschrieben:

$$\underbrace{\begin{bmatrix} \bar{v}_{i,x} \\ \bar{v}_{i,y} \\ 0 \end{bmatrix}}_{=:\bar{\mathbf{v}}_i} = \underbrace{\begin{bmatrix} v \cdot \cos(\beta) \\ v \cdot \sin(\beta) \\ 0 \end{bmatrix}}_{=:\mathbf{v}} + \underbrace{\begin{bmatrix} 0 \\ 0 \\ \boldsymbol{\omega} \end{bmatrix}}_{=:\boldsymbol{\omega}} \times \underbrace{\begin{bmatrix} r_{i,x} \\ r_{i,y} \\ 0 \end{bmatrix}}_{=:\mathbf{r}_i}. \quad (3.10)$$

²⁰ Ein Radpaar ist die Kombination von zwei unabhängigen Rädern. Bei vier Rädern können sechs Radpaare gebildet werden.

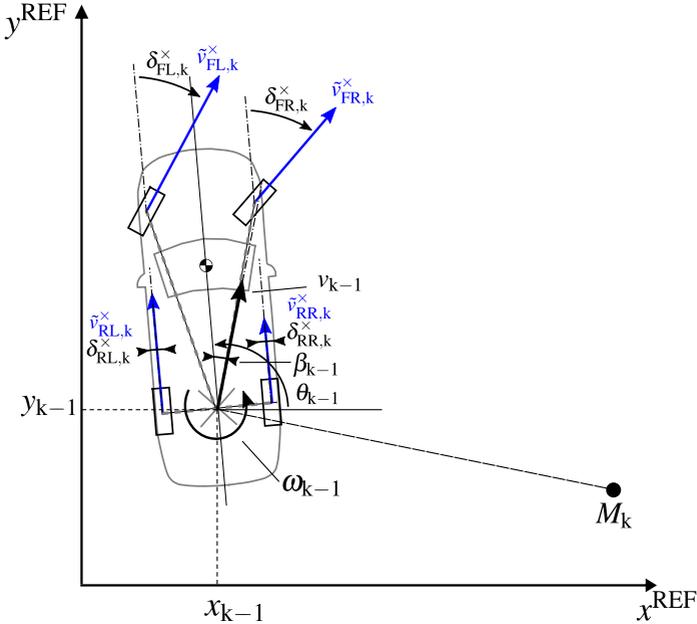


Abbildung 3.2: Eingänge des erweiterten kinematischen Zweispurmodells.

Für die Radgeschwindigkeit \tilde{v}_i ist nur die Komponente der Translationsbewegungsrichtung²¹ ausschlaggebend, die durch den Radlenkwinkel δ_i definiert ist. Die Radgeschwindigkeit \tilde{v}_i lässt sich wie folgt daraus ableiten:

$$\begin{aligned}
 \tilde{v}_i &= \bar{v}_{i,x} \cdot \cos(\delta_i) + \bar{v}_{i,y} \cdot \sin(\delta_i) \\
 &= v \cdot \cos(\delta_i) \cdot \cos(\beta) + v \cdot \sin(\delta_i) \cdot \sin(\beta) \\
 &\quad + \omega \cdot (r_{i,x} \cdot \sin(\delta_i) - r_{i,y} \cdot \cos(\delta_i)) \\
 &= v \cdot \cos(\delta_i - \beta) + \omega \cdot (r_{i,x} \cdot \sin(\delta_i) - r_{i,y} \cdot \cos(\delta_i)). \quad (3.11)
 \end{aligned}$$

Um mit der Methode des Geschwindigkeitsdifferentials aus zwei Geschwindigkeiten eine konstante Kreisbewegung abzuleiten, wird zunächst Gleichung (3.11) für zwei Radgeschwindigkeiten v_1, v_2 aufgestellt. Anschließend wer-

²¹ Die Translationsbewegungsrichtung entspricht der schräglaufwinkelreien Abrollrichtung des Rades.

den die Gleichungen nach ω umgeformt und gleichgesetzt. Die entstehende Gleichung wird wie folgt nach der Fahrzeuggeschwindigkeit v aufgelöst:

$$v = f(v_1, v_2) = \frac{r_{1,x} \cdot v_2 \cdot \sin(\delta_1) - r_{1,y} \cdot v_2 \cdot \cos(\delta_1) - r_{2,x} \cdot v_1 \cdot \sin(\delta_2) + r_{2,y} \cdot v_1 \cdot \cos(\delta_2)}{N}. \quad (3.12)$$

Werden beide Gleichungen zuerst nach der Fahrzeuggeschwindigkeit v umgestellt und gleichgesetzt, kann diese Gleichung nach der Gierrate ω aufgelöst werden:

$$\omega = f(v_1, v_2) = \frac{v_1 \cdot \cos(\delta_2 - \beta) - v_2 \cdot \cos(\delta_1 - \beta)}{N}. \quad (3.13)$$

In beiden Fällen lässt sich der Nenner N wie folgt zusammenfassen:

$$N = \frac{r_{1,x} \cdot \sin(\delta_1) \cdot \cos(\delta_2 - \beta) - r_{1,y} \cdot \cos(\delta_1) \cdot \cos(\delta_2 - \beta) - r_{2,x} \cdot \sin(\delta_2) \cdot \cos(\delta_1 - \beta) + r_{2,y} \cdot \cos(\delta_2) \cdot \cos(\delta_1 - \beta)}{1}. \quad (3.14)$$

Des Weiteren kann davon ausgegangen werden, dass sich der kinematische Schwimmwinkel β in Parkszenarien nur langsam ändert, weshalb er sich aus der vorherigen Trajektorie und einer Radgeschwindigkeit v_1 wie folgt berechnen lässt:

$$\beta = f(v_1) = \delta_1 - \arctan\left(\frac{v_1 - \omega \cdot (r_{1,x} \cdot \sin(\delta_1) - r_{1,y} \cdot \cos(\delta_1))}{v}\right). \quad (3.15)$$

Aus der Bewegungsgleichung (3.9) und den Geschwindigkeitsdifferentialen ergibt sich die Trajektorie des *erweiterten kinematischen Zweispurmodells* OdoExt2Track als zeitdiskretes Zustandsraummodell wie folgt:

$$\begin{bmatrix} x_k \\ y_k \\ \theta_k \\ \beta_k \\ v_k \\ \omega_k \end{bmatrix} = \begin{bmatrix} x_{k-1} + v_{k-1} \cdot \Delta t \cdot \cos(\beta_{k-1} + \theta_{k-1} + \frac{\omega_{k-1} \cdot \Delta t}{2}) \\ y_{k-1} + v_{k-1} \cdot \Delta t \cdot \sin(\beta_{k-1} + \theta_{k-1} + \frac{\omega_{k-1} \cdot \Delta t}{2}) \\ \theta_{k-1} + \omega_{k-1} \cdot \Delta t \\ \bar{\beta}(\check{\mathbf{v}}_k, \boldsymbol{\delta}_k, \mathbf{r}_x, \mathbf{r}_y, v_{k-1}, \omega_{k-1}) \\ \bar{v}(\check{\mathbf{v}}_k, \boldsymbol{\delta}_k, \mathbf{r}_x, \mathbf{r}_y, \beta_{k-1}) \\ \bar{\omega}(\check{\mathbf{v}}_k, \boldsymbol{\delta}_k, \mathbf{r}_x, \mathbf{r}_y, v_{k-1}) \end{bmatrix}, \quad (3.16)$$

wobei die Radgeschwindigkeiten \tilde{v}_k , die Radlenkwinkel δ_k und die RAPE r_x, r_y aller vier Räder jeweils als Vektoren zusammengefasst sind und die Zustände über alle möglichen Kombinationen gemittelt werden.

Ohne Betrachtung der Vorderachse und für ein Fahrzeug ohne Hinterachslenkung $\delta_R^\times = 0 \Rightarrow \delta_{RL}, \delta_{RR} = 0$ kann die Trajektorie zum *kinematischen Zweispurmodell* Odo2Track vereinfacht werden:

$$\begin{bmatrix} x_k \\ y_k \\ \theta_k \\ \beta_k \\ v_k \\ \omega_k \end{bmatrix} = \begin{bmatrix} x_{k-1} + v_{k-1} \cdot \Delta t \cdot \cos(\beta_{k-1} + \theta_{k-1} + \frac{\omega_{k-1} \cdot \Delta t}{2}) \\ y_{k-1} + v_{k-1} \cdot \Delta t \cdot \sin(\beta_{k-1} + \theta_{k-1} + \frac{\omega_{k-1} \cdot \Delta t}{2}) \\ \theta_{k-1} + \omega_{k-1} \cdot \Delta t \\ 0 \\ \frac{\tilde{v}_{RL,k}^\times + \tilde{v}_{RR,k}^\times}{2} \\ \frac{\tilde{v}_{RR,k}^\times - \tilde{v}_{RL,k}^\times}{(r_{RR,y} - r_{RL,y})} \end{bmatrix}. \quad (3.17)$$

3.2.2 Kinematisches Einspurmodell

Als Nächstes wird das *kinematische Einspurmodell* Odo1Track entwickelt, das von dem bekanntesten Fahrzeugbewegungsmodell, dem *linearen Einspurmodell* [26], abgeleitet ist. Es verwendet die Richtung der Geschwindigkeitsvektoren, die mittig an den Achsen liegen. Die Translationsbewegung wird durch die Durchschnittsgeschwindigkeit der Hinterräder und die Rotationsbewegung durch die Schwimmwinkel $\beta_j \in (-\frac{\pi}{2}, \frac{\pi}{2})$ der jeweiligen Achse j bestimmt. Diese sind als wahre Achslenkwinkel zu verstehen. Der Schwimmwinkel β wird aus dem Lenkwinkel δ und dem Schräglaufwinkel α gebildet: $\beta = \delta + \alpha$. Abbildung 3.3 zeigt die Zusammenhänge zwischen dem bekannten Bewegungszustand \mathbf{x}_{k-1} und dem Schwimmwinkel β_j , die als Eingänge für das Fahrzeugbewegungsmodell berücksichtigt werden:

Zur Herleitung wird der Zusammenhang verwendet, dass bei der Rotation des Fahrzeugs der Geschwindigkeitsvektor $\mathbf{v} \in \mathbb{R}^3$, der Längenvektor²² $\mathbf{r}_{RM} \in \mathbb{R}^3$ und der Drehratenvektor $\boldsymbol{\omega} \in \mathbb{R}^3$ orthogonal zueinander stehen:

$$\mathbf{v} = \boldsymbol{\omega} \times \mathbf{r}_{RM} \Rightarrow \|\mathbf{v}\| = \|\boldsymbol{\omega} \times \mathbf{r}_{RM}\| \Leftrightarrow \omega = \frac{v}{r_{RM}}. \quad (3.18)$$

²² Der Längenvektor $\mathbf{r}_{RM} \in \mathbb{R}^3$ verläuft geradlinig zwischen dem Momentanpol und dem Ursprung des Fahrzeugkoordinatensystems, welcher sich am Mittelpunkt der Hinterachse befindet.

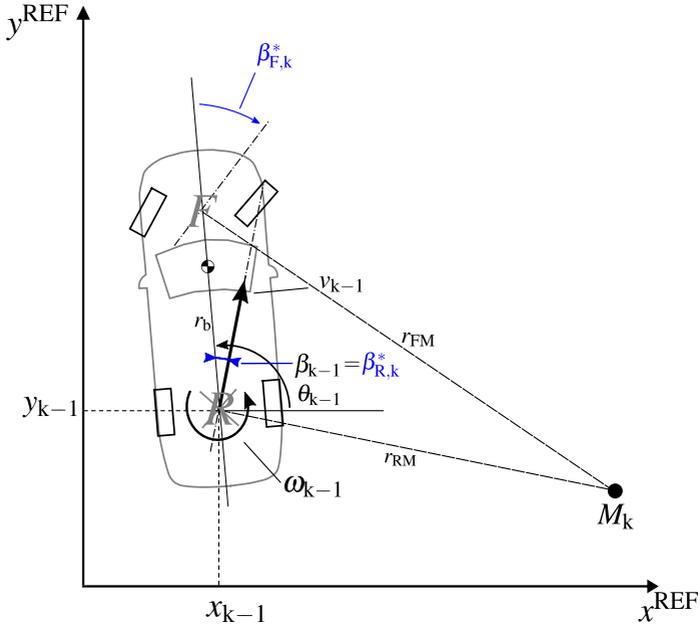


Abbildung 3.3: Eingänge des *kinematischen Einspurmodells*.

Der Abstand zum Momentanpol des Fahrzeugs r_{RM} errechnet sich aus der Projektion des Dreiecks (F, R, M) mithilfe des Radstandes r_b und des Kosinussatzes:

$$r_{RM} = r_b \cdot \cos\left(\frac{\pi}{2} + \beta_R\right) + r_{FM} \cdot \cos(\beta_F - \beta_R). \quad (3.19)$$

Mithilfe des Sinussatzes und durch Ersetzen von r_{FM} mit $r_b \cdot \frac{\sin(\frac{\pi}{2} + \beta_R)}{\sin(\beta_F - \beta_R)}$ ergibt sich:

$$r_{RM} = r_b \cdot \left(\cos\left(\frac{\pi}{2} + \beta_R\right) + \frac{\sin\left(\frac{\pi}{2} + \beta_R\right)}{\tan(\beta_F - \beta_R)} \right). \quad (3.20)$$

Durch die Symmetrien von Sinus und Kosinus folgt weiterhin:

$$r_{RM} = r_b \cdot \left(\frac{1}{\cos(\beta_R) \cdot (\tan(\beta_F) - \tan(\beta_R))} \right). \quad (3.21)$$

Gleichung (3.21) kann dann in Gleichung (3.18) eingesetzt werden, um folgenden Ausdruck für die Gierrate des Fahrzeugs ω zu erhalten:

$$\omega = \frac{v}{r_b} \cdot \cos(\beta_R) \cdot (\tan(\beta_F) - \tan(\beta_R)). \quad (3.22)$$

Zusätzlich ergibt sich für ein Fahrzeug ohne Hinterachslenkung $\delta_R^\times = 0 \Rightarrow \beta_R = 0$, die einfache Form als:

$$\omega = \frac{v}{r_b} \cdot \tan(\beta_F). \quad (3.23)$$

Für das Messmodell im Lokalisierungsfilter wird später der vordere Schwimmwinkel β_F benötigt, der durch Umformen von Gleichung (3.22) gebildet werden kann:

$$\beta_F = \arctan \left(\frac{\omega \cdot r_b}{v \cdot \cos(\beta_R)} + \tan(\beta_R) \right). \quad (3.24)$$

Für das *kinematische Einspurmodell* Odo1Track wird der meist unbekannt vordere Achsschräglaufwinkel $\alpha_F = 0$ gesetzt und es gilt: $\delta_F^\times = \beta_F$. Für ein Fahrzeug ohne Hinterachslenkung gilt weiter: $\delta_R^\times = \beta_R = \alpha_R = 0$. Mithilfe der Bewegungsgleichung (3.9) und der geometrischen Berechnung der Schwimmwinkel ergibt sich das folgende zeitdiskrete Zustandsraummodell:

$$\begin{bmatrix} x_k \\ y_k \\ \theta_k \\ \beta_k \\ v_k \\ \omega_k \end{bmatrix} = \begin{bmatrix} x_{k-1} + v_{k-1} \cdot \Delta t \cdot \cos(\beta_{k-1} + \theta_{k-1} + \frac{\omega_{k-1} \cdot \Delta t}{2}) \\ y_{k-1} + v_{k-1} \cdot \Delta t \cdot \sin(\beta_{k-1} + \theta_{k-1} + \frac{\omega_{k-1} \cdot \Delta t}{2}) \\ \theta_{k-1} + \omega_{k-1} \cdot \Delta t \\ 0 \\ \frac{\tilde{v}_{RL,k}^\times + \tilde{v}_{RR,k}^\times}{2} \\ \frac{v_{k-1}}{r_b} \cdot \tan(\delta_{F,k}^\times) \end{bmatrix}. \quad (3.25)$$

Das *korrigierte kinematische Einspurmodell* Odo1Track* wird eingeführt, weil die Schwimmwinkel durch Fehler in der Radstellung (dem sogenannten Ackermannfehler [27]) und durch elastische Eigenschaften, die in Abhängigkeit von der Fahrtrichtung wirken, beeinflusst werden. Deshalb werden die Schwimmwinkel unter Berücksichtigung dieser Faktoren korrigiert, und zwar mithilfe der rollrichtungsabhängig korrigierten kinematischen Schwimmwin-

kel $\beta_j^*(\delta_F^\times, \delta_R^\times, d^\times, An_{Konz})$ (vgl. Abschnitt 2.3.2). Es ergibt sich das folgende zeitdiskrete Zustandsraummodell:

$$\begin{bmatrix} x_k \\ y_k \\ \theta_k \\ \beta_k \\ v_k \\ \omega_k \end{bmatrix} = \begin{bmatrix} x_{k-1} + v_{k-1} \cdot \Delta t \cdot \cos(\beta_{k-1} + \theta_{k-1} + \frac{\omega_{k-1} \cdot \Delta t}{2}) \\ y_{k-1} + v_{k-1} \cdot \Delta t \cdot \sin(\beta_{k-1} + \theta_{k-1} + \frac{\omega_{k-1} \cdot \Delta t}{2}) \\ \theta_{k-1} + \omega_{k-1} \cdot \Delta t \\ \beta_{R,k}^* \\ \frac{\bar{v}_{RL,k}^\times + \bar{v}_{RR,k}^\times}{2} \\ \frac{v_{k-1}}{r_b} \cdot \cos(\beta_{R,k}^*) \cdot (\tan(\beta_{F,k}^*) - \tan(\beta_{R,k}^*)) \end{bmatrix}. \quad (3.26)$$

3.2.3 Kinematisches Gierratenmodell

Das letzte Fahrzeugbewegungsmodell stammt aus dem Bereich der Trägheitsnavigation und wird vom *Inertialsensormodell* abgeleitet. Das für den Parkvorgang konstruierte *kinematische Gierratenmodell* OdoYawRate [29] verwendet die von dem Sensorcluster des ESP gemessene Gierrate ω^\times als Information der Rotation. Für die Translationsbewegung verwendet das Modell die Durchschnittsgeschwindigkeit der Hinterräder. Abbildung 3.4 zeigt die Zusammenhänge zwischen dem bekannten Bewegungszustand \mathbf{x}_{k-1} und der gemessenen Gierrate ω^\times , die als Eingangsvariable für das Fahrzeugbewegungsmodell berücksichtigt wird:

Für ein Fahrzeug ohne Hinterachslenkung $\delta_R^\times = 0$ ergibt sich das folgende zeitdiskrete Zustandsraummodell:

$$\begin{bmatrix} x_k \\ y_k \\ \theta_k \\ \beta_k \\ v_k \\ \omega_k \end{bmatrix} = \begin{bmatrix} x_{k-1} + v_{k-1} \cdot \Delta t \cdot \cos(\beta_{k-1} + \theta_{k-1} + \frac{\omega_{k-1} \cdot \Delta t}{2}) \\ y_{k-1} + v_{k-1} \cdot \Delta t \cdot \sin(\beta_{k-1} + \theta_{k-1} + \frac{\omega_{k-1} \cdot \Delta t}{2}) \\ \theta_{k-1} + \omega_{k-1} \cdot \Delta t \\ 0 \\ \frac{\bar{v}_{RL,k}^\times + \bar{v}_{RR,k}^\times}{2} \\ \omega_k^\times \end{bmatrix}. \quad (3.27)$$

3.3 Aufbau des Lokalisierungsfilters

Um eine robuste und präzise Positionsbestimmung zu ermöglichen, werden die vorgestellten Fahrzeugbewegungsmodelle nun über einen Lokalisierungs-

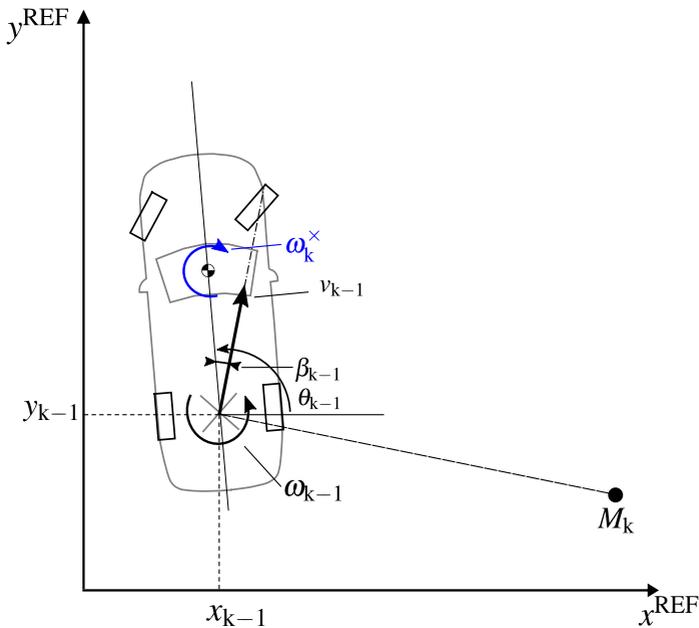


Abbildung 3.4: Eingänge des kinematischen Gierratenmodells.

filter zusammengeführt. Dazu werden in diesem Abschnitt verschiedene Bayes-Filteralgorithmen verglichen.

3.3.1 Filteralgorithmen

Durch die Verwendung von Filtern besteht die Möglichkeit, das Problem der Zusammenführung von Zustandsinformationen und Messungen erfolgreich zu lösen. Der wohl bekannteste Filteralgorithmus ist der²³ Kalman-Filter. Er eignet sich gut für die Implementierung in Echtzeit, da er rekursiv arbeitet. Der Kalman-Filter besteht aus zwei Phasen: In der ersten Phase, der Prädiktionsphase, werden die Zustände des Prozesses und ihre jeweiligen Kovarianzen geschätzt. In der zweiten Phase, der Innovationsphase, wird die Vorhersage anhand der Messungen angepasst. Die Filteralgorithmen gehen

²³ Im technischen Kontext wird oft die neutrale Form "das Filter" verwendet. In dieser Arbeit wird jedoch die männliche Form "der Filter" aus dem alltäglichen Sprachgebrauch genutzt.

davon aus, dass sowohl der Prozess als auch die Messungen durch Rauschen verfälscht werden. Das Rauschen wird als Nullmittelwert und durch eine GNV angenommen. Es bestimmt, wie sehr der Filter der Prädiktion auf Basis des Systemmodells und der Messmodellkorrektur auf Basis des Messmodells vertraut. Es gibt verschiedene Filteralgorithmen zur Implementierung des Lokalisierungsfilters, die jeweils dasselbe Systemmodell und Messmodell verwenden. Das Buch „Optimal State Estimation: Kalman, H Infinity, and Nonlinear Approaches“ [52] von Simon gilt als ausgezeichnete Einführung in die Filteralgorithmen.

3.3.1.1 Formulierung des Problems

Damit die Filtergleichungen in Echtzeit auf dem Steuergerät ausgeführt werden können, müssen sie in diskreter Form vorliegen. Der Filter geht davon aus, dass sich der Zustand \mathbf{x}_k eines Systems linear aus dem vorherigen Zustand im Zeitschritt $k - 1$ entwickelt:

$$\begin{aligned}\mathbf{x}_k &= \mathbf{f}(\mathbf{x}_{k-1}, \mathbf{u}_k) + \mathbf{q}_{k-1}, \\ \mathbf{z}_k &= \mathbf{h}(\mathbf{x}_k, \mathbf{u}_k) + \mathbf{r}_k,\end{aligned}\tag{3.28}$$

wobei der Eingangsvektor \mathbf{u}_k , das Systemmodell $\mathbf{f}(\cdot)$ und das Prozessrauschen \mathbf{q}_{k-1} bekannt sind. Für den Innovationsschritt stehen der Messvektor \mathbf{z}_k , das Messmodell \mathbf{H} und der Messrauschvektor \mathbf{r}_k fest. Das mittelwertfreie Rauschen wird durch die Prozess-Kovarianzmatrix $\mathbf{Q}_k := E(\mathbf{q}_k \cdot \mathbf{q}_k^T)$ und die Messkovarianzmatrix $\mathbf{R}_k := E(\mathbf{r}_k \cdot \mathbf{r}_k^T)$ angenähert. Der wahre Zustand \mathbf{x}_k des Systems kann nicht direkt gemessen werden. Der Filter liefert eine Schätzung der Systemzustände $\hat{\mathbf{x}}_k$. Diese wird erzeugt, indem die Systemvorhersage mit den verfälschten Messungen des Rauschens aus Zufallsvariablen mit einem entsprechenden Mittelwert und einer Varianz kombiniert wird. Die Varianz der Zustände und die entsprechende Kovarianz dazwischen werden durch die Matrix $\mathbf{P}_k = E[(\mathbf{x}_k - \hat{\mathbf{x}}_k) \cdot (\mathbf{x}_k - \hat{\mathbf{x}}_k)^T]$ bestimmt, die der Filter für jede Iteration berechnet. Die Diagonaleinträge sind die Varianzen der Zustände und die Off-Diagonaleinträge sind die Kovarianzen zwischen den Zuständen. Der Filter versucht, rekursiv optimale Werte für diese Zustands-Kovarianzmatrix \mathbf{P}_k zu finden, wobei $\hat{\mathbf{x}}_k^-$ die *A-priori*-Schätzung des Zustandes, basierend auf dem Systemmodell, ist und \mathbf{P}_k^- die *A-priori*-Aktualisierung der Kovarianzmatrix, basierend auf dem System und der Prozess-Kovarianzmatrix

\mathbf{Q}_k . Der Filter berechnet die *A-posteriori*-Schätzung $\hat{\mathbf{x}}_k$ des Zustandsvektors, wobei der gemessene Messvektor \mathbf{z}_k mit der Schätzung der Messung $\hat{\mathbf{z}}_k$ verglichen wird. Dieser Vergleich wird *Innovation* genannt. Die *A-posteriori*-Kovarianzmatrix \mathbf{P}_k wird schließlich berechnet, um sie im nächsten Schritt wiederverwenden zu können. Die in dieser Arbeit verwendeten Filteralgorithmen sind in Anhang A.2 zusammengefasst. Eine Bewertung der verschiedenen Filteralgorithmen für das gegebene Problem wird im Folgenden beschrieben.

3.3.1.2 Extended-Kalman-Filter (EKF)

Der Kalman-Filter ist nicht in der Lage, nichtlineare Systeme genau zu schätzen, da er auf der Annahme der Linearität basiert. Um das Problem der Schätzung des Systemzustands eines nichtlinearen diskreten Zeitsystems zu lösen, wird der EKF eingesetzt. Dabei wird die Taylor-Linearisierung erster Ordnung genutzt, um Vorhersagen über die zukünftige Prozess-Kovarianz zu treffen. Dies geschieht durch die Berechnung der partiellen Ableitungen der Prozessfunktion \mathbf{F}_k und der Messfunktion \mathbf{H}_k . Während der Innovationsphase des Filters wird die Kalman-Verstärkung \mathbf{K}_k eingesetzt, um den Anteil der Innovationsupdates zu bestimmen. Obwohl der EKF eine Annäherung der optimalen Bedingungen für den linearen Fall berechnet, kann dies aufgrund der nichtlinearen Systemdynamik zur Instabilität oder sogar zur Divergenz der geschätzten Zustände führen. Um die Herausforderungen eines nichtlinearen Systemmodells besser zu bewältigen, kann der UKF eingesetzt werden.

3.3.1.3 Unscented-Kalman-Filter (UKF)

Im UKF wird die nichtlineare Ausbreitung der GNV durch Verwendung einer Unscented-Transformation behandelt. Dabei wird die GNV approximiert, indem ein minimaler Satz sorgfältig ausgewählter Stichprobenpunkte, auch bekannt als Sigma-Punkte, verwendet wird. Diese Punkte erfassen den wahren Mittelwert des nichtlinearen Systemmodells und die Kovarianzen werden durch Approximation mit der dritten Taylor-Reihe erfasst. Im Gegensatz zum EKF-Algorithmus müssen im UKF keine Jacobimatrizen für das System erstellt werden. Die Ableitung dieser Matrizen kann bei unkomplexen Systemmodellen analytisch durchgeführt werden, jedoch kann die Aufgabe bei zunehmender Komplexität des verwendeten Systemmodells sehr anspruchsvoll werden und die Matrizen müssen oft numerisch approximiert werden. Der UKF bietet daher den Vorteil, dass die Jacobimatrizen nicht

benötigt werden.

Auffallend am EKF und am UKF ist, dass in der Innovationsphase die Messkovarianz \mathbf{R}_k in jedem Berechnungsschritt invertiert werden muss. Dies kann zu numerischen Problemen führen, wenn Messungen ausgeschlossen werden sollen, da theoretisch die Kovarianzwerte $\Rightarrow \infty$ eingestellt werden müssen. Eine mögliche Lösung wäre, die Länge des Messvektors \mathbf{z}_k in jedem Schritt anzupassen. Allerdings können hierbei in einigen Programmiersprachen Probleme bei der Implementierung auf dem Steuergerät auftreten, da sich die Größe der Vektoren und Matrizen dynamisch ändert.

Der Informationsfilter bietet hingegen eine vielversprechendere Option.

3.3.1.4 Extended-Information-Filter (EIF)

Der EIF basiert auf dem EKF und verwendet den Informationszustand, um das Innovationsupdate durchzuführen. Zu Beginn des Filters wird eine Transformation der Informationen durchgeführt, bei der der Zustandsvektor und die Kovarianzmatrix invertiert werden.

Ein Vorteil dieses Filters ist, dass bei zeitinvarianten Systemen, bei denen $\mathbf{R}_k = \mathbf{R}$ gilt, die Inversion von \mathbf{R}_k nur einmal erfolgen muss. Wenn die Messkovarianzen bekannt und unveränderlich sind, kann \mathbf{R} einmal invertiert werden. Danach können die Diagonaleinträge von \mathbf{R}^{-1} auf 0 gesetzt werden, um bestimmte Messungen auszuschließen.

3.3.1.5 Unscented-Information-Filter (UIF)

Zum Schluss erfolgt die Bewertung des UIF. Dieser verwendet wie der UKF die Approximation mit der dritten Taylor-Reihe, kombiniert jedoch die Vorteile der Informationsfilter mit einer präziseren Approximation durch die Sigma-Punkte.

In der Fusion verschiedener Fahrzeugbewegungsmodelle eignen sich Informationsfilter theoretisch besonders gut, da ihr Algorithmus rechnerisch einfacher ist als der Kalman-Filter. Eine Studie von N. Assimakis [53] zeigt, dass der Aufwand für Informationsfilter sinkt, wenn die Länge des Zustandsvektors weniger als 0,75-mal die Länge des Messvektors beträgt. Informationsfilter haben auch den Vorteil, dass keine Invertierung der Messkovarianzmatrix erforderlich ist. Das bedeutet, dass die Messeingänge über die Koeffizienten auf null gesetzt werden können, was zu einer einfachen Anpassung der

Eingänge für den Lokalisierungsfilter führt. Daher ist es wichtig zu überprüfen, welcher Filteralgorithmus für die Aufgabe des Lokalisierungsfilters am besten geeignet ist. Demzufolge wurden in dieser Arbeit alle vorgestellten Filteralgorithmen implementiert.

Ergebnisse hinsichtlich der verschiedenen **Filteralgorithmen**:

- Die in dieser Arbeit beschriebene standardisierte Form ermöglicht eine einfache Implementierung der verschiedenen Filteralgorithmen.
- Die Filteralgorithmen mit Linearisierung auf Basis der Unscented Transformation liefern eine genaue Annäherung.
- Die Informationsfilter eignen sich zur Fusion, wenn die Länge des Zustandsvektors weniger als $0,75 \times$ der Länge des Messvektors beträgt.
- Die Informationsfilter ermöglichen eine einfache Anpassung der Messingänge, da die Einträge der Messkovarianz \mathbf{R}^{-1} durch Koeffizientenwerte einfach auf 0 gesetzt werden können.

3.3.2 Modellierung

Zur Schätzung der Bewegungszustände eines Fahrzeugs werden unterschiedliche Fahrzeugbewegungsmodelle zusammengeführt. Der Lokalisierungsfilter prognostiziert den nächsten Bewegungszustand mithilfe des Systemmodells. Die Fusion der Modelle findet im Messmodell statt. Um das Verfahren zu verstehen, werden im Folgenden der Zustand sowie das System- und das Messmodell definiert.

3.3.2.1 Definition des Zustands

Der Zustand des Lokalisierungsfilters kommt aus dem Bewegungsmodell aus Kapitel 3.1 und entspricht dem Bewegungszustand. Es gilt:

$$\mathbf{x}_k = \begin{bmatrix} x_k & y_k & \theta_k & \beta_k & v_k & \omega_k \end{bmatrix}^T \in \mathbb{R}^6. \quad (3.29)$$

3.3.2.2 Definition des Systemmodells

Für den Lokalisierungsfilter wird in dieser Arbeit eine Architektur gewählt, bei der das verwendete Systemmodell $f(\cdot)$ in der Vorhersagephase nur den vorherigen Zustand \mathbf{x}_{k-1} zur Berechnung des aktuellen Zustands \mathbf{x}_k verwendet, er ist daher wie folgt definiert:

$$\mathbf{x}_k = \mathbf{f}(\mathbf{x}_{k-1}). \quad (3.30)$$

Der Vorteil dieses Systemmodells besteht darin, dass es nicht direkt auf Störungen reagiert und ein einfach zu bedienender gewichteter Mittelwertschätzer resultiert. Überdies können unabhängige Messungen hinzugefügt oder entfernt werden, ohne das Modell zu beeinflussen. Das Systemmodell verwendet ausschließlich die Bewegungsgleichung (3.9):

$$\mathbf{f}(\mathbf{x}_{k-1}) = \begin{bmatrix} x_{k-1} \\ y_{k-1} \\ \theta_{k-1} \\ \beta_{k-1} \\ v_{k-1} \\ \omega_{k-1} \end{bmatrix} + \begin{bmatrix} v_{k-1} \cdot \Delta t \cdot \cos(\beta_{k-1} + \theta_{k-1} + \frac{\omega_{k-1} \cdot \Delta t}{2}) \\ v_{k-1} \cdot \Delta t \cdot \sin(\beta_{k-1} + \theta_{k-1} + \frac{\omega_{k-1} \cdot \Delta t}{2}) \\ \omega_{k-1} \cdot \Delta t \\ 0 \\ 0 \\ 0 \end{bmatrix}. \quad (3.31)$$

Die Zustände β_k , v_k und ω_k werden vom Systemmodell in der Prädiktionsphase nicht aktualisiert und bleiben konstant. Die Aktualisierung erfolgt in der Innovationsphase durch das Messmodell.

3.3.2.3 Definition des Messmodells

In der Innovationsphase bestimmt das Messmodell $h(\cdot)$ den Messvektor \mathbf{z} unter Verwendung des prädizierten Zustands \mathbf{x}_k und des Eingangs \mathbf{u}_k . Das Modell verarbeitet somit neue Informationen über die Fahrzeugbewegung durch Verwendung der Eingangsvariablen \mathbf{u}_k :

$$\mathbf{z}_k = \mathbf{h}(\mathbf{x}_k, \mathbf{u}_k). \quad (3.32)$$

Abbildung 3.5 fasst den bekannten Bewegungszustand \mathbf{x}_{k-1} und alle relevanten Messeingänge zusammen, die im Lokalisierungsfilter verwendet werden:

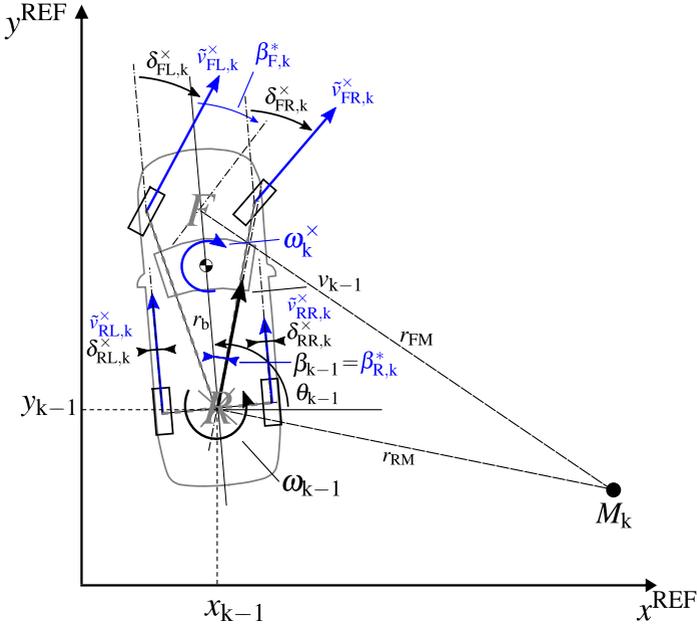


Abbildung 3.5: Eingänge des Messmodells.

Im Lokalisierungsfilter sind alle Informationen über die Bewegungen der einzelnen Fahrzeugbewegungsmodelle integriert. Das *erweiterte kinematische Zweispurmodell* OdoExt2Track wird durch den Radgeschwindigkeitsvektor $\vec{v}_k^{\times} \in \mathbb{R}^4$ aus Gleichung (3.11) berücksichtigt. Um für die anderen Fahrzeugbewegungsmodelle eine unabhängige Geschwindigkeitsmessung zu gewährleisten, wird zusätzlich die mittlere Geschwindigkeit \vec{v}_k^* hinzugefügt. Das *korrigierte kinematische Einspurmodell* Odo1Track* wird unter Verwendung der korrigierten Schwimmwinkel $\beta_{j,k}^*$ berücksichtigt. Das *kinematische Gierratenmodell* OdoYawRate wird mithilfe der gemessenen Gierrate ω_k^{\times} integriert. Daraus ergibt sich der folgende Messvektor für den Lokalisierungsfilter:

$$\mathbf{z}_k = \left[\vec{v}_k^{\times} \quad \vec{v}_k^* \quad \omega_k^{\times} \quad \beta_{F,k}^* \quad \beta_{R,k}^* \right]^T \in \mathbb{R}^8.$$

Die mittlere Geschwindigkeit \tilde{v}_k^* wird als die Durchschnittsgeschwindigkeit der Hinterräder definiert und wie folgt berechnet:

$$\tilde{v}_k^* = \frac{\tilde{v}_{\text{RL},k}^\times + \tilde{v}_{\text{RR},k}^\times}{2}. \quad (3.33)$$

Das Messmodell $\mathbf{h}(\cdot)$ setzt sich aus den formelmäßigen Zusammenhängen zwischen den einzelnen Fahrzeugbewegungsmodellen wie folgt zusammen:

$$\mathbf{h}(\mathbf{x}_k, \mathbf{u}_k) = \begin{bmatrix} v_k \cdot \cos(\boldsymbol{\delta}_k - \beta_k) + \omega_k \cdot (\mathbf{r}_{x,k} \cdot \sin(\boldsymbol{\delta}_k) - \mathbf{r}_{y,k} \cdot \cos(\boldsymbol{\delta}_k)) \\ v_k \\ \omega_k \\ \hat{\beta}_{\text{F},k} \\ \beta_k \end{bmatrix}, \quad (3.34)$$

$$\hat{\beta}_{\text{F},k} = \begin{cases} \arctan\left(\frac{\omega_k \cdot r_{\text{F}}}{v_k \cdot \cos(\beta_k)} + \tan(\beta_k)\right) & \text{if } v_k \neq 0 \\ \beta_k & \text{else} \end{cases}.$$

Für die Geschwindigkeit $v_k = 0$ ist der berechnete vordere Schwimmwinkel $\beta_{\text{F},k}$ nicht definiert, sodass eine Fallunterscheidung getroffen wird. Als Eingänge des Messmodells \mathbf{u}_k dienen der Radlenkwinkelvektor $\boldsymbol{\delta}_k \in \mathbb{R}^4$ (vgl. Abschnitt 2.3.2) und die RAPE in x^{VEH} -Richtung $\mathbf{r}_{x,k} \in \mathbb{R}^4$ sowie in y^{VEH} -Richtung $\mathbf{r}_{y,k} \in \mathbb{R}^4$ (vgl. Abschnitt 2.2.2). Der Eingangsvektor \mathbf{u}_k ist somit definiert als:

$$\mathbf{u}_k = \begin{bmatrix} \boldsymbol{\delta}_k & \mathbf{r}_{x,k} & \mathbf{r}_{y,k} \end{bmatrix}^T \in \mathbb{R}^{12}. \quad (3.35)$$

Der Lokalisierungsfilter arbeitet ohne Eingabe in der Prädiktionsphase und nutzt ausschließlich Informationen des vorherigen Zustands. Während der Innovationsphase erfolgt die Eingabe durch das nichtlineare Messmodell. Dadurch kann die Anzahl der Messungen angepasst werden, ohne das Systemmodell zu beeinträchtigen. Der Filter kann das Messmodell anpassen und die Fahrzeugbewegungsmodelle ändern, ohne die Stabilität zu verlieren. Dabei werden redundante Messungen abgeschaltet, um Fehlfunktionen zu vermeiden. Ferner kann die Anzahl der Messungen erweitert werden, wenn sich das Sensorset und das Messmodell ändern, wie in der Offenlegung [O3] beschrieben.

Ergebnisse hinsichtlich der **Modellierung des Lokalisierungsfilters**:

- Der Lokalisierungsfilter fusioniert verschiedene Fahrzeugbewegungsmodelle, welche eine Modellierung von vierradgelenkten Fahrzeugen ermöglichen.
- Das nichtlineare Systemmodell hat keinen Eingang und verwendet in der Prädiktionsphase nur den vorherigen Zustand. Der Eingang erfolgt während der Innovationsphase durch das entsprechende nichtlineare Messmodell, sodass die Anzahl der Messungen angepasst werden kann, ohne den Betrieb des Systemmodells zu beeinträchtigen.
- Der Aufbau erlaubt es, das Messmodell anzupassen und gleichzeitig die Zusammensetzung der Fahrzeugbewegungsmodelle zu verändern. Das Messmodell macht es einfach, zusätzliche Sensoren und Modelle zur Erweiterung hinzuzufügen.

3.3.3 Filtereinstellungen

Eine der größten Herausforderungen im Bereich der Systemmodellierung ist die Filtereinstellung (auch Filtertuning genannt). Da Modellierungen nie perfekt sind und das reale System durch das Modell nur angenähert wird, ist es wichtig, abzuschätzen, wie genau die Dynamik des realen Systems erfasst werden kann. Die Abstimmung der oben genannten Filter erfolgt mithilfe der Prozessrauschen-Kovarianzmatrix \mathbf{Q}_k und der Messkovarianzmatrix \mathbf{R}_k . Die Prozessrauschen-Kovarianzmatrix \mathbf{Q}_k gibt an, inwieweit dem Systemmodell des Filters vertraut wird. Wenn z. B. ein vereinfachtes Modell im Filter verwendet wird, können die Werte der Prozessrauschen-Kovarianzmatrix \mathbf{Q}_k erhöht und somit der Filter adaptiert werden, indem der Vorhersage weniger vertraut wird. Für die Filtereinstellung ist in der Regel die Beziehung zwischen der Prozessrauschen-Kovarianzmatrix \mathbf{Q}_k und der Messkovarianzmatrix \mathbf{R}_k ausschlaggebend²⁴. In dieser Arbeit werden die Filter in folgenden Schritten eingestellt:

²⁴ In der Veröffentlichung [V2] zum SA-RAKPE wurde eine andere Form der Modellierung des Kalman-Filters verwendet. Die Standardabweichung für das Systemmodell wurde dazu zwischen einer Kovarianzmatrix, bezogen auf den Zustand \mathbf{Q} , und einer Kovarianzmatrix, bezogen auf den Eingang \mathbf{T} , aufgeteilt. In dieser Arbeit werden aus Gründen der Übersicht-

1. Die Startkovarianz \mathbf{P}_0 gibt an, wie groß die Startfehler der Zustände sind. Diese sind entscheidend für das Einschwingverhalten des Filters. Für den Lokalisierungsfilter gilt eine Startkovarianz $\mathbf{P}_0 = \mathbf{Q}$ als gute Annäherung.
2. Das Sensorrauschen wird aus der Sensorspezifikation der Hersteller bzw. anhand der Fehlermodelle (vgl. Kapitel 2) bestimmt.
3. Das Messrauschen \mathbf{R} wird durch Modellierung aus dem Sensorrauschen abgeleitet (vgl. Tabelle 2.1 und 2.3).
4. Das Prozessrauschen \mathbf{Q} wird durch modellbasierte Messungen ermittelt und anschließend empirisch angepasst (vgl. Tabelle 2.1 und 2.3).
5. Um möglichen Stabilitätsproblemen der Filteralgorithmen vorzubeugen und die Leistung zu verbessern, werden in dieser Arbeit adaptive Filtererweiterungen entwickelt.

Die Grund-Filtereinstellung des Lokalisierungsfilters wird wie folgt definiert:

$$\begin{aligned}\mathbf{P}_0 = \mathbf{Q} &= \text{diag} \left(\left[\begin{array}{cccccc} \sigma_{x,y}^2 & \sigma_{x,y}^2 & \sigma_{\theta}^2 & \sigma_{\beta}^2 & \sigma_{v,f}^2 & \sigma_{\omega,f}^2 \end{array} \right] \right), \\ \mathbf{R} &= \text{diag} \left(\left[\begin{array}{cccccccc} \sigma_{v,h}^2 & \sigma_{v,h}^2 & \sigma_{v,h}^2 & \sigma_{v,h}^2 & \sigma_{v,h}^2 & \sigma_{\omega,h}^2 & \sigma_{\beta_F}^2 & \sigma_{\beta_R}^2 \end{array} \right] \right).\end{aligned}\tag{3.36}$$

Die diagonalen Matrizen $\text{diag}([\])$ enthalten die quadratischen Standardabweichungen σ , die in Kapitel 2 erarbeitet wurden und in Tabelle 3.1 zusammengefasst sind.

3.4 Adaptive Filtererweiterung

Um den Lokalisierungsfilter adaptiv anzupassen, werden verschiedene Filtererweiterungen entwickelt, die den Messeingang adaptiv schalten und damit das Fahrzeugbewegungsmodell anpassen können. Bei einem Kalman-Lokalisierungsfilter ist die Anpassung komplexer: Um die Messung der Radgeschwindigkeit ab einer gewissen Radschlupfgrenze ignorieren zu können, müssen die Standardabweichungen der Messkovarianzmatrix \mathbf{R}_k theoretisch

lichkeit die Standardabweichungen in einer gemeinsamen Prozessrauschen-Kovarianzmatrix \mathbf{Q} zusammengefasst.

Tabelle 3.1: Standardabweichung σ der Kovarianzmatrizen.

Variable	Wert	Einheit	Beschreibung
$\sigma_{x,y}$	$\pm 1 \cdot 10^{-5}$	m	Positionsfehler
σ_{θ}	$\pm 1 \cdot 10^{-5}$	°	Ausrichtungsfehler
σ_{β}	$\pm 1 \cdot 10^{-4}$	°	Schwimmwinkelfehler
$\sigma_{v,f}$	$\pm 2 \cdot 10^{-3}$	m/s	Geschwindigkeitsfehler
$\sigma_{\omega,f}$	$\pm 3 \cdot 10^{-3}$	°/s	Gierratenfehler
$\sigma_{\bar{v},h}$	$\pm 1 \cdot 10^{-2}$	m/s	Geschwindigkeitsrauschen
$\sigma_{\omega,h}$	$\pm 1 \cdot 10^{-1}$	°/s	Gierratenrauschen
σ_{β_F}	$\pm 4 \cdot 10^{-1}$	°	Rauschen des vorderen Schwimmwinkels
σ_{β_R}	$\pm 4 \cdot 10^{-1}$	°	Rauschen des hinteren Schwimmwinkels

auf den Wert ∞ gesetzt werden. In der Praxis wird oft ein hoher Wert wie 10^6 verwendet, wodurch numerische Fehler entstehen können. Eine Alternative besteht in diesem Fall darin, die Länge des Messvektors n_z und damit die Länge der Vektoren und Matrizen der Innovationsphase in jedem Berechnungsschritt anzupassen, um die falsche Geschwindigkeitsmessung zu ignorieren. Diese zusätzliche Logik stellt sicher, dass der Kalman-Lokalisierungsfilter keine numerischen Fehler produziert. Da sich die Vektor- und Matrizenlängen dynamisch ändern können, müssen jedoch spezielle Mechanismen angewandt werden, um die Implementierungen auf dem Steuergerät entsprechend anzupassen. Im Rahmen dieser Arbeit werden die Kalman-Lokalisierungsfilter erweitert, um sie mit den Informations-Lokalisierungsfiltern zu vergleichen. Da die Logik zur Anpassung der Informations-Lokalisierungsfilter besser veranschaulicht werden kann, wird diese im Folgenden näher erläutert.

Der Informationsfilter verwendet die invertierte Messkovarianzmatrix \mathbf{R}^{-1} wodurch eine Messung mit dem Wert 0 effektiv ignoriert werden kann, ohne dass numerische Fehler auftreten. Die Länge des Messvektors n_z ist zudem konstant. Deshalb wird die Berechnung der adaptiven, zeitabhängigen Informationskovarianzmatrix \mathbf{R}_k^{-1} mithilfe der zeitabhängigen Koeffizientenmatrizen $\mathbf{\Lambda}_k$, $\mathbf{\Pi}_k$ und \mathbf{Z}_k erweitert:

$$\mathbf{R}_k^{-1} = \mathbf{R}^{-1} \cdot \mathbf{\Lambda}_k \cdot \mathbf{\Pi}_k \cdot \mathbf{Z}_k. \quad (3.37)$$

Diese Formulierung minimiert den Gesamtrechenaufwand, da die Invertierung der Informationskovarianzmatrix \mathbf{R}_k^{-1} nur einmal durchgeführt werden muss und somit der Rechenaufwand weitestgehend konstant bleibt. Die Diagonaleinträge der Koeffizientenmatrizen beschreiben den Anteil der in den Lokalisierungsfilter eingegebenen Informationen, wobei ein Wert von 0,01 einem Faktor von $10\times$ weniger Vertrauen und ein Wert von 100 einem Faktor von $10\times$ mehr Vertrauen in die Messung entspricht. Die zeitabhängigen Koeffizientenmatrizen dienen der dynamischen Anpassung des Lokalisierungsfilters und sind leicht erweiterbar. Die im Rahmen dieser Arbeit entwickelten Filteranpassungen durch die Koeffizientenmatrix werden in den folgenden Absätzen näher erläutert.

3.4.1 Bewegungszustandsabhängige Anpassung

Die erste Koeffizientenmatrix Λ_k beinhaltet die bewegungszustandsabhängige Abstimmung des Lokalisierungsfilters. Die Abbildungen 3.6 und 3.7 zeigen die geschätzten Bewegungszustände des Lokalisierungsfilters und die entsprechenden Messungen während eines 30 s dauernden Einparkvorgangs. Zum Vergleich werden die Werte des Referenzmesssystems aus Gleichung (2.28) blau dargestellt. Die bewegungszustandsabhängige Filtergenerierung wirkt möglichen Stabilitätsproblemen des Filteralgorithmus entgegen. Die bewegungszustandsabhängige Abstimmung ist mit einem grauen Hintergrund gekennzeichnet.

Die Informationskovarianzmatrix \mathbf{R}_k^{-1} wird durch Λ_k bewegungszustandsabhängig angepasst. Die geschätzte Position x, y und die Ausrichtung θ liegen nahe an der Referenz und zeigen ein ruhiges Verhalten. Die geschätzte Geschwindigkeit v und die Gierrate ω des Fahrzeugs liegen ebenfalls in der Nähe der Referenz, schwanken aber mit zunehmender Amplitude stärker. Dies wird durch die Bestimmung nach der Methode des Geschwindigkeitsdifferentials des *erweiterten kinematischen Zweispurmodells* Odo2Track verursacht. Der Quantisierungsfehler der DWPCs w_i^x aus Gleichung (2.14) kommt gerade bei kleinen Geschwindigkeiten zum Tragen. Der geschätzte vordere Schwimmwinkel β_F^* schwingt auch bei niedrigen Geschwindigkeiten stark, da in Gleichung (3.34) die Geschwindigkeit im Nenner steht. Der Einfluss wird jeweils durch die bewegungszustandsabhängige Koeffizientenmatrix Λ_k gefiltert. Der geschätzte hintere Schwimmwinkel β_R^* zeigt ein leicht träges Verhalten, da die Schätzung durch die Methode des Geschwin-

digkeitsdifferentials mehr Informationen berücksichtigt als die Messung der korrigierten Schwimmwinkel β_R^* .

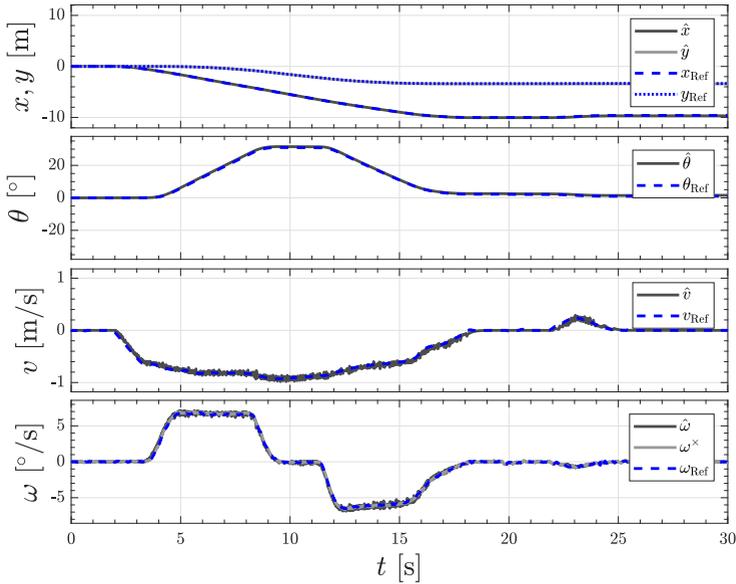


Abbildung 3.6: Zustände des Lokalisierungsfilters beim Parkvorgang.

Die bewegungszustandsabhängige Filtereinstellung kann mit der Koeffizientenmatrix Λ_k wie folgt zusammengefasst werden:

$$\Lambda_k = \text{diag} \left(\begin{array}{l} (1:4) \\ (5) \\ (6) \\ (7) \\ (8) \end{array} = \begin{array}{l} \left\{ \begin{array}{ll} 1 \cdot 10^{-2} & \text{if } \|v_k\| < 0,1 \text{ m/s} \\ 1 & \text{else} \end{array} \right. \\ 1 \\ 1 \\ \left\{ \begin{array}{ll} 0 & \text{if } \|v_k\| < 0,1 \text{ m/s} \\ 1 & \text{else} \end{array} \right. \\ 1 \end{array} \right) \in \mathbb{R}^{8 \times 8}. \quad (3.38)$$

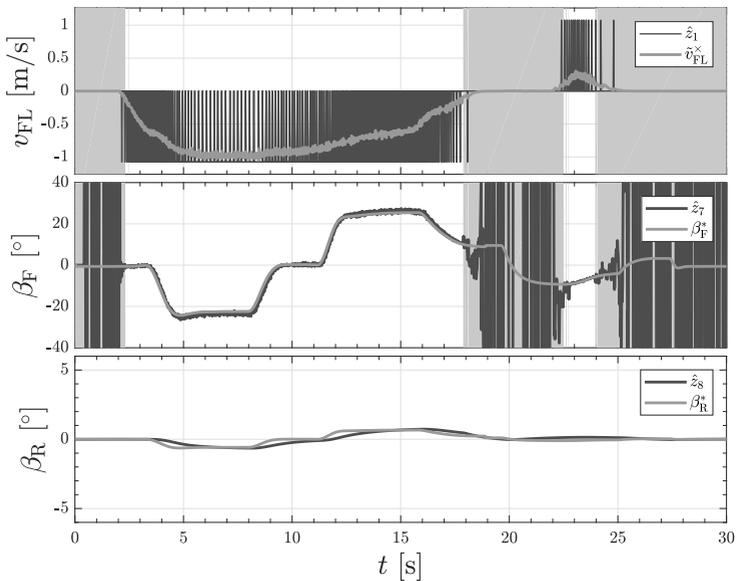


Abbildung 3.7: Messungen des Lokalisierungsfilters beim Parkvorgang. Die bewegungszustandsabhängige Abstimmung ist mit einem grauen Hintergrund gekennzeichnet.

Ergebnisse hinsichtlich der **bewegungszustandsabhängigen Anpassung:**

- Der Quantisierungsfehler macht sich mit kleinen Geschwindigkeiten bemerkbar.
- Die Schwimmwinkel schwingen bei niedrigen Geschwindigkeiten stark.
- Eine Filterung der Effekte sorgt für stabile Schätzungen.

3.4.2 Radschlupfabhängige Anpassung

Um sicherzustellen, dass der Lokalisierungsfilter auf schlupfende Räder reagieren kann, wird der Slip-Detection-Algorithm (SDA) entwickelt. Radschlupf kann an jedem Rad durch die Umfangskraft verursacht werden und stellt einen unsystematischen Fehler dar²⁵. Der Lokalisierungsfilter reduziert den Einfluss von systematischen und unsystematischen Fehlern, indem er redundante Messungen fusioniert. Um den Einfluss von durchdrehenden Rädern auf die Positionsbestimmung zu minimieren, ist es notwendig, den Radschlupf zu erkennen und bei zu hohem Schlupf die Messungen des betroffenen Rads auszuschließen. Der Lokalisierungsfilter kann trotz minimaler Verwendung von nur einem rollenden Rad funktionieren, indem redundante Informationen fusioniert werden. Eine Logik wird entwickelt, die bis zu drei schlupfende Räder erkennen kann und einen booleschen Vektor \mathbf{S}_k liefert, der angibt, ob die Räder schlupfen. Um die Messungen der schlupfenden Räder auszuschließen, wird daher die Koeffizientenmatrix $\mathbf{\Pi}_k$ wie folgt definiert:

$$\mathbf{\Pi}_k = \text{diag} \left(\left[\text{not}(\mathbf{S}_k) \ 1 \ 1 \ 1 \ 1 \right] \right) \in \mathbb{R}^{8 \times 8}. \quad (3.39)$$

Schlupft ein Rad, wird die entsprechende Messung des Radgeschwindigkeitsvektors $\hat{\mathbf{v}}_k^x \in \mathbb{R}^4$ durch die radschlupfabhängige Anpassung aktiv herausgenommen.

3.4.2.1 Slip-Detection-Algorithm (SDA)

Der in dieser Arbeit verwendete SDA wurde bereits in der Veröffentlichung [V1] vorgestellt. Daher wird er hier nur methodisch erläutert und bewertet. Der Radschlupf wird als Geschwindigkeitsdifferenz zwischen der Radgeschwindigkeit und der Fahrzeuggeschwindigkeit im Verhältnis zur Fahrzeuggeschwindigkeit definiert. Die Messungen im Rahmen dieser Arbeit haben gezeigt, dass während eines Parkvorgangs ein durchdrehendes Rad, das ver-

²⁵ Der Fehler, der durch Radschlupf verursacht wird, ist unsystematisch, da er nicht auf vorhersehbare oder wiederholbare Faktoren zurückzuführen ist. Systematische Fehler können in den Modellen und Algorithmen des Lokalisierungsfilters berücksichtigt und kalibriert werden, während unsystematische Fehler unvorhersehbar sind und an jedem Rad durch Umstände wie Straßenzustand ausgelöst werden können.

nachlässigt werden sollte, ab einer Schlupfabweichung von 12 % erkannt werden kann. Daher wird die Radschlupferkennung wie folgt definiert:

$$\mathbf{S} = \begin{cases} true & \text{if } \left\| \frac{v_i^{WHL} - v^{VEH}}{v^{VEH}} \right\| > 12\%, \\ false & \text{else .} \end{cases} \quad (3.40)$$

Der SDA benötigt als Eingangsvariable einen Vektor mit den normierten DWPCs \mathbf{W}_i . Diese Normierung erfolgt durch die Berücksichtigung der geschätzten Abrollumfänge c_i und der RAPE $\mathbf{r}_{i,k}(\delta_F^\times, \delta_R^\times)$ auf den Referenzpunkt mittig an der Hinterachse:

$$W_{i,k} = w_{i,k}^\times \cdot \frac{c_{\text{default}}}{c_{\text{default}} + \Delta c_i} \cdot \frac{\|\mathbf{r}_{RM,k}\|}{\|\mathbf{r}_{i,k}(\delta_F^\times, \delta_R^\times) - \mathbf{r}_{RM,k}\|}. \quad (3.41)$$

Die Funktionsweise des SDA besteht darin, die normierten DWPCs jedes Rades mit dem Mittelwert der Abweichung zu den anderen Rädern und der Standardabweichung zu vergleichen. Liegt einer der Werte außerhalb des Grenzwertes, wird Radschlupf erkannt. Schlupfen mehr als zwei Räder, wird unterschieden, ob es sich um einen Anfahr- oder einen Abbremsvorgang handelt. Beim Abbremsen wird angenommen, dass unabhängig von der Antriebsart durch die Anti-Schlupf-Regelung (ASR) immer das Rad mit der höchsten Geschwindigkeit schlupffrei abrollt. Beim Anfahren wird angenommen, dass bei Fahrzeugen mit nur einer angetriebenen Achse die Räder der nichtangetriebenen Achse abrollen. Beim 4x4-Fahrzeug wird angenommen, dass das Rad mit der niedrigsten Geschwindigkeit schlupffrei abrollt. Als Ausgang liefert der SDA einen booleschen Vektor für den Schlupf \mathbf{S}_k der einzelnen Räder:

$$\mathbf{S}_k = \text{SDA}(\mathbf{W}_k) \in \mathbb{R}^4. \quad (3.42)$$

Abbildung 3.8 zeigt die Berechnungswerte des SDA, wenn sich die rechte Seite des 4x2-Versuchsfahrzeugs auf einer reibungsarmen Oberfläche befindet. Wird ein Radschlupf $> 12\%$ festgestellt, wird dies durch die Hintergrundfarbe angezeigt.

Die beiden obigen Abbildungen zeigen die DWPCs W_i und die gleitenden Mittelwerte \bar{W}_i . Durch die Mittelung wird eine bessere Leistung erreicht, da der Quantisierungsfehler der DWPCs einen geringeren Einfluss hat. Blockierende Räder und damit Radschlupf wird ab 9,6 s vorne rechts und ab 10,1 s hinten rechts erkannt, da die Abweichung von DWPCs $\Delta \bar{W}_i$ die Schwelle

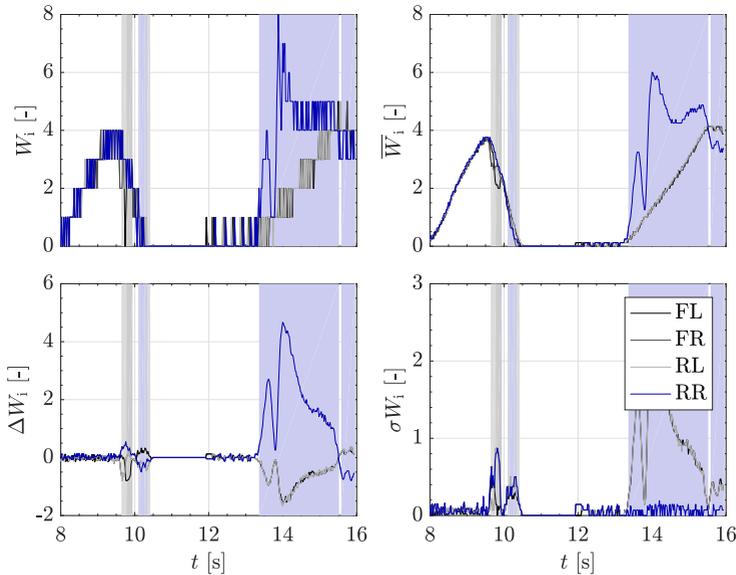


Abbildung 3.8: Signalverläufe der Berechnungsgrößen des SDA. Erkannter Radschlupf wird durch die Hintergrundfarbe markiert.

$\Delta \bar{W}_{\min}$ überschreitet und die Standardabweichung σW_i innerhalb der Schwelle σW_{\max} bleibt. Ab 12,4 s wird der Anfahradschlupf am hinteren rechten Rad erkannt.

3.4.2.2 Ergebnis des Lokalisierungsfilters mit SDA

Abbildung 3.9 zeigt die Trajektorien des Lokalisierungsfilters mit und ohne SDA für Messfahrten, bei denen das Fahrzeug auf einer teilweise schneebedeckten Fläche fährt. Der ermittelte Radschlupf wird in Schwarz und der Referenzradschlupf in Blau an der Position des RAP angezeigt. Der Referenzradschlupf wird über die Referenzgeschwindigkeit des Referenzmesssystems bestimmt. In den Abbildungen sind die Schneeflächen als hellgraue Schraffur dargestellt.

Die beiden oberen Abbildungen zeigen das Ergebnis des SDA beim Abbremsen. Der Lokalisierungsfilter (OdoFilter) mit SDA weist hier eine adäquate Leistung auf. Das Odo2Track schneidet in der rechten Abbildung besser ab,

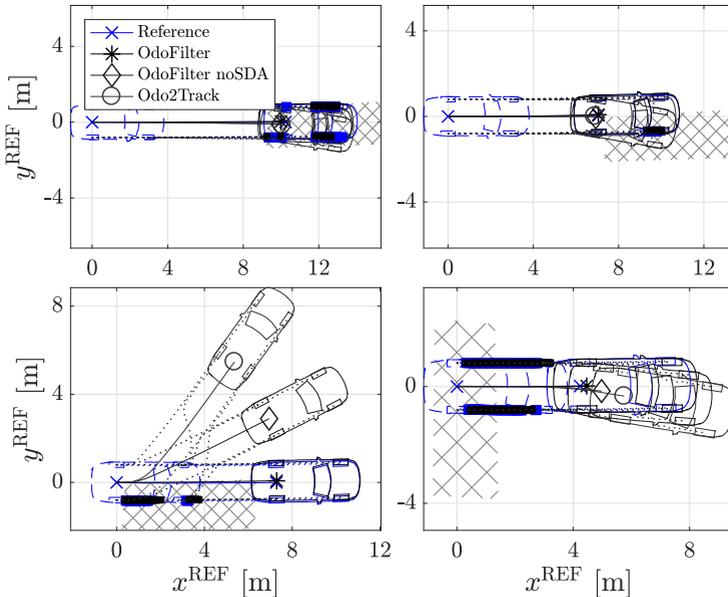


Abbildung 3.9: Trajektorien des Lokalisierungsfilters mit und ohne SDA von 4 unterschiedlichen Messfahrten auf teilweise schneebedeckter Fahrbahn.

weil es nur die Radgeschwindigkeiten der Hinterachse verwendet und ein Blockieren der Vorderachse keine Auswirkung hat.

Die beiden unteren Abbildungen zeigen das Ergebnis des SDA beim Anfahren. Der Lokalisierungsfilter (OdoFilter) mit SDA zeigt hier ebenfalls eine adäquate Leistung. Der Lokalisierungsfilter ohne SDA (OdoFilter noSDA) weist im Vergleich zum Odo2Track etwa 50 % des Ausrichtungsfehlers beim Anfahren mit Radschlupf auf. Dies ist auf die Multisensordatenfusion zurückzuführen, die die Geschwindigkeitsinformation aller vier Räder verwendet. Es wird deutlich, dass insbesondere die Ausrichtungsgenauigkeit durch den SDA erhöht werden kann.

Der SDA in Kombination mit der Filtererweiterung im adaptiven Lokalisierungsfilter erreicht eine adäquate Leistung und macht den Lokalisierungsfilter robust gegen unsystematische Fehler. Falls in Zukunft eine DGNSS-

Geschwindigkeit im Fahrzeug zur Verfügung steht, könnte der SDA auch diese verwenden, wie in der Offenlegung [O14] beschrieben. Dadurch würde es eine noch höhere Robustheit geben und der Radschlupf könnte bereits ab einem niedrigeren Radschlupfgrenze erkannt werden.

Ergebnisse hinsichtlich der **radschlupfabhängigen Anpassung**:

- Der Radschlupf lässt sich durch einen Vergleich der Radgeschwindigkeiten und deren Standardabweichungen durch den Slip-Detection-Algorithm (SDA) bestimmen.
- Die Empfindlichkeit kann mit den Parametern der Geschwindigkeits- und der Standardabweichungsdifferenz eingestellt werden.
- Der adaptive Lokalisierungsfilter mit SDA zeigt eine deutlich bessere Leistung, insbesondere bezüglich der Ausrichtungsgenauigkeit.

3.4.3 Fahrzeugbewegungsmodellabhängige Anpassung

Um den Lokalisierungsfilter komplett frei einzustellen, kann über die fahrzeugbewegungsmodellabhängige Koeffizientenmatrix \mathbf{Z}_k zwischen den einzelnen Fahrzeugbewegungsmodellen umgeschaltet werden, genauer gesagt, es können verschiedene Kombinationen eingestellt werden. Diese Anpassung wird später im Kapitel 6 in der Optimierung verwendet, um den Lokalisierungsfilter für verschiedene Parkszenarien optimal einstellen zu können.. Die fahrzeugbewegungsmodellabhängige Koeffizientenmatrix \mathbf{Z}_k ist durch den Koeffizientenvektor $\boldsymbol{\zeta}_k$ wie folgt definiert:

$$\mathbf{Z}_k = \text{diag} \left(\left[\boldsymbol{\zeta}_k \right] \right) \in \mathbb{R}^{8 \times 8}. \quad (3.43)$$

Die Tabelle 3.2 zeigt die Vektoren der jeweiligen Fahrzeugbewegungsmodelle des aktuellen Stands der Technik und die Informationsinhalte für die Längsbewegung n_v sowie die Drehbewegung n_ω . Dies gibt einen Hinweis darauf, wie hoch die Redundanz des verwendeten Fahrzeugbewegungsmodells ist:

Das OdoExt2Track kann auf sechs verschiedene Arten berechnet werden, je nachdem, welche Radkombinationen ausgewählt werden, und hat damit

Tabelle 3.2: Koeffizientenvektor ζ_k für die Konfiguration unterschiedlicher Fahrzeugbewegungsmodelle.

Fahrzeugbewegungsmodelle	Vektor ζ_k	n_v	n_ω
OdoFilter	11111111	6	8
Odo2Track	00110000	1	1
OdoExt2Track	11110000	6	6
Odo1Track*	00001011	1(2)	1
OdoYawRate	00001100	1(2)	1

die höchste Redundanz. Die Modelle Odo1Track* und OdoYawRate haben nicht mehr Redundanz als das Odo2Track, wenn allerdings eine Geschwindigkeitsmessung fehlerhaft ist, sind sie robuster, da die Informationen der Translations- und der Rotationsbewegung unabhängig voneinander sind.

Um die Robustheit des Lokalisierungsfilters zu steigern, kann die fahrzeugbewegungsmodellabhängige Koeffizientenmatrix für die adaptive Einstellung in Abhängigkeit von den Fahrzuständen angepasst werden. Die Idee zur Anpassung des Bewegungsmodells an die Fahrsituation wurde bereits in der Offenlegung [O2] beschrieben. In der Offenlegung [O8] wurde zusätzlich die Methode zur Generierung der Modellgewichtung in Abhängigkeit von der Fahrsituation dargestellt. Die Anwendung dieser Methoden erlaubt die in Kapitel 6 angewandte automatisierte Optimierung des Lokalisierungsfilters.

3.5 Validierung des Lokalisierungsfilters

Um die Leistung des entwickelten Lokalisierungsfilters zu bewerten, werden die Ergebnisse verschiedener Testfahrten ausgewertet, die einen großen Teil der spezifizierten Szenarien²⁶ abdecken. Damit kann objektiv nachgewiesen werden, dass die Anforderungen des Lokalisierungsfilters erfüllt werden. Das Versuchsfahrzeug ist mit dem Referenzmesssystem aus Abschnitt 2.4 ausgestattet. Zunächst erfolgt die Auswahl des am besten geeigneten Filteralgorithmus für die Implementierung auf einem Steuergerät. Dabei wird darauf geachtet, die vorhandenen Rechenressourcen möglichst effizient zu nutzen.

²⁶ In dieser Arbeit wird der Ansatz verfolgt, nicht die spezifizierten Auslegungsbereiche zu untersuchen, sondern anwendungsnah zu testen. Daher wird bei der Überprüfung der Parkqualität des Lokalisierungsfilters und der Vergleichsmodelle anstelle von Verifizierung der Begriff Validierung verwendet.

Anschließend wird die Lokalisierungsleistung für die spezifizierte Odometrietestszenarien²⁷ und Parkmanöver²⁸ im Vergleich zu den konventionellen Fahrzeugbewegungsmodellen untersucht. Dafür wird eine Sensitivitätsanalyse durchgeführt, um den Leistungsgewinn des Lokalisierungsfilters im Fehlerfall zu demonstrieren. Die konventionellen Fahrzeugbewegungsmodelle dienen als Vergleichsmodelle für den Stand des Wissens.

3.5.1 Beurteilung des Rechenressourcenbedarfs

Zum Vergleich des Rechenressourcenbedarfs wird die MATLAB Tic-Toc-Methode²⁹ zur Laufzeitmessung verwendet, bei der ein Stoppuhrtimer durch den Befehl Tic gestartet und durch den Befehl Toc gestoppt wird. Die Methode misst die interne Rechenzeit während der Ausführung der Algorithmen auf einem Messrechner mit einer Taktfrequenz von 3,4 Hz und 32 GB RAM im Single-Core-Modus. Abbildung 3.10 zeigt die Simulationszeiten *toc* der verschiedenen Implementierungen der Lokalisierungsfilter (OdoEKF, OdoUKF, OdoEIF, OdoUIF) und der Vergleichsmodelle (Odo2Track, Odo1Track*, OdoYawRate). In der Legende sind die Modelle nach der Simulationszeit geordnet. Die Implementierungen sind jeweils mit der Filtererweiterung aus Abschnitt 3.4 ausgestattet.

Die Vergleichsmodelle benötigen den geringsten Rechenressourcenaufwand. Der Durchschnitt liegt bei 25 μ s, die Lokalisierungsfilter benötigen etwa 10 \times mehr Rechenaufwand. Der Grund dafür ist, dass die Kovarianzmatrixberechnungen auch Informationen aus der Vergangenheit berücksichtigen und der Lokalisierungsfilter alle drei konventionellen Fahrzeugbewegungsmodelle kombiniert. Die Implementierungen des Informationsfilters sind jeweils etwa 10 μ s schneller als die des Kalman-Filters. Dies entspricht dem Ergebnis der Arbeit von Assimakis [53], in der beschrieben wurde, dass der Rechenressourcenaufwand für ein zeitvariantes System bereits bei einem Verhältnis

²⁷ Z-Manöver: Das Fahrzeug wird abwechselnd im Zickzack vorwärts und rückwärts gefahren, 8-Manöver: das Fahrzeug wird abwechselnd im Kreis zur einen und dann zur anderen Seite gefahren.

²⁸ PS+3m: Parallelparklücke (engl. (PARALLEL) PARKING SLOT) mit der Fahrzeuglänge +3 m, PPS+2m: Querparklücke (engl. PERPENDICULAR PARKING SLOT) mit der Fahrzeugbreite +2 m.

²⁹ Es ist zu beachten, dass die Tic-Toc-Methode nur die CPU-Zeit misst, die der Code zur Ausführung benötigt. Andere Faktoren wie Speicherzugriffe, Ein- und Ausgabeoperationen oder Netzwerkkommunikation können die Gesamtlaufzeit des Codes zusätzlich beeinflussen, werden aber der Einfachheit halber nicht berücksichtigt.

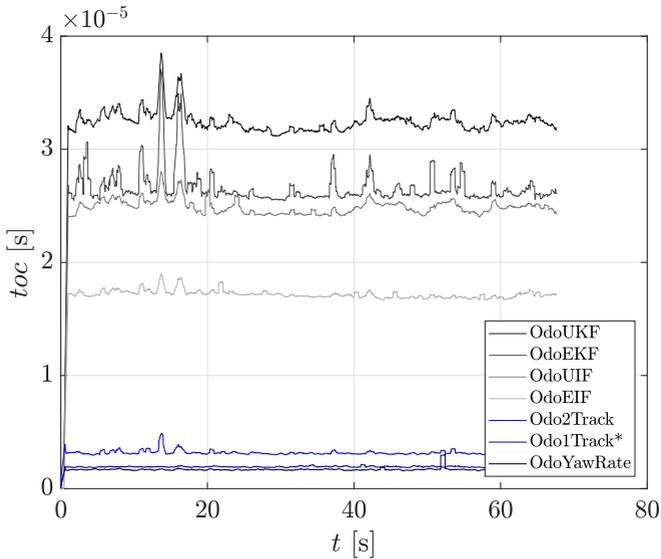


Abbildung 3.10: Vergleich der Simulationszeiten der einzelnen Fahrzeugbewegungsmodelle bei einem PS+3m-Manöver.

von $3n_z > 4n_x$ sinkt. Der EIF ist mit einer Durchschnittszeit von $17 \mu\text{s}$ die schnellste Implementierung des Lokalisierungsfilters und ist im Vergleich zu den aktuellen Implementierungen ausreichend schnell, um auf einem Parksteuergerät ausgeführt zu werden. Das OdoYawRate ist das schnellste Modell, da es keine Berechnung für die Rotationsbewegung erfordert, weil die gemessene Gierrate direkt verwendet wird.

Ergebnisse hinsichtlich des Vergleichs des **Rechenressourcenbedarfs**:

- Die Lokalisierungsfilter-Implementierungen (OdoEKF, OdoUKF, OdoEIF, OdoUIF) sind nach der Methode der Laufzeitmessung um den Faktor 10 langsamer als die Vergleichsmodelle (Odo2Track, Odo1Track*, OdoYawRate).
- Der OdoEIF ist nach der Methode der Laufzeitmessung die Rechenressourcen-schonendste Lokalisierungsfilter-Implementierung

und mit $17 \mu\text{s}$ ausreichend schnell, um auf dem Parksteuergerät ausgeführt zu werden.

- Der OdoEIF erfordert zwar doppelt so viele Rechenressourcen im Vergleich zur Summe aller drei Vergleichsmodelle, jedoch muss man berücksichtigen, dass zusätzlich die Berechnung von Kovarianz- und Matrixoperationen sowie die adaptiven Filtererweiterungen durchgeführt werden. Daher ist dieser zusätzliche Rechenressourcenaufwand vertretbar.

3.5.2 Vergleich der Filteralgorithmen

Als Nächstes werden die Trajektorien der unterschiedlichen Filteralgorithmen verglichen. Abbildung 3.11 zeigt dafür die Trajektorie der verschiedenen Filteralgorithmen bei einem PS+3m-Manöver. Zur besseren Veranschaulichung wird zusätzlich der Bereich der Endpositionen vergrößert dargestellt.

Die Endpositionen aller Implementierungen liegen nahezu übereinander, die Abweichung beträgt maximal 3 mm. Die UKF- und UIF-Implementierungen unter Verwendung der Sigma-Punkte sind nahezu identisch mit den EKF- und EIF-Implementierungen unter Verwendung der partiellen Ableitungen. Dies zeigt, dass eine Approximation durch die erste Taylorreihe für das gegebene System ausreichend genau ist. Die Unterschiede zwischen den Kalman- und den Informationsimplementierungen können auf numerische Rundungsfehler zurückgeführt werden.

Ergebnisse hinsichtlich des Vergleichs der verschiedenen **Filteralgorithmen**:

- Die Art des Filteralgorithmus (EKF, UKF, EIF, UIF) hat keinen signifikanten Einfluss auf die Positioniergenauigkeit des Lokalisierungsfilters.
- Der EIF wird aufgrund seiner rechenressourcenschonenden Laufzeitmessung, der nahezu gleichen Positioniergenauigkeit und der einfachen Implementierung als Lokalisierungsfilter gewählt und wird im Folgenden als Odofilter bezeichnet.

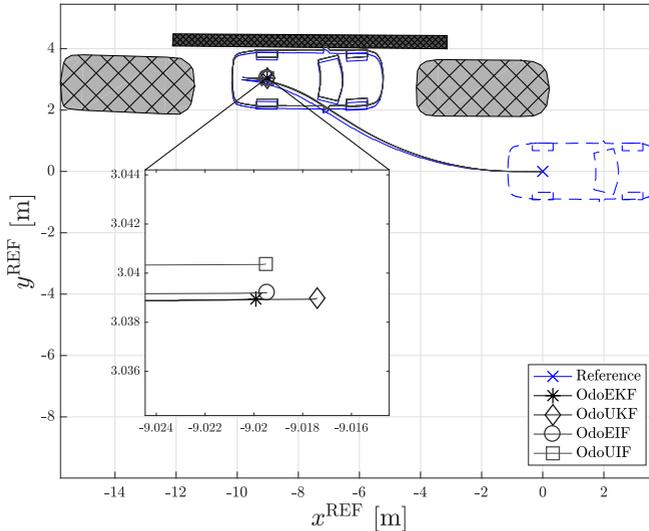


Abbildung 3.11: Vergleich der Trajektorien der verschiedenen Filteralgorithmen bei einem PS+3m-Manöver.

3.5.3 Beurteilung der Lokalisierungsleistung

Um die Lokalisierungsleistung des Lokalisierungsfilters (Odofilter) im Vergleich zum aktuellen Stand des Wissens bei den Fahrzeugbewegungsmodellen zu überprüfen, werden Kriterien für die Auswertung der Simulationsergebnisse definiert. Die wahre Position und die Ausrichtung werden durch das Referenzmesssystem angenähert. Neben der Abweichung der Zielposition werden Bewertungskriterien definiert, da eine relative mit einer absoluten Trajektorie verglichen wird und es einen Unterschied macht, wann ein Fehler während des Manövers auftritt. Um die Bewertungskriterien zu berechnen, wird eine Genauigkeit von Zentimetern verwendet, da das Referenzmesssystem ebenfalls auf diese Genauigkeit arbeitet. Die Bewertungskriterien werden am Ende der Messung $k = k_{\text{end}}$ in einem Modellfehlervektor $\xi \in \{e_{\text{pos},x}, e_{\text{pos},y}, e_{\text{alig}}, e_{\text{loc}}, e_{\text{max}}\}$ zusammengefasst, welcher aus folgenden Fehlern besteht:

1. Der Positionsfehler e_{pos} gibt den Fehler der Position, bezogen auf die Referenz-Position, in globalen x -/ y -Koordinaten an:

$$\begin{bmatrix} e_{\text{pos},x} \\ e_{\text{pos},y} \end{bmatrix} := e_{\text{pos}} := \mathbf{T}(\theta_{\text{Ref}}) \cdot (\mathbf{p} - \mathbf{p}_{\text{Ref}}),$$

$$\mathbf{T}(\theta) = \begin{bmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{bmatrix}, \quad (3.44)$$

2. Der Fehler der Fahrzeugausrichtung gegenüber der Referenz-Ausrichtung wird durch den Ausrichtungsfehler e_{align} angegeben:

$$e_{\text{align}} := \theta - \theta_{\text{Ref}}, \quad (3.45)$$

3. Die kumulierte Summe der absoluten Positionsfehler, bezogen auf die zurückgelegte Strecke, wird durch den Lokalisierungsfehler e_{loc} angegeben:

$$e_{\text{loc}} := \frac{\sum_{i=0}^{k_{\text{end}}} \|\mathbf{p}_i - \mathbf{p}_{\text{Ref},i}\|}{\sum_{i=1}^{k_{\text{end}}} \|\mathbf{p}_{\text{Ref},i} - \mathbf{p}_{\text{Ref},i-1}\|}, \quad (3.46)$$

4. Der maximale Positionsfehler des Manövers wird durch den maximalen Positionsfehler e_{max} angegeben:

$$e_{\text{max}} := \max_{i \in \{0, \dots, k_{\text{end}}\}} \|\mathbf{p}_i - \mathbf{p}_{\text{Ref},i}\|. \quad (3.47)$$

3.5.3.1 Lokalisierungsleistung ohne Sensorfehler

Zuerst wird die Lokalisierungsleistung im Normalzustand und ohne Sensorfehler untersucht. Hierzu werden die Bewertungskriterien für die Odometrietestszenarien (Z-, 8-Manöver) und für Parkmanöver (PS+3m, PPS+2m-Manöver) ausgewertet. Abbildung 3.12 zeigt die Trajektorien der Fahrzeugbewegungsmodelle für die vier ausgewählten Manöver. Da die Endpositionen der Trajektorien schwer zu erkennen sind, wird er in der Tabelle 3.3 zusätzlich der Modellfehlervektor $\xi \in \{e_{\text{pos},x}, e_{\text{pos},y}, e_{\text{align}}, e_{\text{loc}}, e_{\text{max}}\}$ dargestellt.

Das Odo1Track weist die größten Positions- sowie Ausrichtungsfehler auf und die Leistungssteigerung des Odo1Track* durch die korrigierten

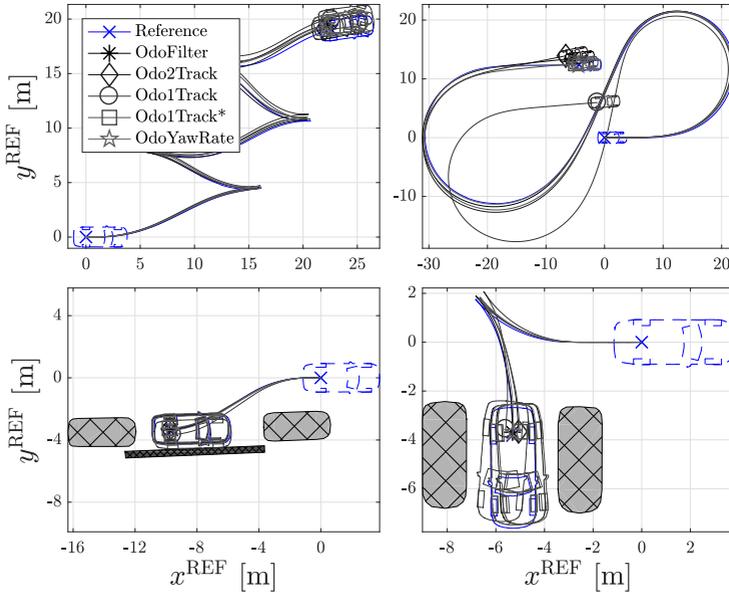


Abbildung 3.12: Trajektorien des OdoFilter und der Vergleichsmodelle für verschiedene Odometriemanöver.

Schwimmwinkel wird deutlich. Bei einem Manöver mit großem Lenkwinkel (8-Manöver) wird der Positionsfehler um 5 m und bei zusätzlichen Rückwärtsfahrten (PPS+2m) um 4 m verbessert. Der OdoFilter kombiniert grundsätzlich alle Fahrzeugbewegungsmodelle und wird somit von den einzelnen Fehlern beeinflusst. Die Fehlerwerte machen jedoch deutlich, dass der OdoFilter funktioniert. Bei keinem der betrachteten Manöver verhält er sich schlechter als das schlechteste Vergleichsmodell.

3.5.3.2 Lokalisierungsleistung mit Sensorfehlern

Als Nächstes wird untersucht, wie sich der OdoFilter und die Vergleichsmodelle im Fehlerfall verhalten. Tabelle 3.4 fasst dafür die relevanten Parameter- und Sensorfehler aus Kapitel 2 im Sensorfehlervektor ρ zusammen.

In diesem Fall werden die Sensorwerte der Fehler als Offset aufgeprägt. Für die Gierrate wird ein konstanter Offset angenommen. Abbildung 3.13

Tabelle 3.3: Modellfehlervektor $\xi \in \{e_{\text{pos},x}, e_{\text{pos},y}, e_{\text{alig}}, e_{\text{loc}}, e_{\text{max}}\}$ für unterschiedliche Odometrie- und Parkmanöver ohne Sensorfehler.

Modelle	ξ	Z	8	PS+3m	PPS+2m
OdoFilter	$e_{\text{pos},x}$	0,54 m	1,15 m	0,05 m	0,14 m
	$e_{\text{pos},y}$	-0,47 m	-1,06 m	0,12 m	-0,18 m
	e_{alig}	-0,57 °	-5,74 °	-0,14 °	1,23 °
	e_{loc}	10,21 -	8,35 -	11,30 -	27,07 -
	e_{max}	0,72 m	1,62 m	0,17 m	0,31 m
Odo2Track	$e_{\text{pos},x}$	0,69 m	2,26 m	0,14 m	-0,25 m
	$e_{\text{pos},y}$	-0,15 m	-1,52 m	-0,07 m	-0,16 m
	e_{alig}	2,01 °	10,93 °	-0,19 °	2,88 °
	e_{loc}	8,18 -	15,90 -	8,39 -	26,63 -
	e_{max}	1,39 m	2,85 m	0,17 m	0,31 m
Odo1Track	$e_{\text{pos},x}$	0,07 m	-3,17 m	-0,14 m	0,28 m
	$e_{\text{pos},y}$	-1,02 m	6,42 m	0,29 m	-0,27 m
	e_{alig}	-1,06 °	4,05 °	0,43 °	-5,03 °
	e_{loc}	15,96 -	58,83 -	26,23 -	42,29 -
	e_{max}	1,38 m	9,20 m	0,35 m	0,47 m
Odo1Track*	$e_{\text{pos},x}$	-0,07 m	0,56 m	0,01 m	-0,01 m
	$e_{\text{pos},y}$	-0,42 m	-0,22 m	0,22 m	-0,30 m
	e_{alig}	-1,51 °	4,81 °	0,54 °	-1,17 °
	e_{loc}	7,32 -	9,97 -	21,45 -	38,40 -
	e_{max}	1,38 m	1,48 m	0,30 m	0,45 m
OdoYawRate	$e_{\text{pos},x}$	0,51 m	0,11 m	0,09 m	-0,4 m
	$e_{\text{pos},y}$	-0,48 m	0,01 m	0,04 m	-0,13 m
	e_{alig}	0,99 °	0,60 °	0,53 °	-0,03 °
	e_{loc}	7,95 -	2,82 -	6,90 -	19,16 -
	e_{max}	1,37 m	0,50 m	0,10 m	0,20 m

zeigt die Trajektorie des OdoFilter und des jeweiligen Vergleichsmodells mit der größten Auswirkung auf den betrachteten Sensorfehlervektor für ein PS+3m-Manöver. Die Abbildung 3.13 oben links stellt den Normalfall für alle Fahrzeugbewegungsmodelle ohne Sensorfehler dar. Die anderen drei Abbildungen zeigen die Trajektorie des OdoFilter und des Fahrzeugbewegungsmodells mit dem stärksten Einfluss auf den in der Legende beschriebenen Sensorfehler. Die Trajektorien für den maximalen negativen und positiven Fehler werden zusammen dargestellt.

Es wird deutlich, dass die Fahrzeugbewegungsmodelle teilweise den Bordstein berühren oder weit auf der Straße stehen, wenn die maximalen Sensorfehler auftreten. Erkennt das Parksystem eine Überlappung, wird das

Tabelle 3.4: Übersicht des Sensorfehlervektors ρ .

ρ	μ	ρ_A	ρ_B	Einheit	Fehlerart
Δc_i	2,090	-0,040	+0,030	m	Abrollumfang
Δc_{RR}	2,090	-0,040	+0,030	m	Abrollumfangs hinten rechts
Δt_F	1,589	-0,000	+0,021	m	Spurweiten vorne
Δt_R	1,604	-0,020	+0,016	m	Spurweiten hinten
$\Delta \delta_F$	0	-1	+1	°	Achslenkwinkel
$\Delta \omega$	0	-0,7	+0,7	°/s	Gierrate

Fahrzeug normalerweise angehalten oder das System bricht den automatischen Parkvorgang ab. Ist das Fahrzeug zu weit auf der Straße, reagiert das Parksystem mit einer Neuberechnung der Trajektorie und plant Korrekturzüge, die zu einem echten Bordsteinkontakt führen können. Der OdoFilter schneidet in allen betrachteten Fehlerfällen gut ab, da die falschen Informationen nur teilweise im Fahrzeugbewegungsmodell enthalten sind. Hier wird der Vorteil der Multisensordatenfusion von redundanten Messungen durch Mittelung deutlich. Um die Robustheitssteigerung des OdoFilter durch ein definiertes Maß darzustellen, wird im nächsten Abschnitt eine Sensitivitätsanalyse durchgeführt.

Ergebnisse hinsichtlich der **Beurteilung der Lokalisierungsleistung:**

- Die Leistungssteigerung des OdoTrack* ist deutlich, die Schwimmwinkelbestimmung gleicht Positionsfehler von 4–5 m aus.
- Die Lokalisierungsleistungen ohne Sensorfehler des OdoFilter und der Vergleichsmodelle sind nahezu identisch, daher kann davon ausgegangen werden, dass die Modellierungsfehler sehr klein sind.
- Die Lokalisierungsleistung mit Sensorfehlern der Vergleichsmodelle ist unzureichend; in allen Szenarien kommt es zu einer virtuellen Kollision mit dem Bordstein.
- Beim OdoFilter ist die Lokalisierungsleistung durch die Multisensordatenfusion deutlich besser und es gibt praktisch keinen Bordsteinkontakt, obwohl große einzelne Sensorfehler auftreten.

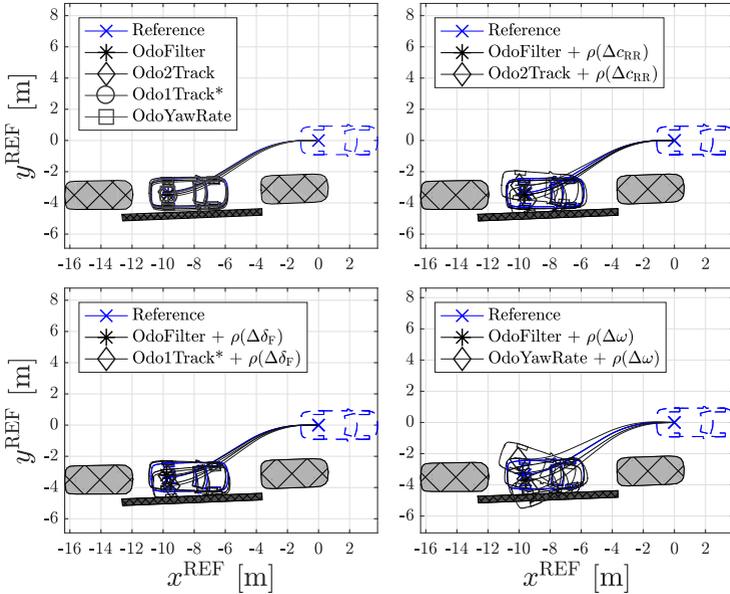


Abbildung 3.13: Trajektorien des OdoFilter und der Vergleichsmodele mit dem größten Einfluss auf die einzelnen Sensorfehler. Oben links: Normalfall für alle Fahrzeugbewegungsmodelle ohne Sensorfehler.

3.5.4 Sensitivitätsanalyse zur Lokalisierungsleistung

Um den OdoFilter auf seine Robustheit zu überprüfen, wird ein objektives Maß benötigt, um die Leistungssteigerung zu messen. Im Rahmen dieser Arbeit wurde daher eine Sensitivitätsanalyse entwickelt, die ein relatives Sensitivitätskriterium berechnet. Dadurch kann bestimmt werden, wie empfindlich die Fahrzeugbewegungsmodelle auf verschiedene Sensorfehler reagieren. Im Einzelfehlerfall werden die Sensitivitäten für die verschiedenen Fehler aus Tabelle 3.4 im Rahmen der Sensitivitätsanalyse berücksichtigt.

3.5.4.1 Definition des Sensitivitätskriteriums (SC)

Um die Sensitivität bzgl. des Sensorfehlervektors ρ zu ermitteln, werden die Testsznarien aus Abbildung 3.12 einmal mit dem Nominalwert des Sensorfehlervektors ρ , einmal mit dem Sensorfehlervektor für negative Fehler ρ_A und einmal mit dem Sensorfehlervektor für positive Fehler ρ_B simuliert. Die Sensitivität des Modellfehlervektors $\xi \in \{e_{\text{pos},x}, e_{\text{pos},y}, e_{\text{alig}}, e_{\text{loc}}, e_{\text{max}}\}$, bezogen auf den Sensorfehlervektor $\rho \in \{\Delta c_1, \Delta c_{RR}, \Delta t_F, \Delta t_R, \Delta \delta_F, \Delta \omega\}$, kann mit dem Sensitivitätskriterium $SC(\xi, \rho)$ wie folgt berechnet werden:

$$SC(\xi, \rho) := \frac{1}{2} \cdot \left(\left\| \frac{\xi |_{\rho} - \xi |_{\rho_A}}{\rho_A} \right\| + \left\| \frac{\xi |_{\rho} - \xi |_{\rho_B}}{\rho_B} \right\| \right). \quad (3.48)$$

Das Sensitivitätskriterium $SC(\xi, \rho)$ drückt aus, inwieweit der Modellfehler ξ auf eine Änderung des Sensorfehlers ρ reagiert. Je kleiner der Wert, desto robuster ist das Modell gegenüber dem Sensorfehler. Wenn der Wert durch einen Strich “-“, beschrieben ist, wird die Abweichung nicht durch eine Änderung des Sensorfehlervektors ρ beeinflusst. Das Odo1Track* verwendet nicht die Gierrate ω^\times , daher hat es keine Empfindlichkeit gegenüber der Gierrate. Das OdoYawRate ist hingegen unempfindlich gegenüber dem Achsenlenkwinkel. Das Odo2Track ist unempfindlich gegenüber beiden Messungen.

3.5.4.2 Sensitivitätskriterium (SC) für ein PS+3m-Manöver

Zunächst wird das Sensitivitätskriterium lokal für alle Manöver einzeln berechnet. Aus Platzgründen wird nur das Sensitivitätskriterium für den Einparkvorgang eines PS+3m-Manövers näher erläutert, um den Ablauf und die Bedeutung zu verdeutlichen. Später wird eine globale Auswertung erstellt, die gemittelte Sensitivitätskriterien enthält. Tabelle 3.5 zeigt die Werte des Sensitivitätskriteriums aus Gleichung (3.48) in den Spalten, jene für die verschiedenen Fahrzeugbewegungsmodelle in den Zeilen und mögliche Fehler in den Unterzeilen.

Es wird deutlich, dass die Modellfehler $e_{\text{pos},x}$, $e_{\text{pos},y}$ und e_{loc} des OdoFilter weniger empfindlich auf die Sensorfehler ρ reagieren als in den Vergleichsmodellen.

Weisen die Abrollumfänge c_i einen falschen Wert auf oder sind sie falsch kalibriert, wirkt sich das am stärksten auf den Lokalisierungsfehler e_{loc}

Tabelle 3.5: Sensitivitätskriterium (SC) des Modellfehlervektors $\xi \in \{e_{\text{pos},x}, e_{\text{pos},y}, e_{\text{align}}, e_{\text{loc}}, e_{\text{max}}\}$, bezogen auf den Sensorfehlervektor $\rho \in \{\Delta c_i, \Delta c_{RR}, \Delta t_F, \Delta t_R, \Delta \delta_F, \Delta \omega\}$, für ein PS+3m-Manöver. Pro Zeile/Spalte mit fester Unterzeile: grün für beste, blau für besser als Durchschnitt, rot für schlechteste.

Modelle	ρ	$SC(e_{\text{pos},x}, \rho)$	$SC(e_{\text{pos},y}, \rho)$	$SC(e_{\text{align}}, \rho)$	$SC(e_{\text{loc}}, \rho)$	$SC(e_{\text{max}}, \rho)$					
OdoFilter	Δc_i	0,13	m/m	0,10	m/m	0,02 °/m	6,41	1/m	0,07	m/m	
	Δc_{RR}	0,04	m/m	0,01	m/m	0,11 °/m	1,61	1/m	0,01	m/m	
	Δt_F	0	m/m	0	m/m	0	0,09	1/m	0	m/m	
	Δt_R	0	m/m	0	m/m	0	0,11	1/m	0	m/m	
	$\Delta \delta_F$	0	m/°	0,01	m/°	0,11 °/°	0,46	1/°	0,01	m/°	
	$\Delta \omega$	0	m/(°/s)	0,01	m/(°/s)	0,42	°/(°/s)	0,53	1/(°/s)	0,01	m/(°/s)
Odo2Track	Δc_i	0,13	m/m	0,10	m/m	0,02 °/m	8,09	1/m	0,10	m/m	
	Δc_{RR}	0,26	m/m	0,45	m/m	5,95 °/m	35,92	1/m	0,42	m/m	
	Δt_F	-	m/m	-	m/m	-	-	1/m	-	m/m	
	Δt_R	0,03	m/m	0,06	m/m	0,02 °/m	4,40	1/m	0,05	m/m	
	$\Delta \delta_F$	-	m/°	-	m/°	-	-	1/°	-	m/°	
	$\Delta \omega$	-	m/(°/s)	-	m/(°/s)	-	-	1/(°/s)	-	m/(°/s)	
Odo1Track*	Δc_i	0,13	m/m	0,11	m/m	0,03 °/m	4,29	1/m	0,04	m/m	
	Δc_{RR}	0,06	m/m	0,05	m/m	0,04 °/m	2,29	1/m	0,01	m/m	
	Δt_F	-	m/m	-	m/m	-	-	1/m	-	m/m	
	Δt_R	-	m/m	-	m/m	-	-	1/m	-	m/m	
	$\Delta \delta_F$	0	m/°	0,01	m/°	0,13 °/°	0,67	1/°	0,01	m/°	
	$\Delta \omega$	-	m/(°/s)	-	m/(°/s)	-	-	1/(°/s)	-	m/(°/s)	
OdoYawRate	Δc_i	0,15	m/m	0,05	m/m	0	8,60	1/m	0,13	m/m	
	Δc_{RR}	0,08	m/m	0,03	m/m	0	2,01	1/m	0,05	m/m	
	Δt_F	-	m/m	-	m/m	-	-	1/m	-	m/m	
	Δt_R	-	m/m	-	m/m	-	-	1/m	-	m/m	
	$\Delta \delta_F$	-	m/°	-	m/°	-	-	1/°	-	m/°	
	$\Delta \omega$	0,02	m/(°/s)	0,05	m/(°/s)	0,99	°/(°/s)	4,32	1/(°/s)	0,05	m/(°/s)

des Odo2Track und des OdoYawRate aus. Das Odo1Track* wird am wenigsten beeinflusst, der OdoFilter liegt dazwischen. Wenn aber ein Fehler im Abrollumfang hinten rechts c_{RR} auftritt, geht die Genauigkeit des Odo2Track deutlich zurück und die Modellfehler sind 6,5–54× empfindlicher als die des OdoFilters. Beträgt der Fehler im Abrollumfang den Maximalwert $\Delta c_{RR} = 4$ cm, so beträgt die Abweichung des Odo2Track im Lokalisierungsfehler $\Delta c_{RR} \cdot SC(e_{\text{loc}}, \Delta c_{RR}) = 1,44$ m, im Vergleich zu 0,06 m beim OdoFilter. Am größten ist der Einfluss auf die Ausrichtung, der Ausrichtungsfehler des Odo2Track beträgt $e_{\text{align}} = 5,95^\circ/\text{m}$ im Vergleich zu $e_{\text{align}} = 0,11^\circ/\text{m}$ des OdoFilters. Das lässt sich dadurch erklären, dass der OdoFilter die Drehrate durch die sechs Radpaare, die Schwimmwinkel und die Gierrate bestimmt.

Die Empfindlichkeit gegenüber der vorderen Spurweite $SC(\cdot, \Delta t_F)$ kann nur durch den OdoFilter beurteilt werden, da dieser als Einziger die vordere Spurweite verwendet. Der Einfluss ist allerdings mit dem Lokalisierungsfehler

$e_{\text{align}} = 0,89$ 1/m vernachlässigbar.

Die Empfindlichkeit gegenüber der Spurweite $SC(:, \Delta t_R)$ wirkt sich nur auf das Odo2Track und den OdoFilter aus. Es kann aber festgehalten werden, dass der Einfluss auf einen Fehler in der Spurweite geringer ist. Allein der Lokalisierungsfehler ist mit 4,40 1/m ausschlaggebend.

Die Empfindlichkeit gegenüber einem Radlenkwinkelfehler $SC(:, \Delta \delta_F)$ beeinflusst nur das Odo1Track* und den OdoFilter, da δ_F^\times nur von diesem Modell verwendet wird. Die Abweichung ist sehr gering: Ein Fehler von $\Delta \delta_F = 1^\circ$ beeinflusst die Ausrichtung nur um $0,0054^\circ$ bei Odo1Track*. Dies lässt sich dadurch erklären, dass es sich um einen Parallelparkvorgang handelt und das Fahrzeug eine Rechts- sowie eine Linkskurve macht.

Die Empfindlichkeit gegenüber Fehlern in der Gierrate $SC(:, \Delta \omega)$ kann nur mit dem OdoYawRate und dem OdoFilter verglichen werden. Wenn der Fehler $\Delta \omega = 0,7^\circ/\text{s}$ beträgt, ändert sich der Ausrichtungsfehler des OdoFilter um $0,7^\circ$, während sich der Ausrichtungsfehler des OdoYawRate um 2° ändert. Auch der Lokalisierungsfehler des OdoYawRate ist mit $8,22^\circ/(\circ/\text{s})$ sehr hoch.

Der Einfluss auf den Maximalfehler e_{max} ist für das PS+3m-Manöver nicht entscheidend. Die Sensitivitäten hängen grundsätzlich von der Messkovarianz des verwendeten OdoFilter ab. Der OdoFilter reagiert stärker auf die Unsicherheiten der Gierrate ω^\times , was zu einer niedrigeren Empfindlichkeit bei anderen Sensorfehlern führt.

3.5.4.3 Globales Sensitivitätskriterium (SC) für alle Manöver

Um die Leistungssteigerung global zu beschreiben, werden Sensitivitätskriterien für alle vier Manöver berechnet und gemittelt. Tabelle 3.6 zeigt die gemittelten Sensitivitätswerte.

Die gemittelten Sensitivitätskriterien können nun dazu verwendet werden, um globale Schlussfolgerungen über den Leistungsgewinn durch die Implementierung eines OdoFilters zu ziehen. Diese Schlussfolgerungen werden direkt in der Ergebnisbox zusammengefasst. Der Prozentbereich repräsentiert jeweils die geringsten und größten Fehlerunterschiede zwischen dem OdoFilter und den jeweiligen Modellen.

Tabelle 3.6: Gemittelttes Sensitivitätskriterium (SC) des Modellfehlervektors $\xi \in \{e_{\text{pos},x}, e_{\text{pos},y}, e_{\text{alig}}, e_{\text{loc}}, e_{\text{max}}\}$, bezogen auf den Sensorfehlervektor $\rho \in \{\Delta c_i, \Delta c_{RR}, \Delta t_F, \Delta t_R, \Delta \delta_F, \Delta \omega\}$. Pro Zeile/Spalte mit fester Unterzeile: grün für beste, blau für besser als Durchschnitt, rot für schlechteste.

Modelle	ρ	$\overline{SC}(e_{\text{pos},x}, \rho)$	$\overline{SC}(e_{\text{pos},y}, \rho)$	$\overline{SC}(e_{\text{alig}}, \rho)$	$\overline{SC}(e_{\text{loc}}, \rho)$	$\overline{SC}(e_{\text{max}}, \rho)$
OdoFilter	Δc_i	0,64 m/m	1,40 m/m	1,44 °/m	15,70 1/m	1,18 m/m
	Δc_{RR}	1,40 m/m	0,39 m/m	1,00 °/m	13,09 1/m	2,02 m/m
	Δt_F	0,12 m/m	0,27 m/m	0,09 °/m	0,89 1/m	0,26 m/m
	Δt_R	0,14 m/m	0,29 m/m	0,12 °/m	1,06 1/m	0,20 m/m
	$\Delta \delta_F$	0,07 m/°	0,04 m/°	0,52 °/°	1,58 1/°	0,14 m/°
	$\Delta \omega$	0,09 m/(°/s)	0,02 m/(°/s)	0,98 °/(°/s)	1,71 1/(°/s)	0,10 m/(°/s)
Odo2Track	Δc_i	0,91 m/m	1,95 m/m	1,35 °/m	16,13 1/m	1,69 m/m
	Δc_{RR}	6,67 m/m	6,74 m/m	7,11 °/m	170,45 1/m	22,65 m/m
	Δt_F	- m/m	- m/m	- °/m	- 1/m	- m/m
	Δt_R	1,10 m/m	2,41 m/m	1,88 °/m	18,03 1/m	2,16 m/m
	$\Delta \delta_F$	- m/°	- m/°	- °/°	- 1/°	- m/°
	$\Delta \omega$	- m/(°/s)	- m/(°/s)	- °/(°/s)	- 1/(°/s)	- m/(°/s)
Odo1Track*	Δc_i	0,91 m/m	1,99 m/m	1,49 °/m	17,43 1/m	1,56 m/m
	Δc_{RR}	0,45 m/m	1,01 m/m	1,03 °/m	9,15 1/m	0,68 m/m
	Δt_F	- m/m	- m/m	- °/m	- 1/m	- m/m
	Δt_R	- m/m	- m/m	- °/m	- 1/m	- m/m
	$\Delta \delta_F$	0,16 m/°	0,09 m/°	1,34 °/°	3,42 1/°	0,44 m/°
	$\Delta \omega$	- m/(°/s)	- m/(°/s)	- °/(°/s)	- 1/(°/s)	- m/(°/s)
OdoYawRate	Δc_i	0,36 m/m	0,39 m/m	0 °/m	11,10 1/m	0,26 m/m
	Δc_{RR}	0,18 m/m	0,20 m/m	0 °/m	3,33 1/m	0,11 m/m
	Δt_F	- m/m	- m/m	- °/m	- 1/m	- m/m
	Δt_R	- m/m	- m/m	- °/m	- 1/m	- m/m
	$\Delta \delta_F$	- m/°	- m/°	- °/°	- 1/°	- m/°
	$\Delta \omega$	0,25 m/(°/s)	0,09 m/(°/s)	2,77 °/(°/s)	8,22 1/(°/s)	0,44 m/(°/s)

Ergebnisse hinsichtlich der Sensitivitätsanalyse zur Lokalisierungsleistung:

- Das Sensitivitätskriterium gibt an, wie groß die Steigerung der Robustheit ist, und dient als objektive Maßeinheit. Kleine Werte bedeuten eine geringere Empfindlichkeit der Modellfehler gegenüber Sensorfehlern.
- Durch die Multisensordatenfusion erhöht sich die Robustheit des OdoFilter deutlich.
- Die Sensitivität des OdoFilter gegenüber spezifizierten Fehlern:
 - im Abrollumfang c_i sinkt um 3–30 % gegenüber dem Odo1Track*,
 - im Abrollumfang c_{RR} sinkt um 47–94 % gegenüber dem Odo2Track,

- in der Spurweite der Vorderachse t_F ist deutlich geringer als bei anderen Fehlern,
- in der Spurweite der Hinterachse t_R ist ebenfalls gering, sinkt aber nochmal um 87–94 % gegenüber dem Odo2Track,
- im vorderen Achsenwinkel δ_F sinkt um 54–68 % gegenüber dem Odo1Track*,
- in der Gierrate ω sinkt um 64–79 % gegenüber dem OdoYawRate.

3.5.5 Untersuchung der Streuung mit Statistikfahrten

In dieser Arbeit werden die Ergebnisse am Beispiel einer Testfahrt in verschiedenen Szenarien dargestellt und bewertet. Da diese Testfahrt nur einen Teil aller möglichen Testläufe darstellt, wird hier untersucht, wie sich die Trajektorien bei Wiederholung eines Testlaufs statistisch verändern. Zu diesem Zweck wurde ein Parkvorgang mehrmals durchgeführt. Das Fahrzeug wurde mithilfe eines selbst entwickelten funktionsbasierten Fahrroboters³⁰ am Parkplatz vorbeigefahren und der Parkplatz wurde vom ParksysteM vermessen. Abbildung 3.14 zeigt zur Übersicht die Trajektorien für 10 von insgesamt 30 Einparkversuchen.

Der Erwartungswert, die Standardabweichung, der Maximalfehler und der RSME³¹ wurden für die verschiedenen Fehler berechnet und in der Tabelle 3.7 für alle 30 Testläufe zusammengefasst.

Der OdoFilter hat kleine Werte in fast allen Modellfehlern. Die Wiederholbarkeit der Position bei 30 Parkmanövern liegt für den OdoFilter mit $\mu(30 \times, e_{\text{pos},x}) = 0,06 \text{ m}$ und $\sigma(30 \times, e_{\text{pos},x}) = 0,03 \text{ m}$ höher als beim Odo2Track mit $\mu(30 \times, e_{\text{pos},x}) = 0,14 \text{ m}$ und $\sigma(30 \times, e_{\text{pos},x}) = 0,03 \text{ m}$. Zu-

³⁰ Der für die Messfahrten verwendete funktionsbasierte Fahrroboter wurde speziell für diesen Zweck in der Masterarbeit von Spengler [A5] entwickelt und nutzt die Funktionsschnittstelle, um mit dem ParksysteM zu kommunizieren. Er ermöglicht es, eine Trajektorie von $\pm 1 \text{ cm}$ für die Parkplatzsuche einzuhalten. Das ParksysteM wird dadurch immer von einer definierten Startposition gestartet. Für den Parkvorgang wird ein bereits vorhandenes Serien-ParksysteM verwendet.

³¹ RSME ist kurz für ROOT-MEAN-SQUARE-ERROR. Er gibt an, wie stark die Schätzung im Durchschnitt von der Messung abweicht und wie gut eine Funktion folglich an die Daten angepasst ist.

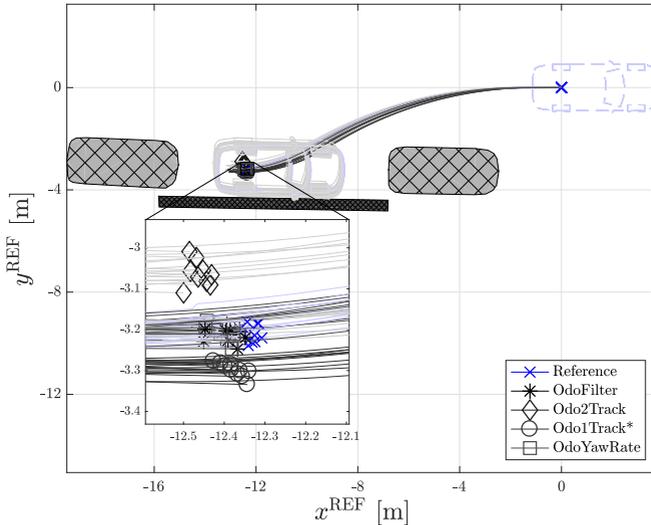


Abbildung 3.14: Verlauf des OdoFilter und der Vergleichsmodelle für 10 von 30 Parkmanövern.

sätzlich kann eine Standardabweichung von bis zu 3 cm im Positionsfehler und $0,01^\circ$ bei der Ausrichtung abgeleitet werden. Diese Standardabweichungen werden auch als Odometrierauschen bezeichnet und geben an, wie viel Rauschen z. B. durch Modellierungsfehler beim Fahrzeugbewegungsmodell vorhanden ist. Durch die deutliche Reduktion des Odometrierauschens, die der OdoFilter bewirkt, ergibt sich ein großer Vorteil für die Parkqualität.

Ergebnisse hinsichtlich der Untersuchung der Streuung durch Statistikfahrten:

- Für die Beurteilung der statistischen Streuung eines Fahrzeugbewegungsmodells kann das Odometrierauschen verwendet werden.
- Das odometrische Rauschen ist bei der Positionsbestimmung des Lokalisierungsfilters mit $\sigma = 0,03$ m und bei der Ausrichtung mit $0,01^\circ$ deutlich geringer als bei allen Vergleichsmodellen.

Tabelle 3.7: Statistische Fehler $\mu(30\times, \xi)$, $\sigma(30\times, \xi)$, $\max(30\times, \xi)$ und $\text{RSME}(30\times, \xi)$ für 30 automatisierte Parkmanöver inkl. Suchvorgang.

Modelle	ξ	$\mu(30\times, \xi)$	$\sigma(30\times, \xi)$	$\max(30\times, \xi)$	$\text{RSME}(30\times, \xi)$
OdoFilter	$e_{\text{pos},x}$	0,06 m	0,03 m	0,12 m	0,07 m
	$e_{\text{pos},y}$	0,00 °	0,01 °	0,03 °	0,02 °
	e_{alig}	0,01 °	0,01 °	0,01 °	0,01 °
	e_{loc}	0,59 -	0,10 -	0,72 -	0,60 -
	e_{max}	0,13 m	0,03 m	0,17 m	0,13 m
Odo2Track	$e_{\text{pos},x}$	0,14 m	0,03 m	0,19 m	0,14 m
	$e_{\text{pos},y}$	-0,17 °	0,05 °	-0,09 °	0,17 °
	e_{alig}	5,02 °	2,64 °	6,28 °	5,61 °
	e_{loc}	1,35 -	0,36 -	2,09 -	1,39 -
	e_{max}	0,22 m	0,05 m	0,35 m	0,23 m
Odo1Track*	$e_{\text{pos},x}$	0,05 m	0,02 m	0,08 m	0,05 m
	$e_{\text{pos},y}$	0,09 °	0,02 °	0,11 °	0,09 °
	e_{alig}	6,27 °	0,00 °	6,28 °	6,27 °
	e_{loc}	1,25 -	0,10 -	1,38 -	1,25 -
	e_{max}	0,22 m	0,03 m	0,25 m	0,22 m
OdoYawRate	$e_{\text{pos},x}$	0,09 m	0,02 m	0,12 m	0,09 m
	$e_{\text{pos},y}$	-0,01 °	0,03 °	0,03 °	0,03 °
	e_{alig}	0,01 °	0,01 °	0,01 °	0,01 °
	e_{loc}	0,65 -	0,09 -	0,77 -	0,66 -
	e_{max}	0,10 m	0,01 m	0,13 m	0,11 m

4 Fahrzeugparameterschätzung

Durch die Integration kleiner Bewegungsabschnitte sind die relativen Fahrzeugbewegungsmodelle anfällig für systematische Fehler in den Fahrzeugparametern. Sind die im Modell verwendeten Parameter nicht genau bekannt, nimmt der Fehler in der geschätzten Position mit der Zeit zu. Im schlimmsten Fall kann bspw. ein saisonaler Radwechsel zu einer Fehlfunktion oder sogar zu einem Abbruch des Parksystems führen. Um dies zu vermeiden, werden die relevanten Fahrzeugparameter während der Fahrt geschätzt. Um in kurzer Zeit die richtigen Fahrzeugparameter für jede mögliche Fahrzeugvariante zu erlernen, werden in diesem Kapitel verschiedene Kalibrierfilter und Filtererweiterungen entwickelt. Die *adaptiven Achsparameterkalibrierfilter* Self-Adaptive-Front-Axle-Kinematic-Parameter-Estimator (SA-FAKPE) und Self-Adaptive-Rear-Axle-Kinematic-Parameter-Estimator (SA-RAKPE) schätzen trotz Messunterbrechungen zuverlässig die Abrollumfänge und Spurweiten, der *Gierratenfehlerkalibrierfilter* Yaw-Rate-Parameter-Estimator (YRPE) schätzt die Gierratensensorfehler.

4.1 Stand des Wissens: Fahrzeugparameterschätzung

Mit unabhängigen Sensoren und Sensormodellen können die Fahrzeugparameter im Fahrbetrieb kalibriert werden. Es gibt bereits viele Ansätze, die Fahrzeugparameter mithilfe von hochauflösenden Sensoren wie Kameras [40], Radaren [41] oder Lidaren [42] zu kalibrieren. Diese Arbeit hat das Ziel, Methoden zu entwickeln, um das derzeit in Serienfahrzeugen installierte Sensorset zu nutzen.

Die Offenlegung [O4] beschreibt das Verfahren zur Schätzung der Abrollumfänge durch GNSS-Positionsmessungen für die spätere Nutzung zur odometriebasierten Lokalisierung. Der große Vorteil des Verfahrens zur Kalibrierung des Fahrzeugbewegungsmodells mit GNSS besteht darin, dass die absolute Positionsmessung für die Kalibrierung verwendet werden kann. Die

Genauigkeit der Schätzung nimmt mit der Entfernung zu, da der Positionierungsfehler mit den GNSS-Absolutwerten gemessen wird, was bereits in den Arbeiten von Caltabiano [16] und Wada [54] gezeigt wurde. Der GNSS-Empfänger liefert zusätzlich eine Geschwindigkeit und eine Ausrichtung. Diese sind jedoch für eine Kalibrierung ungeeignet, da sich der Geschwindigkeitsvektor im Raum frei drehen kann, weshalb sich der Einsatz ohne zusätzlichen Aufwand auf Fahrten mit konstanten Kurvenverhältnissen beschränkt.

Die zur Schätzung verwendeten absoluten Positionsmessungen des GNSS weisen Einschränkungen auf, wenn es zu Mehrwegeeffekten (engl. MULTIPATH) und plötzlichen Unterbrechungen kommt. Um Mehrwegeeffekte zu eliminieren, wurden bereits Kalman-Smoother entwickelt, wie in der Arbeit von Agamennoni [55] beschrieben. Diese werden in der Regel vom Lieferanten direkt im GNSS-Empfänger implementiert. Zur Lösung des Problems im Umgang mit GNSS-Messunterbrechungen z. B. durch Brücken, Tunnel oder Hochhauszonen gibt es im Kontext der Fahrzeugparameterschätzung noch keine Arbeiten. Allerdings ist aus der Arbeit von Katriniok [36] eine Methode bekannt, bei der virtuelle Messungen zur Auswertung für den Filterbetrieb verwendet werden können, falls es zu Messunterbrechungen kommt.

In aktuellen Fahrzeugarchitekturen sind die Sensoren und Steuergeräte oft komplex miteinander vernetzt und das Routing kann zu dynamischen Signalverzögerungen führen. Der GNSS-Empfänger ist meistens direkt mit dem Infotainmentsystem verbunden, um die Funktionalität für das eCall und das Navigationssystem bereitzustellen. Die dynamischen Signalverzögerungen resultieren im Wesentlichen aus den veränderten Betriebsbedingungen des Infotainmentsystems, d. h. es gibt Signalverzögerungen aufgrund von bspw. neuen Multimedia- oder Navigationseingaben.

Eine weitere Methode zur Kalibrierung der Achsparameter ist die Verwendung der Inertialsensorik, wie in den Arbeiten von Chung [29] und Rodrigo-Marco [39] beschrieben. Wie bereits im Absatz 2.3.5 erläutert, reichen die ESP-Spezifikationen der Inertialsensorik nicht aus, um eine Lokalisierung durchzuführen. Eine gleichzeitige Lokalisierung und Kalibrierung, wie in der Arbeit von Ibraheem [32] nach dem *kinematischen Zweispurmodell* oder der Arbeit von Carlsen [56] auf Basis zusätzlicher GNSS-Messungen, ist daher ebenfalls nicht anwendbar. Eine Kombination der Ansätze zur exklusiven Kalibrierung mit einem zuvor kalibrierten *kinematischen Zweispurmodell*

Odo2Track bietet für Parkanwendungen Vorteile und ist so noch nicht entwickelt worden.

4.2 Konzept: Fahrzeugparameterschätzung

Um die für den Lokalisierungsfilter relevanten Fahrzeugparameter im Fahrbetrieb zu schätzen, wird ein Konzept zur Fahrzeugparameterschätzung entwickelt. Abbildung 4.1 zeigt, wie die beiden *erweiterten Achsparameterkalibrierungsfilter* SA-FAKPE und SA-RAKPE sowie der *Gierratenfehlerkalibrierfilter* YRPE zusammenarbeiten, um die Fahrzeugparameter kontinuierlich zu bestimmen.

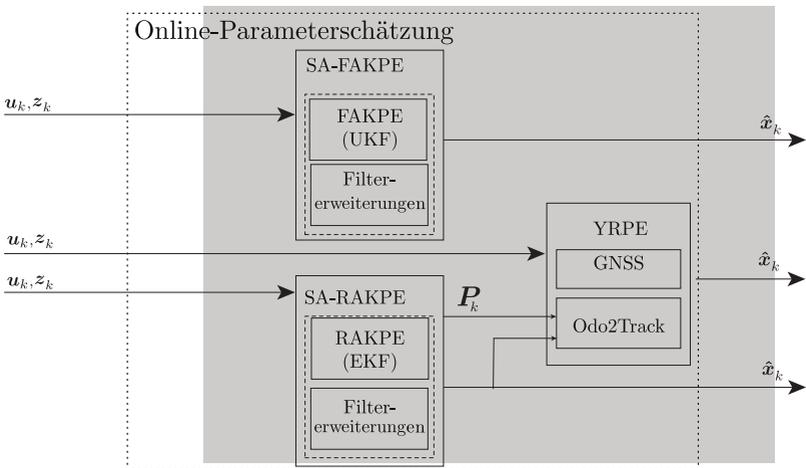


Abbildung 4.1: Konzept zur Fahrzeugparameterschätzung mittels SA-FAKPE, SA-RAKPE und YRPE.

Da die kontinuierliche Kalibrierung der Fahrzeugparameter vergleichsweise rechenintensiv ist, wurde bereits in der Offenlegung [O15] eine Methode zur Kalibrierung der Fahrzeugparameter eines komplexen Fahrzeugbewegungsmodells durch unabhängige einfache Modelle beschrieben. Diese sind in dem entwickelten Konzept in den Kalibrierfiltern verankert und werden nur dann aktiv, wenn sich das Fahrzeug nicht im aktiven Parkmanöver befindet. Bei längeren Kalibrierläufen wird eine zusätzliche Logik verwendet, die die

geschätzten Parameter zwischenspeichert und gegebenenfalls die Schätzung neu startet, um weitere Schätzungen zu generieren.

Um einen hohen Konvergenzgrad der Schätzungen zu erreichen und die Achsparameter in kürzester Zeit zu schätzen, sind die Kalibrierfilter mit Filtererweiterungen ausgestattet. Diese sind in der Lage, Messunterbrechungen zuverlässig zu erkennen und danach weiterzulernen. In der Veröffentlichung [V2] wurde zu diesem Zweck das Konzept des *erweiterten Hinterachsparemeterkalibrierfilters* SA-RAKPE vorgestellt. In dieser Arbeit wird eine verallgemeinerte Form des *Achsparameterkalibrierfilters* AKPE entwickelt, der die Schätzung von Vorder- sowie Hinterachsparemetern erlaubt und aus dem *erweiterten kinematischen Zweispurmodell* OdoExt2Track abgeleitet ist. Auch die Filtererweiterungen werden neuformuliert, um eine allgemeinere Form zu erhalten. Die Filtererweiterungen stellen grundsätzlich verschiedene Optimierungsschritte dar, um eine adäquate Leistung der Kalibrierfilter in der Anwendung im Steuergerät ohne große Rechenressourcen zu gewährleisten.

Die erste Filtererweiterung stellt sicher, dass die Kalibrierfilter erst dann mit der Kalibrierung beginnen, wenn eine genaue Startausrichtung erfolgt ist. Eine weitere Filtererweiterung sorgt für eine adaptive Signaloptimierung in Form eines Signalverzögerungsalgorithmus SSA, der die durch das Routing verursachten dynamischen Signalverzögerungen erkennt. Dieser wurde bereits in der Offenlegung [O16] beschrieben. Ferner werden Filtererweiterungen zur adaptiven Anpassung des System- und des Messmodells entwickelt, welche eine bessere Modellierung ermöglichen. Die letzte Filtererweiterung erkennt die Messunterbrechungen und passt den Filteralgorithmus während sowie nach den Messunterbrechungen an. Der Filterbetrieb wird durch virtuelle Messungen aufrechterhalten, um eine kontinuierliche Kovarianzberechnung zu gewährleisten. Dies sorgt für eine hohe Konvergenz und eine robuste Lernfähigkeit trotz ständiger GNSS-Messunterbrechung, sodass der Kalibrierfilter nicht neu gestartet werden muss.

Zur Kalibrierung des Gierratensensors wird ein *Gierratenfehlerkalibrierfilter* YRPE entwickelt, der zusätzlich zur Positionsmessung des GNSS das kalibrierte *kinematische Zweispurmodell* verwendet. Dieser Kalibrierfilter benötigt die zuvor geschätzten Achskinematikparameter, weshalb in der Offenlegung [O17] eine Logik beschrieben wird, die die Kalibrierfilter nacheinander startet und die ebenfalls implementiert wird.

Darüber hinaus gibt es bereits Ideen für zukünftige Systeme. So beschrieb die

Offenlegung [O2] ein Verfahren, das es ermöglicht, Radwechsel durch das Reifendrucküberwachungssystem basierend auf den Reifendrucksensordaten zu erkennen. In der Offenlegung [O18] wurde beschrieben, wie mobile Geräte, z. B. Mobiltelefone, zur Kalibrierung verwendet werden können, wenn diese in Zukunft genauere und hochwertigere Sensoren verwenden als die im Fahrzeug verfügbaren.

4.3 Adaptiver Achsparameterkalibrierfilter SA-AKPE

In diesem Abschnitt wird zunächst der *Achsparameterkalibrierfilter* Axle-Kinematic-Parameter-Estimator (AKPE) erläutert. Anschließend wird die Filtererweiterung entwickelt und am Beispiel des SA-RAKPE angewendet.

4.3.1 Achsparameterkalibrierfilter AKPE

Die Grundlage für die Schätzung der Achsparameter liegt in der Korrelation des Bewegungsmodells mit den Positionsmessungen des GNSS. Der AKPE prognostiziert zunächst die Bewegung des Fahrzeugs durch das Systemmodell. Anschließend passt er die Achsparameter mittels GNSS-Positionsmessungen im Innovationsschritt an (vgl. Filteralgorithmen aus dem Absatz 3.3.1). Somit werden die Achsparameter kontinuierlich geschätzt. Um die Funktionalität zu verstehen, werden im Folgenden der Zustand sowie das System- und das Messmodell definiert.

4.3.1.1 Definition des Zustands

Der Zustand des AKPE wird aus den Bewegungszuständen x_k , y_k und θ_k sowie den Abrollumfängen der Räder 1 und 2 $c_{1,k}$, $c_{2,k}$ sowie der Spurweite $t_{j,k}$ zusammengesetzt:

$$\mathbf{x}_k = \begin{bmatrix} x_k & y_k & \theta_k & c_{1,k} & c_{2,k} & t_{j,k} \end{bmatrix}^T \in \mathbb{R}^6. \quad (4.1)$$

4.3.1.2 Definition des Systemmodells

Das Systemmodell besteht aus dem *kinematischen Zweispurmodell* (vgl. Absatz 3.2.1). Da die Abtastfrequenz f_S der GNSS-Positionsmessungen $50\times$ kleiner ist als die der Berechnung des Bewegungsmodells, kann das

Bewegungsmodell vereinfacht werden. Der Term $\frac{\omega \cdot \Delta t}{2}$ aus der Bewegungsgleichung (3.9) wird daher komplett vernachlässigt. Das Bewegungsmodell geht somit davon aus, dass das Fahrzeug in jedem Berechnungsschritt eine Gerade fährt und der Winkel anschließend korrigiert wird. Der Schwimmwinkel β wird ebenfalls vernachlässigt, da für die Achsparameterbestimmung nur die Fahrabschnitte verwendet werden, bei denen die Radstellungsfehler (Ackermannfehler) vernachlässigbar sind und der Eigenlenkgradient $EG \approx 0$ angenommen werden kann. Außerdem werden die Achsparameter nur bei einer Vorwärtsfahrt $d = 1$ berechnet, um negative Abrollumfangskorrekturen während der Schätzung zu vermeiden.

Mithilfe der Geschwindigkeitssensorgleichung (2.13) und der Gleichung für den Abrollumfang (2.4), welche ebenfalls die Geschwindigkeitsproportionalität des Abrollumfangs μ_v (vgl. Absatz 2.2.1) verwendet, lässt sich die Korrelation der Geschwindigkeit in Abhängigkeit von den DWPCs $w_{i,k}^\times$ und vom Abrollumfang $c_{i,k}$ definieren als:

$$\tilde{v}_i = \frac{w_{i,k}^\times \cdot c_{i,k}}{w_{\max} \cdot (1 - \mu_v) \cdot \Delta t}. \quad (4.2)$$

Mit der Gleichung für die Geschwindigkeit (3.12) und der Gierrate (3.13) können die Fahrzeuggeschwindigkeit und der Gierwinkel aus zwei unabhängigen Rädern berechnet werden. Das Systemmodell, das die Bewegung des Fahrzeugs in Abhängigkeit von zwei unabhängigen Rädern beschreibt, wird definiert als:

$$\mathbf{x}_k = \mathbf{f}(\mathbf{x}_{k-1}, \mathbf{u}_k) = \begin{bmatrix} x_{k-1} \\ y_{k-1} \\ \theta_{k-1} \\ c_{1,k-1} \\ c_{2,k-1} \\ t_{j,k-1} \end{bmatrix} + \begin{bmatrix} v(\tilde{v}_{1,k}, \tilde{v}_{2,k}, \delta_{1,k}, \delta_{2,k}) \cdot \Delta t \cdot \cos(\theta_{k-1}) \\ v(\tilde{v}_{1,k}, \tilde{v}_{2,k}, \delta_{1,k}, \delta_{2,k}) \cdot \Delta t \cdot \sin(\theta_{k-1}) \\ \omega(\tilde{v}_{1,k}, \tilde{v}_{2,k}, \delta_{1,k}, \delta_{2,k}) \cdot \Delta t \\ 0 \\ 0 \\ 0 \end{bmatrix}. \quad (4.3)$$

Der Eingangsvektor besteht aus den DWPCs $w_{1,k}^\times$, $w_{2,k}^\times$ und den Radlenkwinkeln $\delta_{1,k}$, $\delta_{2,k}$:

$$\mathbf{u}_k = \begin{bmatrix} w_{1,k}^\times & w_{2,k}^\times & \delta_{1,k} & \delta_{2,k} \end{bmatrix}^\top \in \mathbb{R}^4. \quad (4.4)$$

Da die in Abschnitt 2.2.2 beschriebenen veränderlichen RAP keinen signifikanten Einfluss haben, wird die Spurweite als konstant angesehen. Für den einfachen Fall des Rear-Axle-Kinematic-Parameter-Estimator (RAKPE) und für ein Fahrzeug ohne Hinterachslenkung $\delta_R^\times = 0 \Rightarrow \delta_{RL}, \delta_{RR} = 0$ berechnen sich die Geschwindigkeit v_k und die Gierrate ω_k wie folgt:

$$\begin{aligned} v_k &= \frac{c_{RL,k} \cdot w_{RL,k}^\times + c_{RR,k} \cdot w_{RR,k}^\times}{2 \cdot w_{\max} \cdot (1 - \mu_v) \cdot \Delta t}, \\ \omega_k &= \frac{c_{RR,k} \cdot w_{RR,k}^\times - c_{RL,k} \cdot w_{RL,k}^\times}{t_{R,k} \cdot w_{\max} \cdot (1 - \mu_v) \cdot \Delta t}. \end{aligned} \quad (4.5)$$

Das Zustandsraummodell mit dem erweiterten Zustandsvektor vereinfacht sich zu:

$$\mathbf{x}_k = \mathbf{f}(\mathbf{x}_{k-1}, \mathbf{u}_k) = \begin{bmatrix} x_{k-1} \\ y_{k-1} \\ \theta_{k-1} \\ c_{RL,k-1} \\ c_{RR,k-1} \\ t_{R,k-1} \end{bmatrix} + \begin{bmatrix} \frac{c_{RL,k-1} \cdot w_{RR,k}^\times + c_{RR,k-1} \cdot w_{RL,k}^\times}{2 \cdot w_{\max} \cdot (1 - \mu_v)} \cos(\theta_{k-1}) \\ \frac{c_{RL,k-1} \cdot w_{RR,k}^\times + c_{RR,k-1} \cdot w_{RL,k}^\times}{2 \cdot w_{\max} \cdot (1 - \mu_v)} \sin(\theta_{k-1}) \\ \frac{c_{RR,k-1} \cdot w_{RR,k}^\times - c_{RL,k-1} \cdot w_{RL,k}^\times}{t_{R,k-1} \cdot w_{\max} \cdot (1 - \mu_v)} \\ 0 \\ 0 \\ 0 \end{bmatrix}. \quad (4.6)$$

Der Eingangsvektor ergibt sich folgendermaßen:

$$\mathbf{u}_k = \begin{bmatrix} w_{RL,k}^\times & w_{RR,k}^\times \end{bmatrix}^\top \in \mathbb{R}^2. \quad (4.7)$$

4.3.1.3 Definition des Messmodells

Das Messmodell gleicht nur die Bewegungszustände ab, da der Geschwindigkeitwinkel des GNSS zu ungenau ist. Der GNSS-Empfänger liefert die

Position in geodätischen Koordinaten \mathbf{p}^{LLH} . Diese müssen mittels Transformation zu kartesischen Koordinaten \mathbf{p}^{REF} relativ zu dem Punkt mittig auf der Hinterachse transformiert werden (vgl. Abschnitt 2.4). Basierend auf der GNSS-Information, ist der Messvektor \mathbf{z}_k wie folgt aufgebaut:

$$\mathbf{z}_k = \begin{bmatrix} x_{\text{GNSS},k}^{\times} & y_{\text{GNSS},k}^{\times} \end{bmatrix}^T \in \mathbb{R}^2. \quad (4.8)$$

Da die Messungen nach der Transformation als Referenz-Position \mathbf{p}^{REF} verfügbar sind, ist das Messmodell sehr einfach und kann wie folgt definiert werden:

$$\mathbf{h}(\mathbf{x}_k) = \begin{bmatrix} x_k & y_k \end{bmatrix}^T. \quad (4.9)$$

4.3.1.4 Filteralgorithmus

Mithilfe der allgemeinen Formulierung des Systemmodells für das *kinematische Zweispurmodell* Odo2Track (vgl. Gleichung (4.3)) können ein RAKPE und ein FAKPE konstruiert werden. Zum Aufbau der Kalibrierfilter werden die Filteralgorithmen aus Absatz 3.3.1 verwendet. Für die Schätzung der Achsparameter der Hinterachse im RAKPE ist die Approximation durch die erste Taylor-Linearisierung von EKF ausreichend, da für ein Fahrzeug ohne Hinterachslenkung Vereinfachungen gelten. Der UKF wird für die Schätzung der Achsparameter der Vorderachse im FAKPE verwendet, da hier die komplexere Beschreibung der Zusammenhänge der Vorderachskinematik durch die dritte Taylor-Linearisierung eine bessere Approximation erreicht. Neben der richtigen Auswahl des Filtertyps spielt auch die Tatsache eine Rolle, dass der Zustandsvektor mit sechs Zuständen deutlich größer ist als der Messvektor mit zwei Messungen. So gilt, wie in der Arbeit von Assimakis [53] gezeigt, dass der Rechenaufwand der Kalman-Filter für die Aufgabe der Achsparameterschätzung geringer ist als der Informationsfilter.

4.3.1.5 Filtereinstellung

Für die Abstimmung des Filters werden für die Kovarianzmatrizen die ermittelten Standardabweichungen aus Tabelle 2.1 und 2.3 verwendet. Tabelle 4.1 fasst alle Standardabweichungen zusammen. Die Diagonalmatrizen $\text{diag}(\cdot)$ für die Messkovarianzmatrix \mathbf{R} und die Prozessrauschen-Kovarianzmatrix \mathbf{Q} werden durch die Standardabweichungen definiert und die Anfangskovarianz

P_0 der Achsparameter durch den möglichen Fehlerbereich der Parameter aus Abschnitt 2.2:

$$\begin{aligned} \mathbf{P}_0 &= \text{diag} \left(\left[\sigma_{f,x}^2 \quad \sigma_{f,y}^2 \quad \sigma_{f,\theta}^2 \quad \sigma_{c_i}^2 \quad \sigma_{c_i}^2 \quad \sigma_{f_j}^2 \right] \right), \\ \mathbf{Q} &= \text{diag} \left(\left[\sigma_{f,x}^2 \quad \sigma_{f,y}^2 \quad \sigma_{f,\theta}^2 \quad \sigma_{f,c_i}^2 \quad \sigma_{f,c_i}^2 \quad \sigma_{f,t_j}^2 \right] \right), \\ \mathbf{R} &= \text{diag} \left(\left[\sigma_{\text{PGNSS}}^2 \quad \sigma_{\text{PGNSS}}^2 \right] \right). \end{aligned} \quad (4.10)$$

Tabelle 4.1: Standardabweichung σ der Kovarianzmatrizen des RAKPE.

Variable	Wert	Einheit	Beschreibung
$\sigma_{f,x}$	$\pm 5 \cdot 10^{-2}$	m	Modellfehler in x^{VEH} -Richtung
$\sigma_{f,y}$	$\pm 5 \cdot 10^{-2}$	m	Modellfehler in y^{VEH} -Richtung
$\sigma_{f,\theta}$	$\pm 1 \cdot 10^{-2}$	°	Modellfehler des Gierwinkels
σ_{f,c_i}	$\pm 7 \cdot 10^{-2}$	m	Abrollumfangsfehler
σ_{f,t_j}	$\pm 3,6 \cdot 10^{-2}$	m	Spurweitenfehler
σ_{PGNSS}	± 2	m	GNSS-Positionsfehler

4.3.1.6 Ergebnis des RAKPE

Um die Funktion und Leistung des RAKPE zu testen, wird ein Szenario mit städtischen Straßen, Autobahnen und Kreuzungen sowie ihren jeweiligen Geschwindigkeitsbegrenzungen verwendet. Zur Vereinfachung der Interpretation zeigt Abbildung 4.2 lediglich die Abweichungen der ermittelten Abrollumfänge und Spurweite von den tatsächlichen Werten, die durch die Parameterschätzung ermittelt wurden. Zur Ermittlung der tatsächlichen Abrollumfänge wird das manuelle Verfahren zur Bestimmung des Abrollumfanges (vgl. Absatz 2.2.1) angewendet.

Es ist zu erkennen, dass sich die Schätzungen trotz der falschen Startwerte schnell dem wahren Wert nähern. Zusätzlich fällt auf, dass die Schätzungen oszillieren. Dies hängt mit der Dynamik des Modells zusammen und ist typisch für Kalibrierfilter, die feste Parameter abschätzen. Der Verlauf sieht bei jeder Messung anders aus, da entscheidend ist, wann der Schätzer die Informationen erhält und lernt. Bei Kurvenfahrten ermittelt der RAKPE die

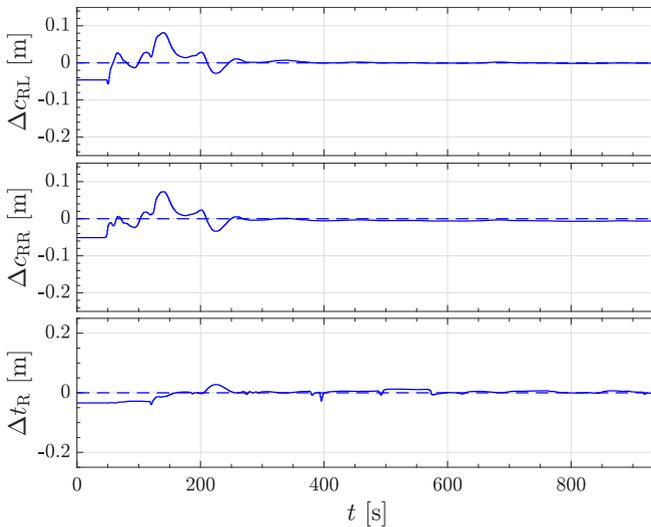


Abbildung 4.2: Geschätzte Abweichung der Achsparameter des RAKPE.

Spurweiteninformation und die Differenz zwischen den Abrollumfängen, bei Geradeausfahrt hingegen ermittelt er die individuellen Abrollumfänge.

4.3.2 Filtererweiterungen

Um die Leistung der *Achsparameterkalibrierungsfiler* AKPE zu erhöhen und den Betrieb auf dem Steuergerät im Fahrzeug zu gewährleisten, werden in diesem Absatz die einzelnen Filtererweiterungen entwickelt und der Leistungsgewinn auf Basis des SA-RAKPE dargestellt.

4.3.2.1 Filterstart bei korrekter Startausrichtung

Die Startausrichtung ist besonders relevant, da ein relatives Systemmodell mit einem absoluten Messmodell zusammengeführt wird. Wenn die Ausrichtung des Messmodells am Anfang der Messung Fehler aufweist, muss das relative Systemmodell angepasst werden, da es keine feste Ausrichtung im Raum hat. Die erste Filtererweiterung des SA-RAKPE erkennt daher, ob eine ausreichend genaue Startausrichtung vorliegt, und startet den Kalibrierfilter. Um den Einfluss einer falschen Startausrichtung zu verdeutlichen, wird eine

Messung mit unterschiedlichen Startausrichtungen untersucht. In der Simulation wird das Systemmodell um einen definierten Winkel zum Messmodell versetzt. Abbildung 4.3 zeigt den Vergleich der geschätzten Abweichung der Achsparameter in Bezug auf verschiedene Startausrichtungen. Die blaue Linie zeigt das Verhalten bei ausgerichtetem System- und Messmodell.

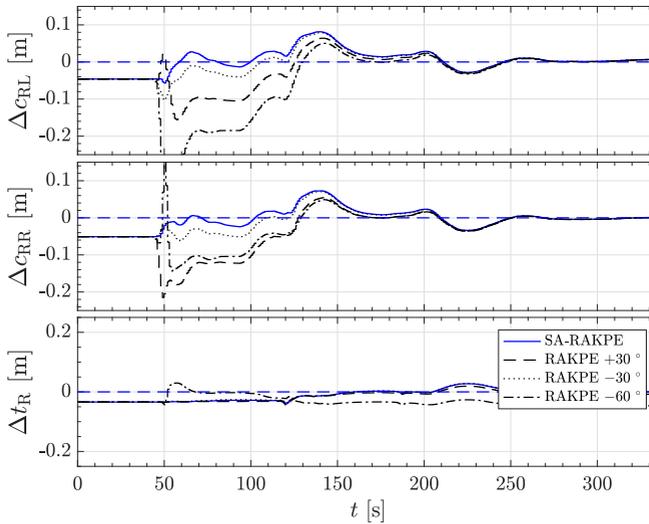


Abbildung 4.3: Geschätzte Abweichung der Achsparameter des SA-RAKPE mit verschiedenen Startausrichtungen.

Es kann beobachtet werden, wie sich die Anfangsphase der Abrollumfangschätzung abhängig von dem Fehler der Startausrichtung ändert. Die endgültigen Schätzwerte der Abrollumfänge bleiben nahezu gleich. Für den Fall RAKPE -60° werden bis zum Ende der Messung zu wenig Informationen bereitgestellt, weshalb der RAKPE eine fehlerhafte Spurweite schätzt. Für eine ausreichende Leistung des Achskalibrierfilters wird daher definiert, dass eine Startausrichtung von $\leq \pm 30^\circ$ bekannt sein muss.

4.3.2.2 Anpassung durch eine dynamische Signalverzögerungserkennung

Die nächste Filtererweiterung des SA-RAKPE erkennt die dynamische Signalverzögerung der GNSS-Messungen. Um die Verzögerung aufgrund des Routings zu bestimmen, wurde ein Signalverzögerungsalgorithmus (engl. SIGNAL-SHIFT-ALGORITHM (SSA)) entwickelt. Dies ist eine Voraussetzung für die Verwendung der GNSS-Messungen in dem Steuergerät des Parksystems. Er nutzt die Methode der kleinsten Fehlerquadrate, um die Korrelationen zwischen dem Geschwindigkeitsprofil der durch den GNSS-Empfänger gemessenen Geschwindigkeit v_{GNSS} und der DWPCs-berechneten Geschwindigkeit v zu ermitteln. Das Problem kann wie folgt beschrieben werden:

$$\Delta t_{\text{delay}}(t) = \min_{\Delta t} \left\| \sum_{s \in [s_{\min}, s_{\max}]} [v_{\text{GNSS}}(t + \Delta t) - v(t)]^2 \right\|. \quad (4.11)$$

Der SSA kann das Geschwindigkeitsprofil der maximal gefahrenen Strecke von $s_{\max} = 5$ km verwenden. Nach $s_{\min} = 1$ km Wegstrecke beginnt der SSA, das Geschwindigkeitsprofil zu korrelieren, wenn es genügend aussagekräftige Informationen dazu gibt. Abbildung 4.4 zeigt die von SSA berechnete dynamische Signalverzögerung $\Delta t_{\text{delay}}(t)$ für eine 3150 s andauernde Testfahrt durch Tunnel, über Brücken und durch Hochhauszonen, in denen der Betriebszustand des Infotainmentsystems nach Wunsch geändert wurde.

Das SSA benötigt zunächst das Geschwindigkeitsprofil von 100 s, um genügend Werte für eine Korrelation zu haben. Anschließend bestimmt es die dynamische Signalverzögerung von 1 bis 3 s.

Als nächstes wird der Effekt der dynamischen Signalverzögerung im Vergleich zu statischen Signalverzögerungen im Achskalibrierfilter untersucht. Abbildung 4.5 zeigt die geschätzten Abweichungen der Achsparameter des SA-RAKPE und des RAKPE mit statischen GNSS-Signalverzögerungen von 1, 2 und 3 s.

Dieser Vergleich zeigt, wie sich das Einschwing- und das Nachlaufverhalten durch die GNSS-Signalverzögerung ändern. Sowohl der Abrollumfang als auch die Spurweite werden nach 950 s nicht mit ausreichender Genauigkeit geschätzt. Es wird deutlich, dass der SSA im SA-RAKPE eine Voraussetzung für eine gute Achsparameterschätzung darstellt.

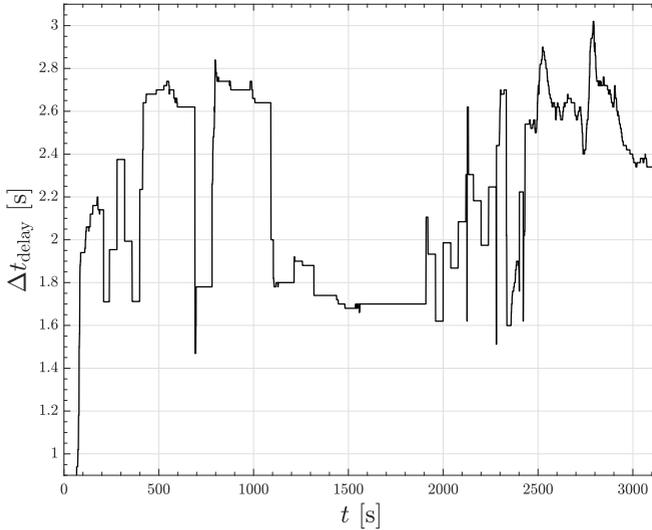


Abbildung 4.4: Signalverzögerung $\Delta t_{\text{delay}}(t)$ aus der Berechnung des SSA.

4.3.2.3 Adaptive Einstellung des Systemmodells

Um die Leistung des Kalibrierfilters zu verbessern, wird die Prozessrauschen-Kovarianzmatrix \mathbf{Q}_k des SA-RAKPE dynamisch angepasst. Dazu wird die Standardabweichung des Fehlers im Systemmodell geschwindigkeitsabhängig adaptiert. Mit der Geschwindigkeit v_k und dem konstanten Abtastzeitabstand Δt wird die Standardabweichung des Systemmodells wie folgt dynamisch berechnet:

$$\begin{aligned}\sigma_{f,x,k}(\bar{v}_k) &= \sigma_{f,x} \cdot \bar{v}_k \cdot \Delta t, \\ \sigma_{f,y,k}(\bar{v}_k) &= \sigma_{f,y} \cdot \bar{v}_k \cdot \Delta t.\end{aligned}\quad (4.12)$$

Dabei wird berücksichtigt, dass der Fehler des Bewegungsmodells geschwindigkeitsabhängig ist. Ferner ist der RAKPE empfindlich gegenüber der Spurweitenschätzung, wenn es zum ersten Mal auf einer kurvenreichen Strecke fährt, ohne ausreichend genaue Abrollumfangswerte bestimmt zu haben. Daher stellt die folgende erweiterte adaptive Einstellung des Systemmodells sicher, dass zunächst der Abrollumfang bestimmt wird. Der Filter ist so

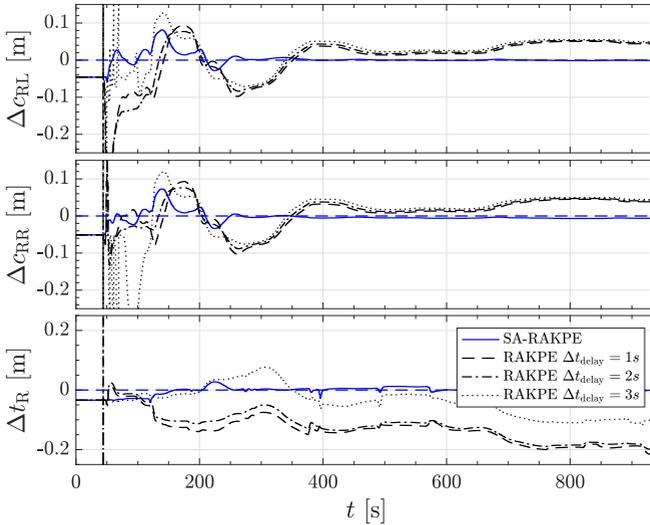


Abbildung 4.5: Geschätzte Abweichung der Achsparameter des SA-RAKPE im Vergleich zum RAKPE mit verschiedenen statischen GNSS-Signalverzögerungen.

eingestellt, dass der Vergleich der Bewegungsgleichung, in der gleichzeitig die Spurweite und die Abrollumfänge bestimmt werden, erst dann vollständig in den Filter einbezogen wird, wenn ausreichend genaue Werte für den Abrollumfang berechnet werden.

$$\sigma_{f,\theta,k}(P_{c_i,k}, \omega^\times) = \begin{cases} \sigma_{f,\theta} \cdot \omega^\times \cdot \Delta t & \text{for } P_{c_i,k} \leq P_{c_i,\min} \\ \sigma_{f,\theta}^\times & \text{for } P_{c_i,k} > P_{c_i,\min} \end{cases} \quad (4.13)$$

Da der Kalibrierfilter so schnell wie möglich neue Abrollumfangswerte ermitteln soll, sind die geschätzten Parameterwerte während der Messunterbrechung zu speichern. Zu diesem Zweck werden die Kovarianzwerte der Parameter auf 0 gesetzt. So behält der Filter auch ohne zusätzliche Mes-

sungen seinen erlernten Parameter bei. Für diese Annahmen ändert sich die Kovarianz der Prozessrauschen-Kovarianzmatrix \mathbf{Q}_k zu:

$$\mathbf{Q}_k = \text{diag} \left(\left[\sigma_{f,x,k}^2 \quad \sigma_{f,y,k}^2 \quad \sigma_{f,\theta,k}^2 \quad 0 \quad 0 \quad 0 \right] \right). \quad (4.14)$$

4.3.2.4 Adaptive Einstellung des Messmodells

Um die Leistung des Kalibrierfilters weiter zu erhöhen, wird im nächsten Schritt das Messmodell in Abhängigkeit von der Messqualität angepasst. Die Geometrische-Präzisionsverdünnung (GDOP) bietet ein Maß für die Streuung von Messwerten des GNSS (vgl. Absatz 2.3.6). Aus der GNSS-Sensorspezifikation geht hervor, dass ab einem Wert von $GDOP_{\max}^{\times} = 3$ das GNSS-Signal $\sigma_{p,\text{GNSS},k}$ ungenau wird. Mithilfe der GDOP wird die Standardabweichung des Fehlers der GNSS-Absolutpositionsmessung $\sigma_{p,\text{GNSS}}$ daher erweitert zu:

$$\sigma_{p,\text{GNSS},k} = \sigma_{p,\text{GNSS}} \cdot GDOP_k^{\times} \quad (4.15)$$

und die Kovarianzmatrix der Messung \mathbf{R}_k ändert sich zu:

$$\mathbf{R}_k = \text{diag} \left(\left[\sigma_{p,\text{GNSS},k}^2 \quad \sigma_{p,\text{GNSS},k}^2 \right] \right). \quad (4.16)$$

Für den Fall, dass die Genauigkeit des GNSS abnimmt und sich $GDOP_k^{\times} \geq 3$ einstellt, wird eine GNSS-Unterbrechung detektiert. Zusätzlich werden die verfolgten Satelliten $TrackSat_k^{\times}$ beobachtet. Sind weniger als sieben Satelliten an der Positionsbestimmung beteiligt, werden die Positionsmessungen nicht verwendet. Die GNSS-Messungen sind dann nicht mehr vertrauenswürdig und die Innovationsgleichungen des Filters werden durch die im folgenden Absatz beschriebenen Filtererweiterungen geändert.

4.3.2.5 Anpassung des Filteralgorithmus bei einer Messunterbrechung

Erkennt der SA-RAKPE eine Messunterbrechung, wird der Filteralgorithmus des Kalibrierfilters angepasst. Die geänderte Prozessrauschen-Kovarianzmatrix aus Gleichung (4.14) lässt die Parameter und deren Kovarianz konvergieren. Geht jedoch die Beobachtungsfähigkeit durch eine Messunterbrechung verloren, müssen die kompletten Innovationsgleichun-

gen modifiziert werden, um die Informationen der erlernten Parameter zu speichern. Für die Auswertung wird der Filter durch die Methode der virtuellen Messungen weiter betrieben. Um die gelernten Parameter zu speichern, werden ihre Werte und die dazugehörigen Kovarianzen im Filter eingefroren. Um Sprünge in den Parametern und Kovarianzen zu vermeiden, wird eine zusätzliche Kompensationsphase eingeführt, die das Systemmodell nach einer Messunterbrechung korrigiert. Dies gewährleistet einen stabilen Filterbetrieb. Da der Kalibrierfilter nicht neu gestartet werden muss, werden die Parameter weiter angelernt und es gehen keine Informationen verloren.

Innovation während der Messunterbrechung

Wenn eine Messunterbrechung erkannt wird, sollten die GNSS-Messungen nicht mehr verwendet werden. Mit der bisherigen Einstellung würde der Kalibrierfilter einfach neu gestartet, nachdem er den Messunterbrechungsbereich verlassen hat. Die in dieser Arbeit entwickelte Filtererweiterung hält den Filterbetrieb aufrecht. Dazu wird der Filteralgorithmus der Innovationsphase aus Absatz 3.3.1 angepasst. Der erweiterte Zustandsvektor $\hat{\mathbf{x}}_k^*$ wird durch die Messung nicht aktualisiert und die entsprechende Kovarianzmatrix \mathbf{P}_k^* aktualisiert nur die Kovarianzen der Bewegungsgleichung³². Die Gleichungen für die Zustände und die Kovarianzen ändern sich zu:

$$\hat{\mathbf{x}}_k^* = \hat{\mathbf{x}}_k^-,$$

$$\mathbf{P}_k^* = \begin{cases} \mathbf{P}_k(i) & \text{for } i = (1:3, 1:3), (1:3, 4:6), (4:6, 1:3) \\ \mathbf{P}_{k-1}(i) & \text{for } i = (4:6, 4:6) \end{cases}. \quad (4.17)$$

Als Messmodell werden virtuelle Messungen der zuvor geschätzten Parameter \mathbf{z}_k^* verwendet:

$$\mathbf{z}_k^* = \begin{bmatrix} c_{\text{RL},k-1}^\times & c_{\text{RR},k-1}^\times & t_{\text{R},k-1}^\times \end{bmatrix}^\text{T} \in \mathbb{R}^3. \quad (4.18)$$

³² Bewegungsgleichungsuntermatrix: $\mathbf{P}(1 : 3, 1 : 3)$,
Kreuzkovarianzuntermatrizen: $\mathbf{P}(1 : 3, 4 : 6)$ und $\mathbf{P}(4 : 6, 1 : 3)$,
Parameterkovarianzuntermatrix: $\mathbf{P}(4 : 6, 4 : 6)$.

Hierdurch ändert sich das Messmodell $\mathbf{h}^*(\cdot)$ zu:

$$\mathbf{h}^*(\mathbf{x}_k) = \begin{bmatrix} c_{RL,k} & c_{RR,k} & t_{R,k} \end{bmatrix}^T. \quad (4.19)$$

Die Messkovarianz wird mit dem Status der Kovarianzen der Parameter zu Beginn der Messunterbrechung versorgt:

$$\mathbf{R}_k^* = \mathbf{P}_{k-1}^*(4 : 6, 4 : 6). \quad (4.20)$$

Innovation nach der Messunterbrechung

Abhängig von der Genauigkeit der geschätzten Parameter liefern das Systemmodell und das nach der Messunterbrechung wieder verfügbare Messmodell möglicherweise stark abweichende Werte für die Bewegungszustände. Deshalb wird der Kalibrierfilter um eine Kompensationsphase erweitert, in der das möglicherweise fehlerhafte Systemmodell und das wieder verfügbare Messmodell angeglichen werden. Die Länge der Kompensationsphase hängt von den Kovarianzwerten der Parameter zu Beginn der Messunterbrechung und von der Änderung der Kovarianzen der Bewegungszustände während der Messunterbrechung ab. Der Kalibrierfilter kann wieder den normalen Filteralgorithmus verwenden, sobald die Kovarianzwerte der Bewegungsgleichung den Wert vor der Messunterbrechung erreichen. Die Gleichungen werden wie folgt angepasst:

$$\begin{aligned} \hat{\mathbf{x}}_k^{\sim} &= \begin{cases} \hat{\mathbf{x}}_k(i) & \text{for } i=(1:3) \text{ Bewegungsgleichung} \\ \hat{\mathbf{x}}_{k-1}(i) & \text{for } i=(4:6) \text{ Parameter} \end{cases}, \\ \mathbf{P}_k^{\sim} &= \begin{cases} \mathbf{P}_k(i) & \text{for } i=(1:3,1:3),(1:3,4:6),(4:6,1:3) \\ \mathbf{P}_{k-1}(i) & \text{for } i=(4:6,4:6) \end{cases}. \end{aligned} \quad (4.21)$$

In der Kompensationsphase werden für die GNSS-Positionsmessungen die virtuellen Messungen der Parameter verwendet, um die Parameter konstant zu halten und die Bewegungszustände langsam anzupassen:

$$\mathbf{z}_k^{\sim} = \begin{bmatrix} x_{GNSS,k}^{\times} & y_{GNSS,k}^{\times} & c_{RL,k-1}^{\times} & c_{RR,k-1}^{\times} & t_{R,k-1}^{\times} \end{bmatrix}^T \in \mathbb{R}^5. \quad (4.22)$$

Das Messmodell $\tilde{h}(\cdot)$ erweitert sich zu:

$$\tilde{h}(\mathbf{x}_k) = \begin{bmatrix} x_k & y_k & c_{RL,k} & c_{RR,k} & t_{R,k} \end{bmatrix}^T. \quad (4.23)$$

Die Messkovarianz wird zusammen mit den berechneten Kovarianzen der GNSS-Positionsmessung erweitert:

$$\tilde{\mathbf{R}}_k = \text{diag} \left(\begin{bmatrix} \mathbf{R}_k & \mathbf{P}_{k-1}(4:6, 4:6) \end{bmatrix} \right). \quad (4.24)$$

Ergebnis des SA-RAKPE bei einer Messunterbrechung

Um die Leistung des SA-RAKPE zu überprüfen, wird er mit einem RAKPE verglichen, der nach jeder Messunterbrechung neu startet. Abbildung 4.6 zeigt die geschätzten Abweichungen der Achsparameter; die Bereiche der Messunterbrechungen sind grau markiert.

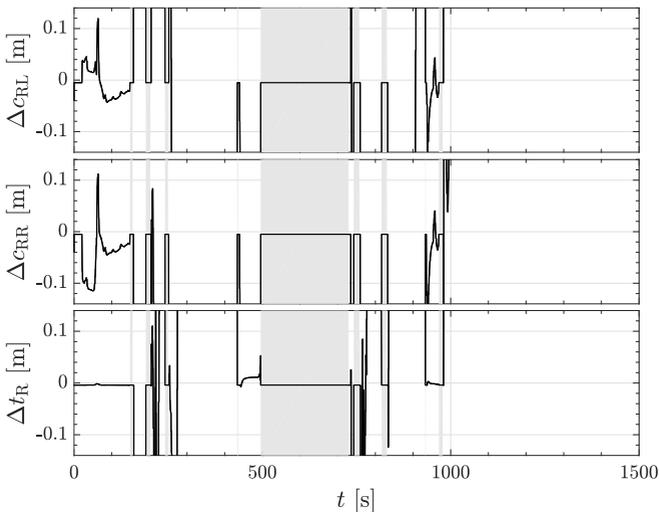


Abbildung 4.6: Geschätzte Abweichung der Achsparameter des RAKPE.

Es ist zu beobachten, dass die Parameter zu Beginn kurzzeitig in Richtung der realen Parameter konvergieren. Das konvergente Verhalten wird jedoch

durch die Messunterbrechung und den anschließenden Neustart immer wieder gestört. Um zu verstehen, ob und wie viel der Kalibrierfilter lernt, werden die Kovarianzen weiter untersucht.

Dazu zeigt Abbildung 4.7 die geschätzten Kovarianzen von RAKPE. Oben sind die Standardabweichungen des Messmodells, in der Mitte die Standardabweichungen des Systemmodells und unten die geschätzten Standardabweichungen der vom Kalibrierfilter berechneten Zustände dargestellt.

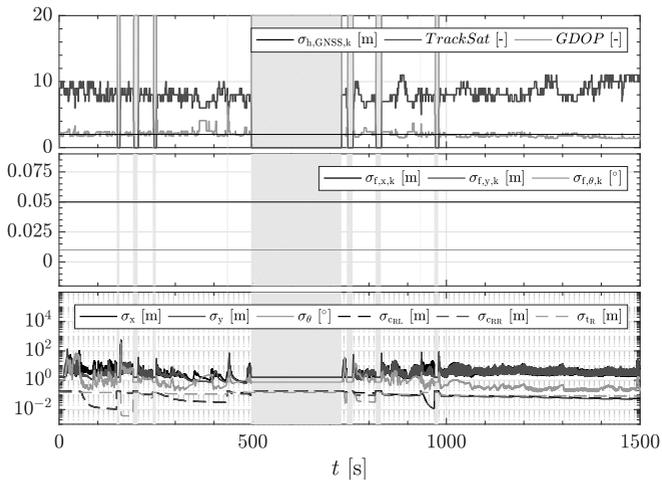


Abbildung 4.7: Geschätzte Kovarianzen des RAKPE.

Die Standardabweichungen des Messmodells und des Systemmodells sind konstant, da der RAKPE kein adaptives Systemmodell berücksichtigt. Die geschätzten Standardabweichungen der vom Kalibrierfilter berechneten Zustände zeigen kurze Lernphasen, in denen die Standardabweichungen der Abrollumfänge σ_{cRL} und σ_{cRR} sowie die Spurweite σ_{tr} zu 0 konvergieren. Nach dem Neustart beginnt der Kalibrierfilter wieder von vorn.

Abbildung 4.8 zeigt die geschätzten Abweichungen der Achsparameter des SA-RAKPE.

Es ist zu erkennen, dass das Systemmodell während der Messunterbrechung immer noch läuft. Sobald die Messunterbrechung überwunden ist, passt sich das fehlerhafte Systemmodell nach kurzer Zeit an die gemessene GNSS-Position an. Nach Durchlaufen der Kompensationsphase schaltet der Filter

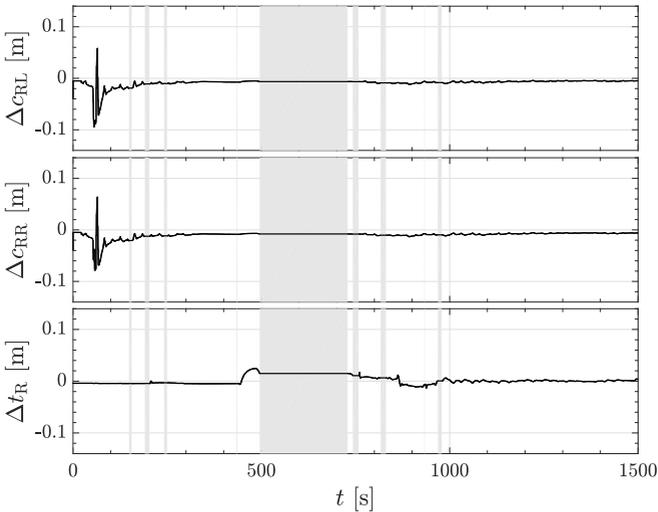


Abbildung 4.8: Geschätzte Abweichung der Achsparameter des SA-RAKPE.

wieder auf den normalen Filteralgorithmus zurück und schätzt weiterhin die Parameter. Es wird deutlich, wie gut die erlernten Parameter sind, die nach einer Unterbrechung gehalten und nicht neu gestartet werden. Insgesamt benötigen der Abrollumfang ca. 1 km und die Spurweite ca. 3 km, bevor gute Werte erreicht werden. Dies liegt daran, dass die Spurweite mehr Informationen aus Kurvenfahrten benötigt.

Abbildung 4.9 zeigt die geschätzten Kovarianzen des SA-RAKPE.

In der Abbildung gut zu erkennen, dass die Standardabweichungen der GNSS-Position σ_{h,GNSS_k} und des Systemmodells $\sigma_{f,x,k}$, $\sigma_{f,y,k}$ sowie $\sigma_{f,\theta,k}$ nun dynamisch angepasst werden, um eine höhere Modellierungsgenauigkeit zu erreichen. Ferner wird deutlich, dass sich die Standardabweichungen der Zustände während der Messunterbrechung deutlich verschlechtern. Hier hilft die Kompensationsphase dabei, das fehlerhafte Systemmodell anschließend anzupassen. Schließlich wird deutlich, dass die Standardabweichung der geschätzten Parameter in Richtung 0 konvergiert und während der Messunterbrechungen eingefroren bleibt.

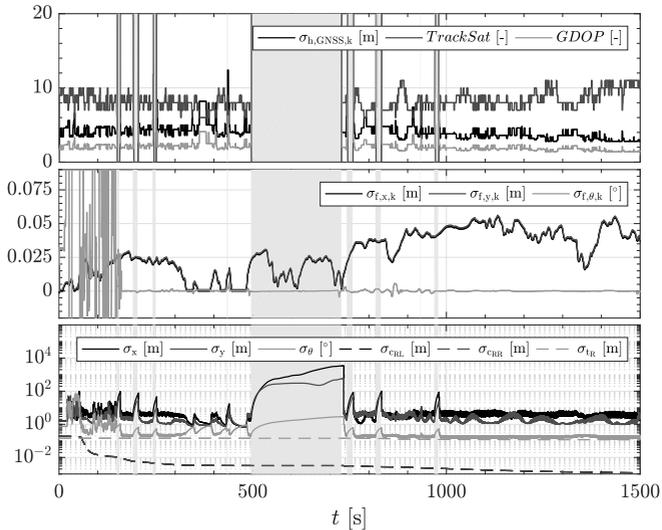


Abbildung 4.9: Geschätzte Kovarianzen des SA-RAKPE.

Ergebnisse hinsichtlich der **Achsparameterschätzung**:

- Es ist möglich, Fahrzeugparameter mithilfe von Kalibrierfiltern im Parksystem einfach und unabhängig zu schätzen. Hierfür sind keine zusätzlichen Rechenressourcen erforderlich, da die Filter außerhalb der Parkphasen arbeiten.
- Die Parameter der Vorder- und der Hinterachse lassen sich durch eine Abwandlung des *Achsparameterkalibrierfilters* AKPE unabhängig voneinander bestimmen.
- Der AKPE verwendet aufgrund des geringeren Rechenaufwands den Kalman-Filteralgorithmus sowie ein vereinfachtes Bewegungsmodell, welches vom *kinematischen Zweispurmodell* Odo2Track abgeleitet ist. Für den RAKPE ist der EKF und für den FAKPE der UKF am besten geeignet.

- Um die Leistung des AKPE zu erhöhen, werden verschiedene Filtererweiterungen im SA-AKPE entwickelt, die eine schnelle Konvergenz der Parameterschätzung gewährleisten:
 - Der Kalibrierfilter wird erst nach einer ausreichend genauen Startausrichtung $\leq \pm 30^\circ$ automatisch gestartet.
 - Die GNSS-Signalverzögerung wird durch den Signalverzögerungsalgorithmus SSA erkannt und berücksichtigt.
 - Um eine höhere Modellierungsgenauigkeit zu erhalten, werden die Kovarianzen des System- und des Messmodells geschwindigkeitsabhängig angepasst.
 - Mithilfe der Qualitätskriterien vom GNSS wird eine Messunterbrechung frühzeitig erkannt. Sobald der GDOP-Wert $GDOP_k^x \geq 3$ und die verfolgten Satelliten $TrackSat_k^x \leq 6$ erreichen, wird eine Messunterbrechung festgestellt.
 - Um trotz Messunterbrechungen weiterzulernen, wird der Self-Adaptive-Axle-Kinematic-Parameter-Estimator (SA-AKPE) durch Anpassung des Filteralgorithmus mit virtuellen Parametermessungen ausgestattet. So liefert er realistische Werte für die Kovarianz der Bewegungszustände und bleibt im Fahrbetrieb auswertbar.
 - Um den SA-AKPE auch nach den Messunterbrechungen zur Parameterschätzung weiter verwenden zu können, wird das Systemmodell durch den angepassten Filteralgorithmus der Kompensationsphase angeglichen und keine falschen Änderungen der Parameter werden vorgenommen. Nach erfolgreicher Einstellung fährt der Filter mit den bereits erlernten Parametern und Kovarianzen fort.

4.4 Gierratenfehlerkalibrierfilter YRPE

Um das *kinematische Gierratenmodell* $OdoYawRate$, genauer gesagt die gemessene Gierrate als Eingangsvariable, für den Lokalisierungsfilter verwenden zu können, muss zunächst der Gierratensensor kalibriert werden. Zu

diesem Zweck wird in diesem Abschnitt der *Gierratenfehlerkalibrierfilter* YRPE entwickelt. Der Gierratensensorfehler wird mit dem Nullpunktdrift $Drift_{\omega}(T, A, \Delta t_0)$ und dem Sensitivitätsfehler $Sens_{\omega}(T, A, \Delta t_0)$ korrigiert. Dadurch werden die Temperatur- T und Alterungseffekte A des Sensors berücksichtigt. Zusätzlich wird der Einfluss des Anlaufdrifts beachtet, da der YRPE erst nach $\Delta t_0 = 5$ min nach dem Anlassen des Motors gestartet wird (siehe Absatz 2.3.5). Um die Funktionalität zu verstehen, werden im Folgenden der Zustand sowie das System- und das Messmodell definiert.

Definition des Zustands

Als Zustand werden die Bewegungszustände x_k , y_k und θ_k sowie die Gierrate ω_k verwendet. Um die Fehlergrößen der Gierrate zu ermitteln, wird der Zustandsvektor um die möglichen Sensorfehler der Gierrate mit dem invertierten Sensitivitätsfehler $Sens_{\omega,k}^{-1}$ und dem Nullpunktdrift $Drift_{\omega}$ aus Gleichung 2.25 erweitert. Der erweiterte Zustandsvektor nimmt folgende Form an:

$$\mathbf{x}_k = \left[x_k \quad y_k \quad \theta_k \quad \omega_k \quad Sens_{\omega,k}^{-1} \quad Drift_{\omega,k} \right]^T \in \mathbb{R}^6. \quad (4.25)$$

Definition des Systemmodells

Die Grundlage für die Schätzung der Fehlergrößen der Gierrate, bildet das *kinematische Gierratenmodell* OdoYawRate. Hierfür wird die erweiterte Bewegungsgleichung aus Abschnitt 3.1 verwendet, die den Term $\frac{\omega \cdot \Delta t}{2}$ beinhaltet. Dies ist notwendig, da für die Kalibrierung des Gierratensensors eine genaue Bestimmung der Rotation erforderlich ist. Zusätzlich ist die Abtastfrequenz f_s des Gierratensensors doppelt so hoch wie die der Kalibrierfilter. Mithilfe

der Bewegungsgleichungen (3.9) und der Gleichung des Sensorfehlers (2.25) ergibt sich das Zustandsraummodell für den YRPE:

$$\mathbf{x}_k = \mathbf{f}(\mathbf{x}_{k-1}, \mathbf{u}_k) = \begin{bmatrix} x_{k-1} \\ y_{k-1} \\ \theta_{k-1} \\ 0 \\ Sens_{\omega, k-1}^{-1} \\ Drift_{\omega, k-1} \end{bmatrix} + \begin{bmatrix} \bar{v}_k^\times \cdot \cos(\theta_{k-1} + \frac{\omega_{k-1} \cdot \Delta t}{2}) \\ \bar{v}_k^\times \cdot \sin(\theta_{k-1} + \frac{\omega_{k-1} \cdot \Delta t}{2}) \\ \omega_{k-1} \cdot \Delta t \\ (\omega_{ESP, k}^\times - Drift_{\omega, k-1}) \cdot Sens_{\omega, k-1}^{-1} \\ 0 \\ 0 \end{bmatrix}. \quad (4.26)$$

Als Eingänge werden die mittlere Geschwindigkeit der Hinterräder \bar{v}_k^\times und die Messung des Gierratensensors $\omega_{ESP, k}^\times$ definiert:

$$\mathbf{u}_k = \begin{bmatrix} \bar{v}_k^\times & \omega_{ESP, k}^\times \end{bmatrix}^T \in \mathbb{R}^2. \quad (4.27)$$

Definition des Messmodells

Als Messmodell wird die absolute Positionsmessung des GNSS-Empfängers des Fahrzeugs verwendet, ebenso wie bereits beim AKPE. Zusätzlich wird das Messmodell durch die berechnete Gierrate des *kinematischen Zweispurmodells* erweitert. Falls nur die GNSS-Positionsmessung genutzt wird, führt das zu einer schlechteren Leistung, da die Gierrate empfindlich auf mögliche Fehler reagiert.

$$\mathbf{z}_k = \begin{bmatrix} x_{GNSS, k}^\times & y_{GNSS, k}^\times & \omega_{Modell, k} \end{bmatrix}^T \in \mathbb{R}^3. \quad (4.28)$$

Das Messmodell $\mathbf{h}(\cdot)$ ist unkompliziert und die Zustände können direkt durch die Messungen angepasst werden:

$$\mathbf{h}(\mathbf{x}_k) = \begin{bmatrix} x_k & y_k & \omega_k \end{bmatrix}^T. \quad (4.29)$$

Filteralgorithmus

Es wird der Filteralgorithmus des EKF aus Absatz 3.3.1 verwendet, da dieser das Bewegungs- und das Fehlermodell des Gierratenmodells im Systemmodell sowie das Messmodell hinreichend genau approximiert.

Filtereinstellung

Für die Einstellung des Filters werden die Kovarianzmatrizen mit den Standardabweichungen ausgestattet. Tabelle 4.2 fasst die für den YRPE zusätzlich bestimmten Standardabweichungen zusammen. Die Standardabweichungen für die Parameter werden parallel zum SA-RAKPE direkt auf 0 gesetzt, um einen konvergierenden Kalibrierfilter zu erhalten. Die Diagonalmatrizen $\text{diag}(\cdot)$ für die Messkovarianzmatrix \mathbf{R} und die Prozessrauschenkovarianzmatrix \mathbf{Q} ergeben sich folgendermaßen:

$$\begin{aligned}\mathbf{Q} &= \text{diag} \left(\left[\begin{array}{ccccc} \sigma_{f,x,k}^2 & \sigma_{f,y,k}^2 & \sigma_{f,\theta,k}^2 & \sigma_{f,\omega}^2 & 0 & 0 \end{array} \right] \right), \\ \mathbf{R} &= \text{diag} \left(\left[\begin{array}{ccc} \sigma_{\text{GNSS},k}^2 & \sigma_{\text{GNSS},k}^2 & \sigma_{h,\omega}^2 \end{array} \right] \right).\end{aligned}\quad (4.30)$$

Tabelle 4.2: Zusätzliche Standardabweichungen σ für den YRPE.

Variable	Wert	Einheit	Standardabweichung
$\sigma_{f,\omega}$	$\pm 1 \cdot 10^{-3}$	$^{\circ}/s$	Modellfehler der Gierrate
$\sigma_{h,\omega}$	$\pm 1 \cdot 10^{-0}$	$^{\circ}/s$	Gierratenfehler des Odo2Track

Ergebnis des YRPE

Um die Funktionalität und die Leistung des YRPE zu testen, wird ein Szenario auf einem großen Parkplatz ausgewählt, in dem Kurven und Wendungen durchfahren werden. Der Gierratensensor wird mit einem künstlichen Gierratensensorfehler beaufschlagt. Zudem wird er mit dem spezifizierten Nullpunktsfehler $Drift_{\omega} = 0,5^{\circ}/s$ und dem Sensitivitätsfehler $Sens_{\omega} = 1,1$ versehen. Abbildung 4.10 zeigt den Verlauf der geschätzten Zustände.

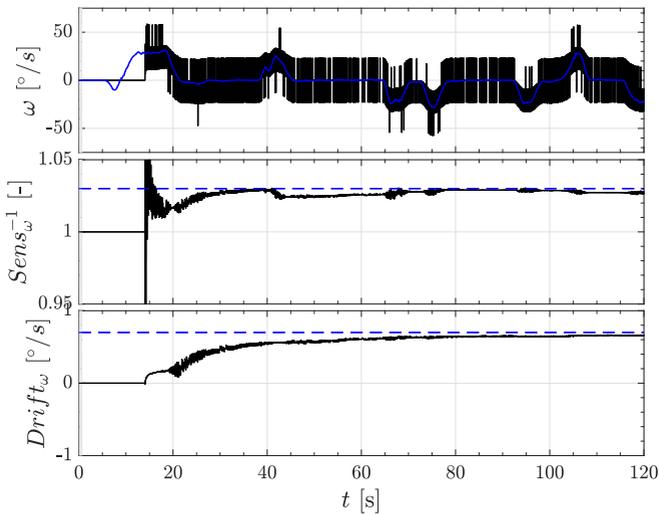


Abbildung 4.10: Bewegungszustände und geschätzte Gierratensensorfehler des YRPE mit Messungen des GNSS und des kalibrierten Odo2Track. Die Referenz-Gierrate sowie die Fehlergrößen sind in Blau angegeben.

Nach einer Verzögerung von 14 s beginnt die Messung des SSA, da in dieser Zeit die Signalverzögerung erkannt wird. Die Bestimmung der Gierratensensorfehler erfolgt daraufhin schnell und nach 80 s sind die Werte ausreichend genau. Falls ausschließlich das *kinematische Zweispurmodell* zur Messung genutzt wird, kann der YRPE instabil sein und die Genauigkeit bei kurzen Messungen nicht vollständig erreicht werden. Verwendet man hingegen nur GNSS-Messungen, gestaltet sich die Schätzung der Gierratensensorfehler nahezu unmöglich.

Ergebnis des YRPE und des SA-RAKPE

Um zu demonstrieren, wie die Kalibrierfilter für das Konzept der Parameterschätzung zusammenarbeiten, zeigt Abbildung 4.11 die geschätzten Parameter und Kovarianzen von SA-RAKPE und YRPE. Diesmal wird ein Szenario gewählt, bei dem das Versuchsfahrzeug sich zunächst auf Straßen außerhalb der Stadt bewegt und dann auf einem großen Parkplatz herumfährt.

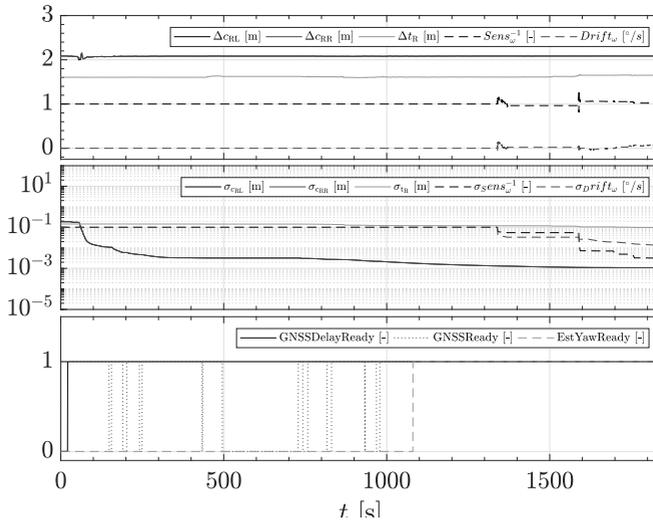


Abbildung 4.11: Parameterschätzung des YRPE und des SA-RAKPE.

Es ist zu erkennen, dass der SSA 25 s benötigt, um mithilfe der Korrelationsfunktion eine GNSS-Signalverzögerung zu erkennen. Anschließend berechnet der SA-RAKPE die Abrollumfänge und die Spurweite. Sobald eine Genauigkeit von $\sigma_{cRL} + \sigma_{cRR} \leq 0,004$ m erreicht wird, wird nach 1350 s der YRPE gestartet, um die Gierratensensorfehler zu bestimmen. Die Kalibrierung des Gierraten-Sensorfehlers erfordert daher lange Kalibrierläufe, was zu einer Einschränkung der Verwendung der gemessenen Gierrate im Lokalisierungsfilter führen kann. Das Gierratenmodell muss nach einer längeren Standzeit kalibriert werden, da Temperatur- und Alterungseinflüsse zu großen Sensorfehlern führen können.

Ergebnisse hinsichtlich der **Gierratensensor-Kalibrierung:**

- Der YRPE kann verwendet werden, um mithilfe des Fehlermodells die Gierratensensorfehler zu bestimmen. Dafür werden das Bewegungsmodell des OdoYawRate und der EKF verwendet.

- Das Sensorfehlermodell berücksichtigt die Temperatur- und Alterungseinflüsse des Gierratensensors. Zusätzlich wird der Einfluss des Anlaufdrifts berücksichtigt und die Kalibrierung nach einer Verweildauer ($\Delta t_0 = 5 \text{ min}$) nach dem Starten des Motors gestartet.
- Um Gierratensensorfehler zu erkennen, müssen die absolute GNSS-Positionsmessung und das kalibrierte Odo2Track zusammen verwendet werden, damit eine ausreichende Leistung erzielt werden kann.
- Damit der YRPE hinreichend genaue Werte liefert, muss der SA-RAKPE vorher entsprechend genaue Achsparameter ($\sigma_{\text{cRL}} + \sigma_{\text{cRR}} \leq 0,004 \text{ m}$) ermitteln.
- Im Konzept der Fahrzeugparameterschätzung erfordert der YRPE aufgrund des SA-RAKPE längere Kalibrierläufe. Für eine höhere Standzeit des Fahrzeugs bedeutet dies eine eingeschränkte Nutzung der gemessenen Gierrate im Lokalisierungsfilter.

5 Sichere Rollrichtungsschätzung

In diesem Kapitel wird eine Erweiterung des Lokalisierungsfilters behandelt, die es ermöglicht, die Rollrichtung beim Parken frühzeitig und zuverlässig zu erkennen. Dazu werden zwei Ansätze für die frühe Schätzung der Rollrichtung entwickelt, die eine Schätzung liefern, noch bevor der anisotrope magnetoresistive (AMR)+Sensor eine Rollrichtung definiert hat (siehe Abschnitt 2.3.1). Der erste Ansatz nutzt den Kräftegleichgewichtsalgorithmus Force-Equilibrium-Algorithm (FEA). Der zweite Ansatz basiert auf dem Radzählermusteralgorithmus WPA. Da die Rollrichtungsschätzung eingeschränkt sein und zu falschen Schätzungen führen kann, wurde eine Dual-Filtererweiterung entwickelt. Diese setzt sich aus zwei gegenläufigen Lokalisierungsfiltren und einer Initialisierungslogik zusammen, die eine Absicherung gegen fehlerhafte Rollrichtungsschätzungen gewährleistet.

5.1 Rollrichtungsschätzung

Damit der Lokalisierungsfilter in Echtzeit betrieben werden kann, muss die Information über die Rollrichtung frühzeitig vorliegen. In Abbildung 5.1 ist in der oberen Grafik der Verlauf der verschiedenen Rollrichtungssignale d gezeigt. In der unteren Grafik sind die DWPCs mit und ohne definiertes Rollrichtungssignal dargestellt. Zusätzlich sind die Geschwindigkeit des Odo-Filters unter Verwendung aller DWPCs und die Referenz-Geschwindigkeit des Referenzmesssystems abgebildet. Bei der Messung wird das Versuchsfahrzeug aus einer Rückwärtsfahrt in den Stillstand abgebremst und nach kurzer Zeit vorwärts beschleunigt.

Es ist zu erkennen, dass beim Anfahren bis zu vier DWPCs und beim Abbremsen bis zu zwei DWPCs ohne definierte Rollrichtung vorliegen. Die beiden neuen Methoden der Radzählermuster und des Kraftgleichgewichts hingegen schätzen die tatsächliche Rollrichtung schon 0,5-2 s früher ab. Im Folgenden werden nun die verschiedenen Methoden mit ihren Stärken und Schwächen beschrieben.

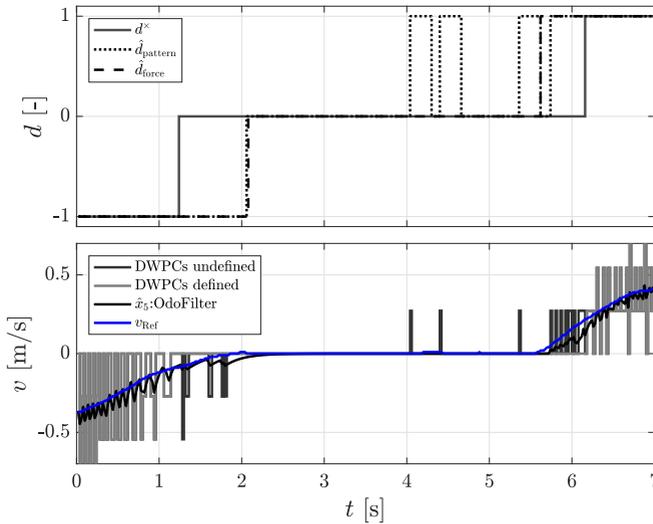


Abbildung 5.1: Vergleich der Methoden zur Schätzung der Rollrichtung beim Wechsel von der Rückwärts- zur Vorwärtsfahrt mit kurzzeitigem Stillstand. Oben: Rollrichtungssignale, unten: DWPCs und Geschwindigkeit.

Rollrichtungserkennung mittels AMR+-Sensoren

Die Radrollrichtungserkennung mittels AMR+-Sensoren wurde bereits im Absatz 2.3.1 beschrieben. Um eine Rollrichtung für das gesamte Fahrzeug zu erhalten, werden die Radrollrichtungen der zwei bzw. vier AMR+-Sensoren nach einer einfachen Logik kombiniert. Wenn mehr als ein Rad eine Richtung erkannt hat, wird diese Richtung ausgegeben, gibt es eine mehrdeutige Lösung, wird keine Richtung ausgegeben. Wie in Abbildung 5.1 dargestellt, kann es vorkommen, dass ein gültiges Rollrichtungssignal d^\times erst nach 4 gemessenen DWPCs ausgegeben wird.

5.1.1 Wheel-Counter-Pattern-Algorithm (WPA)

Für eine frühzeitige Rollrichtungswechseleerkennung wird ein Radzählermusteralgorithmus der WPA entwickelt, der die zeitliche Abfolge der DWPCs der einzelnen Räder paarweise untersucht. Eine detaillierte Beschreibung

des Verfahrens mit Beispiel findet sich in der Offenlegung [O5]. Das Prinzip ähnelt der Richtungserkennung von AMR+-Sensoren, bei der zwei leicht gegeneinander verdrehte Encoderringe zur Erfassung einer Phasenverschiebung der Signale verwendet werden. Der WPA speichert die Reihenfolge der DWPCs. Zu diesem Zweck werden sechs Radpaare gebildet und für jedes Radpaar geprüft, ob sich die Reihenfolge umgedreht hat. Wird eine Umkehr für mehr als zwei Radpaare festgestellt, erkennt der WPA eine Änderung der Rollrichtung. Wenn eine neue Rollrichtung erkannt wird, wird diese für 250 ms beibehalten, um schnelle Richtungsänderungen zu verhindern. Die zeitliche Abfolge ergibt sich aus einer zufälligen Gegeneinander-Verdrehung der Encoderringe der Räder. Abbildung 5.2 zeigt den Verlauf der DWPCs der einzelnen Räder.

In diesem Vektor sind die Unterkomponenten FL, RR, FR, RL, usw. die Merkmale oder Datenpunkte, die im Kontext deines Problems relevant sind, und sie sind in Abhängigkeit von den Indizes j und k . Dieser Vektor enthält Informationen über die verschiedenen Radpaare und ist ein wichtiges Merkmal in deinem Anwendungsfall.

Die DWPCs bis $t = 2$ s wechseln nach dem Schema [..., RL, FR, RR, FL]. Ab $t = 4$ s kehrt sich das Schema um zu [FL, RR, FR, RL, ...] und das Fahrzeug hat seine Rollrichtung geändert. Die ersten drei DWPCs der Vorderräder und 2 DWPCs der Hinterräder haben dabei keine Richtungszugehörigkeit durch die AMR+-Sensoren. Der WPA verspricht eine schnellere Erkennung des Rollenrichtungswechsels. Bei dynamischen Änderungen kann es allerdings vorkommen, dass falsche Rollrichtungsänderungen erkannt werden, wenn z. B. die initiale Rollrichtung falsch indiziert wurde, weil das gespeicherte Schema aus Vorwärts- und Rückwärtsabschnitten besteht. Da der WPA nur eine Änderung der Rollrichtung erkennt, gibt es keine Aussage über die absolute Rollrichtung. Es könnte theoretisch vorkommen, dass alle DWPCs gleichzeitig auftreten, weil die Encoderringe perfekt ausgerichtet sind; hier funktioniert der WPA ebenfalls nicht. Wenn die Radlenkwinkel durch Lenken im Stillstand verändert werden oder große Abrollumfangdifferenzen herrschen, kann sich die Abfolge der DWPCs ändern, hier ist der WPA ebenfalls eingeschränkt. Trotz seiner adäquaten Leistung hat der WPA somit einige Einschränkungen, die dazu führen, dass eine falsche Rollrichtung erkannt werden kann.

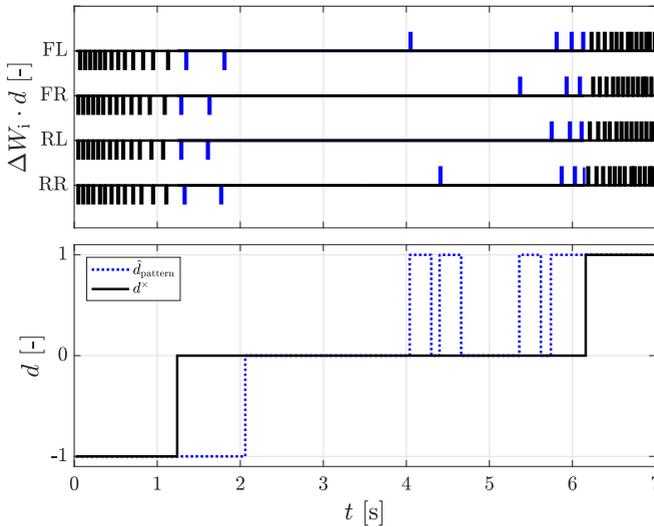


Abbildung 5.2: Veranschaulichung der Methode der Radzählermuster zur Rollrichtungsschätzung der WPAs. Die schwarz markierten DWPCs verfügen durch den AMR+-Sensor über eine definierte Rollrichtung. Die DWPCs, die keine definierte Rollrichtung haben, sind blau markiert.

5.1.2 Kräftegleichgewicht-Rollrichtung

Für eine frühzeitige Rollrichtungs- und Stillstandserkennung wird der Kräftegleichgewichtsalgorithmus (engl. FORCE-EQUILIBRIUM-ALGORITHM (FEA)) entwickelt, der mittels eines Kräftegleichgewichts in Fahrzeuglängsrichtung eine Rollrichtung und einen sicheren Stillstand bestimmen kann. Eine detaillierte Beschreibung des Verfahrens inklusive Algorithmus und Beispiel findet sich in der Offenlegung [O6].

Der FEA bestimmt aus dem Vorzeichen der Geschwindigkeit $\text{sign}(v_x)$ des Kräftegleichgewichts in Fahrzeuglängsrichtung eine absolute Rollrichtung. Dazu wird das Kräftegleichgewicht wie folgt bestimmt:

$$m \cdot a_x = \sum_i F_{x,i}(v_x) = F_{\text{drive}} - F_{\text{fric}}(v_x). \quad (5.1)$$

Wenn der Betrag der Reibungskraft F_{fric} größer ist als der Betrag der Antriebskraft F_{drive} , wird zudem ein sicherer Stillstand definiert. Die Reibungskraft $F_{\text{fric}}(v_x)$ beinhaltet das geschwindigkeitsabhängige Vorzeichen, das für die Rollrichtungsschätzung ausgewertet wird. Die folgenden Kräfte oder Momente werden für das Kräftegleichgewicht berücksichtigt:

- Motormoment am Rad $T_{\text{engine}} \rightarrow F_{\text{engine}} = T_{\text{engine}}/r_D$,
- Motorschleppmoment am Rad $T_{\text{drag}} \rightarrow F_{\text{drag}} = T_{\text{drag}}/r_D$,
- Bremskraft $T_{\text{brake}} \rightarrow F_{\text{brake}} = T_{\text{brake}}/r_D$,
- Rollreibungskraft $F_{\text{roll}} = \mu_{\text{roll}} \cdot m \cdot g \cdot \cos(\phi)$,
- Hangabtriebskraft $F_{\text{slope}} = m \cdot g \cdot \sin(\phi)$.

Das Motor- und das Motorschleppmoment am Rad T_{engine} , T_{drag} sowie das Bremsmoment T_{brake} werden auf dem Fahrzeugbus bereitgestellt. Die Steigung der Fahrbahn ϕ , die Fahrzeugmasse m und der Reibungskoeffizient μ_{roll} müssen zusätzlich geschätzt werden. Es gibt bereits viele Forschungsarbeiten [57–59] zu dem Thema. Für eine einfache Umsetzung reichen Grundwerte und eine simple Steigungsschätzung mithilfe eines Abgleichs über den Längsbeschleunigungssensor, um die Steigung für das Anfahren aus dem Stillstand zu bestimmen.

Die Reibungskraft F_{fric} wirkt der Geschwindigkeit entgegen und setzt sich aus der Bremskraft F_{brake} , der Motorschleppkraft F_{drag} und der Rollreibungskraft F_{roll} wie folgt zusammen:

$$F_{\text{fric}}(v_x) = \text{sign}(v_x) \cdot (F_{\text{brake}} + F_{\text{drag}} + F_{\text{roll}}). \quad (5.2)$$

Die Antriebskraft F_{drive} setzt sich aus der Motorkraft F_{engine} und der Hangabtriebskraft F_{slope} zusammen und ist unabhängig von der Richtung der Geschwindigkeit:

$$F_{\text{drive}} = F_{\text{engine}} + F_{\text{slope}}. \quad (5.3)$$

In Abbildung 5.3 sind in der oberen Grafik die Antriebskraft F_{drive} und der positive sowie negative Wert der Reibungskraft F_{fric} aus dem Kräftegleichgewicht dargestellt. In der unteren Grafik sind die Rollrichtungen dargestellt. Sobald die Antriebskraft F_{drive} betragsmäßig die Reibungskraft F_{fric} übersteigt, ist eine Rollrichtung definiert. Sobald die Antriebskraft F_{drive} für

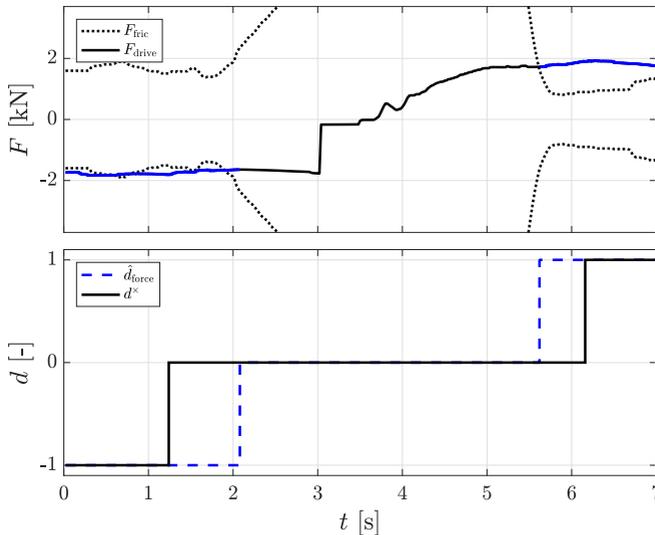


Abbildung 5.3: Veranschaulichung der Methode des Kräftegleichgewichts zur Rollrichtungsschätzung. In Schwarz markiert die Kräfte und die AMR+-Sensor definierte Rollrichtung ohne Erkennung. In Blau die durch den WPA erkannte betragsmäßig positive Antriebskraft und dazugehörige Rollrichtung.

100 ms betragsmäßig kleiner ist als die Reibungskraft F_{fric} , gilt ein sicherer Stillstand.

Der Ansatz des Kräftegleichgewichts ist empfindlich gegenüber falschen Steigungsschätzungen, wie in der Veröffentlichung [V3] gezeigt wurde. Dynamische Fahrmanöver führen zu ähnlichen Einschränkungen wie beim WPA. Ein großer Vorteil des Kräftegleichgewichts ist jedoch, dass keine DWPCs verwendet werden, was zu einer unabhängigen Methode der Rollrichtungsschätzung führt.

Ergebnisse hinsichtlich der **Rollrichtungsschätzung**:

- Die Rollrichtungen mittels anisotropen magneto-resistiven (AMR)-Sensoren werden aus zwei bzw. vier Radrollrichtungen berechnet. Es kann teilweise bis zu vier Delta-Wheel-Pulse-Counts (DWPCs) dauern, bis eine Rollrichtung ausgegeben wird.
- Der Rollrichtungswechsel kann durch den Radzählermusteralgorithmus WPA früh erkannt werden. In den meisten Fällen wird eine Änderung der Rollrichtung bereits mit dem ersten DWPCs festgestellt. Allerdings gibt es Einschränkungen bei dynamischen Manövern mit schnellen Änderungen der Rollrichtung, insbesondere wenn die initiale Rollrichtung noch unbekannt ist. Große Veränderungen der Radlenkwinkel und Unterschiede im Abrollumfang können ebenfalls zu Einschränkungen führen.
- Die absolute Rollrichtung und der Stillstand können mittels Force-Equilibrium-Algorithm (FEA) durch das Kraftgleichgewicht in Fahrzeuglängsrichtung bestimmt werden. Der Vorteil dabei ist die Unabhängigkeit von den Messungen des DWPCs, was früh zu Schätzungen der Rollrichtung führt. Einschränkungen ergeben sich hauptsächlich aus der Berechnung der Hangabtriebskraft durch die geschätzte Steigung, aber auch durch eine falsch berechnete Fahrzeugmasse, ungenaue Fahrzeugmomente oder unbekannte Reibungskoeffizienten.

5.2 Dual-Lokalisierungsfilter-Erweiterung

Die neuen Methoden zur Rollrichtungsschätzung können die Rollrichtung bereits vor oder mit dem ersten DWPC erfassen und eine echtzeitfähige Anwendung des Lokalisierungsfilters ermöglichen. Dennoch kann es zu einer fehlerhaften Schätzung kommen. Da der Lokalisierungsfilter ständig eine Berechnung der Position durchführen muss, verwendet er eine Schätzrollrichtung. Stellt sich heraus, dass die geschätzte Rollrichtung falsch ist, muss eine Lösung gefunden werden, da der Fehler nicht einfach aus dem Lokalisierungsfilter mit den Zuständen und Kovarianzen zurückgerechnet werden kann. Daher wird eine Dual-Filtererweiterung entwickelt, die diesen Fehler behebt. Die Idee des Dual-Lokalisierungsfilters wurde bereits in der Offenlegung [O7] vorgestellt und in der Veröffentlichung [V3] angewendet.

Im Folgenden wird das Konzept kurz gezeigt und bewertet.

Die Dual-Filtererweiterung verwendet zwei Filter und eine Initialisierungslogik, die sicherstellt, dass bei verzögerten bilateralen Mehrdeutigkeitsmessungen die beiden Filter jeweils eine andere Messung verwenden und durch eine Schätzung die Lösung des primären Filters herausgegeben wird. Nach der Verzögerung und der Auswertung der korrekten Messung wird der falsche Filter mit den Zuständen und Kovarianzen des korrekten Filters initialisiert.

Zum Schutz vor einer falschen Rollrichtungsschätzung werden für die Dual-Lokalisierungsfilter-Erweiterung zwei Lokalisierungsfilter und die Initialisierungslogik verwendet. Der primäre (1.) Filter verwendet die durch die neuen Methoden geschätzte und der sekundäre (2.) Filter die entgegengesetzte Richtung. Sobald ein valides Rollrichtungssignal des AMR+-Sensors vorliegt, wird über eine Initialisierungslogik entschieden, welcher Lokalisierungsfilter sich zuvor in die korrekte Richtung bewegt hat. Der Lokalisierungsfilter, der in die falsche Richtung gefahren ist, wird mit den Zuständen und Kovarianzen des anderen Lokalisierungsfilters initialisiert. Das Konzept des Dual-Lokalisierungsfilters ist in Abbildung 5.4 dargestellt.

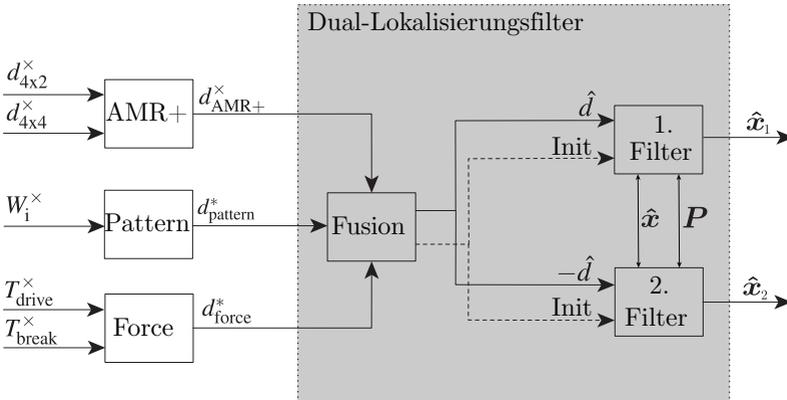


Abbildung 5.4: Konzept des Dual-Lokalisierungsfilters.

Es gibt sechs Module, die ersten drei enthalten jeweils die Rollrichtungsschätzungen und übergeben diese an das Fusionsmodul, das die Rollrichtungen auswertet und die Initialisierungslogik enthält. Die letzten beiden Module bestehen aus dem 1. und dem 2. Filter, die ihre Zustände und Kovarianzen austauschen können. Theoretisch verdoppelt sich der Rechenressourcenbedarf mit der Dual-Lokalisierungsfilter-Erweiterung, da zwei Lokalisierungsfilter verwendet werden. Allerdings kann durch Halbierung der Abtastrate f_S beim Anfahren und beim Betrieb des Dual-Lokalisierungsfilters der zusätzliche Rechenressourcenbedarf ausgeglichen werden. Im schlimmsten Fall kann dies dazu führen, dass das Fahrzeugbewegungsmodell um eine halbe Abtastrate hinterherhinkt, was beim Anfahren noch akzeptabel wäre.

Initialisierungslogik

Wenn die AMR+-Rollrichtung einen Stillstand anzeigt, folgt der 1. Filter der fusionierten Schätzrichtung und der 2. Filter der entgegengesetzten Richtung. Wenn die AMR+-Rollrichtung entweder den Wert 1 oder den Wert -1 einnimmt, folgen beide Lokalisierungsfilter dieser Richtung. Es wird ermittelt, welcher Lokalisierungsfilter sich zuvor in die korrekte Richtung bewegt hat und dadurch zu jedem Zeitpunkt den Initialisierungszustand definiert. Insgesamt können die sieben Initialisierungszustände *Init* ermittelt werden, die in Tabelle 5.1 zusammengefasst und anschließend näher beschrieben werden:

Tabelle 5.1: Initialisierungszustände der Initialisierungslogik des Dual-Lokalisierungsfilters.

<i>Init</i>	DWPCs	d^\times	d^*	<i>true/false</i>
1	0	-	-	-
2	0	0	1	-
3	0	0	0	-
4	1	1	-	-
5	1	1	1	<i>true</i>
6	1	1	-1	<i>false</i>
7	1	-1	0	<i>false</i>

1. Ausgangszustand: Keine DWPCs und keine Schätzrichtung.

2. Aktiver Zustand: Es liegen noch keine DWPCs vor, aber es gibt schon eine Schätzrichtung. Hierbei bewegen sich beide Lokalisierungsfilter in entgegengesetzte Richtungen.
3. Passiver Zustand: Keine DWPCs und keine Schätzrichtung. Zuvor gab es allerdings eine initiale Richtung.
4. Idealer Zustand: Es gibt DWPCs und die AMR+-Rollrichtung erkennt sofort eine Rollrichtung.
5. Sekundärer Initialisierungszustand: Es gibt DWPCs und die Schätzrichtung war richtig. Der 2. Filter wird mit den Werten des 1. Filter initialisiert.
6. Primärer Initialisierungszustand: Es gibt DWPCs und die Schätzrichtung war falsch. Der 1. Filter wird mit den Werten des 2. Filter initialisiert.
7. Fehlerzustand: Es erscheinen DWPCs und die AMR+-Rollrichtung wechselt das Vorzeichen.

Abbildung 5.5 zeigt die Vorgehensweise des Dual-Lokalisierungsfilters und den Wechsel der Initialisierungszustände. In der oberen Abbildung sind die 3 Rollrichtungssignale des Dual-Lokalisierungsfilters aus Abbildung 5.4 für einen Einparkvorgang zu sehen. In der mittleren Abbildung ist die Richtungsschätzung abgebildet. Die untere Abbildung stellt den zeitlichen Verlauf des Initialisierungszustands Init aus Tabelle 5.1 dar.

In den ersten Sekunden befindet sich das Fahrzeug im Stillstand und alle Rollrichtungssignale sind 0 oder zeigen in die initiale Vorwärtsrichtung; es herrscht der Ausgangszustand Init 1. Ab 2 s wird eine Schätzrichtung durch das Kräftegleichgewicht in Rückwärtsrichtung ermittelt und die AMR+-Rollrichtung hat immer noch den Wert 0. Es herrscht der aktive Zustand Init 2, der 1. Filter nimmt die geschätzte Richtung und der 2. Filter die entgegengesetzte Richtung an. Ab 2,5 s wird eine AMR+-Rollrichtung erkannt, folglich wird der sekundäre Initialisierungszustand Init 5 gewählt und der 2. Filter wird mit den Werten des 1. Filters initialisiert. Ab 18 s springt die AMR+-Rollrichtung auf 0, die Richtungsschätzung liefert weiter den Wert -1 . Deshalb wird wieder der aktive Zustand Init 2 aktiviert und der 2. Filter nimmt die entgegengesetzte Richtung des 1. Filters ein. Ab 19 s liefert die Richtungsschätzung den Wert 0 und das Fahrzeug befindet sich im Stillstand.

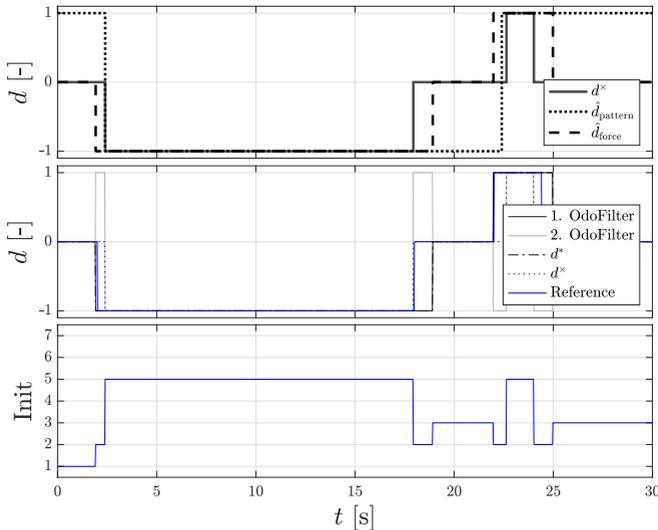


Abbildung 5.5: Veranschaulichung der Initialisierungszustände bei Schätzung der Rollrichtung beim Parkvorgang.

Da die AMR+-Rollrichtung und die Richtungsschätzung den Wert 0 einnehmen, kann nicht ausgewertet werden, welcher Lokalisierungsfiler sich in die richtige Richtung bewegt hat, weil der passive Zustand Init 3 vorliegt. Das Schema für die Vorwärtsfahrt ist danach entsprechend.

Beurteilung des Konzepts beim Parkvorgang

Um die Leistung des Dual-Lokalisierungsfilters zu testen, wird der Geschwindigkeitsverlauf der einzelnen Lokalisierungsfiler in Abbildung 5.6 gezeigt. Zusätzlich wird ein Lokalisierungsfiler dargestellt, der die Rollrichtungsschätzung OdoFilter d^* und die AMR+-Rollrichtung OdoFilter d^x verwendet.

Es ist zu erkennen, dass der 2. Filter nach jedem Anfahren initialisiert wird, weil die Rollrichtungsschätzung richtig war. Hierbei wird deutlich, dass die Leistung der in Abschnitt 5.1 vorgestellten Methoden zu einer schnelleren Rollrichtungsschätzung führt. Zur Beurteilung wird zusätzlich der akkumulierte Geschwindigkeitsfehler betrachtet, da die Beurteilungskriterien aus

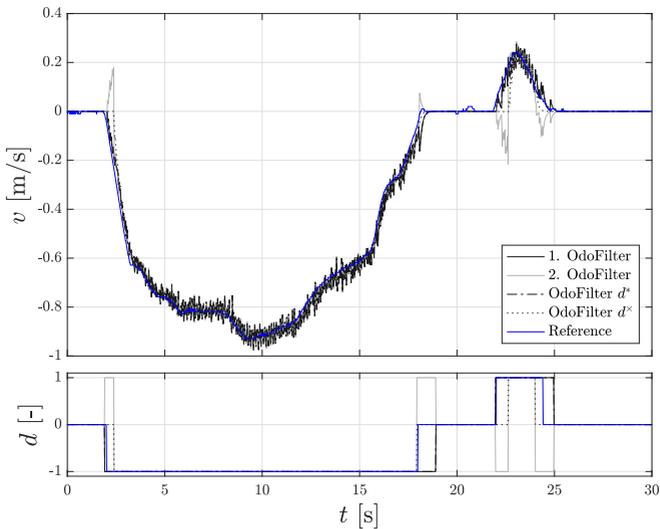


Abbildung 5.6: Geschwindigkeitsverlauf des 1. und des 2. Filters beim Parkvorgang.

Absatz 3.5.3 für den Vergleich nicht herangezogen werden können, da sie die Rollrichtung nicht explizit berücksichtigen. Ein falsch angenommenes Rollrichtungssignal kann so den Positionsfehler wieder ausgleichen. Abbildung 5.7 zeigt den akkumulierten Geschwindigkeitsfehler und den Initialisierungszustand.

Beim Parkvorgang verarbeitet der 1. OdoFilter dieselben Rollrichtungen wie der Lokalisierungsfilter unter Verwendung der Rollrichtungsschätzung OdoFilter d^* , weshalb der derselbe akkumulierte Geschwindigkeitsfehler auftritt. Der 2. Filter weist den größten akkumulierten Geschwindigkeitsfehler auf. Jedoch wird dieser immer mit den Zuständen des 1. Filters initialisiert und folglich besitzen beide Lokalisierungsfilter bei vorhandener AMR+-Rollrichtung dieselben Initialisierungszustandswerte. Der zuvor bei nichtvorhandener AMR+-Rollrichtung aufgebaute akkumulierte Geschwindigkeitsfehler kann nicht abgebaut werden. Der akkumulierte Fehler des 1. Filters ist niedriger als der des Lokalisierungsfilters mit AMR+-Rollrichtung. Dies bestätigt, dass die Richtungsschätzung, soweit sie der wahren Richtung

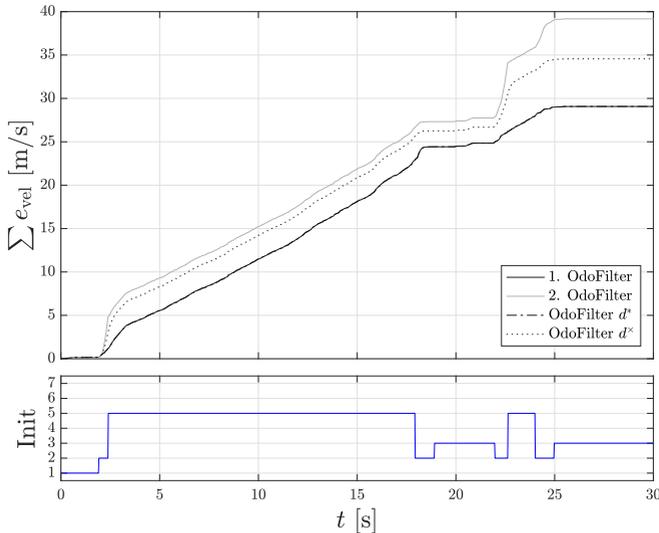


Abbildung 5.7: Geschwindigkeitsfehler des 1. und des 2. Filters beim Parkvorgang und die Initialisierungszustandswerte beim Parkvorgang.

entspricht, sinnvoll ist und zu einer genaueren Modellierung des Lokalisierungsfilters führt.

Beurteilung des Konzepts am Steigungshügel

Wie in Absatz 5.1.2 beschrieben, kann es aufgrund der geschätzten Steigung zu Problemen des FEA kommen. Damit beide Ansätze zur Rollrichtungsschätzung an ihre Grenzen stoßen, wird eine Messung am Steigungshügel mit einem dynamischen Fahrmanöver, bestehend aus mehreren schnellen Anfahrten und Änderungen der Rollrichtung, gewählt. Zu Beginn der Messung befindet sich das Fahrzeug im Ruhezustand. Anschließend fährt es den 20%igen Steigungshügel mit etwa 10 km/h hinauf und wird bis zum Stillstand abgebremst. Im weiteren Verlauf der Messung wird kontinuierlich angefahren und gebremst. Zusätzlich wird zugelassen, dass das Fahrzeug gelegentlich leicht zurückrollt. In Abbildung 5.8 sind die Geschwindigkeitsverläufe und die Rollrichtungen dargestellt.

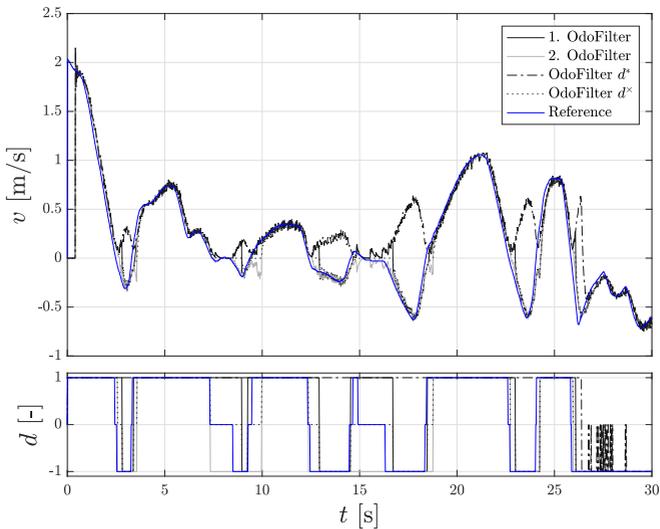


Abbildung 5.8: Geschwindigkeitsverlauf und Richtungssignal des 1. und des 2. Filters am Steigungshügel.

Es ist zu erkennen, dass meistens der 2. Filter die korrekte Richtung verwendet, da die geschätzte Rollrichtung falsch ist. Besonders der Ansatz mit dem Kräftegleichgewicht scheint hier fehlerhaft zu sein, weil hier teilweise ruckartig angefahren wird und die Steigung schwierig zu bestimmen ist. Abbildung 5.9 zeigt den akkumulierten Geschwindigkeitsfehler.

Der akkumulierte Geschwindigkeitsfehler des Lokalisierungsfilters mit der geschätzten Rollrichtung ist hier fast doppelt so groß wie bei den anderen Lokalisierungsfiltern. Der 2. Filter weist den kleinsten akkumulierten Geschwindigkeitsfehler auf, da dieser immer die entgegengesetzte Rollrichtung verwendet. Die bisherigen Untersuchungen zeigen, dass die Rollrichtungsschätzung in der Ebene die Richtung gut abschätzt, wenn das Fahrzeug aber auf einer Steigung steht und das Fahrmanöver dynamischer wird, ist die Richtungsschätzung oft falsch. Der Ansatz mit dem Kräftegleichgewicht ist somit deutlich von der Steigung abhängig.

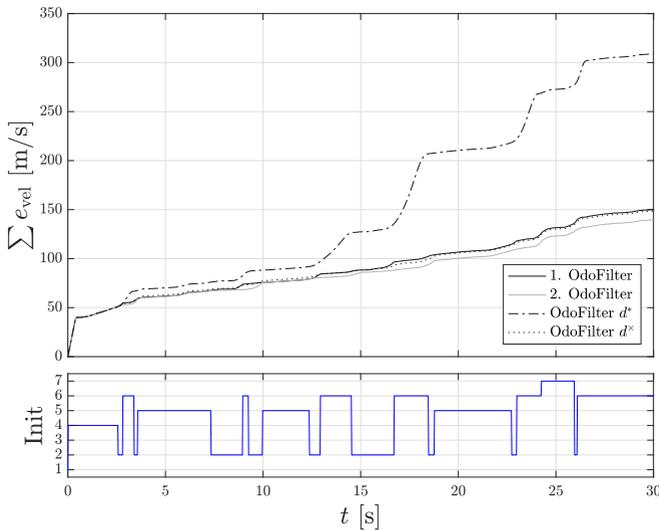


Abbildung 5.9: Geschwindigkeitsfehler und die Initialisierungszustands- werte des 1. und des 2. Filters am Steigungshügel.

Ergebnisse hinsichtlich des Konzepts der **Dual-Lokalisierungsfiler-Erweiterung:**

- Die Dual-Lokalisierungsfiler-Erweiterung sichert den Lokalisierungsfiler bei falscher Schätzung der Rollrichtung ab.
- Der doppelte Rechenressourcenbedarf des Dual-Lokalisierungsfilters kann durch Halbieren der Abtastrate f_s beim Betrieb während des Anfahrens eliminiert werden.
- Der Dual-Lokalisierungsfiler verringert den akkumulierten Geschwindigkeitsfehler bei einem falsch geschätzten Rollrichtungssignal um bis zu 50 %.
- Das Dual-Filtererweiterungsverfahren kann auch für andere Anwendungen eines Filteralgorithmus mit verzögerten bilateralen Mehrdeutigkeitsmessungen verwendet werden.

6 Automatisierte Optimierung des Lokalisierungsfilters

Die konventionellen Fahrzeugbewegungsmodelle haben aufgrund ihrer unterschiedlichen Modellierung der Bewegungszustände und Messgrößen jeweils eigene Stärken und Schwächen in verschiedenen Fahrzuständen. Um die Robustheit des Lokalisierungsfilters zu erhöhen, wird in diesem Kapitel ein Verfahren vorgestellt, das für verschiedene Fahrzustände innerhalb eines Parkvorgangs automatisiert fahrzustandsabhängige Filtereinstellungen erzeugt. Im ersten Schritt des Verfahrens wird ein Parkmanöver mithilfe der Fahrzustandsklassifizierung automatisch in Fahrsegmente mit ähnlichen Fahrzuständen unterteilt. Anschließend werden Simulationen in Form einer Monte-Carlo-Simulation (MCS) für die Fahrsegmente mit einem Fehler- und einem Koeffizientenmodell erstellt. Schließlich werden die Ergebnisse der MCS in der Optimierung verwendet, um die besten Filtereinstellungen zu finden. Zur Validierung des Verfahrens wird dann der fahrzustandsabhängige Lokalisierungsfilter in einem ähnlichen Parkmanöver mit möglichen Sensorfehlern ausgewertet. Um eine globale Bewertung der Leistungssteigerung durchzuführen, wird zusätzlich die Sensitivitätsauswertung aus Abschnitt 3.5 für den fahrzustandsabhängigen Lokalisierungsfilter durchgeführt.

6.1 Konzept: Verfahren zur automatisierten fahrzustandsabhängigen Optimierung

Der Lokalisierungsfilter bietet durch die fahrzeugbewegungsmodellabhängige Koeffizientenmatrix (vgl. Absatz 3.4.3) die Möglichkeit, das Messmodell adaptiv einzustellen. Um die Robustheit zu steigern, werden in diesem Verfahren die Filtereinstellungen für die adaptive Einstellung in Abhängigkeit vom Fahrzustand generiert. Die Idee zur Anpassung des Bewegungsmodells an die Fahrsituation wurde in der Offenlegung [O2] dargestellt. In der Offenlegung [O8] wurde zusätzlich die Methode zur Generierung der Modellgewichtung in Abhängigkeit von der Fahrsituation beschrieben. Entsprechend wurde in der Veröffentlichung [V4] eine Umsetzung des gesamten Verfahrens am

Beispiel einer einseitigen Längsparklücke gezeigt. In dieser Arbeit wird das Verfahren kurz beschrieben und auf ein symmetrisches Parkmanöver übertragen, um eine allgemeine Filterabstimmung zu erhalten. Abbildung 6.1 zeigt das Blockschaltbild des Verfahrens zur automatisierten Optimierung des Lokalisierungsfilters.

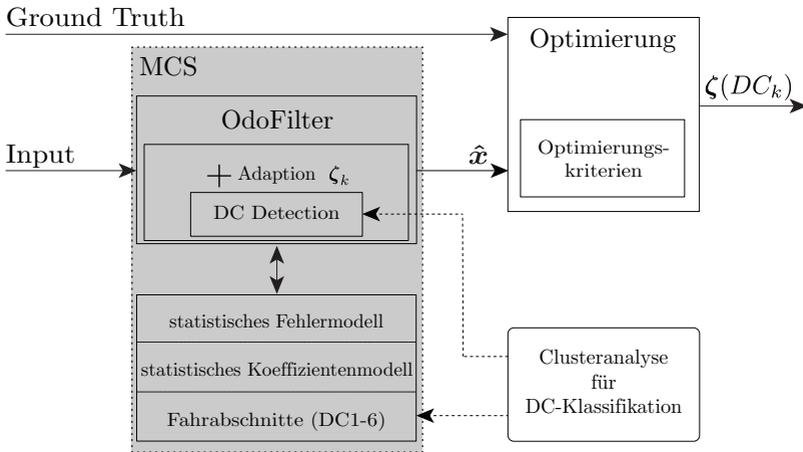


Abbildung 6.1: Konzept zur automatisierten Optimierung des Lokalisierungsfilters.

Um die fahrzustandsabhängige Optimierung durchführen zu können, wird das Parkmanöver im ersten Teil des Verfahrens, der Fahrzustandsklassifikation, in sinnvolle Fahrsegmente unterteilt, in denen konstante Fahrzustände herrschen. Diese werden im Folgenden als Driving-Conditionss (DCs) bezeichnet. In der Veröffentlichung [V4] wurde in diesem Zusammenhang bereits ein gesamter Parkprozess, bestehend aus Ein- und Ausparkmanöver, für ein PS+3m-Manöver untersucht. Weiterhin konnte gezeigt werden, dass die Fuzzy-C-Means-Clustering (FCM)-Methode nach Bezdek [60] am besten für die Aufteilung der Fahrsegmente geeignet ist, da sie gute Konvergenzeigenschaften aufweist. Um in dieser Arbeit eine allgemeinere Aussage über das Verfahren zu treffen, wird ein D-PS+3m-Manöver³³ untersucht, um

³³ D-PS+3m: Das Duplex PS+3m-Manöver stellt ein kombiniertes Szenario von zwei Längsparkvorgängen dar, einer auf der Fahrerseite und einer auf der Beifahrerseite.

symmetrische Fahrzustände zu erhalten und die Einstellung der Lokalisierungsfilter auch auf andere Szenarien übertragen zu können.

Im zweiten Teil des Verfahrens wird der in verschiedene Fahrsegmente unterteilte Parkvorgang genutzt, um ein robustes Tuning für den Lokalisierungsfilter *OdoFilter* zu generieren. Zu diesem Zweck wird eine MCS verwendet. Diese nutzt wiederholte Proben aus statistischen Modellen, um eine große Anzahl von Ergebnissen zu erhalten [61]. Dazu wird das *statistische Fehlermodell* verwendet, um statistische Fehler der Fahrzeugparameter darzustellen, und das *statistische Koeffizientenmodell*, um statistisch verteilte Messkovarianzwerte bzw. Filtereinstellungen anzugeben. Weiterhin wird die MCS für die jeweiligen Fahrsegmente erweitert und die statistischen Modelle werden je nach Fahrzustand eingesetzt. Die Ergebnisse der MCS werden verwendet und mit den Referenzwerten verglichen. Die abgeleiteten Fehler werden in der Optimierung gemäß den Bewertungskriterien (vgl. Abschnitt 3.5.3) minimiert, um die robustesten Einstellungen des Lokalisierungsfilters je nach Fahrzustand zu identifizieren.

6.2 Automatisierte Fahrzustandsklassifikation

Zunächst wird die automatisierte Fahrzustandsklassifikation mittels Clustering-Algorithmus vorgestellt. Clustering-Algorithmen oder Clusteranalysen sind Methoden zur Entdeckung von Ähnlichkeitsstrukturen in einem großen Datensatz \mathbf{X} . Die Aufzeichnung des Parkvorgangs bildet den Datensatz $\mathbf{X} = \{\mathbf{x}_1, \dots, \mathbf{x}_n\}$, der wiederum aus der chronologisch geordneten Sammlung der Daten-Tupel \mathbf{x} besteht. Diese enthalten Attribute, die dazu dienen, Fahrsegmente mit ähnlichen Fahrzuständen zu definieren und diese zu gruppieren.

Definition des Datensatzes

Um das Parkmanöver in Fahrsegmente aufzuteilen, werden Daten-Tupel mit den statischen Attributen $\mathbf{x}_i^\times \in \{\bar{v}_i^*, \delta_{F,i}^\times, \omega_i^\times\}$ verwendet. Die mittlere Geschwindigkeit \bar{v}^* , der vordere Achsenlenkwinkel δ_F^\times und die gemessene Gierrate ω^\times sind am besten geeignet, um ein Fahrsegment zu identifizieren. Ein konstantes Fahrsegment könnte z. B. ein Kurvenabschnitt sein. Dynamische Größen sind für die Klassifizierung von Fahrsegmenten nicht geeignet, da die Amplituden der Signale bei Parkmanövern im Messrauschen verloren gehen. Um die statischen Daten-Tupel zu klassifizieren, werden sie vari-

anznormalisiert, d. h. der Mittelwert und die Standardabweichung werden auf 0 gesetzt, um trotz unterschiedlicher Einheiten gleichmäßige Skalen zu erhalten. Die varianznormalisierten Daten-Tupel sind wie folgt definiert:

$$\mathbf{x}_i = \frac{1}{\hat{\sigma}_{\mathbf{x}_n^\times}} (\mathbf{x}_i^\times - \bar{\mathbf{x}}_n^\times). \quad (6.1)$$

Klassifizierung mittels Fuzzy-C-Means-Clustering (FCM)

Für die Klassifizierung von Fahrsegmenten eines Parkvorgangs hat sich das Fuzzy-C-Means-Clustering (FCM) bewährt (vgl. Veröffentlichung [V4]). Beim FCM muss die Clusteranzahl vorher festgelegt werden. Die manuell initialisierten oder zufälligen Start-Clusterzentren $\bar{\mathbf{X}} = \{\bar{\mathbf{x}}_1, \bar{\mathbf{x}}_2, \dots, \bar{\mathbf{x}}_c\}$ mit der Größe $c \leq n$ dienen als Eingangsvariablen für den Clustering-Algorithmus, der die Cluster $\mathbf{C} = \{C_1, \dots, C_c\}$ bestimmt. Die Zuordnung eines Daten-Tupels zu den Clustern wird beim FCM durch einen Satz von Gewichtungen ausgedrückt, die angeben, wie groß die Bindung zu einem bestimmten Cluster ist. Zusätzlich wird ein Abbruchkriterium definiert, das entweder die Anzahl der Integrationsschritte oder das Konvergenzkriterium beinhaltet. Die Clusterzentren werden in jedem Schritt iterativ durch die Lösung des Minimierungsproblems mit den Gewichtungen w_{ij}^q berechnet:

$$\arg \min_{\mathbf{C}} \sum_{i=1}^n \sum_{j=1}^c w_{ij}^q \|\mathbf{x}_i - \mathbf{c}_j\|^2. \quad (6.2)$$

Der Parameter q bestimmt den Grad der Unschärfe. Ein Wert von $q = 1$ entspricht der K-means-Clustering (KM)-Methode, die feste Zugehörigkeiten zu einem Clusterzentrum statt graduellen Zugehörigkeiten enthält. Für die FCM-Methode ist ein Wert von $q = 2$ üblich. Infolgedessen werden den Clustern die Clusterzentren $\bar{\mathbf{X}}$ der c -Cluster und die graduellen Zugehörigkeiten μ_B des Daten-Tupels \mathbf{x} zugewiesen. Die FCM-Methode ist im Allgemeinen langsamer als die KM-Methode, bietet aber bessere Konvergenzeigenschaften. Ein Grund dafür ist, dass die FCM-Methode aufgrund der proportionalen Verteilung eine feinere Auflösung bietet, unabhängig davon, wie die Cluster zu Beginn des Prozesses initialisiert werden. Detaillierte Beschreibungen von Cluster-Methoden mit Beispielen finden sich in den Büchern von Bezdek [60] und Bishop [62].

Bewertungskriterien für das Auswerten der richtigen Clusteranzahl

Das Finden der optimalen Anzahl von Clustern ist eine große Herausforderung bei der Anwendung von Clustering-Algorithmen. Mathematisch gibt es keinen zuverlässigen Weg, um die beste Anzahl zu bestimmen. Eine kritische Überprüfung der Ergebnisse ist erforderlich. Eine steigende Anzahl von Clustern führt zu einem linearen Anstieg des Rechenressourcenaufwands, weshalb die Anzahl so gering wie möglich sein sollte. Um die Ergebnisse des Clustering-Algorithmus mit verschiedenen Clusteranzahlen zu bewerten, werden Qualitätskriterien definiert. Je kleiner der Wert der Qualitätskriterien ist, desto besser ist das Ergebnis der Klassifikation. Diese Qualitätskriterien können auch zur Bewertung des richtigen Clustering-Algorithmus verwendet werden, wie in der Veröffentlichung [V4] beschrieben. In dieser wurde auch gezeigt, dass das FCM bei der Fahrzustandsklassifikation keine Konvergenzprobleme aufweist.

Qualitäts-Konvergenzkriterium (QCC)

Das Qualitäts-Konvergenzkriterium QCC wird normalerweise zur Beurteilung von Konvergenzen verwendet, da es nach dem Abbruchkriterium die Entfernungen der Daten-Tupel zu den Clustern, zu denen sie gehören, aufsummiert. Es kann auch zur Auswertung der Anzahl von Clustern verwendet werden und gibt den Basisabstand des Daten-Tupels zu den entsprechenden Clustern an. Das Qualitäts-Konvergenzkriterium QCC wird wie folgt gebildet:

$$QCC = \sum_{i=1}^c \sum_{\mathbf{x} \in C_i} \|\mathbf{x} - \boldsymbol{\mu}_i\|^2. \quad (6.3)$$

Qualitäts-Varianzkriterium (QVC)

Um zu bewerten, wie gut die Clusterzentren innerhalb und untereinander verteilt sind, wird zusätzlich eine multivariate Varianzanalyse (MANOVA) nach Mikut [63] durchgeführt. Um die Ergebnisse auszuwerten, wird das Qualitätsvarianzkriterium QVC durch die Wilks-Lambda-Kriterien mit der

Varianz innerhalb der Cluster \mathbf{W} und der Varianz zwischen den Clustern \mathbf{B} gebildet:

$$QVC = \frac{\det(\mathbf{W})}{\det(\mathbf{B} + \mathbf{W})}. \quad (6.4)$$

Qualitäts-Seperationskriterium (QSC)

Als Letztes wird das Qualitäts-Seperationskriterium QSC verwendet, um die Clusterergebnisse anhand des Trennungsgrades (Seperation) miteinander zu vergleichen. Dieses Kriterium wird wie folgt gebildet:

$$QSC = \frac{QCC}{c \cdot \min_{i,j=1,\dots,c,i \neq j} \|\bar{\mathbf{x}}_i - \bar{\mathbf{x}}_j\|^2}. \quad (6.5)$$

Ergebnisse hinsichtlich der Clusteranzahl

In der Veröffentlichung [V4] wurde bereits gezeigt, dass das FCM für die Klassifizierung von Fahrsegmenten am geeignetsten ist. Um die richtige Clusteranzahl für das D-PS+3m-Manöver zu finden, zeigt Tabelle 6.1 eine Übersicht über die Qualitätskriterien bei verschiedenen Clusteranzahlen.

Tabelle 6.1: Qualitätskriterien bei unterschiedlichen Clusteranzahlen c beim D-PS+3m-Manöver.

c	2	3	4	5	6	7	8	9	10
QCC	4,457	3,842	3,499	2,858	2,467	1,759	2,563	1,823	2,173
QVC	0,408	0,233	0,088	0,040	0,011	0,005	0,002	0,003	0,001
QSC	15963	4608	6151	2225	2097	1341	2521	3775	3034

Es ist zu erkennen, dass für die Clusteranzahl $c = 7$ das Konvergenzkriterium QCC und der Trennungsgrad QSC ein lokales Minimum aufweisen. Zusätzlich ist der Wert des Varianzkriteriums QVC niedrig. Die Simulation mit höheren Clusteranzahlen hat zusätzlich gezeigt, dass der Verlauf der Zugehörigkeit über die Zeit hinweg instabil werden kann, wenn bei der Fahrzustandsbestimmung regelmäßig zwischen mehreren Clusterzentren gesprungen wird. Um klar definierbare Fahrzustände zu erhalten, wird die Clusteranzahl $c = 7$ für das D-PS+3m-Manöver gewählt. Im Gegensatz zum einseitigen Manöver

steigt die Anzahl der Cluster so nur um ein Clusterzentrum, was zu einer guten Rechenressourcenauslastung führt.

Ergebnis der Klassifizierung der Fahrsegmente

Der Datensatz des D-PS+3m-Manövers wird mit der FCM-Methode untersucht. Der klassifizierte Datensatz ist in Abbildung 6.2 zu sehen. Die großen blauen Kreuze stellen die Clusterzentren dar. Für das D-PS+3m-Manöver ergeben sich für den Parkvorgang auf der Fahrerseite 66,16 s und auf der Beifahrerseite 76,48 s, zusammen mit einer Abtastrate von $f_s = 50$ Hz ergeben sich insgesamt $n = 7132$ Daten-Tupel.

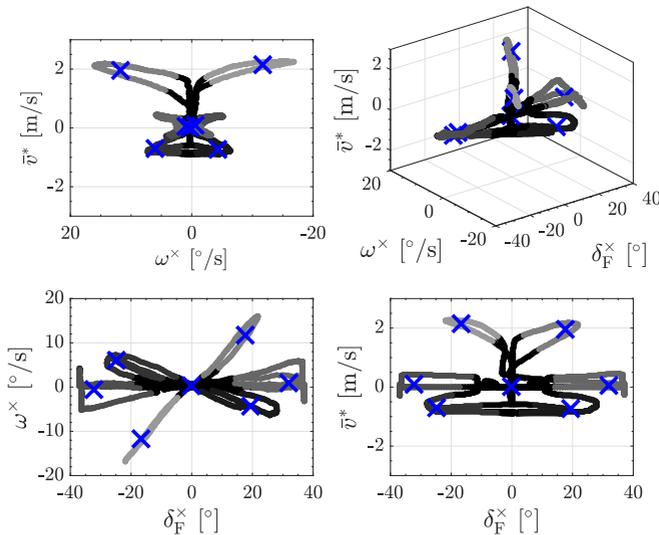


Abbildung 6.2: Ergebnis der Klassifizierung des Datensatzes des D-PS+3m-Manövers ($n = 7132$) mit dem FCM-Verfahren, unterteilt in $c = 7$ DCs.

Es ist zu erkennen, dass über den gesamten von den Daten-Tupeln abgedeckten Raum hinweg eindeutige Bereiche jedes Clusters sichtbar sind. Zusätzlich wurden die Bereiche, die auch für das symmetrische Fahrmanöver symmetrisch sind, als Clusterzentren klassifiziert. Es sind also klare, sinnvolle und gut trennbare Clusterzentren entstanden.

Ergebnis der Klassifizierung des D-PS+3m-Manövers (Fahrerseite)

Im nächsten Schritt wird untersucht, welche Fahrsegmente DCs sich aus den Clusterzentren ableiten lassen, in denen ein konstanter Fahrzustand herrscht. Abbildung 6.3 zeigt die proportionale Zugehörigkeit der Daten-Tupel für den Parkvorgang auf der Fahrerseite. Zu vielen Zeitpunkten dominiert die Zugehörigkeit zu einem Fahrzustand, d. h. es gibt einen klaren DC. Um individuelle DCs zu erhalten, wird in Abbildung 6.4 jedes Daten-Tupel dem DC zugeordnet, zu dem es die größte Zugehörigkeit hat.

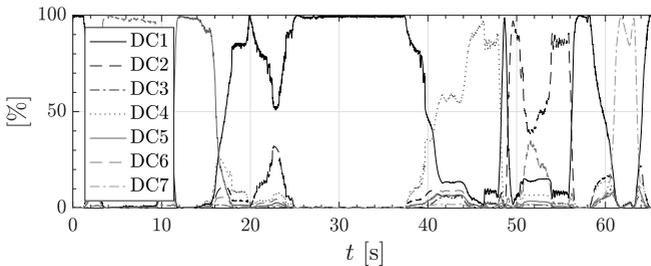


Abbildung 6.3: Proportionale Zuordnung der Daten-Tupel nach der Zeit für das D-PS+3m-Manöver (Fahrerseite) mit dem FCM-Verfahren, unterteilt in $c = 7$ DCs.

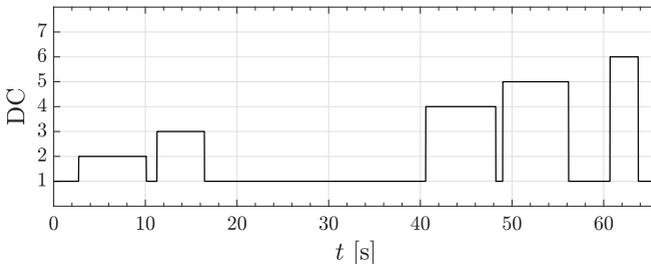


Abbildung 6.4: Zuordnung der Daten-Tupel nach der Zeit für das D-PS+3m-Manöver (Fahrerseite) mit dem FCM-Verfahren, unterteilt in $c = 7$ DCs.

Um die Aufteilung weiter zu interpretieren und die Fahrzustände bzw. DCs beim Ein- und Ausparkvorgang zu beurteilen, zeigt Abbildung 6.5 die aufgeteilten Trajektorien.

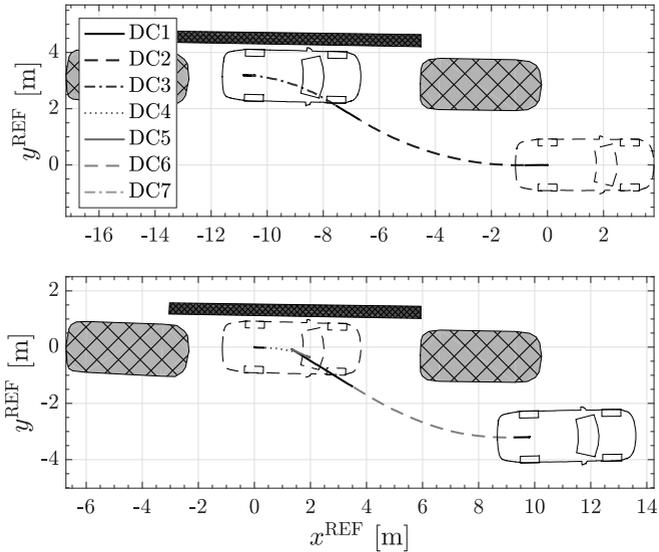


Abbildung 6.5: PS+3m-Manöver (Fahrerseite), aufgeteilt in sieben DCs.
Oben: Einparkvorgang, unten: Ausparkvorgang.

Es gibt gut trennbare und übersichtliche Fahrsegmente, in denen konstante Fahrzustände herrschen.

Ergebnis der Klassifizierung des PS+3m-Manövers (Beifahrerseite)

Die Abbildungen 6.6 und 6.7 zeigen die Aufteilung und die aufgeteilte Trajektorie des PS+3m-Manövers auf der Beifahrerseite.

Hier sind ebenfalls eindeutige Fahrsegmente identifizierbar. Zusätzlich wird deutlich, dass sich das Szenario spiegelverkehrt verhält und sich die Zustände abwechseln.

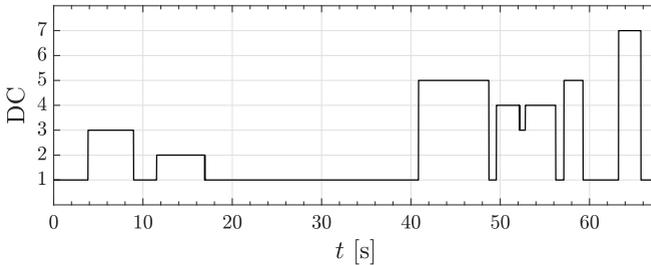


Abbildung 6.6: Zuordnung der Daten-Tupel nach der Zeit für das PS+3m-Manöver (Beifahrerseite) mit dem FCM-Verfahren, unterteilt in $c = 7$ DCs.

Klassifizierung der Fahrzustände

Für die Klassifizierung werden die optimalen Filtereinstellungen der Fahrsegmente im Modell gespeichert. Um die fahrzustandsabhängige Filtereinstellung nutzen zu können, muss sich das Fahrzeug in einem eindeutig zuweisbaren Fahrzustand befinden. Die vom FCM klassifizierten DCs werden in Form von Clusterzentren gespeichert. Während des Parkmanövers werden kontinuierlich neue Daten-Tupel über die Fahrzeugdaten generiert, die den DCs zugeordnet sind. Um Probleme zu vermeiden, wenn sich das Fahrzeug zwischen zwei DCs befindet, wird eine unscharfe Klassifizierung des aktuellen DC durchgeführt. Dies basiert auf dem gleichen Ansatz wie der Fuzzy-Clustering-Algorithmus, d. h. es wird eine proportionale Zugehörigkeit für alle DCs berechnet. Da die Filtereinstellung nur für die DCs selbst und nicht für Zwischenwerte verfügbar ist, wird die Fuzzy-Klassifizierung entsprechend der proportionalen Zugehörigkeit interpoliert.

Ergebnisse hinsichtlich der **automatisierten Bestimmung von Fahrsegmenten:**

- Das Fuzzy-C-Means-Clustering (FCM) eignet sich aufgrund seiner guten Konvergenzeigenschaften für die Identifikation von Fahrzuständen beim Parkvorgang am besten.
- Mithilfe der Qualitätskriterien kann die optimale Clusteranzahl bestimmt werden.

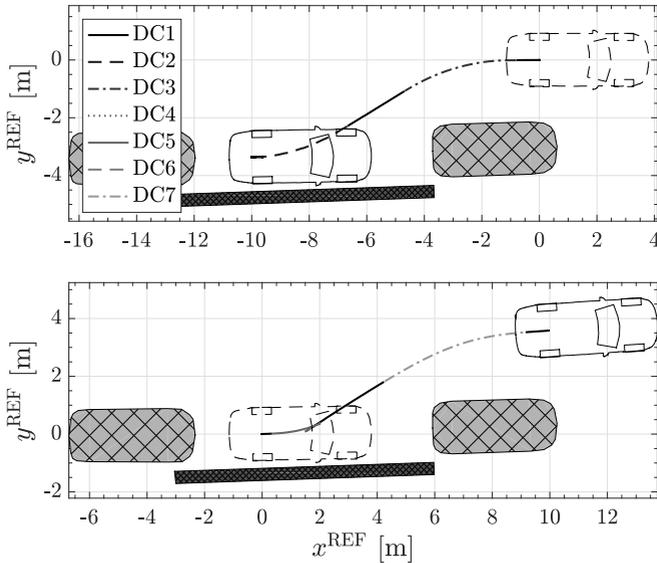


Abbildung 6.7: PS+3m-Manöver (Beifahrerseite), aufgeteilt in sieben DCs. Oben: Einparkvorgang, unten: Ausparkvorgang.

- Ein Längsparkmanöver (PS+3m) kann eindeutig in $c = 6$ gut trennbare Fahrsegmente unterteilt werden.
- Für das zusätzlich gespiegelte Szenario (D-PS+3m) auf der Beifahrerseite sind insgesamt $c = 7$ Fahrsegmente eindeutig identifizierbar. Der Rechenressourcenbedarf steigt daher mit zunehmenden Szenarien nur geringfügig an, da sich die Fahrzustände bei verschiedenen Parkszenarien gleichen.

6.3 Automatisierte Optimierung der Filtereinstellung

Dieser Abschnitt befasst sich mit dem Aufbau der MCS und dem Optimierungsprozess. Insgesamt werden $m = 700.000$ Simulationsergebnisse der MCS mit den Referenzwerten vom Referenzmesssystem (vgl. Abschnitt 2.4) verglichen und mithilfe von Optimierungskriterien (vgl. Absatz 3.5.3) die beste Einstellung für den Lokalisierungsfilter in jedem Fahrsegment gefunden.

6.3.1 Monte-Carlo-Simulation (MCS)

Bei der MCS handelt es sich um eine Simulation, die auf wiederholten Stichproben und statistischen Analysen basiert, anhand derer die Ergebnisse berechnet werden. In den Ingenieurwissenschaften werden häufig mathematische Modelle verwendet, um Zusammenhänge in einem System zu beschreiben. Diese hängen oft von einer Reihe von Eingangsparametern ab, die in mathematischen Gleichungen verwendet werden. Diese beschreiben das System und führen zu einem oder mehreren Ausgängen. Die Eingangsparameter der Modelle hängen in der Regel von externen Faktoren und Umwelteinflüssen ab. Diese Faktoren und Einflüsse können bei realistischen Modellen zu systematischen Abweichungen der ungewissen Eingangsparameter führen. In deterministischen Modellen werden diese Abweichungen in der Regel nicht berücksichtigt, da es sich bei den Eingabeparametern um feste Werte handelt. Mit der MCS können die Auswirkungen eines unsicheren Eingangsparameters über seine gesamte Breite hinweg methodisch untersucht werden. Dazu wird das *statistische Fehlermodell* verwendet, um statistische Fehler der Fahrzeugparameter darzustellen, und das *statistische Koeffizientenmodell*, um statistisch verteilte Messkovarianzwerte bzw. Filtereinstellungen anzugeben. Die verschiedenen Methoden der einzelnen Schritte sowie weitere Anwendungsmöglichkeiten der MCS-Methode sind in diversen Arbeiten zu finden [61, 64, 65]. Für das Verfahren werden statistische Modelle als variable Parameter in einer MCS verwendet. Die statistischen Fehler der Fahrzeugparameter und die statistische Verteilung der möglichen Messkovarianzwerte werden dabei berücksichtigt.

Die MCS umfasst statistische Modelle für die Größe p des *statistischen Fehlermodells* $\mathcal{E}_p \subseteq \mathcal{E}$, die Größe z des *statistischen Koeffizientenmodells* $\mathcal{L}_z \subseteq \mathcal{L}$ und die Anzahl der Fahrsegmente c . Da die MCS auf Simulationen

basiert und theoretisch unbegrenzte Simulationen möglich sind, ist es notwendig, den Umfang der Simulationen abzuschätzen. Im Folgenden wird beschrieben, wie die Anzahl der Simulationen ermittelt wurde.

Durch Multicore-Berechnungen sind 100 Simulationen pro Minute auf dem Simulationsrechner für das ausgewählte D-PS+3m-Manöver durchführbar. Für die robuste Abstimmung werden mindestens $p = 100$ mögliche Fehlervarianten des Fahrzeugs durch das *statistische Fehlermodell* \mathcal{E}_p berücksichtigt. Das *statistische Koeffizientenmodell* \mathcal{C}_z wird hingegen mit $z = 1000$ möglichen Koeffizientenverteilungen verwendet, um die optimale Koeffizientenverteilung ermitteln zu können. Für die vorliegende MCS ergibt sich somit ein Simulationsaufwand von $p \cdot z \cdot c = 100 \cdot 1000 \cdot 7 = 700000$ Simulationen, was einer Simulationszeit von ca. 120 Stunden bzw. 5 Tagen entspricht.

In den folgenden Absätzen werden die einzelnen Komponenten der MCS beschrieben.

6.3.1.1 Fahrzustandsabhängiges Modell

Um eine fahrzustandsabhängige Optimierung der Filtereinstellungen zu erreichen, wird die Simulation des Parkmanövers bzgl. der Fahrsegmente aufgeteilt. Für alle Fahrsegmente mit gleichem Fahrzustand wird eine Simulation durchgeführt. Startet ein Fahrsegment nicht zu Beginn des Manövers, wird die Simulation mit den Referenzdaten initialisiert.

6.3.1.2 Statistisches Fehlermodell

Anstelle einer Simulation einzelner Grenzfälle, wie bei der Sensitivitätsbewertung (vgl. Absatz 3.5.4), werden $p = 100$ Varianten des *statistischen Fehlermodells* verwendet, um 100 verschiedene Fahrzeuge mit statistischen Fehlern zu beschreiben $\rho \in \{\Delta c_i, \Delta t_R, \Delta \delta_F, \Delta \omega\}$. Tabelle 6.2 fasst die relevanten Parameter- und Sensorfehler aus Kapitel 2 zusammen.

Tabelle 6.2: Übersicht des Sensorfehlervektors ρ .

ρ	μ	ρ_A	ρ_B	Einheit	Fehlerart
Δc_i	2,090	-0,040	+0,030	m	Abrollumfang
Δt_R	1,604	-0,020	+0,016	m	Spurweite hinten
$\Delta \delta_F$	0	-1	+1	°	v. Achslenkwinkel
$\Delta \omega$	0	-0,7	+0,7	°/s	Gierrate

Die Parameter- und Sensorfehler werden im *statistischen Fehlermodell* durch eine Normalverteilung mit den entsprechenden Häufigkeiten der Fehler modelliert. Abbildung 6.8 zeigt das *statistische Fehlermodell* für $p = 100$ Varianten.

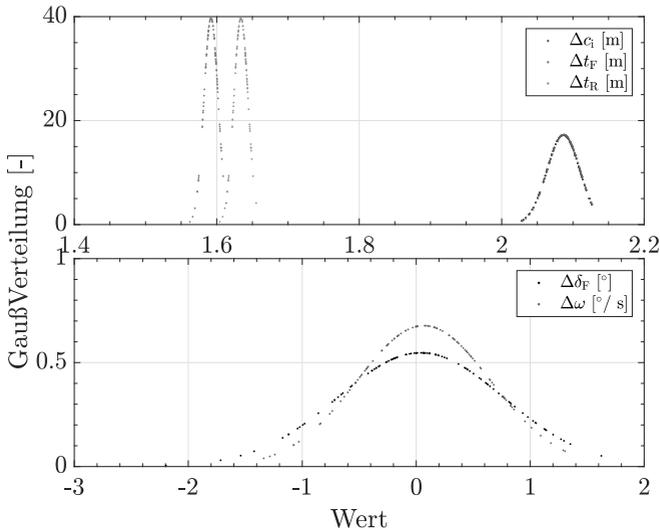


Abbildung 6.8: *Statistisches Fehlermodell* für $p = 100$ Varianten. Oben: Wahrscheinlichkeit der Abrollumfangs- und Spurweitenwerte, unten: Wahrscheinlichkeiten des Achsenwinkelfehlers und des Gierratenfehlers.

Die Abrollumfangsfehler Δc_i und der Spurweitenfehler Δt_j werden durch eine schräge Normalverteilung nach Hippel [66] modelliert und beinhalten den Erwartungswert (siehe Abbildung 6.8, oben). Der vordere Achsenwinkelfehler $\Delta \delta_F$ und der Gierratenfehler $\Delta \omega$ werden durch eine Normalverteilung modelliert (Abbildung 6.8, unten). Die Fehler im gesamten Abrollumfang und in der vorderen Spurweite (siehe Abschnitt 3.5.4) werden nicht berücksichtigt, da sie keinen Einfluss auf die Filtereinstellung haben.

6.3.1.3 Statistisches Koeffizientenmodell

Durch die Filtererweiterung des Lokalisierungsfilters durch die fahrzeugbewegungsmodellabhängige Koeffizientenmatrix \mathbf{Z}_k aus Absatz 3.4.3 kann die

Filtereinstellung vorgenommen werden. Dazu wird der Koeffizientenvektor ζ_k mithilfe der GNV der Koeffizienten des *statistischen Koeffizientenmodells* variiert. Abbildung 6.9 zeigt die logarithmische statistische Verteilung der Werte des Koeffizientenvektors ζ_k für $z = 1000$ Varianten.

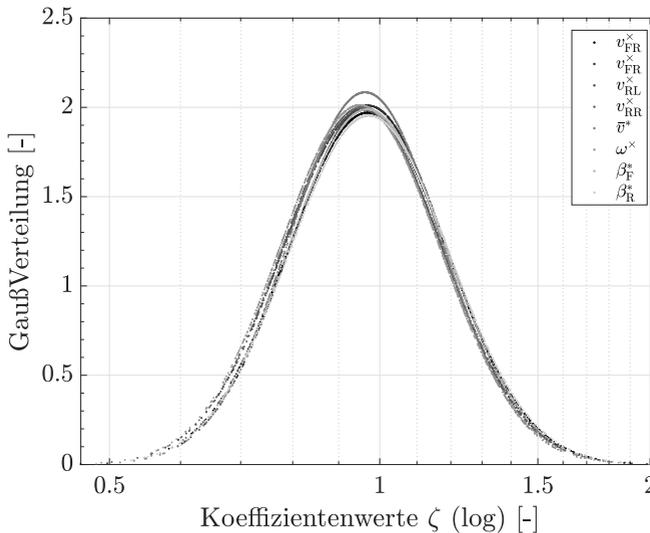


Abbildung 6.9: Wahrscheinlichkeitsverteilung des *statistischen Koeffizientenmodells* für den Koeffizientenvektor ζ_k für $z = 1000$ Varianten.

Die logarithmische Darstellung beinhaltet die Variation des Koeffizientenwertes um 1, wodurch es möglich ist, die Modelleingänge entweder zu halbieren oder zu verdoppeln, indem sie mit 0,5 oder 2 multipliziert werden.

6.3.2 Optimierung

Für die Optimierung werden die Bewertungskriterien aus Kapitel 6.2 verwendet, um die perfekte Zusammensetzung der Koeffizienten $\zeta(DC_k)$ für

die verschiedenen Fahrsegmente DC_k zu finden. Zu diesem Zweck wird das folgende Optimierungsproblem gelöst:

$$\zeta(DC) := \mathcal{C}(c) = \arg \min_{z \in \mathcal{C}_z} \left\| \sigma \left(\sum_{p \in \mathcal{C}_p} \xi(p, z, c) \right) \right\|. \quad (6.6)$$

Für jeden Fahrzustand DC aus der Anzahl c wird der Wert für den Koeffizientenvektor ζ bestimmt, für die die Standardabweichung σ des kumulativen Fehlerfaktors $\sum \xi(\cdot)$ aller Simulationen mit dem *statistischen Fehlermodell* \mathcal{C}_p die kleinste für das jeweilige z im *statistischen Koeffizientenmodell* \mathcal{C}_z ist. Eine Optimierung über die zu minimierende Funktion bringt in diesem Fall keine Verbesserung, da durch die Einfachheit des Problems davon ausgegangen wird, dass nur ein globales Minimum existiert.

6.4 Ergebnis der automatisierten fahrzustandsabhängigen Optimierung

Um die Ergebnisse der MCS-basierten Optimierung mit und ohne fahrzustandsabhängige Filtereinstellung auszuwerten, wird ein weiteres einseitiges PS+3m-v2-Manöver aufgezeichnet und simuliert. Es werden $p = 100$ neue Fahrzeugvarianten des *statistischen Fehlermodells* simuliert. Diese stellen $p = 100$ andere Fahrzeugvarianten dar. Für jede dieser Fahrzeugkonfigurationen wird der Parkvorgang simuliert und die Bewertungskriterien zeigen die Leistungssteigerung. Als Bewertungskriterien werden die Standardabweichung σ und der erwartete Wert μ mit den Indizes *in* und *out* für den Ein- und den Ausparkvorgang zur Beurteilung herangezogen. Zusätzlich werden die Mittelwerte \bar{e} des Lokalisierungsfehlers und des maximalen Positionsfehlers untersucht (vgl. Absatz 3.5.3). Tabelle 6.3 fasst alle Ergebnisse zusammen, die nachfolgend einzeln interpretiert werden.

Tabelle 6.3: Bewertungskriterien für das PS+3m-v2-Manöver.

typ	σ_{in}	μ_{in}	σ_{out}	μ_{out}	\bar{e}_{loc}	\bar{e}_{max}
-	m	m	m	m	-	m
noOpt	0,26	0,08	0,95	-0,55	11,15	1,96
Opt	0,18	-0,19	0,40	-0,15	11,14	1,05
Opt+DC	0,16	0,04	0,09	0,08	9,18	0,38

Ergebnis bei Basiseinstellung (noOpt)

Zunächst wird das Ergebnis des Parkmanövers für die Basiseinstellung mit dem Koeffizientenvektor als Einheitsvektor betrachtet. Abbildung 6.10 zeigt das Resultat für das PS+3m-v2-Manöver auf der Beifahrerseite. Das Parkmanöver wird für jede Fahrzeugkonfiguration des *statistischen Fehlermodells* simuliert.

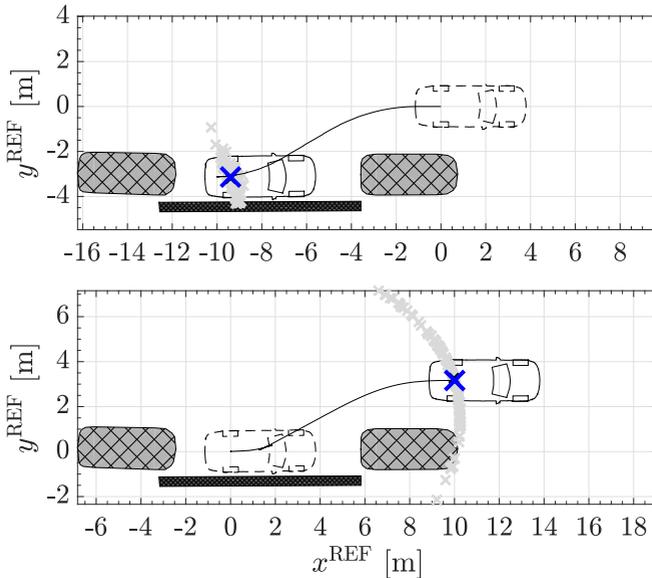


Abbildung 6.10: PS+3m-v2-Manöver: keine Optimierung, $p = 100$ Fahrzeugkonfigurationen und Basiskoeffizienten. Endposition der Simulationen (grau), Fahrzeug (blau).

Die Endpositionen (graue Kreuze) der verschiedenen Simulationen mit den jeweiligen Fahrzeugkonfigurationen sind breit gestreut, weshalb in Tabelle 6.3 auch eine große Standardabweichung σ von 0,26 m und 0,95 m aufgeführt ist. Die Standardabweichung ist nach dem gesamten Parkmanöver deutlich höher als in der Parkposition. Bei der Betrachtung der Bewertungskriterien ist zu berücksichtigen, dass der Wert den Durchschnitt des Beurteilungskriteriums über die verschiedenen Fahrzeugkonfigurationen hinweg darstellt.

Das bedeutet, dass die maximale Abweichung während eines Parkmanövers durchschnittlich 1,97 m beträgt, was für ein PS+3m-Manöver ein vergleichsweise hoher Wert ist.

Ergebnis bei optimierter Einstellung (Opt)

Als Nächstes wird untersucht, wie das Ergebnis durch Optimierung mit den Resultaten der MCS und des *statistischen Fehlermodells* verbessert werden kann. In diesem Schritt wird das Parkmanöver zunächst nicht in DCs unterteilt, sondern das gesamte Parkmanöver wird verwendet, um die Kovarianzen zu optimieren. Als Ergebnis der Optimierung entsteht der Vektor aus Tabelle 6.4, welcher Faktoren für die einzelnen gemessenen Parameter enthält.

Tabelle 6.4: Bester Messkoeffizientenvektor $\zeta(DC)$ des *statistischen Koeffizientenmodells*.

\tilde{v}_{FL}^\times	\tilde{v}_{FR}^\times	\tilde{v}_{RL}^\times	\tilde{v}_{RR}^\times	\tilde{v}^*	ω^\times	β_F^*	β_R^*
11,95	0,11	0,12	9,85	11,03	0,13	2,30	1,36

Wie in Abschnitt 6.3.1.3 beschrieben, enthält das *statistische Koeffizientenmodell* eine statistisch verteilte Varianz von Koeffizienten und kann eine bessere Übereinstimmung mit den Parametern des Lokalisierungsfilters finden. Das Ergebnis der Endpositionen für alle Fahrzeugkonfigurationen ist in Abbildung 6.11 dargestellt.

Es ist zu erkennen, dass die Standardabweichung σ , wie in Tabelle 6.3 nachzulesen, um 32 % beim Einparkvorgang und um 58 % beim Ausparkvorgang gesunken ist. Der Erwartungswert μ für den Einparkvorgang ist gestiegen, für den Ausparkvorgang aber gesunken und die mittleren Lokalisierungsfehler sowie die maximalen Fehler sind ähnlich geblieben.

Ergebnis bei fahrzustandsabhängiger Filtereinstellung (Opt+DC)

Um die Einteilung des Parkmanövers zu interpretieren, wird nun die Einteilung in DCs über die Trajektorie des Fahrzeugs bei Ein- und Ausparkvorgang für die Optimierung berücksichtigt. Tabelle 6.5 beinhaltet die gefundenen Koeffizientenwerte für die einzelnen DCs.

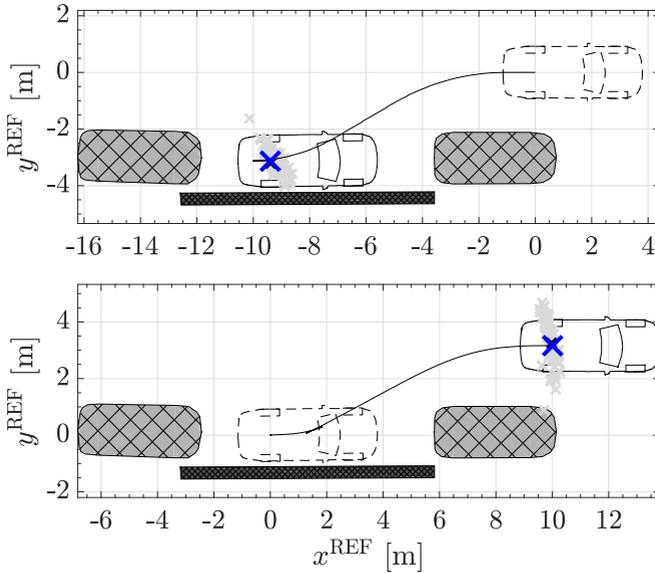


Abbildung 6.11: PS+3m-v2-Manöver: Optimierung, $p = 100$ Fahrzeugkonfigurationen und $z = 1000$ Koeffizienten. Endposition der Simulationen (grau), Fahrzeug (blau).

Es scheint offensichtlich, dass das Vertrauen in die Messung der Radgeschwindigkeiten für bestimmte DCs besonders hoch ist. Im Allgemeinen sind Messungen der Gierrate und des kinematischen Schwimmwinkels weniger zuverlässig, da sie einen großen Beitrag zur Erhöhung des Modellfehlervektors leisten. Dies hängt sowohl von den Spezifikationen als auch von der Anzahl der Fehler ab. In Abbildung 6.12 sind die Endpositionen aller Fahrzeugkonfigurationen dargestellt, wobei die Kovarianzen der einzelnen DCs optimiert wurden.

Es ist eine deutliche Verbesserung gegenüber den vorherigen Simulationen zu sehen. Die Standardabweichung σ ist um insgesamt 33 % beim Einparkvorgang und um 95 % beim Ausparkvorgang gesunken. Zusätzlich ist der Erwartungswert μ auf 0,04 m bzw. 0,08 m herabgegangen (vgl. Tabelle 6.3). Auch die Werte für den Maximalfehler e_{\max} sind deutlich gesunken.

Tabelle 6.5: Bester Messkoeffizientenvektor $\zeta(DC)$ des *statistischen Koeffizientenmodells* für sieben Fahrsegmente.

	\tilde{v}_{FL}^\times	\tilde{v}_{FR}^\times	\tilde{v}_{RL}^\times	\tilde{v}_{RR}^\times	\tilde{v}^*	ω^\times	β_F^*	β_R^*
DC1	0,01	9,74	11,17	10,23	0,96	0,08	0,01	1,09
DC2	0,85	10,98	11,07	10,22	0,96	0,98	1,01	0,83
DC3	1,30	1,24	3,12	1,29	4,85	0,68	0,23	0,42
DC4	0,25	3,43	0,71	1,36	5,37	0,87	0,37	0,77
DC5	11,53	8,77	11,36	8,05	10,53	0,12	1,52	0,82
DC6	12,38	9,27	11,05	10,01	4,07	0,09	0,24	0,92
DC7	0,10	0,11	0,96	10,02	11,36	0,10	0,10	0,11

Ergebnisse der automatisierten fahrzustandsabhängigen Optimierung:

- Durch das Verfahren der automatisierten Optimierung der Kovarianz des Lokalisierungsfilters erhöht sich die allgemeine Robustheit gegenüber den spezifizierten Fehlern um bis zu 58 %.
- Durch die zusätzliche fahrzustandsabhängige Filtereinstellung erhöht sich die Robustheit noch einmal um bis zu 95 %.
- Mit ca. 120 Stunden bzw. 5 Tagen Rechenzeit ist der Rechenressourcenaufwand für die automatisierte fahrzustandsabhängige Optimierung sehr hoch.

Für die Zukunft wäre eine größere Untersuchung des Verfahrens mit mehr Szenarien, einem größeren Fehlermodell und mehr Koeffizienten eine konsequente Erweiterung, sodass letztlich eine vollständige Abdeckung aller Fahrzustände für alle spezifizierten Parkszenarien erfolgt und das adaptive Fahrzeugbewegungsmodell vollständig wird. Um dennoch eine Beurteilung der bisherigen fahrzustandsabhängigen Anpassung für weitere Fahrmanöver zu erhalten, wird im nächsten Abschnitt eine Sensitivitätsauswertung mit zusätzlichen Manövern durchgeführt, für die keine direkte Optimierung stattgefunden hat.

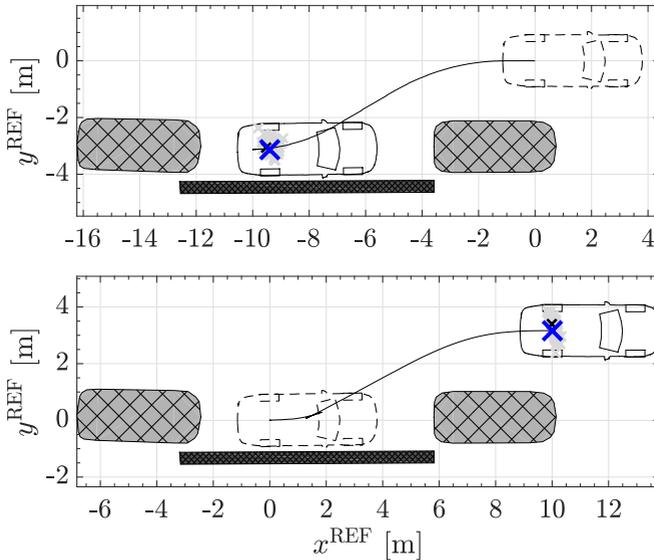


Abbildung 6.12: PS+3m-v2-Manöver: Optimierung + DC-Klassifikation, $p = 100$ Fahrzeugkonfigurationen, $z = 1000$ Koeffizienten und $c = 7$ DCs. Endposition der Simulationen (grau), Fahrzeug (blau).

Ergebnis der Sensitivitätsauswertung mit fahrzustandsabhängiger Optimierung des Lokalisierungsfilters für weitere Manöver

Um zu zeigen, welche Leistung die fahrzustandsabhängige Einstellung des Lokalisierungsfilters im OdoFilterApp bringt, wird die Sensitivitätsanalyse aus Absatz 3.5.4 noch einmal durchgeführt. Tabelle 6.6 zeigt die Werte des gemittelten Sensitivitätskriteriums aus Gleichung (3.48) in den Spalten, die verschiedenen Fahrzeugbewegungsmodelle in den Zeilen und mögliche Fehler in den Unterzeilen. Es werden die gemittelten Sensitivitätskriterien für die vier Fahrmanöver aus Absatz 3.5.4 gebildet.

Die globalen Aussagen über den Leistungsgewinn durch die fahrzustandsabhängige Koeffizientenmatrix des Lokalisierungsfilters sind in der Erkenntnisbox zusammengefasst.

Tabelle 6.6: Gemittelttes Sensitivitätskriterium (SC) des Modellfehlervektors $\xi \in \{e_{\text{pos},x}, e_{\text{pos},y}, e_{\text{align}}, e_{\text{loc}}, e_{\text{max}}\}$, bezogen auf den Sensorfehlervektor $\rho \in \{\Delta c_i, \Delta c_{RR}, \Delta t_F, \Delta t_R, \Delta \delta_F, \Delta \omega\}$. Pro Zeile/Spalte mit fester Unterzeile: grün für beste, blau für besser als Durchschnitt, rot für schlechteste.

Modelle	ρ	$\overline{SC}(e_{\text{pos},x}, \rho)$	$\overline{SC}(e_{\text{pos},y}, \rho)$	$\overline{SC}(e_{\text{align}}, \rho)$	$\overline{SC}(e_{\text{loc}}, \rho)$	$\overline{SC}(e_{\text{max}}, \rho)$
OdoFilterApp	Δc_i	1,02	0,81	1,02	18,62	0,98
	Δc_{RR}	1,77	2,55	5,77	28,51	3,10
	Δt_F	0,15	0,51	0,01	2,22	0,50
	Δt_R	0,22	0,46	0,01	1,96	0,46
	$\Delta \delta_F$	0,14	0,04	0,07	0,81	0,13
	$\Delta \omega$	0,14	0,26	0,49	3,39	0,32
OdoFilter	Δc_i	0,64	1,40	1,44	15,70	1,18
	Δc_{RR}	1,40	0,39	1,00	13,09	2,02
	Δt_F	0,12	0,27	0,09	0,89	0,26
	Δt_R	0,14	0,29	0,12	1,06	0,20
	$\Delta \delta_F$	0,07	0,04	0,52	1,58	0,14
	$\Delta \omega$	0,09	0,02	0,98	1,71	0,10
Odo2Track	Δc_i	0,91	1,95	1,35	16,13	1,69
	Δc_{RR}	6,67	6,74	7,11	170,45	22,65
	Δt_F	-	-	-	-	-
	Δt_R	1,10	2,41	1,88	18,03	2,16
	$\Delta \delta_F$	-	-	-	-	-
	$\Delta \omega$	-	-	-	-	-
Odo1Track*	Δc_i	0,91	1,99	1,49	17,43	1,56
	Δc_{RR}	0,45	1,01	1,03	9,15	0,68
	Δt_F	-	-	-	-	-
	Δt_R	-	-	-	-	-
	$\Delta \delta_F$	0,16	0,09	1,34	3,42	0,44
	$\Delta \omega$	-	-	-	-	-
OdoYawRate	Δc_i	0,36	0,39	0	11,10	0,26
	Δc_{RR}	0,18	0,20	0	3,33	0,11
	Δt_F	-	-	-	-	-
	Δt_R	-	-	-	-	-
	$\Delta \delta_F$	-	-	-	-	-
	$\Delta \omega$	0,25	0,09	2,77	8,22	0,44

Ergebnisse der Sensitivitätsauswertung des fahrzustandsabhängigen Lokalisierungsfilters:

- Die Methode der automatischen Optimierung der Kovarianz des Lokalisierungsfilters erhöht die Robustheit gegenüber den spezifizierten Fehlern nur teilweise. Es gibt Werte, die schlechter sind als bei den Vergleichsmodellen. Dies liegt unter anderem daran, dass die Gierratenmessung aufgrund des großen möglichen Fehlers weniger vertrauenswürdig ist. In Fällen, in denen der Gierratensensor gute Werte liefert, können Fehlmessungen z. B. in den Achslenkwinkeln zu größeren Lokalisierungsfehlern führen.

- Die Sensitivität des OdoFilterApp gegenüber spezifizierten Fehlern:
 - im Abrollumfang c_i sinkt zwar teilweise um 60 %, steigt aber auch um 12 % gegenüber dem OdoFilter, abhängig von der Fehlerart,
 - im Abrollumfang c_{RR} sinkt um 34–84 % gegenüber dem OdoFilter, weist aber keinen Wert schlechter als die Vergleichsmodelle auf,
 - in der Spurweite der Vorderachse t_F ist zwar allgemein größer als beim OdoFilter, die Fehler sind aber deutlich kleiner als bei den anderen Fehlergrößen,
 - in der Spurweite der Hinterachse t_R ist sehr gering und unterscheidet sich nur schwach vom OdoFilter,
 - im vorderen Achslenkwinkel δ_F ist teilweise um 49 % und um 86 % geringer als der OdoFilter,
 - in der Gierrate ω sinkt um bis zu 82 % gegenüber dem OdoYawRate.

7 Zusammenfassung

In der vorliegenden Arbeit wurde ein spezielles Fahrzeugbewegungsmodell für Parkanwendungen entwickelt. Ziel war es, mit bewährten Methoden der Robotik ein Fahrzeugbewegungsmodell zu entwickeln, welches eine genauere und robustere Positionierung während eines Parkmanövers ohne zusätzliche Sensoren oder Rechenressourcen erlaubt. Zu diesem Zweck wurde ein Extended-Information-Filter (EIF)-basierter Lokalisierungsfilter entwickelt, der verschiedene erweiterte Fahrzeugbewegungsmodelle fusioniert und durch Filtererweiterungen adaptiv angepasst werden kann. Zusätzlich wurden Kalibrierfilter zur effizienten Fahrzeugparameterschätzung, Filtererweiterungen zur Absicherung der Rollrichtung und ein Verfahren zur Fahrzustandsabhängigen automatisierte Optimierung entwickelt. Durch die Validierung des Lokalisierungsfilters mithilfe realer Testfahrten konnte das signifikante Verbesserungspotenzial gegenüber der konventionellen Methode der odometriebasierten Fahrzeuglokalisierung aufgezeigt werden. Die Ergebnisboxen dienen als Zusammenfassung aller Resultate der Arbeit. Das Gesamtergebnis kann wie folgt zusammengefasst werden:

- Der neu entwickelte Lokalisierungsfilter verwendet als Messdaten alle vier unabhängigen Radgeschwindigkeiten, die kinematischen Schwimmwinkel und die kalibrierte Gierrate. Damit kann er auch für vierradgelenkte Fahrzeuge eingesetzt werden. Im Vergleich zu den drei konventionellen Fahrzeugbewegungsmodellen sorgt die Multisensordatenfusion dafür, dass der Lokalisierungsfilter weniger anfällig für systematische und unsystematische Fehlergrößen in den Fahrzeugparametern und Sensormessungen ist. Die Achskinematik wurde untersucht und es hat sich gezeigt, dass die Berücksichtigung der Radaufstandspunkt (RAP)-Verschiebung für die Lokalisierung keinen Vorteil bringt. Die Schwimmwinkel, die durch das neu entwickelte Verfahren mit stationären Kreisfahrten und Differential-Global-Navigation-Satellite-System (DGNSS)-Positionsmessungen bestimmt werden können, verbessern die Genauigkeit des OdoTrack*-Modells deutlich. Die Störgrößen des Verfahrens sind jedoch noch nicht ausreichend berücksichtig-

sichtigt und die Übertragbarkeit auf andere Fahrzeuge der gleichen Baureihe sowie der Einfluss von Steigung müssen noch untersucht werden. Die auf der Achsvermessungsanlage gemessenen Radlenkwinkel werden für das OdoExt2Track-Modell verwendet und sorgen für eine genauere Modellierung. Der Lokalisierungsfilter selbst zeigt im Vergleich zum Odo2Track-Modell eine bessere Lokalisierungsleistung durch unabhängige Messungen von Translation und Rotation. Ebenso hat der Lokalisierungsfilter gegenüber dem Odo1Track*-Modell den Vorteil, dass er die Rotation aus zusätzlichen Sensorinformationen abschätzen kann. Im Gegensatz zum OdoYawRate-Modell bietet der Lokalisierungsfilter Vorteile, wenn die Gierrate falsch ist. Die Fusion der Fahrzeugbewegungsmodelle durch einen EIF sorgt dafür, dass einzelne Messunsicherheiten nur einen geringeren Einfluss auf die Positionsschätzung des Lokalisierungsfilters haben. Das nichtlineare Systemmodell der Lokalisierungsfilter arbeitet ohne Eingabe und ausschließlich mit den Informationen des vorherigen Zustands der Prädiktionsphase. Die Eingabe in den Filter erfolgt nur während der Innovationsphase durch das entsprechende nichtlineare Messmodell, sodass die Anzahl der Messungen angepasst werden kann, ohne den Betrieb des Systemmodells zu beeinträchtigen. Der Aufbau des Lokalisierungsfilters erlaubt es, das Messmodell anzupassen und gleichzeitig die Zusammensetzung der Fahrzeugbewegungsmodelle zu verändern. Dabei geht keine Stabilität verloren, da darauf geachtet wird, dass nur redundante Messungen abgeschaltet werden. Außerdem ist es möglich, die Anzahl der Messungen zu vergrößern, wenn sich das Sensorset und damit das Messmodell erweitern. Durch die bewegungszustandsabhängige Filtererweiterung kommt es zu keinen Stabilitätsproblemen. Durch den Einsatz der Radschlupferkennung im adaptiven Messmodell des Lokalisierungsfilters konnte die Positionsbestimmung in Anwendungsfällen mit schlupfenden Rädern deutlich verbessert werden. Der Slip-Detection-Algorithm (SDA) erkennt zuverlässig den einzelnen Radschlupf und hat keinen negativen Einfluss auf die Lokalisierung, da nur redundante Informationen verwendet werden. Beim Anfahren und Bremsen im Schnee wurde der Fehler der Ausrichtung deutlich reduziert. Obwohl der adaptive Lokalisierungsfilter zu einer erheblich verbesserten Lokalisierungsleistung führt, beansprucht er lediglich etwa das Doppelte der Rechenressourcen im Vergleich zur Gesamt-

summe der drei herkömmlichen Fahrzeugbewegungsmodelle. Diese geringe Ressourcenanforderung ist überraschend.

- Die Fahrzeugparameterschätzung erfolgt durch verschiedene Kalibrierfilter, die das fahrzeugeigene Global-Navigation-Satellite-System (GNSS) nutzen und sicherstellen, dass auch nach einem saisonbedingten Radwechsel und nach Alterung der Sensoren eine hohe Parkqualität gewährleistet ist. Um die erforderlichen Achsparameter schnellstmöglich abschätzen zu können, wurden verschiedene Kalibrierfiltererweiterungen entwickelt, um trotz GNSS-Signalverzug sowie -Unterbrechung eine schnell konvergierende Parameterschätzung zu realisieren. Zur Abschätzung von Gierratensensorfehlern wird zusätzlich das kalibrierte *kinematische Zweispurmodell* verwendet und in Abhängigkeit von den Kovarianzwerten der Achsparameterschätzung gestartet. Die Kalibrierfilter laufen ausserhalb der Parkphasen und verwenden somit keine zusätzlichen Rechenressourcen.
- Die frühzeitige Erkennung der Rollrichtung ist für den Lokalisierungsfilter von besonderer Bedeutung, da die Rollrichtung einen großen Einfluss auf den Geschwindigkeitsfehler hat. Die Geschwindigkeitsmessungen können ansonsten nicht in Echtzeit verarbeitet werden. Mit neuen Konzepten zur Richtungserkennung, basierend auf dem Muster der Delta-Wheel-Pulse-Count (DWPC)-Impulse und dem Fahrzeugkräftegleichgewicht in Längsrichtung, ist es möglich, eine Rollrichtung bereits vor der Geschwindigkeitsmessung zu erkennen. Es besteht jedoch noch weiteres Verbesserungspotenzial, da auch falsche Werte berechnet werden, sobald das Szenario dynamischer oder in der Steigung gefahren wird. Zum Schutz wurde eine Dual-Lokalisierungsfilter-Erweiterung entwickelt, die trotz falsch erkannter Rollrichtungssignale rückwirkend eine korrekte Positionsberechnung verwendet, da sich beim Anfahren zwei Filter in entgegengesetzte Richtungen bewegen und eine Initialisierungslogik die Filter initialisiert, sobald eine genauere Rollrichtungsinformation vorliegt. Der doppelte Rechenressourcenbedarf der Dual-Lokalisierungsfilter-Erweiterung kann durch Halbieren der Abtastezeit beim Betrieb während des Anfahrens kompensiert werden.
- Durch das Verfahren zur automatisierten fahrzustandsabhängigen Filtereinstellung des Lokalisierungsfilters wurde gezeigt, dass eine ro-

buste Einstellung des Filters durch ein automatisiertes Verfahren offline ermittelt werden kann. Dazu wurde das Parkmanöver zuerst in Fahrsegmente aufgeteilt, in denen die gleichen Fahrzustände vorliegen. Anschließend wurde mit den Ergebnissen einer Monte-Carlo-Simulation (MCS) jeweils die beste Einstellung des Filters für die verschiedenen Fahrsegmente bestimmt. In der MCS wurden mit dem *statistischen Fehlermodell* verschiedene Fahrzeuge mit unterschiedlichen Fehlern berücksichtigt. Zunächst wurden mithilfe des *statistischen Koeffizientenmodells* zufällige Konfigurationen des Lokalisierungsfilters festgelegt, aus denen dann im Rahmen der Optimierung die optimalen Einstellungen ermittelt wurden. Diese Methode liefert automatisch eine robuste Einstellung, erfordert allerdings einen hohen Simulationsaufwand.

Die beschriebenen neuen Methoden und Verfahren bieten eine Grundlage für die Steigerung der Robustheit und der Genauigkeit von odometriebasierten Lokalisierungsmethoden beim Parken. Es konnte gezeigt werden, dass auch mit dem eingeschränkten Sensorset heutiger Fahrzeuge die Parkqualität durch ein spezielles Fahrzeugbewegungsmodell deutlich gesteigert werden kann. Dafür werden keine zusätzlichen Sensoren oder erhöhte Rechenressourcen benötigt.

7.1 Wissenschaftlicher Beitrag

Basierend auf den bewährten Methoden der Robotik wurde ein ganzheitliches Konzept zur odometrischen Lokalisierung beim Parken entwickelt. Allein die systematische Entwicklung eines völlig neuen, selbst-kalibrierenden und adaptiven Fahrzeugbewegungsmodells zeigte bislang unbekanntes Problemstellungen auf. Gleichzeitig wurden Lösungen vorgeschlagen, bewertet und eine hohe Lokalisierungsleistung demonstriert. Neu ist die Verwendung eines EIF als Lokalisierungsmethode, die ein vierrädriges und allradgelenktes Fahrzeugbewegungsmodell durch größtmögliche Nutzung der verfügbaren Sensoren realisiert und einfach angepasst werden kann. Auch zur Ermittlung der Rollrichtung wurden neue Verfahren zur zuverlässigen Schätzung und Verarbeitung entwickelt. Optimale Filtereinstellungen werden durch neue Methoden automatisch gefunden. Die Dokumentation der für ein spezielles Fahrzeugbewegungsmodell erforderlichen Komponenten erleichtert die

Abschätzung des Aufwands und dient als Leitfaden für die Entwicklung zukünftiger Parksysteme.

7.2 Ausblick

Diese Arbeit beschäftigt sich mit der erweiterten Grundlagenforschung der odometriebasierten Lokalisierung. Die dargestellte Entwicklung, Anwendung und Validierung neuer Methoden bietet eine Bereicherung für bisherige Forschungsarbeiten auf diesem Gebiet. Eine Übertragung auf autonome Fahrsysteme, die trotz neuer hochpräziser Sensoren weiterhin die Odometrie als zuverlässige Fahrzeugbewegungsschätzung verwenden, ist ebenfalls möglich.

Der Lokalisierungsfilter eignet sich auch für den Einsatz in omnidirektionalen Fahrzeugen, die alle vier Räder unabhängig voneinander stellen können. Der Lokalisierungsfilter bietet eine geeignete Grundlage für die Lokalisierung solcher Fahrzeuge.

Der Lokalisierungsfilter kann mit Lokalisierungsmethoden anderer Sensoren in zukünftigen Parksystemen problemlos erweitert werden. Visuelle Odometrie-, Radar- und Lidar-Bewegungsdaten können als zusätzliche Messmodelle im bestehenden Lokalisierungsfilter erweitert werden.

Da der Lokalisierungsfilter auch eine Kovarianz seiner Positionsschätzung liefert, kann dies in Zukunft zur Beurteilung der Parkfunktionalität verwendet werden. Diese Informationen können dem Kunden z. B. angezeigt werden, um zu erklären, ob und welche Art von Fehlern das System derzeit aufweist und wie groß die Einschränkungen sind.

A Anhang

A.1 Graphical-User-Interface (GUI)

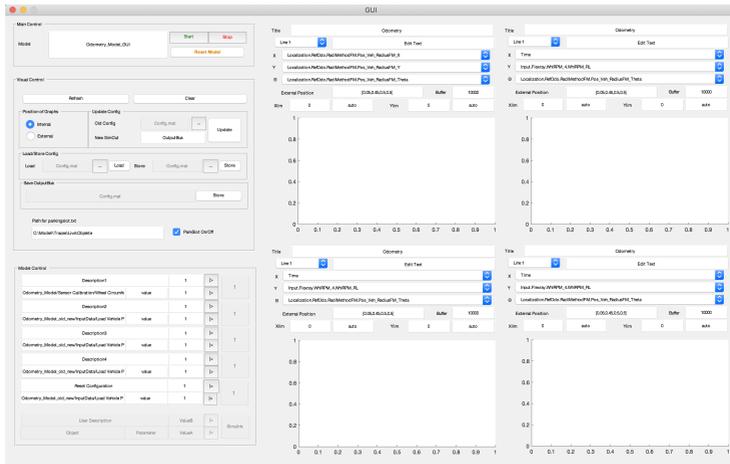


Abbildung A.1: Graphical-User-Interface (GUI) des Simulationsrahmenwerks.

A.2 Filteralgorithmen

A.2.1 Extended-Kalman-Filter (EKF)

Der EKF verwendet die partiellen Ableitungen der Prozessfunktion \mathbf{F}_k und Messfunktion \mathbf{H}_k zur Linearisierung. Diese sind wie folgt definiert:

$$\mathbf{F}_k = \frac{\partial \mathbf{f}}{\partial \hat{\mathbf{x}}_k}, \quad \mathbf{H}_k = \frac{\partial \mathbf{h}}{\partial \hat{\mathbf{x}}_k}. \quad (\text{A.1})$$

Der EKF Algorithmus kann wie folgt zusammengefasst werden [52]:

Prädiktion des Systemmodells

$$\begin{aligned} \hat{\mathbf{x}}_k^- &= \mathbf{f}(\hat{\mathbf{x}}_{k-1}, \mathbf{u}_k) \\ \mathbf{P}_k^- &= \mathbf{F}_k \cdot \mathbf{P}_{k-1} \cdot \mathbf{F}_k^T + \mathbf{Q}_k \end{aligned}$$

Prädiktion des Messmodells

$$\begin{aligned} \hat{\mathbf{z}}_k^- &= \mathbf{h}(\hat{\mathbf{x}}_k^-, \mathbf{u}_k) \\ \mathbf{P}_{xz,k} &= \mathbf{P}_k^- \cdot \mathbf{H}_k^T \\ \mathbf{P}_{zz,k} &= \mathbf{H}_k \cdot \mathbf{P}_k^- \cdot \mathbf{H}_k^T + \mathbf{R}_k \end{aligned}$$

Innovation durch Messmodell

$$\begin{aligned} \hat{\mathbf{x}}_k &= \hat{\mathbf{x}}_k^- + \mathbf{K}_k \cdot [\mathbf{z}_k - \hat{\mathbf{z}}_k^-] \\ \mathbf{P}_k &= \mathbf{P}_k^- - \mathbf{K}_k \cdot \mathbf{P}_{xz,k}^T = (\mathbf{I} - \mathbf{K}_k \cdot \mathbf{H}_k) \cdot \mathbf{P}_k^- \\ \mathbf{K}_k &= \mathbf{P}_{xz,k} \cdot \mathbf{P}_{zz,k}^{-1} \end{aligned}$$

A.2.2 Unscented-Kalman-Filter (UKF)

Der UKF verwendet eine Unscented-Transformation mit einem minimalen Satz sorgfältig ausgewählter Stichprobenpunkte (engl. SIGMA POINTS) zur Linearisierung.

Definition der Sigma Punkte

Um den Unscented-Filteralgorithmus zu beschreiben, wird der Zustand mit einem Satz von Gewichtungen erweitert [67]. Dazu werden folgende Parameter definiert: Zur Kontrolle der Ausbreitung der Sigma-Punkte wird $\alpha = 0, 1$, $\kappa = 0$ und im Zusammenhang mit der Verteilung $\beta = 2$ gewählt. Der Skalierungsfaktor λ wird durch $\lambda = \sqrt{(\alpha + \beta) \mathbf{P}_{xx}}$ definiert.

rungsparameter λ wird abhängig von der Länge des Zustandsvektors n_x wie folgt $\lambda = \alpha^2 \cdot (n_x + \kappa) - n_x$ gewählt. Die Gewichtungen berechnen sich zu:

$$\begin{aligned} w_m^{[0]} &= \lambda / (n_x + \lambda), \\ w_c^{[0]} &= \lambda / (n_x + \lambda) + (1 - \alpha^2 + \beta), \\ w_m^{[i]} &= w_c^{[i]} = 1 / [2 \cdot (n_x + \lambda)], \quad i \in \{1, \dots, 2n_x\}. \end{aligned} \quad (\text{A.2})$$

Mithilfe der Gewichtung wird ein Satz von $2n_x + 1$ gewichteten Sigma-Punkten definiert, wobei die Matrixwurzelberechnung durch die Cholesky-Faktorisierung bestimmt wird:

$$\begin{aligned} \mathbf{x}^{[0]} &= \sum_{i=0}^{2n_x} w^{[i]} \cdot \mathbf{x}^{[i]}, \\ \mathbf{x}^{[i]} &= \mathbf{x}^{[0]} + \left[\sqrt{(n_x + \lambda) \cdot \mathbf{P}} \right]_i, \quad i \in \{1, \dots, n_x\}, \\ \mathbf{x}^{[i]} &= \mathbf{x}^{[0]} - \left[\sqrt{(n_x + \lambda) \cdot \mathbf{P}} \right]_{i-n_x}, \quad i \in \{n_x + 1, \dots, 2n_x\}. \end{aligned} \quad (\text{A.3})$$

Der Ausdruck $[\cdot]_i$ steht für die i -te Zeile der Quadratwurzelmatrix. Der Algorithmus für den UKF lässt sich wie folgt zusammenfassen [67]:

Prädiktion des Systemmodells

Sigma-Punkte	$\left[\hat{\mathbf{x}}_{k-1}^{[i]}, w_m, w_c \right] = \text{sigmaPoints}(\hat{\mathbf{x}}_{k-1}, \mathbf{P}_{k-1})$
prädierte Sigma-Punkte	$\hat{\mathbf{x}}_k^{[i]-} = \mathbf{f}(\hat{\mathbf{x}}_{k-1}^{[i]}, \mathbf{u}_k), \quad i \in \{0, \dots, 2n_x\}$
prädiertes Zustand	$\hat{\mathbf{x}}_k^- = \sum_{i=0}^{2n_x} w_m^{[i]} \cdot \hat{\mathbf{x}}_k^{[i]-}$
prädierte Kovarianz	$\mathbf{P}_k^- = \sum_{i=0}^{2n_x} w_c^{[i]} \cdot (\hat{\mathbf{x}}_k^{[i]-} - \hat{\mathbf{x}}_k^-) \cdot (\hat{\mathbf{x}}_k^{[i]-} - \hat{\mathbf{x}}_k^-)^T + \mathbf{Q}_k$

Prädiktion des Messmodells

Sigma-Punkte	$\left[\hat{\mathbf{x}}_k^{[i]-}, w_m, w_c \right] = \text{sigmaPoints} \left(\hat{\mathbf{x}}_k^-, \mathbf{P}_k^- \right)$
prädizierte Sigma-Punkte	$\hat{\mathbf{z}}_k^{[i]-} = \mathbf{h} \left(\hat{\mathbf{x}}_k^{[i]-}, \mathbf{u}_k \right), i \in \{0, \dots, 2n_x\}$
prädizierte Messung	$\hat{\mathbf{z}}_k^- = \sum_{i=0}^{2n_x} w_m^{[i]} \cdot \hat{\mathbf{z}}_k^{[i]-}$
Kreuzkovarianz	$\mathbf{P}_{xz,k} = \sum_{i=0}^{2n_x} w_c^{[i]} \cdot \left(\hat{\mathbf{x}}_k^{[i]-} - \hat{\mathbf{x}}_k^- \right) \cdot \left(\hat{\mathbf{z}}_k^{[i]-} - \hat{\mathbf{z}}_k^- \right)^T$
Innovationskovarianz	$\mathbf{P}_{zz,k} = \sum_{i=0}^{2n_x} w_c^{[i]} \cdot \left(\hat{\mathbf{z}}_k^{[i]-} - \hat{\mathbf{z}}_k^- \right) \cdot \left(\hat{\mathbf{z}}_k^{[i]-} - \hat{\mathbf{z}}_k^- \right)^T + \mathbf{R}_k$

Innovation durch Messmodell

fusionierter Zustand	$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}_k \cdot \left[\mathbf{z}_k - \hat{\mathbf{z}}_k^- \right]$
fusionierte Kovarianz	$\mathbf{P}_k = \mathbf{P}_k^- - \mathbf{K}_k \cdot \mathbf{P}_{xz,k}^T$
Kalmanverstärkung	$\mathbf{K}_k = \mathbf{P}_{xz,k} \cdot \mathbf{P}_{zz,k}^{-1}$

A.2.3 Extended-Information-Filter (EIF)

Der EIF ist vom EKF abgeleitet und führt das Innovationsupdate mithilfe des Informationszustands durch. Dazu führt der Filter zuerst eine Informationstransformierung durch und invertiert den Zustandsvektor und die Kovarianzmatrix. Der Algorithmus für den EIF kann wie folgt zusammengefasst werden [19]:

Prädiktion des Systemmodells

prädizierter Zustand	$\hat{\mathbf{x}}_k^- = \mathbf{f}(\hat{\mathbf{x}}_{k-1}, \mathbf{u}_k)$
prädizierte Kovarianz	$\mathbf{P}_k^- = \mathbf{F}_k \cdot \mathbf{P}_{k-1} \cdot \mathbf{F}_k^T + \mathbf{Q}_k$

Transformierung in Informationszustande

prädizierter Informationszustand	$\hat{\mathbf{y}}_k^- = (\mathbf{P}_k^-)^{-1} \cdot \hat{\mathbf{x}}_k^-$
prädizierte Informationskovarianz	$\mathbf{Y}_k^- = (\mathbf{P}_k^-)^{-1}$

Prädiktion des Messmodells

prädizierte Messung	$\hat{\mathbf{z}}_k^- = \mathbf{h}(\hat{\mathbf{x}}_k^-, \mathbf{u}_k)$
---------------------	---

Informationsinnovation durch Messmodell

$$\begin{aligned} \text{fusionierter Informationszustand} & \quad \hat{\mathbf{y}}_k = \hat{\mathbf{y}}_k^- + \mathbf{H}_k^T \cdot \mathbf{R}_k^{-1} \cdot [\mathbf{z}_k - \hat{\mathbf{z}}_k^- + \mathbf{H}_k \cdot \hat{\mathbf{x}}_k^-] \\ \text{fusionierte Informationskovarianz} & \quad \mathbf{Y}_k = \mathbf{Y}_k^- + \mathbf{H}_k^T \cdot \mathbf{R}_k^{-1} \cdot \mathbf{H}_k \end{aligned}$$

Rücktransformierung in Systemzustand

$$\begin{aligned} \text{fusionierter Zustand} & \quad \hat{\mathbf{x}}_k = (\mathbf{Y}_k)^{-1} \cdot \hat{\mathbf{y}}_k \\ \text{fusionierte Kovarianz} & \quad \mathbf{P}_k = (\mathbf{Y}_k)^{-1} \end{aligned}$$

A.2.4 Unscented-Information-Filter (UIF)

Der UIF verwendet ebenfalls die Sigma-Punkte zur Approximation. Die Gleichungen werden so formuliert, dass sich die Innovationsphase des Extended-Information-Filter (EIF) und Unscented-Information-Filter (UIF) nicht unterscheidet und es wird die aus dem UKF bekannte sog. Pseudo-Messmodellmatrix \mathcal{H}_k verwendet. Der Algorithmus für den UIF lässt sich wie folgt zusammenfassen [19]:

Prädiktion des Systemmodells

$$\begin{aligned} \text{Sigma-Punkte} & \quad \left[\hat{\mathbf{x}}_{k-1}^{[i]}, w_m, w_c \right] = \text{sigmaPoints}(\hat{\mathbf{x}}_{k-1}, \mathbf{P}_{k-1}) \\ \text{prädizierte Sigma-Punkte} & \quad \hat{\mathbf{x}}_k^{[i]-} = \mathbf{f}(\hat{\mathbf{x}}_{k-1}^{[i]}, \mathbf{u}_k), \quad i \in \{0, \dots, 2n_x\} \\ \text{prädizierter Zustand} & \quad \hat{\mathbf{x}}_k^- = \sum_{i=0}^{2n_x} w_m^{[i]} \cdot \hat{\mathbf{x}}_k^{[i]-} \\ \text{prädizierte Kovarianz} & \quad \mathbf{P}_k^- = \sum_{i=0}^{2n_x} w_c^{[i]} \cdot (\hat{\mathbf{x}}_k^{[i]-} - \hat{\mathbf{x}}_k^-) \cdot (\hat{\mathbf{x}}_k^{[i]-} - \hat{\mathbf{x}}_k^-)^T + \mathbf{Q}_k \end{aligned}$$

Transformierung des Informationszustandes

$$\begin{aligned} \text{präd. Inform.-Zustand} & \quad \hat{\mathbf{y}}_k^- = (\mathbf{P}_k^-)^{-1} \cdot \hat{\mathbf{x}}_k^- \\ \text{präd. Inform.-Kovarianz} & \quad \mathbf{Y}_k^- = (\mathbf{P}_k^-)^{-1} \end{aligned}$$

Prädiktion des Messmodells

Sigma-Punkte	$\left[\hat{\mathbf{x}}_k^{[i]-}, w_m, w_c \right] = \text{sigmaPoints}(\hat{\mathbf{x}}_k^-, \mathbf{P}_k^-)$
prädizierte Sigma-Punkte	$\hat{\mathbf{z}}_k^{[i]-} = \mathbf{h}(\hat{\mathbf{x}}_k^{[i]-}, \mathbf{u}_k), i \in \{0, \dots, 2n_x\}$
prädizierte Messung	$\hat{\mathbf{z}}_k^- = \sum_{i=0}^{2n_x} w_m^{[i]} \cdot \hat{\mathbf{z}}_k^{[i]-}$
Kreuzkovarianz	$\mathbf{P}_{xz,k} = \sum_{i=0}^{2n_x} w_c^{[i]} \cdot (\hat{\mathbf{x}}_k^{[i]-} - \hat{\mathbf{x}}_k^-) \cdot (\hat{\mathbf{z}}_k^{[i]-} - \hat{\mathbf{z}}_k^-)^T$
Pseudo-Messkovarianz	$\mathcal{H}_k^T = (\mathbf{P}_k^-)^{-1} \cdot \mathbf{P}_{xz,k}$

Informationsinnovation durch Messmodell

fusionierter Zustand	$\hat{\mathbf{y}}_k = \hat{\mathbf{y}}_k^- + \mathcal{H}_k^T \cdot \mathbf{R}_k^{-1} \cdot [\mathbf{z}_k - \hat{\mathbf{z}}_k^- + \mathcal{H}_k \cdot \hat{\mathbf{x}}_k^-]$
fusionierte Kovarianz	$\mathbf{Y}_k = \mathbf{Y}_k^- + \mathcal{H}_k^T \cdot \mathbf{R}_k^{-1} \cdot \mathcal{H}_k$

Rücktransformierung des Systemzustand

fusionierter Zustand	$\hat{\mathbf{x}}_k = (\mathbf{Y}_k)^{-1} \cdot \hat{\mathbf{y}}_k$
fusionierte Kovarianz	$\mathbf{P}_k = (\mathbf{Y}_k)^{-1}$

Abkürzungs- und Symbolverzeichnis

Abkürzungen

AKPE	Axle-Kinematic-Parameter-Estimator
AMR	anisotropen magnetoresistiven
ASR	Anti-Schlupf-Regelung
CAN	Controller-Area-Network
DC	Driving-Conditions
DGNSS	Differential-Global-Navigation-Satellite-System
DWPC	Delta-Wheel-Pulse-Count
ECEF	kartesische Earth-Centered-Fixed-Koordinatensystem
EIF	Extended-Information-Filter
EKF	Extended-Kalman-Filter
EPS	Electric-Power-Steering
ESP	Elektronisches-Stabilitätsprogramm
ETRTO	European Tyre and Rim Technical Organisation
FAKPE	Front-Axle-Kinematic-Parameter-Estimator
FCM	Fuzzy-C-Means-Clustering
FEA	Force-Equilibrium-Algorithm
GDOP	Geometrische-Präzisionsverdünnung
GNSS	Global-Navigation-Satellite-System
GNV	Gaußsche-Normalverteilung
GPS	Global-Positioning-System
GUI	Graphical-User-Interface
IMU	Inertial-Measurement-Unit
KM	K-means-Clustering
LLH	Geodätisches-Koordinatensystem
MCS	Monte-Carlo-Simulation
MEMS	Micro-Electro-Mechanical-Systems
NED	lokales North-East-Down-Koordinatensystem

NRMSE	Normalized-Root-Mean-Square-Error
QCC	Qualitäts-Konvergenzkriterium
QVC	Qualitäts-Varianzkriterium
QSC	Qualitäts-Seperationskriterium
RAKPE	Rear-Axle-Kinematic-Parameter-Estimator
RAP	Radaufstandspunkt
REF	Referenzkoordinatensystem
RSME	Root-Mean-Squar-Error
RTK	Real-Time-Kinematic
SA-AKPE	Self-Adaptive-Axle-Kinematic-Parameter-Estimator
SA-FAKPE	Self-Adaptive-Front-Axle-Kinematic-Parameter-Estimator
SA-RAKPE	Self-Adaptive-Rear-Axle-Kinematic-Parameter-Estimator
SDA	Slip-Detection-Algorithm
SLAM	Simultaneous Localization and Mapping
SRUIF	Square-Root-Unscented-Information-Filter
SSA	Signal-Shift-Algorithm
UIF	Unscented-Information-Filter
UKF	Unscented-Kalman-Filter
VEH	Fahrzeugkoordinatensystem
WPA	Wheel-Counter-Pattern-Algorithm
WGS84	World-Geodetic-System-1984
YRPE	Yaw-Rate-Parameter-Estimator

Mathematische Notation

Zeichen	Raum	Einheit	Bedeutung
x	$\in \mathbb{R}$		Skalar
\mathbf{x}	$\in \mathbb{R}^{n \times 1}$		n -dimensionaler Spaltenvektor
\mathbf{x}^T	$\in \mathbb{R}^{1 \times n}$		n -dimensionaler Zeilenvektor
\mathbf{Z}	$\in \mathbb{R}^{n \times n}$		n, m -dimensionale Matrix
$\dot{x} \hat{=} \frac{dx}{dt}$			Zeitableitung
$\frac{\partial x}{\partial s}$			Partielle Ableitung
$f(x)$			Funktion von x
x_{Ref}			Referenzwert von x
$\hat{\mathbf{x}}$			Schätzwert von x
x^\times			gemessener Wert von x
x^*			korrigierter Wert von x
Δx			Abweichung von x
x_{max}			Maximalwert von x
$E(x)$			Erwartungswert von x
$N(x)$			Verteilung von x
$\text{Var}(x)$			Varianz von x
μ			Erwartungswert
σ			Standardabweichung

Variablen

A.2.4.1 Fahrzeugparameter und -sensorik

Zeichen	Raum	Einheit	Bedeutung
An_{Konz}	$\in \{4 \times 2, 4 \times 4\}$	[-]	Antriebskonzept
a_x^\times	$\in \mathbb{R}$	[m/s ²]	Beschleunigung in x -Richtung
a_y^\times	$\in \mathbb{R}$	[m/s ²]	Beschleunigung in y -Richtung
A	$\in \mathbb{R}$	[a]	Alterung
α_i	$\in \mathbb{R}$	[°]	Einzelradschräglaufwinkel
α_j	$\in \mathbb{R}$	[°]	Achsschräglaufwinkel
$b_{\text{Axle,F}}$	$\in \mathbb{R}$	[m]	Vordere Achsbreite (Flansch)
$b_{\text{Axle,R}}$	$\in \mathbb{R}$	[m]	Hintere Achsbreite (Flansch)
B	$\in \mathbb{R}$	[-]	Bogen-Sehne-Faktor
β_F	$\in \mathbb{R}$	[°]	vorderer Schwimmwinkel
β_R	$\in \mathbb{R}$	[°]	hinterer Schwimmwinkel
β_0	$\in \mathbb{R}$	[°]	geometrische Fahrachse
c_D	$\in \mathbb{R}$	[m]	dynamischer Abrollumfang
c_i	$\in \mathbb{R}$	[m]	Abrollumfang

$d_{i,k}^\times$	$\in \{-1, 0, 1\}$	[-]	Radrollrichtung
d	$\in \{-1, 0, 1\}$	[-]	Rollrichtung
$Drift_\omega$	$\in \mathbb{R}$	[°]	Gierraten-Nullpunktsdrift
δ_i	$\in \mathbb{R}$	[°]	Einzelradlenkwinkel
δ_F	$\in \mathbb{R}$	[°]	vorderer Achslenkwinkel
δ_R	$\in \mathbb{R}$	[°]	hinterer Achslenkwinkel
En_{\max}	$\in \mathbb{R}$	[-]	maximalen Zählerwert
ET_j	$\in \mathbb{R}$	[mm]	Felgen-Einpresstiefe einer Achse
$GDOP$	$\in \mathbb{R}$	[-]	GNSS GDOP
γ_i	$\in \mathbb{R}$	[°]	Einzelsturzwinkel
h	$\in \mathbb{R}$	[m]	geodätische Höhe
W_{type}	$\in \mathbb{R}$		Raddimension
w_{\max}	$\in \mathbb{R}$	[-]	Radimpulse pro Umdrehung
r_b	$\in \mathbb{R}$	[m]	Radstand
r_{tol}	$\in \mathbb{R}$	[m]	Reifen-Fertigungstoleranz
r_{ab}	$\in \mathbb{R}$	[m]	Reifenabrieb
p	$\in \mathbb{R}$	[bar]	Reifendruck
r_D	$\in \mathbb{R}$	[m]	dyn. Rollradius
r_0	$\in \mathbb{R}$	[m]	unbelasteter Rollradius
r_S	$\in \mathbb{R}$	[m]	statischer Rollradius
$r_{i,x}$	$\in \mathbb{R}$	[m]	Radaufstandpunkt in x^{VEH}
$r_{i,y}$	$\in \mathbb{R}$	[m]	Radaufstandpunkt in y^{VEH}
$Sens_\omega$	$\in \mathbb{R}$	[°]	Gierraten-Sensitivitätsfehler
t_F	$\in \mathbb{R}$	[m]	Vordere Spurbreite
t_R	$\in \mathbb{R}$	[m]	Hintere Spurbreite
T	$\in \mathbb{R}$	[°C]	Temperatur
$TrackSat$	$\in \mathbb{R}$	[-]	GNSS getrackte Satelliten
v	$\in \mathbb{R}$	[m/s]	Geschwindigkeiten
$\tilde{v}_{i,k}^\times$	$\in \mathbb{R}$	[m/s]	Einzelradgeschwindigkeit
$w_{i,k}^\times$	$\in \mathbb{R}$	[-]	Radimpluszählerwert (DWPC)
x	$\in \mathbb{R}$	[m]	Position in x
y	$\in \mathbb{R}$	[m]	Position in y
μ_v	$\in \mathbb{R}$	[-]	Geschwindikeitsproportionalitätskonstante
φ	$\in \mathbb{R}$	[°]	Breitengrad
λ	$\in \mathbb{R}$	[°]	Längengrad
θ	$\in \mathbb{R}$	[°]	Gierwinkel
ψ	$\in \mathbb{R}$	[°]	Nickwinkel
ϕ	$\in \mathbb{R}$	[°]	Rollwinkel
ω	$\in \mathbb{R}$	[°/s]	Gierrate
$\boldsymbol{\omega}$	$\in \mathbb{R}^3$	[°/s]	Drehraten

A.2.4.2 Modellvarianten

Modell	Bedeutung
Odo2Track	kinematisches Zweispurmodell
OdoExt2Track	erweitertes kinematisches Zweispurmodell
Odo1Track	kinematisches Einspurmodell
Odo1Track*	korrigiertes kinematisches Einspurmodell
OdoEKF	EKF Lokalisierungsfilter-Implementierung
OdoEIF	EIF Lokalisierungsfilter-Implementierung
OdoUKF	UKF Lokalisierungsfilter-Implementierung
OdoUIF	UIF Lokalisierungsfilter-Implementierung
OdoYawRate	kinematisches Gierratenmodell
OdoFilter	Lokalisierungsfilter
OdoFilterApp	Lokalisierungsfilter mit fahrzustandsabhängiger Optimierung

A.2.4.3 Lokalisierungsfilter

Zeichen	Raum	Einheit	Bedeutung
F	$\in \mathbb{R}$	[N]	Kräfte in Längsrichtung
\mathbf{p}	$\in \mathbb{R}^2$	[m]	Position des Fahrzeugs
v	$\in \mathbb{R}$	[m/s]	Geschwindigkeit des Fahrzeugs
x	$\in \mathbb{R}$	[m]	Position des Fahrzeugs
y	$\in \mathbb{R}$	[m]	Position des Fahrzeugs
β	$\in \mathbb{R}$	[°]	Schwimmwinkel
β_F	$\in \mathbb{R}$	[°]	Winkel zwischen v_F und δ_F
β_R	$\in \mathbb{R}$	[°]	Winkel zwischen v und δ_R
β_F^*	$\in \mathbb{R}$	[°]	korrigierter Achslenkwinkel vorne
β_R^*	$\in \mathbb{R}$	[°]	korrigierter Achslenkwinkel hinten
δ_F^\times	$\in \mathbb{R}$	[°]	gemessener Achslenkwinkel vorne
δ_R^\times	$\in \mathbb{R}$	[°]	gemessener Achslenkwinkel hinten
ω	$\in \mathbb{R}$	[°/s]	Gierrate um z-Achse
θ	$\in \mathbb{R}$	[°]	Orientierung des Fahrzeugs
Λ	$\in \mathbb{R}^{n_z \times n_z}$		Zustandsabhängige Koeffizientenmatrix
Π	$\in \mathbb{R}^{n_z \times n_z}$		Schlupfabhängige Koeffizientenmatrix
Z	$\in \mathbb{R}^{n_z \times n_z}$		Fahrzustandsabhängige Koeffizientenmatrix
ζ	$\in \mathbb{R}^{n_z}$		Koeffizientenvektor
S	$\in \mathbb{R}^4$		Schlupfvektor
ξ			Fehlerfaktor der Fahrzeugparameter

ρ		Fehlerfaktor der Positionierung
SC	$\in \mathbb{R}$	Sensitivität

A.2.4.4 Filtergleichungen

Zeichen	Raum	Einheit	Bedeutung
f	$\in \mathbb{R}^{n_x}$		Systemmodell
F	$\in \mathbb{R}^{n_x \times n_x}$		Jacobi-Matrix des Systemmodell
h	$\in \mathbb{R}^{n_z}$		Messmodell
H	$\in \mathbb{R}^{n_z \times n_x}$		Jacobi-Matrix des Messmodell
\mathcal{H}	$\in \mathbb{R}^{n_z \times n_x}$		Pseudo-Messmodellmatrix
K	$\in \mathbb{R}^{n_x \times n_z}$		Kalmanverstärkung
P	$\in \mathbb{R}^{n_x \times n_x}$		Kovarianz des Zustands
Y	$\in \mathbb{R}^{n_x \times n_x}$		Kovarianz des Informationszustands
q_x	$\in \mathbb{R}^{n_x}$		Systemrauschen
Q	$\in \mathbb{R}^{n_x \times n_x}$		Kovarianz des Systemrauschens
r_z	$\in \mathbb{R}^{n_z}$		Messrauschen
R	$\in \mathbb{R}^{n_z \times n_z}$		Kovarianz des Messrauschens
w	$\in \mathbb{R}$	[-]	Gewichte
x	$\in \mathbb{R}^{n_x}$		Zustand
u	$\in \mathbb{R}^{n_x}$		Eingang
y	$\in \mathbb{R}^{n_x}$		Informationszustand
z	$\in \mathbb{R}^{n_z}$		Messung
α, β, γ	$\in \mathbb{R}$	[-]	Tuning Parameter

A.2.4.5 Automatisierte Optimierung

Zeichen	Raum	Einheit	Bedeutung
B	$\in \mathbb{R}^c$		Interklassen-Variationsmatrix
c	$\in \mathbb{R}$	[-]	Anzahl der Cluster
C	$\in \mathbb{R}^c$		Cluster
n	$\in \mathbb{R}$	[-]	Anzahl der Datentuple
N	$\in \mathbb{R}$	[-]	Anzahl der Datentuple eines Clusters
m	$\in \mathbb{R}$	[-]	Anzahl der Simulationen
p	$\in \mathbb{R}$	[-]	Anzahl der Fehlermodellpunkte
w	$\in \mathbb{R}$	[-]	Gewichte
W	$\in \mathbb{R}^c$		Innere Klassenvariationsmatrix
\bar{X}	$\in \mathbb{R}^c$		Clusterzentren
μ	$\in \mathbb{R}^n$		Mittelwert der Datentuple
QCC	$\in \mathbb{R}^n$		Qualitäts-Konvergenzkriterium
QVC	$\in \mathbb{R}^n$		Qualitäts-Varianzkriterium
QSC	$\in \mathbb{R}^n$		Qualitäts-Seperationskriterium

z	$\in \mathbb{R}$	[-]	Anzahl der Koeffizientenmodell- punkte
-----	------------------	-----	---

Literaturverzeichnis

- [1] *Bosch-Auswertung: Fahrerassistenzsysteme sind weiter stark auf dem Vormarsch.* Studie. Bosch, 2018. URL: <http://www.bosch-presse.de/pressportal/de/de/bosch-auswertung-fahrerassistenzsysteme-sind-weiter-stark-auf-dem-vormarsch-148032.html>.
- [2] *Mehrheit der Autofahrer würde dem Autopiloten das Steuer übergeben.* Studie. Bitkom, 2017. URL: <https://www.bitkom.org/Presse/Presseinformation/Mehrheit-der-Autofahrer-wuerde-dem-Autopiloten-das-Steuer-uebergeben.html>.
- [3] *Einparkassistenten 10 Systeme im Test.* Artikel. Auto, Motor und Sport, 2013. URL: <https://www.auto-motor-und-sport.de/test/einparkassistenten-10-systeme-im-test.html>.
- [4] *Einparkassistenten im Test.* Artikel. Autozeitung, 2013. URL: <https://www.autozeitung.de/einparkassistenten-im-test-bilder-daten-fazit-66858.html>.
- [5] *Einparkassistenten im Test.* Artikel. Auto Bild, 2012. URL: <https://www.autobild.de/artikel/einparkassistenten-im-test-3464727.html>.
- [6] *Neun Einparkautomaten im Test.* Artikel. Auto Bild, 2015. URL: <https://www.autobild.de/artikel/neun-einparkautomaten-im-test-5666647.html>.
- [7] S. Reuter, B.-T. Vo, B.-N. Vo und K. Dietmayer. „Multi-Object Tracking Using Labeled Multi-Bernoulli Random Finite Sets“. In: *17th International Conference on Information Fusion (FUSION)*. (7.–10. Juni 2014).
- [8] A. Scheel, S. Reuter und K. Dietmayer. „Vehicle Tracking Using Extended Object Methods: An Approach for Fusing Radar and Laser“. In: *IEEE International Conference on Robotics and Automation (ICRA)*. (29. Mai–3. Juni 2017).

- [9] M. Stubler, S. Reuter und K. Dietmayer. „A continuously learning feature-based map using a bernoulli filtering approach“. In: *Sensor Data Fusion: Trends, Solutions, Applications (SDF)* (2017), S. 1–6.
- [10] J. K. Suhr und H. G. Jung. „Sensor Fusion-Based Vacant Parking Slot Detection and Tracking“. In: *IEEE Transactions on Intelligent Transportation Systems* 15.1 (Feb. 2014), S. 21–36. ISSN: 1524-9050.
- [11] T. Bär, D. Linke, D. Nienhüser und J. M. Zöllner. „Seen and missed traffic objects: A traffic object-specific awareness estimation“. In: *IEEE Intelligent Vehicles Symposium (IV)*. (23.–26. Juni 2013). Gold Coast, QLD, Australia, S. 1–6.
- [12] J. Chen und C. Hsu. „A visual method for the detection of available parking slots“. In: *IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. (5.–8. Okt. 2017), S. 2980–2985.
- [13] S. Lee und S.-W. Seo. „Available parking slot recognition based on slot context analysis“. In: *IET Intelligent Transport Systems* (Okt. 2016), S. 1–6.
- [14] D. Dolgov, S. Thrun, M. Montemerlo und J. Diebel. „Path Planning for Autonomous Vehicles in Unknown Semi-structured Environments“. In: *The International Journal of Robotics Research* 29 (5 2010), S. 485–501. ISSN: 0278-3649.
- [15] D. Gonzalez, J. Perez, V. Milanés und F. Nashashibi. „A Review of Motion Planning Techniques for Automated Vehicles“. In: *IEEE Transactions on Intelligent Transportation Systems* 17 (4 2016), S. 1135–1145. ISSN: 1524-9050.
- [16] D. Caltabiano, G. Muscato und F. Russo. „Localization and self-calibration of a robot for volcano exploration“. In: *Proc. IEEE Int. Conf. Robot. Autom.* Bd. 1. New Orleans, LA, USA, Juni 2004, S. 586–591.
- [17] M. Kochem, R. Neddenriep, R. Isermann, N. Wagner und C.-D. Hamann. „Accurate local vehicle dead-reckoning for a parking assistance system“. eng. In: *American Control Conference*. 2002.

-
- [18] T. D. Larsen, K. L. Hansen, N. A. Andersen und O. Ravn. „Design of Kalman filters for mobile robots; evaluation of the kinematic and odometric approach“. In: *Proc. IEEE Int. Conf. Control Appl.* (22.–27. Aug. 1999). Bd. 2. Kohala Coast, HI, USA, S. 1021–1026.
- [19] K. Lee und W. Chung. „Calibration of kinematic parameters of a Car-Like Mobile Robot to improve odometry accuracy“. In: *Proc. IEEE Int. Conf. Robot. Autom.* (19.–23. Mai 2008). Pasadena, CA, USA, S. 2546–2551.
- [20] Y. K. Tham, H. Wang und E. K. Teoh. „Adaptive State Estimation For 4-wheel Steerable Industrial Vehicles“. In: *Proc. IEEE Conf. Decision & Control.* (18.–18. Aug. 2002). Tampa, FL, USA, S. 4509–4514.
- [21] H. Deusch, S. Reuter und K. Dietmayer. „The Labeled Multi-Bernoulli SLAM Filter“. In: *IEEE Signal Processing Letters* 22 (10 2015), S. 1561–1565. ISSN: 1070-9908.
- [22] H. Durrant-Whyte und T. Bailey. „Simultaneous Localisation and Mapping (SLAM): Part I“. In: *IEEE Robotics & Automation Magazine* 13 (2 Juni 2006), S. 99–110.
- [23] H. Durrant-Whyte und T. Bailey. „Simultaneous Localisation and Mapping (SLAM): Part II“. In: *IEEE Robotics & Automation Magazine* 13 (3 Sep. 2006), S. 108–117.
- [24] V. Ivanov, D. Savitski und S. B. „A Survey of Traction Control and Antilock Braking Systems of Full Electric Vehicles With Individually Controlled Electric Motors“. In: *IEEE Transactions on Vehicular Technology.* Bd. 64. 9. 2014, S. 3878–3896.
- [25] A. v. Vietinghoff. *Nichtlineare Regelung von Kraftfahrzeugen in querdynamisch kritischen Fahrsituationen*. KIT Scientific Publishing, 2008.
- [26] B. Gao, W. Tao, H. Chu, M. Tian und H. Chen. „A reference vehicle model applied to electronic stability control (ESC) system“. In: *36th Chinese Control Conference (CCC)*. (26.–28. Juli 2017). Dalian, China, S. 9436–9441.

- [27] P. Simionescu und D. Beale. „Optimum synthesis of the four-bar function generator in its symmetric embodiment. The Ackermann steering linkage“. In: *Mechanism and Machine Theory*. Bd. 37. 2002, S. 1487–1504.
- [28] M. R. Rajamani. *Vehicle Dynamics and Control*. Springer US, 2006, S. 101–103.
- [29] H. Chung, L. Ojeda und J. Borenstein. „Accurate mobile robot dead-reckoning with a precision-calibrated fiber-optic gyroscope“. In: *IEEE Transaction on Robotics and Automation*. 2001, S. 80–84.
- [30] V. Rodrigo-Marco, J. Kalkkuhl und T. Seel. „Nonlinear observer with observability-based parameter adaptation for vehicle motion estimation“. In: *IFAC-PapersOnLine* 51.15 (2018). 18th IFAC Symposium on System Identification SYSID 2018, S. 60–65. ISSN: 2405-8963.
- [31] L. Armesto, J. Tornero und M. Vincze. „Fast Ego-motion Estimation with Multi-rate Fusion of Inertial and Vision“. In: *The International Journal of Robotics Research*. Bd. 26. 2016, S. 577–589.
- [32] M. Ibraheem. „Gyroscope-Enhanced Dead Reckoning Localization System For an Intelligent Walker“. eng. In: *Int. Conf. Informat. Network. Automat.* (18.–19. Okt. 2010). Kunming, China.
- [33] K. Berntorp. „Particle filter for combined wheel-slip and vehicle-motion estimation“. In: *American Control Conference (ACC)*. (1.–3. Juli 2015). Chicago, IL, USA, S. 5414–5419.
- [34] G. H. Oettinger. *eCall in all new cars from April 2018*. URL: <https://ec.europa.eu/digital-single-market/en/news/ecall-all-new-cars-april-2018.html> (besucht am 19. 11. 2018).
- [35] S. Klemm u. a. „Autonomous multi-story navigation for valet parking“. In: *IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)*. (1.–4. Nov. 2016). Rio de Janeiro, Brazil.
- [36] A. Katriniok und D. Abel. „Adaptive EKF-Based Vehicle State Estimation With Online Assessment of Local Observability“. In: *IEEE Transactions on Control Systems Technology* 24 (4 2016), S. 1368–1381. ISSN: 1063-6536.

-
- [37] J. Borenstein und L. Feng. „Measurement and correction of systematic odometry errors in mobile robots“. In: *IEEE Transactions on robotics and automation* 12.6 (1996), S. 869–880.
- [38] S. Krivić, A. Mrzić, J. Velagić und N. Osmić. „Optimization based algorithm for correction of systematic odometry errors of mobile robot“. In: *Control Conference (ASCC), 2013 9th Asian*. (23.–26. Juni 2013). IEEE, S. 1–6.
- [39] V. Rodrigo-Marco, J. Kalkkuhl und J. Raisch. „EKF for simultaneous vehicle motion estimation and IMU bias calibration with observability-based adaptation“. In: *2018 Annual American Control Conference (ACC)*. (27.–29. Juni 2018), S. 6309–6316.
- [40] T. Müller, J. Rannacher, C. Rabe und U. Franke. „Feature- and depth-supported modified total variation optical flow for 3D motion field estimation in real scenes“. In: *Proc. IEEE Conf. Comput. Vision and Pattern Recog.* (Colorado Springs, CO, USA, 20.–25. Juni 2011). Colorado Springs, CO, USA, S. 1193–1200.
- [41] H. Lategahn und C. Stiller. „Vision-Only Localization“. In: *IEEE Transactions on Intelligent Transportation Systems*. Bd. 15. 2014, S. 1246–1257.
- [42] S. Schneider, T. Luettel und H.-J. Wuensche. „Odometry-based online extrinsic sensor calibration“. In: *Intelligent Robots and Systems (IROS), 2013 IEEE/RSJ International Conference on*. (3.–7. Nov. 2013). IEEE, S. 1287–1292.
- [43] B. M. Akesson, J. B. Jorgensen und S. B. Jorgensen. „A Generalized Autocovariance Least-Squares Method for Covariance Estimation“. In: *American Control Conference (ACC)*. (9.–13. Juli 2007). New York, NY, USA, S. 3713–3714.
- [44] M. R. Rajamani und J. B. Rawlings. „Estimation of the Disturbance Structure from Data using Semidefinite Programming and Optimal Weighting“. In: *Model. Control Cons.* Bd. 45. Feb. 2007, S. 142–148.
- [45] J. E. Stellet, F. Straub, J. Schumacher, W. Branz und J. M. Zöllner. „Estimating the process noise variance for vehicle motion models“. In: *18th IEEE International Conference on Intelligent Transportation Systems*. (15.–18. Sep. 2015).

- [46] The European Tyre and Rim Technical Organisation. *Standards Manual*. 2017.
- [47] R. Gnadler, H.-J. Unrau, M. Frey und M. Fertig. „Grundsatzuntersuchung zum quantitativen Einfluss von Reifenbauform und -ausführung auf die Fahrstabilität von Kraftfahrzeugen. FAT-Schriftreihe 192“. In: *FAT-Schriftenreihe 192* (2005). Hrsg. von VDA - Verband der Automobilindustrie.
- [48] B. Heimann, A. Albert, T. Ortmaier und L. Rissing. *Mechatronik. Komponenten - Methoden - Beispiele*. Carl Hanser Verlag GmbH & Co. KG, 2015. 450 S.
- [49] V. Pratt. „Direct Least-Squares Fitting of Algebraic Surfaces“. In: *Computer Graphics* 21 (1987), S. 145–152.
- [50] C.-D. Wann. „Mobile sensing systems based on improved GDOP for target localization and tracking“. In: *IEEE Sensors*. (Taipei, Taiwan, 28.–31. Okt. 2012). IEEE, 2012, S. 1–4.
- [51] B. L. Stevens, F. L. Lewis und E. N. Johnson. *Aircraft control and simulation. Dynamics, controls design, and autonomous systems*. 3. Aufl. 2016. xii, 749 Seiten.
- [52] D. Simon. *Optimal state estimation. Kalman, H[infinity], and non-linear approaches*. Wiley-Interscience. Hoboken NJ: Wiley, 2006. XXVI, 526 S. ISBN: 978-0-471-70858-2.
- [53] N. Assimakis, M. Adam und A. Douladiris. „Information Filter and Kalman Filter Comparison: Selection of the Faster Filter“. In: *International Journal of Information Engineering*. 2012.
- [54] M. Wada, K. Sup Yoon und H. Hashimoto. „Development of Advanced Parking Assistance System“. In: *IEEE Transactions on industrial Electronics* (2003).
- [55] G. Agamennoni, S. Worrall, J. Ward und E. Nebot. „Robust non-linear smoothing for vehicle state estimation“. In: *Proc. IEEE Intell. Veh. Symp.* (23.–26. Juni 2013). Gold Coast City, Australia, S. 156–162.
- [56] C. R. Carlson, J. C. Gerdes und J. D. Powell. „Practical Position and Yaw Rate Estimation with GPS and differential wheelspeeds“. In: *researchgate* (2014).

- [57] I. Kim, H. Kim, J. Bang und K. Huh. „Development of estimation algorithms for vehicle’s mass and road grade“. In: *International Journal of Automotive Technology* 14 (6 2013), S. 889–895. ISSN: 1229-9138.
- [58] S. Rhode. „Robust and Regularized Algorithms for Vehicle Tractive Force Prediction and Mass Estimation“. Englisch. Diss. Karlsruher Institut für Technologie (KIT), 2016. 143 S. DOI: 10.54445/IR/1000058815.
- [59] Z. Sun, T. Zhu und H. Zheng. „Research on Road Friction Coefficient Estimation Algorithm Based on Extended Kalman Filter“. In: *International Conference on Intelligent Computation Technology and Automation (ICICTA)*. (20.–22. Okt. 2008). Bd. 2, S. 418–422. DOI: 10.1109/ICICTA.2008.38.
- [60] J. C. Bezdek. *Pattern Recognition with Fuzzy Objective Function Algorithms*. Springer US, 1981.
- [61] S. Raychaudhuri. „Introduction to Monte Carlo Simulation“. In: *Proc. Conf. Winter Simu.* (7.–10. Dez. 2008). Miami, FL, USA, S. 91–100.
- [62] C. M. Bishop. *Pattern Recognition and Machine Learning*. New York City, NY, USA: Springer US, 2016.
- [63] R. Mikut. *Data Mining in der Medizin und Medizintechnik*. Teilw. zugl.: Karlsruhe, Univ., Habil.-Schr., 2007 u.d.T.: Mikut, Ralf: Automatisierte Datenanalyse in der Medizin und Medizintechnik. ger. Bd. 22. Schriftenreihe des Instituts für Angewandte Informatik/Automatisierungstechnik an der Universität Karlsruhe (TH). Karlsruhe: Univ.-Verl., 2008. 356 S.
- [64] C. Z. Mooney. *Monte Carlo simulation*. eng. Bd. 116. Thousand Oaks, Calif.: Sage, 2003. 103 S.
- [65] C. P. Robert und G. Casella. *Monte Carlo statistical methods*. eng. 2. ed. New York, NY, USA: Springer US, 2010. 645 S.
- [66] P. T. Von Hippel. „Mean, median, and skew: Correcting a textbook rule“. In: *Journal of Statistics Education* 13.2 (2005).

- [67] E. A. Wan und R. van der Merwe. „The Unscented Kalman Filter for Nonlinear Estimation“. In: *IEEE Adaptive Systems for Signal Processing and Control Symposium*. (4.–4. Aug. 2002). Lake Louise, AB, Canada.

Eigene Veröffentlichungen

- [V1] A. Brunker, T. Wohlgemuth, M. Frey und F. Gauterin. „Odometry 2.0: A Slip-Adaptive EIF-Based Four-Wheel-Odometry Model for Parking“. In: *IEEE Transactions on Intelligent Vehicles*. Bd. 4. 1. Beiträge der Autoren: A. Brunker: Aufbau und Anwendung des Modells, Auswertung und Dokumentation; T. Wohlgemuth: Korrekturlesen; M. Frey: Supervision und Korrekturlesen; F. Gauterin: Supervision und Korrekturlesen. März 2019, S. 114–126.
- [V2] A. Brunker, T. Wohlgemuth, M. Frey und F. Gauterin. „GNSS-Shortages-Resistant and Self-Adaptive Rear Axle Kinematic Parameter Estimator (SA-RAKPE)“. In: *IEEE Intelligent Vehicles Symposium (IV)*. (11.–14. Juni 2017). Beiträge der Autoren: A. Brunker: Aufbau und Anwendung des Modells, Auswertung und Dokumentation; T. Wohlgemuth: Korrekturlesen; M. Frey: Supervision und Korrekturlesen; F. Gauterin: Supervision und Korrekturlesen. Redondo Beach, CA, USA, S. 456–461.
- [V3] A. Brunker, T. Wohlgemuth, M. Frey und F. Gauterin. „Dual-Bayes Localization Filter Extension for safeguarding in case of uncertain Direction Signals“. In: *Sensors*. Bd. 18. 10. Beiträge der Autoren: A. Brunker: Aufbau und Anwendung des Modells, Auswertung und Dokumentation; T. Wohlgemuth: Korrekturlesen; M. Frey: Supervision und Korrekturlesen; F. Gauterin: Supervision und Korrekturlesen. Okt. 2018, S. 3539.
- [V4] A. Brunker, M. K. Paul, T. Wohlgemuth, M. Frey und F. Gauterin. „Driving-Condition dependent and Monte Carlo Simulation-based Optimization Method for a Bayesian Localization Filter for Parking“. In: *IEEE Transactions on Intelligent Vehicles*. Bd. 5. 1. Beiträge der Autoren: A. Brunker: Überarbeitung und Anwendung des Modells, Auswertung und Dokumentation; T. Wohlgemuth: Korrekturlesen; M. K. Paul: Erstaufbau des Modells im Rahmen der Masterarbeit;

M. Frey: Supervision und Korrekturlesen; F. Gauterin: Supervision und Korrekturlesen. März 2020, S. 139–148.

Eigene Offenlegungen

- [O1] A. Brunker. Schutzrecht. Titel der Anmeldung: *Verfahren zur Anpassung eines Parkassistenzsystems an ein Fahrzeug*. Detaillierter Titel: *Verfahren zur Anpassung eines Parkassistenzsystems an ein Fahrzeug zur hochgenauen und robusten laufenden Ortsbestimmung*. DPMA Offenlegungsschrift, DE102016014325A1, 18.05.2017.
- [O2] A. Brunker. Schutzrecht. Titel der Anmeldung: *Verfahren zur Ermittlung der Eigenbewegung eines Fahrzeugs*. Detaillierter Titel: *Verfahren für ein fahrzustandsabhängiges Vierrad-Odometriemodell zur Lokalisierung*. DPMA Offenlegungsschrift, DE102016005739A1, 05.01.2017.
- [O3] A. Brunker. Schutzrecht. Titel der Anmeldung: *Verfahren zur Ermittlung der Eigenbewegung eines Fahrzeugs, insbesondere eines Kraftfahrzeugs*. Detaillierter Titel: *Verfahren zur Vereinheitlichung von verschiedenster Messgrößen unterschiedlicher Sensoren zur Fusion in einem Lokalisierungsfilters*. DPMA Offenlegungsschrift, DE102017002637A1, 19.10.2017.
- [O4] A. Brunker, A. Mates und C. Völzke. Schutzrecht. Titel der Anmeldung: *Verfahren zum Betrieb eines Fahrzeuges*. Detaillierter Titel: *Verfahren zur Abrollumfangsschätzung mittels GNSS-Positionsmessungen und anschließender Nutzung für die odometriebasierte Lokalisierung*. Beiträge der Autoren: A. Brunker: Ausarbeitung der Erfindung; Anwendung, Auswertung und Dokumentation. Entwicklung des Algorithmus; Implementierung, Testing; A. Mates: Entwicklung des Grundkonzepts; Machbarkeit, Korrekturlesen; C. Völzke: Entwicklung des Grundkonzepts; Theorie, Korrekturlesen. DPMA Offenlegungsschrift, DE102016005470A1, 09.02.2017.

- [O5] A. Bruncker und F. Stein. Schutzrecht. Titel der Anmeldung: *Verfahren zur Fahrtrichtungserkennung eines Fahrzeugs*. Detaillierter Titel: *Verfahren zur Rollrichtungsumkehrerkennung mittels Mustererkennung der Radticks*. Beiträge der Autoren: A. Bruncker: Entwicklung des Grundkonzepts: Theorie, Machbarkeit und Ausarbeitung der Erfindung: Anwendung, Auswertung und Dokumentation; F. Stein: Entwicklung des Algorithmus: Implementierung, Testing, Korrekturlesen. DPMA Offenlegungsschrift, DE102017003442A1, 04.01.2018.
- [O6] A. Bruncker, F. Stein, M. Greiner, V. Rodrigo-Marco und J. Kalkkuhl. Schutzrecht. Titel der Anmeldung: *Verfahren zur Ermittlung der Eigenbewegung eines Fahrzeugs, insbesondere eines Kraftfahrzeugs*. Detaillierter Titel: *Verfahren zur Detektion der Fahrtrichtung und des sicheren Stillstandes eines Fahrzeuges anhand des Kräftegleichgewichts in Längsrichtung*. Beiträge der Autoren: A. Bruncker: Entwicklung des Grundkonzepts: Theorie und Ausarbeitung der Erfindung: Anwendung, Auswertung und Dokumentation; F. Stein: Entwicklung des Algorithmus: Implementierung, Testing, Korrekturlesen; M. Greiner: Korrekturlesen; V. R.-Marco: Korrekturlesen; J. Kalkkuhl: Entwicklung des Grundkonzepts: Machbarkeit, Korrekturlesen. DPMA Offenlegungsschrift, DE102017007122A1, 01.03.2018.
- [O7] A. Bruncker und F. Stein. Schutzrecht. Titel der Anmeldung: *Verfahren zur odometriebasierten Positionsbestimmung für ein Fahrzeug*. Detaillierter Titel: *Verfahren zur robusten echtzeitfähigen Lokalisierung bei Anfahren mit falschen Rollrichtungssignal mittels Lokalisierungsfilters*. Beiträge der Autoren: A. Bruncker: Entwicklung des Grundkonzepts: Theorie, Machbarkeit und Ausarbeitung der Erfindung: Anwendung, Auswertung und Dokumentation; F. Stein: Entwicklung des Algorithmus: Implementierung, Testing, Korrekturlesen. DPMA Offenlegungsschrift, DE102017007773A1, 19.04.2018.
- [O8] A. Bruncker und M. K. Paul. Schutzrecht. Titel der Anmeldung: *Verfahren zur Optimierung eines Lokalisierungsfilters eines Fahrzeugs*. Detaillierter Titel: *Verfahren zur Optimierung eines Lokalisierungsfilters, in Abhängigkeit eines Fahrzustands klassifiziert mittels Clusteranalyse, durch Gewichtung der Eingänge mittels Fehlermodell und Monte-Carlo-Simulation*. Beiträge der Autoren: A. Bruncker: Ent-

wicklung des Grundkonzepts: Theorie, Machbarkeit und Ausarbeitung der Erfindung: Anwendung, Auswertung und Dokumentation; F. Stein: Entwicklung des Algorithmus: Implementierung, Testing, Korrekturlesen. DPMA Offenlegungsschrift, DE102017010833A1, 09.05.2018.

- [O9] A. Bruncker und F. Stein. Schutzrecht. Titel der Anmeldung: *Verfahren zur Korrektur eines Radwinkels gelenkter Räder eines Fahrzeugs*. Detaillierter Titel: *Verfahren zur Korrektur der mittleren Radwinkel durch kreisförmige Messfahrten*. Beiträge der Autoren: A. Bruncker: Entwicklung des Grundkonzepts: Theorie, Machbarkeit und Ausarbeitung der Erfindung: Anwendung, Auswertung und Dokumentation; F. Stein: Entwicklung des Algorithmus: Implementierung, Testing, Korrekturlesen. DPMA Offenlegungsschrift, DE102017006595A1, 01.03.2018.
- [O10] A. Bruncker. Schutzrecht. Titel der Anmeldung: *Verfahren zur Korrektur eines Einbaulagefehlers einer inertialen Messeinheit eines Fahrzeugs*. Detaillierter Titel: *Verfahren zur Korrektur eines Einbaulagefehlers zur Schwimmwinkelbestimmung einer inertialen Messeinheit eines Fahrzeugs*. DPMA Offenlegungsschrift, DE102018006372A1, 21.02.2019.
- [O11] A. Bruncker. Schutzrecht. Titel der Anmeldung: *Verfahren zur Ermittlung einer Eigenbewegung*. Detaillierter Titel: *Verfahren zur Adaption eines Vierrad-Lokalisierungsfilters unter Verwendung eines Reifenmodells*. DPMA Offenlegungsschrift, DE102017006056A1, 22.02.2018.
- [O12] A. Bruncker. Schutzrecht. Titel der Anmeldung: *Verfahren zur Ermittlung einer Eigenbewegung*. Detaillierter Titel: *Verfahren zur Optimieren des Fahrzeugmodells für ein Fahrerassistenzsystem mithilfe der Information vom Wetter per GNSS-Lokalisierung und UMTS*. DPMA Offenlegungsschrift, DE102017010384A1, 05.07.2018.
- [O13] A. Bruncker. Schutzrecht. Titel der Anmeldung: *Verfahren zur Korrektur eines Radwinkels gelenkter Räder eines Fahrzeugs*. Detaillierter Titel: *Verfahren zur Korrektur der Radwinkel durch Messfahrten, durchgeführt mit einer Referenzmesstechnik, mittels Bestimmung der Korrekturparameter für die gesamte Trajektorie der Messfahrt*. DPMA Offenlegungsschrift, DE102017006585A1, 01.03.2018.

- [O14] A. Brunker und F. Stein. Schutzrecht. Titel der Anmeldung: *Verfahren zur Ermittlung der Eigenbewegung eines Fahrzeugs*. Detaillierter Titel: *Verfahren zur Detektion des Einzelradschlupfes für einen Lokalisierungsfilter mittels Vergleich der Einzelradgeschwindigkeiten mit der DGNSS-Geschwindigkeit*. Beiträge der Autoren: A. Brunker: Entwicklung des Grundkonzepts: Theorie, Machbarkeit und Ausarbeitung der Erfindung; Anwendung, Auswertung und Dokumentation; F. Stein: Entwicklung des Algorithmus: Implementierung, Testing, Korrekturlesen. DPMA Offenlegungsschrift, DE102017007824A1, 19.04.2018.
- [O15] A. Brunker. Schutzrecht. Titel der Anmeldung: *Verfahren zur Leistungsoptimierung eines Fahrerassistenzsystems und Kraftfahrzeug mit einem Fahrerassistenzsystem*. Detaillierter Titel: *Verfahren zur Kalibrierung der Fahrzeugparameter eines komplexen Systemmodells zur Fahrzeuglokalisierung beim Parken durch ein unabhängiges Systemmodell während das Parksysteem inaktiv ist*. DPMA Offenlegungsschrift, DE102016011075A1, 06.04.2017.
- [O16] A. Brunker und F. Stein. Schutzrecht. Titel der Anmeldung: *Verfahren zum Schätzen von Achsparametern eines Fahrzeugs*. Detaillierter Titel: *Verfahren zur Detektieren der Verzögerung aufgrund der Fahrzeugkommunikationsschnittstelle für einen Achsparameterschätzer*. Beiträge der Autoren: A. Brunker: Entwicklung des Grundkonzepts: Theorie, Machbarkeit und Ausarbeitung der Erfindung; Anwendung, Auswertung und Dokumentation; F. Stein: Entwicklung des Algorithmus: Implementierung, Testing, Korrekturlesen. DPMA Offenlegungsschrift, DE102017007216A1, 15.03.2018.
- [O17] A. Brunker. Schutzrecht. Titel der Anmeldung: *Verfahren zur sequenziellen Schätzung von Parametern der Fahrzeugdynamik*. Detaillierter Titel: *Verfahren zur schrittweisen Kalibrierung von Fahrzeugparametern mit unterschiedlichen Kalibriermodulen*. DPMA Offenlegungsschrift, DE102017010763A1, 12.07.2018.
- [O18] A. Brunker. Schutzrecht. Titel der Anmeldung: *Verfahren zum Betrieben eines Kraftfahrzeugs insbesondere eines Kraftwagens*. Detaillierter Titel: *Verfahren zur Kalibrierung der Fahrzeugparameter mithilfe eines mobilen Endgerätes*. DPMA Offenlegungsschrift, DE102017003619A1, 19.10.2017.

Betreute Abschlussarbeiten

- [A1] A. Remäng. *Development of an Extended Kalman Filter for Vehicle Localization and Parameter Estimation*. Beitrag des Studierenden zu dieser Arbeit: Aufbau, Anwendung der Extended-Kalman-Filter (EKF)-Implementierung zur Multisensordatenfusion, welche die vier Radgeschwindigkeiten aus dem erweiterten kinematischen Zweispurmodell OdoExt2Track und die Gierrate fusionierte. Universität Stuttgart, Sep. 2016.
- [A2] F. Stein. *Eigenlokalisierung eines Kraftfahrzeugs im Niedergeschwindigkeitsbereich*. Beitrag des Studenten zu dieser Arbeit: Aufbau, Anwendung der Unscented-Kalman-Filter (UKF)-Implementierung zur Multisensordatenfusion, welche die vier Radgeschwindigkeiten aus dem erweiterten kinematischen Zweispurmodell OdoExt2Track und die DGNSS-korrigierte Schwimmwinkel und die Gierrate fusionierte und radschlupfbasiert eine Radgeschwindigkeit ausblenden kann. Universität Stuttgart, März 2017.
- [A3] M. K. Paul. *Fahrzustandsabhängige Applikation eines Filters zur Fahrzeuglokalisierung mithilfe von Monte-Carlo-Simulationen*. Beitrag des Studenten zu dieser Arbeit: Aufbau einer Fahrzustandsklassifizierung und der automatisierten Optimierung des Lokalisierungsfilters mit Hilfe von Monte-Carlo-Simulationen. KIT - Karlsruher Institut für Technologie, Okt. 2017.
- [A4] A. Zajonz. *Untersuchung der Lenk- und Fahrwerkseinflüsse beim automatisierten Parken*. Beitrag des Studenten zu dieser Arbeit: Untersuchung von Lenkungs- und Aufhängungstoleranzen und Ausarbeitung des Einflusses der Radaufstandspunktverschiebung. Hochschule Ruhr West (HRW), Juni 2016.
- [A5] J. Spengler. *Automatisierte Parameteridentifikation für ein kinematisches Fahrzeugmodell unter Verwendung eines Fahrroboters*. Beitrag des Studenten zu dieser Arbeit: Auswertungsoptimierungen

im Rahmenwerk und Anbindung an einen Fahrroboter. Hochschule Esslingen, Aug. 2017.

- [A6] R.-M. Mates. *Development of Test Environment for the Estimation of Driving Conditions and Vehicle Parameters during Parking*. Beitrag des Studenten zu dieser Arbeit: Literaturrecherche und Aufbau eines Rahmenwerks zur Darstellung verschiedener bereits bekannter Lokalisierungsmodellen. Hochschule Esslingen, März 2016.
- [A7] M. Pfeleiderer. *Potentialanalyse eines mit Vierradlenkung ausgestatteten Fahrzeugs im Bereich Manövrierassistenz im Niedriggeschwindigkeitsbereichs*. Beitrag des Studenten zu dieser Arbeit: Validierung des Lokalisierungsmodells anhand virtueller vierradgelenkter Fahrzeuge. DHBW - Duale Hochschule Baden-Württemberg, Aug. 2016.
- [A8] M. Greiner. *Erweiterung eines Simulationsmodells zur Lokalisierung eines Fahrzeugs beim Parken*. Beitrag des Studenten zu dieser Arbeit: Aufbau eines Fahrtrichtungs- und Stillstandserkennung per Kraftansatz. Universität Ilmenau, Aug. 2016.
- [A9] S. Hänle. *Optimierung eines Simulationsmodells zur Lokalisierung eines Fahrzeuges beim Parken durch Korrektur des Gierratensensors und mit Hilfe eines Algorithmus zur Steigerung der Robustheit bei fehlendem Richtungssignal*. Beitrag des Studenten zu dieser Arbeit: Aufbau von Prototypen für einen Yaw-Rate-Parameter-Estimator (YRPE) und einen Dual-Lokalisierungsfilter. Hochschule Esslingen, Aug. 2017.