



## Zustandsschätzung mit chronologisch ungeordneten Sensordaten für die Fahrzeugumfelderfassung

## DISSERTATION

zur Erlangung des akademischen Grades eines

## **Doktor-Ingenieurs**

(Dr.-Ing.)

der Fakultät für Ingenieurwissenschaften und Informatik der Universität Ulm

von

## Marc M. Muntzinger

aus Leonberg

Gutachter:

Amtierender Dekan:

Prof. Dr.-Ing. Klaus Dietmayer Prof. Dr.-Ing. Martin Bossert Prof. Dr.-Ing. Klaus Dietmayer

Ulm, 25.11.2011

## Danksagung

Die vorliegende Dissertation entstand während meiner Zeit als Doktorand bei der Daimler AG in Ulm. Die Arbeit fand in Kooperation mit dem Institut für Mess-, Regel- und Mikrotechnik der Universität Ulm statt.

Mein herzlicher Dank gilt Herrn Prof. Dr.-Ing. Klaus Dietmayer für die fachliche Betreuung meiner Dissertation und die andauernde Unterstützung während meiner Promotionszeit. Weiter danke ich Herrn Prof. Dr.-Ing. Martin Bossert vom Institut für Nachrichtentechnik für die Übernahme des Koreferats.

Die Konzeption des Pre-Crash-Systems sowie die praktische Realisierung fanden innerhalb des Daimler-Forschungszentrums statt. Danken möchte ich dem Team Aktive Sensoren unter der Leitung von Dr. Jürgen Dickmann, der mir die nötigen Freiräume zur Anfertigung meiner Dissertation gegeben hat und mir organisatorisch sowie fachlich zur Seite stand.

Stellvertretend für das ganze Team danke ich außerdem Dr. Mirko Mählisch, Matthias Schmid und Fabian Diewald für die fachlichen Anregungen und hilfreichen Diskussionen. Bei Antje Westenberger möchte ich mich herzlich für umfangreiches Korrekturlesen bedanken.

Mein ganz besonderer Dank gilt Sebastian Zuther, dessen kontinuierliche Unterstützung während meiner Promotionszeit eine große Hilfe war. Ich danke ihm für die sehr gute Teamarbeit und für seine Freundschaft.

Meinen Diplomanden Gregory de Souza, Frederik Sarholz, Maik Badel, Florian Schröder und Michael Aeberhard möchte ich für ihre Motivation und ihren überdurchschnittlichen Arbeitseinsatz danken.

Besonders möchte ich mich bei meinen Eltern und meiner Schwester bedanken, ohne deren motivierende Unterstützung diese Arbeit nicht möglich gewesen wäre.

Ulm, 25. November 2011

## Summary

### State Estimation with Out-of-Sequence Measurements in an Automotive Environment Perception

Future driver assistance systems are based on environment perception and situation analysis that must be reliable and fast. Especially in very time-critical applications such as pre-crash, it is vital to quickly and accurately estimate the position and velocity of other vehicles. An imminent impact is detected via a multi-target multi-sensor tracking system, from which a time-to-collision is determined.

Sensor fusion techniques carry with them the problem of measurements from different sensors arriving at the processing unit out-of-sequence, i.e., the original temporal ordering of measurements is lost. This poses a problem in usual sensor fusion algorithms, which is normally solved via buffering of measurements to ensure the correct temporal ordering. However, buffering causes severe temporal delays that have to be avoided by all means in time-critical applications.

For the first time in an automotive context, the presented work analyses algorithms to handle out-of-sequence-measurements (OOSM) by directly incorporating them into the state estimation without buffering. Both the 1-step-lag and *l*-step-lag case are examined, where out-of-sequence measurements may even be delayed more than one measurement cycle duration. The performance, temporal gain and costs of different approaches are evaluated. Therefore a detailed complexity analysis of the algorithms is presented. OOSM algorithms are shown to speed up the tracking and thus perform well in situations where common algorithms fail due to temporal delays.

The presented work proposes a novel data association technique as well, which incorporates out-of-sequence-measurements. Therefore the Joint Probabilistic Data Association (JPDA) is extended in order to associate (possibly delayed) measurements with tracks in a cluttered environment. The resulting algorithms are then applied to an automotive frontal pre-crash system, where OOSM and JPDA are vital factors to improve the performance of the system. In addition, a novel risk assessment with incorporating covariance propagation into a real-time pre-crash application is presented. A powerful, yet applicable method for using not only state but also covariance information for triggering actuators is proposed. A comprehensive parameter study on simulated as well as on real data shows statistically significant improvements in detection rate. Further, the importance of covariance errors in terms of accuracy for pre-crash applications is demonstrated. Even with few detection cycles and short filter settling times, a high-performance balance between detection rate and false alarms can be deduced.

The performance of the different OOSM algorithms is demonstrated using a test vehicle setup with several radar sensors, where an impact sensor is used to evaluate the estimated time to collision (TTC). OOSM algorithms lead to more accurate TTC estimations and thus increase the overall performance of the pre-crash system. Furthermore, the results from the OOSM algorithms are evaluated against reference data from a highly accurate laser scanner. Advanced OOSM algorithms in pre-crash systems are proven to reduce computational costs compared to previous approaches.

All in all, out-of-sequence algorithms are shown to significantly improve the tracking of vehicles especially in time-critical applications. OOSM algorithms may be a valuable means in future driver assistance systems to prevent collisions where usual tracking algorithms fail.

# Inhaltsverzeichnis

Sι	Summary				
1	Einleitung und Zielsetzung				
	1.1	Motiv	ation	1	
	1.2	Proble	emstellung	2	
	1.3	Inhalt	und Aufbau der Arbeit	5	
<b>2</b>	$\mathbf{Sys}$	temüb	erblick	9	
	2.1	Fahre	rassistenz- und Fahrzeugsicherheitssysteme	11	
		2.1.1	Überblick über aktuelle FAS	11	
		2.1.2	Zukünftige Systeme	12	
		2.1.3	Unfallstatistiken und rechtliche Aspekte	13	
		2.1.4	Pre-Crash als integriertes Sicherheitskonzept	14	
	2.2	Konze	ption des Versuchsfahrzeuges	15	
2.3 Radarsensoren zur Fahrzeugumfelderfassung		Radar	sensoren zur Fahrzeugumfelderfassung	16	
		2.3.1	Nahbereichsradar	17	
		2.3.2	Mehrmodusradar	18	
		2.3.3	Modellierung der Messunsicherheiten	19	
		2.3.4	Räumliche und zeitliche Kalibrierung	20	
2.4 Sensoren zur Evaluierung		Sensor	ren zur Evaluierung	21	
		2.4.1	Laserscanner	21	
		2.4.2	Kontaktsensor	22	
	2.5	Kapit	elzusammenfassung und Ausblick	22	

3	Schätztheorie zur Mehrobjektverfolgung			<b>25</b>			
	3.1	1 Sensordatenfusion					
	3.2	Filter-	und Schätzverfahren	27			
		3.2.1	Bayesfilter	28			
		3.2.2	Kalmanfilter	28			
		3.2.3	Informationsfilter	32			
	3.3	Model	lierung der Zustandsschätzung	33			
		3.3.1	Prozessmodell	33			
		3.3.2	Messmodell	36			
	3.4	4 Filterinitialisierung					
	3.5	Datena	assoziation	39			
		3.5.1	Aufwandsreduzierung durch Suchbereiche	40			
		3.5.2	Verfahren zur Datenassoziation	40			
	3.6	Objekt	tverwaltung	41			
	3.7	.7 Kapitelzusammenfassung					
4	Ver	Verfahren zur Integration chronologisch ungeordneter Sensordaten					
	4.1	1 Messdatenverzögerung					
	4.2	Reproz	zessierung	47			
	4.3	liktion	48				
		4.3.1	Ein-Schritt-Problem	50			
		4.3.2	l-Schritt-Problem	58			
		4.3.3	Eigenschaften der Retrodiktion	61			
	4.4	rts-Prädiktion mit Fusion und Dekorrelation	63				
		4.4.1	Herleitung	63			
		4.4.2	Optimale Lösung	67			
	4.5	Kompl	lexitätsanalysen	67			
		4.5.1	Rechenaufwand	68			
		4.5.2	Speicherbedarf	75			
	4.6	Kapite	elzusammenfassung	78			
<b>5</b>	00	SM mi	t probabilistischen Datenassoziationsverfahren	81			
	5.1	Probal	bilistische Datenassoziation	82			

		5.1.1	Datenassoziationsgewichte	83	
		5.1.2	Probabilistisches Datenassoziationsfilter	85	
5.2 Herleitung einer probabilistischen Datenassoziatio			tung einer probabilistischen Datenassoziation mit OOSM	85	
		5.2.1	Modifizierte Retrodiktion $(mA1)$	86	
		5.2.2	Retrodiktion mit äquivalenter Messung $(eA1)$	96	
		5.2.3	Vorwärts-Prädiktion mit Fusion und Dekorrelation	96	
		5.2.4	l-Schritt-Problem	97	
	5.3	Evalua	ation	97	
		5.3.1	Ein-Schritt-Problem	98	
		5.3.2	l-Schritt-Problem	102	
	5.4	Komp	lexitätsanalyse	104	
		5.4.1	Laufzeit	104	
		5.4.2	Speicherbedarf	104	
	5.5	Kapite	elzusammenfassung und Ausblick	105	
~		. •			
6	Situ	tuationsanalyse für Pre-Crash-Funktionen 10			
	6.1	Projek	ation des Zustandsvektors	108	
		6.1.1	Raumliche Projektion	109	
		6.1.2	Zeitliche Projektion	110	
	6.2	Projek	ctionen der Schätzfehlerkovarianz	111	
		6.2.1	Linearisierungsmethode	112	
		6.2.2	Sigma-Punkt-Methode	114	
		6.2.3	Partikel-Methode	117	
	6.3	Entsch	neidungsalgorithmus	118	
	6.4	Evalua	ation	119	
		6.4.1	Simulation einer zentralen Kollision	120	
		6.4.2	Simulation eines Ausweichmanövers	121	
		6.4.3	Pre-Crash-Simulation	122	
	6.5	Kapite	elzusammenfassung und Ausblick	126	
7 Experimentelle Ergebnisse		ntelle Ergebnisse	127		
	7.1	Bewer	tungsmaße	128	
	7.2	Simula	- ation	131	

		7.2.1	Simulation eines Drei-Schritt-OOSM-Problems	132
		7.2.2	Simulation eines Fünf-Schritt-OOSM-Problems	138
		7.2.3	OOSM-Einflussfaktoren	139
		7.2.4	ROC-Gesamtanalyse	. 140
	7.3	Auswe	ertungen realer Fahrversuche	. 143
		7.3.1	Experimente zur Schätzfehlerkovarianz	143
		7.3.2	Experimente zur Auslösewahrscheinlichkeit	146
		7.3.3	Experimente zur Fehleranalyse mittels Laserscanner	147
		7.3.4	Experimente zur TTC-Analyse mit Kontaktsensorik	148
		7.3.5	Pre-Crash-Testkatalog	152
		7.3.6	Gesamtperformanz	157
	7.4	Kapite	elzusammenfassung	160
8	Zusammenfassung und Ausblick			
	8.1	Entwie	ckelte Fusionsalgorithmen und erzielte Ergebnisse $\ldots$ $\ldots$ $\ldots$	163
	8.2	Diskus	ssion $\ldots$	165
	8.3	Ausbli	ick	. 166
$\mathbf{A}$	Anhang			
	A.1	Schalt	ungsentwurf zur zeitlichen Kalibrierung	169
	A.2	Hardw	vare der Kontaktsensorik	. 171
A	okürz	zungsv	/erzeichnis	175
Symbolverzeichnis				
Li	terat	urverz	zeichnis	181
Li	ste d	er eige	enen Publikationen	193
Index				195

## Einleitung und Zielsetzung

## 1.1 Motivation

Ein Blick auf die Unfallstatistik zeigt, dass die Zahl der Verkehrstoten seit 1970 kontinuierlich gesunken ist. Laut statistischem Bundesamt wurden im Jahr 2010 im Straßenverkehr so wenig Menschen wie noch nie getötet [130]. Mit 3 651 Getöteten handelt es sich um einen Rückgang um etwa 12 % im Vergleich zum Vorjahr. Auch die Zahl der Unfälle mit Personenschäden ist um 7,2 % auf rund 288 800 zurückgegangen. Dabei ist jedoch ein deutlicher Unterschied zwischen den Unfallstatistiken innerorts und außerorts feststellbar. Insgesamt gab es knapp 290 000 Unfälle mit Personenschäden, wovon sich über 195 000 innerorts ereigneten. Somit ist der Anteil der Unfälle mit Personenschäden innerorts mehr als doppelt so groß im Vergleich zu außerorts.

Hinzu kommt, dass mit einer fortschreitenden Urbanisierung der innerstädtische Verkehr weiter zunehmen wird. Seit 2007 wohnt mehr als die Hälfte der Menschen in Städten, wohingegen 1950 noch 70 % der Weltbevölkerung auf dem Land lebte [58]. Nach Schätzungen der UNO wird sich dieser Trend noch verschärfen. So soll der Anteil der städtischen Bevölkerung 2030 auf 60 % und 2050 bereits auf 70 % steigen.

Die Fähigkeit komplexe innerstädtische Verkehrssituationen präzise zu erkennen und einzuschätzen ist der Schlüssel für zukünftige Fahrerassistenzsysteme (FAS, *engl.* "Advanced Driver Assistance Systems", ADAS). Ein Schwerpunkt aktueller Forschungsarbeiten im Bereich der FAS konzentriert sich daher auf komplexe Kreuzungsszenarien im städtischen Straßenverkehr. Aufgrund von Verdeckungen durch Bebauungen und andere Verkehrsteilnehmer werden die Zeitfenster zur Objektverfolgung immer kürzer und dabei ergeben sich neue Herausforderungen für die Umgebungserfassung und die Situationsbewertung.

Die vorliegende Arbeit soll einen Beitrag dazu leisten, die vorhandenen Defizite heutiger Fahrerassistenzsysteme mit sehr langen Datenaufbereitungszeiten zu reduzieren und somit eine zuverlässige Prognose hochdynamischer Verkehrssituationen zu ermöglichen. Zu diesem Ziel ist eine Verkürzung der Signalverarbeitungszeiten ebenso notwendig wie eine Verringerung der Unsicherheiten in der Zustandsschätzung sowie in der Situationsanalyse. Hierfür ist neben einer effizienteren und schnelleren Signalverarbeitung eine verlässliche Methodik zur Erkennung von drohenden Kollisionen nötig, die mittels einer berechneten Kollisionswahrscheinlichkeit eine fundierte Situationsklassifikation ermöglicht. In der vorliegenden Arbeit soll daher ein Gesamtsystem zur Verbesserung bisheriger Assistenzsysteme insbesondere in zeitkritischen Situationen entwickelt und vorgestellt werden.

Um komplexe Verkehrssituationen schnellstmöglich und zuverlässig erkennen und interpretieren zu können, werden in heutigen Sicherheitssystemen Sensoren mit unterschiedlichen physikalischen Messprinzipien fusioniert. Eine Kombination aus Sensoren wie Ultraschall, Radar, Lidar und Kamerasystemen ermöglicht die Erfassung der Umgebung auch unter schwierigsten Bedingungen. Assistenzsysteme wie die automatische Distanzregelung, Nachtsichtgeräte oder Spurhalteassistenten sind die ersten Schritte zum "kognitiven Auto", in dem Sensoren und Computer immer mehr Funktionen übernehmen [141].

Die Kombination einzelner Sensoren zu einem ganzheitlichen Fusionssystem stellt neue Anforderungen an die Signalverarbeitung. So verlangt z.B. eine Zustandsschätzung mittels Kalmanfilterung Sensordaten in chronologisch geordneter Reihenfolge. Dies ist jedoch bei einer Sensordatenfusion nicht immer garantiert. Durch die Fusion verschiedener Sensoren mit unterschiedlichen Zykluszeiten und unterschiedlichen Latenzen können Messungen außerhalb der zeitlichen Reihenfolge (*engl.* "Out-of-Sequence Measurements", OOSM) entstehen. Die Berücksichtigung von nicht chronologischen Sensordaten wurde im automotiven Kontext bisher nicht adressiert, was zu unnötig langen Verarbeitungszeiten und großen Unsicherheiten in der Zustandsschätzung heutiger Assistenzsysteme führt. Dies stellt im Hinblick auf die oben beschriebenen zu erwartenden Entwicklungen in der Automobilindustrie einen gravierenden Nachteil dar. Die vorliegende Arbeit soll daher die Integration von nicht chronologischen Sensordaten in die Zustandsschätzung untersuchen und die Herausforderungen, Möglichkeiten und Beschränkungen dieser Verfahren analysieren.

## 1.2 Problemstellung

Die Problematik chronologisch ungeordneter Sensordaten wird anhand eines Beispiels mit zwei asynchron laufenden Sensoren erläutert. Die beiden Sensoren, im Folgenden Sensor 1 und Sensor 2 genannt, unterscheiden sich zum einen in der Zykluszeit, also der Zeitspanne zwischen den Aufnahmezeitpunkten zweier aufeinanderfolgender Messungen. Zum anderen wird ein Unterschied in den Sensorlatenzen angenommen, das heißt in der Zeitspanne zwischen Messzeitpunkt und Ankunftszeitpunkt der Messung am Fusionssystem. Im vorliegenden Beispiel werden die Zykluszeiten von Sensor 1 bzw. Sensor 2 als konstant mit 66 ms bzw. 40 ms angenommen und die Latenzen mit 198 ms bzw. 80 ms.

Abbildung 1.1 zeigt das zeitliche Verhalten der hier beispielhaft verwendeten Sensoren. Die Nummerierungen der Messungen entsprechen der chronologischen Reihenfolge des Messzeitpunktes. Messungen von Sensor 1 werden als Rechtecke, Messungen von Sensor 2 als Kreise dargestellt. Wenn beide Sensoren denselben Startzeitpunkt haben, erreicht die erste Messung von Sensor 2 die Fusionseinheit nach 80 ms und die erste Messung von Sensor 1 nach 198 ms.



**Abbildung 1.1:** Zeitachse mit Messzeitpunkten zweier Sensoren mit unterschiedlichen Zykluszeiten von 66 ms bzw. 40 ms und unterschiedlichen Latenzen von 198 ms bzw. 80 ms. Messung (1) erreicht nach Messung (5) die Fusionseinheit und stellt die erste Messung außerhalb der zeitlichen Reihenfolge dar.

Betrachtet man nun das zeitliche Eintreffen in der Fusionseinheit, so ist folgende Reihenfolge zu beobachten: Nach Messungen mit den Nummern (2), (3) und (5) erreicht Messung (1) die Fusionseinheit erst nach 198 ms. Diese Messung mit der Nummer (1) ist die erste Messung in nicht chronologischer Reihenfolge. Ein solches Problem wird im Folgenden als OOSM-Problem bezeichnet. Eine Zustandsschätzung würde in diesem Fall einen aktuellen Systemzustand zum Messzeitpunkt der Messung (5), also 80 ms enthalten. Zur Integration von Messung (1) muss die Zeit des Zustands gleich der Zeit der Messung sein. In diesem Fall muss also zuerst in die Vergangenheit zum Zeitpunkt 0 ms prädiziert werden. Das Standard-Kalmanfilter kann jedoch nicht in die Vergangenheit prädizieren, sondern nur Sensordaten in zeitlicher Reihenfolge verarbeiten.

Die einfachste Lösung des beschriebenen Problems ist die Messungen zwischenzuspeichern, die entsprechende Zeit zu warten und schließlich in richtiger Reihenfolge zu integrieren. Diese sogenannte Messdatenverzögerung stellt die am häufigsten verwendete Lösung für das OOSM-Problem dar.

Nachteile der Messdatenverzögerung treten insbesondere in zeitkritischen Anwendungen auf, beispielsweise bei der Auslösung eines Pre-Crash-Systems, also eines Systems zur Aktivierung von reversiblen Sicherheitseinrichtungen vor einer detektierten Kollision. Bei Verwendung einer Messdatenverzögerung sind nicht alle vorhandenen Messungen in die Zustandsschätzung integriert und damit bei der Kollisionsklassifikation berücksichtigt. Dies führt zu einem geringeren Informationsgehalt als unter sofortiger Integration aller Messungen.

Ein weiterer großer Nachteil dieses Verfahrens ist, dass durch das Zwischenspeichern von Messdaten eine unerwünschte zeitliche Verzögerung entsteht, die vor allem in zeitkritischen Situationen sehr relevant sein kann. Beispielsweise stehen bei der Entscheidung, ob ein Pre-Crash-System ausgelöst wird oder nicht, nur veraltete Daten zur Verfügung. Neuere Messungen sind zwar vorhanden, wurden aber durch die Zwischenspeicherung noch nicht integriert, was einen Verlust von wertvollen Informationen darstellt. Abbildung 1.2 stellt die Nachteile dieses Verfahrens schematisch dar. Es wird ein einfacher Pre-Crash-Fall angenommen, bei dem es mit konstanter Geschwindigkeit zu einer frontalen Kollision mit einem Hindernis kommt. Die Sensordaten erreichen die Fusionseinheit in einer Reihenfolge wie in der vorherigen Abbildung 1.1 gezeigt. Die Ankunftszeiten der jeweiligen Sensoren sind mit senkrechten Linien markiert und die schattierten Ellipsen einer Messung kennzeichnen dabei bereits integrierte Messungen der Zustandsschätzung. Die grau gestrichelte Linie stellt eine Pre-Crash-Auslösezeit von 200 ms dar. Zu diesem Zeitpunkt muss entschieden werden, ob das Pre-Crash-System reversible Sicherheitssysteme aktivieren soll. Bei der Messdatenverzögerung muss auf die Messung mit der größeren Latenz gewartet werden. Aus diesem Grund können die zwei letzten Messungen von Sensor 2 bis zur Pre-Crash-Auslösezeit nicht in die Zustandsschätzung integriert werden.

Im Gegensatz zur Messdatenverzögerung kann bei einem erweiterten OOSM-Algorithmus, wie in Abbildung 1.3 gezeigt, jede Messung sofort nach Erreichen der Fusionseinheit integriert werden. Das heißt, alle bis zum Zeitpunkt 200 ms vor der Kollision in der Fusionseinheit vorhandenen Messungen tragen zur Zustandsschätzung bei. Dies führt zu einem erhöhten Informationsgehalt, einerseits durch die größere Anzahl an integrierten Messungen und andererseits dadurch, dass es sich um aktuellere Messungen handelt.

Ein weiterer Vorteil der OOSM-Algorithmen ist bei der auf die Signalverarbeitung folgenden Situationsanalyse ersichtlich. In der vorliegenden Arbeit wird eine Kollisionsklassifikation entwickelt, bei der basierend auf den Unsicherheiten der Zustandsschätzung eine Kollisionswahrscheinlichkeit hergeleitet wird, mittels der die Auslösung des Pre-Crash-Systems erfolgt. Unter Verwendung einer Messdatenverzögerung sind aufgrund der hier größeren Unsicherheiten auch nur weniger verlässliche Kollisionswahrscheinlichkeiten ableitbar und eine fundierte Entscheidung über die Auslösung des Pre-Crash-Systems ist kaum möglich.

Bei der Messdatenverzögerung stehen also durch eine Zwischenspeicherung weniger Messungen und somit weniger Informationen zur Pre-Crash-Aktivierung zur Verfügung. Im konkreten Fall der gezeigten schematischen Darstellung wird bei der Messdatenverzögerung basierend auf zwei Messungen entschieden, wohingegen dem erweiterten Algorithmus vier Messungen zur Verfügung stehen. Außerdem werden mit der aktuellen Schätzung modellbasierte Prädiktionen über zukünftige Zustände berechnet. Somit liegt bei einer Messdatenverzögerung die letzte integrierte Messung in der Vergangenheit und eine längere zeitliche Prädiktion als beim erweiterten Algorithmus ist erforderlich. Dies ist in der Abbildung durch die Länge des waagerechten Pfeils gekennzeichnet. Aus der geringeren Anzahl integrierter Messungen und den zeitlich längeren Prädiktionen folgt eine im Allgemeinen schlechtere Pre-Crash-Erkennungsrate.

Diese Arbeit dient insbesondere der Verbesserung von Systemen mit sehr kurzen Reaktionszeiten, also vor allem von zeitkritischen Sicherheitssystemen. Die entwickelten Algorithmen werden am Beispiel eines Pre-Crash-Systems evaluiert und deren Vorteile aufgezeigt. Ein Pre-Crash-System eignet sich aufgrund der hohen Anforderungen bezüglich niedriger Falschalarmrate und kurzer Reaktionszeiten besonders gut für einen Vergleich zeitkritischer Systeme. Diese Arbeit ist jedoch nicht nur auf Pre-Crash-Systeme beschränkt, sondern zeigt die neuen Anforderungen an Signalverarbeitungsalgorithmen und deren Lösungen für zukünftige Fahrerassistenz- und Sicherheitssysteme auf.



Abbildung 1.2: Messdatenverzögerung bei asynchronen Sensoren (S1 und S2) mit zwei integrierten Messungen und Modellprädiktion. Zwei Messungen des zweiten Sensors (S2) müssen zwischengespeichert werden und können zu diesem Zeitpunkt noch nicht in die Zustandsschätzung integriert werden.



Abbildung 1.3: Erweiterter Algorithmus mit Integration jeder vorhandenen Messung bis 200 ms vor der Kollision und kürzerer Modellprädiktion.

## 1.3 Inhalt und Aufbau der Arbeit

Ziel der Arbeit ist es, theoretisch sowie experimentell zu untersuchen, ob und wie die OOSM-Algorithmen in zukünftigen Fahrerassistenzsystemen eingesetzt werden können und welche Erweiterungen nötig sind, um den oben beschriebenen Anforderungen diffiziler innerstädtischer Verkehrssituationen gerecht zu werden. Die Arbeit wird in folgende Kapitel untergliedert:

Kapitel 2 gibt einen Überblick über den Aufbau des vorliegenden Gesamtsystems. Das verwendete Pre-Crash-System wird erläutert und in den Kontext aktueller sowie zukünftiger Fahrerassistenz- und Fahrzeugsicherheitssysteme gestellt. Es werden die Rahmenbedingungen und Einflussfaktoren der weiteren Arbeit erläutert. Hierzu zählen eine Einführung in die verwendete Hardware eines prototypisch aufgebauten Versuchsfahrzeuges ebenso wie die umgebungserfassende Sensorik und die speziellen Referenzsensoren zur Evaluierung der entwickelten Algorithmen.

Kapitel 3 bietet eine umfassende Einführung in Verfahren zur Verfolgung mehrerer Objekte. Es dient als Grundlagenkapitel der Zustandsschätzung. Die hier vorgestellten Algorithmen werden in den nachfolgenden Kapiteln für die OOSM-Behandlung erweitert. Das Kalmanfilter mit Datenassoziation und die in dieser Arbeit verwendeten Modelle bilden dabei den Schwerpunkt dieses Kapitels.

Kapitel 4 behandelt Signalverarbeitungsalgorithmen zur Integration von chronologisch ungeordneten Sensordaten. Beginnend mit der Erklärung der Notwendigkeit einer getrennten Behandlung von OOS-Messungen (*engl.* "Out-of-Sequence") im Kalmanfilter wird schließlich auf das Prozessmodell eingegangen und die Schwierigkeit einer Prädiktion in die Vergangenheit erläutert. Es werden zwei OOSM-Lösungen vorgeschlagen und mit dem Standard-Ansatz einer Messdatenverzögerung verglichen. Als Referenzalgorithmus dient eine Reprozessierung, die eine Integration aller Messungen in zeitlicher Reihenfolge ermöglicht. Das Kapitel schließt mit einer ausführlichen Komplexitätsanalyse, die die Laufzeit- und Speicheranforderungen der verschiedenen Algorithmen im Detail vergleicht.

In Kapitel 5 wird ein neues Verfahren zur Integration von chronologisch ungeordneten Sensordaten in die Zustandsschätzung bei Hintergrundrauschen entwickelt. Dies ermöglicht die Anwendung des vereinheitlichten probabilistischen Datenassoziationsverfahrens (*engl.* "Joint Probabilistic Data Association", JPDA) mit den in Kapitel 4 vorgestellten OOSM-Algorithmen. Die Erweiterung der OOSM-Algorithmen um eine probabilistische Datenassoziation ist entscheidend, da es bei einfacheren Datenassoziationsverfahren durch die fehlende Information der OOS-Messung zu Falschassoziationen kommen kann.

In Kapitel 6 wird eine neue Situationsbewertung für Pre-Crash-Funktionen vorgestellt. Das Pre-Crash-Entscheidungsmodul basiert dabei nicht nur auf den Systemzuständen, sondern zusätzlich auch auf den Schätzfehlerkovarianzen. Durch die Projektion dieser Unsicherheiten kann sowohl eine räumliche als auch eine zeitliche Kollisionswahrscheinlichkeit berechnet werden. Die Nichtlinearität der Projektion erfordert hierbei gesonderte Beachtung, es werden drei unterschiedliche Verfahren entwickelt, die einander gegenübergestellt werden. Das hergeleitete Verfahren ermöglicht eine Parametrierung je nach vorliegendem Anwendungsfall und das Pre-Crash-System kann somit zuverlässiger ausgelöst werden.

In Kapitel 7 werden die entwickelten OOSM-Algorithmen mit Simulationen sowie mit realen Fahrversuchen untersucht. Der Schwerpunkt der Auswertung liegt auf den Experimenten mit realen Sensordaten. Das Pre-Crash-System des Versuchsfahrzeuges wird dabei mit einem Kontaktsensor und einem Laserscanner einem bewertenden Vergleich unterzogen und die Bedeutung von OOSM-Algorithmen anhand von praktischen Beispielen verdeutlicht. Die Verbesserung der Gesamtperformanz durch höhere Erkennungsrate und niedrigere Falschalarmrate wird mit einem ausgiebigen Fahrmanöverkatalog belegt. Der Aufbau dieser Arbeit folgt der prinzipiellen Funktionsweise eines Pre-Crash-Systems: Angefangen mit dem Versuchsfahrzeug und der umgebungserfassenden Sensorik über die neuen Algorithmen zur Signalverarbeitung bis hin zur Aktivierung reversibler Rückhaltesysteme in der Situationsbewertung. Die Arbeit schließt in Kapitel 8 mit einer Zusammenfassung der erzielten Ergebnisse und gibt einen Ausblick auf zukünftige mögliche Forschungsarbeiten.

## Systemüberblick

Im Rahmen dieses Kapitels wird ein Überblick über das verwendete Gesamtsystem gegeben. Der zentrale Fokus der vorliegenden Arbeit liegt auf der Signalverarbeitung, Objektverfolgung und Situationsanalyse. Diese Komponenten werden von einer Reihe an Einflussfaktoren und Rahmenbedingungen bestimmt, die im folgenden Kapitel näher erläutert werden. Hierbei ist eine Kenntnis der zu Grunde liegenden Applikation unter Berücksichtigung der rechtlichen Aspekte ebenso wichtig wie die Beschreibung der verwendeten Sensoren und Evaluierungshardware.

Der Gesamtkontext des verwendeten Systems ist in Abbildung 2.1 schematisch dargestellt. Als Grundlage dient hierbei ein Überblick über Fahrerassistenz- und Fahrzeugsicherheitssysteme, wobei im Folgenden beide Begriffe abkürzend unter dem Begriff Fahrerassistenzsysteme zusammengefasst werden. Hierbei wird eine Unterteilung vorgenommen in aktuelle Systeme, die als Grundlage der Weiterentwicklung dienen, und zukünftige Systeme, welche die bisher nicht erfüllten Anforderungen und Ziele vorgeben, wobei auch die rechtlichen Aspekte zu berücksichtigen sind. Diese Arbeit hat zum Ziel, den Anforderungen zukünftiger Systeme besser gerecht zu werden.

Der Schwerpunkt des Kapitels liegt auf dem in dieser Arbeit verwendeten Pre-Crash-System, das beim Erkennen einer kritischen Situation die Insassen auf einen drohenden Unfall optimal vorbereitet. So wird ein reversibler Gurtstraffer bei Bedarf schon vor dem Unfallereignis aktiviert, um die Gurtlose zu beseitigen und damit eine optimale Wirkung des Gurt- und Airbagsystems zu gewährleisten.

Ein weiterer wichtiger Einflussfaktor des verwendeten Gesamtsystems ist die Sensorik, weswegen ein Überblick über die verwendete Hardware zur Umgebungserfassung gegeben wird. Zuerst wird auf den Aufbau des Versuchsfahrzeugs eingegangen, danach erfolgt eine Beschreibung der Sensorik zur Umgebungserfassung, deren spezielle Eigenschaften zur Problematik chronologisch ungeordneter Sensordaten führt, und schließlich werden die Sensoren zur Evaluierung vorgestellt. Wichtige Randbedingungen der Sensorik sind die Kalibrierung sowie die Modellierung der Messunsicherheiten, siehe Abbildung 2.1. Es ist zu beachten, dass es sich bei dieser Abbildung um eine schematische Darstellung handelt, die als Überblick über die Rahmenbedingungen dienen soll. Weitere wichtige Einflussfaktoren wie zum Beispiel das Prozessmodell gehören inhaltlich zur Signalverarbeitung und werden daher erst in den darauffolgenden Kapiteln erläutert.



Abbildung 2.1: Schematischer Überblick über das verwendete Gesamtsystem. Das Kernmodul bildet die Signalverarbeitung und Situationsanalyse im grau hinterlegten Kasten mit den verschiedenen dargestellten Einflussfaktoren.

### 2.1 Fahrerassistenz- und Fahrzeugsicherheitssysteme

Neue Fahrerassistenzsysteme (FAS) kommen in immer kürzer werdenden Abständen auf den Markt und gehören derzeit neben alternativen Antriebskonzepten zu den Forschungsschwerpunkten der Automobil- und Automobilzulieferindustrie. Diese Systeme stehen jedoch auch unter enormem Kostendruck und Innovationen werden häufig nur in der Premiumklasse bzw. als Sonderausstattung angeboten. Ein durchdringender Markterfolg ist jedoch für die Verbesserung der Sicherheit im Straßenverkehr von großer Bedeutung. Eine Kostenreduktion kann in Zukunft nur erreicht werden, wenn auf Basis einer gemeinsamen Sensorkonfiguration mehrere Anwendungen bedient werden können. Eine solche allgemeine Sensorplattform für verschiedene FAS wurde in [70] vorgestellt. Werden mehrere verschiedene Anwendungen von einer gemeinsamen Fusionseinheit bedient, ist eine Fusion unterschiedlicher Sensoren häufig unausweichlich. In der vorliegenden Arbeit wird am Beispiel zweier unterschiedlicher Radarsensoren ein Fusionskonzept mit chronologisch ungeordneten Sensordaten entwickelt. Im Folgenden wird ein Überblick über die aktuellen und zukünftigen Fahrerassistenzsysteme gegeben und ein Pre-Crash-System vorgestellt.

#### 2.1.1 Überblick über aktuelle FAS

Unter Fahrerassistenzsystemen (FAS) versteht man jegliche Art von Mithilfe oder Unterstützung, die ein Fahrer von einem technischen System erhält. Somit gehören schon die automatische Blinkerrückstellung oder der elektrische Starter zu den frühen FAS. Im Gegensatz zu diesen klassischen besitzen neuere FAS Sensoren zur Erfassung der Umgebung und je nach Anwendung eine komplexe Signalverarbeitung.

Die Evolution dieser neueren Fahrerassistenzsysteme beginnt mit dem automatischen Abstandsregler (*engl.* "Adaptive Cruise Control", ACC). Weitere FAS wie Spurwechselassistent (*engl.* "Lane Change Decision Aid"), Spurhalteassistent (*engl.* "Lane Keeping Support") oder die Kombination dieser Systeme zur integrierten Längs- und Querführung [53] folgten. Sichtverbesserungssysteme oder Einparkassistenten gehören ebenso zu FAS wie Navigationssysteme. Aktuelle Forschungsarbeiten konzentrieren sich auf Überhol-, Kreuzungs- und Ausweichassistenten [117]. Hierzu zählen beispielsweise das europäische Projekt *INTERSAFE-2* [61] oder das deutsche Projekt *Ko-PER*, das zur Projektinitiative *Ko-FAS* gehört [72].

Sicherheitssysteme werden in aktive und passive Systeme unterteilt. Passive Sicherheitssysteme werden während oder nach einem Unfall aktiviert, um die Insassen besser zu schützen. Zur Reduzierung von Unfallfolgen sind passive Sicherheitssysteme wie nichtreversible Gurtstraffer oder Airbags in modernen Fahrzeugen mittlerweile Standard. Derartige Systeme werden meist durch Sensoren ausgelöst, die erst im Moment des eigentlichen Unfalls reagieren. Diese Sensoren sind in der Lage, Verzögerungswerte, die Stoßrichtung sowie die Auftreffposition zum Zeitpunkt des Unfalls zu ermitteln und an die Sicherheitssysteme weiterzugeben. Beispiele solcher klassischen passiven Sicherheitssysteme sind Knautschzonen, pyrotechnische Gurtstraffer und Airbags. Im Gegensatz dazu beschränken sich aktive Sicherheitssysteme auf den direkten Eingriff in das Fahrgeschehen, um einen Unfall zu vermeiden. Aktive Sicherheitssysteme sind z.B. das Antiblockiersystem (ABS), das Elektronische Stabilisierungsprogramm (ESP) oder der intelligente Bremsassistent (BAS).

Neuere Sicherheitssysteme verbinden die aktive und passive Sicherheit zur Unfallvermeidung oder zur Minimierung der Unfallschwere (*engl.* "Collision Mitigation Systems", CMS). Diese Systeme werden wenige Millisekunden vor dem Unfall aktiviert und sollen die Insassen besser auf den drohenden Unfall vorbereiten. Solche Systeme, die sowohl vor einem Unfall als auch während des Unfalls aktiv eingreifen, werden häufig als integrierte Sicherheitssysteme bezeichnet. Pre-Crash ist ein Beispiel eines solchen integrierten Sicherheitssystems und wird in Abschnitt 2.1.4 näher beschrieben.

Ein detaillierter Überblick aktueller FAS findet sich in [67, 103, 139]. Die heutigen FAS-Produkte der Erstausrüster (*engl.* "Original Equipment Manufacturer", OEM) und der Zulieferindustrie stellt [21] vor. Die Vielfalt der verschiedensten Fahrerassistenz- und aktiven Sicherheitssysteme wird in [48, 141] zusammengefasst.

#### 2.1.2 Zukünftige Systeme

Ein häufig gebrauchtes Schlagwort zukünftiger Sicherheitssysteme ist die kooperative Perzeption. Gemeint sind damit Fahrzeuge, die untereinander (*engl.* "Car-to-Car", Car2Car) oder mit der Infrastruktur (*engl.* "Car-to-Infrastructure", Car2X) Informationen austauschen und im kollektiven Verbund Entscheidungen treffen [68, 86]. Die Untersuchung von Car-to-Car und Car-to-Infrastructure-Kommunikation ist Gegenstand aktueller Projekte, wie beispielsweise des deutschen Forschungsprojekts *simTD* [123].

Neben der Verbesserung der Sicherheit leisten Fahrerassistenzsysteme heute schon einen Beitrag zum umweltfreundlicheren Straßenverkehr, z.B. durch geringere Beschleunigungsund Bremsspitzen. Dieser Trend wird sich auch aufgrund des öffentlichen Interesses an umweltfreundlicher Mobilität in Zukunft noch verstärken [13, 41].

Innerstädtische Fahrsituationen, wie sie insbesondere an Kreuzungen auftreten, sind noch zu komplex für heutige FAS und stehen deshalb im Mittelpunkt aktueller Forschungsarbeiten [50, 57], [141, S. 572ff.]. Zukünftige Sicherheitssysteme werden vermehrt aktive Eingriffe in die Fahrdynamik zur Kollisionsvermeidung vornehmen. Das langfristige Ziel ist dabei ein "Vollverkehrsautomat", der autonomes Fahren ohne Einschränkungen ermöglichen soll [81, 134].

Die von der "Defense Advanced Research Projects Agency (DARPA)" ausgerichtete Urban Challenge 2007 war ein Rennen zwischen vollautonomen Fahrzeugen. Das Ziel war es, so schnell wie möglich eine 96 Kilometer lange Strecke auf unbekanntem und bebautem Gebiet einer ehemaligen Kaserne zu durchfahren [76, 107, 142]. Nur elf von 89 Fahrzeugen erreichten das Ziel, darunter wiederum nur sechs Fahrzeuge ohne größere Schäden [37]. Das Rennen zeigte das Potential, aber auch den enormen Aufwand und die noch bestehenden Schwierigkeiten autonomen Fahrens auf. Inzwischen existieren schon einige Weiterentwicklungen der damals verwendeten Systeme, die auf eine breitere Anwendbarkeit in realistischeren Szenarien abzielen [79]. Ein ähnliches Projekt aufbauend auf der Urban Challenge ist das Stadtpilot-Projekt der Technischen Universität Braunschweig, dessen Ziel es ist, vollständig autonom im Stadtverkehr unter Berücksichtigung von Verkehrsregeln zu fahren [118]. Weiter wurde in der VIAC, der VisLab Intercontinental Autonomous Challenge, eine dreimonatige autonome Folgefahrt von Italien nach China durchgeführt. Das Ziel war fahrerloses Folgefahren unter unbekannten Straßen- und Wetterverhältnissen [16].

Auch der US-amerikanische Internetdienstleister Google arbeitet mittlerweile an computergesteuertem Fahren. Mit sieben Testfahrzeugen ist der Konzern nach eigenen Angaben bereits über 225 000 Kilometer autonom gefahren [121]. Unter Leitung von Sebastian Thrun, Professor für künstliche Intelligenz an der Stanford Universität, ist zu erwarten, dass die Forschungsaktivitäten von Google auf diesem Gebiet weiter ausgebaut werden [133].

Zusammenfassend ist also vor allem eine Entwicklung zu autonomem Fahren und Fahrerunterstützung in komplexen innerstädtischen Situationen ersichtlich. In diesen Bereichen wird die Bedeutung von Sensorfusionsalgorithmen weiter steigen.

#### 2.1.3 Unfallstatistiken und rechtliche Aspekte

Laut statistischem Bundesamt ereigneten sich 2010 in Deutschland 2 398 414 Unfälle [130]. Während der Bestand an motorisierten Fahrzeugen kontinuierlich wächst, nimmt die Zahl der Getöteten, wie in der Einleitung bereits erwähnt, ständig ab. So weist die Statistik die niedrigste Zahl an Todesopfern seit 1950 aus. Abgesehen von den zwei Jahren nach der Deutschen Wiedervereinigung, als die Gesamtzahl der Bevölkerung stieg, sank die Zahl der im Straßenverkehr Getöteten seit 1970 kontinuierlich. Einer der Hauptgründe hierfür sind neue Fahrerassistenz- und Fahrzeugsicherheitssysteme. In einem Bericht des statistischen Bundesamtes heißt es [129, S. 10]:

"Verkehrsrechtliche Regelungen, wie beispielsweise die Einführung der Helmtrageund Gurtanlegepflicht, die Senkung der Höchstgrenze für den Blutalkoholkonzentrationswert haben ebenso wie eine ständige Verbesserung der Sicherheit und der technischen Ausstattung der Fahrzeuge dazu beigetragen [...]"

Zukünftige Fahrerassistenzsysteme, die in Richtung autonomes Fahren tendieren, dürften diesen Trend noch verstärken.

Ein weiterer Aspekt hinsichtlich dieser zukünftigen Systeme ist die Betrachtung der rechtlichen Fragen. Im Wiener Übereinkommen über den Straßenverkehr von 1968, auch bekannt unter dem Namen Wiener Konvention [136, S. 15], heißt es in Art. 13 Abs. 1:

"Every driver of a vehicle shall in all circumstances have his vehicle under control so as to be able to exercise due and proper care and to be at all times in a position to perform all manoeuvres required of him. [...]"

Der Fahrer muss also immer und unter allen Umständen sein Fahrzeug beherrschen und somit Fahrerassistenz- und Sicherheitssysteme übersteuern können. Eine große Hürde

auf dem Weg zum autonomen Fahren ist deshalb die Zulassung zum Straßenverkehr und die Begrenzung von Hersteller- und Fahrerhaftung [19]. Auch die Absicherung und somit der Aufwand von Dauerlauftests ist aus heutiger Sicht noch nicht abzuschätzen. Aktuelle Systeme unterstützen den Fahrer und haben somit einen noch sehr geringen Automatisierungsgrad. Nur solange der Fahrer den automatischen Ablauf überwacht und die Fahrerassistenzsysteme übersteuern kann, sind diese Systeme rechtlich unproblematisch [1, 39].

Inzwischen gibt es jedoch Hinweise darauf, dass die rechtlichen Fragen bezüglich autonomen Fahrens in Zukunft zunehmend thematisiert werden. Beispielsweise hat der amerikanische Bundesstaat Nevada im April 2011 eine Gesetzesvorlage veröffentlich, welcher zum ersten Mal fahrerloses Fahren auf öffentlichen Straßen legalisieren soll [135]. Der Ausgang dieser Initiative und die weiteren juristischen Fragen beim Einsatz vollautonomer Fahrzeuge können zum Zeitpunkt der Erstellung dieser Arbeit noch nicht beantwortet werden.

#### 2.1.4 Pre-Crash als integriertes Sicherheitskonzept

Passive Sicherheitssysteme alleine ermöglichen keine Vorauslösung reversibler Sicherheitssysteme. Damit ein verbesserter Insassenschutz bei Unfällen gewährleistet werden kann, benötigen Sicherheitssysteme Informationen über das Umfeld des Fahrzeuges. Mit einer umgebungserfassenden Sensorik können diese Informationen bereits vor einem Unfall bereitgestellt werden. Die Nutzung verschiedener Frequenzbereiche aus dem elektromagnetischen Spektrum mittels Fusion von Radarsensoren und optischen Sensoren wie Laserscanner und Kamera ermöglicht die Umgebungserfassung und Interpretation auch unter schwierigsten Bedingungen (Details siehe z.B. [148]).

Durch die Verfolgung von Objekten und die Bestimmung ihrer Eigenschaften können vor dem eigentlichen Unfall Systeme aktiviert werden, die den Insassenschutz noch verbessern. So können zum Beispiel die Sitze in eine optimale Position gefahren, Fenster geschlossen oder das Straffen der Gurte veranlasst werden. Einen Überblick über den Aufbau eines solchen Pre-Crash-Systems zeigt Abbildung 2.2. Beginnend mit der Sensortechnologie wird das Umfeld des Fahrzeuges beobachtet. Die Messdaten der Sensoren werden mit einer Signalverarbeitungsalgorithmik gefiltert und die wahren Zustände der Umgebung geschätzt. Anschließend erfolgt eine Situationsbewertung, die anhand von Objekten und ihrer Dynamik entscheidet, ob es zu einem Unfall kommt oder nicht. Falls ja, werden in der Funktionseinheit reversible Rückhaltesysteme wie z.B. die Gurtstraffer aktiviert.

In dieser Arbeit wird basierend auf einer asynchronen Sensordatenfusion ein erweitertes Pre-Crash-System entwickelt. Zwei Nahbereichsradare und ein Mehrmodusradar (siehe Abschnitt 2.3) werden unter Berücksichtigung chronologisch ungeordneter Sensordaten miteinander fusioniert. Die Fusion ist durch verschiedene Sichtbereiche und unterschiedliche Eigenschaften der Sensoren begründet. Die schlechte Winkelgenauigkeit der Nahbereichsradare kann durch eine Fusion mit dem Mehrmodusradar ausgeglichen werden. Auf der anderen Seite ergänzt die hohe Entfernungsgenauigkeit der Nahbereichsradare die schlechtere Genauigkeit des Mehrmodusradars. Das in dieser Arbeit entwickelte Pre-Crash-System löst bei Aktivierung einen reversiblen Gurtstraffer aus.



Abbildung 2.2: Allgemeiner Aufbau eines Pre-Crash-Systems.

In bisherigen Pre-Crash-Systemen wurde die Integration chronologisch ungeordneter Messungen nicht berücksichtigt. Ein auf zwei Nahbereichsradaren basierendes Pre-Crash-System wurde in [128] und [98] beschrieben. Eine aus Laserscanner und Radarsensoren bestehende Fusion stellte [127] sowie [109] vor. In [49] wurde eine Fusionsarchitektur bestehend aus Radar, Laserscanner und Kamera entwickelt. Alle diese Pre-Crash-Systemen setzten jedoch bei der Fusion chronologisch geordnete Sensordaten voraus. Ein Pre-Crash-System unter Berücksichtigung der Fahrerreaktionszeit wurde in [97] vorgestellt. Eine Pre-Crash-Funktion realisiert mit einer monokularen Kamera ist nachzulesen in [132]. was jedoch den Nachteil einer unsichereren Entfernungsbestimmung im Vergleich zum Radar mit sich bringt. In [28] ist die Situationsanalyse so erweitert worden, dass ein Heckaufprall klassifiziert werden kann. Eine 360°-Pre-Crash-Rundumsicht mit Radarsensoren wurde in [147] gegeben und ein Pre-Crash-System mit einem Laserscanner wurde in [51] vorgestellt. Letzteres hat den Nachteil sehr hoher Kosten. Eine ausführliche Funktionsbeschreibung aktueller Pre-Crash-Systeme ist in [125] zu finden. Diese Systeme kennzeichnet wieder die Voraussetzung, dass Sensordaten in chronologischer zeitlicher Ordnung vorliegen. Das in der vorliegenden Arbeit betrachtete System stellt daher eine sinnvolle und notwendige Erweiterung bisheriger Pre-Crash-Systeme dar.

## 2.2 Konzeption des Versuchsfahrzeuges

Ein Versuchsfahrzeug vom Typ Mercedes-Benz S-Klasse bildet die Plattform des in dieser Arbeit entwickelten Pre-Crash-Systems. Abbildung 2.3a zeigt den Aufbau des Rammschutzes mit Kontaktsensor und Abbildung 2.3b den Messtechnikaufbau im Kofferraum.

Abbildung 2.3c zeigt die Kollision mit einem Schaumstoffzylinder. Bei Erkennung einer unvermeidbaren Kollision wird auf dem Bildschirm des Beifahrerplatzes ein Warndreieck wie in Abbildung 2.3d angezeigt und die reversiblen Gurtstraffer von Fahrer und Beifahrer aktiviert. Das Versuchsfahrzeug ist mit zwei Nahbereichsradaren ausgestattet, die hinter dem Stoßfänger montiert sind und einem Mehrmodusradar, das hinter dem Kühlergrill eingebaut ist. Die Nahbereichsradare dienen zur Unterstützung der aktiven Geschwindigkeitsregelung im Nahbereich und das Mehrmodusradar bildet den Hauptsensor für die Regelung im Fernbereich. Eine ausführliche Beschreibung der Radarsensorik findet sich in Abschnitt 2.3. Die Kontaktsensorik ist mit einem Linearpotentiometer realisiert und wird in Kapitel 2.4.2 erläutert. Unterhalb des Nummernschildes befindet sich zusätzlich noch ein Laserscanner, der als Referenzsensor bei der Echtdatenauswertung dient. Der Laserscanner wird ausführlich in Kapitel 2.4.1 beschrieben. Eine VGA-Kamera hinter der Windschutzscheibe dient zur Dokumentation der Messfahrten.



Abbildung 2.3: (a) Versuchsfahrzeug mit Rammschutz und Kontaktsensorik an der unteren Schiene. (b) Messtechnikaufbau im Kofferraum. (c) Test mit Kollisionszylinder aus Schaumstoff. (d) Bildschirmfoto des Fahrzeugrechners bei einer Pre-Crash-Auslösung: Bei Erscheinen des Warndreiecks wird im Fahrzeug der reversible Gurtstraffer von Fahrer und Beifahrer aktiviert.

## 2.3 Radarsensoren zur Fahrzeugumfelderfassung

Radar (*engl.* "Radio Detection and Ranging") hat seine Ursprünge in der Militärtechnik und wurde erstmals 1998 für eine adaptive Geschwindigkeitsregelung in Fahrzeugen angeboten. Für heutige Radarsysteme im Straßenverkehr stehen insgesamt die vier Bänder 24,0–24,25 GHz [25, 131], 76–77 GHz [112], 77–81 GHz [120] und ein Ultraweitband von 21,65–26,65 GHz [43, 140] zur Verfügung. Bis auf das 77–81 GHz-Band werden alle genutzt. Das meistbenutzte Band, das auch weltweit für das Automobilradar reguliert ist, stellt das Frequenzband um 76,5 GHz dar [116, 119].

Bei Radaren handelt es sich um aktive Sensoren, die gebündelte elektromagnetische Wellen aussenden und die reflektierten Echos auswerten. Die Auswertung der Laufzeit und der Doppler-Verschiebung ergibt die Distanz und die radiale Geschwindigkeit eines Objektes. Radarsensoren stellen bis heute eine der wichtigsten Sensorklassen im Automobilbereich dar. Die Gründe für die Bedeutung von Radarsensoren für FAS sind die relativ einfache Verbaubarkeit, die geringen Wetterabhängigkeiten und die direkte Messung der radialen Geschwindigkeit. Als nachteilig erweist sich in vielen Fällen die relativ schlechte Winkelauflösung und die fehlende Möglichkeit einer Klassifikation. Ersteres kann jedoch teilweise mit einem neuartigen Radarkonzept ausgeglichen werden (s. Abschnitt 2.3.2).

Das in dieser Arbeit vorgestellte Pre-Crash-System basiert auf zwei Nahbereichsradaren und einem Mehrmodusradar. Dies hat wie bereits erwähnt zum einen den Vorteil, dass die hohe Winkelauflösung des Mehrmodusradars mit der exakten Entfernungsmessung der Nahbereichsradare kombiniert werden kann. Zum anderen ergänzen sich die beiden Sichtbereiche (*engl.* "Field of View", FoV) der Sensoren, so dass insgesamt ein größerer Sichtbereich abgedeckt werden kann. Abbildung 2.4 zeigt die Sichtbereiche beider Sensoren. Im folgenden Abschnitt werden die beiden Radarsensoren genauer vorgestellt.



Abbildung 2.4: Sichtbereiche der Radarsensorik des Pre-Crash-Systems basierend auf zwei Nabreichsraden (SRR) und einem Mehrmodusradar (MMR) mit Nah- und Fernbereichsmodus. Definition des Fahrzeugkoordinatensystems mit den Koordinaten  $\xi$ ,  $\eta$  und  $\zeta$ .

#### 2.3.1 Nahbereichsradar

Für die Pre-Crash-Funktion kommen zwei Nahbereichsradare (*engl.* "Short Range Radar", SRR) zum Einsatz. Diese sind nicht sichtbar hinter dem Stoßfänger montiert und werden über das Fahrzeugbussystem (*engl.* "Controller Area Network", CAN) ausgelesen. Es handelt sich hierbei um Puls-Doppler Radare basierend auf einer 24 GHz-Technologie im Ultraweitband (*engl.* "Ultra Wide Band", UWB). Um eine Entfernungsauflösung von wenigen Zentimetern zu ermöglichen werden Impulse mit einer Pulsdauer im Nanosekundenbereich gesendet. Dazu wird eine zur Pulslänge reziproke Bandbreite von mehreren Gigahertz benötigt.

Die Bestimmung des Winkels erfolgt mit dem Antennen-Monopulsverfahren [124, Kapitel 18.3]. Dieses Verfahren basiert auf einer Doppelantennen-Anordnung für den Empfangskanal. Durch eine unterschiedliche Strahlcharakteristik kann der Winkel aus dem Quotienten von Differenz und Summensignal der Amplitudenbeträge berechnet werden. Unter Annahme einer konstanten Rückstreuamplitude zwischen zwei aufeinanderfolgenden Messungen kann eine sequentielle Auswertung der einzelnen Antennen erfolgen (*engl.* "Sequential Lobing"). Dieses Messprinzip ergibt eine Winkelgenauigkeit von bis zu 10°, was sich in der vorliegenden Anwendung als nicht ausreichend erweist, um den genauen Ort des Zusammenpralls zu berechnen. Aus diesem Grund werden die Messungen des Nahbereichsradars mit denjenigen des Mehrmodusradars fusioniert.

In den vorliegenden zeitkritischen Anwendungen ist es wichtig, die genauen Latenzen der einzelnen Sensoren zu kennen. Dies ist insbesondere notwendig, um chronologisch ungeordnete Sensordaten überhaupt identifizieren zu können. Die Sensorlatenz beschreibt dabei die Zeit, die zwischen der Messaufnahme und der Ankunft der Daten am Fusionssystem verstreicht. Die zwei SRR des Versuchsfahrzeugs haben eine Latenz von 80 ms und eine Periodendauer von 40 ms. Die Kenntnis der Zykluszeiten ist entscheidend dafür, ob ein deterministischer Pufferspeicher verwendet werden kann, was in Kapitel 4 genauer beschrieben wird.

Die SRR verfügen über einen sehr großen Öffnungswinkel von 80°, was den Sichtbereich des Mehrmodusradars für querenden Verkehr sinnvoll erweitert. Außerdem besitzen sie eine Reichweite von bis zu 30 m. Auf die Verwendung von Reflexions- und Breitenmodellen für das Nahbereichsradar wird in dieser Arbeit verzichtet und auf [29, 30] verwiesen. Hierdurch könnte die Genauigkeit des verwendeten Pre-Crash-Systems weiter erhöht werden, indem nicht nur Punktziele, sondern ausgedehnte Objekte für die Berechnung einer Kollisionswahrscheinlichkeit verwendet werden. Die für ein Pre-Crash-System relevanten Eigenschaften der SRR sind neben anderen Sensoren in Tabelle 2.1 zusammengefasst.

#### 2.3.2 Mehrmodusradar

Das Mehrmodusradar (*engl.* "Multi Mode Radar", MMR) vereint ein Nah- und ein Fernbereichsradar in einem Gehäuse. Im Unterschied zum SRR arbeitet das Galliumarsenid-Hochfrequenzmodul des MRR in einem Frequenzbereich von 76–77 GHz als frequenzmoduliertes Dauerstrichradar (*engl.* "Frequency Modulated Continuous Wave", FMCW). Bei der Frequenzmodulation werden die Informationen über die Laufzeit des Signals durch Frequenzvariation gewonnen. Dabei wird die Momentanfrequenz kontinuierlich und rampenförmig verändert und das überlagerte Signal an der Empfangsseite ausgewertet.

Das in dieser Arbeit verwendete MMR hat durch sein spezielles Messprinzip den Vorteil einer vergleichsweise hohen Winkelgenauigkeit. Dazu führt ein Wellenleiter die Millimeterwellen, die durch eine mechanisch drehende Walze gestreut werden. Ein Rillenabstand auf der Walze bestimmt den Winkel der abstrahlenden Welle und ermöglicht ein mechanisches Scanning-Prinzip. Der genaue Aufbau und die Funktionsweise der patentierten Antennenkomponenten [95] werden ausführlich in [141, S. 159ff.] beschrieben. Die Anbindung des Sensors an den Fahrzeugrechner erfolgt über Ethernet mittels einer LVDS-Schnittstelle (*engl.* "Low Voltage Differential Signaling").

Im Modus des Fernbereichsradars (*engl.* "Long Range Radar", LRR) wird eine Reichweite bis zu 200 m und eine Winkelgenauigkeit von bis zu 0,1° erzielt. Diese vergleichsweise hohe Winkelgenauigkeit erweist sich in Pre-Crash-Anwendungen als sehr hilfreich, der LRR-Modus muss jedoch aufgrund des eher geringen Öffnungswinkels von 18° mit dem SRR-Modus fusioniert werden. Im SRR-Modus kann eine Winkelgenauigkeit bezogen auf Punktziele von 1° bei einem Öffnungswinkel von 56° erzielt werden.

Eigenschaft	SRR	MMR (Nah/Fern)	LS
Messfrequenz	$25\mathrm{Hz}$	$15\mathrm{Hz}$	$25\mathrm{Hz}$
Latenz	$80\mathrm{ms}$	$198\mathrm{ms}$	$40\mathrm{ms}$
Messprinzip	Puls-Doppler	FMCW	Lidar
Frequenz	$24\mathrm{GHz}$	$7677\mathrm{GHz}$	$331\mathrm{THz}$
Bandbreite	$5\mathrm{GHz}$	$187\mathrm{MHz}$	$167\mathrm{MHz}$
Maximaler Öffnungswinkel	$80^{\circ}$	$56^{\circ}/18^{\circ}$	$160^{\circ}$
Maximale Entfernungsmessung	$30\mathrm{m}$	$60\mathrm{m}/200\mathrm{m}$	$200\mathrm{m}$
Winkelgenauigkeit $(3\sigma$ -Werte)	$\pm 5^{\circ}10^{\circ}$	$\pm 1,0^{\circ}/\pm 0,1^{\circ}$	$\pm 0,5^{\circ}$
Entfernungsgenauigkeit $(3\sigma$ -Werte)	$\pm5\mathrm{cm}\ldots7,5\mathrm{cm}$	$\pm 25\mathrm{cm}$	$\pm 5\mathrm{cm}$
Dopplergenauigkeit ( $3\sigma$ -Werte)	$\pm 5  \frac{\mathrm{km}}{\mathrm{h}}$	$\pm 1  \frac{\mathrm{km}}{\mathrm{h}} / \pm 0.5  \frac{\mathrm{km}}{\mathrm{h}}$	

**Tabelle 2.1:** Sensorspezifikation des Nahbereichsradars (SRR), des Mehrmodusradars (MMR) und des Laserscanners (LS). Bei den Genauigkeitswerten des SRR gilt dabei die größere Angabe für den ungenaueren Randbereich des Sichtfelds.

Die Latenz dieses Radarsensors beträgt 198 ms bei einer Periodendauer von 66 ms. Somit beträgt die Latenz mehr als das Doppelte im Vergleich zum SRR. Dies deutet bereits darauf hin, dass es aufgrund der unterschiedlichen Latenzen zu chronologisch ungeordneten Sensordaten kommen kann, worauf in den folgenden Kapiteln genauer eingegangen wird. Tabelle 2.1 listet die Eigenschaften des MMR im Vergleich zu anderen Sensoren auf.

#### 2.3.3 Modellierung der Messunsicherheiten

Für Signalverarbeitungsalgorithmen wird eine möglichst genaue Modellierung der Messunsicherheiten benötigt. Bei Radarsensoren weist jeder detektierte Punkt eine Varianz in Entfernung, Winkel und Doppler-Geschwindigkeit auf. In der Zustandsschätzung können diese Unsicherheiten in den Messfehlerkovarianzmatrizen  $\mathbf{R}$  modelliert werden. Die Varianzen sind über das gesamte Sichtfeld meistens nicht konstant und wurden daher an verschiedenen Punkten bestimmt (siehe Abbildung 2.5). Dazu werden die Herstellerangaben über die Unsicherheiten der Sensoren mit statischen Referenzmessungen verifiziert und entsprechend modifiziert.

Abbildung 2.5a zeigt die mit einem Laserdistanzmesser vermessenen Referenzpunkte. An diesen Stellen wird für jede Messung ein Winkelreflektor (*engl.* "Corner Reflector") aufgestellt. Abbildung 2.5b zeigt das über alle Messungen und über alle Zeitschritte integrierte Ergebnis. Man sieht, dass die Messgenauigkeit stark von Entfernung und insbesondere Winkel des Reflektors abhängt. Bei den verwendeten Radarsensoren ist sogar ein Unterschied zwischen dem rechten und dem linken Sichtbereich feststellbar. Idealerweise verwendet man daher eine Varianzfunktion in Abhängigkeit von Entfernung und Winkel. Für das in dieser Arbeit entwickelte Pre-Crash-System wurde eine Lookup-Tabelle implementiert.



Abbildung 2.5: (a) Bekannte Referenzpunkte und (b) deren statische Messungen in Form von entsprechenden Radarreflektionen. Ziel ist die Bestimmung der Messunsicherheit und der räumlichen Kalibrierung.

Die statisch berechneten Messfehlerkovarianzen haben sich in der Praxis auch für dynamische Fahrmanöver bewährt. Für das Messrauschen wird in der Filtertheorie ein normalverteiltes, additives, mittelwertfreies, weißes und gegenseitig unkorreliertes Rauschen gefordert. Bei Sensoren mit völlig unterschiedlichen Messprinzipien kann die Annahme der Unkorreliertheit adäquat sein. Die Unkorreliertheit verschiedener, jedoch baugleicher Sensoren kann in diesem Fall aber nicht garantiert werden. Falls die Unkorreliertheit der Sensoren nicht gewährleistet werden kann, können alternative Formen des Kalmanfilters verwendet werden [122, S. 183ff]. Im Rahmen dieser Arbeit wird jedoch das Messrauschen als unkorreliert angenommen, was sich in praktischen Anwendungen als ausreichend erwiesen hat.

#### 2.3.4 Räumliche und zeitliche Kalibrierung

Um verschiedene Sensoren fusionieren zu können, müssen die Sensoren zeitlich und räumlich zueinander kalibriert werden. Die Radarsensoren besitzen unterschiedliche Messzeitpunkte. Die zeitliche Kalibrierung erzeugt einen globalen Zeitstempel, damit alle Sensordaten in einer einheitlichen Zeitbasis vorliegen, was im folgenden genauer beschrieben wird.

Der SRR-Sensor wird über ein Radarsteuergerät (*engl.* "Radar Decision Unit", RDU) getriggert. Der MMR-Sensor ist jedoch nicht triggerbar, sondern freilaufend, und die Daten werden über eine USB-Schnittstelle (*engl.* "Universal Serial Bus") eingelesen. Zur zeitlichen Kalibrierung dieses Sensors wurde eine Laserdiodenschaltung entworfen, die direkt die Frequenz der sich drehenden Walze abgreift. Im Anhang A.1 wird die Schaltung der Laserdiode vorgestellt, die auch in [157] veröffentlicht wurde. Außerdem kommt auf dem Messtechnikrechner ein Betriebssystemkern mit sehr kurzen Prozesstakten zum Einsatz,

so dass sehr schnell zwischen einzelnen Prozessen umgeschaltet wird. Dies verhindert zu lange Latenzen und Schwankungen in der Verarbeitungszeit eines einzelnen Prozesses. Zusätzlich werden die aufgenommenen Messzeitpunkte durch eine Zustandsschätzung gefiltert. Hierzu werden der Messzeitpunkt und die Zykluszeit mit einem linearen Kalmanfilter geschätzt, was einzelne Schwankungen in der Ankunftszeit der Messdaten herausfiltert. Dies ermöglicht eine noch genauere Rekonstruktion des wahren Messzeitpunktes.

Für die räumliche Kalibrierung wird das Koordinatensystem nach Norm 70 000 [38] gewählt, definiert vom Deutschen Institut für Normung (DIN). Abbildung 2.4 zeigt das in dieser Arbeit verwendete Fahrzeugkoordinatensystem mit Koordinatenursprung in der Mitte des vorderen Stoßfängers. Da die Radarsensoren nur Messungen in einer Ebene liefern, wird im Folgenden die  $\zeta$ -Achse nicht weiter berücksichtigt. Die Messpunkte aller Sensoren werden in dieses Fahrzeugkoordinatensystem transformiert. Die extrinsische Kalibrierung wird durch die Sensorposition und Orientierung bestimmt. Da es sich bei den Radaren dieser Arbeit um Seriensensoren handelt, werden die exakten Einbaupositionen aus den Konstruktionsdaten der Baureihe entnommen. Die intrinsische Kalibrierung bestimmt die internen Sensorparameter, wie zum Beispiel das Antennendiagramm. Diese sind im Datenblatt angegeben und werden vom Radarsensor intern verwendet.

Die räumliche Kalibrierung dient schließlich zur Umrechnung von Messdaten in das verwendete Fahrzeugkoordinatensystem. Diese Kalibrierdaten werden ebenfalls aus dem oben beschriebenen Experiment zur Bestimmung der Messunsicherheiten gewonnen. Dazu wird der quadratische Fehler über alle Messpunkte minimiert. Diese globale Minimierungsfunktion zwischen allen berechneten Mittelwerten und den Referenzpunkten liefert die gewünschte räumliche Kalibrierung.

## 2.4 Sensoren zur Evaluierung

Um die entwickelten Algorithmen vergleichen zu können, wird das Versuchsfahrzeug mit zusätzlichen Sensoren ausgestattet. Diese Sensorik dient jedoch nur zur Evaluierung der entwickelten Verfahren und wird nicht zur Berechnung der Pre-Crash-Auslösung verwendet. In diesem Abschnitt wird zuerst ein Laserscanner und anschließend ein Kontaktsensor beschrieben. Ersterer liefert die Referenzposition des verfolgten Objektes, zweiterer ermöglicht die Bestimmung der exakten Aufprallzeit bei einer Kollision.

#### 2.4.1 Laserscanner

Um die wahre Position eines Objektes zu bestimmen, werden die verfolgten Objekte mit den Daten eines Laserscanners verglichen. Ein im Vergleich zu Radar hochgenauer Laserscanner mit einer Winkelgenauigkeit von 0,5° und einem Öffnungswinkel von 160° dient als Referenzsensor. Der Laserscanner basiert auf dem Lidar-Prinzip (*engl.* "Light Detection and Ranging") und liefert Messungen in verschiedene Winkelrichtungen. Dieses scannende Verfahren ermöglicht den großen Sichtbereich und wird bei dem in dieser Arbeit benutzten Sensor mit einem drehenden Spiegel realisiert. Das Messprinzip eines Lidarsensors ist dem eines Radarsensors sehr ähnlich. Anstelle von Mikrowellen (300 MHz–300 GHz) werden bei Laserscannern im automobilen Bereich elektromagnetische Wellen aus dem NIR-Spektrum (*engl.* "Near-Infrared") verwendet. Es werden Lichtimpulse ausgesendet und mittels Laufzeitverfahren (*engl.* "Time-of-Flight", ToF) die Entfernung zum Ziel bestimmt. Im Unterschied zum Radar erfolgt die Bestimmung der Geschwindigkeit jedoch durch Differenziation von mehreren aufeinanderfolgenden Abstandsmessungen und nicht durch eine Dopplermessung. Der messtechnische Aufwand wäre hierfür im Automobilbereich zu groß, da der Unterschied zwischen der Dopplerverschiebung und der hohen Sendefrequenz bei Laserscannern zu gering ist. Ein qualitativer Vergleich zwischen Radar- und Lidarsensoren im Automobilbereich findet sich in [82, S. 84f.]. Die wichtigsten Eigenschaften des verwendeten Laserscanners werden in Tabelle 2.1 mit den Radarsensoren verglichen.

#### 2.4.2 Kontaktsensor

Zur Auswertung der verschiedenen Algorithmen zur Integration zeitlich ungeordneter Sensordaten ist ein Vergleich der geschätzten Kollisionszeit (*engl.* "Time-to-Collision", TTC) mit der realen Kollisionszeit unerlässlich. Neben dem Verhältnis aus Erkennungsrate und Falschalarmrate ist der genaue Kollisionszeitpunkt zur Aktivierung von reversiblen Rückhaltesystemen von großer Bedeutung. Je sicherer und genauer die Schätzungen erfolgen, desto gezielter können passive Sicherheitssysteme eingesetzt werden. Zur Bestimmung einer TTC-Referenz wird in dieser Arbeit ein Linearpotentiometer benutzt, das sowohl die exakte Position des Objektes bei einer Kollision als auch den exakten Aufprallzeitpunkt detektiert.

Das 1,20 m lange Linearpotentiometer ist an der unteren Querstrebe des Rammschutzes befestigt, welcher in Abbildung 2.3a dargestellt wurde. Der schlauchförmige Sensor besteht aus mehreren hintereinandergeschalteten Widerständen. Beim Aufprall schließt der Stromkreis an der Kontaktstelle und ein Teil der Stromversorgungsspannung fällt an den Widerständen bis zur Kontaktstelle ab. Die Sensorausgangsspannung wird an einen Mikrocontroller weitergeleitet, der den Spannungswert mit Hilfe eines A/D-Wandlers konvertiert und dem Fahrzeugrechner zur Verfügung stellt. Eine ausführliche Beschreibung der messtechnischen Anbindung im Versuchsfahrzeug erfolgt im Anhang unter A.2 und wurde in [158] veröffentlicht.

## 2.5 Kapitelzusammenfassung und Ausblick

Im vorliegenden Kapitel wurde der Gesamtaufbau des verwendeten Systems beschrieben. Es wurden die einzelnen Einflussfaktoren im Detail erläutert, die in Abbildung 2.1 schematisch dargestellt sind. Hierbei wurden aktuelle Fahrerassistenzsysteme als Stand der Technik beschrieben sowie zukünftige Assistenzsysteme als Ausblick auf die zu erwartenden Anforderungen und Herausforderungen unter Einbeziehung rechtlicher Fragen. Weiter wurde ein Überblick über das in dieser Arbeit verwendete Pre-Crash-System gegeben. Schließlich wurden die verwendeten Seriensensoren ebenso wie die spezielle Evaluierungshardware vorgestellt. Anhand der zeitlichen Eigenschaften der beiden Radarsensoren ist ersichtlich, dass es zu dem in Abschnitt 1.2 beschriebenen OOSM-Problem kommt, da der MMR eine vielfach größere Latenz als der SRR besitzt. Das stellt neue Herausforderungen an die Signalverarbeitung, welche in Abbildung 2.1 durch den grau hinterlegten Kasten dargestellt ist. Dieser Teil des Gesamtsystems stellt den Schwerpunkt der vorliegenden Arbeit dar. In den nachfolgenden Kapiteln wird daher detailliert auf die Signalverarbeitung, Datenassoziation und Situationsanalyse unter Berücksichtigung chronologisch ungeordneter Sensordaten eingegangen.

# Schätztheorie zur Mehrobjektverfolgung

In der Umgebungserfassung spielt die zeitliche Verfolgung von Objekten (*engl.* "Tracking") eine entscheidende Rolle, um möglichst genaue Vorhersagen über die Auftreffwahrscheinlichkeit und die Auftreffzeit auf relevante Kollisionsobjekte zu berechnen. Dazu müssen dynamische Eigenschaften der Objekte optimal geschätzt werden. Filter- bzw. Schätzalgorithmen werden eingesetzt, um Informationen zu verbessern oder neue Informationen zu gewinnen. Dadurch sollen die Signale von Störungen befreit und nicht direkt messbare Zustandsgrößen geschätzt werden. Ein ausführlicher Überblick über Filter- und Schätzverfahren findet sich in [10].

Die in diesem Kapitel vorgestellten Verfahren sind in der Literatur bekannt und werden im Folgenden in ihrer Nomenklatur eingeführt. Dazu gibt dieses Kapitel einen umfassenden Überblick über die Schätztheorie zur Verfolgung mehrerer Objekte [55]. Dabei bilden das Kalmanfilter und die zu Grunde liegende Modellierung der Zustandsschätzung den Schwerpunkt dieses Kapitels. Die Signalverarbeitungskette kann allgemein in vier Abschnitte unterteilt werden: Messen, Verfolgen, Entscheiden und Handeln [4]. Bei einem Sicherheitssystem wird dies in Sensor, Schätzverfahren, Situationsanalyse und Aktorik unterteilt. Die konkrete Umsetzung für das in dieser Arbeit vorgestellte Pre-Crash-System besteht aus Radar, Kalmanfilter, Kollisionsklassifikation und Aktivierung des Gurtstraffersystems.

Bei einem Pre-Crash-System werden von Radarsensoren Distanz- und Geschwindigkeitsmessungen von Objekten im Fahrzeugumfeld aufgenommen und an eine Fusionseinheit übermittelt. Abbildung 3.1 zeigt den allgemeinen Ablauf von der Signalaufnahme bis zur Objektbildung mit folgenden Schritten:

- (1) Im ersten Schritt werden vom Empfangselement rauschüberlagerte Signale in Form von Energie empfangen. Die Energie ist bei Radarsensoren elektromagnetische Strahlung. Diese wird über eine Antenne empfangen und in Rohsignale umgewandelt.
- (2) Die Rohsignale werden durch die Empfangseinheit in Spannungen bzw. Frequenzen umgewandelt. Dies geschieht durch eine Vielzahl von elektronischen Bauelementen



Abbildung 3.1: Allgemeines Ablaufdiagramm von der Sensordatenaufnahme bis zur Objektbildung in Anlehnung an [36, S. 9]. Die Signalvorverarbeitung beschreibt dabei die Messwertgenerierung und die Zustandsschätzung die Objektbildung z.B. mittels Kalman-Filterung.

wie z.B. Tiefpass, Verstärker und A/D-Wandler. Anschließend erfolgt die Messdatengewinnung durch sensorspezifische Signalvorverarbeitungsschritte.

- (3) Die Messdaten repräsentieren Ziele mit Intensitäten, Entfernungen, Winkel und Doppler-Geschwindigkeiten.
- (4) Auf Basis der Messdaten erfolgt eine Zustandschätzung und Filterung der Ziele. Die resultierenden Objekte beschreiben unter anderem Fahrzeuge in der Umgebung in einem einheitlichen Koordinatensystem.

In den meisten Fällen erfolgen die Schritte bis zur Signalvorverarbeitung im Sensor, die anschließende Zustandsschätzung wird häufig auf einem externen Steuergerät realisiert.

## 3.1 Sensordatenfusion

Allgemeines Ziel der Sensordatenfusion ist es, die Stärken aller Sensoren gewinnbringend zu kombinieren und die Schwächen einzelner Sensoren zu reduzieren. Eine Kombination mehrerer Sensoren bewirkt somit eine geringere Gefahr von Fehlinterpretationen und eine höhere Genauigkeit. In der vorliegenden Arbeit wird eine zentrale Fusion auf Merkmalsebene realisiert, bei der die Messungen sequenziell in die Zustandsschätzung integriert werden. Diese wird im Folgenden genauer beschrieben.

#### Zentrale Fusion auf Merkmalsebene

Bei einer Fusion mehrerer Sensoren, bei dem jeder Sensor wiederum mehrere Ziele liefert (*engl.* "Multi-Sensor Multi-Target Tracking") spielt die Wahl der Fusionsebene eine entscheidende Rolle [115]. Eine Möglichkeit ist die Fusion auf Objektebene (*engl.* "High Level Sensor Fusion"), die sogenannte Objekt-zu-Objekt-Fusion. Dabei werden alle Schritte bis zur Objektbildung aus Abbildung 3.1 getrennt für jeden Sensor berechnet und diese anschließend fusioniert. Diese sogenannte dezentrale Fusion bietet den Vorteil einer Realisierung der Zustandsschätzung im Prozessor des Sensors, was zu geringerer Datenlast
führt. Als Nachteil erweist sich die hohe Abstraktionsebene, bei der die Wahrscheinlichkeit einer fehlerhaften Interpretation der Messungen steigt [141, S. 243f.]. Beispielsweise werden im Konfliktfall nicht alle vorhandenen Messungen aller Sensoren zu Rate gezogen, so dass es zu fehlerhaften Entscheidungen kommen kann. Aus diesem Grund wurde in der vorliegenden Arbeit auf Merkmalsebene statt auf Objektebene fusioniert.

In der realisierten Fusionsarchitektur stellen ungefilterte Radar-Rohziele die Merkmalsebene der Fusion dar. Dieser Fusionsansatz wird auch als Messdatenfusion bezeichnet (*engl.* "Low Level Sensor Fusion"). Der Nachteil dieses Verfahren liegt in dem höheren Übertragungsaufwand, da nicht nur die Objekte, sondern die Messdaten des Sensors übertragen werden müssen. Außerdem kann die Zustandsschätzung, wie in Abbildung 3.1 gezeigt, nicht mehr im Sensor realisiert werden, sondern muss auf einem externen Steuergerät durchgeführt werden.

Der Sensoraufbau basiert auf nicht orthogonalen Radarsensoren, das heißt Sensoren mit gleichem oder ähnlichem physikalischem Messprinzip. Dies ist ein weiterer Grund dafür, den Ansatz einer zentralen Architektur zu wählen, der einer dezentralen Architektur bei nicht orthogonalen Sensoren überlegen ist [71].

Ein weiterer wichtiger Aspekt der Fusion von Messdaten oder Originaldaten ist die Vermeidung von Filterketten. Bei der Filterung von schon gefilterten Daten, wie sie bei einer Objekt-zu-Objekt-Fusion entstehen, sind die Fehler korreliert und die Zustandsschätzung muss dementsprechend angepasst werden [122].

### Sequenzielle Fusion

Eine weitere Einteilung der Fusionsverfahren kann in parallele und sequenzielle Fusion erfolgen. Bei der sequenziellen Fusion werden die Messungen in mehreren aufeinander folgenden Zeitschritten in das Filter integriert. Da in dieser Arbeit der Schwerpunkt auf der Zustandsschätzung mit nicht synchronisierten Sensoren liegt, wird ein sequenzieller Ansatz realisiert. Dieser wird häufig auch als implizite Fusion bezeichnet [42].

Weiterführende Literatur zur Fusionsarchitektur findet sich in [36] und eine ausführliche Beschreibung verschiedener Fusionsebenen gibt [139]. Verschiedene Fusionsansätze bei Pre-Crash-Systemen werden in [126] vorgestellt.

# 3.2 Filter- und Schätzverfahren

Die Aufgabe der zeitlichen Verfolgung von Objekten ist es, aus Messungen  $\mathbf{z}_k$  zum Zeitpunkt  $t_k$  die interessierenden Zustandsgrößen  $\mathbf{x}_k$  zu schätzen. Ausgehend vom Bayesfilter, das ein allgemeingültiges Schätzverfahren für dynamische Systeme darstellt, wird in diesem Abschnitt auf mögliche Realisierungen eingegangen. Nimmt man normalverteilte Wahrscheinlichkeitsdichten an, so wird eine effiziente Verarbeitung durch das Kalmanfilter möglich. Für den allgemeinen Fall, dass die Wahrscheinlichkeitsdichten nicht normalverteilt und häufig auch nicht mehr analytisch geschlossen darstellbar sind, approximiert das Partikelfilter die Wahrscheinlichkeitsdichtefunktionen.

### 3.2.1 Bayesfilter

Bedingte Wahrscheinlichkeiten lassen sich nach dem Satz von Bayes [14] folgendermaßen schreiben: (-1, -2k, 1) (-1, 2k, 1, -1)

$$p(\mathbf{x}_k|Z^k, U^k) = \frac{p(\mathbf{z}_k|\mathbf{x}_k, Z^{k-1})p(\mathbf{x}_k|Z^{k-1}, U^k)}{p(\mathbf{z}_k|Z^{k-1})},$$
(3.2.1)

wobei  $Z^{k-1}$  alle Messungen bis zum Zeitpunkt  $t_{k-1}$  beinhaltet:

$$Z^{k-1} = \{ \mathbf{z}_i \}_{i=0}^{k-1} = \{ \mathbf{z}_0, ..., \mathbf{z}_{k-1} \}.$$
 (3.2.2)

Die Menge  $U^k$  besteht aus externen Steuervektoren:

$$U^{k} = \{\mathbf{u}_{i}\}_{i=0}^{k} = \{\mathbf{u}_{0}, ..., \mathbf{u}_{k}\}.$$
(3.2.3)

Unter der Annahme, dass die aktuelle Messung  $\mathbf{z}_k$  von den früheren Messungen unabhängig ist, erhält man:

$$p(\mathbf{x}_k|Z^k, U^k) = c_k \cdot p(\mathbf{z}_k|\mathbf{x}_k) p(\mathbf{x}_k|Z^{k-1}, U^k), \qquad (3.2.4)$$

mit einer von  $\mathbf{x}_k$  unabhängigen Normierungskonstante  $c_k$ . Die formale Beschreibung des letzten Faktors aus Gleichung (3.2.4) lässt sich mit dem Gesetz der totalen Wahrscheinlichkeit umschreiben in:

$$p(\mathbf{x}_k|Z^{k-1}, U^k) = \int p(\mathbf{x}_k|\mathbf{x}_{k-1}, Z^{k-1}, U^k) p(\mathbf{x}_{k-1}|Z^{k-1}, U^{k-1}) \, d\mathbf{x}_{k-1}.$$
(3.2.5)

Mit der Markow-Eigenschaft des Bayesfilters hängt die Zukunft des Systems nur von der Gegenwart und nicht von der Vergangenheit ab. Somit wird der aktuelle Zustand  $\mathbf{x}_k$  nur vom letzten Zustand  $\mathbf{x}_{k-1}$ , der die gesamte Historie enthält, und vom aktuellen Steuervektor  $\mathbf{u}_k$  beeinflusst. Durch Einsetzen der Gleichung (3.2.5) in Gleichung (3.2.4) erhält man die rekursive Form des Bayesfilters:

$$p(\mathbf{x}_k|Z^K, U^k) = c_k \cdot p(\mathbf{z}_k|\mathbf{x}_k) \underbrace{\int p(\mathbf{x}_k|\mathbf{x}_{k-1}, \mathbf{u}_k) p(\mathbf{x}_{k-1}|Z^{k-1}, U^{k-1}) \, d\mathbf{x}_{k-1}}_{\text{Prädiktion}}.$$
(3.2.6)

Das Bayesfilter ist somit ein sequenzielles Filter bestehend aus einem Prädiktions- und einem Innovationsschritt. Für die Prädiktion wird das Integral aus Gleichung (3.2.6) ausgewertet und bei der Innovation wird die Schätzung mit der aktuellen Messung korrigiert. Die Schwierigkeit liegt nun in der Berechung der bedingten Wahrscheinlichkeiten, die im Allgemeinen nicht analytisch geschlossen darstellbar sind. Im Falle normalverteilter Signale wird im kommenden Abschnitt das Kalmanfilter als eine mögliche Realisierung beschrieben. Weiterführende Literatur findet sich in [35, 138].

### 3.2.2 Kalmanfilter

Das Kalmanfilter ist nach seinem Erfinder, dem ungarisch-amerikanischen Mathematiker Rudolf Emil Kalman, benannt und wurde 1960 veröffentlicht [66]. Lange Zeit wurde das Filter hauptsächlich in der Luft- und Raumfahrt eingesetzt und fand seinen Höhepunkt beim Apollo-Programm der NASA [94]. Heute wird in vielen Anwendungen das Filter benutzt, um bei fehlerbehafteten Beobachtungen Rückschlüsse auf den wahren Zustand des Systems zu erhalten.

Werden die Wahrscheinlichkeitsdichtefunktionen des Bayesfilters aus Abschnitt 3.2.1 durch die ersten beiden statistischen Momente einer Normalverteilung approximiert, spricht man von einem Gaußfilter. Das Kalmanfilter ist dabei die bekannteste Realisierung eines Gaußfilters. Die multivariate Gaußverteilung ist gegeben durch

$$p(\mathbf{x}) = \frac{1}{(2\pi)^{\frac{N}{2}} |\mathbf{P}|^{\frac{1}{2}}} \exp\left(-\frac{1}{2}(\mathbf{x} - \overline{\mathbf{x}})^T \mathbf{P}^{-1}(\mathbf{x} - \overline{\mathbf{x}})\right)$$
(3.2.7)

mit  $\overline{\mathbf{x}}$  als Erwartungswert und  $|\mathbf{P}|$  als Determinante der Kovarianz. Für linear stochastische Systeme mit gaußverteilten Signalen stellt das Kalmanfilter einen Bayes'schen Minimum-Varianz-Schätzer dar und ist ein Optimalfilter [10].

#### Nomenklatur

Im Rahmen dieser Arbeit wird mit Ausnahme der Indizierung eine Nomenklatur aufbauend auf [10] verwendet. Es werden die diskreten Zeitpunkte  $t_k$  im Sinne einer einfachen Notation verkürzt als Index k der betreffenden Größe geschrieben; beispielsweise beschreibt  $\mathbf{z}_{k-1}$  die Messung zum Zeitpunkt  $t_{k-1}$ . Weiter ist  $Z^{k-1}$  die Menge aller Messungen bis zum Zeitpunkt  $t_{k-1}$ . Für den Wert  $E[\mathbf{x}_k|Z^{k-1}]$ , also den a priori erwarteten Zustand unter Voraussetzung der Messungen  $Z^{k-1}$ , wird abkürzend  $\hat{\mathbf{x}}_{k|k-1}$  geschrieben. Die Transitionsmatrix  $\mathbf{F}_{k,k-1}$  beschreibt den Übergang zwischen den Zeitpunkten  $t_k$  und  $t_{k-1}$ . Der Ausdruck  $\hat{\mathbf{v}}_{k,k_0|k}$  definiert das Prozessrauschen zwischen den Zeitpunkten  $t_k$ und  $t_{k_0}$  unter der Bedingung aller Messungen  $Z^k$ .

### Lineares Kalmanfilter

Ein zeitkontinuierliches, deterministisches und lineares System wird durch Differentialgleichungen im Zeitbereich beschrieben. Die Lösungen dieser Differentialgleichungen ergeben die Prozess- und Messgleichungen des Kalmanfilters [10, 27]. Das Prozessmodell beschreibt dabei die zeitliche Veränderung der Systemzustände vom Zeitpunkt  $t_{k-1}$  zum Zeitpunkt  $t_k$ :

$$\mathbf{x}_k = \mathbf{F}_{k,k-1}\mathbf{x}_{k-1} + \mathbf{B}_k\mathbf{u}_k + \mathbf{v}_k. \tag{3.2.8}$$

Hierbei ist  $\mathbf{F}_{k,k-1}$  die Transitionsmatrix,  $\mathbf{x}_{k-1}$  der Systemzustand,  $\mathbf{B}_k$  die Steuermatrix,  $\mathbf{u}_k$  der Steuervektor und  $\mathbf{v}_k$  das Prozessrauschen. Das Messmodell beschreibt den linearen Zusammenhang zwischen dem Systemzustand  $\mathbf{x}_k$  und dem Messdatum  $\mathbf{z}_k$ :

$$\mathbf{z}_k = \mathbf{H}_k \mathbf{x}_k + \mathbf{w}_k. \tag{3.2.9}$$

Dabei ist  $\mathbf{H}_k$  die Messmatrix und  $\mathbf{w}_k$  das Messrauschen. Es wird angenommen, dass Prozess- und Messrauschen additiv, mittelwertfrei, weiß, normalverteilt und unkorreliert sind. Das Prozessrauschen repräsentiert dabei die Ungenauigkeit des dynamischen Modells mit

$$\mathbf{Q}_k = E[\mathbf{v}_k \mathbf{v}_k^T]. \tag{3.2.10}$$

Das Messrauschen wird durch die Kovarianzmatrix  $\mathbf{R}_k$  beschrieben:

$$\mathbf{R}_k = E[\mathbf{w}_k \mathbf{w}_k^T]. \tag{3.2.11}$$

Das Kalmanfilter führt für diskrete Zeitschritte  $t_k$  eine iterative Schätzung des Systemzustandes  $\mathbf{x}_k$  mit der dazugehörigen Schätzfehlerkovarianz

$$\mathbf{P}_{k|k} = E[(\mathbf{x}_k - \hat{\mathbf{x}}_k)(\mathbf{x}_k - \hat{\mathbf{x}}_k)|Z^k]$$
(3.2.12)

durch. Im Prädiktionsschritt des Kalmanfilters wird die Schätzung des vorherigen Zeitschrittes  $t_{k-1}$  auf den aktuellen Zeitschritt  $t_k$  projiziert. Die Prädiktion des Systemzustandes ergibt:

$$\hat{\mathbf{x}}_{k|k-1} = \mathbf{F}_{k,k-1}\hat{\mathbf{x}}_{k-1|k-1} + \mathbf{B}_k\mathbf{u}_k$$
(3.2.13)

und die Prädiktion der Schätzfehlerkovarianz leitet sich hieraus folgendermaßen ab:

$$\mathbf{P}_{k|k-1} = E[(\mathbf{x}_{k} - \hat{\mathbf{x}}_{k|k-1})(\mathbf{x}_{k} - \hat{\mathbf{x}}_{k|k-1})^{T}] \\
= E[(\mathbf{F}_{k,k-1}(\mathbf{x}_{k-1} - \hat{\mathbf{x}}_{k-1|k-1}) + v_{k})(\mathbf{F}_{k,k-1}(\mathbf{x}_{k-1} - \hat{\mathbf{x}}_{k-1|k-1}) + v_{k})^{T}] \\
= \mathbf{F}_{k,k-1}\mathbf{P}_{k-1|k-1}\mathbf{F}_{k,k-1}^{T} + \mathbf{Q}_{k}.$$
(3.2.14)

Die Systemzustände und Schätzfehlerkovarianzen sind auf einer zeitlichen Achse in Abbildung 3.2 abgebildet.

Die Schätzung des a posteriori Systemzustandes erfolgt durch die gewichtete Addition mit einem Residuumvektor, auch Innovationsvektor genannt:

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k \boldsymbol{\gamma}_k. \tag{3.2.15}$$

Dabei ist  $\hat{\mathbf{x}}_{k|k}$  die Schätzung zum Zeitpunkt  $t_k$  mit integrierter Messung  $\mathbf{z}_k$  und  $\hat{\mathbf{x}}_{k|k-1}$  ist die prädizierte Schätzung mit den bis  $\mathbf{z}_{k-1}$  integrierten Messungen.  $\mathbf{K}_k$  ist die Kalmanverstärkungsmatrix (*engl.* "Kalman Gain") und das Residuum  $\boldsymbol{\gamma}_k$  ist wie folgt definiert:

$$\boldsymbol{\gamma}_k = \mathbf{z}_k - \hat{\mathbf{z}}_{k|k-1} \tag{3.2.16}$$

mit

$$\hat{\mathbf{z}}_{k|k-1} = \mathbf{H}_k \hat{\mathbf{x}}_{k|k-1}.$$
(3.2.17)

Die Kovarianz des Residuums  $\mathbf{S}_k$  erhält man analog zu (3.2.14):

$$\mathbf{S}_k = \mathbf{H}_k \mathbf{P}_{k|k-1} \mathbf{H}_k^T + \mathbf{R}_k. \tag{3.2.18}$$

Aus Gleichung (3.2.15) ergibt sich die Innovation zu:

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k \left[ \mathbf{z}_k - \mathbf{H}_k \hat{\mathbf{x}}_{k|k-1} \right].$$
(3.2.19)

Abbildung 3.2: Zeitachse mit a priori Zustandsschätzungen  $\hat{\mathbf{x}}_{k-1|k-2}, \hat{\mathbf{x}}_{k|k-1}$  und a posteriori Zustandsschätzungen  $\hat{\mathbf{x}}_{k-1|k-1}, \hat{\mathbf{x}}_{k|k}$  sowie zugehörigen Schätzfehlerkovarianzen.

Die Aktualisierung der Schätzfehlerkovarianz auf den Zeitpunkt  $t_k$  ergibt sich folgendermaßen:

$$\mathbf{P}_{k|k} = E[(\mathbf{x}_{k} - \hat{\mathbf{x}}_{k|k})(\mathbf{x}_{k} - \hat{\mathbf{x}}_{k|k})^{T}]$$
  

$$= E[(\mathbf{x}_{k} - (\hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_{k}(\mathbf{H}_{k}\mathbf{x}_{k} - \mathbf{H}_{k}\hat{\mathbf{x}}_{k|k-1})))(...)^{T}]$$
  

$$= E[((\mathbf{I} - \mathbf{K}_{k}\mathbf{H}_{k})(\mathbf{x}_{k} - \hat{\mathbf{x}}_{k|k-1}))(...)^{T}] + E[(\mathbf{K}_{k}\mathbf{v}_{k})(\mathbf{K}_{k}\mathbf{v}_{k})^{T}]$$
  

$$= (\mathbf{I} - \mathbf{K}_{k}\mathbf{H}_{k})\mathbf{P}_{k|k-1}(\mathbf{I} - \mathbf{K}_{k}\mathbf{H}_{k})^{T} + \mathbf{K}_{k}\mathbf{R}_{k}\mathbf{K}_{k}^{T}.$$
(3.2.20)

Diese Form der Schätzfehlerkovarianz ist laut [10] numerisch besonders stabil und garantiert Symmetrie und positive Definitheit. Sie wird häufig auch als Joseph-Form der Innovation bezeichnet. Um die numerische Genauigkeit weiter zu erhöhen, existieren weitere verschiedene Algorithmen wie die Wurzel-Implementierung [108, 110] oder der Bierman-Thornton-UD-Algorithmus [20].

Die Kalmanverstärkungsmatrix  $\mathbf{K}_k$  aus Gleichung (3.2.19) bestimmt den Einfluss jeder Messgröße auf den Zustandsvektor und entspricht Minimierung des mittleren quadratischen Fehlers der Schätzung. Dies ist äquivalent zur Minimierung der Spur der Schätzfehlerkovarianz  $\mathbf{P}_k$ . Nullsetzen der ersten Ableitung der Schätzfehlerkovarianz liefert als notwendige Bedingung für ein Minimum die Definition der Kalman-Verstärkungsmatrix:

$$\mathbf{K}_k = \mathbf{P}_{k|k-1} \mathbf{H}_k^T \mathbf{S}_k^{-1}. \tag{3.2.21}$$

Hieraus ergibt sich unter Verwendung der Joseph-Form eine weitere mögliche Aktualisierung der Schätzfehlerkovarianz, die häufig statt der Joseph-Form verwendet wird:

$$\mathbf{P}_{k|k} = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_{k|k-1}.$$
(3.2.22)

Aus den letzten beiden Gleichungen erhält man eine äquivalente symmetrische Schreibweise wie folgt:

$$\mathbf{P}_{k|k} = \mathbf{P}_{k|k-1} - \mathbf{K}_k \mathbf{S}_k \mathbf{K}_k^T.$$
(3.2.23)

Dies vervollständigt die Gleichungen des linearen Kalmanfilters, die zur Verdeutlichung noch einmal in Abbildung 3.3 zusammengefasst sind.



Abbildung 3.3: Ablaufdiagramm des linearen Kalmanfilters in seiner Prädiktor-Korrektur-Struktur [138, S. 24]. Im Prädiktionsschritt wird der Zustand  $\hat{\mathbf{x}}_{k|k-1}$  sowie die Schätzfehlerkovarianz  $\mathbf{P}_{k|k-1}$  zum nächsten Zeitschritt projiziert und im Innovationsschritt mit der Messung  $\mathbf{z}_k$  aktualisiert.

### 3.2.3 Informationsfilter

Beim inversen Kovarianzfilter oder Informationsfilter wird die Inverse der Schätzfehlerkovarianz  $\mathbf{P}_{k|k}$  benutzt. Im Gegensatz zum Kalmanfilter, bei dem  $\mathbf{P}_{k|k}$  die Unsicherheit repräsentiert, beschreibt die Informationsmatrix den Informationsgehalt der Schätzung. Sie wird wie folgt definiert:

$$\mathcal{I}_{k|k} = \mathbf{P}_{k|k}^{-1}.\tag{3.2.24}$$

Im Grenzfall  $\mathbf{P}_{k|k} \to 0$  ( $\mathcal{I}_{k|k} \to \infty$ ) ist die Schätzung exakt und bei  $\mathbf{P}_{k|k} \to \infty$ ( $\mathcal{I}_{k|k} \to 0$ ) gibt es keine Informationen über die Systemzustände. Gleichung (3.2.18) in Gleichung (3.2.21) eingesetzt und das Ergebnis wiederum in Gleichung (3.2.22) eingesetzt ergibt die Innovation der Schätzfehlerkovarianz:

$$\mathbf{P}_{k|k} = \mathbf{P}_{k|k-1} - \mathbf{P}_{k|k-1}\mathbf{H}_{k}^{T} \left(\mathbf{H}_{k}\mathbf{P}_{k|k-1}\mathbf{H}_{k}^{T} + \mathbf{R}_{k}\right)^{-1}\mathbf{H}_{k}\mathbf{P}_{k|k-1}.$$
(3.2.25)

Mit der Woodbury-Matrix-Identität [10, S. 23]:

$$\mathbf{A}^{-1} - \mathbf{A}^{-1}\mathbf{B} \left(\mathbf{B}^T \mathbf{A}^{-1} \mathbf{B} + \mathbf{C}^{-1}\right)^{-1} \mathbf{B}^T \mathbf{A}^{-1} = \left(\mathbf{A} + \mathbf{B} \mathbf{C} \mathbf{B}^T\right)^{-1}$$
(3.2.26)

wird aus Gleichung (3.2.25):

$$\mathbf{P}_{k|k}^{-1} = \mathbf{P}_{k|k-1}^{-1} + \mathbf{H}_{k}^{T} \mathbf{R}_{k}^{-1} \mathbf{H}_{k}.$$
(3.2.27)

Die Innovation der Schätzfehlerkovarianz wird in Notation des Informationsfilters wie folgt geschrieben:

$$\mathcal{I}_{k|k} = \mathcal{I}_{k|k-1} + \mathbf{H}_k^T \mathbf{R}_k^{-1} \mathbf{H}_k.$$
(3.2.28)

Eine ausführliche Herleitung der Filtergleichungen findet sich in [10, 122]. Eine wichtige Eigenschaft von Informationsfiltern ist deren Additivität:

$$\mathcal{I}_{a,b} = \mathcal{I}_a + \mathcal{I}_b. \tag{3.2.29}$$

Diese Eigenschaft und die Gleichungen des Informationsfilters werden zur Berechung der äquivalenten Messung in Kapitel 4.3.2 und zur Berechnung des FPFD-Algorithmus in Kapitel 4.4 benötigt. Weiterführende Literatur zum Informationsfilter findet sich in [2, 23].

# 3.3 Modellierung der Zustandsschätzung

Dieser Abschnitt beschreibt die konkrete Realisierung der Zustandsschätzung für das in dieser Arbeit entwickelte Pre-Crash-System. Es wird ein lineares Kalmanfilter für die Zustandsschätzung mit verzerrungsfreier Messvektorkonvertierung und Einpunktinitialisierung verwendet, sowie ein kontinuierliches mittelwertfreies weißes Prozessrauschmodell und eine JPDA-Datenassoziation benutzt.

### 3.3.1 Prozessmodell

Das Modell für konstante Geschwindigkeit ist ein einfaches und häufig benutztes Prozessmodell. In diesem Modell zweiter Ordnung wird davon ausgegangen, dass keine Beschleunigungen auftreten. Der Zustandsvektor setzt sich wie folgt zusammen:

$$\mathbf{x} = \begin{bmatrix} \xi & \eta & \dot{\xi} & \dot{\eta} \end{bmatrix}^T. \tag{3.3.1}$$

Dabei sind  $\xi$  und  $\eta$  die kartesischen Positionen und  $\dot{\xi}$  und  $\dot{\eta}$  die dazugehörigen Geschwindigkeitskomponenten. Die Fehler, die durch eine Beschleunigung des Objektes verursacht werden können, müssen im Prozessrauschen modelliert werden. Des Weiteren wird in dieser Arbeit zur Evaluierung des Pre-Crash-Systems neben dem Modell für konstante Geschwindigkeit noch das Modell für konstante Beschleunigung, ein Modell dritter Ordnung, verwendet [4].

Ein zeitkontinuierliches lineares System, wie in Abbildung 3.4 schematisch dargestellt, wird in Zustandsraumdarstellung nach [122] folgendermaßen beschrieben:

$$\dot{\mathbf{x}} = \mathbf{A}\mathbf{x} + \mathbf{B}\mathbf{u},$$
  
$$\mathbf{y} = \mathbf{C}\mathbf{x}.$$
(3.3.2)

Dabei ist  $\mathbf{x}$  der Zustandsvektor,  $\mathbf{u}$  der Steuervektor und  $\mathbf{y}$  der Ausgangsvektor.  $\mathbf{A}$  ist die Systemmatrix,  $\mathbf{B}$  wird als Eingangsmatrix und  $\mathbf{C}$  als Ausgangsmatrix bezeichnet.

Unter der Annahme, dass die Matrizen **A**, **B** und **C** konstant sind, ergeben sich folgende Gleichungen als Lösung der Differenzialgleichung:

$$\mathbf{x}(t) = e^{\mathbf{A}(t-t_0)}\mathbf{x}(t_0) + \int_{t_0}^t e^{\mathbf{A}(t-\tau)}\mathbf{B}\mathbf{u}(\tau)d\tau,$$
  
$$\mathbf{y}(t) = \mathbf{C}\mathbf{x}(t),$$
  
(3.3.3)



Abbildung 3.4: Signalflussplan eines zeitkontinuierlich-linearen Systems. Die Übertragungsfunktion des kontinuierlichen zeitinvarianten Zustandsraum-Modells wird dabei mit der Laplace-Transformation beschrieben.

mit dem Anfangszeitpunkt  $t_0$ . In dieser Arbeit wird der Steuervektor nicht verwendet, da keine deterministischen Eingangsgrößen modelliert werden. Die Differentialgleichung im Zustandsraum für ein Modell konstanter Geschwindigkeit ohne Steuervektor lautet demnach:

$$\begin{bmatrix} \dot{\xi} \\ \dot{\eta} \\ \ddot{\xi} \\ \ddot{\eta} \end{bmatrix} = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} \xi \\ \eta \\ \dot{\xi} \\ \dot{\eta} \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ v_{\xi} \\ v_{\eta} \end{bmatrix}.$$
(3.3.4)

Dabei repräsentieren  $v_{\xi}$  und  $v_{\eta}$  ein kontinuierliches weißes gaußsches Beschleunigungsrauschen. Ohne Steuervektor ergibt sich folgende vereinfachte Lösung der Differentialgleichung:

$$\mathbf{x}(t) = e^{\mathbf{A}(t-t_0)} \mathbf{x}(t_0). \tag{3.3.5}$$

Zur Diskretisierung werden zwei Zeitpunkte  $t_k$  und  $t_{k-1}$  betrachtet mit

$$\mathbf{x}(t_k) = e^{\mathbf{A}(t_k - t_0)} \mathbf{x}(t_0),$$
  
$$\mathbf{x}(t_{k-1}) = e^{\mathbf{A}(t_{k-1} - t_0)} \mathbf{x}(t_0).$$
 (3.3.6)

Hieraus ergibt sich durch Einsetzen folgende Diskretisierung:

$$\mathbf{x}(t_k) = e^{\mathbf{A}(t_k - t_0)} e^{-\mathbf{A}(t_{k-1} - t_0)} \mathbf{x}(t_{k-1}) = e^{\mathbf{A}(t_k - t_{k-1})} \mathbf{x}(t_{k-1})$$
(3.3.7)

und daher mit einem Abtastintervall  $\Delta t = t_k - t_{k-1}$ :

$$\mathbf{x}(t_k) = e^{\mathbf{A}\Delta t} \mathbf{x}(t_{k-1}) =: \mathbf{F}(\Delta t) \mathbf{x}(t_{k-1}).$$
(3.3.8)

Die Transitionsmatrix  $\mathbf{F}_k$  kann durch eine Taylorreihenentwicklung beschrieben werden:

$$\mathbf{F}_{k} := \mathbf{F}(\Delta t) = e^{\mathbf{A}\Delta t} = \mathbf{I} + \mathbf{A}\Delta t + \frac{(\mathbf{A}\Delta t)^{2}}{2!} + \dots + \frac{(\mathbf{A}\Delta t)^{n}}{n!} + \dots$$
(3.3.9)

Die Systemmatrix **A** aus Gleichung (3.3.4) beschreibt ein Prozessmodell für konstante Geschwindigkeiten. Da alle Terme mit dem Faktor  $\mathbf{A}^2$  aus Gleichung (3.3.9) Null ergeben, folgt für die diskrete Transitionsmatrix:

$$\mathbf{F}_{k} = \mathbf{I} + \mathbf{A}\Delta t = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} + \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} \Delta t = \begin{bmatrix} 1 & 0 & \Delta t & 0 \\ 0 & 1 & 0 & \Delta t \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}.$$
 (3.3.10)

Das Modellrauschen hat allgemein die Form:

$$\mathbf{Q} = E[\mathbf{v}\mathbf{v}^T]. \tag{3.3.11}$$

Unter der Annahme  $v_{\xi} = v_{\eta}$  kann für ein zeitkontinuierliches weißes Prozessrauschen **v** die Kovarianz **Q** wie folgt modelliert werden:

 $\operatorname{mit}$ 

$$q = E[v_{\xi}^2] = E[v_{\eta}^2]. \tag{3.3.13}$$

Das Prozessrauschen q ist hier ein skalarer Wert und modelliert Modellfehler durch Beschleunigungs- oder Bremsvorgänge. Durch Diskretisierung des kontinuierlichen Modells erhält man:

$$\mathbf{Q}_{k} = \int_{0}^{\Delta t} \mathbf{F}(\tau) \mathbf{Q} \mathbf{F}(\tau)^{T} d\tau = \int_{0}^{\Delta t} \begin{bmatrix} \tau^{2} q & 0 & \tau q & 0\\ 0 & \tau^{2} q & 0 & \tau q\\ \tau q & 0 & q & 0\\ 0 & \tau q & 0 & q \end{bmatrix} d\tau.$$
(3.3.14)

Aufgelöst ergibt sich für die Kovarianzmatrix mit einem zeitkontinuierlichen mittelwertfreien weißen Rauschmodell folgende Matrix:

$$\mathbf{Q}_{k} = \begin{bmatrix} \frac{1}{3} (\Delta t)^{3} & 0 & \frac{1}{2} (\Delta t)^{2} & 0\\ 0 & \frac{1}{3} (\Delta t)^{3} & 0 & \frac{1}{2} (\Delta t)^{2}\\ \frac{1}{2} (\Delta t)^{2} & 0 & \Delta t & 0\\ 0 & \frac{1}{2} (\Delta t)^{2} & 0 & \Delta t \end{bmatrix} q.$$
(3.3.15)

Ånderungen in der Geschwindigkeitskomponente innerhalb eines Zeitintervalls  $\Delta t$  sind in der Größenordnung von  $\sqrt{\Delta t \cdot q}$ . Der Wert für q ist ein Designparameter und wird in Abhängigkeit der maximalen Beschleunigungen gewählt. Die Wahl von q stellt einen wichtigen Parameter des Kalmanfilters dar und ist in der Einheit m<sup>2</sup>/s<sup>3</sup>. Eine mögliche Abschätzung von q in Abhängigkeit der Periodendauer  $\Delta t$  ist in [10, S. 272] gegeben:

$$q \approx \sigma_a^2 \Delta t. \tag{3.3.16}$$

Dabei beschreibt  $\sigma_a$  die Abweichungen in der Geschwindigkeit, die in der Größenordnung der maximalen Beschleunigung liegen. In einer praktischen Realisierung wird diese durch Feldversuche ermittelt [26] und das  $3\sigma$ -Intervall wird häufig zwischen 6 und  $9 \text{ m/s}^2$ gewählt. Bei Sportwagen werden maximale Verzögerungswerte von  $11 \text{ m/s}^2$  erreicht.

### 3.3.2 Messmodell

In den meisten Anwendungen von Filter- und Schätzverfahren werden kartesische Koordinaten verwendet, siehe Gleichung (3.3.1). Die Messdaten der Radarsensoren liegen jedoch in Polarkoordinaten wie folgt vor:

$$\mathbf{z} = \begin{bmatrix} r\\ \varphi\\ \dot{r} \end{bmatrix} \quad \text{bzw.} \quad \mathbf{R} = \begin{bmatrix} \sigma_r^2 & 0 & 0\\ 0 & \sigma_\varphi^2 & 0\\ 0 & 0 & \sigma_{\dot{r}}^2 \end{bmatrix}$$
(3.3.17)

mit radialer Entfernung r, Winkel  $\varphi$  und Doppler-Geschwindigkeit  $\dot{r}$ . Abbildung 3.5 veranschaulicht das kartesische Fahrzeugkoordinatensystem und das Messprinzip der Radarsensoren in polaren Koordinaten.



Abbildung 3.5: Definition des Fahrzeugkoordinatensystems mit den Koordinaten  $\xi$ ,  $\eta$  und dem polaren Messprinzip der Radarsensoren in r,  $\varphi$ .

Zur Handhabung dieser unterschiedlichen Koordinatensysteme gibt es im Wesentlichen zwei Modellierungen. Das erste Modell arbeitet ohne eine Koordinatentransformation direkt in Polarkoordinaten mit einem erweiterten Kalmanfilter. Das nichtlineare Messmodell wird dabei durch die Jacobimatrix linearisiert und die Messdaten des Sensors können in Polarkoordinaten verwendet werden.

Um direkt mit dem linearen Kalmanfilter arbeiten zu können, wurde in der vorliegenden Arbeit eine Konvertierung von Polarkoordinaten in kartesische Koordinaten vorgenommen, die sogenannte klassische Konvertierung (siehe [22]). Die Komponenten der Messfehlerkovarianz ergeben sich dabei aus der Darstellung

$$r = \hat{r} + w_r, \tag{3.3.18}$$

$$\varphi = \hat{\varphi} + w_{\varphi} \tag{3.3.19}$$

der Messdaten  $r, \varphi$  als Summe der Erwartungswerte  $\hat{r}, \hat{\varphi}$  und der Messfehler  $w_r, w_{\varphi}$ . Die Transformation in kartesische Koordinaten erfolgt mittels

$$\xi = \hat{\xi} + w_{\xi} = (\hat{r} + w_r) \cos(\hat{\varphi} + w_{\varphi}), \qquad (3.3.20)$$

$$\eta = \hat{\eta} + w_{\eta} = (\hat{r} + w_{r})\sin(\hat{\varphi} + w_{\varphi}).$$
(3.3.21)

Hieraus folgt für die Messfehler in kartesischen Koordinaten mit den Additionstheoremen für trigonometrische Funktionen

$$w_{\xi} = \hat{r}\cos\hat{\varphi}(\cos w_{\varphi} - 1) - \hat{r}\sin\hat{\varphi}\sin w_{\varphi} + w_{r}\cos\hat{\varphi}\cos w_{\varphi} - w_{r}\sin\hat{\varphi}\sin w_{\varphi}, \quad (3.3.22)$$

$$w_{\eta} = \hat{r}\sin\hat{\varphi}(\cos w_{\varphi} - 1) + \hat{r}\cos\hat{\varphi}\sin w_{\varphi} + w_{r}\cos\hat{\varphi}\sin w_{\varphi} + w_{r}\sin\hat{\varphi}\cos w_{\varphi}.$$
 (3.3.23)

Ein Nachteil der Konvertierung ist, dass die Messfehler korreliert sind und von den Erwartungswerten abhängen. Unter der Annahme kleiner Winkelfehler und mit Approximation der Erwartungswerte durch die Messwerte ergibt sich insgesamt

$$\mathbf{z} = \begin{bmatrix} \xi \\ \eta \end{bmatrix} = \begin{bmatrix} r \cos \varphi \\ r \sin \varphi \end{bmatrix} \quad \text{und} \quad \mathbf{R} = \begin{bmatrix} \sigma_{\xi}^2 & \sigma_{\xi\eta}^2 \\ \sigma_{\eta\xi}^2 & \sigma_{\eta}^2 \end{bmatrix}$$
(3.3.24)

mit den Komponenten der Messfehlerkovarianz:

$$\sigma_{\xi}^2 = \sigma_r^2 \cos^2(\varphi) + r^2 \sin^2(\varphi) \sigma_{\varphi}^2, \qquad (3.3.25)$$

$$\sigma_{\eta}^2 = \sigma_r^2 \sin^2(\varphi) + r^2 \cos^2(\varphi) \sigma_{\varphi}^2, \qquad (3.3.26)$$

$$\sigma_{\xi\eta}^2 = \frac{1}{2}\sin(2\varphi)(\sigma_r^2 - r^2\sigma_{\varphi}^2), \qquad (3.3.27)$$

$$\sigma_{\eta\xi}^2 = \sigma_{\xi\eta}^2. \tag{3.3.28}$$

Die Messmatrix des linearen Kalman-Filters lautet bei diesem Messmodell damit wie folgt:

$$\mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}.$$
 (3.3.29)

Bei der hier beschriebenen Konvertierung wird also auf die Doppler-Information verzichtet, um das lineare Kalmanfilter benutzen zu können. Die Doppler-Geschwindigkeit wird aber bei der Initialisierung der Objektzustände verwendet (siehe Abschnit 3.4). In [78] wird gezeigt, dass durch diese Konvertierung Verzerrungen bei großem Winkelfehler  $\sigma_{\varphi}^2$ entstehen. Um diese Verzerrungen zu vermeiden wird in [80] eine verzerrungsfreie Konvertierung (*engl.* "Unbiased Converted Measurements") vorgeschlagen. Die klassische Konvertierung hat sich in dieser Arbeit jedoch als hinreichend genau erwiesen.

# 3.4 Filterinitialisierung

Die Initialisierung eines Systemzustandes ist ein wichtiger Aspekt der Objektverfolgung. Eine korrekte Initialisierung gewährleistet, dass die Einschwingphasen nur wenige Filterzyklen lang sind und das Filter dabei konsistent ist. Im Gegensatz zur Zwei-Punkt-Initialisierung [10] wird bei der Ein-Punkt-Initialisierung nur ein einziger Messwert für das Setzen des ersten Wertes benutzt. Bei dem in dieser Arbeit vorgestellten Sensoraufbau kann die Zwei-Punkt-Initialisierung aufgrund der Asynchronität der Sensoren nicht verwendet werden: Zwei Messungen in kurzer zeitlicher Reihenfolge könnten durch das Messrauschen sehr große initiale Objektgeschwindigkeiten verursachen. Daher wird in dieser Arbeit eine Ein-Punkt-Initialisierung verwendet. Gegeben ist ein initiales Messdatum wie folgt:

$$\mathbf{z_0} = \begin{bmatrix} r_0 \\ \varphi_0 \\ \dot{r}_0 \end{bmatrix} \quad \text{bzw.} \quad \mathbf{R_0} = \begin{bmatrix} \sigma_{r_0}^2 & 0 & 0 \\ 0 & \sigma_{\varphi_0}^2 & 0 \\ 0 & 0 & \sigma_{\dot{r}_0}^2 \end{bmatrix}.$$
(3.4.1)

Gegeben ist außerdem die a-priori Schätzfehlerkovarianz  $\mathbf{P}_{\dot{\xi},\dot{\eta}}^{-}(0)$  der Geschwindigkeiten in kartesischen Koordinaten:

$$\mathbf{P}_{\dot{\xi},\dot{\eta}}^{-}(0) = \begin{bmatrix} \sigma_s^2 & 0\\ 0 & \sigma_s^2 \end{bmatrix}.$$
(3.4.2)

Dabei modelliert  $\sigma_s^2$  die maximal auftretende Geschwindigkeit im kartesischen Zustandsraum. Gesucht sind der initiale Zustandsvektor und die dazugehörige Schätzfehlerkovarianz:

$$\mathbf{x}_{0|0} = \begin{bmatrix} \xi_0 \\ \eta_0 \\ \dot{\xi}_0 \\ \dot{\eta}_0 \end{bmatrix} \quad \text{bzw.} \quad \mathbf{P}_{0|0} = \begin{bmatrix} \mathbf{P}_{\xi,\eta}(0) & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & \mathbf{P}_{\dot{\xi},\dot{\eta}}(0) \end{bmatrix}.$$
(3.4.3)

Im Folgenden wird eine Ein-Punkt-Initialisierung sowohl für den Zustandsvektor als auch für die Schätzfehlerkovarianz unter Verwendung der Doppler-Geschwindigkeit beschrieben.

#### Initialisierung des Zustandsvektors

Die initialen Positionskomponenten des Zustandvektors werden wie bei dem Messmodel durch Transformation von kartesische in polare Koordinaten berechnet:

$$\begin{bmatrix} \xi_0 \\ \eta_0 \end{bmatrix} = \begin{bmatrix} r_0 \cos \varphi_0 \\ r_0 \sin \varphi_0 \end{bmatrix}.$$
(3.4.4)

Für die initialen Geschwindigkeitskomponenten des Zustandsvektors soll die gemessene Doppler-Geschwindigkeit verwendet werden. Dabei bildet die Messmatrix

$$\mathbf{H}_{\dot{\xi}\dot{\eta}} = \begin{bmatrix} \cos(\varphi) & \sin(\varphi) \end{bmatrix}$$
(3.4.5)

die Geschwindigkeit des kartesischen Koordinatensystems in eine radiale Geschwindigkeit ab. Die Berechnung des initialen Filterzustandes für die Geschwindigkeiten entspricht der Innovation eines Kalmanfilters:

$$\begin{bmatrix} \dot{\xi}_0 \\ \dot{\eta}_0 \end{bmatrix} = \mathbf{P}_{\dot{\xi},\dot{\eta}}^{-} \mathbf{H}_{\dot{\xi}\dot{\eta}}^{T} (\mathbf{H}_{\dot{\xi}\dot{\eta}} \mathbf{P}_{\dot{\xi},\dot{\eta}}^{-} \mathbf{H}_{\dot{\xi}\dot{\eta}}^{T} + \mathbf{R}_{\dot{r}})^{-1} \dot{r}_0$$
$$= \frac{\sigma_s^2}{\sigma_s^2 + \sigma_{\dot{r}}^2} \begin{bmatrix} \cos\varphi \\ \sin\varphi \end{bmatrix} \dot{r}_0. \tag{3.4.6}$$

Dabei ist  $\dot{r}_0$  die gemessene Doppler-Geschwindigkeit mit Varianz  $\mathbf{R}_{\dot{r}_0} = \left[\sigma_{\dot{r}_0}^2\right]$ .

#### Initialisierung der Schätzfehlerkovarianz

Die Kovarianzen der Positionen  $(\xi, \eta)$  werden, wie in Abschnitt 3.3.2 hergeleitet wurde, angegeben mit:

$$\mathbf{P}_{\xi,\eta}(0) = \begin{bmatrix} \sigma_{r_0}^2 \cos^2(\varphi_0) + r_0^2 \sin^2(\varphi_0) \sigma_{\varphi_0}^2 & \frac{1}{2} \sin^2(2\varphi_0) \left(\sigma_{r_0}^2 - r_0^2 \sigma_{\varphi_0}^2\right) \\ \frac{1}{2} \sin^2(2\varphi_0) \left(\sigma_{r_0}^2 - r_0^2 \sigma_{\varphi_0}^2\right) & \sigma_{r_0}^2 \sin^2(\varphi_0) + r_0^2 \cos^2(\varphi_0) \sigma_{\varphi_0}^2 \end{bmatrix}.$$
 (3.4.7)

Dabei sind  $r_0$ ,  $\varphi_0$  und  $\dot{r}_0$  die initialen Sensordaten. Unter Berücksichtigung der Doppler-Geschwindigkeit berechnen sich die Kovarianzen in  $(\dot{\xi}, \dot{\eta})$  durch Integration der Doppler-Geschwindigkeit als Messung wie folgt:

$$\mathbf{P}_{\dot{\xi},\dot{\eta}}(0) = \mathbf{P}_{\dot{\xi},\dot{\eta}}^{-} - \mathbf{P}_{\dot{\xi},\dot{\eta}}^{-} \mathbf{H}_{\dot{\xi}\dot{\eta}}^{T} (\mathbf{H}_{\dot{\xi}\dot{\eta}} \mathbf{P}_{\dot{\xi},\dot{\eta}}^{-} \mathbf{H}_{\dot{\xi}\dot{\eta}}^{T} + \mathbf{R}_{\dot{r}})^{-1} \mathbf{H}_{\dot{\xi}\dot{\eta}} \mathbf{P}_{\dot{\xi},\dot{\eta}}^{-} \\ = \sigma_{s}^{2} \begin{bmatrix} 1 - \frac{\sigma_{s}^{2}}{\sigma_{s}^{2} + \sigma_{\dot{r}_{0}}^{2}} \cos^{2}(\varphi_{0}) & -\frac{\sigma_{s}^{2}}{\sigma_{s}^{2} + \sigma_{\dot{r}_{0}}^{2}} \cos(\varphi_{0}) \sin(\varphi_{0}) \\ -\frac{\sigma_{s}^{2}}{\sigma_{s}^{2} + \sigma_{\dot{r}_{0}}^{2}} \cos(\varphi_{0}) \sin(\varphi_{0}) & 1 - \frac{\sigma_{s}^{2}}{\sigma_{s}^{2} + \sigma_{\dot{r}_{0}}^{2}} \sin^{2}(\varphi_{0}) \end{bmatrix}.$$
(3.4.8)

Dabei stellt Gleichung (3.4.8) die Kalman-Innovation der Schätzfehlerkovarianzmatrix, wie in Gleichung (3.2.22) beschrieben wurde, dar. Durch diesen Ansatz wird die genaue Doppler-Information des Radarsensors ausgenutzt, um die Unsicherheit in radialer Richtung zu verkleinern. Für die dazu orthogonale Varianz wird die maximal auftretende Geschwindigkeit verwendet, da hier keine weiteren Informationen vorliegen. Die Idee der hier vorgestellten Ein-Punktinitialisierung mit der Doppler-Geschwindigkeit findet man in [143], deren Ergebnis zur Schätzfehlerkovarianz jedoch fehlerbehaftet ist.

# 3.5 Datenassoziation

Ein Datenassoziationsverfahren berechnet, welche Messungen welchen Objekten zugeordnet werden. Zur Verringerung von Komplexität und Rechenaufwand wird vor der Assoziation noch ein Suchverfahren durchgeführt, das heißt, die Zuordnungspaare werden auf sinnvolle Kandidaten eingeschränkt (*engl.* "Gating"). Folgende Datenassoziationsverfahren werden in dieser Arbeit betrachtet.

- Nächste-Nachbarn (engl. "Simple Nearest Neighbor", SNN)
- Globale-Nächste-Nachbarn (engl. "Global Nearest Neighbor", GNN)
- Probabilistisch (engl. "Probabilistic Data Association", PDA)
- Gemeinsam-Probabilistisch (engl. "Joint Probabilistic Data Association", JPDA)

### 3.5.1 Aufwandsreduzierung durch Suchbereiche

Suchverfahren werden vor der eigentlichen Datenassoziation zur Komplexitätsreduktion angewendet. Um jedes prädizierte Objekt wird ein Suchbereich (Assoziationstor, *engl.* "Gate") gelegt, auf das sich die Assoziationsverfahren beschränken. Nur Messungen, die in einem solchen Assoziationstor eines Objektes liegen, können diesem auch zugeordnet werden. Hierzu wird die Mahalanobis-Distanz d berechnet:

$$d^{2} = \boldsymbol{\gamma}_{k}^{T} \mathbf{S}_{k}^{-1} \boldsymbol{\gamma}_{k}$$
  
=  $\left(\mathbf{z}_{k} - \mathbf{H}_{k} \mathbf{x}_{k|k-1}\right)^{T} \left(\mathbf{H}_{k} \mathbf{P}_{k|k-1} \mathbf{H}_{k}^{T} + \mathbf{R}_{k}\right)^{-1} \left(\mathbf{z}_{k} - \mathbf{H}_{k} \mathbf{x}_{k|k-1}\right).$  (3.5.1)

Im zweidimensionalen Raum bilden Punkte gleicher Mahalanobis-Distanz eine Ellipse um das prädizierte Objekt, höherdimensional entsprechend ein Ellipsoid. Die Mahalanobis-Distanz entspricht einer Chi-Quadrat-Verteilung mit Freiheitsgrad M, wobei M die Dimension des Messvektors ist:

$$\chi_M^2 = \mathcal{N}_1^2(0,1) + \dots + \mathcal{N}_M^2(0,1). \tag{3.5.2}$$

Die Grenzen der Mahalanobis-Distanz für das Gating können daher je nach geforderten Konfidenzen aus einer Chi-Quadrat-Tabelle abgelesen werden.

### 3.5.2 Verfahren zur Datenassoziation

Datenassoziationsverfahren lassen sich zunächst in Ein-Nachbar-Verfahren und Alle-Nachbarn-Verfahren einteilen. Bei den Ein-Nachbar-Verfahren unterscheidet man das Nächste-Nachbarn-Verfahren vom globalen Nächste-Nachbarn-Verfahren.

Das Nächste-Nachbarn-Datenassoziationsverfahren (SNN) stellt eine 1-zu-1-Beziehung zwischen den Objekten und den Messungen her. Zu jedem Objekt wird die nächstgelegene Messung gesucht und diesem zugeordnet. Eine erneute Zuordnung zu einem anderen Objekt ist anschließend nicht mehr möglich. Als Distanzmaß wird die in Gleichung (3.5.1) vorgestellte Mahalanobis-Distanz gewählt. Zu beachten ist, dass die Assoziation von der Reihenfolge der Zuordnungen abhängt, was möglichst vermieden werden sollte.

Das globale Nächste-Nachbarn-Verfahren (GNN) ähnelt dem SNN, da beide Verfahren eine 1-zu-1-Zuordnung erstellen. Im Unterschied zum SNN wird jedoch beim GNN ein globales Optimierungsproblem gelöst. Das GNN-Verfahren verwendet die folgende modifizierte Mahalanobis-Distanz zur Entscheidung, ob eine Messung j einem Objekt i zugeordnet wird:

$$d_{G_{ij}}^2 = d_{ij}^2 + \ln\left(|\mathbf{S}_{ij}|\right), \qquad (3.5.3)$$

dabei wird  $d_{G_{ij}}^2$  als globale Mahalanobis-Distanz bezeichnet. Der heuristische Zusatzterm führt dazu, dass Schätzungen mit großer Unsicherheit eine vergrößerte globale Mahalanobis-Distanz zu einer Messung erhalten. Somit werden Messungen eher sicheren als unsicheren Schätzungen zugeordnet. Die globale Mahalanobis-Distanz wird dann minimiert, wofür es mehrere mögliche Algorithmen gibt. In dieser Arbeit wurde der Auktionsalgorithmus (*engl.* "Auction Algorithm") verwendet [15]. Dieser iterative Prozess findet unter geeigneter Parametrierung die optimale Gesamtlösung der Zuordnungsproblematik. Einen weiteren Algorithmus zum Lösen gewichteter Zuordnungsprobleme stellt der Kuhn-Munkres-Algorithmus [47] dar.

Neben den Ein-Nachbar-Verfahren gibt es die Alle-Nachbarn-Verfahren, die zu den wahrscheinlichkeitsbasierten Datenassoziationsverfahren gehören. Hierbei können mehrere Messungen mittels einer probabilistischen Gewichtung zu einem einzigen Objekt assoziiert werden. Dies vermindert den Effekt von Falschassoziationen, vergrößert jedoch auch die Komplexität. Auf Alle-Nachbarn-Verfahren wird in Kapitel 5 näher eingegangen, wo auch eine Erweiterung der Verfahren bei chronologisch ungeordneten Sensordaten hergeleitet wird.

# 3.6 Objektverwaltung

Die Objektverwaltung (*engl.* "Track Management") enthält die Logik für das Löschen nicht mehr relevanter Objekte und das Erstellen neuer Objekte aus nicht-assoziierten Messungen. Im Fall von OOSM-Algorithmen müssen übliche Objektverwaltungsansätze modifiziert werden.

Die Objektverwaltung ohne Berücksichtigung von OOS-Messungen verläuft in den Stadien gelöscht über detektiert, initialisiert, vorläufig bis zu bestätigt. Da in dieser Arbeit eine Ein-Punkt-Initialisierung verwendet wird, entfällt der Zustand detektiert und ein Objekt geht sofort bei der erstmaligen Entdeckung in den Zustand initialisiert über. Von jedem dieser Zustände aus kann ein Objekt wieder in den Zustand gelöscht übergehen, sofern es nicht mehr detektiert wird.

Bei der Zustandsschätzung mit nicht chronologischen Messungen ergibt sich das Problem, dass Objekte vorschnell gelöscht werden können, obwohl sie durch eine OOS-Messung noch bestätigt werden könnten. Daher wird ein neuer Zustand mit dem Namen *OOSM* eingeführt. Dieser ist ein Zwischenzustand und erlaubt eine Wiederherstellung von Objekten mit OOS-Messungen, bevor diese in den nächsten Zustand übergehen oder bevor diese endgültig gelöscht werden. Somit wird verhindert, dass Objekte frühzeitig gelöscht werden, obwohl noch



**Abbildung 3.6:** Zustandsautomat zur Objektverwaltung mit OOSM.

eine Innovation mit einer älteren Messung stattfinden kann. In Abbildung 3.6 werden die Zustandsübergänge graphisch dargestellt. Die Beschriftung der Pfeile beschreibt dabei, aus welchem Zustand ein Objekt kommen muss. Beispielsweise kann ein Objekt nur vom Zustand *OOSM* in den Zustand *bestätigt* wechseln, wenn es vorher schon *vorläufig* oder *bestätigt* war, was durch die Beschriftung [V,B] verdeutlicht wird.

Weiterführende Literatur findet sich in [22]. Ein erweitertes Verfahren, das die gleichzeitige Behandlung von Assoziations- und Existenzunsicherheiten berücksichtigt, wird in [82] beschrieben.

# 3.7 Kapitelzusammenfassung

In diesem Kapitel wurden die grundlegenden Algorithmen und stochastischen Signalverarbeitungsmethoden zur Fahrzeugumfelderfassung beschrieben, auf denen die weiteren Algorithmen aufbauen. In Abschnitt 3.1 wurden verschiedene Fusionsmethoden beschrieben und die in dieser Arbeit verwendete Fusionsarchitektur vorgestellt. In Abschnitt 3.2 wurde auf die verwendeten Filtertechniken eingegangen, wobei auch Herleitungen und Erläuterungen einbezogen wurden, die in den folgenden aufbauenden Algorithmen verwendet werden. Die konkrete Modellierung des Prozesses und der Messungen wurde in Abschnitt 3.3 beschrieben. Weiter wurde auf die Filterinitialisierung und Objektverwaltung der verwendeten Architektur eingegangen. Außerdem wurden verschiedene Möglichkeiten zur Datenassoziation gegenübergestellt.

Der Überblick über die Filterverfahren stellt die Grundlage der nachfolgenden Algorithmen dar. Im nun folgendene Kapitel 4 wird die Zustandsschätzung aus Abschnitt 3.2 für die Integration von chronologisch ungeordneten Sensordaten erweitert. Im nachgelagerten Kapitel 5 werden die Assoziationsverfahren aus Abschnitt 3.5 erweitert, so dass sie auch bei OOS-Messungen angewandt werden können. 4

# Verfahren zur Integration chronologisch ungeordneter Sensordaten

Um die Genauigkeit verwendeter Filter- und Schätzverfahren zu erhöhen, werden in der Praxis häufig die Messungen mehrerer Sensoren fusioniert. Daraus ergibt sich jedoch das Problem unterschiedlicher Latenz- und Zykluszeiten einzelner Sensoren. Dies führt dazu, dass Messungen die Fusionseinheit außerhalb der zeitlichen Reihenfolge erreichen. Solche Out-of-Sequence-Messungen (OOSM) sind insbesondere darum kritisch, weil sie ein direktes Anwenden des linearen Kalmanfilters unmöglich machen.

Die naheliegendste Lösung dieses Problems wäre es, die außerhalb der Reihenfolge ankommenden Sensordaten zu ignorieren und nur zeitlich chronologische Messungen zu integrieren. Dies hätte bei den hier verwendeten Sensoren jedoch zur Folge, dass Messungen des Mehrmodusradars generell nicht berücksichtigt, sondern nur Messungen der beiden Nahbereichsradare zur Zustandsschätzung beitragen würden. Diese Möglichkeit wurde daher in der vorliegenden Arbeit nicht weiter verfolgt.

Out-of-Sequence-Probleme lassen sich in zwei Kategorien unterteilen. Zum einen gibt es sogenannte Ein-Schritt-Probleme, bei denen die OOS-Messung zwischen dem aktuellen und dem letzten Innovationsschritt liegt und somit eine Messung höchstens einen Zeit-schritt verzögert eintrifft. Im Fall einer um mehr als einen Innovationsschritt verzögerten Messung spricht man von einem Mehr-Schritt-Problem.

Zur Behandlung des Einschrittproblems werden in der vorliegenden Arbeit vier verschiedene Verfahren vorgestellt und analysiert. Die am häufigsten verwendete Methode ist die Messdatenverzögerung (engl. "Buffering"), bei dem Messdaten erst dann integriert werden, wenn von allen Sensoren Messungen vorliegen. Dies hat den Nachteil, dass zusätzliche Latenzen entstehen und die Unsicherheit vergrößert wird, was in zeitkritischen Anwendungen möglichst zu vermeiden ist. Die zweite Möglichkeit ist die sogenannte *Reprozessierung*, die das aufwändigste, aber auch genaueste Verfahren darstellt. Hierbei wird beim Eintreffen einer OOS-Messung die aktuelle Zustandsschätzung verworfen und sämtliche Messungen nach der OOS-Messung werden neu integriert. Aufgrund der hohen Genauigkeit der Reprozessierung wird diese in der vorliegenden Arbeit als Referenzalgorithmus verwendet. Speicherbegrenzungen und Echtzeitanforderungen machen jedoch ein Anwenden der Reprozessierung in der Praxis häufig unmöglich. Als Alternativen werden zwei Algorithmen zur direkten Integration der zeitlich verzögerten Messungen in die Zustandsschätzung untersucht, *Retrodiktion* und *Vorwärts-Prädiktion Fusion und Dekorrelation (FPFD)*, die in diesem Kapitel näher beschrieben werden.

Die in dieser Arbeit vorgestellte Retrodiktion basiert auf [5] und wurde für das Ein-Schritt-OOSM-Problem entwickelt. Der Ansatz ist eine Erweiterung des suboptimalen Algorithmus aus [56] und wurde außerdem in [6] veröffentlicht. Die Anwendung der Algorithmen auf den Automobilbereich wird jedoch erstmalig im Rahmen dieser Arbeit untersucht.

Der zweite in dieser Arbeit untersuchte Algorithmus zur Lösung des OOSM-Problems wurde erstmals in [77] vorgestellt. Der Name des Algorithmus lautet Zwei-Schritt-Methode (*engl.* "Two-Step Method"), nicht zu verwechseln mit dem Ein-Schritt- oder Mehr-Schritt-Problem. Bekannt wurde die Methode erst, als kanadische Wissenschaftler den Algorithmus unter dem Namen "Vorwärts-Prädiktion Fusion und Dekorrelation" (*engl.* "Forward-Prediction Fusion and Decorrelation", FPFD) veröffentlichten [114]. Eine ausführlichere Version in Form eines wissenschaftlichen Berichtes findet sich in [113].

Ein etwas komplizierteres Problem stellt das Mehr-Schritt-Problem dar, bei dem eine Messung mehrere Integrationszeitpunkte verzögert eintrifft. Erste Verfahren zur Integration von OOS-Messungen für Mehr-Schritt-Probleme wurden in [104] und [144] vorgestellt. Diese Algorithmen benötigen jedoch mehrere Signalverarbeitungsschritte, um die OOS-Messung zu integrieren. Eine Ein-Schritt-Lösung für das Mehr-Schritt-OOSM-Problem wurde erstmals in [11] und in [9] vorgestellt und zeitgleich auch in [32] beschrieben. Die Idee besteht darin, das Mehr-Schritt-Problem auf ein Ein-Schritt-Problem zurückzuführen, indem eine sogenannte äquivalente Messung berechnet wird.

Zusätzlich zu den hier untersuchten Algorithmen zur Behandlung von Out-of-Sequence-Messungen gibt es eine Reihe weiterer Ansätze, die im Folgenden kurz erläutert werden.

Ein weiteres in der Literatur bekanntes Verfahren ist der Mehr-Schritt-Algorithmus aus [88, 89]. In [77] wurde jedoch gezeigt, dass dieses Verfahren bereits aufwändiger ist als Reprozessierung. Daher wird das Mehr-Schritt-Verfahren in dieser Arbeit nicht betrachtet.

Ein verwandter Ansatz, bei dem bereits integrierte Messungen aus Objekten entfernt werden können, wird in [8] beschrieben. In [24, 93] wurde ein Filter aus mehreren separaten Einzelfiltern für verschiedene Prozessmodelle, ein sogenanntes "Interacting Multiple Model"(IMM), vorgestellt, das in [7] für OOSM-Algorithmen erweitert wurde. [87] führte die Objektverfolgung mit mehreren Hypothesen (*engl.* "Multi-Hypothesis Tracking", MHT) in Kombination mit OOSM ein.

In [17, 18] wurden auf nichtlineare Erweiterungen zur Integration chronologisch ungeordneter Sensordaten eingegangen. Ein Vergleich zwischen einem Partikelfilter mit nicht chronologischen Messdaten und einem Kalmanfilter mit OOSM findet sich in [90]. Weitere Betrachtungen hierzu wurden in [88, 106] diskutiert. Eine Objekt-zu-Objekt-Fusion mit OOSM-Algorithmen wurde in [31] behandelt. Im Folgenden werden die wichtigsten vier Methoden zur Integration von Out-of-Sequence-Messungen näher erläutert.

# 4.1 Messdatenverzögerung

Die Verzögerung von Messdaten ist die einfachste Signalverarbeitungsmethode, um OOS-Messungen zu verarbeiten. Der Ansatz wird mit einem Pufferspeicher (*engl.* "Buffer") realisiert und daher wird diese Methode häufig auch als Buffering bezeichnet. Dabei werden die Sensormessdaten in einem Pufferspeicher geschrieben. Erst wenn eine OOS-Messung die Fusionseinheit erreicht, werden die Daten aus dem Speicher in zeitlich richtiger Reihenfolge in das Standard-Kalmanfilter integriert. Bei asynchronen Sensoren gibt es zwei Ansätze, einen Pufferspeicher zu realisieren, den sogenannten deterministischen und den nicht-deterministischen Ansatz.

Bei einem nicht-deterministischen Ansatz sind weder Informationen über den nächsten Messzeitpunkt noch Wissen über die Zykluszeiten der Sensoren notwendig. Obwohl in dieser Arbeit die Sensorlatenzen und die Messfrequenzen bekannt sind, wird der nicht-deterministische Ansatz gewählt. Damit wird ein robusteres System gegen Zeitstempelschwankungen bei der Realisierung im Versuchsfahrzeug erreicht. Beim nichtdeterministischen Pufferspeicher werden nur Daten in die Zustandsschätzung integriert, wenn von allen zu fusionierenden Sensoren mindestens eine Messung im Puffer gespeichert ist. Nach jeder Integration wird diese Abfrage erneut gestellt und Innovationen durchgeführt, bis von einem Sensor keine Messungen mehr im Pufferspeicher vorhanden sind. Abbildung 4.1 zeigt das Ablaufdiagramm des nicht-deterministischen Pufferspeichers nach [69].



Abbildung 4.1: Ablaufdiagramm des nicht-deterministischen Pufferspeichers.

Im Gegensatz dazu sind beim deterministischen Pufferspeicher die genauen Zykluszeiten bekannt. Hierdurch kann entschieden werden, ob eine OOS-Messung zu erwarten ist; andernfalls können die zwischengespeicherten Messungen früher integriert werden.

Abbildung 4.2 zeigt den zeitlichen Ablauf der realen Messdatenaufnahme bei gleichzeitigem Messbeginn. Die Zykluszeiten und die Latenzen sind der Spezifikation der Radarsensoren aus Kapitel 2 entnommen.



**Abbildung 4.2:** Messdatenverzögerung mit deterministischem (I) und nichtdeterministischem (II) Pufferspeicher zur Integration von chronologisch ungeordneten Sensordaten in der Fusionseinheit. Bei Pufferspeicher I müssen die Zykluszeiten und die Latenzen aller Sensoren bekannt sein, wodurch Messungen früher integriert werden können. Bei Pufferspeicher II sind keine Informationen über den nächsten Messzeitpunkt vorhanden, was zu längeren Latenzen führt.

Zum Zeitpunkt t = 198 ms erreicht die erste OOS-Messung die Fusionseinheit. Diese Messung mit der Nummer (1) ist älter als der aktuelle Systemzustand mit der Messnummer (5). Bei einem deterministischen Pufferspeicher, in Abbildung 4.2 mit Pufferspeicher I bezeichnet, erfolgt nach Eintreffen der Messung (1) die erste Filterinnovation. Dabei werden die OOS-Messung und alle Messungen zwischen dieser und der nächsten OOS-Messung integriert. Dies setzt die Kenntnis über die genaue Zykluszeit voraus. Im Gegensatz hierzu kann eine Messung beim nicht-deterministischen Ansatz, in Abbildung 4.2 mit Pufferspeicher II gekennzeichnet, nur dann integriert werden, wenn von beiden Sensoren mindestens ein Messdatum gespeichert ist. Im konkreten Beispiel kann zum Zeitpunkt t = 198 ms nur eine Messung, nämlich die OOS-Messung, in die Zustandsschätzung integriert werden.

Der Vorteil einer Messdatenverzögerung ist es, dass nur die Gleichungen des Standard-Kalmanfilters benutzt werden. Es werden nur Sensordaten in chronologisch geordneter Reihenfolge integriert und das Problem einer separaten Behandlung von OOS-Messungen wird durch einen Pufferspeicher umgangen. Die Gleichungen des linearen Kalmanfilters sind in Tabelle 4.1 zusammengefasst.



**Tabelle 4.1:** Überblick über die Gleichungen des Standard-Kalmanfilters mit Prädiktions- und Innovationsschritt, die bei Messdatenverzögerung und Reprozessierung verwendet werden.

# 4.2 Reprozessierung

Reprozessierung (*engl.* "Reprocessing" oder "Rollback") stellt die genaueste Methode zur Integration von Messungen außerhalb der zeitlichen Reihenfolge dar. Aus diesem Grund wird in der vorliegenden Arbeit die Reprozessierung als Referenzalgorithmus (*engl.* "Ground Truth") verwendet. Diese Methode wird, wie später gezeigt, jedoch auch die schlechteste Methode bezüglich Speicher- und Laufzeiteffizienz sein. Alle weiteren in dieser Arbeit entwickelten Algorithmen werden mit der Reprozessierung verglichen. Ein OOSM-Algorithmus gilt als optimal, wenn er das gleiche Ergebnis wie die Reprozessierung liefert.

Der Ablauf des Algorithmus ist in Abbildung 4.3 gezeigt. Beim Eintreffen der OOS-Messung nach 198 ms werden alle Systemzustände des Filters auf den Stand vor der OOS-Messung zurückgesetzt. Nachdem die OOS-Messung integriert wurde, werden alle Messungen bis zum aktuellen Zeitpunkt erneut integriert. Dies erfordert die Speicherung von Systemzuständen und Messungen in Abhängigkeit der Schrittweite *l*. Die Schrittweite gibt an, mit welcher maximalen Verzögerung die OOS-Messungen die Fusionseinheit erreichen können. Wie bei der Messdatenverzögerung werden bei einer Reprozessierung der Messungen nur die Gleichungen des Standard-Kalmanfilters aus Tabelle 4.1 benötigt. In den folgenden Abschnitten 4.3 und 4.4 werden zwei erweiterte Methoden zur Integration von OOS-Messungen vorgestellt.



Abbildung 4.3: Reprozessierung vorheriger Sensormessdaten. Bei Eintreffen einer Messung außerhalb der zeitlichen Reihenfolge werden sämtliche Messungen vom Zeitpunkt der OOS-Messung bis zum aktuellen Zeitpunkt wieder neu in die Zustandsschätzung integriert.

# 4.3 Retrodiktion

Das Ziel eines OOSM-Algorithmus ist die direkte Integration einer nicht chronologischen Messung in die Zustandsschätzung. Dabei wird der Aufwand begrenzt und die Innovation der OOS-Messung erfolgt in nur wenigen Signalverarbeitungsschritten. Nur so kann eine effizientere Verarbeitung von OOS-Messungen im Vergleich zur Reprozessierung garantiert werden. Abbildung 4.4 zeigt den Ablauf eines OOSM-Algorithmus. Die Ebene der Fusionseinheit kennzeichnet die Ankunftszeit der Messdaten. Mit einem OOSM-Algorithmus wird erreicht, dass die Reihenfolge in der Verarbeitungskette mit der Reihenfolge der Messungen in der Fusionseinheit identisch ist. Das heißt, jede eintreffende Messung wird direkt verarbeitet, ohne bereits integrierte Messungen erneut aufarbeiten zu müssen.

In diesem Abschnitt werden die zur Integration einer OOS-Messung notwendigen Änderungen des Kalmanfilters vorgestellt. In Kapitel 3.2.2 wurde das Filter durch die zeitliche Veränderung von Systemzuständen eingeführt mit

$$\mathbf{x}_k = \mathbf{F}_{k,k-1}\mathbf{x}_{k-1} + \mathbf{v}_k.$$

Dabei ist  $\mathbf{v}_k$  der Prozessrauschterm mit  $\mathbf{v}_k \sim \mathcal{N}(\mathbf{0}, \mathbf{Q}_k)$ . Durch die Annahme eines mittelwertfreien Rauschens ergibt sich der Erwartungswert der a priori Schätzung zu:

$$\mathbf{\hat{x}}_{k|k-1} = \mathbf{F}_{k,k-1}\mathbf{\hat{x}}_{k-1|k-1}.$$

Somit ist die Prädiktion  $\hat{\mathbf{x}}_{k|k-1}$  der Systemzustände vom Prozessrauschen unabhängig. Im Unterschied dazu ist jedoch der a posteriori Schätzwert  $\hat{\mathbf{x}}_{k|k}$  von der Kovarianz des



Abbildung 4.4: Reihenfolge der direkten Integration aller Sensormessdaten. Beim Eintreffen einer Messung außerhalb der zeitlichen Reihenfolge werden erweiterte OOSM-Algorithmen angewendet.

Prozessrauschens  $\mathbf{Q}_k$  abhänigig. Die Kovarianz des Prozessrauschens  $\mathbf{Q}_k$  beeinflusst die Schätzfehlerkovarianz  $\mathbf{P}_{k|k-1}$  über die Kalman-Verstärkungsmatrix  $\mathbf{K}_k$  und hat so direkten Einfluss auf die Systemzustände, wie folgende Rechnung zeigt:

$$\begin{aligned} \hat{\mathbf{x}}_{k|k} &= \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k \gamma_k \\ &= \hat{\mathbf{x}}_{k|k-1} + \left( \mathbf{P}_{k|k-1} \mathbf{H}_k^T \mathbf{S}_k^{-1} \right) \gamma_k \\ &= \hat{\mathbf{x}}_{k|k-1} + \left( \left( \mathbf{F}_{k,k-1} \mathbf{P}_{k-1|k-1} \mathbf{F}_{k,k-1}^T + \mathbf{Q}_k \right) \mathbf{H}_k^T \mathbf{S}_k^{-1} \right) \gamma_k. \end{aligned}$$
(4.3.1)

Bei einer Prädiktion in die Vergangenheit, einer sogenannten Retrodiktion, wird die a posteriori Schätzung  $\hat{\mathbf{x}}_{k|k}$  verwendet und in die Vergangenheit projiziert. Daher sind die Systemzustände bei einer Retrodiktion mit dem Prozessrauschen korreliert. Auf diese Problematik wird in den folgenden Abschnitten näher eingegangen. Abbildung 4.5 verdeutlicht graphisch den Einfluss der Kovarianz des Prozessrauschens.



Abbildung 4.5: Einfluss des Prozessrauschens auf die Systemzustände durch die Innovation. Die Schätzung des Zustandsvektors ist bei der Prädiktion vom Prozessrauschen unabhängig. Für den a posteriori Zustandsvektor gilt diese Unabhängigkeit nicht mehr.

Die erste Lösung, die zur Integration von chronologisch ungeordneten Messungen vorgestellt wird, heißt Retrodiktion und wird häufig auch als Ein-Schritt-Algorithmus (*engl.*  "One-Step Algorithm") bezeichnet. Beim Eintreffen von Sensormessdaten, die älter als der aktuelle Systemzustand  $\hat{\mathbf{x}}_{k|k}$  und  $\mathbf{P}_{k|k}$  sind, wird bei diesem Verfahren eine Retrodiktion und anschließend eine modifizierte Innovation durchgeführt. Retrodiktion wird auch als Prädiktion in die Vergangenheit (*engl.* "Backward Prediction") oder negatives Zeit-Update bezeichnet. Bei diesem Verfahren wird beim Eintreffen einer Messung  $\mathbf{z}_{k_0}$ zum Zeitpunkt  $t_k$  eine Schätzung der Vergangenheit  $\hat{\mathbf{x}}_{k_0|k}$  und  $\mathbf{P}_{k_0|k}$  unter Berücksichtigung des Prozessrauschens  $\mathbf{Q}_k$  berechnet. Anschließend wird die OOS-Messung in die Zustandschätzung des aktuellen Zustandes integriert, um die Schätzungen  $\hat{\mathbf{x}}_{k|k_0}$  und  $\mathbf{P}_{k|k_0}$ zu erhalten. Hierzu werden zwei Fälle der Retrodiktion unterschieden, das Ein-Schritt-Problem (*engl.* "One-Step Lag") und das Mehr-Schritt- oder *l*-Schritt-Problem (*engl.* "*l*-Lag Case").

Das Ein-Schritt-Problem ist nicht zu verwechseln mit dem Ein-Schritt-Algorithmus. Aus diesem Grund wird in dieser Arbeit der Algorithmus mit Retrodiktion bezeichnet. Im folgenden Abschnitt 4.3.1 wird das Ein-Schritt-Problem eingeführt und Lösungen zur Signalverarbeitung präsentiert. Im Abschnitt 4.3.2 folgt die Herleitung für das Mehr-Schritt-Problem.

## 4.3.1 Ein-Schritt-Problem

Bei einem Ein-Schritt-OOSM-Problem erreicht eine Messung zum Zeitpunkt  $t_{k_0}$  mit  $t_{k-1} < t_{k_0} < t_k$  die Fusionseinheit. Die OOS-Messung hat somit einen Messzeitpunkt zwischen dem letzten und dem aktuellen Innovationszeitpunkt. Das Ein-Schritt-Problem kann auch als *l*-Schritt-Problem mit l = 1 bezeichnet werden, wobei *l* die Anzahl der maximal möglichen Schritte vom aktuellen Zustand zurück bis zur OOS-Messung angibt.

Der Algorithmus zur Lösung des OOS-Problems mit einer Retrodiktion wurde erstmals in [5] vorgestellt. In den folgenden Abschnitten wird auf eine optimale und zwei suboptimale Lösungen eingegangen.

### Optimale Lösung

Bei der optimalen Lösung werden die Systemzustände von Zeitpunkt  $t_{k-1}$  nach  $t_k$  durch eine lineare Differenzengleichung propagiert. Das Prozessmodell beschreibt die zeitlichen Änderungen der Objektparameter wie folgt:

$$\mathbf{x}_k = \mathbf{F}_{k,k-1} \mathbf{x}_{k-1} + \mathbf{v}_{k,k-1}. \tag{4.3.2}$$

Hierbei ist  $\mathbf{F}_{k,k-1}$  die Systemmatrix und  $\mathbf{v}_{k,k-1}$  der kumulative Einfluss des weißen, normalverteilten Prozessrauschens, das durch die Kovarianzmatrix  $\mathbf{Q}_{k,k-1}$  beschrieben wird:

$$E[\mathbf{v}_{k,k-1}\mathbf{v}_{k,k-1}^{T}] = \mathbf{Q}_{k,k-1}.$$
(4.3.3)

Die ausführliche Indizierung  $\mathbf{Q}_{k,k-1}$  statt  $\mathbf{Q}_k$  ist notwendig, um die Kovarianz im weiteren Verlauf vom OOSM-Fall  $\mathbf{Q}_{k,k_0} = E[\mathbf{v}_{k,k_0}\mathbf{v}_{k,k_0}^T]$  unterscheiden zu können. Zu beachten ist, dass die folgenden Berechnungen ein diskretisiertes zeitkontinuierliches weißes Prozessrauschen (*engl.* "Discretized Continuous-Time White-Noise Model") voraussetzen. Das Messmodell beschreibt den linearen Zusammenhang zwischen dem Systemzustand  $\mathbf{x}_k$ und dem Messvektor  $\mathbf{z}_k$  wie folgt:

$$\mathbf{z}_k = \mathbf{H}_k \mathbf{x}_k + \mathbf{w}_k. \tag{4.3.4}$$

Hierbei ist  $\mathbf{H}_k$  die Messmatrix und  $\mathbf{w}_k$  das mittelwertfreie normalverteilte Rauschen, das durch die Kovarianzmatrix  $\mathbf{R}_k$  beschrieben wird:

$$E[\mathbf{w}_k \mathbf{w}_k^T] = \mathbf{R}_k. \tag{4.3.5}$$

Zum aktuellen Zeitpunkt  $t_k$ sind die System<br/>zustände und Kovarianzen gegeben durch

$$\hat{\mathbf{x}}_{k|k} = E[\mathbf{x}_k|Z^k] \quad \text{bzw.} \quad \mathbf{P}_{k|k} = \text{cov}[\mathbf{x}_k|Z^k]$$

$$(4.3.6)$$

und beinhalten die kumulativen Messungen  $Z^k$  mit

$$Z^k = \{\mathbf{z}_i\}_{i=0}^k. \tag{4.3.7}$$

Das heißt,  $Z^k$  umfasst die Menge aller Messungen bis zum Zeitpunkt  $t_k$ . Trifft nun eine verzögerte Messung zum Zeitpunkt  $t_{k_0}$  ein, ist folgender Systemzustand und folgende Kovarianz gesucht:

$$\hat{\mathbf{x}}_{k|k_0} = E[\mathbf{x}_k|Z^{k_0}] \quad \text{bzw.} \quad \mathbf{P}_{k|k_0} = \text{cov}[\mathbf{x}_k|Z^{k_0}], \tag{4.3.8}$$

wobei  $Z^{k_0}$  die kumulativen Messungen bis zum Zeitpunkt  $t_k$  inklusive der OOS-Messung zum Zeitpunkt  $t_{k_0}$  beinhaltet:

$$Z^{k_0} = \{ Z^k, \mathbf{z}_{k_0} \}.$$
(4.3.9)

Die Integration von nicht chronologischen Messungen in die Zustandsschätzung lässt sich wie beim Standard-Kalmanfilter in zwei Signalverarbeitungsschritte unterteilen: die Prädiktion in die Vergangenheit und die Innovation. Zu beachten ist, dass die Bezeichnung Retrodiktion als Algorithmus sowohl den eigentlichen Retrodiktionsschritt als auch die Innovation umfasst. Die Retrodiktion vom Zeitpunkt  $t_k$  nach  $t_{k_0}$  wird wie folgt beschrieben:

- Rückwärtsprädiktion der Systemzustände  $\mathbf{x}_{k|k}$  vom Zeitpunkt  $t_k$  zum Zeitpunkt der verzögerten Messung  $t_{k_0}$
- Rückwärtsprädiktion der Kovarianzmatrix  $\mathbf{P}_{k|k}$  vom Zeitpunkt  $t_k$  nach  $t_{k_0}$

Innovation vom Zeitpunkt  $t_{k_0}$  nach  $t_k$ :

- Berechung der Kalman-Verstärkungsmatrix
- Innovation der Systemzustände von  $\mathbf{x}_{k|k}$  nach  $\mathbf{x}_{k|k_0}$
- Innovation der Schätzfehlerkovarianz von  $\mathbf{P}_{k|k}$  nach  $\mathbf{P}_{k|k_0}$

Der Ablauf einer OOSM-Integration ist in Abbildung 4.6 gezeigt. Erreicht eine OOS-Messung die Fusionseinheit zum Zeitpunkt  $t_{k_0}$ , kann der Systemzustand zum Zeitpunkt  $t_k$  wie folgt beschrieben werden:

$$\mathbf{x}_k = \mathbf{F}_{k,k_0} \mathbf{x}_{k_0} + \mathbf{v}_{k,k_0}. \tag{4.3.10}$$

Hierbei beschreibt der Index  $k_0$  die zeitlich diskreten Zustände zum Zeitpunkt  $t_{k_0}$ . Gleichung (4.3.10) kann jetzt wie folgt umgeformt werden:

$$\mathbf{x}_{k_0} = \mathbf{F}_{k_0,k}[\mathbf{x}_k - \mathbf{v}_{k,k_0}], \qquad (4.3.11)$$

wobei  $\mathbf{F}_{k_0,k}$  die inverse Systemmatrix (engl. "Backward Transition Matrix") ist,

$$\mathbf{F}_{k_0,k} = \mathbf{F}_{k,k_0}^{-1}.$$
 (4.3.12)

Die Invertierbarkeit der Matrix  $\mathbf{F}_{k,k_0}$  ist garantiert, wenn die Matrix das zeitliche Verhalten eines realen Systems beschreibt. Eine detaillierte Herleitung hierzu findet sich in Abschnitt 4.3.3.



**Abbildung 4.6:** Retrodiktion und Innovation für das Ein-Schritt-OOSM-Problem mit einer Messung zum Zeitpunkt  $t_{k_0}$ .

#### **Retrodiktion des Systemzustands**

Die Schwierigkeit besteht nun darin, den Systemzustand  $\hat{\mathbf{x}}_{k|k_0}$  und die Schätzfehlerkovarianz  $\mathbf{P}_{k|k_0}$  mit integrierter OOS-Messung zu berechnen, nachdem die Zustände  $\hat{\mathbf{x}}_{k|k}$  und  $\mathbf{P}_{k|k}$  zum Zeitpunkt  $t_k$  schon berechnet worden sind.

Der erste Schritt, die Retrodiktion, beinhaltet die Prädiktion vom aktuellen Zeitpunkt  $t_k$  in die Vergangenheit zum Zeitpunkt  $t_{k_0}$ . Die Schätzung  $\hat{\mathbf{x}}_{k_0|k}$  erhält man analog zu Gleichung (4.3.11) folgendermaßen:

$$\hat{\mathbf{x}}_{k_0|k} = E[\mathbf{x}_{k_0}|Z^k] = \mathbf{F}_{k_0,k}[\hat{\mathbf{x}}_{k|k} - \hat{\mathbf{v}}_{k,k_0|k}].$$
(4.3.13)

Wie in Abschnitt 4.3 hergeleitet wurde, ist der a priori Schätzwert  $\hat{\mathbf{x}}_{k|k-1}$  vom Prozessrauschen  $\mathbf{Q}_k$  unabhängig, der a posteriori Schätzwert  $\hat{\mathbf{x}}_{k|k}$  aber nicht mehr. Da dieser jedoch bei der Retrodiktion (4.3.13) verwendet wird, muss hier im Unterschied zum Standard-Kalmanfilter der Term des Prozessrauschens  $\hat{\mathbf{v}}_{k,k_0|k}$  von  $t_{k_0}$  nach  $t_k$  unter Voraussetzung der Messung  $Z^k$  berücksichtigt werden. Es gilt also

$$\hat{\mathbf{v}}_{k,k_0|k-1} = E[\mathbf{v}_{k,k_0}|Z^{k-1}] = 0, \qquad (4.3.14)$$

$$\hat{\mathbf{v}}_{k,k_0|k} = E[\mathbf{v}_{k,k_0}|Z^k] \neq 0.$$
(4.3.15)

Man könnte  $\hat{\mathbf{v}}_{k,k_0|k-1}$  als a priori Erwartungswert des Prozessrauschens bezeichnen, der sich zu Null ergibt, und  $\hat{\mathbf{v}}_{k,k_0|k}$  als a posteriori Erwartungswert.

Im Folgenden wird daher eine Innovationsformel für den Zustandsvektor hergeleitet, die das Prozessrauschen berücksichtigt. Die Schätzung  $\hat{\mathbf{x}}_{k|k}$  erhält man durch die Innovation (3.2.15) des linearen Kalmanfilters unter Verwendung von (3.2.21):

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k \left( \mathbf{z}_k - \hat{\mathbf{z}}_{k|k-1} \right)$$
$$= \hat{\mathbf{x}}_{k|k-1} + \mathbf{P}_{k|k-1} \mathbf{H}_k^T \mathbf{S}_k^{-1} \left( \mathbf{z}_k - \hat{\mathbf{z}}_{k|k-1} \right).$$
(4.3.16)

Die Berechnung der Retrodiktion benötigt die bedingte Kreuzkovarianz zwischen einer Messung  $\mathbf{z}_k$  und den Systemzuständen  $\mathbf{x}_k$  zum Zeitpunkt  $t_k$ . Die bedingte Kovarianz bzw. bedingte Kreuzkovarianz ist wie folgt definiert:

$$\operatorname{cov}\{\mathbf{a}|\mathbf{c}\} = E\left[(\mathbf{a} - E[\mathbf{a}])(\mathbf{a} - E[\mathbf{a}])^{T}|\mathbf{c}\right]$$
$$\operatorname{cov}\{\mathbf{a}, \mathbf{b}|\mathbf{c}\} = E\left[(\mathbf{a} - E[\mathbf{a}])(\mathbf{b} - E[\mathbf{b}])^{T}|\mathbf{c}\right].$$
(4.3.17)

Die Kreuzkovarianz zwischen dem Systemzustand  $\mathbf{x}_k$  und der Messung  $\mathbf{z}_k$  lässt sich durch Einsetzen der Messgleichung folgendermaßen berechnen:

$$\operatorname{cov}\{\mathbf{x}_{k}, \mathbf{z}_{k} | Z^{k-1}\} = \operatorname{cov}\{\mathbf{x}_{k}, \mathbf{H}_{k}\mathbf{x}_{k} + \mathbf{w}_{k} | Z^{k-1}\}$$

$$= \operatorname{cov}\{\mathbf{x}_{k}, \mathbf{H}_{k}\mathbf{x}_{k} | Z^{k-1}\} + \operatorname{cov}\{\mathbf{x}_{k}, \mathbf{w}_{k} | Z^{k-1}\}$$

$$= \operatorname{cov}\{\mathbf{x}_{k}, \mathbf{H}_{k}\mathbf{x}_{k} | Z^{k-1}\}$$

$$= E[(\mathbf{x}_{k} - \hat{\mathbf{x}}_{k})(\mathbf{H}_{k}\mathbf{x}_{k} - \mathbf{H}_{k}\hat{\mathbf{x}}_{k})^{T} | Z^{k-1}]$$

$$= E[(\mathbf{x}_{k} - \hat{\mathbf{x}}_{k})(\mathbf{x}_{k} - \hat{\mathbf{x}}_{k})^{T}\mathbf{H}_{k}^{T} | Z^{k-1}]$$

$$= \operatorname{cov}\{\mathbf{x}_{k} | Z^{k-1}\}\mathbf{H}_{k}^{T}$$

$$= \mathbf{P}_{k|k-1}\mathbf{H}_{k}^{T}.$$

$$(4.3.18)$$

Hier wurde ausgenutzt, dass das Messrauschen  $\mathbf{w}_k$  und der Systemzustand  $\mathbf{x}_k$  unabhängig voneinander sind. Die bedingte Kreuzkovarianz cov $\{\mathbf{x}_k, \mathbf{z}_k | Z^{k-1}\}$  beschreibt dabei den Zusammenhang zwischen Zustand  $\mathbf{x}_k$  und Messung  $\mathbf{z}_k$  unter der Bedingung, dass die aktuelle Messung noch nicht in die Zustandsschätzung integriert wurde. Das heißt, es handelt sich um eine a priori Kovarianz unter Verwendung von  $\hat{\mathbf{x}}_{k|k-1}$  anstelle von  $\hat{\mathbf{x}}_{k|k}$ .

Mit der Kovarianz des Residuums

$$\operatorname{cov}\{\mathbf{z}_k|Z^{k-1}\} = \mathbf{S}_k \tag{4.3.19}$$

ergibt sich mit (4.3.18) die folgende Umformung der Innovationsgleichung (4.3.16):

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \operatorname{cov}\{\mathbf{x}_k, \mathbf{z}_k | Z^{k-1}\} \operatorname{cov}\{\mathbf{z}_k | Z^{k-1}\}^{-1} \left(\mathbf{z}_k - \hat{\mathbf{z}}_{k|k-1}\right).$$
(4.3.20)

Da wegen (4.3.15) nicht nur der Zustand, sondern auch das Prozessrauschen geschätzt werden muss, definiert man einen Vektor  $\mathbf{y}_k$  wie folgt:

$$\mathbf{y}_k := \begin{bmatrix} \mathbf{x}_k \\ \mathbf{v}_{k,k_0} \end{bmatrix}. \tag{4.3.21}$$

Die Innovation dieses erweiterten Zustandsvektors ergibt sich analog zu (4.3.20):

$$\hat{\mathbf{y}}_{k|k} = \hat{\mathbf{y}}_{k|k-1} + \operatorname{cov}\{\mathbf{y}_k, \mathbf{z}_k | Z^{k-1}\} \operatorname{cov}\{\mathbf{z}_k | Z^{k-1}\}^{-1} \left(\mathbf{z}_k - \hat{\mathbf{z}}_{k|k-1}\right), \qquad (4.3.22)$$

mit der Kreuzkovarianzmatrix

$$\operatorname{cov}\{\mathbf{y}_{k}, \mathbf{z}_{k} | Z^{k-1}\} = \begin{bmatrix} \operatorname{cov}\{\mathbf{x}_{k}, \mathbf{z}_{k} | Z^{k-1}\} \\ \operatorname{cov}\{\mathbf{v}_{k,k_{0}}, \mathbf{z}_{k} | Z^{k-1}\} \end{bmatrix}.$$
(4.3.23)

Die untere Kreuzkovarianz aus Gleichung (4.3.23) ist unter Verwendung von (4.3.14) darstellbar durch:

$$\operatorname{cov}\{\mathbf{v}_{k,k_{0}}, \mathbf{z}_{k} | Z^{k-1}\} = E\left[(\mathbf{v}_{k,k_{0}} - \hat{\mathbf{v}}_{k,k_{0}})(\mathbf{z}_{k} - \hat{\mathbf{z}}_{k})^{T} | Z^{k-1}\right]$$
$$= E\left[\mathbf{v}_{k,k_{0}}\left[\mathbf{H}_{k}(\mathbf{F}_{k,k_{0}}\mathbf{x}_{k_{0}} + \mathbf{v}_{k,k_{0}}) + \mathbf{w}_{k} - \hat{\mathbf{z}}_{k}\right]^{T} | Z^{k-1}\right]. \quad (4.3.24)$$

Da die Kreuzkovarianzen von  $\mathbf{v}_{k|k_0}$  zu  $\mathbf{x}_{k_0}$ , zu  $\mathbf{w}_k$  und zu  $\hat{\mathbf{z}}_k$  wegen ihrer vorausgesetzten stochastischen Unabhängigkeit Null sind, vereinfacht sich diese Gleichung folgendermaßen:

$$\operatorname{cov}\{\mathbf{v}_{k,k_0}, \mathbf{z}_k | Z^{k-1}\} = E\left[\mathbf{v}_{k,k_0} \mathbf{v}_{k,k_0}^T \mathbf{H}_k^T\right]$$
$$= \mathbf{Q}_{k,k_0} \mathbf{H}_k^T.$$
(4.3.25)

Gleichung (4.3.22) ergibt für den a posteriori Erwartungswert des Prozessrauschens zwischen den Zeitschritten  $t_{k_0}$  und  $t_k$  mit den gegebenen Messungen  $Z^k$ :

$$\hat{\mathbf{v}}_{k,k_0|k} = \operatorname{cov}\{\mathbf{v}_{k,k_0}, \mathbf{z}_k | Z^{k-1}\} \operatorname{cov}\{\mathbf{z}_k | Z^{k-1}\}^{-1} \left(\mathbf{z}_k - \hat{\mathbf{z}}_{k|k-1}\right), \qquad (4.3.26)$$

wobei wieder die Mittelwertfreiheit des Prozessrauschens (4.3.14) verwendet wurde. Dadurch berechnet sich mit (4.3.25) die gesuchte Innovationsformel für das Prozessrauschen:

$$\hat{\mathbf{v}}_{k,k_0|k} = \mathbf{Q}_{k,k_0} \mathbf{H}_k^T \mathbf{S}_k^{-1} \boldsymbol{\gamma}_k.$$
(4.3.27)

Anschaulich beschreibt der a posteriori Erwartungswert des Prozessrauschens  $\hat{\mathbf{v}}_{k,k_0|k}$  genau den Teil des Prozessrauschens zwischen der OOS-Messung  $\mathbf{z}_{k_0}$  und der neuesten Messung  $\mathbf{z}_k$ , der den Innovationsschritt von  $\hat{\mathbf{x}}_{k|k-1}$  zu  $\hat{\mathbf{x}}_{k|k}$  beeinflusst hat. Dieser Teil muss demnach bei der Retrodiktion wieder rückgängig gemacht werden. Die Retrodiktion der Zustandsschätzung vom Zeitpunkt  $t_k$  zurück zum Zeitpunkt  $t_{k_0}$  lautet daher nach Gleichung (4.3.13):

$$\hat{\mathbf{x}}_{k_0|k} = \mathbf{F}_{k_0,k} [\hat{\mathbf{x}}_{k|k} - \mathbf{Q}_{k,k_0} \mathbf{H}_k^T \mathbf{S}_k^{-1} \boldsymbol{\gamma}_k].$$
(4.3.28)

Der Systemzustand  $\hat{\mathbf{x}}_{k_0|k}$  stellt die Zustandsschätzung zum Zeitpunkt  $k_0$  dar, wobei alle Messungen bis zum Zeitpunkt  $t_k$  außer der Messung zum Zeitpunkt  $t_{k_0}$  berücksichtigt sind. Dies vervollständigt die Retrodiktion des Systemzustands.

#### Retrodiktion der Schätzfehlerkovarianz

Im nächsten Schritt wird der Einfluss des Prozessrauschens auf die Schätzfehlerkovarianz entfernt. Dies ermöglicht eine Retrodiktion der Kovarianzen von Zeitschritt  $t_k$  zu  $t_{k_0}$ . Aus

Gleichung (4.3.11) leitet man folgende Bedingung für die gesuchte Schätzfehlerkovarianz der Retrodiktion her:

$$\begin{aligned} \mathbf{P}_{k_{0}|k} &\coloneqq \operatorname{cov}\{\mathbf{x}_{k_{0}}|Z^{k}\} \\ &= \operatorname{cov}\{\mathbf{F}_{k_{0},k}(\mathbf{x}_{k} - \mathbf{v}_{k,k_{0}})|Z^{k}\} \\ &= \mathbf{F}_{k_{0},k}\left[\operatorname{cov}\{\mathbf{x}_{k} - \mathbf{v}_{k,k_{0}}|Z^{k}\}\right]\mathbf{F}_{k_{0},k}^{T} \\ &= \mathbf{F}_{k_{0},k}\left[\operatorname{cov}\{\mathbf{x}_{k}|Z^{k}\} - \operatorname{cov}\{\mathbf{x}_{k},\mathbf{v}_{k,k_{0}}|Z^{k}\}\right] \\ &- \operatorname{cov}\{\mathbf{x}_{k},\mathbf{v}_{k,k_{0}}|Z^{k}\}^{T} + \operatorname{cov}\{\mathbf{v}_{k,k_{0}}|Z^{k}\}\right]\mathbf{F}_{k_{0},k}^{T} \\ &=: \mathbf{F}_{k_{0},k}\left[\mathbf{P}_{k|k} - \mathbf{P}_{k,k_{0}|k}^{\mathbf{x}\mathbf{v}} - \left(\mathbf{P}_{k,k_{0}|k}^{\mathbf{x}\mathbf{v}}\right)^{T} + \mathbf{P}_{k,k_{0}|k}^{\mathbf{v}\mathbf{v}}\right]\mathbf{F}_{k_{0},k}^{T}. \end{aligned}$$
(4.3.29)

Man sieht, dass im Unterschied zum Standard-Kalmanfilter aufgrund des Prozessrauschens weitere Kovarianzen notwendig sind. Die beiden Terme

$$\mathbf{P}_{k,k_0|k}^{\mathbf{xv}} \coloneqq \operatorname{cov}\{\mathbf{x}_k, \mathbf{v}_{k,k_0} | Z^k\}, \\ \mathbf{P}_{k,k_0|k}^{\mathbf{vv}} \coloneqq \operatorname{cov}\{\mathbf{v}_{k,k_0} | Z^k\}$$
(4.3.30)

sollen im Folgenden hergeleitet werden.

Die a posteriori Schätzfehlerkovarianz zum Zeitpunkt  $t_k$  ist nach (3.2.22) gegeben durch

$$\mathbf{P}_{k|k} = \mathbf{P}_{k|k-1} - \mathbf{P}_{k|k-1} \mathbf{H}_k^T \mathbf{S}_k^{-1} \mathbf{H}_k \mathbf{P}_{k|k-1}.$$
(4.3.31)

Eine äquivalente Schreibweise mittels Kreuzkovarianzen erhält man unter Verwendung von (4.3.18) und (4.3.19) wie folgt:

$$\operatorname{cov}\{\mathbf{x}_{k}|Z^{k}\} = \operatorname{cov}\{\mathbf{x}_{k}|Z^{k-1}\} - \operatorname{cov}\{\mathbf{x}_{k}, \mathbf{z}_{k}|Z^{k-1}\} \operatorname{cov}\{\mathbf{z}_{k}|Z^{k-1}\}^{-1} \operatorname{cov}\{\mathbf{z}_{k}, \mathbf{x}_{k}|Z^{k-1}\}.$$
(4.3.32)

Um das Prozessrauschen korrekterweise zu berücksichtigen, wird der Vektor  $\mathbf{y}_k$  aus (4.3.21) verwendet, was zu folgender Gleichung führt:

$$\operatorname{cov}\{\mathbf{y}_{k}|Z^{k}\} = \operatorname{cov}\left\{\begin{bmatrix}\mathbf{x}_{k}\\\mathbf{v}_{k,k_{0}}\end{bmatrix} \middle| Z^{k}\right\}$$
$$= \operatorname{cov}\left\{\begin{bmatrix}\mathbf{x}_{k}\\\mathbf{v}_{k,k_{0}}\end{bmatrix} \middle| Z^{k-1}\right\} - \operatorname{cov}\left\{\begin{bmatrix}\mathbf{x}_{k}\\\mathbf{v}_{k,k_{0}}\end{bmatrix}, \mathbf{z}_{k}\middle| Z^{k-1}\right\}$$
$$\cdot \operatorname{cov}\left\{\mathbf{z}_{k}\middle| Z^{k-1}\right\}^{-1} \operatorname{cov}\left\{\mathbf{z}_{k}, \begin{bmatrix}\mathbf{x}_{k}\\\mathbf{v}_{k,k_{0}}\end{bmatrix}^{T}\middle| Z^{k-1}\right\}$$
$$= \begin{bmatrix}\operatorname{cov}\{\mathbf{x}_{k}|Z^{k-1}\} & \operatorname{cov}\{\mathbf{x}_{k}, \mathbf{v}_{k,k_{0}}|Z^{k-1}\} \\ \operatorname{cov}\{\mathbf{v}_{k,k_{0}}, \mathbf{x}_{k}|Z^{k-1}\} & \operatorname{cov}\{\mathbf{v}_{k,k_{0}}|Z^{k-1}\}\end{bmatrix} - \begin{bmatrix}\operatorname{cov}\{\mathbf{x}_{k}, \mathbf{z}_{k}|Z^{k-1}\} \\ \operatorname{cov}\{\mathbf{v}_{k,k_{0}}, \mathbf{z}_{k}|Z^{k-1}\} \\ \operatorname{cov}\{\mathbf{v}_{k,k_{0}}, \mathbf{z}_{k}|Z^{k-1}\}\end{bmatrix}^{T}. \quad (4.3.33)$$

Die bedingte Kreuzkovarianz des Zustands und des Prozessrauschens ergibt sich aufgrund der Unabhängigkeit von  $\mathbf{x}_{k_0}$  und  $\mathbf{v}_{k,k_0}$  mit (4.3.10) zu

$$cov\{\mathbf{x}_{k}, \mathbf{v}_{k,k_{0}} | Z^{k-1}\} = E[(\mathbf{x}_{k} - \hat{\mathbf{x}}_{k})\mathbf{v}_{k,k_{0}}^{T} | Z^{k-1}] 
= E[(\mathbf{F}_{k,k_{0}}\mathbf{x}_{k_{0}} + \mathbf{v}_{k,k_{0}} - \mathbf{F}_{k,k_{0}}\hat{\mathbf{x}}_{k_{0}})\mathbf{v}_{k,k_{0}}^{T} | Z^{k-1}] 
= E[\mathbf{v}_{k,k_{0}}\mathbf{v}_{k,k_{0}}^{T} | Z^{k-1}] 
= \mathbf{Q}_{k,k_{0}}.$$
(4.3.34)

Einsetzen von (4.3.34), (4.3.18) und (4.3.25) in (4.3.33) ergibt

$$\operatorname{cov}\left\{\begin{bmatrix}\mathbf{x}_{k}\\\mathbf{v}_{k,k_{0}}\end{bmatrix}\middle|Z^{k}\right\} = \begin{bmatrix}\mathbf{P}_{k|k-1} & \mathbf{Q}_{k,k_{0}}\\\mathbf{Q}_{k,k_{0}} & \mathbf{Q}_{k,k_{0}}\end{bmatrix} - \begin{bmatrix}\mathbf{P}_{k|k-1}\mathbf{H}_{k}^{T}\\\mathbf{Q}_{k,k_{0}}\mathbf{H}_{k}^{T}\end{bmatrix}^{T} \mathbf{S}_{k}^{-1}\begin{bmatrix}\mathbf{P}_{k|k-1}\mathbf{H}_{k}^{T}\\\mathbf{Q}_{k,k_{0}}\mathbf{H}_{k}^{T}\end{bmatrix}^{T}$$
$$= \begin{bmatrix}\mathbf{P}_{k|k-1} - \mathbf{P}_{k|k-1}\mathbf{H}_{k}^{T}\mathbf{S}_{k}^{-1}\mathbf{H}_{k}\mathbf{P}_{k|k-1} & \mathbf{Q}_{k,k_{0}} - \mathbf{P}_{k|k-1}\mathbf{H}_{k}^{T}\mathbf{S}_{k}^{-1}\mathbf{H}_{k}\mathbf{Q}_{k,k_{0}}\\\mathbf{Q}_{k,k_{0}} - \mathbf{Q}_{k,k_{0}}\mathbf{H}_{k}^{T}\mathbf{S}_{k}^{-1}\mathbf{H}_{k}\mathbf{P}_{k|k-1} & \mathbf{Q}_{k,k_{0}} - \mathbf{Q}_{k,k_{0}}\mathbf{H}_{k}^{T}\mathbf{S}_{k}^{-1}\mathbf{H}_{k}\mathbf{Q}_{k,k_{0}}\end{bmatrix}$$
$$= \begin{bmatrix}\operatorname{cov}\{\mathbf{x}_{k}|Z^{k}\} & \operatorname{cov}\{\mathbf{x}_{k},\mathbf{v}_{k,k_{0}}|Z^{k}\}^{T} & \operatorname{cov}\{\mathbf{x}_{k},\mathbf{v}_{k,k_{0}}|Z^{k}\}\end{bmatrix}$$
$$= \begin{bmatrix}\mathbf{P}_{k|k} & \mathbf{P}_{k,k_{0}|k}^{\mathbf{x}\mathbf{v}}\\(\mathbf{P}_{k,k_{0}|k}^{\mathbf{x}\mathbf{v}} - \mathbf{P}_{k,k_{0}|k}^{\mathbf{x}\mathbf{v}}\end{bmatrix}. \qquad (4.3.35)$$

Hieraus ergibt sich die gesuchte bedingte Kovarianz der Retrodiktion durch Einsetzen von  $\mathbf{P}_{k,k_0|k}^{\mathbf{xv}}$  und  $\mathbf{P}_{k,k_0|k}^{\mathbf{vv}}$  in (4.3.29).

#### Innovationsschritt

Nachdem der Systemzustand  $\hat{\mathbf{x}}_{k_0|k}$  und die Schätzfehlerkovarianz  $\mathbf{P}_{k_0|k}$  zum Zeitpunkt der OOS-Messung  $t_{k_0}$  retrodiziert wurden, folgt die Innovation zur Integration der Messung  $\mathbf{z}_{k_0}$ . Die Innovation mittels Kreuzkovarianzschreibweise leitet sich analog zu (4.3.20) her:

$$\hat{\mathbf{x}}_{k|k_0} = \hat{\mathbf{x}}_{k|k} + \operatorname{cov}\{\mathbf{x}_k, \mathbf{z}_{k_0} | Z^k\} \operatorname{cov}\{\mathbf{z}_{k_0} | Z^k\}^{-1} (\mathbf{z}_{k_0} - \mathbf{H}_{k_0} \hat{\mathbf{x}}_{k_0|k}).$$
(4.3.36)

Die OOS-Messung ist mit Gleichung (4.3.4) wie folgt gegeben:

$$\mathbf{z}_{k_0} = \mathbf{H}_{k_0} \mathbf{x}_{k_0} + \mathbf{w}_{k_0}. \tag{4.3.37}$$

Die Schätzfehlerkovarianz der OOS-Messung kann gemäß

$$\operatorname{cov}\{\mathbf{z}_{k_0}|Z^k\} = \mathbf{H}_{k_0}\mathbf{P}_{k_0|k}\mathbf{H}_{k_0}^T + \mathbf{R}_{k_0} =: \mathbf{S}_{k_0}$$
(4.3.38)

berechnet werden. Die Kovarianz zwischen dem Zustand zum Zeitpunkt  $t_k$  und der OOS-Messung  $z_{k_0}$  wird aus Gleichung (4.3.11) und (4.3.37) wie folgt ermittelt:

$$\operatorname{cov}\{\mathbf{x}_{k}, \mathbf{z}_{k_{0}} | Z^{k}\} = \operatorname{cov}\{\mathbf{x}_{k}, \mathbf{H}_{k_{0}} \mathbf{F}_{k_{0},k}(\mathbf{x}_{k} - \mathbf{v}_{k,k_{0}}) + \mathbf{w}_{k_{0}} | Z^{k}\}$$
$$= \left[\mathbf{P}_{k|k} - \mathbf{P}_{k,k_{0}|k}^{\mathbf{x}\mathbf{v}}\right] \mathbf{F}_{k_{0},k}^{T} \mathbf{H}_{k_{0}}^{T}$$
$$=: \mathbf{P}_{k,k_{0}|k}^{\mathbf{x}\mathbf{z}}.$$
(4.3.39)

Damit berechnet sich die Kalman-Verstärkungsmatrix einer OOS-Messung analog zu Gleichung (4.3.20):

$$\mathbf{W}_{k_0} \coloneqq \mathbf{P}_{k,k_0|k}^{\mathbf{x}\mathbf{z}} \mathbf{S}_{k_0}^{-1}. \tag{4.3.40}$$

Man beachte, dass es sich hierbei nicht um die Verstärkungsmatrix  $\mathbf{K}_k$  des Standard-Kalmanfilters handelt. Der Systemzustand  $\hat{\mathbf{x}}_{k|k}$  kann jetzt direkt mit der OOS-Messung  $\mathbf{z}_{k_0}$  aktualisiert werden. Dazu werden die angegebenen Kreuzkovarianzen in (4.3.36) eingesetzt:

$$\hat{\mathbf{x}}_{k|k_0} = \hat{\mathbf{x}}_{k|k} + \mathbf{W}_{k_0} \left[ \mathbf{z}_{k_0} - \mathbf{H}_{k_0} \hat{\mathbf{x}}_{k_0|k} \right].$$
(4.3.41)

Die Aktualisierung der Schätzfehlerkovarianz ergibt sich zu:

$$\mathbf{P}_{k|k_0} = \mathbf{P}_{k|k} - \mathbf{P}_{k,k_0|k}^{\mathbf{x}\mathbf{z}} \mathbf{S}_{k_0}^{-1} \left( \mathbf{P}_{k,k_0|k}^{\mathbf{x}\mathbf{z}} \right)^T.$$
(4.3.42)

Dies vervollständigt die Herleitung des Retrodiktionsalgorithmus.

Zu beachten ist, dass sich nach der Retrodiktion und nach der Integration der OOS-Messung der neue Systemzustand wieder im aktuellen Zeitpunkt  $t_k$  befindet. Im Ein-Schritt-Fall stellt dieser Algorithmus die exakte Lösung dar [6]. Im Gegensatz zur Retrodiktion integriert Reprozessierung die Messungen in zeitlicher Reihenfolge beginnend mit  $\mathbf{z}_{k-1}$ , dann  $\mathbf{z}_{k_0}$  und schließlich  $\mathbf{z}_k$  und liefert nach der Herleitung das gleiche Ergebnis. Die einzelnen Schritte der Retrodiktion sind Tabelle 4.2 zusammengefasst.

Retrodiktion
$ \hat{\mathbf{x}}_{k_0 k} = \mathbf{F}_{k_0,k} [ \hat{\mathbf{x}}_{k k} - \mathbf{Q}_{k,k_0} \mathbf{H}_k^T \mathbf{S}_k^{-1} \boldsymbol{\gamma}_k ] $ $ \mathbf{P}_{k_0}^{\text{VV}} = \mathbf{Q}_{k,k_0} - \mathbf{Q}_{k,k_0} \mathbf{H}_k^T \mathbf{S}_k^{-1} \mathbf{H}_k \mathbf{Q}_{k,k_0} $
$\mathbf{P}_{k,k_0 k}^{\mathbf{x}} = \mathbf{Q}_{k,k_0} - \mathbf{P}_{k k-1}\mathbf{H}_k^T\mathbf{S}_k^{-1}\mathbf{H}_k\mathbf{Q}_{k,k_0}$ $\mathbf{P}_{k,k_0 k}^{\mathbf{x}} = \mathbf{Q}_{k,k_0} - \mathbf{P}_{k k-1}\mathbf{H}_k^T\mathbf{S}_k^{-1}\mathbf{H}_k\mathbf{Q}_{k,k_0}$
$\mathbf{P}_{k_0 k} = \mathbf{F}_{k_0,k} \left[ \mathbf{P}_{k k} + \mathbf{P}_{k,k_0 k}^{\mathbf{vv}} - \mathbf{P}_{k,k_0 k}^{\mathbf{xv}} - \left( \mathbf{P}_{k,k_0 k}^{\mathbf{xv}} \right)^T \right] \mathbf{F}_{k_0,k}^T$
OOSM-Innovation
$\mathbf{S}_{k_0} = \mathbf{H}_{k_0} \mathbf{P}_{k_0 k} \mathbf{H}_{k_0}^T + \mathbf{R}_{k_0}$
$\mathbf{P}_{k,k_{0} k}^{\mathbf{xz}}=\left \mathbf{P}_{k k}-\mathbf{P}_{k,k_{0} k}^{\mathbf{xv}} ight \mathbf{F}_{k_{0},k}^{T}\mathbf{H}_{k_{0}}^{T}$
$ ilde{\mathbf{W}}_{k_0} = \mathbf{P}^{\mathbf{xz}}_{k,k_0 k} \mathbf{S}^{-1}_{k_0}$
$\mathbf{\hat{x}}_{k k_0} = \mathbf{\hat{x}}_{k k} + \mathbf{W}_{k_0} \left[ \mathbf{z}_{k_0} - \mathbf{H}_{k_0} \mathbf{\hat{x}}_{k_0 k}  ight]_T$
$\mathbf{P}_{k k_0} = \mathbf{P}_{k k} - \mathbf{P}_{k,k_0 k}^{\mathbf{xz}} \mathbf{S}_{k_0}^{-1} \left(\mathbf{P}_{k,k_0 k}^{\mathbf{xz}} ight)^{\mathbf{z}}$

 

 Tabelle 4.2: Zusammenfassung der Gleichungen zur Retrodiktion eines Ein-Schritt-OOSM-Problems.

#### Suboptimale Lösungen

Es gibt zwei suboptimale Lösungen der Retrodiktion, die erstmals in [5] vorgestellt wurden. Diese Algorithmen werden in der Literatur Algorithmus B und Algorithmus C genannt. Der erste vernachlässigt dabei Teile des Prozessrauschens bei der Retrodiktion und der zweite betrachtet den Einfluss des Prozessrauschens sowohl bei der Retrodiktion als auch bei der Innovation gar nicht. Im Folgenden wird auf die Signalverarbeitungsschritte des Algorithmus C eingegangen. Die Retrodiktion der Systemzustände aus Gleichung (4.3.28) vereinfacht sich dadurch wie folgt:

$$\hat{\mathbf{x}}_{k_0|k} = \mathbf{F}_{k_0,k} \hat{\mathbf{x}}_{k|k}. \tag{4.3.43}$$

Die Retrodiktion der Schätzfehlerkovarianz aus Gleichung (4.3.29) wird durch die Folgende ersetzt:

$$\mathbf{P}_{k_0|k} = \mathbf{F}_{k_0,k} \mathbf{P}_{k|k} \mathbf{F}_{k_0,k}^T.$$
(4.3.44)

Im Innovationsschritt vereinfacht sich Gleichung (4.3.39) zu:

$$\mathbf{P}_{k,k_0|k}^{\mathbf{xz}} = \mathbf{P}_{k|k} \mathbf{F}_{k_0,k}^T \mathbf{H}_{k_0}^T.$$
(4.3.45)

Die suboptimalen Lösungen der Retrodiktion können bei laufzeit- und speichereffizienten Anforderungen eine mögliche Alternative zur exakten Lösung bieten, liefern jedoch auch schlechtere Ergebnisse, weshalb sie in der vorliegenden Arbeit nicht berücksichtigt wurden. Die einzelnen Schritte der suboptimalen Retrodiktion sind in Tabelle 4.3 zusammengefasst.



**Tabelle 4.3:** Zusammenfassung der Gleichungen für die suboptimale Lösung (Algorithmus C) der Retrodiktion im Ein-Schritt-Fall.

### 4.3.2 *l*-Schritt-Problem

Bei vielen Sensorfusionssystemen erreicht eine OOS-Messung die Fusionseinheit mehr als einen Schritt verzögert. Der Sensoraufbau dieser Arbeit mit zwei SRR-Sensoren und einem MMR-Sensor weist eine maximale Verzögerung von drei Schritten auf. Die Idee besteht darin, das *l*-Schritt-Problem [9, 11] auf das Ein-Schritt-Problem [5] aus dem vorherigen Abschnitt zurückzuführen. Zum aktuellen Systemzustand zum Zeitpunkt  $t_k$ erreicht eine Messung die Fusionseinheit welche zum Zeitpunkt  $t_{k_0}$  aufgenommen wurde, so dass gilt  $t_{k-l} < t_{k_0} < t_{k-l+1}$ . Abbildung 4.7 zeigt die zeitliche Schematisierung bei einem *l*-Schritt-Problem. Um dieses Mehr-Schritt-Problem auf ein Ein-Schritt-Problem zurückzuführen, werden alle Messungen vom Zeitpunkt  $t_{k-l+1}$  bis zum Zeitpunkt  $t_k$  zu einer sogenannten äquivalenten Messung (*engl.* "Equivalent Measurement") zusammengefasst. Diese Pseudo-Messung wird zum aktuellen Zeitpunkt  $t_k$  berechnet und ersetzt die folgende Menge von Messungen:

$$Z_{k-l+1}^{k} = \{ \mathbf{z}_{k-l+1}, \dots, \mathbf{z}_{k} \}.$$
(4.3.46)



**Abbildung 4.7:** *l*-Schritt-Problem mit einer OOS-Messung zum Zeitpunkt  $t_{k_0}$  zwischen den Zeitschritten  $t_{k-l}$  und  $t_{k-l+1}$  mit l > 1.

Die äquivalente Messung  $\mathbf{z}_k^*$  wird so berechnet, dass sie im Kalmanfilter dieselbe Wirkung erzielt wie die Menge von Original-Messungen  $Z_{k-l+1}^k$ . Damit liegt die OOS-Messung zum Zeitpunkt  $t_{k_0}$  zwischen der äquivalenten Messung zum Zeitpunkt  $t_k$  und der vorherigen Messung zum Zeitpunkt  $t_{k-l}$ . Nun können die Signalverarbeitungsschritte des Ein-Schritt-Problems angewendet werden. Im Folgenden wird genauer auf die Herleitung der Formel für die Lösung des *l*-Schritt-Problems mit äquivalenten Messungen eingegangen.

Die äquivalente Messung ist wie folgt definiert:

$$\mathbf{z}_k^* = \mathbf{H}_k \mathbf{x}_k + \mathbf{w}_k^* \tag{4.3.47}$$

mit einem äquivalenten Messrauschen (engl. "Equivalent Measurement Noise") von:

$$E\left[\mathbf{w}_{k}^{*}\mathbf{w}_{k}^{*T}\right] = \mathbf{R}_{k}^{*}.$$
(4.3.48)

Die äquivalente Messung wird so hergeleitet, dass eine Prädiktion von  $t_{k-l}$  zu  $t_k$  mit anschließender Innovation das gleiche Ergebnis liefert wie bei Integration aller Einzelmessungen  $\mathbf{z}_{k-l}, \mathbf{z}_{k-l+1}, ..., \mathbf{z}_k$  in Reihe. Damit muss gelten:

$$\hat{\mathbf{x}}_{k|k}^* = \hat{\mathbf{x}}_{k|k} \tag{4.3.49}$$

$$\mathbf{P}_{k|k}^* = \mathbf{P}_{k|k}.\tag{4.3.50}$$

Die Innovation der äquivalenten Schätzfehlerkovarianz berechnet sich mit dem Informationsfilter nach (3.2.27) wie folgt:

$$\mathbf{P}_{k|k}^{*-1} = \mathbf{P}_{k|k-l}^{-1} + \mathbf{H}_{k}^{*T} \mathbf{R}_{k}^{*-1} \mathbf{H}_{k}^{*} \stackrel{!}{=} \mathbf{P}_{k|k}^{-1}.$$
(4.3.51)

Da für die äquivalente Messung der Messraum beliebig festgelegt werden kann, wird zur Vereinfachung der Messraum des Zustandsraumes gewählt. Daher gilt:

$$\mathbf{H}_{k}^{*} = \boldsymbol{I}. \tag{4.3.52}$$

Nun wird Gleichung (4.3.51) nach dem äquivalenten Messrauschen unter Berücksichtigung von Gleichung (4.3.52) aufgelöst:

$$\mathbf{R}_{k}^{*-1} = \mathbf{P}_{k|k}^{-1} - \mathbf{P}_{k|k-l}^{-1}.$$
(4.3.53)

Die allgemeine Form der Kalman-Verstärkungsmatrix lautet:

$$\mathbf{K}_{k}^{*} = \mathbf{P}_{k|k-l} \left( \mathbf{P}_{k|k-l} + \mathbf{R}_{k}^{*} \right)^{-1}.$$
(4.3.54)

Einsetzen von  $\mathbf{P}_{k|k-l}$  aus Gleichung (4.3.53) in Gleichung (4.3.54) ergibt die äquivalente Kalman-Verstärkungsmatrix:

$$\mathbf{K}_k^* = \mathbf{P}_{k|k} \mathbf{R}_k^{*-1}. \tag{4.3.55}$$

Die Innovation der Systemzustände mittels der äquivalenten Messung ist gegeben durch folgende Gleichung:

$$\hat{\mathbf{x}}_{k|k}^* = \hat{\mathbf{x}}_{k|k-l} + \mathbf{K}_k^* \left[ \mathbf{z}_k^* - \hat{\mathbf{x}}_{k|k-l} \right] \stackrel{!}{=} \hat{\mathbf{x}}_{k|k}.$$
(4.3.56)

Gleichung (4.3.56) nach der äquivalenten Messung  $\mathbf{z}_k^*$  aufgelöst ergibt:

$$\mathbf{z}_{k}^{*} = \hat{\mathbf{x}}_{k|k-l} + \mathbf{K}_{k}^{*-1} \left[ \hat{\mathbf{x}}_{k|k} - \hat{\mathbf{x}}_{k|k-l} \right].$$

$$(4.3.57)$$

Die äquivalente Innovation oder das äquivalente Residuum  $\boldsymbol{\gamma}_k^*$  berechnet sich wie folgt:

$$\boldsymbol{\gamma}_k^* = \mathbf{z}_k^* - \hat{\mathbf{x}}_{k|k-l} \tag{4.3.58}$$

$$=\mathbf{K}_{k}^{*-1}\left[\hat{\mathbf{x}}_{k|k}-\hat{\mathbf{x}}_{k|k-l}\right]$$
(4.3.59)

und die Kovarianz des äquivalenten Residuums ist:

$$\mathbf{S}_k^* = \mathbf{P}_{k|k-l} + \mathbf{R}_k^*. \tag{4.3.60}$$

Eine numerisch stabilere Berechnung von Gleichung (4.3.60) wird in [9] hergeleitet:

$$\mathbf{S}_{k}^{*-1} = \mathbf{P}_{k|k-l}^{-1} - \mathbf{P}_{k|k-l}^{-1} \left[ \mathbf{P}_{k|k-l}^{-1} + \mathbf{R}_{k}^{*-1} \right]^{-1} \mathbf{P}_{k|k-l}^{-1}.$$
 (4.3.61)

Die OOS-Messung liegt zwischen der äquivalenten Messung zum Zeitpunkt  $t_k$  und der Messung zum Zeitpunkt  $t_{k-l}$ . Im Folgenden kann deshalb die Ein-Schritt-Lösung der Innovation (siehe Abschnitt 4.3.1) mit der äquivalenten Messung benutzt werden. Die Retrodiktion vom Zeitpunkt  $t_k$  zum Zeitpunkt der OOS-Messung  $t_{k_0}$  berechnet sich dann:

$$\hat{\mathbf{x}}_{k_0|k} = \mathbf{F}_{k_0,k} \left[ \hat{\mathbf{x}}_{k|k} - \mathbf{Q}_{k,k_0} \mathbf{S}_k^{*-1} \boldsymbol{\gamma}_k^* \right].$$
(4.3.62)

Analog zum Ein-Schritt-Fall aus Gleichung (4.3.30) ergeben sich die Kovarianzen wie folgt:

$$\mathbf{P}_{k,k_0|k}^{vv} = \mathbf{Q}_{k,k_0} - \mathbf{Q}_{k,k_0} \mathbf{S}_k^{*-1} \mathbf{Q}_{k,k_0}, \qquad (4.3.63)$$

$$\mathbf{P}_{k,k_0|k}^{\mathbf{xv}} = \mathbf{Q}_{k,k_0} - \mathbf{P}_{k|k-1} \mathbf{S}_k^{*-1} \mathbf{Q}_{k,k_0}.$$
(4.3.64)

Die Kovarianz der Retrodiktion ist somit:

$$\mathbf{P}_{k_0|k} = \mathbf{F}_{k_0,k} \left[ \mathbf{P}_{k|k} - \mathbf{P}_{k,k_0|k}^{\mathbf{xv}} - \left( \mathbf{P}_{k,k_0|k}^{\mathbf{xv}} \right)^T + \mathbf{P}_{k,k_0|k}^{\mathbf{vv}} \right] \mathbf{F}_{k_0,k}^T.$$
(4.3.65)

Nach der Retrodiktion der Systemzustände und der Schätzfehlerkovarianz wird die OOS-Messung integriert. Die zur OOS-Messung gehörende Kovarianz ist gegeben durch:

$$\mathbf{S}_{k_0} = \mathbf{H}_{k_0} \mathbf{P}_{k_0|k} \mathbf{H}_{k_0}^T + \mathbf{R}_{k_0}.$$
(4.3.66)

Die Kovarianz zwischen dem Zustand im Zeitpunkt  $t_k$  und der OOS-Messung ist:

$$\mathbf{P}_{k,k_0|k}^{\mathbf{xz}} = \left[\mathbf{P}_{k|k} - \mathbf{P}_{k,k_0|k}^{\mathbf{xv}}\right] \mathbf{F}_{k_0,k}^T \mathbf{H}_{k_0}^T.$$
(4.3.67)

Die Kalman-Verstärkungsmatrix wird wie folgt berechnet:

$$\mathbf{W}_{k_0} = \mathbf{P}_{k,k_0|k}^{\mathbf{x}\mathbf{z}} \mathbf{S}_{k_0}^{-1}.$$
 (4.3.68)

Schließlich können die Systemzustände zum Zeitpunkt  $t_k$  direkt mit der OOS-Messung aktualisiert werden:

$$\hat{\mathbf{x}}_{k|k_0} = \hat{\mathbf{x}}_{k|k} + \mathbf{W}_{k_0} \left[ \mathbf{z}_{k_0} - \mathbf{H}_{k_0} \hat{\mathbf{x}}_{k_0|k} \right].$$
(4.3.69)

Die Innovation der Schätzfehlerkovarianz  $t_k$  wird berechnet mit:

$$\mathbf{P}_{k|k_0} = \mathbf{P}_{k|k} - \mathbf{P}_{k,k_0|k}^{\mathbf{x}\mathbf{z}} \mathbf{S}_{k_0}^{-1} \left( \mathbf{P}_{k,k_0|k}^{\mathbf{x}\mathbf{z}} \right)^T.$$
(4.3.70)

Der zeitliche Ablauf des Algorithmus für das Mehr-Schritt-Problem ist in Abbildung 4.8 dargestellt.



**Abbildung 4.8:** Retrodiktion und Innovation für ein 3-Schritt-OOSM-Problem zum Zeitpunkt  $t_{k_0}$ .

Es ist zu beachten, dass der in diesem Abschnitt vorgestellte Algorithmus nur eine Approximation darstellt. Das Rauschen  $\mathbf{w}_k^*$  der äquivalenten Messung korreliert mit dem Prozessrauschen und verletzt somit eine Voraussetzung des Kalmanfilters. Dies hat zur Folge, dass das Prozessrauschen  $\hat{\mathbf{v}}_{k,k_0|k}$  fehlerhaft berechnet wird. Im weiteren Verlauf der Arbeit wird jedoch gezeigt, dass dieser Fehler in praktischen Fällen vernachlässigt werden kann.

Die suboptimalen Algorithmen des Ein-Schritt-Verfahrens können analog bei einem Mehr-Schritt-Problem mit äquivalenter Messung angewendet werden. Die einzelnen Schritte der Retrodiktion für ein l-Schritt-Problem sind in Tabelle 4.4 zusammengefasst.

### 4.3.3 Eigenschaften der Retrodiktion

### Invertierbarkeit der Systemmatrix $\mathbf{F}_{k,k_0}$

Die oben beschriebene Retrodiktion setzt die Invertierbarkeit der Systemmatrix voraus. Dass dies in den hier betrachteten Anwendungsfällen zutrifft, hat folgenden Grund: In (3.3.8) wurde die Herleitung der Systemmatrix gegeben:

$$\mathbf{x}(t_k) = e^{\mathbf{A}\Delta t} \mathbf{x}(t_{k-1}) = \mathbf{F}_k \mathbf{x}(t_{k-1}).$$
(4.3.71)

Die Transitionsmatrix  $\mathbf{F}_k$  wird in der Praxis mit einer Taylorreihenentwicklung berechnet, wobei nach einem der ersten Glieder abgebrochen wird, wie in (3.3.9) beschrieben wurde:

$$\mathbf{F}_{k} = \mathbf{F}(\Delta t) = e^{\mathbf{A}\Delta t} = \mathbf{I} + \mathbf{A}\Delta t + \frac{(\mathbf{A}\Delta t)^{2}}{2!} + \dots + \frac{(\mathbf{A}\Delta t)^{n}}{n!} + \dots$$
(4.3.72)

Die Invertierbarkeit der Matrix  $\mathbf{F}_k$  ist somit für die OOSM-Algorithmen immer garantiert, solange die Systemgleichungen von einem realen linearen System abgeleitet sind.

Äquivalente Messung
$\mathbf{p}^{*-1}$ $\mathbf{p}^{-1}$ $\mathbf{p}^{-1}$
$\mathbf{R}_{k} = \mathbf{P}_{k k} - \mathbf{P}_{k k-l}$
$\mathbf{K}_k^* = \mathbf{P}_{k k} \mathbf{R}_k^{*-1}$
$oldsymbol{\gamma}_k^* = \mathbf{K}_k^{*-1} \left[ \mathbf{\hat{x}}_{k k} - \mathbf{\hat{x}}_{k k-l}  ight]$ ,
$\mathbf{S}_{k}^{*-1} = \mathbf{P}_{k k-l}^{-1} - \mathbf{P}_{k k-l}^{-1} \left[ \mathbf{P}_{k k-l}^{-1} + \mathbf{R}_{k}^{*-1} \right]^{-1} \mathbf{P}_{k k-l}^{-1}$
Retrodiktion
$\hat{\mathbf{x}}_{k_0 k} = \mathbf{F}_{k_0,k} [\hat{\mathbf{x}}_{k k} - \mathbf{Q}_{k,k_0} \mathbf{S}_k^{*-1} oldsymbol{\gamma}_k^*]$
$\mathbf{P}_{k,k_0 k}^{\mathbf{vv}} = \mathbf{Q}_{k,k_0} - \mathbf{Q}_{k,k_0} \mathbf{S}_k^{*-1} \mathbf{Q}_{k,k_0}$
$\mathbf{P}_{k,k_0 k}^{\mathbf{xv}} = \mathbf{Q}_{k,k_0} - \mathbf{P}_{k k-l}\mathbf{S}_k^{*-1}\mathbf{Q}_{k,k_0}$
$\mathbf{P}_{k_0 k} = \mathbf{F}_{k_0,k} \left[ \mathbf{P}_{k k} + \mathbf{P}_{k,k_0 k}^{\mathbf{vv}} - \mathbf{P}_{k,k_0 k}^{\mathbf{xv}} - \left( \mathbf{P}_{k,k_0 k}^{\mathbf{xv}} \right)^T \right] \mathbf{F}_{k_0,k}^T$
OOSM-Innovation
$\mathbf{S}_{k_0} = \mathbf{H}_{k_0} \mathbf{P}_{k_0 k} \mathbf{H}_{k_0}^T + \mathbf{R}_{k_0}$
$\mathbf{P}_{k,k_{0} k}^{\mathbf{xz}} = \left[\mathbf{P}_{k k} - \mathbf{P}_{k,k_{0} k}^{\mathbf{xv}} ight]\mathbf{F}_{k_{0},k}^{T}\mathbf{H}_{k_{0}}^{T}$
$ar{\mathbf{W}}_{k_0} = \mathbf{P}_{k,k_0 k}^{\mathbf{xz}} \mathbf{S}_{k_0}^{-1}$
$\mathbf{\hat{x}}_{k k_0} = \mathbf{\hat{x}}_{k k} + \mathbf{W}_{k_0} \left[ \mathbf{z}_{k_0} - \mathbf{H}_{k_0} \mathbf{\hat{x}}_{k_0 k}  ight]_T$
$\mathbf{P}_{k k_0} = \mathbf{P}_{k k} - \mathbf{P}^{\mathbf{xz}}_{k,k_0 k} \mathbf{S}^{-1}_{k_0} \left(\mathbf{P}^{\mathbf{xz}}_{k,k_0 k} ight)^{\mathbf{z}}$

**Tabelle 4.4:** Zusammenfassung der Gleichungen für die Retrodiktion mit äquivalenter Messung im *l*-Schritt-Fall.

#### Kontinuierliches Prozessrauschen

Zu beachten ist, dass das Verfahren zur Retrodiktion mit einem zeitkontinuierlichen weißen Prozessrauschen [10, S. 268ff.] modelliert werden muss. Nur so ist eine korrekte Prädiktion in die Vergangenheit möglich, da bei einem diskreten Prozessrauschen nachträglich keine Zwischenschritte definiert werden können, was bei OOS-Messungen nötig ist. Abbildung 4.9 zeigt das zeitliche Verhalten des Prozessmodells.



Abbildung 4.9: Prozessmodell mit zeitkontinuierlichem weißem Prozessrauschen, bei dem OOS-Messungen nachträglich integriert werden können.

Das zeitkontinuierliche weiße Rauschen führt zu folgender notwendiger Identität:

$$\mathbf{Q}_{k,k-1} \stackrel{!}{=} \mathbf{Q}_{k_0,k-1} + \mathbf{F}_{k_0,k-1} \mathbf{Q}_{k,k_0} \mathbf{F}_{k_0,k-1}^T.$$
Durch das kontinuierliche Modell wird garantiert, dass das Prozessrauschen in mehreren unterschiedlichen Zeitschritten in das Filter integriert werden kann. Die konkrete Realisierung dieses Prozessmodells wurde im Abschnitt 3.3.1 beschrieben.

# 4.4 Vorwärts-Prädiktion mit Fusion und Dekorrelation

Die Vorwärts-Prädiktion mit Fusion und Dekorrelation (*engl.* "Forward-Prediction Fusion and Decorrelation", FPFD) [114] ist ein weiterer Ansatz zur Lösung des OOSM-Problems. Durch die Unterteilung des Algorithmus in zwei Schritte, einen Prädiktionsschritt und einen Fusions- und Dekorrelationsschritt, ist dieser Ansatz auch unter dem Namen Zwei-Schritt-Methode (*engl.* "Two-Step Method") [77] bekannt.

## 4.4.1 Herleitung

Bei FPFD wird im Gegensatz zur Retrodiktion keine Prädiktion vom Zeitpunkt  $t_k$  in die Vergangenheit, sondern eine Prädiktion von  $t_{k-l}$  zum aktuellen Zeitpunkt durchgeführt und anschließend mit einer Fusions- und Dekorrelationsalgorithmik die OOS-Messung integriert. Für den Zeitpunkt der OOS-Messung  $t_{k_0}$  gilt:

$$t_{k-l} < t_{k_0} < t_{k-l+1}. (4.4.1)$$

Abbildung 4.10 zeigt den zeitlichen Ablauf des FPFD-Algorithmus. Im folgenden Abschnitt werden die einzelnen Signalverarbeitungsschritte genau erläutert. Im ersten Schritt des FPFD-Algorithmus wird eine Prädiktion vom Zeitpunkt  $t_{k-l}$  zum Zeitpunkt der OOS-Messung  $t_{k_0}$  durchgeführt:

$$\hat{\mathbf{x}}_{k_0|k-l} = \mathbf{F}_{k_0,k-l} \hat{\mathbf{x}}_{k-l|k-l}, \qquad (4.4.2)$$

$$\mathbf{P}_{k_0|k-l} = \mathbf{F}_{k_0,k-l} \mathbf{P}_{k-l|k-l} \mathbf{F}_{k_0,k-l}^T + \mathbf{Q}_{k_0,k-l}.$$
(4.4.3)

Dafür müssen alte Systemzustände und Kovarianzen gespeichert werden. Zum Zeitpunkt  $t_{k_0}$  wird die OOS-Messung mit der Innovation des Standard-Kalmanfilters integriert:

$$\mathbf{S}_{k_0} = \mathbf{H}_{k_0} \mathbf{P}_{k_0|k-l} \mathbf{H}_{k_0}^T + \mathbf{R}_{k_0}, \qquad (4.4.4)$$

$$\mathbf{K}_{k_0} = \mathbf{P}_{k_0|k-l} \mathbf{H}_{k_0}^T \mathbf{S}_{k_0}^{-1}, \qquad (4.4.5)$$

$$\hat{\mathbf{x}}_{k_0|k-l,k_0} = \hat{\mathbf{x}}_{k_0|k-l} + \mathbf{K}_{k_0} \left[ \mathbf{z}_{k_0} - \mathbf{H}_{k_0} \hat{\mathbf{x}}_{k_0|k-l} \right], \qquad (4.4.6)$$

$$\mathbf{P}_{k_0|k-l,k_0} = \mathbf{P}_{k_0|k-l} - \mathbf{K}_{k_0} \mathbf{S}_{k_0} \mathbf{K}_{k_0}^T.$$
(4.4.7)

Im nächsten Schritt werden zwei Prädiktionen parallel durchgeführt. Zum einen wird vom Zeitpunkt  $t_{k_0}$  ohne Integration der OOS-Messung zum aktuellen Zeitpunkt  $t_k$  prädiziert:

$$\hat{\mathbf{x}}_{k|k-l} = \mathbf{F}_{k,k_0} \hat{\mathbf{x}}_{k_0|k-l},\tag{4.4.8}$$

$$\mathbf{P}_{k|k-l} = \mathbf{F}_{k,k_0} \hat{\mathbf{P}}_{k_0|k-l} \mathbf{F}_{k,k_0}^T + \mathbf{Q}_{k,k_0}$$
(4.4.9)



Abbildung 4.10: Prädiktionen und Innovationen beim FPFD-Algorithmus.

und zum anderen wird mit integrierter OOS-Messung vom Zeitpunkt  $t_{k_0}$  zum aktuellen Zeitpunkt  $t_k$  prädiziert:

$$\hat{\mathbf{x}}_{k|k-l,k_0} = \mathbf{F}_{k,k_0} \hat{\mathbf{x}}_{k_0|k-l,k_0}, \qquad (4.4.10)$$

$$\mathbf{P}_{k|k-l,k_0} = \mathbf{F}_{k,k_0} \hat{\mathbf{P}}_{k_0|k-l,k_0} \mathbf{F}_{k,k_0}^T + \mathbf{Q}_{k,k_0}.$$
(4.4.11)

Die Schreibweise des Index  $k|k - l, k_0$  gibt an, dass zuerst vom Zeitpunkt  $t_{k-l}$  zum Zeitpunkt  $t_{k_0}$  prädiziert wird, die OOS-Messung  $\mathbf{z}_{k_0}$  integriert wird und anschließend noch eine Prädiktion zum Zeitpunkt  $t_k$  stattfindet. Wie in [77] vorgestellt wurde, können die Prädiktionen aus den Gleichungen (4.4.8) bis (4.4.11) auch von Zeitpunkt  $t_{k-l+1}$  zu  $t_{k_0}$  erfolgen, um danach einmal mit integrierter OOS-Messung und einmal ohne Integration zum Zeitpunkt  $t_k$  zu prädizieren. Aufgrund der folgenden Dekorrelation im Zeitschritt  $t_k$  liefert diese Projektion das gleiche Ergebnis und ist nicht zu verwechseln mit einer Retrodiktion. Abbildung 4.10 zeigt schematisch die einzelnen Signalverarbeitungsschritte des Algorithmus.

### Bestimmung der Schätzfehlerkovarianz

Mit Hilfe der Additivität des Informationsfilters aus Gleichung (3.2.29) werden die beiden Schätzfehlerkovarianzen aus den Gleichungen (4.4.9) und (4.4.11) dekorreliert:

$$\mathbf{P}_{\text{dekorr}}^{-1} = \mathbf{P}_{k|k-l,k_0}^{-1} - \mathbf{P}_{k|k-l}^{-1}.$$
(4.4.12)

Beim Informationsfilter wird die Dekorrelation durch eine Subtraktion und die Fusion durch eine Addition beschrieben. Die Dekorrelation  $\mathbf{P}_{\text{dekorr}}$  extrahiert die Information der OOS-Messung zum Zeitpunkt  $t_k$ . Die Fusion der Kovarianz aus Gleichung (4.4.12) mit der aktuellen Schätzfehlerkovarianz zum Zeitpunkt  $t_k$  ergibt die gesuchte Kovarianz mit integrierter OOS-Messung:

$$\mathbf{P}_{k|k_0}^{-1} = \mathbf{P}_{k|k}^{-1} + \mathbf{P}_{\text{dekorr}}^{-1}.$$
 (4.4.13)

Die Gleichungen (4.4.12) und (4.4.13) können auch nach [52] wie folgt hergeleitet werden:

$$\mathbf{P}_{k|k}^{-1} = \mathbf{P}_{k|k-l}^{-1} + \mathbf{H}_{k}^{T} \mathbf{R}_{k}^{*-1} \mathbf{H}_{k}.$$
(4.4.14)

Dabei ist  $\mathbf{R}_k^*$  die Kovarianzmatrix des Messrauschens der äquivalenten Messung für das Intervall  $[t_{k-l}, t_k]$ . Die Gleichung (4.4.14) wird durch das inverse Kovarianzfilter [23] beschrieben. Eine ähnliche Gleichung kann auch mit integrierter OOS-Messung aufgestellt werden:

$$\mathbf{P}_{k|k_0}^{-1} = \mathbf{P}_{k|k-l,k_0}^{-1} + \mathbf{H}_k^T \mathbf{R}_k^{*-1} \mathbf{H}_k.$$
(4.4.15)

Gleichung (4.4.14) in Gleichung (4.4.15) eingesetzt ergibt:

$$\mathbf{P}_{k|k_0}^{-1} = \mathbf{P}_{k|k}^{-1} + \mathbf{P}_{k|k-l,k_0}^{-1} - \mathbf{P}_{k|k-l}^{-1}.$$
(4.4.16)

Wiederum kann die Subtraktion der Schätzfehlerkovarianz als Dekorrelation und die Addition als Fusion interpretiert werden.

### Bestimmung der Systemzustände

Im Folgenden wird nun auf die Herleitung der Gleichungen der Systemzustände eingegangen. Die äquivalente Verstärkungsmatrix des Kalmanfilters von  $t_{k-l}$  nach  $t_k$  wird wie in Gleichung (4.3.55) angegeben mit:

$$\mathbf{K}_{k}^{*}\mathbf{H}_{k} = \mathbf{P}_{k|k}\mathbf{H}_{k}^{T}\mathbf{R}_{k}^{*-1}\mathbf{H}_{k}.$$
(4.4.17)

Diese Form der Kalman-Verstärkungsmatrix wird auch bei zeitkontinuierlichen Systemen wie dem Kalman-Bucy-Filter [10, 122] benutzt. Gleichung (4.4.14) eingesetzt in Gleichung (4.4.17) ergibt:

$$\mathbf{K}_{k}^{*}\mathbf{H}_{k} = \mathbf{P}_{k|k} \left( \mathbf{P}_{k|k}^{-1} - \mathbf{P}_{k|k-l}^{-1} \right)$$
$$= \mathbf{I} - \mathbf{P}_{k|k}\mathbf{P}_{k|k-l}^{-1}.$$
(4.4.18)

Die Standard-Kalmanfilter-Innovation kann wie folgt umgeschrieben werden:

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-l} + \mathbf{K}_{k}^{*} \left( \mathbf{z}_{k}^{*} - \mathbf{H}_{k} \hat{\mathbf{x}}_{k|k-l} \right) \\
= \left( \mathbf{I} - \mathbf{K}_{k}^{*} \mathbf{H}_{k} \right) \hat{\mathbf{x}}_{k|k-l} + \mathbf{K}_{k}^{*} \mathbf{z}_{k}^{*}.$$
(4.4.19)

Dabei ist  $\mathbf{z}_k^*$  die äquivalente Messung, auch Pseudomessung genannt, die alle Messungen zwischen  $t_{k-1}$  und  $t_k$  zusammenfasst. Eine Umformung von Gleichung (4.4.19) ergibt:

$$\mathbf{K}_{k}^{*}\mathbf{z}_{k}^{*} = \hat{\mathbf{x}}_{k|k} - \left(\mathbf{I} - \mathbf{K}_{k}^{*}\mathbf{H}_{k}\right)\hat{\mathbf{x}}_{k|k-l}.$$
(4.4.20)

Die äquivalente Verstärkungsmatrix des Kalmanfilters von  $t_{k-l}$  nach  $t_k$  mit integrierter OOS-Messung wird analog zur Gleichung (4.4.17) angegeben mit:

$$\mathbf{K}_{k_{0}}^{*}\mathbf{H}_{k_{0}} = \mathbf{P}_{k|k_{0}}\mathbf{H}_{k}^{T}\mathbf{R}_{k}^{*-1}\mathbf{H}_{k} 
= \mathbf{P}_{k|k_{0}}\left(\mathbf{P}_{k|k}^{-1} - \mathbf{P}_{k|k-l}^{-1}\right) 
= \mathbf{P}_{k|k_{0}}\left(\mathbf{P}_{k|k_{0}}^{-1} - \mathbf{P}_{k|k-l,k_{0}}^{-1}\right) 
= \mathbf{I} - \mathbf{P}_{k|k_{0}}\mathbf{P}_{k|k-l,k_{0}}^{-1}.$$
(4.4.21)

Aus Gleichung (4.4.20) ergibt sich:

$$\mathbf{K}_{k_0}^* \mathbf{z}_k^* = \mathbf{P}_{k|k_0} \mathbf{P}_{k|k}^{-1} \mathbf{K}_k^* \mathbf{z}_k^*.$$
(4.4.22)

Die Innovation der Systemzustände wird beschrieben mit:

$$\hat{\mathbf{x}}_{k|k_{0}} = \left(\mathbf{I} - \mathbf{K}_{k_{0}}^{*}\mathbf{H}_{k_{0}}\right)\hat{\mathbf{x}}_{k|k-l,k_{0}} + \mathbf{K}_{k_{0}}^{*}\mathbf{z}_{k}^{*} \\
= \left(\mathbf{I} - \mathbf{I} + \mathbf{P}_{k|k_{0}}\mathbf{P}_{k|k-l,k_{0}}^{-1}\right)\hat{\mathbf{x}}_{k|k-l,k_{0}} + \mathbf{P}_{k|k_{0}}\mathbf{P}_{k|k}^{-1}\left(\hat{\mathbf{x}}_{k|k} - (\mathbf{I} - \mathbf{K}_{k}^{*}\mathbf{H}_{k})\hat{\mathbf{x}}_{k|k-l}\right) \\
= \mathbf{P}_{k|k_{0}}\mathbf{P}_{k|k-l,k_{0}}^{-1}\hat{\mathbf{x}}_{k|k-l,k_{0}} + \underbrace{\mathbf{P}_{k|k_{0}}\mathbf{P}_{k|k}^{-1}\left(\hat{\mathbf{x}}_{k|k} - \mathbf{P}_{k|k}\mathbf{P}_{k|k-l}^{-1}\hat{\mathbf{x}}_{k|k-l}\right)}_{\text{Dekorrelation}}.$$
(4.4.23)

Aufgrund der Dekorrelations- und Fusionsarchitektur wird dieser Algorithmus "Vorwärts-Prädiktion mit Fusion und Dekorrelation" genannt. Die dazugehörigen Gleichungen sind in Tabelle 4.5 zusammengefasst. Wie man sieht, werden nur Prädiktionen in die Zukunft ohne Retrodiktionen verwendet, was keine spezielle Berücksichtigung des Prozessrauschens erforderlich macht. Im Unterschied zur Retrodiktion im Ein-Schritt-Fall sind jedoch deutlich mehr Invertierungen vorhanden. Die äquivalente Messung wird nur für die theoretische Herleitung benötigt und muss in der Praxis nicht berechnet werden. Im folgenden Abschnitt wird anhand der Schätzfehlerkovarianz begründet, warum der FPFD-Algorithmus im Ein-Schritt-Fall die exakte Lösung liefert.

Prädiktion	
$\mathbf{\hat{x}}_{k_0 k-l} = \mathbf{F}_{k_0,k-l}\mathbf{\hat{x}}_{k-l k-l} \ \mathbf{P}_{k_0 k-l} = \mathbf{F}_{k_0,k-l}\mathbf{P}_{k-l k-l}\mathbf{F}_{k_0,k-l}^T + \mathbf{Q}_{k_0,k-l}$	
Innovation	
$ \begin{split} \mathbf{S}_{k_0} = \mathbf{H}_{k_0} \mathbf{P}_{k_0 k-l} \mathbf{H}_{k_0}^T + \mathbf{R}_{k_0} \\ \mathbf{K}_{k_0} = \mathbf{P}_{k_0 k-l} \mathbf{H}_{k_0}^T \mathbf{S}_{k_0}^{-1} \\ \mathbf{\hat{x}}_{k_0 k-l,k_0} = \mathbf{\hat{x}}_{k_0 k-l} + \mathbf{K}_{k_0} \left[ \mathbf{z}_{k_0} - \mathbf{H}_{k_0} \mathbf{\hat{x}}_{k_0 k-l} \right] \\ \mathbf{P}_{k_0 k-l,k_0} = \mathbf{P}_{k_0 k-l} - \mathbf{K}_{k_0} \mathbf{S}_{k_0} \mathbf{K}_{k_0}^T \end{split} $	
Vorwärts-Prädiktion	
$\begin{split} \mathbf{\hat{x}}_{k k-l,k_0} &= \mathbf{F}_{k,k_0} \mathbf{\hat{x}}_{k_0 k-l,k_0} \\ \mathbf{P}_{k k-l,k_0} &= \mathbf{F}_{k,k_0} \mathbf{P}_{k_0 k-l,k_0} \mathbf{F}_{k,k_0}^T + \mathbf{Q}_{k,k_0} \\ \mathbf{\hat{x}}_{k k-l} &= \mathbf{F}_{k,k_0} \mathbf{\hat{x}}_{k_0 k-l} \\ \mathbf{P}_{k k-l} &= \mathbf{F}_{k,k_0} \mathbf{P}_{k_0 k-l} \mathbf{F}_{k,k_0}^T + \mathbf{Q}_{k,k_0} \end{split}$	
Dekorrelation und Fusion	
$\mathbf{P}_{k k_0}^{-1} = \mathbf{P}_{k k}^{-1} + \mathbf{P}_{k k-l,k_0}^{-1} - \mathbf{P}_{k k-l}^{-1}$ $\mathbf{\hat{x}}_{k k_0} = \mathbf{P}_{k k_0} \left( \mathbf{P}_{k k}^{-1} \mathbf{\hat{x}}_{k k} + \mathbf{P}_{k k-l,k_0}^{-1} \mathbf{\hat{x}}_{k k-l,k_0} - \mathbf{P}_{k k-l}^{-1} \mathbf{\hat{x}}_{k k-l} \right)$	

Tabelle 4.5: Zusammenfassung der Gleichungen für den FPFD-Algorithmus.

## 4.4.2 Optimale Lösung

Der im vorherigen Abschnitt vorgestellte FPFD-Algorithmus stellt für das Ein-Schritt-OOSM-Problem die exakte Lösung dar. Folgende Gleichungen wurden zur Bestimmung der Schätzfehlerkovarianz verwendet:

$$\mathbf{P}_{k|k}^{-1} = \mathbf{P}_{k|k-l}^{-1} + \mathbf{H}_{k}^{T} \mathbf{R}_{k}^{*-1} \mathbf{H}_{k}$$
(4.4.24)

$$\mathbf{P}_{k|k_0}^{-1} = \mathbf{P}_{k|k-l,k_0}^{-1} + \mathbf{H}_k^T \mathbf{R}_k^{*-1} \mathbf{H}_k.$$
(4.4.25)

Es ist leicht zu zeigen, dass das Filter für die Kovarianzen bei l = 1 keine Approximation darstellt. In diesem Fall ist die Messung  $\mathbf{z}_k^*$  keine äquivalente Messung, sondern die exakte Messung zum Zeitpunkt  $t_k$  und es gilt  $\mathbf{R}_k^* = \mathbf{R}_k$ . Somit ergibt sich im Ein-Schritt-Fall die exakte Innovation zu:

$$\mathbf{P}_{k|k_0}^{-1} = \mathbf{P}_{k|k}^{-1} + \left(\mathbf{P}_{k|k-1,k_0}^{-1} - \mathbf{P}_{k|k-1}^{-1}\right).$$
(4.4.26)

Die analoge Beweisführung für die Systemzustände ist in [77] gegeben.

Somit liefert der FPFD-Algorithmus ebenso wie die Retrodiktion die exakte Lösung nur für das Ein-Schritt-Problem und eine approximierte Lösung für das l-Schritt-Problem. Im Gegensatz zur Retrodiktion sind die Gleichungen des FPFD-Algorithmus jedoch nicht von der Schrittweite l abhängig. Aus diesem Grund gelten beim FPFD-Algorithmus für das l-Schritt-Problem dieselben Gleichungen wie für das Ein-Schritt-Problem.

Im Unterschied zur Retrodiktion ist beim FPFD-Algorithmus ein kontinuierliches Prozessmodell keine notwendige Bedingung. Es erfolgen nur Prädiktionen in die Zukunft und daher ist auch ein diskretes Prozessmodell verwendbar. Dies führt zu einer erhöhten Flexibilität des FPFD-Algorithmus in Bezug auf die Wahl der Modelle. Weitere Vor- und Nachteile des FPFD-Algorithmus im Vergleich zu Retrodiktion, Messdatenverzögerung und Reprozessierung werden im folgenden Abschnitt näher analysiert.

# 4.5 Komplexitätsanalysen

In den vorherigen Abschnitten wurden zwei Verfahren zur Integration von nicht chronologischen Sensordaten vorgestellt. Beide Verfahren haben das Ziel, die gleichen Zustandsschätzungen wie bei einer Reprozessierung zu erreichen, jedoch mit geringerem Rechen- und Speicheraufwand. Daher wird in diesem Abschnitt eine Komplexitätsanalyse durchgeführt und für die Algorithmen die Anzahl der Additionen, Multiplikationen und Invertierungen bestimmt. Zusätzlich wird der Speicheraufwand in einem bewertenden Vergleich gegenübergestellt. Dies ermöglicht eine hardwareunabhängige Bewertung. Die reale Komplexität für ein spezifisches Steuergerät kann mit einer entsprechenden Kostenfunktion berechnet werden.

# 4.5.1 Rechenaufwand

Im ersten Teil wird der Rechenaufwand der Algorithmen untersucht. Hierzu wird die Anzahl der Additionen, Multiplikationen und Invertierungen jedes einzelnen Signalverarbeitungsschritts berechnet. Für folgende Prädiktionsgleichung

$$\hat{\mathbf{x}}_{k|k-1} = \mathbf{F}_{k,k-1} \hat{\mathbf{x}}_{k-1|k-1} \tag{4.5.1}$$

würde beispielsweise die Berechnung bei einem vierdimensionalen Zustandsraum wie folgt lauten:

$$\begin{bmatrix} a_{11} & a_{12} & a_{13} & a_{14} \\ a_{21} & a_{22} & a_{23} & a_{24} \\ a_{31} & a_{32} & a_{33} & a_{34} \\ a_{41} & a_{42} & a_{43} & a_{44} \end{bmatrix} \begin{bmatrix} b_{11} \\ b_{12} \\ b_{13} \\ b_{14} \end{bmatrix} = \begin{bmatrix} a_{11}b_{11} + a_{12}b_{12} + a_{13}b_{13} + a_{14}b_{14} \\ a_{21}b_{11} + a_{22}b_{12} + a_{23}b_{13} + a_{24}b_{14} \\ a_{31}b_{11} + a_{32}b_{12} + a_{33}b_{13} + a_{34}b_{14} \\ a_{41}b_{11} + a_{42}b_{12} + a_{43}b_{13} + a_{44}b_{14} \end{bmatrix}.$$
(4.5.2)

Es werden  $3 \times 4 = 12$  Additionen und  $4 \times 4 = 16$  Multiplikationen ausgeführt. Im allgemeinen Fall bei einer  $N \times N$ -Matrix und einem  $N \times 1$ -Vektor werden N(N-1) Additionen und  $N^2$  Multiplikationen benötigt. Dabei ist N Dimension des Zustandsraums; die Dimension des Messraums wird im Folgenden mit M bezeichnet.

Der Rechenaufwand wird üblicherweise in Form von arithmetischen Operationen (a.Op.) gemessen. Eine arithmetische Operation setzte sich früher zusammen aus einer Multiplikation und einer Addition. Diese Unterscheidung zwischen Additionen und Multiplikationen hatte technische Gründe, da die Berechnung einer Multiplikation auf älteren Prozessoren deutlich mehr Rechenzeit in Anspruch nahm als eine Addition [111]. Inzwischen hat sich dieser Unterschied jedoch relativiert, so dass in der vorliegenden Arbeit eine arithmetische Operation als eine Addition *oder* eine Multiplikation definiert wird. Im oben beschriebenen Beispiel einer Matrixmultiplikation würden sich somit  $N(N-1)+N^2$  arithmetische Operationen ergeben, in abkürzender Schreibweise  $\mathcal{O}(N^2)$  mit der üblichen Landau-Notation  $\mathcal{O}$ .

Der Aufwand für die Berechnung der Inversen hängt von der Implementierung ab, bei einem gängigen Inversionsalgorithmus übersteigt die Komplexität jedoch nicht  $\mathcal{O}(N^3)$ . Beispielsweise beträgt der Aufwand beim Gauß-Jordan-Algorithmus  $2N^3 + \mathcal{O}(N^2)$ , siehe z.B. [111].

Im Folgenden wird die genaue Anzahl an arithmetischen Operationen für jeweils einen Filterzyklus von Messdatenverzögerung, Reprozessierung, Retrodiktion sowie FPFD verglichen. Die Symmetrieeigenschaften der Kovarianzmatrizen werden in diesem Kapitel nicht berücksichtigt, könnten jedoch zur Kostenreduktion verwendet werden. Außerdem ist zu beachten, dass es sich nur um die Filterung ohne Mehrobjektverfolgung handelt. Bei Hinzunahme z.B. einer Datenassoziation vervielfältigt sich der Aufwand. Dies verlangsamt insbesondere die Reprozessierung noch mehr, da hierbei die Filterzyklen mehrmals durchlaufen werden müssen.

### Messdatenverzögerung

Die Messdatenverzögerung stellt die effizienteste Methode dar, nicht chronologische Sensordaten in das Kalmanfilter zu integrieren. Durch eine Zwischenspeicherung wird erreicht, dass jede Messung nur einmal integriert werden muss. Die Realisierung erfolgt mit dem Standard-Kalmanfilter, das heißt, alle Messungen – auch die OOS-Messung – werden auf die gleiche Art und Weise verarbeitet.

Die berechnete Anzahl an arithmetischen Operationen für die Messdatenverzögerung ist in Tabelle 4.6 abgebildet. Dabei wird jede Gleichung der Prädiktion und Innovation des Standard-Kalmanfilters aus Tabelle 4.1 berücksichtigt. Man sieht, dass der Gesamtaufwand der Berechnung  $\mathcal{O}(N^3)$  beträgt, wenn man  $N \geq M$  annimmt. Die detaillierteren Werte sind in der Tabelle zusammengefasst und werden im Folgenden mit dem Aufwand von Reprozessierung, Retrodiktion und FPFD verglichen.

Berechnung	Additionen	Multiplikationen	Invertierungen
$\mathbf{\hat{x}}_{k k-1}$	N(N-1)	$N^2$	-
$\mathbf{P}_{k k-1}$	$N^2(2N-1)$	$2N^3$	-
$\mathbf{S}_k$	NM(N+M-1)	$N^2M + NM^2$	-
$\mathbf{K}_k$	NM(N+M-2)	$N^2M + NM^2$	$2N^3 + \mathcal{O}(N^2)$
$\mathbf{\hat{x}}_{k k}$	N(M+2)	2NM	-
$\mathbf{P}_{k k}$	NM(N+M-1)	$NM^2 + N^2M$	-

**Tabelle 4.6:** Anzahl an arithmetischen Operationen bei der Messdatenverzögerungmit einem N-dimensionalen Zustandsraum und M-dimensionalen Messraum.

# Reprozessierung

Beim Eintreffen einer Messung außerhalb der zeitlichen Reihenfolge werden bei der Reprozessierung die Zustände auf den Stand vor der OOS-Messung zurückgesetzt. Vom Zeitpunkt dieses gespeicherten Zustandes an werden die Messungen aus dem Speicher in zeitlicher Reihenfolge integriert.

Diese Methode stellt das Verfahren mit dem größten Rechenaufwand dar. Für die Reprozessierung werden die identischen Gleichungen wie bei einer Messdatenverzögerung aus Tabelle 4.1 benutzt. Bei einem Ein-Schritt-Problem werden die Gleichungen beim Eintreffen einer OOS-Messung zweimal hintereinander berechnet und somit verdoppelt sich der Rechenaufwand. Ein l-Schritt-Problem benötigt zur Integration der OOS-Messung dementsprechend l+1 Aufrufe. Somit ergibt sich bei der Reprozessierung der (l+1)-fache Aufwand im Vergleich zur Messdatenverzögerung. Hierbei ist wie bereits erwähnt noch keine Datenassoziation berücksichtigt, was die Kosten weiter in die Höhe treiben würde. Diesen enormen Aufwand gilt es insbesondere bei Echtzeitanforderungen zu reduzieren. Die Komplexität der Reprozessierung ist in Tabelle 4.7 zusammengefasst.

Berechnung	Additionen	Multiplikationen	Invertierungen
$\mathbf{\hat{x}}_{k k-1}$	(l+1)N(N-1)	$(l+1)N^2$	-
$\mathbf{P}_{k k-1}$	$(l+1)N^2(2N-1)$	$(l+1)2N^3$	-
$\mathbf{S}_k$	(l+1)NM(N+M-1)	$(l+1)(N^2M + NM^2)$	-
$\mathbf{K}_k$	(l+1)NM(N+M-2)	$(l+1)(N^2M + NM^2)$	$(l+1)(2N^3 + \mathcal{O}(N^2))$
$\mathbf{\hat{x}}_{k k}$	(l+1)N(M+2)	(l+1)2NM	-
$\mathbf{P}_{k k}$	(l+1)NM(N+M-1)	$(l+1)(NM^2 + N^2M)$	-

**Tabelle 4.7:** Anzahl an arithmetischen Operationen bei der Reprozessierung bei einem l-Schritt-OOSM-Problem. N ist die Dimension des Zustandsraumes und M die Dimension des Messraumes.

### Retrodiktion

Der Vorteil der Retrodiktion ist, dass nur ein Prädiktions- und ein Innovationsschritt zur Integration der OOS-Messung benötigt wird. Im Gegensatz zur Reprozessierung müssen die Messungen zwischen der OOS-Messung und dem aktuellen Zeitpunkt nicht wieder neu in das Kalmanfilter integriert werden. Durch die aufwändigere Retrodiktion und modifizierte Innovation entstehen jedoch zusätzliche Signalverarbeitungsschritte. Die Komplexität des Ein-Schritt-OOSM-Problems ist in Tabelle 4.8 dargestellt.

Berechnung	Additionen	Multiplikationen	Invertierungen
0		1	0
$\mathbf{\hat{x}}_{k_{0} k}$	$N(M^2 + NM + N - 2M + 1)$	N(N+M)(M+1)	$2N^3 + \mathcal{O}(N^2)$
$\mathbf{P}_{k,k_0 k}^{\mathbf{vv}}$	$N(N^2 + M^2 + 2NM - N - 2M)$	$N(N+M)^2$	-
$\mathbf{P}_{k,k_0 k}^{\mathbf{xv}}$	$N(N^2 + M^2 + 2NM - N - 2M)$	$N(N+M)^2$	-
$\mathbf{P}_{k_0 k}$	$N^2(2N+1)$	$2N^3$	-
$\mathbf{S}_{k_0}$	NM(N+M-1)	$N^2M + NM^2$	-
$\mathbf{P}_{k,k_0 k}^{\mathbf{xz}}$	$N(N^2 + NM - M)$	$N^3 + N^2 M$	-
$\mathbf{W}_{k_0}$	NM(M-1)	$NM^2$	$2N^3 + \mathcal{O}(N^2)$
$\mathbf{\hat{x}}_{k k_0}$	N(M+2)	2NM	-
$\mathbf{P}_{k k_0}$	NM(N+M-1)	$NM^2 + N^2M$	-

**Tabelle 4.8:** Anzahl an arithmetischen Operationen bei der Retrodiktion im Ein-Schritt-Fall. N ist die Dimension des Zustandsraumes und M die Dimension des Messraumes.

Im Falle eines Mehr-Schritt- oder l-Schritt-Problems wird zuerst eine äquivalente Messung berechnet und das l-Schritt-Problem auf das Ein-Schritt-Problem zurückgeführt. Durch die Berechnung der äquivalenten Messung steigt die Komplexität, das heißt, es wird eine größere Anzahl an Matrixoperationen benötigt. Aufgrund der Berechnung der äquivalenten Messung von der Größe der Dimension des Zustandraumes ändern sich auch die restlichen Gleichungen aus Tabelle 4.8. Man sieht jedoch im Vergleich mit Tabelle 4.7, dass insbesondere bei großer Schrittweite l die Reprozessierung trotzdem den größeren Aufwand mit sich bringt. Bei der Retrodiktion im l-Schritt-Fall zahlt es sich bei großer

Berechnung	Additionen	Multiplikationen	Invertierungen
$\mathbf{R}_k^{*-1}$	$N^2$	-	$4N^3 + \mathcal{O}(N^2)$
$\mathbf{K}_{k}^{*}$	$N^2(N-1)$	$N^3$	-
$oldsymbol{\gamma}_k^*$	$N^2$	$N^2$	$2N^3 + \mathcal{O}(N^2)$
$\mathbf{S}_{k}^{st-1}$	$2N^3$	$2N^3$	
$\mathbf{\hat{x}}_{k_{0} k}^{''}$	$N(N^2 + N - 1)$	$2N^2 + N^3$	-
$\mathbf{P}_{k,k_0 k}^{\mathbf{v}\mathbf{v}}$	$N^2(2N-1)$	$2N^{3}$	-
$\mathbf{P}_{k,k_0 k}^{\mathbf{xv}}$	$N^2(2N-1)$	$2N^3$	-
$\mathbf{P}_{k_0 k}$	$N^2(2N+1)$	$2N^{3}$	-
$\mathbf{S}_{k_0}$	NM(N+M-1)	$N^2M + NM^2$	-
$\mathbf{P}_{k,k_0 k}^{\mathbf{xz}}$	$N(N^2 + NM - M)$	$N^3 + N^2 M$	-
$\mathbf{W}_{k_0}$	NM(M-1)	$NM^2$	$2N^3 + \mathcal{O}(N^2)$
$\mathbf{\hat{x}}_{k k_0}$	N(M+2)	2NM	-
$\mathbf{P}_{k k_0}$	NM(N+M-1)	$NM^2 + N^2M$	-

l aus, dass die einzelnen Schritte zusammengefasst werden. Eine Zusammenfassung der Kosten beim l-Schritt-OOSM-Problem findet sich in Tabelle 4.9.

**Tabelle 4.9:** Anzahl an arithmetischen Operationen bei der Retrodiktion im l-Schritt-Fall mit äquivalenter Messung. N ist die Dimension des Zustandsraumes und M die Dimension des Messraumes.

### FPFD

Die Komplexität des FPFD-Algorithmus ist in Tabelle 4.10 dargestellt. Wie bei der Retrodiktion kann die OOS-Messung direkt in die Zustandsschätzung integriert werden, ohne ältere Messungen wiederaufbereiten zu müssen. Der FPFD-Algorithmus benötigt die gleiche Anzahl an Invertierungen wie der *l*-Schritt-Retrodiktionsalgorithmus, führt jedoch weniger Additionen und Multiplikationen durch. Insbesondere fällt auf, dass für einen *l*-Schritt-Fall mit FPFD nicht mehr arithmetische Operationen benötigt werden als für einen Ein-Schritt-Fall mit FPFD. Im folgenden Abschnitt wird ein detaillierter Komplexitätsvergleich gegeben.

### Bewertender Vergleich des Rechenaufwands

In Tabelle 4.11 ist die Anzahl der Operationen exemplarisch für einen zweidimensionalen Messraum und einen vierdimensionalen Zustandsraum berechnet, da diese Dimensionen in den praktischen Auswertungen dieser Arbeit vorrangig verwendet wurden. Die erste Zeile berechnet sich mit den Gleichungen aus Tabelle 4.6, die weiteren Zeilen ergeben sich mit den Gleichungen aus Tabelle 4.7, 4.8, 4.9 bzw. 4.10. Anhand des Ergebnisses für das Standard-Kalmanfilter in der ersten Zeile wird die Anzahl der Operationen für die Messdatenverzögerung sowie für die Reprozessierung abgeleitet. Die Reprozessierung benötigt im Falle einer OOS-Messung das (l + 1)-fache für die Zustandsaktualisierung. Für

Berechnung	Additionen	Multiplikationen	Invertierungen
$\mathbf{\hat{x}}_{k_0 k-l}$	N(N-1)	$N^2$	-
$\mathbf{P}_{k_0 k-l}$	$N^2(2N-1)$	$2N^3$	-
$\mathbf{S}_{k_0}$	NM(N+M-1)	$N^2M + NM^2$	-
$\mathbf{K}_{k_0}$	NM(N+M-2)	$N^2M + M^3$	$2N^3 + \mathcal{O}(N^2)$
$\mathbf{\hat{x}}_{k_0 k-l,k_0}$	N(M+2)	2NM	-
$\mathbf{P}_{k_0 k-l,k_0}$	NM(N+M-1)	$NM^2 + N^2M$	-
$\mathbf{\hat{x}}_{k k-l,k_0}$	N(N-1)	$N^2$	-
$\mathbf{P}_{k k-l,k_0}$	$N^2(2N-1)$	$2N^3$	-
$\mathbf{\hat{x}}_{k k-l}$	N(N-1)	$N^2$	-
$\mathbf{P}_{k k-l}$	$N^2(2N-1)$	$2N^3$	-
$\mathbf{P}_{k k_0}^{-1}$	$2N^2$	-	$6N^3 + \mathcal{O}(N^2)$
$\mathbf{\hat{x}}_{k k_0}$	2N(2N - 1)	$4N^{2}$	$2N^3 + \mathcal{O}(N^2)$

4. Verfahren zur Integration chronologisch ungeordneter Sensordaten

**Tabelle 4.10:** Anzahl an arithmetischen Operationen beim FPFD-Algorithmus. N ist die Dimension des Zustandsraumes und M die Dimension des Messraumes.

Algorithmus	Additionen	Multiplikationen	Invertierungen
Messdatenverzögerung	252	288	1
Reprozessierung $(l$ -Schritt-Problem)	(l+1)252	(l+1)288	l+1
Retrodiktion (1-Schritt-Problem)	596	712	2
Retrodiktion $(l$ -Schritt-Problem)	828	1008	5
FPFD (1- und $l$ -Schritt-Problem)	588	640	5

**Tabelle 4.11:** Anzahl skalarer Operationen und Matrixinvertierungen des Standard-Kalmanfilters, der Retrodiktion und des FPFD-Algorithmus bei einem vierdimensionalen Zustandsraum (N = 4) und einem zweidimensionalen Messraum (M = 2).

eine Prädiktion und eine Innovation des Standard-Kalmanfilters mit N = 4 und M = 2werden in Summe 252 Additionen, 288 Multiplikationen und eine Invertierung benötigt. Man sieht, dass bei einem Ein-Schritt-Problem der Aufwand für die Reprozessierung sogar knapp unterhalb des Aufwands für die Retrodiktion liegt. Die Datenassoziation muss im Unterschied zur Retrodiktion bei der Reprozessierung jedoch komplett neu aufgerollt werden, was einen großen Nachteil dieses Verfahrens darstellt. Man sieht außerdem, dass die Retrodiktion im Ein-Schritt-Fall deutlich weniger Aufwand erfordert als der FPFD-Algorithmus, es sind hier insbesondere zwei statt fünf Invertierungen nötig.

Im *l*-Schritt-Fall sieht die Situation deutlich anders aus. Zunächst fällt der enorme Aufwand der Reprozessierung auf, hier vervielfacht sich bei steigendem l jeweils der Aufwand. Die OOSM-Algorithmen hingegen erfordern für  $l \ge 2$  einen konstanten Aufwand, was sich insbesondere bei großer OOSM-Schrittweite l auszahlt. Innerhalb der OOSM-Algorithmen lässt sich ein klarer Vorteil für den FPFD-Algorithmus feststellen, es sind bei gleicher Anzahl an Invertierungen deutlich weniger Additionen und Multiplikationen nötig.

Zusammenfassend ist im Ein-Schritt-Fall bei den angegebenen Dimensionen die Retrodiktion zu empfehlen, sobald eine Datenassoziation stattfindet, ansonsten kann auch die Reprozessierung verwendet werden. Im l-Schritt-Fall ist das Arbeiten mit dem FPFD-Algorithmus sinnvoller als mit der l-Schritt-Retrodiktion.

Zur graphischen Veranschaulichung der hergeleiteten Komplexitätsvergleiche zeigt Abbildung 4.11 die Entwicklung der Operationen bei steigender Schrittweite. In Abbildung 4.11a wird ein Vergleich für ein Ein-Schritt-Problem gezeigt. Für die Komplexitätsanalyse einer Reprozessierung, Retrodiktion und des FPFD-Algorithmus ist der Aufwand der Messdatenverzögerung auf Eins normiert und die Komplexität der anderen Algorithmen im Vergleich hierzu dargestellt. Die Messdatenverzögerung benötigt die wenigsten arithmetischen Operationen. Bei einem Ein-Schritt-Problem wird für die Reprozessierung genau die doppelte Anzahl an Operationen benötigt.

In Abbildung 4.11b bis 4.11d ist zu erkennen, dass sich die Anzahl der Operationen der Retrodiktion bei einem l-Schritt-Problem (l > 1) nicht vergrößert. Im Gegensatz dazu steigt jedoch bei einer Reprozessierung die Anzahl der Matrixoperationen mit größer werdenden Schrittweiten deutlich an. Der FPFD-Algorithmus führt sowohl für das Ein-Schritt- als auch für das l-Schritt-Problem immer die gleiche Anzahl an Additionen, Multiplikationen und Invertierungen aus.

Bisher wurden vor allem theoretische Analysen durchgeführt. In Abbildung 4.12 werden daher zwei praxisnahe Tests dargestellt. Abbildung 4.12a zeigt die durchschnittliche Anzahl an Operationen für die Kombination eines Mehrmodus- mit zwei Nahbereichsradaren. Im Versuchsfahrzeug ergibt sich ein l-Schritt-Problem mit zwei variierenden Schrittweiten (l = 2 und l = 3). Die maximale Schrittweite ist drei, daher wird das Problem als Drei-Schritt-OOSM-Problem beschrieben. Da jedoch zwei SRR verwendet wurden, kommen jeweils zwei SRR-Messungen gleichzeitig an. Hierdurch ergibt sich ein Spezialfall, der zwar als Drei-Schritt-Problem bezeichnet werden kann, aber durch die doppelte Integration zusätzlichen Aufwand bei der Reprozessierung erfordert. Daher ist dieser Spezialfall in Abbildung 4.12a analysiert. Es wurden dabei die durchschnittlich auftretenden Fälle über eine bestimmte Zeitspanne gemittelt.

Man sieht in Abbildung 4.12a, dass im Unterschied zu Abbildung 4.11b der Vorteil der OOSM-Algorithmen im Vergleich zur Reprozessierung sinkt. Dies liegt daran, dass neben den Drei-Schritt-Fällen auch vereinzelt Zwei-Schritt-Fälle vorkommen. Die Reprozessierung benötigt durchschnittlich die 2,4-fache Anzahl an Rechenoperationen. Es ist wiederum zu beobachten, dass die OOSM-Algorithmen mehr Rechenoperationen als die Messdatenverzögerung, aber weniger als die Reprozessierung benötigen. Zwischen den OOSM-Algorithmen ist eine geringere Komplexität des FPFD-Algorithmus im Vergleich zur Retrodiktion feststellbar. Daher wird der FPFD-Algorithmus in der vorliegenden Konfiguration als der bevorzugte Algorithmus empfohlen.

Wie bereits erwähnt, wurden bei der bisherigen Analyse nur die Signalverarbeitungsschritte des Filters betrachtet. Die Komplexität der Reprozessierung bei einem Mehrobjektverfolgungssystem vergrößert sich durch eine doppelte Ausführung von Initialisierung, Objektverwaltung und Datenassoziation. Um die Gesamtkomplexität der Zustandsschätzung zu untersuchen, wurden daher praktische Laufzeituntersuchungen durchgeführt. Das



Abbildung 4.11: Normierte Anzahl arithmetischer Operationen der verschiedenen Algorithmen für ein (a) Ein-Schritt-, ein (b) Drei-Schritt-, ein (c) Fünf-Schritt- und ein (d) Sechs-Schritt-Problem. Hierbei wurden nur die OOSM-Signalverarbeitungsschritte betrachetet. Die Messdatenverzögerung wurde jeweils auf Eins normiert.



**Abbildung 4.12:** (a) Komplexitätsanalyse zur Sensorauswahl des Versuchsfahrzeuges mit einem Mehrmodus- und zwei Nahbereichsradaren. Durchschnittliche normierte Anzahl arithmetischer Operationen über alle OOSM-Schritte in der vorliegenden praktischen Konstellation. (b) Laufzeituntersuchung des gesamten Objektverfolgungssystems mit Initialisierung, Objektverwaltung, Datenassoziation und Filterung. Die Messdatenverzögerung wurde jeweils auf Eins normiert.

komplette Mehrzielverfolgungssystem beinhaltet die Initialisierung, Objektverwaltung, Datenassoziation und Filterung. Die Ergebnisse sind in Abbildung 4.12b dargestellt. Dabei wurde wieder die Messdatenverzögerung auf Eins normiert und die übrigen Größen hiermit verglichen.

Es zeigt sich, dass der Aufwand für die Reprozessierung im Vergleich zur Messdatenverzögerung nochmals steigt. Bei einer Reprozessierung werden alle Messungen zwischen  $t_{k_0}$  und  $t_k$  erneut in das Kalmanfilter integriert und deshalb muss auch mehrmals das komplette Mehrzielverfolgungssystem mit Datenassoziation berechnet werden. Außerdem ist eine Annäherung der OOSM-Algorithmen an die Messdatenverzögerung zu beobachten. In dieser Gesamtbetrachtung ist zu sehen, dass die Retrodiktion mit 56,84% des Aufwands für die Reprozessierung und der FPFD-Algorithmus mit 53,62% annähernd so effizient wie die Messdatenverzögerung (48,98%) sind, aber einen deutlich geringeren Rechenaufwand als die Reprozessierung aufweisen.

# 4.5.2 Speicherbedarf

Der Speicherbedarf der jeweiligen Algorithmen ist ein entscheidendes Kriterium bei der Wahl des passenden Objektverfolgungssystems. Insbesondere für eingebettete Systeme (*engl.* "Embedded Systems") mit geringen Ressourcen für Prozessor- und Arbeitsspeicher werden hohe Anforderungen bezüglich des Speicherbedarfs an die Signalverarbeitung

gestellt. Im Folgenden werden für jeden vorgeschlagenen Algorithmus die Speicheranforderungen bestimmt. Die Angaben beziehen sich darauf, wie viele skalare Werte zwischengespeichert werden müssen. So müssen zum Beispiel für eine  $2 \times 2$ -Matrix vier Werte gespeichert werden.

Im Folgenden wird jeweils davon ausgegangen, dass der a posteriori Systemzustand  $\hat{\mathbf{x}}_{k|k}$ mit der aktuellen Schätzfehlerkovarianzmatrix  $\mathbf{P}_{k|k}$  vorhanden ist. Die weiteren Speicheranforderungen der jeweiligen Algorithmen werden nun genauer analysiert.

### Messdatenverzögerung

In Tabelle 4.12 ist der Speicherbedarf für die Messdatenverzögerung zusammengefasst. Bei einer Messdatenverzögerung werden alle eintreffenden Messungen zwischengespeichert, um diese dann in chronologischer Reihenfolge in das Kalmanfilter zu integrieren. Bei einem l-Schritt Problem befinden sich demnach l Messungen der Dimension M im Speicher. Im allgemeinen Fall, wenn das Messrauschen nicht als konstant angenommen werden kann, müssen zusätzlich auch die Kovarianzmatrizen der Messungen gespeichert werden. Bei den in dieser Arbeit verwendeten Radarsensoren ist das Messrauschen abhängig vom Winkel und der Entfernung eines detektierten Objekts, wie in Kapitel 2.3.3 beschrieben wurde.

Speichervariable	Benötigter Speicher
Sensordaten	$l \cdot M$
Messfehlerkovarianzmatrizen	$l \cdot M^2$

Tabelle 4.12: Speicheranforderungen der Messdatenverzögerung.

### Reprozessierung

Tabelle 4.13 zeigt die Speicheranforderungen für die Reprozessierung mit der maximalen Schrittweite l. Es werden vier verschiedene Speicher benötigt. Der Speicher für die Systemzustände beinhaltet die Zustände  $\hat{\mathbf{x}}$  nach jeder Kalmanfilter-Innovation. Weiter werden die Schätzfehlerkovarianzmatrizen  $\mathbf{P}$  nach jeder Innovation abgespeichert.

Speichervariable	Benötigter Speicher
Systemzustände	$l\cdot N$
Schätzfehlerkovarianzmatrizen	$l \cdot N^2$
Sensordaten	$l\cdot M$
Messfehlerkovarianzmatrizen	$l\cdot M^2$

 Tabelle 4.13:
 Speicheranfoderungen f
 ür die Reprozessierung.

Der Speicher für die Sensormessdaten beinhaltet alle Sensordaten  $\mathbf{z}$  von Zeitpunkt  $t_k$ zurück bis zum Zeitpunkt  $t_{k-l+1}$  inklusive der Messfehlerkovarianzmatrizen  $\mathbf{R}$ . Sobald eine OOS-Messung die Fusionseinheit erreicht, werden alle Filterzustände und Kovarianzen auf die Werte vor der OOS-Messung zurückgesetzt und die Sensordaten inklusive OOS-Messung in chronologischer Reihenfolge in das Kalmanfilter integriert.

### Retrodiktion

In Tabelle 4.14 und Tabelle 4.15 sind der Speicherbedarf für das Ein-Schritt-Problem und für das *l*-Schritt-Problem abgebildet. Im Ein-Schritt-Fall muss keine äquivalente Messung berechnet werden. Um die Retrodiktion durchzuführen, müssen die zuletzt integrierte Messung  $\mathbf{z}_k$  und der a priori Systemzustand  $\hat{\mathbf{x}}_{k|k-1}$  gespeichert werden, so dass das Residuum berechnet werden kann. Alternativ kann das Residuum  $\boldsymbol{\gamma}_k$  direkt gespeichert werden. Außerdem werden die dazugehörige Kovarianzmatrix  $\mathbf{S}_k$  sowie die prädizierte a priori Schätzfehlerkovarianz  $\mathbf{P}_{k|k-1}$  im Zeitpunkt  $t_k$  benötigt.

Beim *l*-Schritt-Problem wird ein Speicher für die Systemzustände und deren Schätzfehlerkovarianzen implementiert. Im Unterschied zur Reprozessierung wird kein Speicher für ältere Sensordaten ( $t < t_k$ ) benötigt, da eine äquivalente Messung  $\mathbf{z}_k^*$  berechnet wird. Die Daten des Speichers für den Systemzustand  $\hat{\mathbf{x}}_{k|k-l}$  und dessen Kovarianzmatrix  $\mathbf{P}_{k|k-l}$  werden benutzt, um die äquivalente Messung im Zustandsraum zu berechnen.

Speichervariable	Benötigter Speicher
Residuum Kovarianzmatrix des Residuums Schätzfehlerkovarianz	$\begin{array}{c} M\\ M^2\\ N^2 \end{array}$

Tabelle 4.14: Speicheranforderungen der Retrodiktion (Ein-Schritt-Problem).

Speichervariable	Benötigter Speicher
Systemzustände Schätzfehlerkovarianzmatrizen	$l\cdot N \ l\cdot N^2$

Tabelle 4.15: Speicheranforderungen der Retrodiktion (*l*-Schritt-Problem).

### FPFD

Die Speicheranforderungen des FPFD-Algorithmus sind in Tabelle 4.16 abgebildet. Bei diesem Algorithmus ist keine Wiederaufbereitung alter Messungen nötig und daher entfällt der Speicher für Sensordaten. Es müssen nur die Systemzustände  $\hat{\mathbf{x}}$  mit den dazugehörigen Kovarianzen **P** gespeichert werden. Der FPFD-Algorithmus hat die gleichen Speicheranforderungen wie die Retrodiktion im *l*-Schritt-Fall. Es müssen alle Systemzustände und alle Schätzfehlerkovarianzmatrizen des jeweiligen Zeitschritts zwischen der OOS-Messung  $t_{k_0}$  und dem aktuellen Zeitpunkt  $t_k$  zwischengespeichert werden.

Speichervariable	Benötigter Speicher
Systemzustände Schätzfehlerkovarianzmatrizen	$l\cdot N \ l\cdot N^2$

Tabelle 4.16: Speicheranforderungen des FPFD-Algorihmus.

### Bewertender Vergleich des Speicherbedarfs

Bei der Fusion des Mehrmodusradars und der Nahbereichsradare handelt es sich um ein Drei-Schritt-OOSM-Problem, wobei teilweise auch OOS-Messungen mit l=2 auftreten. Trotzdem muss die maximale Schrittweite für die Speicherung angenommen werden, da im Voraus nicht bekannt ist, um welchen Fall es sich handelt. Als Beispiel wird ein zweidimensionaler Messraum M = 2 und ein vierdimensionaler Zustandsraum N = 4 angenommen, da dies den praktischen Versuchsaufbau dieser Arbeit widerspiegelt. Durch die doppelten Messungen der beiden SRR müssen bei der Messdatenverzögerung und bei der Reprozessierung jeweils die doppelten Speicheranforderungen für die Sensordaten und die Messfehlerkovarianzen zur Verfügung gestellt werden.

In Tabelle 4.17 ist die Anzahl der zu speichernden skalaren Werte abgebildet. Die Reprozessierung muss durch das Wiederaufarbeiten aller Messungen zwischen dem aktuellen Zeitpunkt  $t_k$  und der OOS-Messung  $t_{k_0}$  die meisten Werte zwischenspeichern. Dies wird noch verschlimmert durch die doppelten SRR-Messungen im vorliegenden Fall. Diese doppelten Messungen erfordern im Gegensatz dazu bei den OOSM-Algorithmen keinen zusätzlichen Speicher, da die Messungen hier nicht mehr benötigt werden. Man sieht, dass die OOSM-Algorithmen jeweils ungefähr den doppelten Speicher im Vergleich zur Messdatenverzögerung benötigen und die Reprozessierung fast das Dreifache. Somit ist ein deutlicher Vorteil der OOSM-Algorithmen auch in Bezug auf die Speicheranforderungen feststellbar. Die Retrodiktion unterscheidet sich dabei bezüglich der Speicheranforderungen nicht vom FPFD-Algorithmus.

Algorithmus	Messdatenverzögerung	Reprozessierung	Retrodiktion	FPFD
Skalare Werte $(l = 3)$	36	96	60	60

**Tabelle 4.17:** Speicheranforderungen im Versuchsfahrzeug bei einer maximalen Schrittweite von l = 3, wobei die doppelten Messungen der beiden SRR berücksichtigt sind.

# 4.6 Kapitelzusammenfassung

In diesem Kapitel wurden die verschiedenen Verfahren zur Integration nicht chronologischer Messdaten vorgestellt. Den Schwerpunkt bildeten dabei zwei OOSM-Algorithmen, die Retrodiktion und der FPFD-Algorithmus. Diese beiden Algorithmen wurden mit der Messdatenverzögerung und der Reprozessierung verglichen. Sowohl die Messdatenverzögerung als auch die Reprozessierung umgehen das Problem der Integration einer OOS-Messung durch das Zwischenspeichern von Messungen. Insbesondere bei nicht zeitkritischen Anwendungen stellt die Messdatenverzögerung das am weitesten verbreitete Verfahren dar [141]. Die Reprozessierung dient in dieser Arbeit als Referenz und ist das aufwändigste Verfahren. Die OOSM-Algorithmen haben das Ziel, eine vergleichbar gute Zustandsschätzung wie eine Reprozessierung unter geringerem Aufwand zu berechnen.

Zum Vergleich der einzelnen Algorithmen wurde eine detaillierte Aufwands- und Speicheranalyse durchgeführt. Hierfür wurde die genaue Anzahl benötigter arithmetischer Operationen der einzelnen Algorithmen berechnet. Eine Anpassung auf den in dieser Arbeit praktisch verwendeten Fall wurde gegeben. Entsprechende Analysen wurden für den Speicherbedarf durchgeführt, wobei wieder der allgemeine Fall und der vorliegende praktische Anwendungsfall unterschieden wurden.

Das Ergebnis der Analysen war, dass die Messdatenverzögerung der kostengünstigste und die Reprozessierung der aufwändigste Algorithmus ist, sowohl Rechenaufwand als auch Speicher betreffend. Der Vorteil der OOSM-Algorithmen im Vergleich zur Reprozessierung steigt mit wachsender OOSM-Schrittweite *l*. Es wurde im Ein-Schritt-Fall eine Überlegenheit der Retrodiktion festgestellt und im *l*-Schritt-Fall ein Vorteil des FPFD-Algorithmus.

Insgesamt werden mit den OOSM-Algorithmen für das Ein-Schritt-Problem dieselben Ergebnisse wie bei einer Reprozessierung erzielt, da es sich um analytisch äquivalente Algorithmen handelt. Die OOSM-Algorithmen besitzen jedoch im Vergleich zur Reprozessierung einen geringeren Rechen- und Speicherbedarf und sind aus diesem Grund vorzuziehen.

 $\mathbf{5}$ 

# OOSM mit probabilistischen Datenassoziationsverfahren

Bei der Verfolgung mehrerer Ziele spielt die Zuordnung von Messungen zu Objekten eine entscheidende Rolle. Bisherige Arbeiten zu den im vorigen Kapitel vorgestellten OOSM-Algorithmen beinhalten jedoch keine Datenassoziation. Das folgende Kapitel beschreibt daher einen neuen Algorithmus, der die probabilistischen Datenassoziationsverfahren PDA und JPDA mit Integration von OOS-Messungen ermöglicht.

Wie in Kapitel 3.5 beschrieben, wird die Datenassoziation in nicht-probabilistische (z.B. SNN, GNN) und probabilistische (z.B. PDA, JPDA) Verfahren unterteilt. Bei einer probabilistischen oder wahrscheinlichkeitsbasierten Datenassoziation können mehrere Messungen einem Objekt gewichtet zugeordnet werden. In vielen Mehrzielverfolgungssystemen erweisen sich nicht-probabilistische Datenassoziationsverfahren als nicht ausreichend, da Assoziationen in jedem Schritt endgültig festgelegt werden und später nicht mehr revidiert werden. Bei probabilistischen Verfahren werden harte Entscheidungen vermieden, so dass der Einfluss von Zuordnungsfehlern minimiert wird.

Im Kapitel 4.3 wurde die Retrodiktion für das Ein-Schritt- und das Mehr-Schritt-Problem vorgestellt. Für den Ein-Schritt-Fall wurde gezeigt, dass der Algorithmus das gleiche Ergebnis wie die Reprozessierung liefert. Würden also die Daten in chronologischer Reihenfolge wieder aufgearbeitet werden, würde die Retrodiktion die exakt gleiche Zustandsschätzung liefern. Dies gilt jedoch nur, solange kein Datenassoziationsproblem entsteht. Bei einer Einobjektverfolgung ist dies ohne Hintergrundrauschen immer garantiert, bei einer Mehrzielverfolgung kann jedoch durch Wiederaufbereitung der Messungen eine neue Konstellation von Datenzuordnungen entstehen. In solchen Fällen unterscheidet sich die Retrodiktion von der Reprozessierung.

Der entstehende Unterschied ist im Fall von Ein-Nachbar-Verfahren besonders groß, da hier harte Entscheidungen bezüglich der Datenassoziation getroffen werden. Hierdurch kann es vor Eintreffen einer OOS-Messung zu einer Falschassoziation aufgrund von fehlender Information kommen. Messungen können aufgrund der fehlenden OOS-Messung als Rauschen klassifiziert und verworfen werden, obwohl sie bei Vorhandensein der OOS-Messung als relevant erkannt werden könnten. Eine weitere Möglichkeit ist, dass fälschlicherweise ein neues Objekt aufgesetzt wird. Nach der Ein-Nachbar-Datenassoziation ist durch die harte Entscheidung keine Korrektur mehr möglich, auch wenn die Informationslage durch Eintreffen einer OOS-Messung verändert wird.

Aus diesem Grund ist es bei OOSM-Algorithmen entscheidend, bei der Datenassoziation auf probabilistische Verfahren zurückzugreifen. Diese vermeiden harte Entscheidungen und assoziieren unter Umständen mehrere gewichtete Messungen zu einem Objekt. Gerade im Konfliktfall, der durch eine OOS-Messung aufgelöst werden kann, wird keine vorschnelle Entscheidung getroffen.

Erste Untersuchungen von Datenassoziationsverfahren und deren Integration in OOSM-Algorithmen erfolgten in [33, 105]. In [91] wurden OOSM-Algorithmen mit graphischen Modellen vorgestellt und eine allgemeine Lösung des Datenassoziationsproblems über ein Bayessches Netzwerk beschrieben. Eine konkrete Realisierung bei normalverteilten Wahrscheinlichkeitsdichten wurde jedoch nicht gegeben. Eine alternative Lösung des OOSM-Problems mit minimalem Speicherbedarf wurde in [144] beschrieben und in [145] für das Datenassoziationsverfahren PDA angepasst. Für die in Kapitel 4 vorgestellten Algorithmen zur OOSM-Integration existieren bisher jedoch keine Erweiterungen auf probabilistische Datenassoziationsverfahren.

In diesem Kapitel soll die Retrodiktion erweitert werden, so dass sie für probabilistische Datenassoziationsverfahren verwendet werden kann. Die Schwierigkeit besteht darin, den Einfluss des Prozessrauschens beim Innovationsschritt vollständig zu berücksichtigen. Durch die gewichtete Innovation des Zustandsvektors mit mehreren Messungen entstehen mehrfache Einflüsse des Prozessrauschens auf die neue Schätzung. Aus diesem Grund kann die im vorherigen Kapitel vorgestellte Retrodiktion nicht mit JPDA kombiniert werden. In diesem Kapitel wird hierzu eine Erweiterung der Retrodiktion und des FPFD-Algorithmus für probabilistische Datenassoziationsverfahren gegeben. Diese modifizierte Version der Retrodiktion ermöglicht die Integration nicht chronologischer Sensormessdaten mit einer probabilistischen Datenassoziation. Die hier vorgestellten Algorithmen wurden in [150] und [152] veröffentlicht.

# 5.1 Probabilistische Datenassoziation

Das probabilistische oder wahrscheinlichkeitsbasierte Datenassoziationsverfahren (PDA) stellt eine 1-zu-m-Beziehung zwischen einem Objekt und allen im Suchbereich liegenden Messungen her. Dabei wird von einer Objekt-Detektionswahrscheinlichkeit  $P_D$  und einem gleichverteiltem Hintergrundrauschen  $\beta$  ausgegangen. Beim gemeinsamen probabilistischen Verfahren (JPDA) [40] werden die Hypothesen, welche Messung zu welchem Objekt gehört, gemeinsam erstellt. Somit wird eine n-zu-m-Beziehung hergestellt, das heißt, es werden mehrere Messungen mit  $p_{ij}$  gewichtet zu je einem Objekt assoziiert. Im folgenden Abschnitt wird auf den genauen Ablauf des JPDA-Algorithmus eingegangen, wobei dieser bis auf die Hypothesenbestimmung zum PDA identisch ist.

### 5.1.1 Datenassoziationsgewichte

Im Folgenden werden die Gewichte zur probabilistischen Datenassoziation beschrieben. Die Zuordnungswahrscheinlichkeit einer Messung j zu einem Objekt i lautet unter der Annahme, dass der Residuumsvektor normalverteilt ist:

$$p'_{ij} = P_D \; \frac{\exp\left(\frac{-d_{ij}^2}{2}\right)}{(2\pi)^{\frac{M}{2}} \sqrt{|\mathbf{S}_{ij}|}}.$$
(5.1.1)

Dabei ist M die Dimension der Innovationskovarianz  $\mathbf{S}_{ij}$  und  $d_{ij}$  die Mahalanobis-Distanz zwischen Messung j und Objekt i. Die Summe der Wahrscheinlichkeiten aller Hypothesen ist Eins. Eine Messung kann pro Hypothese nur einem Objekt zugeordnet werden. Dabei muss gelten, dass diese Messung auch im Assoziationstor des Objektes liegt. Das Gewicht einer Hypothese  $H_l$  setzt sich zusammen aus dem Produkt der Einzelwahrscheinlichkeiten der verschiedenen Assoziationen unter Berücksichtigung von Objekten, die nicht detektiert werden. Diese werden durch einen Faktor  $1 - P_D$  modelliert. Weiter werden Messungen zugelassen, die zu keinem Objekt assoziiert werden und daher durch das Hintergrundrauschen  $\beta$  beschrieben werden können. Insgesamt ergibt sich folgende Formel für die Hypothesengewichte [46]:

$$P(H_l) = \beta^m \cdot (1 - P_D)^n \cdot \prod_{(i,j) \in B(H_l)} p'_{ij}.$$
 (5.1.2)

Dabei ist m die Anzahl der Messungen, die zu keinem Objekt assoziiert werden, n ist die Anzahl der Objekte, die nicht detektiert werden und  $B(H_l)$  enthält alle Tupel von (i, j), bei denen Objekt i zu Messung j assoziiert wird.  $\beta$  beschreibt die Dichte des Hintergrundrauschens.

Diese Gewichte beschreiben noch keine Wahrscheinlichkeiten, sondern müssen noch mit der Summe der Gesamtwahrscheinlichkeiten normiert werden. Unter der Annahme, dass die Menge A(i, j) alle Hypothesen  $H_l$  enthält, in denen Objekt *i* zu Messung *j* assoziiert wird, so werden die Filtergewichte  $p_{ij}$  wie folgt berechnet:

$$p_{ij} = \frac{\sum_{H_l \in A(i,j)} P(H_l)}{\sum_{H_l} P(H_l)}.$$
(5.1.3)

Welche Messung die korrekte Repräsentation des Objektes darstellt ist unbekannt. Aus diesem Grund wird im aktuellen Zeitschritt keine Entscheidung getroffen und die Kovarianzen werden entsprechend vergrößert.

Abbildung 5.1 zeigt ein typisches Datenassoziationsproblem mit zwei Objekten A, B und drei Messungen. Folgende Hypothesengewichte P(H) werden bei diesem Beispiel gebildet. Dabei enthält die Menge Z(H) genau die Tupel (i, j), bei denen Objekt i zu Messung j



Abbildung 5.1: Beispiel einer JPDA-Datenzuordnung.

unter Annahme von Hypothese H zugeordnet wird.

 $P(H_1) = \beta^3 \cdot (1 - P_D)^2$  $Z(H_1) = \emptyset$  $P(H_2) = \beta^2 \cdot (1 - P_D) \cdot p'_{A1}$  $Z(H_2) = \{(A, 1)\}$  $P(H_{3}) = \beta \cdot p_{A1}' \cdot p_{B2}'$  $Z(H_3) = \{(A, 1), (B, 2)\}$  $P(H_4) = \beta \cdot p'_{A1} \cdot p'_{B3}$  $Z(H_4) = \{(A, 1), (B, 3)\}$  $P(H_5) = \beta^2 \cdot (1 - P_D) \cdot p'_{A2}$  $Z(H_5) = \{(A, 2)\}$  $P(H_{6}) = \beta \cdot p_{A2}' \cdot p_{B3}'$  $Z(H_6) = \{(A, 2), (B, 3)\}$  $P(H_7) = \beta^2 \cdot (1 - P_D) \cdot p'_{B2}$  $Z(H_7) = \{(B, 2)\}$  $P(H_8) = \beta^2 \cdot (1 - P_D) \cdot p'_{B3}$  $Z(H_8) = \{(B,3)\}$ 

Die resultierenden Gewichte des Kalmanfilters mit JPDA-Innovation werden nach (5.1.3) berechnet. Hierbei bezeichnet  $p_{A0}$  die Wahrscheinlichkeit, dass zu Objekt A keine Messung zugeordnet wird. Im obigen Beispiel erhält man die Wahrscheinlichkeiten

$$p_{A0} = c \cdot (P(H_1) + P(H_7) + P(H_8))$$
  

$$p_{A1} = c \cdot (P(H_2) + P(H_3) + P(H_4))$$
  

$$p_{A2} = c \cdot (P(H_5) + P(H_6))$$
  

$$p_{B0} = c \cdot (P(H_1) + P(H_2) + P(H_5))$$
  

$$p_{B2} = c \cdot (P(H_3) + P(H_7))$$
  

$$p_{B3} = c \cdot (P(H_4) + P(H_6) + P(H_8))$$

mit dem Normierungsfaktor c entsprechend Gleichung (5.1.3):

$$c = \left(\sum_{\forall H_l} P(H_l)\right)^{-1} = \left(P(H_1) + P(H_2) + \dots + P(H_8)\right)^{-1}.$$

Wahrscheinlichkeitsbasierte Datenassoziationsverfahren wurden in [12] erstmalig eingeführt. Weiterführende Literatur findet sich in [4].

### 5.1.2 Probabilistisches Datenassoziationsfilter

Zur gleichzeitigen Behandlung der Assoziations- und Zustandsunsicherheiten verwendet man das sogenannte vereinheitlichte probabilistische Datenassoziationsfilter, bei dem der lineare Kalmanfilter um ein Datenassoziationsverfahren erweitert wird. Hierbei muss die Innovation des Kalmanfilters entsprechend angepasst werden, so dass die Innovation nicht nur über eine einzige Messung erfolgt, sondern über eine gewichtete Summe aller Messungen im Suchbereich. Die Kalmanfilter-Innovation des Systemzustands aus Gleichung (3.2.15) lautet demnach mit JPDA-Datenassoziation wie folgt [12]:

$$\left(\hat{\mathbf{x}}_{k|k}\right)_{i} = \sum_{j=0}^{M_{i}} p_{ij} \left[ \left(\hat{\mathbf{x}}_{k|k-1}\right)_{i} + \left(\mathbf{K}_{k}\right)_{ij} \left(\boldsymbol{\gamma}_{k}\right)_{ij} \right].$$
(5.1.4)

Dabei ist  $M_i$  die Anzahl der Messungen  $(\mathbf{z}_k)_j$ , die im Assoziationstor um Objekt *i* liegen, und  $p_{ij}$  sind die Filtergewichte aus Gleichung (5.1.3). Die Innovation der Schätzfehlerkovarianz aus Gleichung (3.2.23) mit einer JPDA-Datenassoziation berechnet sich zu:

$$\left(\mathbf{P}_{k|k}\right)_{i} = \sum_{j=0}^{M_{i}} p_{ij} \left[ \left(\mathbf{P}_{k|k-1}\right)_{i} - \left(\mathbf{K}_{k}\right)_{ij} \left(\mathbf{S}_{k}\right)_{ij} \left(\mathbf{K}_{k}\right)_{ij}^{T} + \left(\left(\hat{\mathbf{x}}_{k|k-1}\right)_{i} + \left(\mathbf{K}_{k}\right)_{ij} \left(\boldsymbol{\gamma}_{k}\right)_{ij} - \left(\hat{\mathbf{x}}_{k|k}\right)_{i}\right) \right] \\ \cdot \left( \left(\hat{\mathbf{x}}_{k|k-1}\right)_{i} + \left(\mathbf{K}_{k}\right)_{ij} \left(\boldsymbol{\gamma}_{k}\right)_{ij} - \left(\hat{\mathbf{x}}_{k|k}\right)_{i}\right)^{T} \right].$$
(5.1.5)

Dabei ist der Residuumvektor  $(\boldsymbol{\gamma}_k)_{ij}$  als Differenz der *j*-ten Messung und der *i*-ten Zustandsschätzung definiert:

$$(\boldsymbol{\gamma}_k)_{ij} = (\mathbf{z}_k)_j - \mathbf{H}_k(\hat{\mathbf{x}}_{k|k-1})_i.$$
(5.1.6)

Die beiden Zusatzterme in (5.1.5) vergrößern die Schätzfehlerkovarianz, da die verschiedenen Assoziationsmöglichkeiten zu einer größeren Unsicherheit führen. Im Folgenden wird eine JPDA-Datenassoziation für die OOSM-Algorithmen entwickelt. Hierbei ist zu beachten, dass diese Methodik generisch für jedes probabilistische Datenassoziationsverfahren anwendbar ist, solange dieses eine Innovation der Form (5.1.4), (5.1.5) aufweist.

# 5.2 Herleitung einer probabilistischen Datenassoziation mit OOSM

Die in diesem Kapitel entwickelten Algorithmen werden wieder in ein Ein-Schritt- und ein Mehr-Schritt-Problem unterteilt. Im Folgenden werden drei Lösungsvorschläge für das Ein-Schritt-Problem, bei dem die OOS-Messung zwischen dem aktuellen Zeitpunkt  $t_k$  und dem letzten Zeitpunkt  $t_{k-1}$  liegt, vorgestellt. Danach wird das hergeleitete Verfahren für das Ein-Schritt-Problem auf das l-Schritt-Problem verallgemeinert.

# 5.2.1 Modifizierte Retrodiktion (mA1)

Wie im letzten Kapitel hergeleitet, korreliert das Prozessrauschen bei der Retrodiktion mit dem Systemzustand. Die Schwierigkeit bei einem Kalmanfilter mit JPDA und nicht chronologischen Sensormessdaten ist eine vollständige Berücksichtigung des Prozessrauschens. Wurde im letzten Zeitschritt  $t_k$  vor der OOS-Messung  $t_{k_0}$  eine JPDA-Innovation durchgeführt, bestehen Abhängigkeiten zwischen mehreren Messungen und mehreren Systemzuständen. Diese vielfältigen Abhängigkeiten müssen bei der Retrodiktion mit JPDA berücksichtigt werden. Das bedeutet eine erhöhte Komplexität im Vergleich zur bisher betrachteten Retrodiktion ohne Datenassoziation.

Wie in Abbildung 5.2 schematisch gezeigt, hat das Prozessrauschen  $\mathbf{Q}_k$  über mehrere a priori Schätzfehlerkovarianzen  $(\mathbf{P}_{k|k-1})_i$  Einfluss auf mehrere a posteriori Systemzustände  $(\hat{\mathbf{x}}_{k|k})_i$ . In dem Beispiel dieser Abbildung fällt mindestens eine gemeinsame Messung in den Suchbereich von Objekt 1 und Objekt 2. Somit verändert die Schätzfehlerkovarianz von Objekt 2 die Systemzustände von Objekt 1 und umgekehrt. Diese Veränderungen in den Systemzuständen müssen bei der Retrodiktion wieder rückgängig gemacht werden.

Beim Eintreffen einer OOS-Messung zum Zeitpunkt  $t_{k_0}$  sind wieder die folgenden retrodizierten Systemzustände (4.3.13) gesucht, dieses Mal jedoch unter Einbeziehung der probabilistischen Datenassoziation im Innovationsschritt:

$$\hat{\mathbf{x}}_{k_0|k} = E[\mathbf{x}_{k_0}|Z^k] = \mathbf{F}_{k_0,k}[\hat{\mathbf{x}}_{k|k} - \hat{\mathbf{v}}_{k,k_0|k}].$$
(5.2.1)

Hierbei wird der Term des Prozessrauschens vom Zeitpunkt  $t_k$  zurück zum Zeitpunkt  $t_{k_0}$  wieder mit dem Vektor  $\hat{\mathbf{v}}_{k,k_0|k}$  beschrieben.

Weiter ist die retrodizierte Schätzfehlerkovarianz  $\mathbf{P}_{k_0|k}$  mit probabilistischer Datenassoziation analog zu (4.3.29) gesucht:

$$\mathbf{P}_{k_{0}|k} = \operatorname{cov}\{\mathbf{x}_{k_{0}}|Z^{k}\}$$

$$= \mathbf{F}_{k_{0},k} \left[\operatorname{cov}\{\mathbf{x}_{k}|Z^{k}\} - \operatorname{cov}\{\mathbf{x}_{k}, \mathbf{v}_{k,k_{0}}|Z^{k}\}\right]$$

$$- \operatorname{cov}\{\mathbf{x}_{k}, \mathbf{v}_{k,k_{0}}|Z^{k}\}^{T} + \operatorname{cov}\{\mathbf{v}_{k,k_{0}}|Z^{k}\}\right] \mathbf{F}_{k_{0},k}^{T}$$

$$= \mathbf{F}_{k_{0},k} \left[\mathbf{P}_{k|k} - \mathbf{P}_{k,k_{0}|k}^{\mathbf{x}\mathbf{v}} - \left(\mathbf{P}_{k,k_{0}|k}^{\mathbf{x}\mathbf{v}}\right)^{T} + \mathbf{P}_{k,k_{0}|k}^{\mathbf{v}\mathbf{v}}\right] \mathbf{F}_{k_{0},k}^{T}.$$
(5.2.2)

Es soll nun die JPDA-Innovation unter Berücksichtigung des Prozessrauschens hergeleitet werden. Analog zu Gleichung (4.3.21) in Kapitel 4.3.1 wird für den modifizierten OOSM-Algorithmus mit JPDA wie folgt ein neuer Vektor definiert, der das Prozessrauschen berücksichtigt:

$$\mathbf{y}_k := \begin{bmatrix} \mathbf{x}_k \\ \mathbf{v}_{k,k_0} \end{bmatrix}.$$
(5.2.3)

Im Allgemeinen muss man i Objekte mit j Messungen assoziieren. Zur Vereinfachung wird vorerst der Objektindex i weggelassen und nur ein Objekt betrachtet. Somit ergibt



Abbildung 5.2: Einfluss des Prozessrauschens auf die Systemzustände durch die Innovation eines Kalmanfilters mit JPDA-Datenassoziation.

sich für die Systemzustände eines Objektes, indem man die JPDA-Innovation (5.1.4) analog zu (4.3.22) mittels Kreuzkovarianzen schreibt:

$$\hat{\mathbf{y}}_{k|k} = \sum_{j=0}^{M} p_j \left[ \hat{\mathbf{y}}_{k|k-1} + \operatorname{cov}\{\mathbf{y}_k, (\mathbf{z}_k)_j | Z^{k-1}\} \operatorname{cov}\{(\mathbf{z}_k)_j | Z^{k-1}\}^{-1} (\boldsymbol{\gamma}_k)_j \right],$$
(5.2.4)

mit der Zuordnungswahrscheinlichkeit  $p_j = p_{1j}$  der *j*-ten Messung zu dem betrachteten Objekt. Unter der Annahme, dass kein Hintergrundrauschen existiert und ein Nächste-Nachbarn-Datenassoziationsverfahren angewendet werden kann, wird aus Gleichung (5.2.4) mit M = 1 die Formel der Retrodiktion aus Gleichung (4.3.22). Als Innovation der Schätzfehlerkovarianz ergibt sich analog zu (4.3.32), indem man die Korrekturterme aus (5.1.5) hinzufügt:

$$cov\{\mathbf{y}_{k}|Z^{k}\} = \sum_{j=0}^{M} p_{j} \cdot \left[ cov\{\mathbf{y}_{k}|Z^{k-1}\} - cov\{\mathbf{y}_{k}, (\mathbf{z}_{k})_{j}|Z^{k-1}\} cov^{-1}\{(\mathbf{z}_{k})_{j}|Z^{k-1}\} cov\{(\mathbf{z}_{k})_{j}, \mathbf{y}_{k}|Z^{k-1}\} + \left[ \hat{\mathbf{y}}_{k|k-1} + cov\{\mathbf{y}_{k}, (\mathbf{z}_{k})_{j}|Z^{k-1}\} cov^{-1}\{(\mathbf{z}_{k})_{j}|Z^{k-1}\} (\boldsymbol{\gamma}_{k})_{j} - \hat{\mathbf{y}}_{k|k} \right] \\ \cdot \left[ \hat{\mathbf{y}}_{k|k-1} + cov\{\mathbf{y}_{k}, (\mathbf{z}_{k})_{j}|Z^{k-1}\} cov^{-1}\{(\mathbf{z}_{k})_{j}|Z^{k-1}\} (\boldsymbol{\gamma}_{k})_{j} - \hat{\mathbf{y}}_{k|k} \right]^{T} \right].$$
(5.2.5)

Im Gegensatz zur Innovation ohne probabilistische Datenassoziation wird hier einerseits eine gewichtete Summe gebildet, andererseits verändern wie oben beschrieben die Korrekturterme in der Schätzfehlerkovarianz die Innovation. Daher muss eine neue Algorithmik entwickelt werden, um die Retrodiktion auch bei probabilistischer Datenassoziation durchführen zu können. Es müssen also in der folgenden Herleitung durchgängig alle M Messungen gleichzeitig betrachtet werden. Im Folgenden wird zuerst die Retrodiktion der Systemzustände und anschließend die Retrodiktion der Schätzfehlerkovarianz hergeleitet und detailliert beschrieben.

### Berechnung der retrodizierten Systemzustände

Das Ziel ist es nun, die einzelnen Terme aus Gleichung (5.2.4) zu berechnen. Hierzu wird die *j*-te Messung zum Zeitpunkt  $t_k$  mit zugehörigem Messrauschen  $(\mathbf{w}_k)_j$  betrachtet:

$$(\mathbf{z}_k)_j = \mathbf{H}_k \mathbf{x}_k + (\mathbf{w}_k)_j. \tag{5.2.6}$$

Die erste bedingte Kreuzkovarianz aus (5.2.4) lässt sich durch Ersetzen von  $\mathbf{y}_k$  wie folgt beschreiben:

$$\operatorname{cov}\{\mathbf{y}_{k}, (\mathbf{z}_{k})_{j} | Z^{k-1}\} = \begin{bmatrix} \operatorname{cov}\{\mathbf{x}_{k}, (\mathbf{z}_{k})_{j} | Z^{k-1}\} \\ \operatorname{cov}\{\mathbf{v}_{k,k_{0}}, (\mathbf{z}_{k})_{j} | Z^{k-1}\} \end{bmatrix}.$$
(5.2.7)

Zur Berechnung der Retrodiktion wird die bedingte Kreuzkovarianz zwischen der *j*-ten Messung und den Systemzuständen zum Zeitpunkt  $t_k$  benötigt, die in (4.3.17) definiert wurde. Diese lässt sich analog zur Gleichung (4.3.18) aus Kapitel 4 wie folgt berechnen:

$$\operatorname{cov}\{\mathbf{x}_{k}, (\mathbf{z}_{k})_{j} | Z^{k-1}\} = \operatorname{cov}\{\mathbf{x}_{k}, \mathbf{H}_{k}\mathbf{x}_{k} + (\mathbf{w}_{k})_{j} | Z^{k-1}\}$$
$$= \operatorname{cov}\{\mathbf{x}_{k}, \mathbf{H}_{k}\mathbf{x}_{k} | Z^{k-1}\} + \operatorname{cov}\{\mathbf{x}_{k}, (\mathbf{w}_{k})_{j} | Z^{k-1}\}$$
$$= \operatorname{cov}\{\mathbf{x}_{k}, \mathbf{H}_{k}\mathbf{x}_{k} | Z^{k-1}\}$$
$$= \mathbf{P}_{k|k-1}\mathbf{H}_{k}^{T}.$$
(5.2.8)

Das Messrauschen  $(\mathbf{w}_k)_j$  hat keinen Einfluss auf die Kreuzkovarianz, da es vom Systemzustand unabhängig ist, daher ergibt sich für jede Messung dieselbe bedingte Kreuzkovarianz. Die untere bedingte Kreuzkovarianz aus Gleichung (5.2.7) wird analog zu (4.3.25) berechnet mit:

$$\operatorname{cov}\{\mathbf{v}_{k,k_{0}},(\mathbf{z}_{k})_{j}|Z^{k-1}\} = E\left[\left(\mathbf{v}_{k,k_{0}}-\hat{\mathbf{v}}_{k,k_{0}}\right)\left((\mathbf{z}_{k})_{j}-\hat{\mathbf{z}}_{k}\right)^{T}|Z^{k-1}\right]$$
$$= E\left[\mathbf{v}_{k,k_{0}}\left[\mathbf{H}_{k}(\mathbf{F}_{k,k_{0}}\mathbf{x}_{k_{0}}+\mathbf{v}_{k,k_{0}})+(\mathbf{w}_{k})_{j}-\hat{\mathbf{z}}_{k}\right]^{T}|Z^{k-1}\right]$$
$$= E\left[\mathbf{v}_{k,k_{0}}\mathbf{v}_{k,k_{0}}^{T}\mathbf{H}_{k}^{T}\right]$$
$$= \mathbf{Q}_{k,k_{0}}\mathbf{H}_{k}^{T}.$$
(5.2.9)

Hier wurde wieder ausgenutzt, dass aufgrund der vorausgesetzten stochastischen Unabhängigkeit die Kreuzkovarianzen von  $\mathbf{v}_{k|k_0}$  zu  $\mathbf{x}_{k_0}$ , zu  $(\mathbf{w}_k)_j$  und zu  $\hat{\mathbf{z}}_k$  Null sind. Daher ist die berechnete Kreuzkovarianz wieder unabhängig vom Messrauschen  $(\mathbf{w}_k)_j$ .

Die Kovarianzmatrix der Innovation  $(\mathbf{S}_k)_j$  in Abhängigkeit von der *j*-ten Messung lässt sich folgendermaßen herleiten:

$$\operatorname{cov}\{(\mathbf{z}_{k})_{j}|Z^{k-1}\} = E[((\mathbf{z}_{k})_{j} - \hat{\mathbf{z}}_{k})((\mathbf{z}_{k})_{j} - \hat{\mathbf{z}}_{k})^{T}|Z^{k-1}]$$

$$= E\left[(\mathbf{H}_{k}\mathbf{x}_{k} + (\mathbf{w}_{k})_{j} - \mathbf{H}_{k}\hat{\mathbf{x}}_{k})(\mathbf{H}_{k}\mathbf{x}_{k} + (\mathbf{w}_{k})_{j} - \mathbf{H}_{k}\hat{\mathbf{x}}_{k})^{T}|Z^{k-1}\right]$$

$$= E\left[(\mathbf{H}_{k}(\mathbf{x}_{k} - \hat{\mathbf{x}}_{k}) + (\mathbf{w}_{k}))_{j}(\mathbf{H}_{k}(\mathbf{x}_{k} - \hat{\mathbf{x}}_{k}) + (\mathbf{w}_{k})_{j})^{T}|Z^{k-1}\right]$$

$$= \mathbf{H}_{k}\mathbf{P}_{k|k-1}\mathbf{H}_{k}^{T} + (\mathbf{R}_{k})_{j}$$

$$= (\mathbf{S}_{k})_{j}, \qquad (5.2.10)$$

mit der *j*-ten Messfehlerkovarianzmatrix  $(\mathbf{R}_k)_j$ . Setzt man nun (5.2.8), (5.2.9) und (5.2.10) in Gleichung (5.2.4) ein, so ergibt sich:

$$\begin{aligned} \hat{\mathbf{y}}_{k|k} &= \begin{bmatrix} \hat{\mathbf{x}}_{k|k} \\ \hat{\mathbf{v}}_{k,k_0|k} \end{bmatrix} = \sum_{j=0}^{M} p_j \left( \begin{bmatrix} \hat{\mathbf{x}}_{k|k-1} \\ \hat{\mathbf{v}}_{k,k_0|k-1} \end{bmatrix} + \operatorname{cov} \left\{ \begin{bmatrix} \mathbf{x}_k, (\mathbf{z}_k)_j | Z^{k-1} \\ \mathbf{v}_{k,k_0}, (\mathbf{z}_k)_j | Z^{k-1} \end{bmatrix} \right\} \\ &\quad \cdot \operatorname{cov}^{-1} \left\{ (\mathbf{z}_k)_j | Z^{k-1} \right\} (\boldsymbol{\gamma}_k)_j \right) \\ &= \sum_{j=0}^{M} p_j \begin{bmatrix} \hat{\mathbf{x}}_{k|k-1} \\ \hat{\mathbf{v}}_{k,k_0|k-1} \end{bmatrix} + \sum_{j=0}^{M} p_j \left( \begin{bmatrix} \mathbf{P}_{k|k-1}\mathbf{H}_k^T \\ \mathbf{Q}_{k,k_0}\mathbf{H}_k^T \end{bmatrix} (\mathbf{S}_k^{-1})_j (\boldsymbol{\gamma}_k)_j \right) \\ &= \begin{bmatrix} \hat{\mathbf{x}}_{k|k-1} \\ \hat{\mathbf{v}}_{k,k_0|k-1} \end{bmatrix} + \begin{bmatrix} \mathbf{P}_{k|k-1}\mathbf{H}_k^T \\ \mathbf{Q}_{k,k_0}\mathbf{H}_k^T \end{bmatrix} \sum_{j=0}^{M} p_j \left( (\mathbf{S}_k^{-1})_j (\boldsymbol{\gamma}_k)_j \right). \end{aligned}$$
(5.2.11)

Hierbei wurde ausgenutzt, dass die Summe der Zuordnungswahrscheinlichkeiten  $p_j$  sich zu Eins ergibt.

Damit ergibt sich aus der unteren Zeile von (5.2.11) der a posteriori Erwartungswert des Prozessrauschens von  $t_{k_0}$  nach  $t_k$ :

$$\hat{\mathbf{v}}_{k,k_0|k} = \hat{\mathbf{v}}_{k,k_0|k-1} + \mathbf{Q}_{k,k_0} \mathbf{H}_k^T \sum_{j=0}^M p_j \left[ (\mathbf{S}_k^{-1})_j (\boldsymbol{\gamma}_k)_j \right]$$
$$= \mathbf{Q}_{k,k_0} \mathbf{H}_k^T \sum_{j=0}^M p_j \left[ (\mathbf{S}_k^{-1})_j (\boldsymbol{\gamma}_k)_j \right], \qquad (5.2.12)$$

wobei wie in Kapitel 4 verwendet wurde, dass das Prozessrauschen mittelwertfrei ist, vergleiche (4.3.14). Durch Einsetzen der Gleichung (5.2.12) in Gleichung (5.2.1) wird der retrodizierte Zustand vollständig angegeben:

$$\hat{\mathbf{x}}_{k_0|k} = \mathbf{F}_{k_0,k} \left[ \hat{\mathbf{x}}_{k|k} - \mathbf{Q}_{k,k_0} \mathbf{H}_k^T \sum_{j=0}^M p_j \left[ (\mathbf{S}_k^{-1})_j (\boldsymbol{\gamma}_k)_j \right] \right].$$
(5.2.13)

Für M = 1 und  $p_j = 1$  ergibt sich die Retrodiktion der Systemzustände ohne probabilistisches Datenassoziationsverfahren. Die gewichteten Einflüsse der verschiedenen Messungen auf das Prozessrauschen werden bei der Retrodiktion vom a posteriori Systemzustand  $\hat{\mathbf{x}}_{k|k}$  subtrahiert. Hierdurch wird genau der Einfluss der gewichteten Innovation rückgängig gemacht, die im Rahmen der JPDA-Datenassoziation durchgeführt wurde. Man könnte das hergeleitete Verfahren daher als gewichtete Retrodiktion bezeichnen.

#### Berechnung der retrodizierten Schätzfehlerkovarianz

Neben den retrodizierten Systemzuständen  $\hat{\mathbf{x}}_{k_0|k}$  ist auch die retrodizierte Schätzfehlerkovarianz  $\mathbf{P}_{k_0|k}$  gesucht. Ausgangspunkt der Herleitungen ist Gleichung (4.3.35) mit der folgenden bedingten Kovarianz:

$$\operatorname{cov}\{\mathbf{y}_{k}|Z^{k}\} = \operatorname{cov}\left\{\begin{bmatrix}\mathbf{x}_{k}\\\mathbf{v}_{k,k_{0}}\end{bmatrix}\middle|Z^{k}\right\} = \begin{bmatrix}\mathbf{P}_{k|k} & \mathbf{P}_{k,k_{0}|k}^{\mathbf{x}\mathbf{v}}\\(\mathbf{P}_{k,k_{0}|k}^{\mathbf{x}\mathbf{v}})^{T} & \mathbf{P}_{k,k_{0}|k}^{\mathbf{v}\mathbf{v}}\end{bmatrix}.$$
(5.2.14)

Hat man diese vier Teilmatrizen hergeleitet, so ergibt sich die Retrodiktion der Schätzfehlerkovarianz mittels (5.2.2). Das Ziel des folgenden Abschnitts ist es daher, die bedingte Kovarianz aus (5.2.14) unter Berücksichtigung der probabilistischen Datenassoziation zu berechnen.

Durch Einsetzen des neu definierten Vektors aus Gleichung (5.2.3) in die Innovationsgleichung (5.2.5) für die Schätzfehlerkovarianz ergibt sich folgende Darstellung:

$$\operatorname{cov}\{\mathbf{y}_{k}|Z^{k}\} = \operatorname{cov}\left\{\begin{bmatrix}\mathbf{x}_{k}\\\mathbf{v}_{k,k_{0}}\end{bmatrix} \middle| Z^{k}\right\} \\
= \sum_{j=0}^{M} p_{j}\left[\operatorname{cov}\left\{\begin{bmatrix}\mathbf{x}_{k}\\\mathbf{v}_{k,k_{0}}\end{bmatrix} \middle| Z^{k-1}\right\} \\
-\operatorname{cov}\left\{\begin{bmatrix}\mathbf{x}_{k}\\\mathbf{v}_{k,k_{0}}\end{bmatrix}, (\mathbf{z}_{k})_{j}\middle| Z^{k-1}\right\} \operatorname{cov}^{-1}\left\{(\mathbf{z}_{k})_{j}\middle| Z^{k-1}\right\} \operatorname{cov}\left\{(\mathbf{z}_{k})_{j}, \begin{bmatrix}\mathbf{x}_{k}\\\mathbf{v}_{k,k_{0}}\end{bmatrix} \middle| Z^{k-1}\right\} \\
+ \left(\begin{bmatrix}\hat{\mathbf{x}}_{k|k-1}\\\hat{\mathbf{v}}_{k,k_{0}|k-1}\end{bmatrix} + \operatorname{cov}\left\{\begin{bmatrix}\mathbf{x}_{k}\\\mathbf{v}_{k,k_{0}}\end{bmatrix}, (\mathbf{z}_{k})_{j}\middle| Z^{k-1}\right\} \operatorname{cov}^{-1}\left\{(\mathbf{z}_{k})_{j}\middle| Z^{k-1}\right\} (\mathbf{\gamma}_{k})_{j} - \begin{bmatrix}\hat{\mathbf{x}}_{k|k}\\\hat{\mathbf{v}}_{k,k_{0}|k}\end{bmatrix}\right) \\
\cdot \left(\begin{bmatrix}\hat{\mathbf{x}}_{k|k-1}\\\hat{\mathbf{v}}_{k,k_{0}|k-1}\end{bmatrix} + \operatorname{cov}\left\{\begin{bmatrix}\mathbf{x}_{k}\\\mathbf{v}_{k,k_{0}}\end{bmatrix}, (\mathbf{z}_{k})_{j}\middle| Z^{k-1}\right\} \operatorname{cov}^{-1}\left\{(\mathbf{z}_{k})_{j}\middle| Z^{k-1}\right\} (\mathbf{\gamma}_{k})_{j} - \begin{bmatrix}\hat{\mathbf{x}}_{k|k}\\\hat{\mathbf{v}}_{k,k_{0}|k}\end{bmatrix}\right)^{T}\right]. \\ (5.2.15)$$

Durch weiteres Umformen erhält man folgende Schätzung der Kovarianzmatrix:

$$\operatorname{cov}\left\{ \begin{bmatrix} \mathbf{x}_{k} \\ \mathbf{v}_{k,k_{0}} \end{bmatrix} \middle| Z^{k} \right\} = \sum_{j=0}^{M} p_{j} \left[ \begin{bmatrix} \operatorname{cov}\{\mathbf{x}_{k}|Z^{k-1}\} & \operatorname{cov}\{\mathbf{x}_{k}, \mathbf{v}_{k,k_{0}}|Z^{k-1}\} \\ \operatorname{cov}\{\mathbf{v}_{k,k_{0}}, \mathbf{x}_{k}|Z^{k-1}\} & \operatorname{cov}\{\mathbf{v}_{k,k_{0}}|Z^{k-1}\} \end{bmatrix} \right] \\ - \begin{bmatrix} \operatorname{cov}\{\mathbf{x}_{k}, (\mathbf{z}_{k})_{j}|Z^{k-1}\} \\ \operatorname{cov}\{\mathbf{v}_{k,k_{0}}, (\mathbf{z}_{k})_{j}|Z^{k-1}\} \end{bmatrix} & (\mathbf{S}_{k}^{-1})_{j} \begin{bmatrix} \operatorname{cov}\{(\mathbf{z}_{k})_{j}, \mathbf{x}_{k}|Z^{k-1}\} \\ \operatorname{cov}\{(\mathbf{z}_{k})_{j}, \mathbf{v}_{k,k_{0}}|Z^{k-1}\} \end{bmatrix} \\ + \left( \begin{bmatrix} \hat{\mathbf{x}}_{k|k-1} \\ \hat{\mathbf{v}}_{k,k_{0}|k-1} \end{bmatrix} + \begin{bmatrix} \operatorname{cov}\{\mathbf{x}_{k}, (\mathbf{z}_{k})_{j}|Z^{k-1}\} \\ \operatorname{cov}\{\mathbf{v}_{k,k_{0}}, (\mathbf{z}_{k})_{j}|Z^{k-1}\} \end{bmatrix} & (\mathbf{S}_{k}^{-1})_{j} (\boldsymbol{\gamma}_{k})_{j} - \begin{bmatrix} \hat{\mathbf{x}}_{k|k} \\ \hat{\mathbf{v}}_{k,k_{0}|k} \end{bmatrix} \right) \\ \cdot \left( \begin{bmatrix} \hat{\mathbf{x}}_{k|k-1} \\ \hat{\mathbf{v}}_{k,k_{0}|k-1} \end{bmatrix} + \begin{bmatrix} \operatorname{cov}\{\mathbf{x}_{k}, (\mathbf{z}_{k})_{j}|Z^{k-1}\} \\ \operatorname{cov}\{\mathbf{v}_{k,k_{0}}, (\mathbf{z}_{k})_{j}|Z^{k-1}\} \end{bmatrix} & (\mathbf{S}_{k}^{-1})_{j} (\boldsymbol{\gamma}_{k})_{j} - \begin{bmatrix} \hat{\mathbf{x}}_{k|k} \\ \hat{\mathbf{v}}_{k,k_{0}|k} \end{bmatrix} \right)^{T} \end{bmatrix}.$$

$$(5.2.16)$$

Die benötigten Kreuzkovarianzen wurden bereits in den Gleichungen (5.2.8), (5.2.9) und (4.3.34) hergeleitet, wobei letztere keine aktuelle Messung beinhaltet und daher direkt aus Kapitel 4 übernommen werden kann:

$$\operatorname{cov}\{\mathbf{x}_{k}, (\mathbf{z}_{k})_{j} | Z^{k-1}\} = \mathbf{P}_{k|k-1} \mathbf{H}_{k}^{T},$$
  

$$\operatorname{cov}\{\mathbf{v}_{k,k_{0}}, (\mathbf{z}_{k})_{j} | Z^{k-1}\} = \mathbf{Q}_{k,k_{0}} \mathbf{H}_{k}^{T}$$
  

$$\operatorname{cov}\{\mathbf{x}_{k}, \mathbf{v}_{k,k_{0}} | Z^{k-1}\} = \mathbf{Q}_{k,k_{0}}.$$
(5.2.17)

Diese werden nun herangezogen, um die Einträge in den Blockmatrizen in Gleichung (5.2.16)zu ersetzen:

$$\operatorname{cov}\left\{ \begin{bmatrix} \mathbf{x}_{k} \\ \mathbf{v}_{k,k_{0}} \end{bmatrix} \middle| Z^{k} \right\} = \sum_{j=0}^{M} p_{j} \cdot \left[ \begin{bmatrix} \mathbf{P}_{k|k-1} & \mathbf{Q}_{k,k_{0}} \\ \mathbf{Q}_{k,k_{0}} & \mathbf{Q}_{k,k_{0}} \end{bmatrix} \right] \\ - \begin{bmatrix} \mathbf{P}_{k|k-1}\mathbf{H}_{k}^{T} \\ \mathbf{Q}_{k,k_{0}}\mathbf{H}_{k}^{T} \end{bmatrix} (\mathbf{S}_{k}^{-1})_{j} \begin{bmatrix} \mathbf{P}_{k|k-1}\mathbf{H}_{k}^{T} \\ \mathbf{Q}_{k,k_{0}}\mathbf{H}_{k}^{T} \end{bmatrix}^{T} \\ + \left( \begin{bmatrix} \hat{\mathbf{x}}_{k|k-1} \\ \hat{\mathbf{v}}_{k,k_{0}|k-1} \end{bmatrix} + \begin{bmatrix} \mathbf{P}_{k|k-1}\mathbf{H}_{k}^{T} \\ \mathbf{Q}_{k,k_{0}}\mathbf{H}_{k}^{T} \end{bmatrix} (\mathbf{S}_{k}^{-1})_{j} (\boldsymbol{\gamma}_{k})_{j} - \begin{bmatrix} \hat{\mathbf{x}}_{k|k} \\ \hat{\mathbf{v}}_{k,k_{0}|k} \end{bmatrix} \right) \\ \cdot \left( \begin{bmatrix} \hat{\mathbf{x}}_{k|k-1} \\ \hat{\mathbf{v}}_{k,k_{0}|k-1} \end{bmatrix} + \begin{bmatrix} \mathbf{P}_{k|k-1}\mathbf{H}_{k}^{T} \\ \mathbf{Q}_{k,k_{0}}\mathbf{H}_{k}^{T} \end{bmatrix} (\mathbf{S}_{k}^{-1})_{j} (\boldsymbol{\gamma}_{k})_{j} - \begin{bmatrix} \hat{\mathbf{x}}_{k|k} \\ \hat{\mathbf{v}}_{k,k_{0}|k} \end{bmatrix} \right)^{T} \right]. \quad (5.2.18)$$

Durch Ausmultiplizieren dieser Gleichung ergibt sich folgender Term:

$$\begin{aligned} & \operatorname{cov}\left\{ \begin{bmatrix} \mathbf{x}_{k} \\ \mathbf{v}_{k,k_{0}} \end{bmatrix} \middle| Z^{k} \right\} = \sum_{j=0}^{M} p_{j} \cdot \left[ \begin{bmatrix} \mathbf{P}_{k|k-1} & \mathbf{Q}_{k,k_{0}} \\ \mathbf{Q}_{k,k_{0}} & \mathbf{Q}_{k,k_{0}} \end{bmatrix} \\ & - \begin{bmatrix} \mathbf{P}_{k|k-1}\mathbf{H}_{k}^{T}(\mathbf{S}_{k}^{-1})_{j}\mathbf{H}_{k}\mathbf{P}_{k|k-1}^{T} & \mathbf{P}_{k|k-1}\mathbf{H}_{k}^{T}(\mathbf{S}_{k}^{-1})_{j}\mathbf{H}_{k}\mathbf{Q}_{k,k_{0}} \\ \mathbf{Q}_{k,k_{0}}\mathbf{H}_{k}^{T}(\mathbf{S}_{k}^{-1})_{j}\mathbf{H}_{k}\mathbf{P}_{k|k-1}^{T} & \mathbf{Q}_{k,k_{0}}\mathbf{H}_{k}^{T}(\mathbf{S}_{k}^{-1})_{j}\mathbf{H}_{k}\mathbf{Q}_{k,k_{0}} \\ & + \left( \begin{bmatrix} \hat{\mathbf{x}}_{k|k-1}\hat{\mathbf{x}}_{k|k-1}^{T} & \hat{\mathbf{x}}_{k|k-1}\hat{\mathbf{v}}_{k,k_{0}|k-1}^{T} \\ \hat{\mathbf{v}}_{k,k_{0}|k-1}\hat{\mathbf{x}}_{k|k-1}^{T} & \hat{\mathbf{v}}_{k,k_{0}|k-1}\hat{\mathbf{v}}_{k,k_{0}|k-1}^{T} \\ \hat{\mathbf{v}}_{k,k_{0}|k-1}\hat{\mathbf{x}}_{k|k-1}^{T} & \hat{\mathbf{v}}_{k,k_{0}|k-1} \\ \hat{\mathbf{v}}_{k,k_{0}|k-1}\hat{\mathbf{x}}_{k|k-1}^{T}(\mathbf{y}_{k}^{T})_{j}(\mathbf{S}_{k}^{-1})_{j}^{T}\mathbf{H}_{k}\mathbf{P}_{k|k-1}^{T} & \hat{\mathbf{x}}_{k|k-1}(\gamma_{k}^{T})_{j}(\mathbf{S}_{k}^{-1})_{j}^{T}\mathbf{H}_{k}\mathbf{Q}_{k,k_{0}} \\ & + \begin{bmatrix} \hat{\mathbf{x}}_{k|k-1}(\gamma_{k}^{T})_{j}(\mathbf{S}_{k}^{-1})_{j}^{T}\mathbf{H}_{k}\mathbf{P}_{k|k-1}^{T} & \hat{\mathbf{x}}_{k|k-1}(\gamma_{k}^{T})_{j}(\mathbf{S}_{k}^{-1})_{j}^{T}\mathbf{H}_{k}\mathbf{Q}_{k,k_{0}} \\ & \hat{\mathbf{v}}_{k,k_{0}|k-1}(\gamma_{k}^{T})_{j}(\mathbf{S}_{k}^{-1})_{j}^{T}\mathbf{H}_{k}\mathbf{P}_{k|k-1}^{T} & \hat{\mathbf{x}}_{k|k-1}(\gamma_{k}^{T})_{j}(\mathbf{S}_{k}^{-1})_{j}^{T}\mathbf{H}_{k}\mathbf{Q}_{k,k_{0}} \\ & + \begin{bmatrix} \mathbf{x}_{k|k-1}(\mathbf{x}_{k}^{T})_{j}(\mathbf{x}_{k})_{j}\hat{\mathbf{x}}_{k|k-1}^{T} & \mathbf{P}_{k|k-1}(\mathbf{x}_{k}^{T})_{j}(\mathbf{x}_{k})_{j}\hat{\mathbf{x}}_{k|k-1}^{T} \\ & \mathbf{Q}_{k,k_{0}}\mathbf{H}_{k}^{T}(\mathbf{S}_{k}^{-1})_{j}(\mathbf{x}_{k})_{j}\hat{\mathbf{x}}_{k|k-1}^{T} & \mathbf{Q}_{k,k_{0}}\mathbf{H}_{k}^{T}(\mathbf{S}_{k}^{-1})_{j}(\mathbf{x}_{k})_{j}(\mathbf{x}_{k}^{T})_{j}(\mathbf{x}_{k})_{k}^{T}\mathbf{H}_{k}^{T} \\ & \mathbf{Q}_{k,k_{0}}\mathbf{H}_{k}^{T}(\mathbf{S}_{k}^{-1})_{j}(\mathbf{x}_{k})_{j}(\mathbf{x}_{k}^{T})_{j}(\mathbf{S}_{k}^{-1})_{j}^{T}\mathbf{H}_{k}\mathbf{P}_{k|k-1}^{T} & \mathbf{Q}_{k,k_{0}}\mathbf{H}_{k}^{T}(\mathbf{S}_{k}^{-1})_{j}(\mathbf{x}_{k})_{j}(\mathbf{x}_{k}^{T})_{j}(\mathbf{S}_{k}^{-1})_{j}^{T}\mathbf{H}_{k}\mathbf{Q}_{k,k_{0}} \\ \\ & + \begin{bmatrix} \mathbf{x}_{k|k-1}\mathbf{H}_{k}^{T}(\mathbf{S}_{k}^{-1})_{j}(\mathbf{x}_{k})_{j}\hat{\mathbf{x}}_{k}^{T} & \mathbf{Q}_{k,k_{0}}\mathbf{H}_{k}^{T}(\mathbf{S}_{k}^{-1})_{j}(\mathbf{x}_{k})_{j}(\mathbf{x}_{k}^{T})_{j}(\mathbf{S}_{k}^{-1})_{j}^{T}\mathbf{H}_{k}\mathbf{Q}_{k,k_{0}} \\ \\ & - \begin{bmatrix} \mathbf{x}_{k|k-1}\mathbf{H}_{k}^{T}(\mathbf{S}_{k}^{-1})_{j}$$

Nach Gleichung (4.3.14) ist der a priori Erwartungswert des Prozessrauschens Null,

$$\hat{\mathbf{v}}_{k,k_0|k-1} = 0. \tag{5.2.20}$$

Der a posteriori Erwartungswert des Prozessrauschens von Zeitpunkt  $t_{k_0}$  nach  $t_k$  unter Berücksichtigung aller Messungen  $Z^k$  ergibt sich aus Gleichung (5.2.11) zu:

$$\hat{\mathbf{v}}_{k,k_0|k} = \mathbf{Q}_{k,k_0} \mathbf{H}_k^T \sum_{j=0}^M p_j \left[ (\mathbf{S}_k^{-1})_j (\boldsymbol{\gamma}_k)_j \right].$$
(5.2.21)

Es lassen sich nun einzelne Prozessrauschterme  $(\hat{\mathbf{v}}_{k,k_0|k})_j$ , j = 0, ..., M, definieren, die mittels einer gewichteten Summe das gesamte Prozessrauschen ergeben:

$$\hat{\mathbf{v}}_{k,k_0|k} =: \sum_{j=0}^{M} p_j(\hat{\mathbf{v}}_{k,k_0|k})_j.$$
(5.2.22)

Anschaulich beschreibt der a posteriori Erwartungswert  $\hat{\mathbf{v}}_{k,k_0|k}$  den Teil des Prozessrauschens zwischen der OOS-Messung  $\mathbf{z}_{k_0}$  und der aktuellen Messung  $\mathbf{z}_k$ , der die Innovation zum Zeitpunkt  $t_k$  beeinflusst hat. Analog kann man daher den *j*-ten Summanden  $(\hat{\mathbf{v}}_{k,k_0|k})_j$  als den Teil des Prozessrauschens interpretieren, der die Teilinnovation mit der *j*-ten Messung bei der probabilistischen Datenassoziation beeinflusst hat. Diese Aufspaltung in einzelne Summanden ist aufgrund der Linearität der Kalman-Innovation möglich. Der ungewichtete Einfluss des Prozessrauschens auf die Innovation mit der *j*-ten Messung lautet nach (5.2.21):

$$\left(\hat{\mathbf{v}}_{k,k_0|k}\right)_j = \mathbf{Q}_{k,k_0} \mathbf{H}_k^T \left(\mathbf{S}_k^{-1}\right)_j (\boldsymbol{\gamma}_k)_j.$$
(5.2.23)

Mit Hilfe der Symmetrieeigenschaften von  $\mathbf{P}_{k|k-1}$ ,  $\mathbf{Q}_{k,k_0}$  und  $\mathbf{S}_k$  sowie dem Wissen aus Gleichung (5.2.20) wird durch Einsetzen von Gleichung (5.2.23) in Gleichung (5.2.19) folgende Vereinfachung erzielt:

$$\begin{aligned} & \operatorname{cov}\left\{ \begin{bmatrix} \mathbf{x}_{k} \\ \mathbf{v}_{k,k_{0}} \end{bmatrix} \middle| Z^{k} \right\} = \sum_{j=0}^{M} p_{j} \cdot \left[ \begin{bmatrix} \mathbf{P}_{k|k-1} & \mathbf{Q}_{k,k_{0}} \\ \mathbf{Q}_{k,k_{0}} & \mathbf{Q}_{k,k_{0}} \end{bmatrix} \\ & - \begin{bmatrix} \mathbf{P}_{k|k-1} \mathbf{H}_{k}^{T}(\mathbf{S}_{k}^{-1})_{j} \mathbf{H}_{k} \mathbf{P}_{k|k-1} & \mathbf{P}_{k|k-1} \mathbf{H}_{k}^{T}(\mathbf{S}_{k}^{-1})_{j} \mathbf{H}_{k} \mathbf{Q}_{k,k_{0}} \\ \mathbf{Q}_{k,k_{0}} \mathbf{H}_{k}^{T}(\mathbf{S}_{k}^{-1})_{j} \mathbf{H}_{k} \mathbf{P}_{k|k-1} & \mathbf{Q}_{k,k_{0}} \mathbf{H}_{k}^{T}(\mathbf{S}_{k}^{-1})_{j} \mathbf{H}_{k} \mathbf{Q}_{k,k_{0}} \\ & + \left( \begin{bmatrix} \hat{\mathbf{x}}_{k|k-1} \hat{\mathbf{x}}_{k|k-1}^{T} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} - \begin{bmatrix} \hat{\mathbf{x}}_{k|k-1} \hat{\mathbf{x}}_{k|k}^{T} & \hat{\mathbf{x}}_{k|k-1} \hat{\mathbf{y}}_{k,k_{0}|k} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \\ & + \begin{bmatrix} \hat{\mathbf{x}}_{k|k-1} (\boldsymbol{\gamma}_{k}^{T})_{j} (\mathbf{S}_{k}^{-1})_{j} \mathbf{H}_{k} \mathbf{P}_{k|k-1} & \hat{\mathbf{x}}_{k|k-1} (\boldsymbol{\gamma}_{k}^{T})_{j} (\mathbf{S}_{k}^{-1})_{j} \mathbf{H}_{k} \mathbf{Q}_{k,k_{0}} \\ & \mathbf{0} \end{bmatrix} \\ & + \begin{bmatrix} \mathbf{P}_{k|k-1} \mathbf{H}_{k}^{T}(\mathbf{S}_{k}^{-1})_{j} (\boldsymbol{\gamma}_{k})_{j} \hat{\mathbf{x}}_{k|k-1}^{T} & \mathbf{0} \\ (\hat{\mathbf{y}}_{k,k_{0}|k})_{j} \hat{\mathbf{x}}_{k|k-1}^{T} & \mathbf{0} \end{bmatrix} \\ & + \begin{bmatrix} \mathbf{P}_{k|k-1} \mathbf{H}_{k}^{T}(\mathbf{S}_{k}^{-1})_{j} (\boldsymbol{\gamma}_{k})_{j} (\boldsymbol{\gamma}_{k}^{T})_{j} (\mathbf{S}_{k}^{-1})_{j} \mathbf{H}_{k} \mathbf{P}_{k|k-1} & \mathbf{0} \\ (\hat{\mathbf{y}}_{k,k_{0}|k})_{j} (\hat{\mathbf{y}}_{k}^{T})_{j} (\mathbf{y}_{k})_{j} \hat{\mathbf{y}}_{k|k}^{T} & \mathbf{P}_{k|k-1} & \mathbf{P}_{k|k-1} \mathbf{H}_{k}^{T}(\mathbf{S}_{k}^{-1})_{j} (\boldsymbol{\gamma}_{k})_{j} \left( \hat{\mathbf{v}}_{k,k_{0}|k} \right)_{j} \\ & (\hat{\mathbf{v}}_{k,k_{0}|k})_{j} (\mathbf{y}_{k}^{T})_{j} (\mathbf{S}_{k}^{-1})_{j} \mathbf{H}_{k} \mathbf{P}_{k|k-1} & (\hat{\mathbf{v}}_{k,k_{0}|k})_{j} \left( \hat{\mathbf{v}}_{k,k_{0}|k} \right)_{j} \\ & \left( \hat{\mathbf{v}}_{k,k_{0}|k} \right)_{j} \hat{\mathbf{x}}_{k|k}^{T} & \mathbf{P}_{k|k-1} \mathbf{H}_{k}^{T}(\mathbf{S}_{k}^{-1})_{j} (\boldsymbol{\gamma}_{k})_{j} \hat{\mathbf{v}}_{k,k_{0}|k} \right] \\ & - \begin{bmatrix} \hat{\mathbf{x}}_{k|k} \hat{\mathbf{x}}_{k}^{T} & \mathbf{0} \\ \hat{\mathbf{x}}_{k,k_{0}|k} \hat{\mathbf{x}}_{k|k}^{T} & \mathbf{0} \\ \hat{\mathbf{v}}_{k,k_{0}|k} \hat{\mathbf{x}}_{k|k}^{T} & \hat{\mathbf{v}}_{k,k_{0}|k} \left( \hat{\mathbf{v}}_{k,k_{0}|k} \right)_{j} \end{bmatrix} \right] \right] \\ & - \begin{bmatrix} \hat{\mathbf{x}}_{k|k} \hat{\mathbf{x}}_{k}^{T} & \mathbf{0} \\ \hat{\mathbf{x}}_{k,k_{0}|k} \hat{\mathbf{x}}_{k|k}^{T} & \hat{\mathbf{x}}_{k|k} \left( \hat{\mathbf{v}}_{k,k_{0}|k} \right)_{j} \\ \hat{\mathbf{v}}_{k,k_{0}|k} \left( \hat{\mathbf{x}}_{k,0} \right)_{k} \left( \hat{\mathbf{v}}_{k,k_{0}|k} \right)_{j} \end{bmatrix} \right] \\ & - \begin{bmatrix} \hat{\mathbf{x}}_{k|k} \hat{\mathbf{x}}_{k}^{T} & \mathbf{0} \\ \hat{\mathbf{x}}_{k,k_{0}|k} \hat{\mathbf{x}}_{k}^{T} & \hat{\mathbf{x}}_{k} \\$$

Dies vervollständigt die Herleitung der gesuchten Terme. Die einzelnen Einträge der Kovarianzmatrix (5.2.14) können nun direkt aus (5.2.24) abgelesen werden. Damit ergibt sich für die Kovarianz  $\mathbf{P}_{k,k_0|k}^{\mathbf{x}\mathbf{v}}$  aus (5.2.14):

$$\begin{aligned} \mathbf{P}_{k,k_{0}|k}^{\mathbf{x}\mathbf{v}} &= \sum_{j=0}^{M} p_{j} \bigg[ (\mathbf{Q}_{k,k_{0}} - \mathbf{P}_{k|k-1}\mathbf{H}_{k}^{T}(\mathbf{S}_{k}^{-1})_{j}\mathbf{H}_{k}\mathbf{Q}_{k,k_{0}} \\ &\quad - \hat{\mathbf{x}}_{k|k-1}\hat{\mathbf{v}}_{k,k_{0}|k}^{T} + \hat{\mathbf{x}}_{k|k-1} \left( \hat{\mathbf{v}}_{k,k_{0}|k}^{T} \right)_{j} + \mathbf{P}_{k|k-1}\mathbf{H}_{k}^{T}(\mathbf{S}_{k}^{-1})_{j}(\boldsymbol{\gamma}_{k})_{j} \left( \hat{\mathbf{v}}_{k,k_{0}|k}^{T} \right)_{j} \\ &\quad - \mathbf{P}_{k|k-1}\mathbf{H}_{k}^{T}(\mathbf{S}_{k}^{-1})_{j}(\boldsymbol{\gamma}_{k})_{j}\hat{\mathbf{v}}_{k,k_{0}|k}^{T} + \hat{\mathbf{x}}_{k|k}\hat{\mathbf{v}}_{k,k_{0}|k}^{T} - \hat{\mathbf{x}}_{k|k} \left( \hat{\mathbf{v}}_{k,k_{0}|k}^{T} \right)_{j} \bigg] \\ &= \sum_{j=0}^{M} p_{j} \bigg[ (\mathbf{Q}_{k,k_{0}} - \mathbf{P}_{k|k-1}\mathbf{H}_{k}^{T}(\mathbf{S}_{k}^{-1})_{j}\mathbf{H}_{k}\mathbf{Q}_{k,k_{0}} \\ &\quad + \big[ \mathbf{P}_{k|k-1}\mathbf{H}_{k}^{T}(\mathbf{S}_{k}^{-1})_{j}(\boldsymbol{\gamma}_{k})_{j} + \hat{\mathbf{x}}_{k|k-1} - \hat{\mathbf{x}}_{k|k} \big] \left[ \left( \hat{\mathbf{v}}_{k,k_{0}|k} \right)_{j} - \hat{\mathbf{v}}_{k,k_{0}|k} \big]^{T} \bigg] \\ &= \sum_{j=0}^{M} p_{j} \bigg[ (\mathbf{Q}_{k,k_{0}} - (\mathbf{K}_{k})_{j}\mathbf{H}_{k}\mathbf{Q}_{k,k_{0}} \\ &\quad + \big[ (\mathbf{K}_{k})_{j}(\boldsymbol{\gamma}_{k})_{j} + \hat{\mathbf{x}}_{k|k-1} - \hat{\mathbf{x}}_{k|k} \big] \big[ \left( \hat{\mathbf{v}}_{k,k_{0}|k} \right)_{j} - \hat{\mathbf{v}}_{k,k_{0}|k} \big]^{T} \bigg]. \end{aligned}$$

$$(5.2.25)$$

Die Kreuzkovarian<br/>z $\mathbf{P}_{k,k_0|k}^{\mathbf{vv}}$  lässt sich beschreiben mit:

$$\begin{aligned} \mathbf{P}_{k,k_{0}|k}^{\mathbf{vv}} &= \mathbf{Q}_{k,k_{0}} - \sum_{j=0}^{M} p_{j} \bigg[ \mathbf{Q}_{k,k_{0}} \mathbf{H}_{k}^{T} (\mathbf{S}_{k}^{-1})_{j} \mathbf{H}_{k} \mathbf{Q}_{k,k_{0}} \\ &+ \left( \hat{\mathbf{v}}_{k,k_{0}|k} \right)_{j} \left( \hat{\mathbf{v}}_{k,k_{0}|k}^{T} \right)_{j} - \left( \hat{\mathbf{v}}_{k,k_{0}|k} \right)_{j} \hat{\mathbf{v}}_{k,k_{0}|k}^{T} - \hat{\mathbf{v}}_{k,k_{0}|k} \left( \hat{\mathbf{v}}_{k,k_{0}|k}^{T} \right)_{j} + \hat{\mathbf{v}}_{k,k_{0}|k} \hat{\mathbf{v}}_{k,k_{0}|k}^{T} \bigg] \\ &= \mathbf{Q}_{k,k_{0}} - \sum_{j=0}^{M} p_{j} \bigg[ \mathbf{Q}_{k,k_{0}} \mathbf{H}_{k}^{T} (\mathbf{S}_{k}^{-1})_{j} \mathbf{H}_{k} \mathbf{Q}_{k,k_{0}} \\ &+ \left( \hat{\mathbf{v}}_{k,k_{0}|k} \right)_{j} \left[ \left( \hat{\mathbf{v}}_{k,k_{0}|k}^{T} \right)_{j} - \hat{\mathbf{v}}_{k,k_{0}|k}^{T} \bigg] - \hat{\mathbf{v}}_{k,k_{0}|k} \bigg[ \left( \hat{\mathbf{v}}_{k,k_{0}|k}^{T} \right)_{j} - \hat{\mathbf{v}}_{k,k_{0}|k}^{T} \bigg] \bigg] \\ &= \mathbf{Q}_{k,k_{0}} - \sum_{j=0}^{M} p_{j} \bigg[ \mathbf{Q}_{k,k_{0}} \mathbf{H}_{k}^{T} (\mathbf{S}_{k}^{-1})_{j} \mathbf{H}_{k} \mathbf{Q}_{k,k_{0}} \\ &+ \bigg[ \left( \hat{\mathbf{v}}_{k,k_{0}|k} \right)_{j} - \hat{\mathbf{v}}_{k,k_{0}|k} \bigg] \bigg[ \left( \hat{\mathbf{v}}_{k,k_{0}|k} \right)_{j} - \hat{\mathbf{v}}_{k,k_{0}|k} \bigg]^{T}. \end{aligned}$$

$$(5.2.26)$$

Hiermit sind die gesuchten Kreuzkovarianzen vollständig hergeleitet, und die Retrodiktion lässt sich somit analog zu Tabelle 4.2 herleiten.

### Innovationsschritt

Nach der Retrodiktion folgt die Innovation mit probabilistischer Datenassoziation. Hierbei wird nicht nur eine OOS-Messung angenommen, sondern es werden beliebig viele OOS-Messungen berücksichtigt. Es wird daher auch in der Vergangenheit eine probabilistische Datenassoziation durchgeführt. Die modifizierte Innovation mit probabilistischer Datenassoziation in Kreuzkovarianzschreibweise folgt aus Gleichung (5.2.4):

$$\hat{\mathbf{x}}_{k|k_0} = \sum_{j=0}^{M} p_j \left[ \hat{\mathbf{x}}_{k|k} + \operatorname{cov}\{\mathbf{x}_k, (\mathbf{z}_{k_0})_j | Z^k\} \operatorname{cov}\{(\mathbf{z}_{k_0})_j | Z^k\}^{-1} \left( (\mathbf{z}_{k_0})_j - \mathbf{H}_{k_0} \hat{\mathbf{x}}_{k_0|k} \right) \right]. \quad (5.2.27)$$

Die beiden hierfür benötigten Kovarianzen werden analog zu (4.3.39) und (5.2.10) wie folgt berechnet:

$$\operatorname{cov}\{\mathbf{x}_{k}, (\mathbf{z}_{k_{0}})_{j} | Z^{k}\} = \operatorname{cov}\{\mathbf{x}_{k}, \mathbf{H}_{k_{0}} \mathbf{F}_{k_{0},k} (\mathbf{x}_{k} - \mathbf{v}_{k,k_{0}}) + (\mathbf{w}_{k_{0}})_{j} | Z^{k}\}$$
$$= \left[\mathbf{P}_{k|k} - \mathbf{P}_{k,k_{0}|k}^{\mathbf{x}\mathbf{v}}\right] \mathbf{F}_{k_{0},k}^{T} \mathbf{H}_{k_{0}}^{T}$$
$$= \mathbf{P}_{k,k_{0}|k}^{\mathbf{x}\mathbf{z}}$$
(5.2.28)

sowie

$$\operatorname{cov}\{(\mathbf{z}_{k_0})_j | Z^{k-1}\} = \mathbf{H}_{k_0} \mathbf{P}_{k_0 | k} \mathbf{H}_{k_0}^T + (\mathbf{R}_{k_0})_j = (\mathbf{S}_{k_0})_j.$$
(5.2.29)

Damit leitet man die Kalman-Verstärkungsmatrix wie in (4.3.40) her:

$$\left(\mathbf{W}_{k_0}\right)_j = \mathbf{P}_{k,k_0|k}^{\mathbf{x}\mathbf{z}} \left(\mathbf{S}_{k_0}\right)_j^{-1}.$$
 (5.2.30)

Die Innovation erfolgt danach analog zur Innovation nach der in Kapitel 4 hergeleiteten Retrodiktion. Hierbei ist wieder die Innovation mit probabilistischer Datenassoziation (5.1.4) durchzuführen. Man beachte, dass dafür neue Gewichte  $p_j$  berechnet werden müssen und sich eventuell auch die Anzahl M der im Suchbereich liegenden Messungen ändert. Die komplette OOSM-Innovation mit probabilistischer Datenassoziation lautet:

$$\hat{\mathbf{x}}_{k|k_0} = \sum_{j=0}^{M} p_j \left[ \hat{\mathbf{x}}_{k|k} + (\mathbf{W}_{k_0})_j \left( \boldsymbol{\gamma}_{k_0} \right)_j \right]$$
(5.2.31)

$$\mathbf{P}_{k|k_{0}} = \sum_{j=0}^{M} p_{j} \left[ \mathbf{P}_{k|k} - \mathbf{P}_{k,k_{0}|k}^{\mathbf{x}\mathbf{z}} \left( \mathbf{S}_{k_{0}}^{-1} \right)_{j} \left( \mathbf{P}_{k,k_{0}|k}^{\mathbf{x}\mathbf{z}} \right)^{T}$$
(5.2.32)

$$+\left(\hat{\mathbf{x}}_{k|k} + (\mathbf{W}_{k_0})_j \left(\boldsymbol{\gamma}_{k_0}\right)_j - \hat{\mathbf{x}}_{k|k_0}\right)$$
(5.2.33)

$$\cdot \left( \hat{\mathbf{x}}_{k|k} + \left( \mathbf{W}_{k_0} \right)_j \left( \boldsymbol{\gamma}_{k_0} \right)_j - \hat{\mathbf{x}}_{k|k_0} \right)^T \right].$$
 (5.2.34)

Dies vervollständigt die probabilistische Datenassoziation unter Einbeziehung von Messungen außerhalb der zeitlichen Reihenfolge. In Tabelle 5.1 sind die Gleichungen für die Retrodiktion im Ein-Schritt-Fall mit probabilistischer Datenassoziation zusammengefasst. Dabei sind die hergeleiteten Formeln wieder mit dem Index i für die Unterscheidung mehrerer Objekte erweitert.

### Retrodiktion

$\left(\hat{\mathbf{v}}_{k,k_{0} k} ight)_{ij}=\mathbf{Q}_{k,k_{0}}\mathbf{H}_{k}^{T}\left(\mathbf{S}_{k}^{-1} ight)_{ij}(oldsymbol{\gamma}_{k})_{ij}$			
$\left(\hat{\mathbf{v}}_{k,k_0 k}\right)_i = \mathbf{Q}_{k,k_0} \mathbf{H}_k^T \sum_{j=0}^{M_i} p_{ij} \left[ (\mathbf{S}_k^{-1})_{ij} (\boldsymbol{\gamma}_k)_{ij} \right]$			
$\left(\mathbf{S}_{k}\right)_{ij} = \mathbf{H}_{k} \left(\mathbf{P}_{k k-1}\right)_{i} \mathbf{H}_{k}^{T} + \left(\mathbf{R}_{k}\right)_{j}$			
$\left(\hat{\mathbf{x}}_{k_0 k}\right)_i = \mathbf{F}_{k_0,k} \left[ \left(\hat{\mathbf{x}}_{k k}\right)_i - \mathbf{Q}_{k,k_0} \mathbf{H}_k^T \sum_{j=0}^{M_i} p_{ij} \left[ (\mathbf{S}_k^{-1})_{ij} (\boldsymbol{\gamma}_k)_{ij} \right] \right]$			
$(\mathbf{K}_k)_{ij} = (\mathbf{P}_{k k-1})_i \mathbf{H}_k^T (\mathbf{S}_k^{-1})_{ij}$			
$(\mathbf{P}_{k,k_0 k}^{\mathbf{xv}})_i = \sum_{j=0}^{M_i} p_{ij} \bigg[ (\mathbf{Q}_{k,k_0} - (\mathbf{K}_k)_j \mathbf{H}_k \mathbf{Q}_{k,k_0} - (\mathbf{K}_k)_j \mathbf{H}_k \mathbf{Q}_{k,k_0} \bigg] \bigg]$			
$+\left[(\mathbf{K}_k)_j(\boldsymbol{\gamma}_k)_j+(\mathbf{\hat{x}}_{k k-1})_i-(\mathbf{\hat{x}}_{k k})_i\right]\left[\left(\hat{\mathbf{v}}_{k,k_0 k}\right)_{ij}-\left(\mathbf{\hat{v}}_{k,k_0 k}\right)_i\right]^T\right]$			
$(\mathbf{P}_{k,k_0 k}^{\mathbf{vv}})_i = \mathbf{Q}_{k,k_0} - \sum_{j=0}^{M_i} p_{ij} \bigg[ \mathbf{Q}_{k,k_0} \mathbf{H}_k^T (\mathbf{S}_k^{-1})_{ij} \mathbf{H}_k \mathbf{Q}_{k,k_0} \bigg]$			
$+ \left[ \left( \hat{\mathbf{v}}_{k,k_0 k} \right)_{ij} - \left( \hat{\mathbf{v}}_{k,k_0 k} \right)_i \right] \left[ \left( \hat{\mathbf{v}}_{k,k_0 k} \right)_{ij} - \left( \hat{\mathbf{v}}_{k,k_0 k} \right)_i \right]^T$			
$(\mathbf{P}_{k_0 k})_i = \mathbf{F}_{k_0,k} \bigg[ (\mathbf{P}_{k k})_i - (\mathbf{P}_{k,k_0 k}^{\mathbf{xv}})_i - \left(\mathbf{P}_{k,k_0 k}^{\mathbf{xv}}\right)_i^T + (\mathbf{P}_{k,k_0 k}^{\mathbf{vv}})_i \bigg] \mathbf{F}_{k_0,k}^T$			

### **OOSM-Innovation**

$$\begin{aligned} \left(\mathbf{S}_{k_{0}}\right)_{ij} &= \mathbf{H}_{k_{0}}\left(\mathbf{P}_{k_{0}|k}\right)_{i}\mathbf{H}_{k_{0}}^{T} + \left(\mathbf{R}_{k_{0}}\right)_{j} \\ \left(\mathbf{P}_{k,k_{0}|k}^{\mathbf{zz}}\right)_{i} &= \left[\left(\mathbf{P}_{k|k}\right)_{i} - \left(\mathbf{P}_{k,k_{0}|k}^{\mathbf{xv}}\right)_{i}\right]\mathbf{F}_{k_{0}|k}^{T}\mathbf{H}_{k_{0}}^{T} \\ \left(\mathbf{W}_{k_{0}}\right)_{ij} &= \left(\mathbf{P}_{k,k_{0}|k}^{\mathbf{zz}}\right)_{i}\left(\mathbf{S}_{k_{0}}\right)_{ij}^{-1} \\ \left(\boldsymbol{\gamma}_{k_{0}}\right)_{ij} &= \left(\mathbf{z}_{k_{0}}\right)_{j} - \mathbf{H}_{k_{0}}\left(\hat{\mathbf{x}}_{k_{0}|k}\right)_{i} \\ \left(\hat{\mathbf{x}}_{k|k_{0}}\right)_{i} &= \sum_{j=0}^{M_{i}} p_{ij}\left[\left(\hat{\mathbf{x}}_{k|k}\right)_{i} + \left(\mathbf{W}_{k_{0}}\right)_{ij}\left(\mathbf{\gamma}_{k_{0}}\right)_{ij}\right] \\ \left(\mathbf{P}_{k|k_{0}}\right)_{i} &= \sum_{j=0}^{M_{i}} p_{ij}\left[\left(\mathbf{P}_{k|k}\right)_{i} - \left(\mathbf{P}_{k,k_{0}|k}^{\mathbf{xz}}\right)_{i}\left(\mathbf{S}_{k_{0}}^{-1}\right)_{ij}\left(\mathbf{P}_{k,k_{0}|k}^{\mathbf{xz}}\right)_{i}^{T} \\ &+ \left(\left(\hat{\mathbf{x}}_{k|k}\right)_{i} + \left(\mathbf{W}_{k_{0}}\right)_{ij}\left(\mathbf{\gamma}_{k_{0}}\right)_{ij} - \left(\hat{\mathbf{x}}_{k|k_{0}}\right)_{i}\right) \\ &\cdot \left(\left(\hat{\mathbf{x}}_{k|k}\right)_{i} + \left(\mathbf{W}_{k_{0}}\right)_{ij}\left(\mathbf{\gamma}_{k_{0}}\right)_{ij} - \left(\hat{\mathbf{x}}_{k|k_{0}}\right)_{i}\right)^{T}\right] \end{aligned}$$

Tabelle 5.1: Zusammenfassung der Gleichungen für die Retrodiktion im Ein-Schritt-Fall mit probabilistischer Datenassoziation, wobei Objekte mit i und Messungen mit j indiziert werden.

## 5.2.2 Retrodiktion mit äquivalenter Messung (eA1)

In Kapitel 4.3.2 wurde die Retrodiktion für ein l-Schritt-Problem vorgestellt. Dabei wurde das l-Schritt-Problem durch die Berechnung einer äquivalenten Messung  $\mathbf{z}_k^*$  auf ein Ein-Schritt-Problem zurückgeführt. In der vorliegenden Arbeit wird die äquivalente Messung auch bei einer Retrodiktion mit JPDA-Datenassoziation angewendet. Dabei werden nicht Messungen mehrerer Zeitschritte, sondern Messungen einer JPDA-Innovation zum Zeitpunkt  $t_k$  zusammengefasst. Wird die Berechnung der äquivalenten Messung für JPDA erweitert, so muss für jedes der i Objekte folgende Berechnung durchgeführt werden:

$$\left(\mathbf{R}_{k}^{*-1}\right)_{i} = \left(\mathbf{P}_{k|k}^{*-1}\right)_{i} - \left(\mathbf{P}_{k|k-1}^{*-1}\right)_{i}$$
(5.2.35)

$$\left(\mathbf{K}_{k}^{*}\right)_{i} = \left(\mathbf{P}_{k|k}\right)_{i} \left(\mathbf{R}_{k}^{*-1}\right)_{i}$$
(5.2.36)

$$\left(\boldsymbol{\gamma}^*\right)_i = \left(\mathbf{K}_k^{*-1}\right)_i \left[ \left( \hat{\mathbf{x}}_{k|k} \right)_i - \left( \hat{\mathbf{x}}_{k|k-1} \right)_i \right]$$
(5.2.37)

$$\left(\mathbf{S}_{k}^{*}\right)_{i} = \left(\mathbf{P}_{k|k-1}\right)_{i} + \left(\mathbf{R}_{k}^{*}\right)_{i}.$$
(5.2.38)

Nach Berechnung der äquivalenten Messung können die Retrodiktionsgleichungen aus Tabelle 4.2 für jedes der i Objekte erweitert werden:

$$\left(\hat{\mathbf{x}}_{k_{0}|k}\right)_{i} = \mathbf{F}_{k_{0},k} \left[ \left(\hat{\mathbf{x}}_{k|k}\right)_{i} - \mathbf{Q}_{k,k_{0}} \left(\mathbf{S}_{k}^{*-1}\right)_{i} \left(\boldsymbol{\gamma}_{k}^{*-1}\right)_{i} \right]$$
(5.2.39)

$$\left(\mathbf{P}_{k,k_0|k}^{\mathbf{vv}}\right)_i = \mathbf{Q}_{k,k_0} - \mathbf{Q}_{k,k_0} \left(\mathbf{S}_k^{*-1}\right)_i \mathbf{Q}_{k,k_0}$$
(5.2.40)

$$\left(\mathbf{P}_{k,k_{0}|k}^{\mathbf{xv}}\right)_{i} = \mathbf{Q}_{k,k_{0}} - \left(\mathbf{P}_{k|k-1}\right)_{i} \left(\mathbf{S}_{k}^{*-1}\right)_{i} \mathbf{Q}_{k,k_{0}}$$
(5.2.41)

$$\left(\mathbf{P}_{k_{0}|k}\right)_{i} = \mathbf{F}_{k_{0},k} \left[ \left(\mathbf{P}_{k|k}\right)_{i} + \left(\mathbf{P}_{k,k_{0}|k}^{\mathbf{vv}}\right)_{i} - \left(\mathbf{P}_{k,k_{0}|k}^{\mathbf{xv}}\right)_{i} - \left(\mathbf{P}_{k,k_{0}|k}^{\mathbf{xv}}\right)_{i}^{T} \right] \mathbf{F}_{k_{0},k}^{T}.$$
(5.2.42)

Nach der Zustands- und Kovarianzretrodiktion erfolgt die Innovation mit der Messung  $\mathbf{z}_{k_0}$ . Gleichungen (5.1.4) und (5.1.5) werden angewendet, um die a posteriori Zustandsund Kovarianzmatrizen  $(\hat{\mathbf{x}}_{k|k_0})_i$  und  $(\mathbf{P}_{k|k_0})_i$  für das *i*-te Objekt zum Zeitpunkt  $t_k$  zu erhalten.

Die Verwendung einer äquivalenten Messung stellt eine Alternative zur im letzten Abschnitt vorgestellten Methode dar. Insbesondere bei zahlreichen Messungen kann es von Vorteil sein, diese zunächst zusammenzufassen. Bei wenigen Messungen kann der Aufwand zur Berechnung einer äquivalenten Messung unverhältnismäßig groß sein, da hier unter anderem einige Matrixinvertierungen nötig sind. Die Verwendung einer äquivalenten Messung betrifft nur die Retrodiktion, die Innovation findet in jedem Fall entsprechend Tabelle 5.1 statt.

## 5.2.3 Vorwärts-Prädiktion mit Fusion und Dekorrelation

Im Kapitel 4.4 wurde der FPFD-Algorithmus sowohl für das Ein-Schritt- als auch das *l*-Schritt-Problem vorgestellt. Bei dieser Methode wird anstatt einer Retrodiktion eine Prädiktion vom Zeitschritt vor der OOS-Messung durchgeführt. Der FPFD-Algorithmus wird im Folgenden zur Anwendung einer JPDA-Datenassoziation angepasst. Im ersten Schritt dieser Methode erfolgt die Prädiktion der Systemzustände und der Schätzfehlerkovarianz vom Zeitpunkt vor der OOS-Messung  $t_{k-1}$  zum Zeitpunkt  $t_{k_0}$ . Für jedes der *i* Objekte mit Schätzungen  $(\hat{\mathbf{x}}_{k-1|k-1})_i$  und  $(\mathbf{P}_{k-1|k-1})_i$  werden die a priori Zustände  $(\hat{\mathbf{x}}_{k_0|k-1})_i$  und  $(\mathbf{P}_{k_0|k-1})_i$  berechnet. Durch die Integration der OOS-Messung zum Zeitpunkt  $t_{k_0}$  mit den üblichen JPDA-Gleichungen ergeben sich die a posteriori Schätzungen  $(\hat{\mathbf{x}}_{k_0|k_0})_i$  und  $(\mathbf{P}_{k_0|k_0})_i$ .

Im zweiten Schritt erfolgen zwei Prädiktionen der Systemzustände und Schätzfehlerkovarianz vom Zeitpunkt  $t_{k_0}$  zum Zeitpunkt  $t_k$ . Bei der ersten Prädiktion ist die nicht chronologische Messung bereits integriert, dies liefert  $(\hat{\mathbf{x}}_{k|k_0})_i$ ,  $(\mathbf{P}_{k|k_0})_i$ . Bei der zweiten Prädiktion ist die OOS-Messung nicht integriert, was zu  $(\hat{\mathbf{x}}_{k|k-1})_i$ ,  $(\mathbf{P}_{k|k-1})_i$  führt. Diese zwei Schätzfehlerkovarianzen werden im Zeitschritt  $t_k$  wie folgt dekorreliert und fusioniert:

$$\left(\mathbf{P}_{k|k,k_0}^{-1}\right)_i = \left(\mathbf{P}_{k|k}^{-1}\right)_i + \left[\left(\mathbf{P}_{k|k_0}^{-1}\right)_i - \left(\mathbf{P}_{k|k-1}^{-1}\right)_i\right].$$
(5.2.43)

In der Schreibweise der Informationsmatrix entspricht die Addition einer Fusion und die Subtraktion einer Dekorrelation. Dabei ist  $(\mathbf{P}_{k|k})_i$  die Schätzfehlerkovarianz von Objekt i zum Zeitpunkt  $t_k$ , bevor die OOS-Messung  $\mathbf{z}_{k_0}$  die Fusionseinheit erreicht. Die Systemzustände werden schließlich aktualisiert durch:

$$\left( \hat{\mathbf{x}}_{k|k,k_0} \right)_i = \left( \mathbf{P}_{k|k,k_0} \right)_i \left[ \left( \mathbf{P}_{k|k}^{-1} \right)_i \left( \hat{\mathbf{x}}_{k|k} \right)_i + \left( \mathbf{P}_{k|k_0}^{-1} \right)_i \left( \hat{\mathbf{x}}_{k|k_0} \right)_i - \left( \mathbf{P}_{k|k-1}^{-1} \right)_i \left( \hat{\mathbf{x}}_{k|k-1} \right)_i \right].$$
 (5.2.44)

Diese Gleichung wird durch die Berechnung einer äquivalenten Messung hergeleitet. Dabei unterscheidet sich der Standard-FPFD-Algorithmus nicht von dem FPFD-Algorithmus mit JPDA-Datenassoziation.

### 5.2.4 *l*-Schritt-Problem

Bei einem l-Schritt-Problem kann sowohl die Retrodiktion mit äquivalenter Messung aus Kapitel 5.2.2 als auch der FPFD-Algorithmus aus Kapitel 5.2.3 benutzt werden. Ersetzt man bei den Gleichungen des eA1-Algorithmus die Zeitindizes k - 1 mit k - l, erhält man den eAl-Algorithmus. Aufgrund der Korreliertheit von Mess- und Prozessrauschen sind die Algorithmen für das l-Schritt-Problem nur approximierte Lösungen, siehe [4]. Abbildungsbaum 5.3 zeigt einen Überblick über die hier vorgestellten und hergeleiteten OOSM-Algorithmen zur JPDA-Datenassoziation. Im folgenden Abschnitt werden diese Algorithmen im Vergleich zur Reprozessierung, der Wiederaufbereitung aller Sensormessdaten vom Zeitpunkt der OOS-Messung bis zum aktuellen Zeitpunkt, evaluiert.

# 5.3 Evaluation

In diesem Abschnitt werden die vorgestellten OOSM-Algorithmen mit dem probabilistischen Datenassoziationsverfahren JPDA ausgewertet. Es soll jedoch kein Vergleich der verschiedenen OOSM-Algorithmen mit der Messdatenverzögerung erfolgen, sondern es



**Abbildung 5.3:** Überblick der OOSM-Algorithmen für ein Ein-Schritt- und Mehr-Schritt-OOSM-Problem mit JPDA-Datenassoziation.

soll evaluiert werden, wie gut die hergeleiteten OOSM-Algorithmen mit Datenassoziation im Vergleich zur Reprozessierung sind. Hier wird gezeigt, dass die OOSM-Algorithmen im Ein-Schritt-Fall eine zur Reprozessierung äquivalente Lösung und im Mehr-Schritt-Fall eine gute Approximation liefern. Die Evaluierung der OOSM-Algorithmen im Vergleich zur Messdatenverzögerung wird in Kapitel 7 vorgestellt.

# 5.3.1 Ein-Schritt-Problem

Im ersten Experiment wird ein Ein-Schritt-OOSM-Problem zweier Sensoren mit 70 bzw. 50 ms Latenz und einer Zykluszeit von 40 bzw. 66 ms simuliert. Es werden die Algorithmen modifizierte Retrodiktion mA1, Retrodiktion mit äquivalenter Messung eA1 und FPFD untersucht und mit der Reprozessierung verglichen.

# Simulation einer Frontalkollision

Das erste Szenario zur Untersuchung der OOSM-Algorithmen mit JPDA-Datenassoziation stellt eine Frontalkollision zweier Fahrzeuge dar. Eine schematische Darstellung des Szenarios findet sich in Abbildung 5.4. Dabei fährt ein Auto mit konstanter Geschwindigkeit auf das Sensorfahrzeug zu. Zehn Meter vor dem Fahrzeug fährt das Kollisionsfahrzeug knapp an einem stehenden Objekt vorbei. Beide Ziele fallen in den gleichen Suchbereich und werden bei einem JPDA-Datenassoziationsverfahren gewichtet zu jeweils beiden Objekten assoziiert. Damit beide Ziele in den gleichen Suchbereich fallen, wird zu Simulationszwecken die Geschwindigkeit bei der Datenassoziation nicht verwendet. Die Sensormessdaten bestehen bei diesem Versuch aus Winkel und Entfernung, die in kartesische Koordinaten umgewandelt werden. Die realen Ziele werden nur mit einer bestimmten Detektionswahrscheinlichkeit  $P_D$  beträgt bei dieser Simulation 99 % und  $\beta$  wird mit 0,0005 Messungen pro Quadratmeter angegeben, die durch Hintergrundrauschen erzeugt werden.

In der folgenden Auswertung wird Reprozessierung als Vergleichsalgorithmus verwendet, da dieser den exaktesten Algorithmus bei OOS-Messungen darstellt. Wie in Kapitel 4 beschrieben, liefert die Retrodiktion ohne Datenassoziation im Ein-Schritt-Fall Ergebnisse,


Abbildung 5.4: Simulation einer Frontalkollision: Das Kollisionsfahrzeug fährt mit konstanter Geschwindigkeit (10 m/s) auf das Sensorfahrzeug zu. Bei der Vorbeifahrt an einem 10 m vor dem Fahrzeug stehenden Objekt kommt es zu einer Mehrfachzuordnung im Datenassoziationsschritt.

die qualitativ mit denen der Reprozessierung gleichwertig sind. Es konnte sogar analytisch bewiesen werden, dass die beiden Algorithmen äquivalent sind. Im vorliegenden Fall mit probabilistischer Datenassoziation ist offensichtlich die Reprozessierung ebenfalls der exakteste Algorithmus, da hier bei Eintreffen einer OOS-Messung die Schätzung und Datenassoziation komplett neu durchgeführt werden. Reprozessierung mit probabilistischer Datenassoziation kann daher als Vergleichsalgorithmus verwendet werden, und das Ziel der Evaluation ist es zu zeigen, dass die hergeleiteten OOSM-Algorithmen mit probabilistischer Datenassoziation vergleichbar gute Ergebnisse liefern.

Die Ergebnisse der Auswertung sind in Abbildung 5.5 dargestellt. Zu sehen ist der Positionsfehler (*engl.* "Root Mean Square Error", RMSE) über 1 000 Monte-Carlo-Simulationen bei der Verfolgung des Kollisionsfahrzeugs. Wie man sieht, liefern die verwendeten Algorithmen vergleichbare Ergebnisse, die Kurven unterscheiden sich nicht wesentlich. Alle vier Algorithmen (Reprozessierung, *m*A1, *e*A1 und FPFD), die in Abschnitt 5.2 für das Ein-Schritt-Problem vorgestellt wurden, können das Objekt ohne Abbruch verfolgen. Abgesehen von numerischen Rundungsfehlern sind die Positionsfehler bei allen vier Algorithmen identisch. Sie liegen bei allen Algorithmen konstant bei ungefähr 35cm, was verdeutlicht, dass die Datenassoziation unter Einbeziehung von OOS-Messungen in jedem Schritt erfolgreich verläuft. Die Reprozessierung erfordert deutlich mehr Aufwand, da die gesamte Datenassoziation mit exponentieller Komplexität erneut durchgeführt werden muss. Im Vergleich hierzu liefern die hergeleiteten OOS-Algorithmen mit probabilistischer Datenassoziation vergleichbar gute Ergebnisse unter geringerem Aufwand und stellen daher eine lohnende Alternative dar.

Die genauen numerischen Positionsfehler sowohl für das Kollisionsfahrzeug als auch das stehende Objekt sind in Tabelle 5.2 abgebildet. Die Daten sind nach einer Simulationszeit von t = 1 s aufgenommen worden, das heißt, wenn das Kollisionsfahrzeug in zehn Meter Entfernung an dem stehenden Objekt vorbeifährt. Der in Kapitel 5.2.1 hergeleitete Retrodiktionsalgorithmus mA1 liefert dabei das gleiche Ergebnis wie der Retrodiktionsalgorithmus mit äquivalenter Messung (eA1). Diese beiden Algorithmen liefern sogar bis auf Mikrometer identische Ergebnisse. Das liegt daran, dass die beiden Algorithmen ohne



**Abbildung 5.5:** Positionsfehler (RMSE) des Kollisionsfahrzeuges im Ein-Schritt-Fall (Szenario Frontalkollision).

Algorithmus	Stehendes Objekt	Kollisionsfahrzeug
Reprozessierung Retrodiktion $(mA1)$ Retrodiktion $(eA1)$ FPFD	$\begin{array}{c} 353,\!872\mathrm{mm} \\ 356,\!371\mathrm{mm} \\ 356,\!371\mathrm{mm} \\ 356,\!395\mathrm{mm} \end{array}$	$355,005\mathrm{mm}$ $356,135\mathrm{mm}$ $356,135\mathrm{mm}$ $356,076\mathrm{mm}$

**Tabelle 5.2:** Positionsfehler (RMSE) des Kollisionsfahrzeugs und des stehenden Objekts zum Zeitpunkt t = 1 s im Ein-Schritt-Fall.

Datenassoziation analytisch äquivalent sind und sich im vorliegenden Fall nur in der Reihenfolge der Datenassoziation unterscheiden. Diese Reihenfolge hat bei den Algorithmen mA1 und eA1 offensichtlich keine Auswirkung, im Unterschied zur Reprozessierung und dem FPFD-Algorithmus, die sich aus diesem Grund im Millimeterbereich unterscheiden. Die Reprozessierung, also Wiederaufarbeiten von Messungen, verändert das Hintergrundrauschen die Gewichtungen des JPDA-Filters und verursacht kleine Unterschiede bei der Innovation.

Nimmt man Reprozessierung als Referenz, so zeigen die Ergebnisse der Simulation, dass alle vier Algorithmen erfolgreich bei einer JPDA-Datenassoziation angewendet werden können. Es ist also nicht der erhöhte Aufwand einer kompletten Reprozessierung nötig, sondern die hergeleiteten Algorithmen zur Datenassoziation bei OOS-Messungen erweisen sich als ebenso performant.

#### Simulation eines Kreuzungsszenarios

Abbildung 5.6 zeigt das zweite Szenario zur Untersuchung von OOSM-Algorithmen mit JPDA-Datenassoziation. Dabei wurde eine typische innerstädtische Kreuzungsszene mit kurzen Beobachtungszeiten simuliert. Das Sensorfahrzeug fährt hinter einem Fahrzeug auf eine Kreuzung zu. Von der Seite nähert sich ein drittes Fahrzeug, das schließlich mit dem Sensorfahrzeug kollidiert. Für das Ein-Schritt-Verfahren werden wieder Sensorlatenzen von 70 bzw. 50 ms und Zykluszeiten von 40 bzw. 66 ms angenommen.



Abbildung 5.6: Simulation eines Kreuzungsszenarios: Sensorfahrzeug fährt mit konstanter Geschwindigkeit von 15 m/s hinter einem Kolonnenfahrzeug und kollidiert mit dem Kollisionsfahrzeug bei  $\xi = 22 \text{ m}$ .

Abbildung 5.7 zeigt den Positionsfehler über 1000 Monte-Carlo-Simulationen für das Kollisionsfahrzeug. Alle vier Algorithmen (Reprozessierung, mA1, eA1 und FPFD) können das Objekt auch beim zweiten Szenario ohne Abbruch verfolgen. Die Positionsfehler sind wie beim vorherigen Szenario wegen der Reihenfolge der Datenassoziation geringfügig unterschiedlich.

Das Volumen der Schätzfehlerkovarianz  $\mathbf{P}_{k|k}$  während der ersten sechs Filterzyklen ist in Tabelle 5.3 aufgelistet. Das Volumen der Schätzfehlerkovarianz wird im Einschwingvorgang mit jeder neu integrierten Messung verkleinert. Die erste OOS-Messung erreicht die Fusionseinheit zur Ankunftszeit von 136 ms und wurde zum Zeitpunkt  $t_0 = 66 \text{ ms}$ gemessen. Wie man anhand der Tabelle sieht, liefern die Retrodiktionsalgorithmen mA1und eA1 sowie der FPFD-Algorithmus im Ein-Schritt-Fall vergleichbar gute Ergebnisse wie die Reprozessierung.



**Abbildung 5.7:** (a) Positionsfehler und (b) vergrößerter Ausschnitt des Kollisionsfahrzeuges im Ein-Schritt-Fall (Kreuzungsszenario).

Messzeitpunkt [ms]	0	0	40	80	66	120
Ankunftszeit [ms]	50	70	90	130	136	170
Reprozessierung Retrodiktion $(mA1)$ Retrodiktion $(eAl)$ FPFD	$\begin{array}{c} 13,\!465 \\ 13,\!465 \\ 13,\!465 \\ 13,\!465 \end{array}$	6,809 6,809 6,809 6,809	3,822 3,822 3,822 3,822	1,885 1,885 1,885 1,885	$1,348 \\ 1,359 \\ 1,359 \\ 1,358$	$0,753 \\ 0,760 \\ 0,760 \\ 0,758$

**Tabelle 5.3:** 1 $\sigma$ -Volumen der Schätzfehlerkovarianz  $\mathbf{P}_{k|k}$  für ein Ein-Schritt-Problem.

## 5.3.2 *l*-Schritt-Problem

### Simulation eines Kreuzungsszenarios

Das gleiche Fahrszenario aus Abbildung 5.6 wurde entsprechend dem Sensoraufbau des Versuchsfahrzeuges aus Kapitel 2.2 simuliert. Dabei sind die Latenzen zu 80 bzw. 198 ms und die Zykluszeiten zu 40 bzw. 66 ms gewählt. Daraus ergibt sich, dass die OOS-Messung minimal zwei und maximal drei Zeitschritte zurückliegen kann, womit es sich um ein Drei-Schritt-OOSM-Problem handelt. Die Latenzen und Zykluszeiten wurden somit in der Simulation entsprechend den zeitlichen Eigenschaften des SRR- und MMR-Sensor gewählt.

In Abbildung 5.8 ist der Positionsfehler über 1 000 Monte-Carlo-Simulationen gezeigt. Im Unterschied zum Ein-Schritt-Verfahren handelt es sich beim Retrodiktionsalgorithmus eAl und dem FPFD-Algorithmus um eine Approximation aufgrund der Korreliertheit



**Abbildung 5.8:** (a) Positionsfehler und (b) vergrößerter Ausschnitt von dem verfolgten Objekt des Kollisionsfahrzeuges im Drei-Schritt-Fall (Kreuzungsszenario).

von Prozess- und Messrauschen. Man sieht, dass die Ergebnisse dieser beiden Algorithmen sogar minimal besser als Reprozessierung sind. Dieser Effekt ist erst im vergrößerten Ausschnitt zu sehen. Die Abweichungen bewegen sich jedoch im Zentimeterbereich und sind für die vorliegende Anwendung nicht signifikant. Dass es in diesem Fall zu einer Verbesserung kommt, ist situationsabhängig und kann mit der unterschiedlichen Reihenfolge der Assoziation von Messdaten begründet werden.

Das 1 $\sigma$ -Volumen der Schätzfehlerkovarianz  $\mathbf{P}_{k|k}$  während der ersten fünf Filterzyklen ist in Tabelle 5.4 aufgelistet. Die erste OOS-Messung erreicht die Fusionseinheit zur Ankunftszeit von 198 ms und wurde zum Zeitpunkt  $t_0 = 0$  ms gemessen. Die unterschiedlichen numerischen Ergebnisse im Volumen der Schätzfehlerkovarianz sind zum einen auf die Approximationen im *l*-Schritt-Fall und zum anderen wie im Ein-Schritt-Fall auf die Reihenfolge der Datenassoziation zurückzuführen.

Messzeitpunkt [ms]	0	40	80	0	120
Ankunftszeit [ms]	80	120	160	198	200
Reprozessierung Retrodiktion $(eAl)$ FPFD	$13,465 \\ 13,465 \\ 13,465$	6,007 6,007 6,007	2,833 2,833 2,833	$1,909 \\ 1,933 \\ 1,885$	$0,948 \\ 0,949 \\ 0,941$

**Tabelle 5.4:** 1- $\sigma$ -Volumen der Schätzfehlerkovarianz  $\mathbf{P}_{k|k}$  für ein *l*-Schritt-Problem.

Insgesamt zeigen die vorgestellten Untersuchungen, dass die hergeleiteten probabilistischen Datenassoziationsverfahren bei OOS-Messungen sehr performant sind. Die erzielten Ergebnisse sind vergleichbar mit denen der Reprozessierung. Die neuen Algorithmen bieten daher aufgrund des geringeren Rechenaufwands eine lohnende Alternative zur Reprozessierung. Eine Komplexitätsanalyse der Algorithmen wird im folgenden Abschnitt gegeben.

# 5.4 Komplexitätsanalyse

In diesem Abschnitt wird untersucht, wie viel Rechenaufwand durch Anwendung der vorgeschlagenen OOSM-Algorithmen im Vergleich zur Reprozessierung mit probabilistischer Datenassoziation gespart werden kann.

### 5.4.1 Laufzeit

Tabelle 5.5 zeigt eine Laufzeituntersuchung der implementierten Simulation. Diese praktische Evaluation ist von der Implementierung abhängig, kann jedoch für einen ersten Vergleich verwendet werden. Man sieht, dass Reprozessierung insgesamt das langsamste Verfahren ist, was einen erheblichen Nachteil darstellt. Beim Ein-Schritt-OOSM-Problem ist die Reprozessierung um 10 % bis 20 % langsamer als die Retrodiktionsalgorithmen und der FPFD-Algorithmus. Beim Drei-Schritt-OOSM-Problem sind die Unterschiede sehr viel deutlicher zu sehen. Der FPFD-Algorithmus ist im Vergleich zur Reprozessierung fast doppelt so schnell. Im Unterschied zu Kapitel 4, in welchem die OOSM-Algorithmen mit nicht-probabilistischen Datenassoziationsverfahren vorgestellt wurden, wirkt sich bei diesen Experimenten das Wiederholen der Datenassoziation bei der Reprozessierung sehr viel stärker aus. Insgesamt lässt sich bei probabilistischer Datenassoziation daher sogar noch mehr Aufwand sparen, wenn man OOSM-Algorithmen statt Reprozessierung verwendet, als bei herkömmlichen OOSM-Verfahren ohne Datenassoziation.

Algorithmus	Reprozessierung	mA1	eA1/eAl	FPFD
Ein-Schritt-Problem Drei-Schritt-Problem	100% $100%$	$92,\!99\%$	81,71% 56.01 $\%$	88,54% 52.85\%

Tabelle 5.5: Relativer Vergleich der Laufzeit über 1000 Monte-Carlo-Simulationen.

### 5.4.2 Speicherbedarf

Im Unterschied zur Retrodiktion mit einem Ein-Nachbar-Datenassoziationsverfahren benötigt man bei der modifizierten Retrodiktion mA1 noch zusätzlich den a priori Systemzustand  $\hat{\mathbf{x}}_{k|k-1}$  zum Zeitpunkt  $t_k$ . Tabelle 5.6 zeigt die zu speichernden Daten bei einem Ein-Schritt-OOSM-Problem, wobei die aktuellen Systemzustände  $\hat{\mathbf{x}}_{k|k}$  und  $\mathbf{P}_{k|k}$  jeweils als gegeben vorausgesetzt werden. Man sieht, dass die Retrodiktion mit probabilistischer Datenassoziation in Bezug auf Speicheranforderungen keine Verbesserung zur Reprozessierung darstellt. Der Algorithmus mit äquivalenter Messung und der FPFD-Algorithmus

Algorithmus		Speichervariable			Speicherbedarf
Reprozessierung	$\mathbf{P}_{k-1 k-1}$	$\mathbf{\hat{x}}_{k-1 k-1}$	$(\mathbf{z}_k)_j$	$(\mathbf{R}_k)_j$	$N^2 + N + jM + jM^2$
mA1	$\mathbf{P}_{k k-1}$	$\mathbf{\hat{x}}_{k k-1}$	$(oldsymbol{\gamma})_j$	$(\mathbf{S}_k)_j$	$N^2 + N + jM + jM^2$
eA1	$\mathbf{P}_{k-1 k-1}$	$\mathbf{\hat{x}}_{k-1 k-1}$			$N^2 + N$
FPFD	$\mathbf{P}_{k-1 k-1}$	$\mathbf{\hat{x}}_{k-1 k-1}$			$N^2 + N$

**Tabelle 5.6:** Die zu speichernden Variablen für das Ein-Schritt-OOSM-Problem mit JPDA-Datenassoziation.

jedoch weisen einen deutlich geringeren Speicherbedarf auf. Bei einem l-Schritt-Problem steigt die Anzahl der zu speichernden Daten bei der Reprozessierung um ein Vielfaches von l an. Der Speicherbedarf des Retrodiktionsalgorithmus eAl und des FPFD-Algorithmus erhöht sich um ein Vielfaches der Schrittweite l, bleibt aber geringer als bei der Reprozessierung.

# 5.5 Kapitelzusammenfassung und Ausblick

In diesem Kapitel wurden die Retrodiktion und der FPFD-Algorithmus zur Verwendung mit probabilistischen Datenassoziationsverfahren erweitert. Bei der Prädiktion ist das Prozessrauschen unabhängig von den Systemzuständen. Bei der Retrodiktion gilt diese Annahme aufgrund von bereits integrierten Messungen nicht mehr. Durch die Innovation werden die Systemzustände vom Prozessrauschen abhängig. Dieser Einfluss muss bei einer Retrodiktion, einer Prädiktion in die Vergangenheit, wieder rückgängig gemacht werden. Im Falle einer Eins-zu-Eins-Datenassoziation wurden in Kapitel 4 die entsprechenden OOSM-Algorithmen vorgestellt. Im vorliegenden Kapitel wurde der Einfluss des Prozessrauschens unter Berücksichtigung von probabilistischer Datenassoziation hergeleitet. Wird ein Systemzustand zum Beispiel bei PDA oder JPDA mit einer gewichteten Summe aus mehreren Messungen aktualisiert, müssen bei einer Retrodiktion die Einflüsse verschiedener Prozessrauschterme berücksichtigt werden. Unter Berücksichtigung dieser Rauschterme wurde die Retrodiktion im Ein-Schritt-Fall für die Behandlung mit einer JPDA-Datenassoziation erweitert. Hierfür wurden mehrere mögliche Algorithmen hergeleitet und verglichen.

Mit simulierten Ergebnissen konnte gezeigt werden, dass die OOSM-Algorithmen vergleichbar gute Ergebnisse wie die Reprozessierung liefern. Dies konnte anhand verschiedener Szenarien nachgewiesen werden. Außerdem wurden die Algorithmen für ein Mehr-Schritt-OOSM-Problem angepasst und die Komplexität untersucht. Die Komplexitätsanalyse ergab, dass Reprozessierung deutlich aufwändiger ist als die vorgeschlagenen neuen Algorithmen. Dabei ist mit probabilistischer Datenassoziation sogar ein deutlich größerer Unterschied im Aufwand feststellbar als ohne Datenassoziation. Dies liegt an der exponentiellen Komplexität der JPDA-Datenassoziation, welche im Fall einer Reprozessierung komplett neu durchgeführt werden muss. Es wurde daher gezeigt, dass OOSM-Algorithmen mit probabilistischer Datenassoziation sogar mehr Ersparnis im Vergleich zu Reprozessierung liefern als die üblichen OOSM-Algorithmen ohne Datenassoziation.

Weiterführende Arbeiten mit Messungen außerhalb der zeitlichen Reihenfolge können sich auf Erweiterungen der JPDA-Datenassoziation, die JIPDA (*engl.* "Joint Integrated Probabilistic Data Association") [101] oder die JPDAM (*engl.* "Joint Probabilistic Data Association for possibly Merged Measurements") [34] konzentrieren.

# Situationsanalyse für Pre-Crash-Funktionen

In den meisten heutigen Pre-Crash-Systemen basiert die Entscheidung über eine Auslösung und Aktivierung von reversiblen Schutzmechanismen ausschließlich auf dem Zustandsvektor der verfolgten Objekte [109]. Die Unsicherheiten der Zustandsschätzung werden dabei nicht berücksichtigt, wodurch wertvolle Informationen verloren gehen. Um diese Problematik zu vermeiden, wird in der vorliegenden Arbeit die Berechnung einer sensorunabhängigen Kollisionswahrscheinlichkeit mittels Fehlerfortpflanzung vorgeschlagen. Die Berechnung basiert auf einer räumlichen und zeitlichen Transformation der Schätzfehlerkovarianz. Zuerst wird die Projektion des Zustandsvektors beschrieben, bevor auf drei Varianten der Schätzfehlerkovarianzprojektion eingegangen wird.

Bisherige thematisch verwandte Arbeiten berücksichtigen meistens nur die Zustandsschätzung ohne Kovarianzen. Eine Situationsbewertung für ein Pre-Crash-System mit einer Fusion aus Kamera, Lidar- und Radarsensor wurde in [63] vorgestellt. Dabei wurde sowohl die Position des eigenen Fahrzeuges als auch die Position des Hindernisses auf diskrete Zeitschritte in die Zukunft prädiziert. Die Arbeit geht jedoch nicht von einem Mehrobjektverfolgungssystem mit entsprechender Datenassoziation aus. Den Einfluss von Prädiktionen auf die Schätzfehlerkovarianz in Abhängigkeit der Sensorkonfiguration beschreibt [92]. Welche Zeit für die Aktivierung eines reversiblen Gurtstraffers benötigt wird und wie die Zeit bis zur Kollision modelliert wird, wurde in [75] beantwortet. Die zusätzliche Betrachtung von Fahrdynamik und Modellierung eines kammschen Kreises ist nachzulesen in [67, 74]. Die Wichtigkeit einer sehr niedrigen Falschalarmrate bei Pre-Crash-Funktionen und deren Auswirkungen auf die Situationsanalyse wurden in [73] untersucht. Die in dieser Arbeit hergeleiteten Methoden wurden in [153] veröffentlicht.

Die Zustandsschätzung des Kalmanfilters liefert nach jeder Innovation einen a posteriori Zustandsvektor  $\hat{\mathbf{x}}_{k|k}$  und eine a posteriori Schätzfehlerkovarianz  $\mathbf{P}_{k|k}$ . Die Idee des vorgestellten Verfahrens ist es, die Schätzfehlerkovarianz mittels einer nichtlinearen Transformation auf den Kollisionsort zu projizieren, wodurch eine Kollisionswahrscheinlichkeit ermittelt werden kann. Die vierdimensionale Zustandsraumschätzung mit Unsicherheit wird also auf eine eindimensionale Verteilung der Kollisionswahrscheinlichkeit projiziert.



Abbildung 6.1: Schematische Darstellung der nichtlinearen räumlichen Transformation von einem vierdimensionalen Zustandsvektor  $\hat{\mathbf{x}}_{k|k}$  in eine eindimensionale Kollisionskoordinate  $\psi_k$ . Die diskrete Häufigkeitsverteilung  $p(\psi_k)$  gibt die räumliche Kollisionswahrscheinlichkeit an.

Eine schematische Darstellung der Idee des hergeleiteten Verfahrens findet sich in Abbildung 6.1. Auf Basis der berechneten Kollisionswahrscheinlichkeit kann die Situationsbewertung eine fundierte Entscheidung zur Aktivierung des Pre-Crash-Systems treffen.

Einfache Systeme, die nur auf dem Zustandsvektor basieren, benötigen häufig Heuristiken zur richtigen Parametrierung des Systems. So wird zum Beispiel eine Mindestanzahl an Beobachtungsschritten vorausgesetzt oder der Auslösebereich wird eingeschränkt, um die Falschalarmrate zu reduzieren. Die Erkennungsrate eines solchen Systems ist dadurch geringer und die Aktivierung erfolgt mit einer späteren Auslösezeit. Außerdem ist die Wahl der Schwellwerte häufig nicht einfach, sondern basiert auf Erfahrungswerten. Durch die Projektion der Unsicherheiten entfallen diese Heuristiken, denn die Parametrierung erfolgt über die Berechnung einer Kollisionswahrscheinlichkeit. Die Wahl einer Auslöseschwelle stellt den einzigen zu bestimmenden Parameter der gesamten Pre-Crash-Situationsbewertung dar.

Aufgrund der Ungenauigkeit der Odometriedaten bei hochdynamischen Fahrmanövern, wie z.B. Schleudern, wird auf eine Eigenbewegungskompensation verzichtet. Deshalb wird ein relatives Objektverfolgungssystem vorgeschlagen und die Fehler des Fremdbewegungsmodells werden im Prozessrauschen modelliert. In jedem diskreten Filterzeitschritt wird die Kollisionswahrscheinlichkeit durch räumliche und zeitliche Projektionen berechnet. Die beiden Projektionen beschreiben das gesamte Entscheidungsmodul. Dabei werden die physikalischen Grenzen einer dynamischen Fahrszene vollständig durch die Unsicherheitsprojektion modelliert. Je höher die Kollisionswahrscheinlichkeit ist, desto geringer ist die Wahrscheinlichkeit, dass ein Unfall noch verhindert werden kann. Im folgenden Abschnitt 6.1 wird auf die Projektion des Zustandvektors und im Abschnitt 6.2 auf die Projektion der Schätzfehlerkovarianz eingegangen.

# 6.1 Projektion des Zustandsvektors

Die Projektion des Zustandsvektors hängt von der Wahl der zu beobachtenden Größen ab. Die Herleitungen in diesem Kapitel werden am Beispiel eines Zustandsvektors bestehend aus Positions- und Geschwindigkeitsangaben erläutert:

$$\mathbf{x} = \begin{bmatrix} \xi & \eta & \dot{\xi} & \dot{\eta} \end{bmatrix}^T. \tag{6.1.1}$$

Bei höherdimensionalen Zustandsvektoren, z.B. einem Beschleunigungsmodell, sind die abgeleiteten Zustandsgrößen entsprechend zu berücksichtigen. Die generellen Transformationsvorschriften bleiben jedoch unberührt. Der Fahrzeug-Referenzpunkt liegt zur Vereinfachung an der Fahrzeugfront in der Mitte des Stoßfängers.

Betrachtet wird ein Szenario mit einem entgegenkommenden Fahrzeug, dessen geschätzter Zustandsvektor zum Zeitpunkt  $t_k$  mit  $\hat{\mathbf{x}}_{k|k}$  bezeichnet wird. Die Idee ist es nun, diesen Zustandsvektor auf Basis des Bewegungsmodells zeitlich nach vorne zu projizieren und hiermit eine Schätzung des Kollisionspunktes zu ermitteln. Der erwartete Kollisionspunkt wird hierbei als Schnittpunkt  $\begin{bmatrix} 0 & \hat{\psi}_k \end{bmatrix}^T$  der geschätzten Trajektorie des entgegenkommenden Fahrzeugs mit der  $\eta$ -Achse des Ego-Fahrzeugkoordinatensystems definiert, wobei die Zustandsschätzung  $\hat{\mathbf{x}}_{k|k}$  als Grundlage dient. Neben dem räumlichen Kollisionspunkt  $\hat{\psi}_k$ soll auch der geschätzte Kollisionszeitpunkt  $\hat{\tau}_k$  auf Basis von  $\hat{\mathbf{x}}_{k|k}$  bestimmt werden. Dazu werden der Abstand  $d_k$  und der Winkel  $\delta_k$  zum erwarteten Kollisionspunkt  $\hat{\psi}_k$  berechnet. Abbildung 6.2 verdeutlicht die verwendeten Bezeichnungen.



Abbildung 6.2: Schematische Darstellung der Bezugsgrößen: Berechnet werden der Abstand  $d_k$  und der Winkel  $\delta_k$  zum Kollisionspunkt  $\hat{\psi}_k$  unter Verwendung der Fahrzeugkoordinaten  $(\xi_k, \eta_k, \dot{\xi}_k, \dot{\eta}_k)$ .

### 6.1.1 Räumliche Projektion

Die Größe der Koordinate  $\hat{\psi}_k$  gibt Aufschluss darüber, ob es zur Kollision kommt oder zu einer knappen Vorbeifahrt.

Gesucht ist also nicht der gesamte Zustandsvektor, sondern speziell die Koordinate  $\psi_k$ . Hierfür wird eine Projektion  $t_r$  definiert mit

$$t_{\rm r}\left(\hat{\mathbf{x}}_{k|k}\right) = \hat{\psi}_k. \tag{6.1.2}$$

Die Projektion  $\hat{\psi}_k$  von  $\hat{\mathbf{x}}_{k|k}$  kann auch als Erwartungswert des Auftreffpunktes interpretiert werden. Mit dem Zustandsvektor aus Gleichung (6.1.1) ergibt sich die nichtlineare räumliche Transformationsvorschrift  $t_r$ , die den aktuellen Zustandsvektor  $\hat{\mathbf{x}}_{k|k}$  auf die Kollisionskoordinate  $\hat{\psi}_k$  projiziert, wie folgt:

$$t_{\rm r}\left(\hat{\mathbf{x}}_{k|k}\right) = \begin{cases} \eta_k - \frac{\dot{\eta}_k}{\dot{\xi}_k} \xi_k & \text{für } \dot{\xi}_k < 0 \land \xi_k > 0\\ \infty & \text{sonst.} \end{cases}$$
(6.1.3)

Mit Hilfe dieser Transformation ist es nun möglich, den mittleren Auftreffpunkt des verfolgten Objektes auf der Fahrzeugfront zu bestimmen. Aufgrund der fehlenden Breiteninformation bei Radarmessungen können die Ausdehnungen der verfolgten Objekte nicht berücksichtigt werden, es wird daher von Punktobjekten ausgegangen.

### 6.1.2 Zeitliche Projektion

Die zeitliche Projektion ist notwendig, um das Pre-Crash-System im richtigen zeitlichen Auslösefenster zu aktivieren. Gesucht ist daher ein skalarer Wert  $\hat{\tau}_k$ , der den Erwartungswert der Zeit bis zum Aufprall (*engl.* "Time-to-Collision", TTC) angibt.

Um diesen Zeitspanne bis zur Kollision schätzen zu können, ist eine nichtlineare zeitliche Transformationsvorschrift  $t_z$  herzuleiten mit

$$t_{\mathbf{z}}(\hat{\mathbf{x}}_{k|k}) = \hat{\tau}_k. \tag{6.1.4}$$

Die Abbildung  $t_z$  projiziert also den aktuellen Zustandsvektor  $\hat{\mathbf{x}}_{k|k}$  zum Zeitpunkt k auf die Zeitachse  $\tau$ .

Bei gegebenem Zustandsvektor (6.1.1) lässt sich folgende konkrete Realisierung herleiten. Zunächst berechnet man den Abstand  $d_k$  und den Winkel  $\delta_k$  der Trajektorie des entgegenkommenden Fahrzeugs zur  $\eta$ -Achse, wie in Abbildung 6.2 dargestellt:

$$d_k = d\left(\hat{\mathbf{x}}_{k|k}\right) = \sqrt{\xi_k^2 + (\eta_k - \hat{\psi}_k)^2},\tag{6.1.5}$$

$$\delta_{k} = \delta\left(\hat{\mathbf{x}}_{k|k}\right) = \begin{cases} \arctan\left(\frac{\psi_{k} - \eta_{k}}{\xi_{k}}\right) & \text{für } \dot{\xi}_{k} < 0 \land \xi_{k} > 0\\ \text{nicht definiert} & \text{sonst,} \end{cases}$$
(6.1.6)

$$\dot{d}_k = \dot{d}\left(\hat{\mathbf{x}}_{k|k}\right) = \sqrt{\dot{\xi}_k^2 + \dot{\eta}_k^2} \ . \tag{6.1.7}$$

Die Zeit bis zum Aufprall berechnet sich aus dem Quotienten von Wegstrecke und Geschwindigkeit. Die nichtlineare zeitliche Transformationsvorschrift  $t_z$  ergibt sich daher wie folgt:

$$t_{z}(\hat{\mathbf{x}}_{k|k}) = \frac{d\left(\hat{\mathbf{x}}_{k|k}\right)}{\dot{d}\left(\hat{\mathbf{x}}_{k|k}\right)} = \begin{cases} \frac{\sqrt{\xi_{k}^{2} + (\eta_{k} - \hat{\psi}_{k})^{2}}}{\sqrt{\dot{\xi}_{k}^{2} + \dot{\eta}_{k}^{2}}} & \text{für } \dot{\xi}_{k} < 0 \land \xi_{k} > 0\\ \infty & \text{sonst.} \end{cases}$$
(6.1.8)

Einsetzen der hergeleiteten räumlichen Projektion  $t_r$  aus Gleichung (6.1.3) anstelle von  $\hat{\psi}_k$  führt mit einigen Umformungen auf die folgende vereinfachte Formel:

$$t_{z}(\hat{\mathbf{x}}_{k|k}) = \frac{d\left(\hat{\mathbf{x}}_{k|k}\right)}{\dot{d}\left(\hat{\mathbf{x}}_{k|k}\right)} = \begin{cases} \frac{|\xi_{k}|}{|\dot{\xi}_{k}|} & \text{für } \dot{\xi}_{k} < 0 \land \xi_{k} > 0\\ \infty & \text{sonst.} \end{cases}$$
(6.1.9)

Zustandsvektoren  $\hat{\mathbf{x}}_{k|k}$  der Form (6.1.1) können direkt in die nichtlinearen Transformationsgleichungen eingesetzt werden und sowohl räumlich (6.1.3) als auch zeitlich (6.1.9) projiziert werden. Mit Hilfe dieser Transformationsfunktionen ist es möglich, den Kollisionsort sowie die Zeit bis zur drohenden Kollision zu berechnen.

Die Projektion des Zustandsvektors beschreibt jedoch nicht, mit welcher Wahrscheinlichkeit dieses Ergebnis auftritt. So könnte z.B. der räumliche Auftreffpunkt im Auslösebereich der Fahrzeugfront liegen, die Unsicherheit jedoch so groß sein, dass das Pre-Crash-System nicht ausgelöst werden dürfte. Im folgenden Abschnitt werden verschiedene Verfahren zur Projektion der Schätzfehlerkovarianz mit den hier berechneten Transformationsfunktionen vorgestellt.

### 6.2 Projektionen der Schätzfehlerkovarianz

Der projizierte Zustandsvektor alleine beschreibt das System nicht vollständig, erst durch die Berücksichtigung der Unsicherheiten kann eine Vorhersage über die Kollisionswahrscheinlichkeit gegeben werden. Die Methoden der Unsicherheitsprojektion können auch als Verfahren zur Bestimmung der Fehlerfortpflanzung beschrieben werden. Gesucht sind Methoden, um die räumliche und zeitliche Varianz zu berechnen. Die Varianzen werden wie folgt definiert:

$$\sigma_{\psi}^2 = \mathbf{E}\left[(\psi - \hat{\psi})(\psi - \hat{\psi})^T\right] \quad \text{sowie} \quad \sigma_{\tau}^2 = \mathbf{E}\left[(\tau - \hat{\tau})(\tau - \hat{\tau})^T\right]. \tag{6.2.1}$$

Die Idee zur Berechnung dieser Größen ist es, nicht nur die Zustandsvektoren, sondern auch die Kovarianzmatrizen  $\mathbf{P}$  der Zustandsschätzung zu projizieren. Der Zustandsvektor aus Gleichung (6.1.1) hat folgende Schätzfehlerkovarianz:

$$\mathbf{P} = \begin{bmatrix} \sigma_{\xi}^{2} & \sigma_{\xi\eta}^{2} & \sigma_{\xi\xi}^{2} & \sigma_{\xi\eta}^{2} \\ \sigma_{\xi\eta}^{2} & \sigma_{\eta}^{2} & \sigma_{\eta\xi}^{2} & \sigma_{\eta\eta}^{2} \\ \sigma_{\xi\xi}^{2} & \sigma_{\eta\xi}^{2} & \sigma_{\xi}^{2} & \sigma_{\xi\eta}^{2} \\ \sigma_{\xi\eta}^{2} & \sigma_{\eta\eta}^{2} & \sigma_{\xi\eta}^{2} & \sigma_{\eta}^{2} \end{bmatrix}.$$
(6.2.2)

Die Projektion der Schätzfehlerkovarianz auf eine räumliche und zeitliche Varianz ist nach (6.1.3) und (6.1.9) nichtlinear. Im Folgenden werden drei Verfahren zur Projektion, die Linearisierung, die Sigma-Punkt-Methode und das Partikel-Verfahren, vorgestellt. Jedes dieser drei Verfahren berechnet hier sowohl eine räumliche als auch eine zeitliche Projektionsunsicherheit. Die Grundlagen der in dieser Arbeit verwendeten Propagationsverfahren finden sich in der Schätztheorie, sie weisen Parallelen zum Erweiterten Kalmanfilter [65], Sigma-Punkt-Kalmanfilter [64] und Partikelfilter [3] auf. Im folgenden Abschnitt werden die einzelnen Verfahren zur Propagation der Unsicherheiten beschrieben.

### 6.2.1 Linearisierungsmethode

#### **Räumliche Projektion**

Die Linearisierungsmethode löst das Problem einer nichtlinearen Transformation durch eine Linearisierung am Arbeitspunkt der Zustandschätzung. Aus Gleichung (6.1.2) ergibt sich für einen beliebigen Kollisionspunkt

$$\psi_k = t_{\rm r} \left( \mathbf{x}_k \right). \tag{6.2.3}$$

Die Linearisierung entspricht einer Taylorreihenentwicklung bis zur ersten Ordnung um den Schätzwert  $\hat{\mathbf{x}}_{k|k}$  als Arbeitspunkt:

$$\psi_{k} = t_{\mathrm{r}} \left( \hat{\mathbf{x}}_{k|k} \right) + \mathbf{T}_{r} \cdot \left( \mathbf{x}_{k} - \hat{\mathbf{x}}_{k|k} \right) + \mathcal{O} \left( \left( \mathbf{x}_{k} - \hat{\mathbf{x}}_{k|k} \right)^{2} \right).$$
(6.2.4)

Dabei bezeichnet das Landau-Symbol  $\mathcal{O}\left((\mathbf{x}_{\mathbf{k}} - \hat{\mathbf{x}}_{\mathbf{k}})^2\right)$  einen quadratischen Fehler, der unter Annahme kleiner Fehler vernachlässigt werden kann. Mit  $\mathbf{T}_r$  wird die Jacobi-Matrix der räumlichen Projektion  $t_r$  am Arbeitspunkt bezeichnet:

$$\mathbf{T}_{\mathbf{r}} = \left. \frac{\partial}{\partial \mathbf{x}} t_{\mathbf{r}} \left( \mathbf{x} \right) \right|_{\mathbf{x} = \hat{\mathbf{x}}_{k|k}} = \left( \begin{array}{cc} \frac{\partial t_{\mathbf{r}}}{\partial \xi} & \frac{\partial t_{\mathbf{r}}}{\partial \eta} & \frac{\partial t_{\mathbf{r}}}{\partial \dot{\xi}} & \frac{\partial t_{\mathbf{r}}}{\partial \dot{\eta}} \end{array} \right).$$
(6.2.5)

Für den Fehler in der Kollisionspunktberechnung ergibt sich daher die linearisierte Darstellung

$$\psi_k - \hat{\psi}_k = \mathbf{T}_{\mathbf{r}} \cdot \left( \mathbf{x}_k - \hat{\mathbf{x}}_{k|k} \right) \tag{6.2.6}$$

und damit errechnet sich die zugehörige linearisierte Varianz als

$$\sigma_{\psi_k}^2 = \mathbf{E} \left[ (\psi_k - \hat{\psi}_k) (\psi_k - \hat{\psi}_k)^T \right]$$
(6.2.7)

$$= \mathbf{E} \left[ \mathbf{T}_{r} \cdot \left( \mathbf{x}_{k} - \hat{\mathbf{x}}_{k|k} \right) \cdot \left( \mathbf{x}_{k} - \hat{\mathbf{x}}_{k|k} \right)^{T} \cdot \mathbf{T}_{r}^{T} \right]$$
(6.2.8)

$$=\mathbf{T}_r \cdot \mathbf{P}_{k|k} \cdot \mathbf{T}_r^T. \tag{6.2.9}$$

Der Erwartungswert  $\hat{\psi}_k$  aus Gleichung (6.1.2) und die zugehörige Varianz  $\sigma_{\psi_k}^2$  aus Gleichung (6.2.9) beschreiben die Verteilung der räumlichen Kollisionswahrscheinlichkeit, welche bei diesem Verfahren als normalverteilt mit

$$p(\psi_k) \sim \mathcal{N}(\hat{\psi}_k, \sigma_{\psi_k}^2) \tag{6.2.10}$$



**Abbildung 6.3:** Berechnete Kollisionswahrscheinlichkeit  $p_{\text{Kollision}}^{(\psi_k)}$  als Integral der berechneten Wahrscheinlichkeitsdichteverteilung  $p(\psi_k)$  über die Fahrzeugbreite *b* in schematischer Darstellung.

angenommen wird. Die Praktikabilität dieser Annahme wird im Evaluierungskapitel überprüft.

Die Idee ist nun, die Verteilung über die Breite b der Fahrzeugfront zu integrieren. Dieses Integral beschreibt gerade die räumliche Kollisionswahrscheinlichkeit für den k-ten Zeitschritt:

$$p_{\text{Kollision}}^{(\psi_k)} = \int_{-b/2}^{b/2} p(\psi_k) \, d\psi_k. \tag{6.2.11}$$

Die Idee des Verfahrens wird schematisch in Abbildung 6.3 verdeutlicht.

Mit dem Zustandsvektor  $\hat{\mathbf{x}}_{k|k}$  aus Gleichung (6.1.1) und passender Schätzfehlerkovarianz aus Gleichung (6.2.2) lautet die konkrete Realisierung:

$$\mathbf{T}_{\mathbf{r}} = \begin{pmatrix} \frac{\partial t_{\mathbf{r}}}{\partial \xi} & \frac{\partial t_{\mathbf{r}}}{\partial \eta} & \frac{\partial t_{\mathbf{r}}}{\partial \dot{\xi}} & \frac{\partial t_{\mathbf{r}}}{\partial \dot{\eta}} \end{pmatrix}$$
(6.2.12)

$$= \left(\begin{array}{ccc} -\frac{\dot{\eta}_k}{\dot{\xi}_k} & 1 & \frac{\xi_k \dot{\eta}_k}{\dot{\xi}_k^2} & -\frac{\xi_k}{\dot{\xi}_k} \end{array}\right). \tag{6.2.13}$$

Damit ist die räumliche Projektion der Schätzfehlerkovarianz vollständig beschrieben. Auf entstehende Linearisierungsfehler wird in der Evaluation in Abschnitt 6.4 eingegangen.

#### **Zeitliche Projektion**

Zur Berechnung der zeitlichen Projektion wird die Transformationsvorschrift  $t_z$  analog zum vorherigen Abschnitt am Arbeitspunkt  $\hat{\mathbf{x}}_{k|k}$  linearisiert:

$$\mathbf{T}_{z} = \frac{\partial}{\partial \mathbf{x}} t_{z} \left( \mathbf{x} \right) \Big|_{\mathbf{x} = \hat{\mathbf{x}}_{k|k}}.$$
(6.2.14)

Die projizierte zeitliche Schätzfehlerkovarianz kann wie folgt berechnet werden:

$$\sigma_{\tau_k}^2 = \mathbf{T}_{\mathbf{z}} \cdot \mathbf{P}_{k|k} \cdot \mathbf{T}_{\mathbf{z}}^T.$$
(6.2.15)

Der Mittelwert  $\hat{\tau}_k$  aus Gleichung (6.1.4) und die Varianz  $\sigma_{\tau_k}^2$  aus Gleichung (6.2.15) beschreiben die Verteilung der zeitlichen Kollisionswahrscheinlichkeit, welche wiederum als normalverteilt mit

$$p(\tau_k) \sim \mathcal{N}(\hat{\tau}_k, \sigma_{\tau_k}^2)$$

angenommen wird. Durch Integration über das Auslöse-Zeitintervall berechnet sich für den Zeitschritt  $t_k$  die zeitliche Kollisionswahrscheinlichkeit wie folgt:

$$p_{\text{Kollision}}^{(\tau_k)} = \int_{t_1}^{t_2} p(\tau_k) \, d\tau_k.$$
 (6.2.16)

Dabei ist  $t_1$  und  $t_2$  die minimale bzw. maximale Pre-Crash-Auslösezeit und wird in dieser Arbeit mit 100 ms bzw. 300 ms angegeben. Der Zeitpunkt  $t_1$  beschreibt die Totzeit zur Aktivierung des reversiblen Sicherheitssystems. Analog zur räumlichen Projektion lautet die konkrete Realisierung der linearisierten zeitlichen Projektion (6.1.9) für den Zustandsvektor aus Gleichung (6.1.1) und den Unsicherheiten aus Gleichung (6.2.2):

$$\mathbf{T}_{\mathbf{z}} = \left(\begin{array}{ccc} \frac{\partial t_{\mathbf{z}}}{\partial \xi} & \frac{\partial t_{\mathbf{z}}}{\partial \eta} & \frac{\partial t_{\mathbf{z}}}{\partial \dot{\xi}} & \frac{\partial t_{\mathbf{z}}}{\partial \dot{\eta}} \end{array}\right) = \left(\begin{array}{ccc} \frac{1}{\dot{\xi}_k} & 0 & -\frac{\xi_k}{\dot{\xi}_k} & 0 \end{array}\right).$$

Damit sind die Projektionen durch die Linearisierungsmethode vollständig hergeleitet.

#### 6.2.2 Sigma-Punkt-Methode

Die Sigma-Punkt-Methode ist ein weiteres Verfahren zur Berechnung einer Kollisionswahrscheinlichkeit mit einer zugrunde liegenden nichtlinearen Transformationsvorschrift. Dieses Verfahren stellt eine ableitungsfreie Alternative zur Linearisierungsmethode dar und wurde vom Sigma-Punkt-Kalmanfilter (*engl.* "Unscented Kalmanfilter", UKF) inspiriert. Es werden im Unterschied zur vorgestellten Linearisierungsmethode nicht die nichtlinearen Systemübergänge approximiert, sondern die Wahrscheinlichkeitsdichtefunktionen, analog zum Sigma-Punkt-Kalmanfilter [64]. Die grundlegende Idee des Sigma-Punkt-Verfahrens ist es, 2N + 1 Sigma-Punkte zu wählen, welche die Kovarianzmatrix gut approximieren, diese durch die nichtlineare Gleichung (6.1.3) zu propagieren und anschließend den eindimensionalen Mittelwert mit dazugehöriger Varianz des Auftreffpunktes zu berechnen. Dabei ist N die Dimension des Zustandvektors. Dieses Verfahren wird im Folgenden näher beschrieben. Der Zustandsvektor und die Schätzfehlerkovarianz werden durch einzelne gewichtete und transformierte Sigma-Punkte geschätzt. 2N + 1 Sigma-Punkte repräsentieren dabei den aktuellen Systemzustand  $\hat{\mathbf{x}}_{k|k}$  und Schätzfehlerkovarianz  $\mathbf{P}_{k|k}$ . Jedem Sigma-Punkt wird zusätzlich noch ein Gewicht  $W_i$  zugewiesen mit der Bedingung:

$$\sum_{i=0}^{2N} W_i = 1. \tag{6.2.17}$$

Bei der Wahl der Sigma-Punkte existieren verschiedene Varianten. Eine Wahlmöglichkeit mit i = 1, ..., N ist:

$$\boldsymbol{\chi}_{k}^{(0)} = \hat{\mathbf{x}}_{k|k} \tag{6.2.18}$$

$$\boldsymbol{\chi}_{k}^{(i)} = \hat{\mathbf{x}}_{k|k} + \left(\sqrt{(N+\kappa)\mathbf{P}_{k|k}}\right)_{i}$$
(6.2.19)

$$\boldsymbol{\chi}_{k}^{(i+N)} = \hat{\mathbf{x}}_{k|k} - \left(\sqrt{(N+\kappa)\mathbf{P}_{k|k}}\right)_{i}.$$
(6.2.20)

Dabei beschreibt die Notation  $(\mathbf{M})_i$  die *i*-te Spalte einer beliebigen Matrix  $\mathbf{M}$  und  $\boldsymbol{\chi}_k$  die Sigma-Punkte. Die Wurzel der Schätzfehlerkovarianz ist wie folgt definiert:

$$\sqrt{\mathbf{P}} \cdot \sqrt{\mathbf{P}}^T = \mathbf{P} \tag{6.2.21}$$

und kann mit einer Cholesky-Zerlegung ermittelt werden. Die dazugehörigen Gewichte werden folgendermaßen gewählt:

$$W_0 = \frac{\kappa}{N + \kappa} \tag{6.2.22}$$

$$W_i = W_{i+N} = \frac{1}{2(N+\kappa)}.$$
(6.2.23)

Starke lokale Nichtlinearitäten werden mit steigender Dimension N schlechter geschätzt. Um diesem Effekt entgegenzuwirken, kann die Distanz der Sigma-Punkte zum Mittelwert über den Designparameter  $\kappa \neq N$  skaliert werden. Für gaußverteilte Signale hat sich in der Praxis ein Skalierungsfaktor von  $\kappa = 3 - N$  bewährt.

Im Folgenden wird die beschriebene Sigma-Punkt-Methode für die räumliche sowie zeitliche Projektion der Schätzfehlerkovarianz verwendet.

#### **Räumliche Projektion**

Die ausgewählten Sigma-Punkte der Gleichungen (6.2.18) bis (6.2.20) werden mit der Transformationsvorschrift  $t_r$  aus Gleichung (6.1.3) örtlich projiziert:

$$\psi_k^{(i)} = t_r \left( \boldsymbol{\chi}_k^{(i)} \right) \quad \forall i \quad \text{mit } i = 0...2N.$$
(6.2.24)

Dabei ist N die Dimension des Zustandvektors. Der transformierte räumliche Mittelwert wird wie folgt durch eine gewichtete Mittelung berechnet:

$$\hat{\psi}_k = \sum_{i=0}^{2N} W_i \cdot \psi_k^{(i)}.$$
(6.2.25)

Dadurch wird eine verbesserte Schätzung des Kollisionspunktes im Vergleich zu (6.1.3) erzielt. Die dazugehörige räumliche Varianz wird in Anlehnung an das UKF [96] als gewichtetes Produkt der transformierten Sigma-Punkte bestimmt:

$$\sigma_{\psi_k}^2 = \sum_{i=0}^{2N} W_i \left( \psi_k^{(i)} - \hat{\psi}_k \right)^2.$$
 (6.2.26)

Der Erwartungswert  $\hat{\psi}_k$  und die Varianz  $\sigma^2_{\psi_k}$  beschreiben die Verteilung der Kollisionswahrscheinlichkeit und werden wie in (6.2.10) als normalverteilt mit

$$p(\psi_k) \sim \mathcal{N}(\hat{\psi}_k, \sigma_{\psi_k}^2) \tag{6.2.27}$$

angenommen. Durch Integration über die Breite der Fahrzeugfront erhält man analog zur Linearisierungsmethode für den Zeitschritt  $t_k$  die räumliche Kollisionswahrscheinlichkeit:

$$p_{\text{Kollision}}^{(\psi_k)} = \int_{-b/2}^{b/2} p(\psi_k) \, d\psi_k. \tag{6.2.28}$$

Dies vervollständigt die räumliche Kovarianzprojektion mittels Sigma-Punkt-Methode.

#### **Zeitliche Projektion**

Analog zur räumlichen Transformation wird eine zeitliche Projektion durch die nichtlineare Abbildungsvorschrift  $t_z$  beschrieben und jeder einzelne Sigma-Punkt propagiert:

$$\tau_k^{(i)} = t_z \left( \boldsymbol{\chi}_k^{(i)} \right) \quad \forall i \quad \text{mit } i = 0...2N.$$
(6.2.29)

Der neue Erwartungswert und die dazugehörige Varianz sind:

$$\hat{\tau}_k = \sum_{i=0}^{2N} W_i \cdot \tau_k^{(i)} \tag{6.2.30}$$

$$\sigma_{\tau_k}^2 = \sum_{i=0}^{2N} W_i \left( \tau_k^{(i)} - \hat{\tau}_k \right)^2.$$
 (6.2.31)

Mit einer normalverteilten Wahrscheinlichkeitsdichtefunktion  $p(\tau) \sim \mathcal{N}(\hat{\tau}_k, \sigma_{\tau}^2)$  ergibt sich eine zeitliche Kollisionswahrscheinlichkeit von:

$$p_{\text{Kollision}}^{(\tau_k)} = \int_{t_1}^{t_2} p(\tau_k) \, d\tau_k. \tag{6.2.32}$$

Dabei sind  $t_1$  und  $t_2$  die Auslöseschwellen des Pre-Crash-Systems. Die Sigma-Punkt-Methode kann mit einer Taylorreihenentwicklung, die nach dem zweiten Glied abgebrochen wurde, verglichen werden. Dies liefert einen Hinweis darauf, dass es sich um eine bessere Approximation als die Linearisierungsmethode handelt, was in den praktischen Auswertungen evaluiert wird. Die entstehenden Fehler durch die Annahme einer Normalverteilung werden ebenfalls im Evaluierungsteil dieses Kapitels untersucht.

### 6.2.3 Partikel-Methode

Bei der Partikel-Methode, die auf dem Partikelfilter [54, 62] basiert, wird die Wahrscheinlichkeitsdichte durch eine endliche Summe von sogenannten Partikeln approximiert:

$$\mathbf{x}_k^{(i)} \sim p(\mathbf{x}_k | Z^K). \tag{6.2.33}$$

Dabei beschreibt  $\mathbf{x}_k^{(i)}$  das *i*-te Partikel. Für  $i \to \infty$  bildet die Partikelwolke die Wahrscheinlichkeitsdichtefunktion exakt ab.

Die Partikelwolke approximiert eine beliebige Wahrscheinlichkeitsverteilung im Zustandsraum und kann somit auch bei beliebigen parameterfreien Verteilungen angewendet werden. Dies stellt einen entscheidenden Vorteil der Partikel-Methode im Vergleich zu den bisher beschriebenen Methoden dar, da sie nicht auf gaußverteilte Zufallsvariablen beschränkt ist. Ein weiterer Vorteil im Vergleich zur Sigma-Punkt-Methode ist, dass mit steigender Anzahl an Partikeln die Verteilung beliebig gut approximiert wird.

Jedes der gewählten Partikel wird sowohl räumlich als auch zeitlich projiziert und daraus anschließend eine Kollisionswahrscheinlichkeit berechnet. Aufgrund der großen Anzahl an Operationen für jedes Partikel der Partikelwolke stellt diese Methode die aufwändigste, jedoch auch die genaueste Transformationsvorschrift dar.

#### **Räumliche Projektion**

Die räumliche Projektionsvorschrift lautet:

$$\psi_k^{(i)} = t_{\rm r} \left( \mathbf{x}_k^{(i)} \right). \tag{6.2.34}$$

Dabei ist

$$\mathbf{x}_{k}^{(i)} = \begin{bmatrix} \xi_{k}^{(i)} & \eta_{k}^{(i)} & \dot{\xi}_{k}^{(i)} & \dot{\eta}_{k}^{(i)} \end{bmatrix}^{T}$$
(6.2.35)

einer der Partikel wie in Gleichung (6.2.33) definiert. Die konkrete Realisierung mit dem Zustandsvektor eines einzelnen Partikels ergibt sich dann wie folgt:

$$t_{\rm r}\left(\mathbf{x}_{k}^{(i)}\right) = \begin{cases} \eta_{k}^{(i)} - \frac{\dot{\eta}_{k}^{(i)}}{\dot{\xi}_{k}^{(i)}} \xi_{k}^{(i)} & \text{für } \dot{\xi}_{k}^{(i)} < 0 \land \xi_{k}^{(i)} > 0\\ \infty & \text{sonst.} \end{cases}$$
(6.2.36)

Das Verhältnis der Menge aller Schnittpunkte mit der Fahrzeugfront zur Gesamtanzahl aller Punkte liefert die Kollisionswahrscheinlichkeit für  $i \to \infty$ :

$$p_{\text{Kollision}}^{(\psi_k)} = \lim_{i \to \infty} \frac{\#\left\{\psi_k^{(i)} \middle| -\frac{b}{2} \le \psi_k^{(i)} \le \frac{b}{2}\right\}}{\#\left\{\psi_k^{(i)}\right\}}.$$
(6.2.37)

Hierbei bezeichnet das Symbol # die Kardinalität bzw. Mächtigkeit einer Menge. Da die Kollisionswahrscheinlichkeit direkt aus den relativen Häufigkeiten (6.2.37) berechnet werden kann und keine Normalverteilung zu Grunde liegt, ist beim Partikel-Verfahren auch kein Mittelwert bzw. keine Projektion des Zustandsvektors mehr nötig.

#### **Zeitliche Projektion**

Analog zur räumlichen Projektion erfolgt die zeitliche Projektion durch die nichtlineare Abbildungsvorschrift  $t_z$ :

$$\tau_k^{(i)} = t_z(\mathbf{x}_k^{(i)}) \tag{6.2.38}$$

 $\operatorname{mit}$ 

$$t_{z}(\mathbf{x}_{k}^{(i)}) = \begin{cases} \frac{|\xi_{k}^{(i)}|}{|\dot{\xi}_{k}^{(i)}|} & \text{für } \dot{\xi}_{k}^{(i)} < 0 \land \xi_{k}^{(i)} > 0\\ \infty & \text{sonst.} \end{cases}$$
(6.2.39)

Die zeitliche Kollisionswahrscheinlichkeit wird analog zur räumlichen wie folgt berechnet:

$$p_{\text{Kollision}}^{(\tau_k)} = \lim_{i \to \infty} \frac{\#\left\{\tau_k^{(i)} \middle| t_1 \le \tau_k^{(i)} \le t_2\right\}}{\#\left\{\tau_k^{(i)}\right\}}.$$
(6.2.40)

Die Praktikabilität dieser Projektionsmethode im Vergleich zu den anderen beiden vorgeschlagenen Verfahren wird im Folgenden untersucht.

## 6.3 Entscheidungsalgorithmus

Das Fahrzeugumfeld wird durch die Mehrzielverfolgung eines Kalmanfilters beschrieben. Die Aufgabe der Situationsbewertung ist es, die Kollisionswahrscheinlichkeit zu bestimmen. Dazu müssen Fahrsituationen bewertet und im Falle einer unvermeidbaren Kollision entsprechende Sicherheitssysteme aktiviert werden.

Die Aktivierung des Pre-Crash-Systems erfolgt, sobald die räumliche und zeitliche Kollisionswahrscheinlichkeit eine bestimmte Auslöseschwelle überschritten hat. Diese Auslöseschwelle ist je nach zu Grunde liegender Anwendung zu wählen.

Der wesentliche Vorteil der hier vorgestellten Situationsanalyse ist eine parameterfreie Aktivierung des Pre-Crash-Systems, lediglich die Auslöseschwellen für  $p_{\text{Kollision}}^{(\tau_k)}$  und  $p_{\text{Kollision}}^{(\psi_k)}$ stellen Designparameter dar. Die zeitliche Projektion wird für den folgenden Teil der Evaluierung festgelegt und die räumliche Auftreffwahrscheinlichkeit ausgewertet. Für eine Aktivierung des Pre-Crash-Systems soll gelten:

$$p_{\text{Kollision}}^{(\tau_k)} > 90 \%$$

mit einer Zeitspanne von  $t_1$  bis  $t_2$  von 100 ms bis 300 ms. Die Umfeldbeschreibung ist von der Situationsbewertung entkoppelt. Es werden außer dem Zustandsvektor und der Schätzfehlerkovarianz keine zusätzlichen Informationen der verfolgten Objekte benutzt und es findet auch keine Vorauswahl relevanter Objekte statt. Durch diese Trennung von Zustandsschätzung und Situationsbwertung ist es möglich, das Pre-Crash-Entscheidungsmodul auch mit anderen Sensoren zu betreiben.

# 6.4 Evaluation

Mit Hilfe der hergeleiteten räumlichen und zeitlichen Kollisionswahrscheinlichkeiten sind präzisere Aussagen über drohende Kollisionen möglich. Welches der drei hergeleiteten Verfahren zur Projektion der Schätzfehlerkovarianz dabei die besten Ergebnisse erzielt, wird im Folgenden analysiert.

Zunächst wurde eine erste Simulation durchgeführt, um die prinzipielle Funktion der Methodik zur Kovarianzprojektion zu demonstrieren. Abbildung 6.4 zeigt die räumlichen Projektionen des Zustandsvektors und dessen Schätzfehlerkovarianz. Die Kovarianz wird mit 1000 Partikeln repräsentiert und auf die Fahrzeugfront projiziert. Hierbei sind schematisch zur Verdeutlichung zwei Grafiken zu einer zusammengefasst, was durch zwei verschiedene senkrechte Achsenbeschriftungen verdeutlicht ist. Die Partikelwolke resultiert aus dem detektierten Objekt und ist im Fahrzeugkoordinatensystem dargestellt. Hierzu gehört die linke Achsenbeschriftung. Diese Partikelwolke wird mit der Partikel-Methode projiziert, was in der Wahrscheinlichkeitsdichte dargestellt ist, mit der entsprechenden rechten Achsenbeschriftung. Als Vergleich ist zusätzlich die linearisierte Projektion eingezeichnet.



Abbildung 6.4: Schematische Darstellung der Projektion der Partikelwolke eines detektierten Objekts auf eine Verteilung der möglichen Kollisionspunkte mit (a) großen und (b) kleinen Positionsvarianzen  $\sigma_{\xi_k}^2$  und  $\sigma_{\eta_k}^2$  (3 $\sigma$ -Ellipse). Das Histogramm resultiert aus einer Projektion von Partikeln und die einhüllende Normalverteilung aus einer Projektion durch Linearisierung. Die Breite des eigenen Fahrzeugs ist durch die beiden senkrechten Linien gekennzeichnet.

Im Vergleich der beiden Abbildungen 6.4a und 6.4b sieht man den Unterschied der Kovarianzen. In 6.4a ist eine große Kovarianzellipse zu sehen, die in einer flachen Wahrscheinlichkeitsverteilung resultiert. Bei Integration über die Fahrzeugbreite ergibt sich somit ein eher geringer Wert, die Kollisionswahrscheinlichkeit ist aufgrund der hohen Unsicherheit nicht sehr groß. Im Unterschied hierzu sieht man in 6.4b eine sehr kleine Kovarianzellipse, was eine geringe Varianz der Verteilung nach der Projektion zur Folge hat. Hierdurch ergibt sich eine sehr exakte Aussage über den Ort einer möglichen Kollision.

Der entscheidende Vorteil der Kovarianzprojektion ist ebenfalls an den beiden Grafiken ablesbar: Ohne Betrachtung der Unsicherheiten ergibt sich derselbe propagierte Punkt einer Kollision. Anhand der Verteilungen wird jedoch klar, dass im ersten Fall über den tatsächlichen Kollisionsort kaum eine verlässliche Aussage gemacht werden kann, wohingegen im zweiten Fall der Kollisionsort mit hoher Sicherheit vorhergesagt werden kann. Ohne Kovarianzpropagation wird somit die entscheidende Information der Kovarianzen nicht berücksichtigt. Mit Hilfe der entwickelten Methodik ist jedoch in der Praxis eine fundierte Entscheidung über die Auslösung eines Pre-Crash-Systems möglich.

Im Folgenden werden mit simulierten Daten die drei Projektionsarten der Schätzfehlerkovarianz untersucht. Abschließend wird ein Vergleich zwischen bisherigen Ansätzen und dem hier vorgestelltem Pre-Crash-System gegeben.

Zur Auswertung werden zwei exemplarische Pre-Crash-Szenarien simuliert, eine frontale Kollision wie zum Beispiel bei einem Auffahrunfall und ein knappes Ausweichmanöver, bei dem die Kollision durch starkes Bremsen und Lenken noch verhindert wird. Den Schwerpunkt der Simulation bildet eine Auswertung über Erkennungs- und Falschalarmrate in Abhängigkeit der Filtereinschwingzeiten. Die Simulation beruht auf der Sensorkonfiguration des Versuchsfahrzeuges.

# 6.4.1 Simulation einer zentralen Kollision

Die zentrale Kollision wird mit einer konstanten Geschwindigkeit von 55 km/h simuliert und startet bei einer Entfernung von 25 m. Abbildung 6.5a zeigt die berechnete räumliche Kollisionswahrscheinlichkeit in Abhängigkeit der Zeit vom Start bis zum Aufprall.

Mit wenigen kurzen Ausnahmen ist bei allen drei Methoden ein stetig anwachsender Verlauf der Kollisionswahrscheinlichkeit zu beobachten. Die kurzen fallenden Abschnitte sind auf das Prozessmodell zurückzuführen und werden sowohl vom Prozessrauschen als auch vom Messrauschen beeinflusst.

Die Kollisionswahrscheinlichkeit liegt bis 0,75 s vor der Kollision bei unter 40 %. Während dieser Zeit befindet sich das Kollisionsobjekt in zu großer Entfernung. Ab 0,5 s vor der Kollision steigt die Kollisionswahrscheinlichkeit sowohl bei der Partikel- als auch Sigma-Punkt-Methode auf über 80 %. Die Methode der linearisierten Projektion liegt ca. 10 % darunter. Eine räumliche Pre-Crash-Auslöseschwelle von 90 % erreicht die Partikel-Projektion 249 ms vor der Kollision, das Sigma-Punkt-Verfahren 239 ms und die Linearisierung erst 105 ms vorher. Das Ergebnis der Sigma-Punkte-Methode ist bei dieser Simulation fast identisch zur Projektion mit Partikeln. Die linearisierte Methode weicht aufgrund von Linearisierungsfehlern um wenige Prozent davon ab. Insgesamt lässt sich sagen, dass die Sigma-Punkt-Methode und Partikel-Methode in der Praxis zu bevorzugen sind, da sie beispielsweise eine Auslöseschwelle von 90 % Kollisionswahrscheinlichkeit in einem zeitlichen Rahmen erreichen, der die Aktivierung eines Pre-Crash-Systems noch

ermöglicht. Bei Verwendung der Linearisierungsmethode könnte das System mit denselben Anforderungen erst ungefähr 100 ms vor dem Aufprall aktiviert werden, was in der Praxis unter Umständen zu einer eingeschränkten Funktionalität des Systems führt.

### 6.4.2 Simulation eines Ausweichmanövers

In einem zweiten Szenario wurde ein Ausweichmanöver mit einer Geschwindigkeit von 40 km/h simuliert. Das Manöver beginnt 12 m vor dem Fahrzeug. Das verfolgte Objekt bewegt sich 2,5 m rechts am stehenden Sensorfahrzeug vorbei. Abbildung 6.5b zeigt den Verlauf der räumlichen Kollisionswahrscheinlichkeit über eine Beobachtungszeit von zwei Sekunden. Die Zeitachse beschreibt dabei nicht die Zeit bis zur Kollision, sondern die Zeit, bis die Objekttrajektorie die  $\eta$ -Achse des Fahrzeugkoordinatensystems schneidet.

Man sieht, dass bei diesem Szenario alle drei Verfahren sehr gut abschneiden. Die Kollisionswahrscheinlichkeiten erreichen ein Maximum zwischen 1,25 s und 0,75 s vor der drohenden Kollision. Diese Zeitspanne befindet sich noch lange genug vor der möglichen Kollision, so dass aufgrund dieser Kollisionsschätzung keine Entscheidung über die Aktivierung des Pre-Crash-Systems getroffen wird. Danach lässt sich ein rasantes Absinken der Kollisionswahrscheinlichkeit bei allen drei Algorithmen feststellen, innerhalb von 100 ms bis 200 ms sinkt die Kollisionswahrscheinlichkeit fast auf Null.

Im Zeitbereich der Pre-Crash-Auslöseschwelle zwischen 300 ms und 100 ms nähert sich die räumliche Kollisionswahrscheinlichkeit asymptotisch 0% an. Das Ausweichmanöver wird somit korrekt als solches erkannt und zur kritischen Pre-Crash-Auslösezeit gibt die berechnete Kollisionswahrscheinlichkeit sehr exakt das tatsächliche Szenario wieder.



**Abbildung 6.5:** Vergleich der räumlichen Kollisionswahrscheinlichkeit bei (a) einem zentralen Aufprall und (b) einem Ausweichmanöver, berechnet jeweils mit der Partikel-Methode, der Sigma-Punkt-Methode und der Linearisierungsmethode.

	Partikel	Sigma-Punkte	Linearisierung
$p_{\mathrm{Kollision}}^{(\psi_k)}$	$62,\!3\%$	$63{,}4\%$	48,5%

Tabelle 6.1 zeigt die maximal auftretenden Kollisionswahrscheinlichkeiten über die gesamte Zeit des Fahrmanövers. Mit der üblichen Auslöseschwelle von 90% wird das Pre-Crash-

**Tabelle 6.1:** Maximale räumliche Kollisionswahrscheinlichkeit des Ausweichmanövers aus Abbildung 6.5b. Das Pre-Crash-System wird korrekterweise nicht aktiviert.

System richtigerweise nicht aktiviert. Die maximale räumliche Kollisionswahrscheinlichkeit wird zudem auch weit außerhalb der zeitlichen Auslöseschwelle erreicht. Analog zur zentralen Kollision ist die Projektion von Partikeln und Sigma-Punkten fast identisch, die Linearisierung zeigt Abweichungen von bis zu 15 %.

## 6.4.3 Pre-Crash-Simulation

### Versuchsaufbau

Um die Situationsbewertung dieses Kapitels beurteilen zu können, werden die hier vorgestellten Verfahren in eine statistische Pre-Crash-Simulation eingebunden. Dazu werden Fahrmanöver mit und ohne Kollisionen simuliert. Genau die eine Hälfte des Datensatzes enthält keine Unfälle wie zum Beispiel knappe Vorbeifahrten, die andere Hälfte enthält Unfälle wie zum Beispiel Frontalkollisionen oder Kollisionen mit Versatz. Insgesamt werden 100 000 Monte-Carlo-Simulationen mit verschiedenen Startpunkten, Endpunkten und Geschwindigkeiten durchgeführt. Dabei werden lineare Bewegungen mit jeweils konstanten Geschwindigkeiten zwischen 15 km/h und 50 km/h verwendet.

Zur Berechnung der räumlichen und zeitlichen Kollisionswahrscheinlichkeiten wird das Partikel-Verfahren aus Abschnitt 6.2.3 angewendet. Hierzu werden 100 Partikel der Schätzfehlerkovarianz berechnet und auf die Kollisionskoordinate projiziert. Die Auslöseschwelle wird von 0% auf 1% in Schritten der Schrittweite 0,01% erhöht und das Ergebnis bestehend aus Erkennungs- und Falschalarmrate ausgewertet. Zusätzlich werden die Ergebnisse in Abhängigkeit der Anzahl an Filterzyklen untersucht. Hierzu wird die Anzahl der Zyklen, in denen das Objekt gesehen und verfolgt werden kann, von 2 bis 15 variiert.

Im Folgenden wird zunächst als Bewertungskriterium die ROC-Analyse vorgestellt, bevor auf die Ergebnisse eingegangen wird.

### **ROC-Analyse**

Alle möglichen Ausgaben eines Pre-Crash-Systems sind in einer Konfusionsmatrix (Vierfeldtafel, siehe Tabelle 6.2) abgebildet. Dabei wird die Anzahl der korrekt erkannten Kollisionen als *richtig positiv*, die Anzahl der Falschauslösungen als *falsch positiv*, die Anzahl der nicht erkannten Kollisionen als *falsch negativ* und die Anzahl der Fälle, bei denen das System richtigerweise nicht auslöst, als *richtig negativ* bezeichnet. Die falsch

	Kollision	Keine Kollision
Systemauslösung	richtig positiv	falsch positiv
Nichtauslösung	falsch negativ	richtig negativ

 Tabelle 6.2:
 Konfusionsmatrix eines Pre-Crash-Systems.

positiven Ergebnisse werden oftmals auch als Fehler erster Art oder  $\alpha$ -Fehler und die falsch negativen Ergebnisse als Fehler zweiter Art oder  $\beta$ -Fehler bezeichnet.

Ein wichtiges Kriterium zur Beurteilung von Pre-Crash-Systemen stellt die Detektionsrate dar. Sie wird oft auch als Sensitivität bezeichnet und gibt an, wie viel Prozent der Kollisionen richtig erkannt wird:

Detektionsrate (oder Sensitivität) = 
$$\frac{\text{richtig positiv}}{\text{richtig positiv} + \text{falsch negativ}}$$
. (6.4.1)

Ein weiteres Kriterium ist die Spezifität oder Rate der richtig negativen Klassifikationen, die beschreibt, wie oft ein tatsächlicher negativer Sachverhalt auch durch ein negatives Testergebnis erkannt wird. Die Gegenwahrscheinlichkeit zur Spezifität ist die Falschalarmrate (1-Spezifität) und wird auch auf den Daten ausgewertet, bei denen es zu keinem Unfall kommt. Dabei gibt die Falschalarmrate in Prozent an, wie oft ein Pre-Crash-System ausgelöst wird, obwohl keine Kollision stattgefunden hat:

$$Falschalarmrate (1-Spezifität) = \frac{falsch positiv}{falsch positiv + richtig negativ}.$$
 (6.4.2)

Bei den meisten Klassifikationsproblemen ist eine Optimierung ein Kompromiss zwischen Detektionsrate und Falschalarmrate. Das Ziel ist, bei einer hohen Erkennungsrate wenige Falschauslösungen hervorzurufen. Mögliche Paare von Detektions- und Falschalarmrate werden in einer sogenannten ROC-Kurve (*engl.* "Receiver Operating Characteristic") aufgetragen. Die Koordinate (0,1) in der linken oberen Ecke stellt mit 100% Sensitivität und 0% Falschalarmrate das bestmögliche Ergebnis einer Klassifikation dar. Mit Optimierungsverfahren kann das theoretische Optimum der Kurve bestimmt werden. In realen Systemen ist meistens jedoch die Falschalarmrate einer bestimmten Applikation vorgegeben und die Erkennungsrate ergibt sich aus diesen Anforderungen.

#### Ergebnisse

Abbildung 6.6 zeigt das Ergebnis der Pre-Crash-Simulation in Form einer ROC-Analyse. Auf der Ordinatenachse wird die Erkennungsrate in Abhängigkeit der Falschalarmrate auf der Abszissenachse gezeichnet. Als erstes wird das Verhältnis aus Erkennungsrate und Falschalarmrate in Abhängigkeit der als Auslöseschwelle verwendeten räumlichen Kollisionswahrscheinlichkeit untersucht. Die verschiedenen ROC-Kurven in Abbildung 6.6 unterscheiden sich in der Anzahl der Filterzyklen, über die das Objekt verfolgt wurde.

In den dargestellten ROC-Kurven variiert die räumliche Auslöseschwelle zwischen 0% und 1%. Bei einer Auslöseschwelle von 0% Kollisionswahrscheinlichkeit ergibt sich eine



**Abbildung 6.6:** (a) Vergleich der Erkennungsleistung bei verschiedenen Filterzyklen mittels ROC-Kurven (*engl.* "Receiver Operating Characteristic") mit und ohne Kovarianz-Projektion. (b) Vergrößerter Ausschnitt des relevanten Bereichs.

Erkennungsrate von 100 %, jedoch auch eine Falschalarmrate von 100 %, da jede Projektion als drohende Kollision klassifiziert wird. Wird hingegen die Auslöseschwelle der Kollisionswahrscheinlichkeit gleich Eins gesetzt, konvergiert die Falschalarmrate gegen 0 % bei sehr viel geringerer Erkennungsrate von ca. 40 %. Innerhalb dieser Grenzen ist abhängig von der Anwendung eine optimale Auslöseschwelle zu finden. Bei einer typischen Auslöseschwelle von 90 % ergibt sich eine Falschalarmrate von unter 10 %. Die Auslöseschwelle stellt damit den Designparameter dar und steuert das Verhältnis von Erkennungs- und Falschalarmrate. Die Wahl des Arbeitspunktes hängt von der Anwendung ab, dessen Größenwert ist aber in den meisten Fällen so zu wählen, dass eine Falschalarmrate kleiner 10 % erreicht wird. Für zukünftige Systeme, die vermehrt nichtreversible Sicherheitssysteme aktivieren, wird eine Falschalarmrate von annähernd 0 % verlangt werden.

Die ROC-Analysen wurden für verschiedene Zykluszeiten des Filters durchgeführt. Je höher die Anzahl an Filterzyklen ist, über die das Objekt verfolgt wird, desto besser ist das Verhältnis von Erkennungs- zu Falschalarmrate. So hat das Pre-Crash-System nach zwei Filterzyklen bei einer Falschalarmrate von 10 % eine Erkennungsrate von ca. 80 %. Nach nur einem weiteren Zyklus steigt bei gleicher Falschalarmrate die Erkennungsrate um über 10 % an. Nach 15 Schritten ergibt sich schließlich eine Erkennungsrate von 99,8 %.

Im Folgenden wird die neue Situationsbewertung mit dem Standardansatz verglichen, bei dem nur eine Propagation des Zustandsvektors, nicht jedoch eine Kovarianzprojektion stattfindet. Die Ergebnisse des Standardansatzes sind ebenfalls in Abbildung 6.6 zu sehen, wobei hierfür die größeren Symbole verwendet wurden. Der Unterschied zwischen einer alleinigen Zustandsprädiktion und der kombinierten Projektion mit Schätzfehlerkovarianz besteht darin, dass nur das in dieser Arbeit entwickelte Verfahren zur Situationsanalyse eine ROC-Analyse ermöglicht. Wird die Kovarianz nicht projiziert, so ist das Ergebnis nur ein Wertepaar aus Erkennungs- und Falschalarmrate. Dies stellt einen entscheidenden Vorteil des vorgeschlagenen Verfahrens dar, da nur hier ein Arbeitspunkt gewählt werden kann und je nach Anwendung ein optimales Verhältnis von Erkennungs- und Falschalarmrate bestimmt werden kann. Diese Parametrierung wird mit der Kollisionswahrscheinlichkeit durch Ändern der Auslöseschwelle möglich. In herkömmlichen Methoden entfällt die Möglichkeit der Parametrierung, da der Arbeitspunkt nicht verschoben werden kann.

Neben der fehlenden Möglichkeit der Parametrierung ist ein weiterer großer Nachteil des Standardansatzes, dass das hiermit erzielte Resultat in jedem Filterzyklus schlechter als die Verknüpfung mit der Kollisionswahrscheinlichkeit ist. Man sieht, dass bei konstanter Falschalarmrate die Erkennungsrate des Standardansatzes deutlich geringer ist. Umgekehrt bringt eine konstante Erkennungsrate beim Standardansatz mehr Falschalarme mit sich als bei der hier vorgeschlagenen Methodik. Der Vorteil des entwickelten Verfahrens wird insbesondere dann deutlich, wenn die Anzahl der bisherigen Filterzyklen noch sehr klein ist. Die vergrößerten Unsicherheiten sind bei einem konsistenten Filter in der Schätzfehlerkovarianz repräsentiert. Da diese Informationen bei einer reinen Zustandsprädiktion nicht genutzt werden können, ist der Standardansatz in jedem Filterzyklus schlechter als der erweiterte Ansatz. Insgesamt weisen alle vorgestellten Ergebnisse darauf hin, dass der im Rahmen dieser Arbeit entwickelte Ansatz große Vorteile im Vergleich zu bisherigen Methoden bietet. Die Projektion der Schätzfehlerkovarianz liefert eine zuverlässige räumliche und zeitliche Kollisionswahrscheinlichkeit und führt zu verlässlicheren Auslöseentscheidungen des Pre-Crash-Systems.

# 6.5 Kapitelzusammenfassung und Ausblick

In diesem Kapitel wurde eine neue Situationsanalyse für sicherheitsrelevante Fahrerassistenzfunktionen vorgestellt. Am Beispiel Pre-Crash wurde ein Entscheidungsalgorithmus zur Ansteuerung eines reversiblen Gurtstraffersystems entwickelt. Es wurde ein neuartiges Verfahren hergeleitet, um neben dem Zustandsvektor einer Objektverfolgung auch die Kovarianzen zu verwenden. Die Projektion von Schätzfehlerkovarianzen bildet den Schwerpunkt dieses Kapitels. Dabei werden die Kovarianzen der Schätzung auf den erwarteten Kollisionspunkt in die Zukunft projiziert und daher kann eine Kollisionswahrscheinlichkeit berechnet werden. Der räumliche oder zeitliche Kollisionspunkt alleine ist noch nicht aussagekräftig genug, da es mittels des vorgeschlagenen Verfahrens durch unterschiedliche Kollisionswahrscheinlichkeiten zu völlig anderen Auslöseentscheidungen des Pre-Crash-Systems kommen kann. Zur Berechnung der Kollisionswahrscheinlichkeiten ist die Nichtlinearität der hergeleiteten Projektionen zu berücksichtigen. Es wurden drei Verfahren vorgestellt, mit denen sowohl eine räumliche als auch eine zeitliche Unsicherheitsprojektion möglich ist.

Die Ergebnisse zeigen eine deutliche Verbesserung der Kollisionseinschätzung mit Hilfe von Kovarianzprojektion im Vergleich zu herkömmlichen Systemen. Dieser Vorteil ist insbesondere bei zeitkritischen Situationen ohne Objektverfolgung über viele Filterzyklen deutlich zu sehen. Darüber hinaus erlaubt die entwickelte Methode eine Parametrisierung des Pre-Crash-Systems. Die räumliche und zeitliche Auslöseschwelle stellen dabei die einzigen zu bestimmenden Designparameter dar. Durch die Wahl dieser Parameter kann das Verhältnis von Falschalarm- und Erkennungsrate optimiert werden. Mit herkömmlichen Methoden ist aufgrund der fehlenden Kollisionswahrscheinlichkeit eine solche Parametrierung nicht möglich. Die Ergebnisse der Pre-Crash-Simulation dieses Abschnittes wurden in [153] veröffentlicht.

In weiterführenden Arbeiten könnte eine Kombination der räumlichen und zeitlichen Auslöseschwellen mit Algorithmen wie z.B. Dempster-Shafer erfolgen [125]. Auf die Odometriedaten wurde in dieser Arbeit aufgrund ihrer Ungenauigkeiten bei hochdynamischen Fahrmanövern verzichtet. Zukünftige Systeme müssten mit Sensoren arbeiten, die auch bei instabilen Fahrsituationen hochgenaue Eigenbewegungsdaten liefern. Dann wäre die Berechnungen von physikalisch möglichen Trajektorien [67, S. 187ff.] denkbar. Nachfolgende Arbeiten könnten sich auch mit der Erweiterung des hier vorgestellten Ansatzes für ausgedehnte Objekte beschäftigen.

# Experimentelle Ergebnisse

Moderne Fahrerassistenzsysteme basieren auf einer schnellen und zuverlässigen Perzeption und Situationsanalyse. Hierdurch sollen Unfälle vermieden werden oder gegebenenfalls die Unfallschwere gemindert werden. Dabei ist es insbesondere in zeitkritischen Situationen entscheidend, dass Messungen schnellstmöglich in die Zustandsschätzung integriert werden. Aus diesem Grund stellen Pre-Crash-Situationen einen optimalen Testfall für die verschiedenen Algorithmen zur Integration von OOS-Messungen dar. Für die folgende Evaluierung wurden zahlreiche praktische Fahrszenen mit Anpralltests durchgeführt, anhand derer die Performanz der vorgeschlagenen Algorithmen basierend auf einer Fusion mehrerer Radarsensoren untersucht wurde.

Dieses Kapitel dient zur Auswertung des gesamten Pre-Crash-Systems, von der Zustandsschätzung aus Kapitel 3 über die die OOSM-Verfahren aus den Kapiteln 4 und 5 bis hin zur Situationsbewertung aus Kapitel 6. Es wird experimentell gezeigt, dass OOSM-Algorithmen zu einer deutlichen Verbesserung der Erkennungsrate führen und somit Unfälle vermeiden können, wo herkömmliche Algorithmen scheitern. Dies gilt insbesondere für Pre-Crash-Systeme, die innerhalb weniger Hundert Millisekunden Entscheidungen treffen müssen.

Abschnitt 7.1 gibt einen Überblick über die herangezogenen Bewertungsmaße, bevor in Abschnitt 7.2 die Signalverarbeitungsalgorithmen auf Basis einer Simulationsumgebung ausgewertet werden. Dabei wird die Sensorkonfiguration eines Drei-Schritt-OOSM-Problems sowie eine weitere Fusion eines Fünf-Schritt-OOSM-Problems simuliert. Die Auswertung erfolgt anhand zweier exemplarischer Fahrszenen, einer frontalen Kollision mit mittlerer Geschwindigkeit und einem Ausweichmanöver. Abschließend wird eine Pre-Crash-Simulation mit Situationsbewertung vorgestellt und das Verhältnis aus Erkennungs- zu Falschalarmrate unter Verwendung von OOSM-Algorithmen ausgewertet.

Abschnitt 7.3 stellt den Schwerpunkt dieses Kapitels dar, eine Auswertung praktischer Fahrmanöver des entwickelten Pre-Crash-Systems mit einem prototypisch aufgebauten

Versuchsfahrzeug. Durch Evaluierung der Schätzfehlerkovarianz und der Auslösewahrscheinlichkeit werden die Vorteile der OOSM-Algorithmen deutlich. Eine fundierte Untersuchung der zeitlichen Genauigkeit der Algorithmen erfolgt mit Hilfe einer Kontaktsensorik. Die Genauigkeit der verfolgten Objekte wird im Vergleich mit einem Laserscanner ausgewertet. Abschließend wird eine detaillierte Analyse des entwickelten Pre-Crash-Systems anhand eines Fahrmanöverkatalogs präsentiert. Die ausgewählten Fahrszenen sollen repräsentativ für die in Realität vorkommenden kritischen Fahrsituationen sein. Als Bewertungsmerkmal dient dabei eine modifizierte ROC-Analyse.

# 7.1 Bewertungsmaße

Um einen Vergleich der verschiedenen Algorithmen sowohl bei der Simulation als auch bei der Auswertung realer Fahrversuche durchzuführen, werden die im folgenden Abschnitt beschriebenen und aus der Literatur bekannten Bewertungsmaße herangezogen.

### Volumen der Schätzfehlerkovarianz

Zur Bewertung der Schätzfehlerkovarianz wird die  $N \times N$ -Matrix auf einen skalaren Wert abgebildet. Da die Schätzfehlerkovarianz des Zustandsvektors eine multivariate Normalverteilung beschreibt, wurde ein 1 $\sigma$ -Konfidenzbereich gewählt und dessen Volumen berechnet. Dieser Konfidenzbereich stellt bei einer  $N \times N$ -Matrix für N = 2 eine Ellipse und für N > 2 ein Hyperellipsoid dar. Für die Berechnung dieses 1 $\sigma$ -Volumens der Kovarianzmatrix mit den Systemzuständen ( $\xi, \eta, \dot{\xi}, \dot{\eta}$ ) wird folgende Formel aus [23] verwendet:

$$V = c \cdot \sqrt{|\mathbf{P}|} \cdot g^{\frac{N}{2}} \tag{7.1.1}$$

mit  $g \approx 4,7195$  und  $c = \pi^2/2$ . Das Volumen ist somit proportional zur Wurzel der Determinante der Schätzfehlerkovarianz **P**. Die Determinante kann durch die Eigenwerte  $\lambda_i$  beschrieben werden:

$$|\mathbf{P}| = \prod_{i=1}^{N} \lambda_i. \tag{7.1.2}$$

Anhand dieser Schreibweise wird klar, dass das Volumen der Schätzfehlerkovarianz sowohl von den Varianzen als auch den Kovarianzen abhängig ist. Weitere in der Literatur verwendete Verfahren zur Bewertung der Schätzfehlerkovarianz verwenden oft nur die Spur der Matrix und damit die Summe der Eigenwerte. Hier ist ein entscheidender Nachteil, dass nur die Varianzen als Gütekriterium verwendet werden und die Kovarianzen missachtet werden.

### Positions- und Geschwindigkeitsfehler (RMSE)

Als ein Bewertungskriterium wird die Wurzel aus dem Mittelwert des quadratischen Fehlers (*engl.* "Root Mean Square Error", RMSE) berechnet. Für die Berechnung dieses

Positions- und Geschwindigkeitsfehlers wird die reale Position und die reale Geschwindigkeit (*engl.* "Ground Truth") der verfolgten Objekte benötigt. Bei Simulationsdaten sind diese Informationen vorhanden, bei einer Auswertung realer Sensordaten sind die wahren Zustände der Objekte jedoch nicht gegeben.

Bei einer Simulation wird die Differenz zwischen der realen und der geschätzten Position quadriert, über C Monte-Carlo-Simulationen gemittelt und davon schließlich die Quadratwurzel berechnet, um den Positionsfehler zu erhalten:

$$\text{RMSE}_{\xi\eta}(k) = \sqrt{\frac{1}{C} \sum_{i=1}^{C} \left(\xi_k(i) - \hat{\xi}_k(i)\right)^2 + \left(\eta_k(i) - \hat{\eta}_k(i)\right)^2}.$$
 (7.1.3)

Dabei sind  $\xi_k(i)$  und  $\eta_k(i)$  die wahren Positionen der *i*-ten Monte-Carlo-Simulation und  $\hat{\xi}_k(i)$  und  $\hat{\eta}_k(i)$  die geschätzten Zustände des Filters. Die Berechnung des Geschwindigkeitsfehlers erfolgt analog:

$$\text{RMSE}_{\dot{\xi}\dot{\eta}}(k) = \sqrt{\frac{1}{C} \sum_{i=1}^{C} \left(\dot{\xi}_{k}(i) - \dot{\hat{\xi}}_{k}(i)\right)^{2} + \left(\dot{\eta}_{k}(i) - \dot{\hat{\eta}}_{k}(i)\right)^{2}}.$$
 (7.1.4)

Der RMS-Fehler liefert also zu jedem Zeitpunkt einen über alle Monte-Carlo-Simulationen gemittelten Fehler, wobei nicht zusätzlich über die Zeit gemittelt wird.

Bei realen Sensordaten werden die Positionsangaben der Objekte über einen Laserscanner und die Geschwindigkeitsdaten über die odometrischen Daten des Sensorfahrzeugs unter der Annahme unbewegter Objekte gewonnen. Die Gleichungen (7.1.3) und (7.1.4) sind bei der Auswertung realer Fahrversuche analog mit C = 1 anzuwenden, wobei es sich dann nicht mehr um RMS-Fehler, sondern um absolute Positions- und Geschwindigkeitsfehler handelt.

### Fehler der geschätzten Kollisionszeit (TTC-Fehler)

Die Genauigkeit der geschätzten Zeit bis zum Aufprall (*engl.* "Time-to-Collision", TTC) ist bei einer Auswertung realer Fahrversuche ein wichtiges Kriterium zur Beurteilung der Leistungsfähigkeit eines Pre-Crash-Systems. Der wahre Zeitpunkt der Kollision wird in dieser Arbeit mit einer Kontaktsensorik (siehe Abschnitt 2.4.2) bestimmt und mit der geschätzten TTC verglichen. Die Kontaktsensorik liefert zum Zeitpunkt des Aufpralls ein Signal, so dass der genaue Zeitpunkt des Aufpralls bekannt ist. Aus diesem lässt sich dann rückwirkend der TTC-Fehler der Schätzung zu einem beliebigen Zeitpunkt bestimmen.

### Kollisionswahrscheinlichkeit

In Kapitel 6 wurde ein Verfahren entwickelt, um aus dem Zustandsvektor und der Schätzfehlerkovarianz zu einem beliebigen Zeitpunkt eine Kollisionswahrscheinlichkeit zu bestimmen. Die hergeleitete Projektion der Schätzfehlerkovarianz beschreibt die geschätzte räumliche Kollisionswahrscheinlichkeit  $p_{\text{Kollision}}^{(\psi_k)}$ . Zur Evaluierung der Kollisionswahrscheinlichkeit werden reale Messdaten einer Kollision sowie einer knappen Vorbeifahrt ausgewertet. Hierfür wird eine Auslöseschwelle definiert, ab der das Pre-Crash-System aktiviert wird. Entscheidend für die Aktivierung ist, ob die räumliche Kollisionswahrscheinlichkeit diese Schwelle überschreitet. Die Auslöseschwelle dient als zu optimierender Parameter, um die Erkennungsrate im Vergleich zur Falschalarmrate auszubalancieren. Die Leistungsfähigkeit der hergeleiteten Methode zur Projektion der Schätzfehlerkovarianz kann daher in Abhängigkeit von der Auslöseschwelle untersucht werden.

#### Konsistenz

Ein Zustandsschätzer ist konsistent [10], wenn der Erwartungswert des Schätzfehlers gegen Null konvergiert und die vom Filter berechneten Kovarianzen den wahren Kovarianzen entsprechen. Also müssen folgende zwei Bedingungen erfüllt sein:

$$E[\mathbf{x}_k - \hat{\mathbf{x}}_{k|k}] \stackrel{!}{=} 0, \tag{7.1.5}$$

$$E[\left(\mathbf{x}_{k}-\hat{\mathbf{x}}_{k|k}\right)\left(\mathbf{x}_{k}-\hat{\mathbf{x}}_{k|k}\right)^{T}] \stackrel{!}{=} \mathbf{P}_{k|k}.$$
(7.1.6)

Dabei ist  $\mathbf{x}_k$  der wahre Zustandsvektor des verfolgten Objektes und  $\hat{\mathbf{x}}_{k|k}$  der geschätzte Zustandsvektor. Der Nachweis der Filterkonsistenz kann über den NEES (*engl.* "Normalized Estimation Error Squared") erfolgen. Der NEES ist der quadrierte normierte Schätzfehler und setzt das Wissen über den wahren Zustandsvektor voraus. Der NEES wird für jeden Zeitschritt wie folgt berechnet:

$$NEES(k) = \left(\mathbf{x}_{k} - \hat{\mathbf{x}}_{k|k}\right)^{T} \mathbf{P}_{k|k}^{-1} \left(\mathbf{x}_{k} - \hat{\mathbf{x}}_{k|k}\right).$$
(7.1.7)

Es werden also N einzelne Standardnormalverteilungen  $\mathcal{N}(0,1)$  quadriert und aufsummiert. Das heißt, die quadratische Form in Gleichung (7.1.7) ist Chi-Quadrat-verteilt mit N Freiheitsgraden, wenn das Filter konsistent ist und es sich um ein lineares System mit normalverteiltem Fehler handelt. Um das System auf Konsistenz zu überprüfen, wird in einem Test geprüft, ob der NEES einer Chi-Quadrat-Verteilung  $\chi^2_N$  mit Freiheitsgrad Ngenügt. Werden C unabhängige Simulationen durchgeführt, so erhält man den mittleren NEES wie folgt:

$$\overline{\text{NEES}}(k) = \frac{1}{C} \sum_{i=1}^{C} \text{NEES}_i(k).$$
(7.1.8)

Dabei ist  $NEES_i(k)$  der NEES der *i*-ten Simulation zum *k*-ten Zeitschritt. Unter der Hypothese  $H_0$ , dass das Filter konsistent ist, ist  $C \cdot NEES(k)$  Chi-Quadrat-verteilt mit  $C \cdot N$  Freiheitsgraden. Die Hypothese ist erfüllt, wenn

$$NEES(k) \in [r_1, r_2]$$

Dabei wird das Akzeptanzintervall  $a=[r_1, r_2]$  folgendermaßen bestimmt:

$$P(\text{NEES}(k) \in [r_1, r_2] | H_0) = 1 - \alpha,$$

wobei  $\alpha$  das Signifikanzniveau und  $1 - \alpha$  das Quantil ist. Bei dem Test wird  $\alpha$  häufig zu 0,05 gewählt, das heißt, wenn 95% aller Werte innerhalb des Akzeptanzintervalls liegen,

kann angenommen werden, dass der Zustandsschätzer konsistent ist. In der Praxis wird die Definition der Konsistenz, dass die tatsächlichen und die berechneten Unsicherheiten des Schätzfehlers übereinstimmen müssen, nicht so streng ausgelegt. Häufig spricht man auch von Konsistenz, solange die berechneten Unsicherheiten die wahren Unsicherheiten einschließen, das heißt, eine Überschätzung des Fehlers wird toleriert [82, S. 126].

### **ROC-Analyse**

Die ROC-Analyse als Mittel zur Bestimmung des Zusammenhangs zwischen Erkennungsund Falschalarmrate wurde in Abschnitt 6.4.3 beschrieben. Hierbei kann anhand einer Kurve die Erkennungsrate unter Voraussetzung einer beliebigen Falschalarmrate abgelesen werden. Die ROC-Analyse stellt somit ein hilfreiches Mittel zur Optimierung der Auslöseschwelle für das Pre-Crash-System dar, welches die gegebenen Anforderungen an die Erkennungs- und Falschalarmraten berücksichtigt.

# 7.2 Simulation

Zunächst wurden die vorgeschlagenen Algorithmen in einer umfassenden Simulation evaluiert. Alle Verarbeitungsschritte des Pre-Crash-Systems sind hierbei zu beachten. Die Module modellieren sowohl das Sensorverhalten als auch den Systemprozess. Im Folgenden werden die fünf Verarbeitungsschritte der Simulation beschrieben.

Im ersten Modul werden relevante Pre-Crash-Objekte generiert und deren Bewegung simuliert. Ein Beschleunigungsprofil erlaubt die genaue Eingabe der Bewegung für verschiedene Zeitintervalle. Die Bewegungen werden mit den entsprechenden kinematischen Formeln berechnet und mit einem gegebenen Prozessrauschen modelliert. Die maximalen Beschleunigungen werden dabei zum Beispiel bei einem konstanten Geschwindigkeitsmodell gemäß der Wahl von  $\mathbf{Q}$  simuliert. Dieses wurde entsprechend Gleichung (3.3.15) gewählt. Dabei wird der Designparameter

$$q = \sigma_a^2 \Delta t = \left(\frac{10}{3} \frac{\mathrm{m}}{\mathrm{s}^2}\right)^2 \Delta t \tag{7.2.1}$$

gewählt, wobei  $\Delta t$  das jeweilige Abtastintervall bezeichnet und die maximale Beschleunigung  $3\sigma_a$  als  $10 \text{ m/s}^2$  angenommen wurde. Die Ergebnisse der Simulation werden schließlich zu diskret definierten Zeitpunkten gespeichert.

Das Sensormodul simuliert das Verhalten der Sensorik. Dabei wird das Sichtfeld des Sensors und die Sensorrauschmatrix **R** berücksichtigt. Diese wurde entsprechend der realen Sensordaten in Tabelle 2.1 modelliert, so dass das Messrauschen je nach verwendetem Sensor und in Abhängigkeit der Position angepasst wurde. Beispielsweise wurden für die Winkelgenauigkeit des Nahbereichsradars entsprechend der Sensorspezifikation in Tabelle 2.1 die  $3\sigma$ -Werte zwischen 5° und 10° angegeben, wobei die Zwischenwerte durch Messungen bestimmt wurden (vergleiche Abbildung 2.5). Mit der analogen Herleitung für die radiale Messungenauigkeit ergibt sich im optimalen Fall bzw. im ungenaueren Randbereich:

$$\mathbf{R} = \begin{bmatrix} \left(\frac{0,05}{3}\mathrm{m}\right)^2 & 0 & 0\\ 0 & \left(\frac{5^{\circ}}{3}\right)^2 & 0\\ 0 & 0 & \left(\frac{1,39}{3}\frac{\mathrm{m}}{\mathrm{s}}\right)^2 \end{bmatrix} \quad \text{bzw.} \quad \mathbf{R} = \begin{bmatrix} \left(\frac{0,075}{3}\mathrm{m}\right)^2 & 0 & 0\\ 0 & \left(\frac{10^{\circ}}{3}\right)^2 & 0\\ 0 & 0 & \left(\frac{1,39}{3}\frac{\mathrm{m}}{\mathrm{s}}\right)^2 \end{bmatrix}.$$
(7.2.2)

Die übrigen Messungenauigkeiten wurden analog bestimmt und die Messfehlerkovarianzmatrix entsprechend aufgestellt. Mit diesem Modul kann somit das Verhalten beliebig vieler Sensoren simuliert werden. Die Sensordaten werden also gemäß der angegebenen Messunsicherheiten verrauscht.

Um die zeitlichen Charakteristiken der verschiedenen Sensoren zu simulieren, werden jedem Datenpaket Zeitstempel zugeordnet. Diese Zeitstempel beinhalten sowohl den Messzeitpunkt als auch die Ankunftszeit. Hierbei werden wiederum die bekannten Zykluszeiten und Latenzen der realen Sensoren aus Tabelle 2.1 verwendet, was zu einem Drei-Schritt-Problem führt. Um zum Vergleich auch ein Fünf-Schritt-Problem simulieren zu können, werden die Latenzen zusätzlich variiert. Die konkret verwendeten zeitlichen Parameter finden sich in den folgenden Abschnitten. Schließlich werden die Simulationsdaten in der Reihenfolge ihrer Ankunftszeiten gespeichert.

Die Signalverarbeitung zur Integration von chronologisch ungeordneten Messungen stellt das Kernmodul dar. Dieses Modul enthält die Objektinitialisierung mittels der in Abschnitt 3.4 beschriebenen Einpunktinitialisierung, das modifizierte Kalmanfilter mit verschiedenen OOS-Algorithmen aus Kapitel 4, die Datenassoziation nach 5 und die Objektverwaltung gemäß 3.6. Mehrere Algorithmen können parallel mit den gleichen Sensormessdaten arbeiten und erlauben einen schnellen und einfachen Vergleich verschiedener OOSM-Verfahren.

Abschließend werden die Ergebnisse mittels Monte-Carlo-Simulation ausgewertet und gespeichert. Ein Algorithmus wird durch eine Kostenfunktion K evaluiert und die Performanz lässt sich als der Erwartungswert der Kosten darstellen. Als Kostenfunktion kann beispielsweise die Laufzeit oder der Fehler des Algorithmus verwendet werden. In praktischen Fällen, in denen Zufallszahlen eine Rolle spielen, ist es nicht möglich die Performanz analytisch zu berechnen. Es werden C unabhängige und repräsentative Stichproben gewählt und die zu erwartenden Kosten  $\overline{K}$  wie folgt berechnet:

$$\bar{K} = \frac{1}{C} \sum_{i=1}^{C} K_i.$$
(7.2.3)

In der Pre-Crash-Simulation entstehen die stochastischen Ereignisse durch das Sensormessrauschen, das Prozessrauschen, die Detektionswahrscheinlichkeit und das Hintergrundrauschen.

### 7.2.1 Simulation eines Drei-Schritt-OOSM-Problems

Die folgende Simulation soll möglichst genau an die spätere Sensorkonfiguration im Versuchsfahrzeug angelehnt werden. Dazu werden Messungen mit der genauen Spezifikation der Seriensensoren erzeugt. Die charakteristischen Parameter sind Tabelle 2.1 zu entnehmen, was zu Kovarianzmatrizen des Messrauschens gemäß (7.2.2) führt. Passend zu einem SRR- und einem MMR-Sensor wurden gemäß Tabelle 2.1 Latenzen von 80 ms bzw. 198 ms verwendet. Daher ergibt sich ein Drei-Schritt-OOSM-Problem, bei welchem auch vereinzelt Schrittweiten von l=2 vorkommen. Zuerst wird wie in Kapitel 6 eine frontale Kollision und anschließend ein Ausweichmanöver simuliert. Es wurde jeweils ein Modell konstanter Geschwindigkeit verwendet. Die Ergebnisse werden im Folgenden vorgestellt.

### Frontale Kollision

Bei dem ersten Szenario einer frontalen Kollision fährt das Kollisionsfahrzeug mit einer konstanten Geschwindigkeit auf das Sensorfahrzeug zu. Die Geschwindigkeit beträgt 10 km/h und der Startpunkt befindet sich 20 m vor dem Sensorfahrzeug. Die Simulationszeit beträgt 2 s. Insgesamt werden 10 000 Monte-Carlo-Simulationen berechnet. Die wahren Objektverläufe werden unter Berücksichtigung der Prozessfehlerkovarianz  $\mathbf{Q}$  gemäß (7.2.1) verrauscht. Untersucht wird die Performanz von Messdatenverzögerung, Reprozessierung, Retrodiktion und FPFD im Vergleich.

Die Ergebnisse der vier Algorithmen sind in Abbildung 7.1 dargestellt. Abbildung 7.1a zeigt das  $1\sigma$ -Volumen der Schätzfehlerkovarianz **P**. Insbesondere in den ersten Filterzyklen sind große Unterschiede feststellbar, was folgenden Grund hat: Die Reprozessierung und die OOSM-Algorithmen (Retrodiktion und FPFD) integrieren eintreffende Messungen direkt in die Zustandsschätzung. Nach 80 ms trifft die erste Nahbereichsmessung ein und anschließend erfolgen die nächsten Innovationen zum Messzeitpunkt von 120 ms aufgrund der Zykluszeit von 40 ms.

Im Gegensatz dazu erfolgen die Filterinitialisierung und die ersten Innovationen bei einer Messdatenverzögerung erst nach 198 ms, da die Messungen zwischengespeichert werden müssen, bis von jedem Sensor eine Messung vorhanden ist. Der Algorithmus startet somit verzögert, kann dann aber mehrere gespeicherte Messungen zu einem Zeitpunkt integrieren. Durch insgesamt weniger Integrationszeitpunkte ist bei einer Messdatenverzögerung ein größerer Prädiktionsschritt notwendig, der in einer größeren Schätzfehlerkovarianz resultiert. Man sieht daher zu Beginn der Simulation eine größere Unsicherheit bei der Messdatenverzögerung im Vergleich zu den OOSM-Algorithmen.

Abbildung 7.1b zeigt einen vergrößerten Ausschnitt des Unsicherheitsvolumens der Matrix  $\mathbf{P}$ . Die Integrationsschritte erfolgen bei einer Messdatenverzögerung im 66 ms-Takt, wohingegen die OOSM-Algorithmen bei jeder eintreffenden Messung eine Innovation durchführen. Während der ersten halben Sekunde ist das Volumen der Schätzfehlerkovarianz mit einer Messdatenverzögerung um ein Vielfaches größer als bei den OOSM-Algorithmen.

Die Performanz der einzelnen Algorithmen hängt unter anderem von der anfänglichen Wahl der Schätzfehlerkovarianz  $\mathbf{P}$  ab. Diese wurde mittels Einpunktinitialisierung bestimmt, wie in Kapitel 3.4 beschrieben. Da sie jedoch bei allen vier Algorithmen gleich gewählt wurde und zusätzlich über 10000 Monte-Carlo-Läufe gemittelt wurde, relativiert sich diese Abhängigkeit und ein bewertender Vergleich ist möglich.



**Abbildung 7.1:** <u>Simulation</u>: Frontale Kollision simuliert mit einem Drei-Schritt-OOSM-Problem. (a) Volumen der Schätzfehlerkovarianz und (b) vergrößerter Ausschnitt. (c) Positions- und (d) Geschwindigkeitsfehler, zu jedem Zeitpunkt gemittelt über 10 000 Monte-Carlo-Läufe.
Abbildung 7.1c und 7.1d zeigen den Positions- bzw. Geschwindigkeitsfehler der Systemzustände. Insgesamt ist ein deutlicher Vorteil der OOSM-Algorithmen im Vergleich zur Messdatenverzögerung sichtbar, sowohl die Positionsfehler als auch die Geschwindigkeitsfehler sind signifikant kleiner. Bei der Messdatenverzögerung treten in den ersten 500 ms Positionsfehler bis zu 3,5 m auf, wohingegen die OOSM-Algorithmen nur einen maximalen Positionsfehler von 2 m aufweisen. Die Geschwindigkeitsfehler verhalten sich ähnlich wie die Positionsfehler, man sieht die Überlegenheit der OOSM-Algorithmen im Vergleich zur Messdatenverzögerung.

Nach ca. 500 ms ist das System eingeschwungen und das Ergebnis der Messdatenverzögerung nähert sich jeweils den Ergebnissen der OOSM-Algorithmen an. Trotzdem ist eine konstant schlechtere Leistung der Messdatenverzögerung zu beobachten, insbesondere den Positionsfehler betreffend. Dieser Sachverhalt ist in Tabelle 7.1 verdeutlicht. Hier sind die über 10 000 Monte-Carlo-Läufe gemittelten Fehler zu den Simulationszeitpunkten von 250 ms sowie 1s aufgelistet. Nach 250 ms beträgt der Positionsfehler der Messdatenverzögerung das Dreifache im Vergleich zum Fehler der anderen Algorithmen und der Geschwindigkeitsfehler das Doppelte.

Man sieht ebenfalls, dass die Messdatenverzögerung auch noch nach einer Sekunde Laufzeit einen um 4 cm größeren Positionsfehler aufweist sowie einen vernachlässigbar größeren Geschwindigkeitsfehler. Diese konstant schlechtere Leistung der Messdatenverzögerung liegt an den größeren Latenzen bis zur Integration von Messungen, wodurch dauerhaft veraltete Daten verwendet werden.

Algorithmus	Positionsfehler [m]		Geschwindigkeitsfehler [m/s]	
Zeitpunkt	$0{,}25\mathrm{s}$	$1\mathrm{s}$	$0,\!25\mathrm{s}$	$1\mathrm{s}$
Messdatenverzögerung Reprozessierung Retrodiktion FPFD	$3,2106 \\ 0,9125 \\ 0,9125 \\ 0.9124$	0,4734 0,4341 0,4340 0,4345	8,9936 4,8686 4,8687 4,8687	1,7467 1,6351 1,6351 1,6344

**Tabelle 7.1:** RMS-Fehler gemittelt über 10000 Monte-Carlo-Läufe zu den Zeitpunkten t = 0.25 s und t = 1 s.

Zwischen der Reprozessierung, der Retrodiktion und dem FPFD-Algorithmus sind keine Unterschiede zu erkennen, die Differenzen im Positionsfehler betragen weniger als einen Millimeter. Dies könnte daran liegen, dass die Algorithmen im Ein-Schritt-Fall sogar analytisch äquivalent sind. Im Mehr-Schritt-Fall gilt diese analytische Äquivalenz zwar nicht mehr, die vergleichbaren Ergebnisse sprechen jedoch für eine immer noch sehr große Ähnlichkeit der Algorithmen.

#### Ausweichmanöver

Als zweiter Testfall wurde ein Ausweichmanöver simuliert. Die simulierten Radarsensoren sind wie im Versuchsfahrzeug spezifiziert und besitzen somit dieselben charakteristischen

Parameter wie im vorherigen Versuch. Es wurde wiederum eine Simulationszeit von insgesamt 2s gewählt. Im Vergleich zum vorherigen Szenario wurde ein komplizierteres Fahrmanöver gewählt, anstelle einer konstanten Geschwindigkeit wurde eine stückweise konstante Beschleunigung simuliert. Zwischen 0,6s und 0,9s erfährt das Fahrzeug eine Beschleunigung von  $-5 \text{ m/s}^2$  in  $\xi$ -Richtung (schneller zum Ursprung hin) und eine Beschleunigung von  $10 \text{ m/s}^2$  in  $\eta$ -Richtung (Ablenkung nach links). Zwischen 1,1s und 1,4s wird das Objekt in die entgegengesetzte Richtung beschleunigt. Die Objekte des Ausweichmanövers werden mit einem Modell konstanter Geschwindigkeit verfolgt. Die auftretenden Beschleunigungen sind im Prozessrauschen über die Kovarianzmatrix **Q** modelliert. Insgesamt wurden wieder 10000 Monte-Carlo-Läufe simuliert.

Abbildung 7.2a zeigt den Objektverlauf des simulierten Ausweichmanövers mit vergrößertem Ausschnitt in 7.2b. Abgebildet ist die simulierte Trajektorie als Referenz sowie die geschätzten Trajektorien der vier untersuchten Algorithmen. Man sieht besonders in der vergrößerten Darstellung, dass die Messdatenverzögerung bei Richtungsänderungen Probleme hat, dem Verlauf der Trajektorie zu folgen. Aufgrund der geringeren Latenz erweisen sich die OOSM-Algorithmen insbesondere bei dynamischen Fahrmanövern als deutlich performanter und flexibler.

Abbildungen 7.2c und 7.2d zeigen den Positions- bzw. den Geschwindigkeitsfehler. Das Einschwingverhalten und der größere Fehler bei einer Messdatenverzögerung sind identisch zum vorherigen Versuch. Bei den zwei Richtungsänderungen des simulierten Fahrmanövers muss das Filter neu einschwingen, um dem wahren Verlauf der Objekte folgen zu können. Es entstehen zwei Fehlerspitzen bei  $t \approx 1$ s und  $t \approx 1,4$ s. Die Messdatenverzögerung zeigt ein größeres Überschwingen als die OOSM-Algorithmen. Gerade bei Änderungen des Prozessmodells im Rahmen des modellierten Prozessrauschens ist die direkte Integration vorhandener Sensordaten entscheidend. Diese Informationen über eine Änderung des Prozesses stehen den OOSM-Algorithmen zeitlich früher zur Verfügung und eine genauere Zustandsschätzung ist daher möglich.

#### Konsistenz

Zur Auswertung der Konsistenz des entwickelten Filters wird ein Objektverlauf konstanter Geschwindigkeit simuliert. Mit insgesamt 1000 Monte-Carlo-Läufen und einem vierdimensionalen Zustandsvektor ergibt sich eine Chi-Quadrat-Verteilung mit Freiheitsgrad 4000. Bei einem 95 %-Quantil liegt das resultierende Akzeptanzintervall bei [3,827 4,177].

Abbildung 7.3a zeigt den NEES der OOSM-Algorithmen über 400 simulierte Messzeitpunkte. Die gesamte Sequenz wird mittels 1 000 Monte-Carlo-Simulationen ausgewertet. Somit erhält man für jeden Abtastschritt 1 000 gemittelte Werte. Bei der Messdatenverzögerung liegen 4,58%, bei der Reprozessierung 5,01%, bei der Retrodiktion 5,01% und bei dem FPFD-Algorithmus 4,85% der Werte außerhalb des Akzeptanzintervalls. Somit können die Filter als konsistent angenommen werden. Dieser Test soll zeigen, dass auch mit den OOSM-Algorithmen das Filter konsistent bleibt.

Um Änderungen in der Geschwindigkeit im Falle von Beschleunigungen abdecken zu können, wird das Filter mit einem größeren Prozessrauschen modelliert. Dies führt bei



**Abbildung 7.2:** <u>Simulation</u>: Ausweichmanöver simuliert mit einem Drei-Schritt-OOSM-Problem. (a) Verlauf der Objekte und (b) vergrößerter Ausschnitt sowie (c) Positions- und (d) Geschwindigkeitsfehler, zu jedem Zeitpunkt gemittelt über 10000 Monte-Carlo-Läufe.



**Abbildung 7.3:** <u>Simulation</u>: Zweiseitiger NEES-Test über 1 000 Monte-Carlo-Läufe für einen vierdimensionalen Zustandsvektor mit 95%-Quantil der entsprechenden Chi-Quadrat-Verteilung. (a) Konsistentes Filter und (b) leichte Überschätzung der Unsicherheiten.

einem Prozess konstanter Geschwindigkeit zu einer leichten Überschätzung des Filters, wie in Abbildung 7.3b gezeigt. Eine Überschätzung wird bei einer Konsistenzanalyse toleriert, eine Unterschätzung der Schätzfehlerkovarianz ist jedoch zu vermeiden.

### 7.2.2 Simulation eines Fünf-Schritt-OOSM-Problems

Bei den bisherigen Versuchen wurde der Sensoraufbau des Versuchsfahrzeuges simuliert. Um die Auswirkungen der OOSM-Schrittweite zu untersuchen, wird in diesem Experiment die Latenz des Mehrmodusradars von 198 ms um eine weitere Zykluszeit auf 264 ms erhöht. Mit dieser Annahme ergibt sich ein Fünf-Schritt-OOSM-Problem.

Die erste Innovation der Messdatenverzögerung erfolgt hierdurch erst nach 264 ms. Die Integrationsschritte von 66 ms bleiben identisch. Abbildung 7.4 zeigt den Positions- bzw. den Geschwindigkeitsfehler. Wie man sieht, zeigt die Messdatenverzögerung im Einschwingvorgang einen deutlich größeren Fehler als beim Drei-Schritt-Problem. Je größer die Anzahl l der OOS-Schritte, desto größer wird der Fehler der Messdatenverzögerung im Vergleich zu den anderen Algorithmen. Dies liegt daran, dass die integrierten Messungen zunehmend veraltet sind und anfangs noch länger auf die erste Integration gewartet werden muss. Mit zunehmender Anzahl an OOS-Schritten ergibt sich eine immer inakzeptablere Leistung der Messdatenverzögerung.

Nach ca. 1s nähern sich die Ergebnisse der Messdatenverzögerung und die Ergebnisse der OOSM-Algorithmen an. Die Fehlerkurven der Messdatenverzögerung bleiben jedoch über denen von OOSM, da eine Messdatenverzögerung aufgrund von größeren Prädiktionsschritten und verzögerten Innovationen die Systemzustände schlechter schätzen kann. Man sieht somit eine deutlich schlechtere Leistung der Messdatenverzögerung, die sich



**Abbildung 7.4:** <u>Simulation</u>: Frontale Kollision simuliert mit einem Fünf-Schritt-OOSM-Problem. (a) Positions- und (b) Geschwindigkeitsfehler (RMSE) gemittelt über 1000 Monte-Carlo-Simulationen

auch über die Zeit nicht verringert. Dieser Unterschied ist sichtbar größer als im Drei-Schritt-Fall. Bei einer Änderung des Prozesses ist zudem wieder eine deutlich längere Einschwingzeit der Messdatenverzögerung zu erwarten. Mit zunehmender Anzahl an OOS-Schritten ist daher eine Messdatenverzögerung im Vergleich zu Reprozessierung oder den OOS-Algorithmen immer weniger praktikabel.

#### 7.2.3 OOSM-Einflussfaktoren

In der Praxis spielt die Entscheidung eine wichtige Rolle, in welchen Fällen OOSM-Algorithmen zwingend notwendig sind und wann auch mit einer Messdatenverzögerung akzeptable Ergebnisse erzielt werden können. Daher werden im Folgenden die verschiedenen Einflussfaktoren näher untersucht und deren Abhängigkeiten analysiert.

Bei der folgenden Betrachtung wird von einem nicht-deterministischen Pufferspeicher und konstanten Zyklus- und Latenzzeiten ausgegangen. Es wird angenommen, dass bei einer Fusion zweier Sensoren das Problem chronologisch ungeordneter Messdaten entsteht. Sensor 1 (z.B. MMR) liefert die OOS-Messungen mit einer Zykluszeit  $Z_1$ , einer Latenz  $L_1$  und einer Messfehlerkovarianz  $\mathbf{R}_1$ . Analog dazu hat Sensor 2 (z.B. SRR) eine Zykluszeit von  $Z_2$ , eine Latenz von  $L_2$  und eine Messfehlerkovarianz  $\mathbf{R}_2$ . Außerdem ist die Zustandsschätzung mit einer Prozessfehlerkovarianz  $\mathbf{Q}$  modelliert.

Steigt die Zykluszeit von Sensor 2 an, wird die Schrittweite l größer, wodurch der Vorteil der OOSM-Algorithmen gegenüber einer Messdatenverzögerung ansteigt. Erhöht sich auch die Schrittweite durch eine kleinere Zykluszeit von Sensor 1, werden wiederum die OOSM-Algorithmen eine genauere Schätzung liefern. Erhöht sich die Latenz von Sensor 1 oder verkleinert sich die Latenz von Sensor 2, wird wieder die Schrittweite größer und somit eine direkte Integration von Sensordaten von größerer Bedeutung.

Die Messfehlerkovarianz  $\mathbf{R}_1$  hat keinen Einfluss auf die Ergebnisse, da Sensor 1 in diesem Fall die Messungen immer außerhalb der zeitlichen Reihenfolge liefert und diese sowohl bei der Messdatenverzögerung als auch bei den OOSM-Algorithmen zur gleichen Zeit in die Zustandsschätzung integriert werden können. Je kleiner jedoch das Messrauschen  $\mathbf{R}_2$ von Sensor 2 ist, desto genauer sind die Messungen und desto wichtiger ist die direkte Integration dieser Sensordaten.

Das Prozessrauschen vergrößert in jedem Prädiktionsschritt die Schätzfehlerkovarianz. Das Verhältnis der Schätzfehlerkovarianz zu der zugehörigen Messfehlerkovarianz bestimmt die Kalman-Verstärkungsmatrix und somit die Gewichtung des Residuums. Je größer die Prozessfehlerkovarianz  $\mathbf{Q}$  modelliert werden muss, desto größer werden die Unsicherheiten und desto wichtiger ist wiederum die direkte Integration von allen vorhandenen Messungen.

Wie in diesem Abschnitt deutlich wurde, haben zahlreiche Größen einen direkten Einfluss auf die Bedeutung von OOSM-Algorithmen. Nutzen und Aufwand müssen daher für jeden Sensoraufbau und für jede Zustandsschätzung separat abgewogen werden. Insgesamt ist also der Nutzen von OOSM-Algorithmen besonders groß, wenn die OOSM-Schrittweite l groß ist und das Messrauschen der verzögerten Messung besonders klein, wodurch die OOS-Messung einen hohen Informationsgehalt besitzt.

## 7.2.4 ROC-Gesamtanalyse

In den vorherigen Abschnitten wurden exemplarisch einzelne simulierte Fahrversuche untersucht und die OOSM-Algorithmen im Vergleich zur Messdatenverzögerung evaluiert. In diesem Teil der Arbeit wird eine Versuchseinheit inklusive Situationsbewertung für ein Pre-Crash-System aufgebaut und die Algorithmen anhand einer ROC-Kurve bewertet. Dazu werden insgesamt 15 000 Monte-Carlo-Simulationen einer Zustandsschätzung mit chronologisch ungeordneten Messungen und anschließender Situationsanalyse durchgeführt. Die Simulation wird gleich dem Sensoraufbau des Versuchsfahrzeuges gewählt und hat damit zwei Nahbereichsradare und ein Mehrmodusradar. Die genaue Spezifikation der Sensoren wurde in Kapitel 2 gegeben. Die Ergebnisse der folgenden ROC-Analyse wurden in [152] veröffentlicht.

Bei der Simulation werden die ersten 290 ms der Zustandsschätzung betrachtet. Nach dieser Zeit führte eine Hälfte der Tests zu einer Kollision, die andere Hälfte zu einer knappen Vorbeifahrt. Die Geschwindigkeiten wurden zwischen 15 und 50 km/h variiert. Das Sensorfahrzeug steht und das Kollisionsobjekt bewegt sich entweder geradlinig auf das Fahrzeug zu oder knapp am Fahrzeug vorbei, wobei eine lineare Bewegung mit konstanter Geschwindigkeit vorgegeben wurde.

Zur Berechnung der Kollisionswahrscheinlichkeit wird eine räumliche Transformation der Zustandsschätzung und der Schätzfehlerkovarianz mit Hilfe des in Kapitel 6.1 und 6.2 beschriebenen Verfahrens durchgeführt. Die räumliche Transformation erfolgt mit 5000 Partikeln. Diese Partikelwolke repräsentiert die Schätzfehlerkovarianz. Daraus wird eine räumliche Kollisionswahrscheinlichkeit, wie in Kapitel 6 beschrieben, berechnet. Für eine Pre-Crash-Aktivierung muss die zeitliche Projektion eine mittlere TTC von 200 ms bis 400 ms ergeben. Die räumliche Auslöseschwelle wird von 0 bis 1 mit Schrittweiten von 0,01 inkrementiert und die Erkennungs- und Falschalarmrate für jeden dieser Arbeitspunkte berechnet. Hier wird noch einmal der Vorteil der entwickelten Projektionsmethode für die Schätzfehlerkovarianz deutlich, da diese durch die Herleitung einer Kollisionswahrscheinlichkeit erst die Durchführung einer ROC-Gesamtanalyse möglich macht.

Abbildung 7.5 zeigt das Ergebnis der ROC-Analyse für die Messdatenverzögerung, die Reprozessierung, die Retrodiktion und den FPFD-Algorithmus. Es ist ein deutlicher Unterschied zwischen der Messdatenverzögerung verläuft deutlich flacher als die anderen drei ROC-Kurve der Messdatenverzögerung verläuft deutlich flacher als die anderen drei ROC-Kurven und erzielt somit eine ungünstigere Rate von Erkennungsleistung im Vergleich zu Falschalarmen. Die Reprozessierung liefert nach dieser Analyse die besten Ergebnisse, da sie dem optimalen Punkt (0,1) mit einer Erkennungsrate von 100% und einer Falschalarmrate von 0% am nächsten kommt. Nur unwesentlich schlechter sind die Ergebnisse von Retrodiktion und FPFD. Dies wird insbesondere bei Betrachtung des vergrößerten Ausschnittes in 7.5b bei einer Falschalarmrate kleiner 10% deutlich. In diesem Bereich erzielt die Messdatenverzögerung bei gleichbleibender Falschalarmrate eine über 10% schlechtere Erkennungsrate. Die ROC-Kurve kann äquivalent dazu auch folgendermaßen interpretiert werden: Bei einer konstanten Erkennungsrate von über 94% weist die Messdatenverzögerung eine sehr viel größere Falschalarmrate auf. Tabelle 7.2 zeigt die exakten Werte für die beiden genannten Beispiele.

Algorithmus	Verzögerung	Reprozess.	Retrodiktion	FPFD
Erkennung bei 4 $\%$ Falschalarm rate Falschalarm bei 94 $\%$ Erkennungsrate	42,72% 32,31%	$58,\!19\%$ $21,\!06\%$	$53,93\%\ 23,04\%$	53,99% 22,53%

 Tabelle 7.2:
 Erkennungs- und Falschalarmrate der OOSM-Algorithmen.

Die Bestimmung des Arbeitspunktes erfolgt durch Dimensionierung der räumlichen Auslöseschwelle. Je größer die Kollisionswahrscheinlichkeit für eine Auslösung sein muss, desto weniger Falschauslösungen lässt das System zu. Im Grenzfall bei  $p_{\text{Kollision}}^{(\psi_k)} = 1$  wird die Falschalarmrate zu 0%, aber auch die Erkennungsrate sehr klein. Bei einer sehr kleinen Auslöseschwelle steigt die Erkennungsrate bei gleichzeitig steigender Falschalarmrate. Im Grenzfall bei  $p_{\text{Kollision}}^{(\psi_k)} = 0$  ist sowohl die Erkennungsrate als auch die Falschalarmrate gleich 100%. Die Parametrierung und Festlegung des Arbeitspunktes erlaubt die Bestimmung des passenden Verhältnisses aus Erkennungs- und Falschalarmrate.



**Abbildung 7.5:** <u>Simulation</u>: (a) ROC-Kurve mit verschiedenen Auslöseschwellen und (b) vergrößerter Ausschnitt im Bereich einer Falschalarmrate kleiner 10%.

# 7.3 Auswertungen realer Fahrversuche

Neben den Simulationsergebnissen bildet eine Auswertung mit realen Sensordaten den Schwerpunkt dieses Kapitels. Es wurden zahlreiche Messfahrten durchgeführt, um das entwickelte Pre-Crash-Systems in realen Fahrsituationen zu testen und die verschiedenen Algorithmen zu vergleichen. Für die Bewertung eines neuen Systems spielen dabei die Qualität und die Quantität der Messdaten eine entscheidende Rolle. Die Qualität beschreibt die Schwierigkeit der zu klassifizierenden Fahrszenen. Die Fahrszenen beinhalten Kollisionen, Beinahe-Kollisionen und auch Dauertests. Die kritischen Situationen sollen das System an den Auslösegrenzen testen, im Gegensatz dazu sollen die Dauertests und Normalfahrten die Alltagstauglichkeit unter Beweis stellen. Eine große Quantität der Messfahrten garantiert die statistische Signifikanz der ermittelten Ergebnisse; hierfür wurden 80 Kollisionsfahrten sowie 70 kritische Fahrmanöver mit knapper Vorbeifahrt durchgeführt.

Eine Mercedes-Benz S-Klasse, wie in Kapitel 2.2 vorgestellt, dient als Versuchträger und der Pre-Crash-Algorithmus kann im Fahrzeug gleichzeitig mit den verschiedenen Signalverarbeitungsalgorithmen getestet werden. Bei einer erkannten unvermeidbaren Kollision wird auf dem Fahrzeugmonitor ein Warndreieck angezeigt (siehe Abbildung 2.3d) und zur gleichen Zeit ein reversibler Gurtstraffer aktiviert.

Bei dem Sensoraufbau des Versuchsfahrzeugs handelt es sich um ein Drei-Schritt-OOSM-Problem. In den folgenden Experimenten wird auf die einzelnen Bewertungskriterien eingegangen, um die Messdatenverzögerung mit der Reprozessierung, der Retrodiktion und dem FPFD-Algorithmus zu vergleichen. Hierbei wurden die Kovarianzen des Prozessund des Messrauschens wie in der Simulation entsprechend (7.2.1) und (7.2.2) gewählt.

### 7.3.1 Experimente zur Schätzfehlerkovarianz

Ein wichtiges Kriterium zur Beurteilung einer Zustandsschätzung ist die Größe der Schätzfehlerkovarianz. Unter der Annahme konsistenter Filter beschreibt das Volumen der Schätzfehlerkovarianz  $\mathbf{P}_{k|k}$  die Unsicherheit der Systemzustände  $\hat{\mathbf{x}}_{k|k}$ . Im Initialisierungsschritt nimmt das Volumen einen relativ großen Wert an, wobei die Ein-Punkt-Initialisierung gemäß 3.4 verwendet wurde. Wird die Schätzfehlerkovarianz klein, so konvergiert der geschätzte Wert gegen den tatsächlichen Wert. Eine Schätzfehlerkovarianz von Null kann in dynamischen Systemen jedoch aufgrund der Kovarianz des Prozessrauschens nicht erreicht werden.

Abbildung 7.6 zeigt die Sensordaten sowie die Objektverfolgung von der Messdatenverzögerung und den drei OOSM-Algorithmen kurz vor einer zentrischen Kollision. Die  $3\sigma$ -Unsicherheitsellipsen in der Position zeigen einen deutlichen Unterschied. Während die Unsicherheiten der Reprozessierung und der OOSM-Algorithmen annähernd gleich sind, ist die Unsicherheit der Messdatenverzögerung sehr viel größer. Dies zeigt die Problematik einer nicht direkten Integration von vorhandenen Messdaten. Eine Projektion dieser größeren Schätzfehlerkovarianz zur Situationsbewertung resultiert in einer größeren räumlichen Kollisionsunsicherheit. Die Messdatenverzögerung weist zwei Meter vor dem Fahrzeug eine Kollisionswahrscheinlichkeit von nur 29,72 %auf, wohingegen die Reprozessierung und die OOSM-Algorithmen mit einer Wahrscheinlichkeit von über 61 % die Kollision erkennen.

Abbildung 7.7 zeigt das Volumen der Schätzfehlerkovarianz in Abhängigkeit von der Zeit. Es werden die letzten 700 ms vor einer Kollision betrachtet. Die gestrichelte senkrechte Linie stellt den mit einem Kontaktsensor ermittelten wahren Kollisionszeitpunkt dar. Im Unterschied zur Abbildung 7.6 enthält das Volumen die Informationen des kompletten Zustandsvektors. Das heißt, Varianzen und Kovarianzen sowohl der Positions- als auch der Geschwindigkeitsinformationen werden im Volumen abgebildet. Für jeden Zeitschritt  $t_k$  existieren zwei Werte, zum einen die prädizierte Schätzfehlerkovarianz  $\mathbf{P}_{k|k-1}$  und zum anderen die korrigierte Schätzfehlerkovarianz  $\mathbf{P}_{k|k}$ , also nach Integration der Messungen. Es ist deutlich zu sehen, dass die Unsicherheit bei einer Prädiktion steil ansteigt und bei einer Innovation wieder abfällt. Das prädizierte Volumen ist abhängig vom Prozessmodell und steigt abhängig von der Wahl der Prozessfehlerkovarianz  $\mathbf{Q}$  unterschiedlich stark an. Der ansteigende nichtlineare Verlauf bei der Prädiktion ist auf ein kontinuierliches anstelle eines diskreten Prozessmodells, wie in Abschnitt 3.3.1 beschrieben, zurückzuführen.

Zwischen 700 und 550 ms vor der Kollision befindet sich das Kollisionsfahrzeug noch außerhalb des Sichtbereichs des SRR. Hierdurch erfolgen bei allen vier Algorithmen weniger Innovationen und größere Prädiktionsschritte, die Ergebnisse sind entsprechend ähnlich schlecht. 550 ms vor der Kollision wird das Ziel zum ersten Mal von den Nahbereichssensoren detektiert. Deren Messungen können bei der Reprozessierung, der Retrodiktion und dem FPFD-Algorithmus direkt in die Zustandsschätzung integriert werden. Man sieht deutlich die plötzliche Verringerung der Unsicherheit, das Volumen der Schätzfehlerkovarianz reduziert sich auf einen Bruchteil und bleibt auch in den folgenden Schritten stabil klein. Hier ist somit der Benefit der Fusion klar erkennbar. Die Reprozessierung, die Retrodiktion und der FPFD-Algorithmus besitzen fast das gleiche Volumen der Schätzfehlerkovarianzen. Leichte Unterschiede sind auf die Approximation bei dem Mehr-Schritt-Verfahren zurückzuführen.

Der nicht-deterministische Pufferspeicher hingegen kann die ersten SRR-Messdaten nicht sofort integrieren. Es müssen im Gegenteil weitere drei Messungen des MRR abgewartet werden, bis diese integriert werden können. Diese drei Wartezyklen tragen dem Drei-Schritt-Problem Rechnung. Der genaue zeitliche Ablauf einer nicht-deterministischen Pufferspeicherung wurde in Abbildung 4.2 verdeutlicht. In der abgebildeten Kurve in 7.7 ist die Verringerung der Unsicherheit erst drei Schritte nach Eintreffen der ersten SRR-Messungen deutlich erkennbar. Diese verzögerte Verringerung der Schätzfehlerkovarianz stellt einen klaren Nachteil der Messdatenverzögerung dar. Außerdem ist zu sehen, dass selbst nach Integration der SRR-Messungen die Unsicherheit um ein Vielfaches größer bleibt. Das liegt an der andauernden Verzögerung aller SRR-Messungen. Ein dritter großer Nachteil ist ebenfalls deutlich anhand der Grafik abzulesen: Aufgrund der Messdatenverzögerung ergeben sich längere Zeiten bis zur nächsten Innovation und somit längere Prädiktionsschritte, was die Unsicherheit weiter vergrößert. Eine plötzliche Anderung der Fahrdynamik kann aufgrund der seltenen Innovationen unter Umständen erst zu spät erkannt werden. Aus allen diesen Gründen kann somit eine Kollisionsklassifikation mittels Messdatenverzögerung nur unter großen Einschränkungen und Unsicherheiten erfolgen.



Abbildung 7.6: <u>Reale Sensordaten</u>: Objektverfolgung und Situationsbewertung mit Messdatenverzögerung (Buffering), Reprozessierung (Reprocessing), Retrodiktion und FPFD vor einer zentrischen Kollision. Die Messdatenverzögerung hat die größte Unsicherheit und damit die geringste räumliche Kollisionswahrscheinlichkeit.



Abbildung 7.7: <u>Reale Sensordaten</u>:  $1\sigma$ -Volumen der Schätzfehlerkovarianzen. Nach Eintreffen der ersten SRR-Messung ca. 520 ms vor der Kollision hat die Messdatenverzögerung die deutlich höheren Unsicherheiten. Die senkrechte Linie ist der exakte Aufprallzeitpunkt, der durch eine Kontaktsensorik ermittelt wurde.

### 7.3.2 Experimente zur Auslösewahrscheinlichkeit

Im Kapitel 6 wurden drei Verfahren zur Projektion der räumlichen Unsicherheiten vorgestellt. Die Sigma-Punkt-Transformation hat sich als guter Kompromiss zwischen Genauigkeit und Aufwand erwiesen. Dieses Verfahren wird im kommenden Abschnitt zur Berechnung der Kollisionswahrscheinlichkeit verwendet. Wie im vorherigen Abschnitt beschrieben, ergibt sich für die Messdatenverzögerung eine größere Schätzfehlerkovarianz und daraus resultierend eine kleinere Kollisionswahrscheinlichkeit.

Abbildung 7.8a zeigt die Kollisionswahrscheinlichkeit, die aus der räumlichen Projektion der Schätzfehlerkovarianz resultiert. Bei diesem Versuch handelt es sich um eine frontale Kollision, hierbei werden die Unterschiede zwischen einer Messdatenverzögerung und den OOSM-Algorithmen aufgezeigt. Die gestrichelte senkrechte Linie stellt den exakten Aufprallzeitpunkt gemessen mit der Kontaktsensorik dar. Zwischen 500 und 600 ms vor der Kollision erreicht die erste Nahbereichsmessung die Fusionseinheit. Ab diesem Zeitpunkt steigt die räumliche Kollisionswahrscheinlichkeit der OOSM-Algorithmen stärker an als bei der Messdatenverzögerung. Ab ca. 180 ms vor der Kollision haben die Reprozessierung, die Retrodiktion und der FPFD-Algorithmus eine Kollisionswahrscheinlichkeit, die annähernd 100 % beträgt. Somit würde für die OOSM-Algorithmen eine Auslöseschwelle von knapp unter 100 % genügen, wohingegen die Messdatenverzögerung mit einer Schwelle von nur 76 % auslösen müsste.



Abbildung 7.8: <u>Reale Sensordaten</u>: Mit Sigma-Punkt-Transformation berechnete räumliche Kollisionswahrscheinlichkeit bei (a) einer Frontalkollision und (b) einem Ausweichmanöver. Senkrechte Linie kennzeichnet bei (a) den durch die Kontaktsensorik bestimmten Kollisionszeitpunkt.

Abbildung 7.8b zeigt die Kollisionswahrscheinlichkeit für ein Ausweichmanöver. Die projizierte Schätzfehlerkovarianz liefert auch hier für die OOSM-Algorithmen eine größere Kollisionswahrscheinlichkeit. Die Zeitachse kann in diesem Fall nicht auf eine Kollision bezogen werden, da kein Kollisionszeitpunkt vorhanden ist; der Nullpunkt bezeichnet daher den Zeitpunkt der seitlichen Vorbeifahrt am detektierten Objekt. 100 ms vor der drohenden Kollision erreicht die Kollisionswahrscheinlichkeit bei den OOSM-Algorithmen ca. 40 % und die Situationsanalyse würde richtigerweise das Pre-Crash-System nicht aktivieren. Die Messdatenverzögerung besitzt die geringste maximale räumliche Kollisionswahrscheinlichkeit. Dies liegt jedoch nicht daran, dass die Messdatenverzögerung die seitliche Vorbeifahrt richtig erkannt hat, sondern aufgrund der großen Latenzen und Unsicherheiten wurde die Kollisionsgefahr überhaupt nicht erkannt. Das wird anhand der oben beschriebenen Ergebnisse bei einer frontalen Kollision deutlich.

Die kleineren Schätzfehlerkovarianzen machen die OOSM-Algorithmen zu dem sensitiveren Pre-Crash-System. Die Messdatenverzögerung hat im Vergleich dazu bei gleicher Auslöseschwelle ein geringeres Falschalarmrisiko, aber auch eine kleinere Erkennungsrate. Sie ist insgesamt ein sehr träges System und daher insbesondere für dynamische Fahrmanöver und Pre-Crash-Applikationen schlecht geeignet. Wie bereits erwähnt, müsste bei der Messdatenverzögerung eine Auslöseschwelle von 76 % verwendet werden. Die Auslösung eines Pre-Crash-Systems bei einer Kollisionswahrscheinlichkeit von nur 76 % ist in der Praxis jedoch undenkbar. Aus diesem Grund ist klar, dass eine Pre-Crash-Funktion basierend auf Messdatenverzögerung in der vorliegenden Konstellation nicht realisierbar wäre.

### 7.3.3 Experimente zur Fehleranalyse mittels Laserscanner

Zur Auswertung der Positions- und Geschwindigkeitsgenauigkeit werden die Objektpositionen von drei Fahrmanövern mit einem Laserscanner vermessen. Die Geschwindigkeit des Sensorfahrzeuges liegt bei 60 km/h. Der Laserscanner dient als Referenzsensor und liefert im 40 ms-Takt ein Distanzprofil der Umgebung. In jeder dieser Aufnahmen wurde das zu verfolgende Objekt manuell markiert und vereinfacht der Mittelwert der zugehörigen Segementpunkte als wahre Position des Objektes gewählt. Die Betrachtung eines Punktziels ist in dieser Anwendung ausreichend, da das verwendete Kollisionsobjekt sehr schmal ist, wie in Abbildung 2.3c zu sehen war.

Da die Laserdaten und Radarsensoren zu unterschiedlichen Zeitpunkten gemessen wurden, wird eine Trajektorie mittels einer Spline-Interpolation der Laserdaten berechnet. Diese Trajektorie kann dann als Referenztrajektorie verwendet werden, die unabhängig von den Zeitpunkten der Aufnahme ist. Somit ist eine zeitliche Synchronisierung von Laserscanner und Radaren überflüssig. Zusätzlich werden die Odometriedaten zur Bestimmung der Referenzgeschwindigkeiten benutzt. Die anschließende Berechnung der Positions- und Geschwindigkeitsfehler erfolgt wie in Abschnitt 7.1 beschrieben. Die Kovarianzmatrizen wurden dabei wie in den vorausgegangenen Abschnitten gewählt.

Abbildungen 7.9a und 7.9b zeigen den Positions- bzw. Geschwindigkeitsfehler der letzten Sekunde vor einer Frontalkollision. Das Fahrzeug fährt dabei mit konstanter Geschwindigkeit, und es wurde ein Modell konstanter Geschwindigkeit verwendet. Die Messdatenverzögerung liefert ähnlich kleine Fehler wie die OOSM-Algorithmen. Dies ist darauf zurückzuführen, dass das Filter eingeschwungen ist und das Filtermodell die Fahrzeugdynamik daher mit einem sehr kleinen Modellfehler abbildet. Der leichte Anstieg des Geschwindigkeitsfehlers kurz vor der Kollision ist auf Ungenauigkeiten der Interpolation zurückzuführen.

Abbildungen 7.9c und 7.9d zeigen den Positions- bzw. Geschwindigkeitsfehler bei einer Vollbremsung kurz vor dem Kollisionsobjekt. Dabei wird wieder ein Modell konstanter Geschwindigkeit verwendet und die Beschleunigungen werden wie bisher im Prozessrauschen modelliert. Dies garantiert die Konsistenz des Filters. Ungefähr 500 ms vor der Kollision erhält die Fusionseinheit die erste Messung der Nahbereichsradare. Diese Messung kann bei den OOSM-Algorithmen direkt in die Zustandsschätzung integriert werden und die aktuelle Schätzung deutlich verbessern. Hierdurch ist eine plötzliche Verringerung des Positions- und Geschwindigkeitsfehlers sichtbar. Bei der Messdatenverzögerung hingegen ist im Gegenteil ein weiterer Anstieg des Geschwindigkeitsfehlers zu sehen sowie ein deutlich größerer Positionsfehler als bei den OOSM-Algorithmen. Dies liegt an der verzögerten Integration der Sensordaten und an der hohen Dynamik des Fahrmanövers.

Abbildungen 7.9e und 7.9f zeigen schließlich den Positions- bzw. Geschwindigkeitsfehler mit einem Filtermodell konstanter Beschleunigung. Das zur Dynamik passende Filtermodell mit kleinerem Modellfehler verringert den absoluten Positions- und Geschwindigkeitsfehler. Die Verbesserung der Schätzung nach Eintreffen der Nahbereichsinformationen ist somit kleiner, aber immer noch deutlich sichtbar. Insbesondere bei der Betrachtung der Geschwindigkeitsfehler ergibt sich eine Performanzsteigerung durch OOSM-Algorithmen im Vergleich zur Messdatenverzögerung.

Diese Ergebnisse der RMSE-Analyse wurden in [151] veröffentlicht. Fehler in der Positionsbzw. Geschwindigkeitsschätzung haben einen direkten nachteiligen Einfluss auf die Schätzung der Kollisionszeit und ergeben somit einen größeren TTC-Fehler.

## 7.3.4 Experimente zur TTC-Analyse mit Kontaktsensorik

Zur Analyse des Fehlers der geschätzten Kollisionszeit wurde das Versuchsfahrzeug mit einer Kontaktsensorik und einer dazugehörigen Auswerteeinheit ausgerüstet. Der Messtechnikaufbau des Kontaktsensors wurde in Kapitel 2.4.2 vorgestellt und die Berechnung des TTC-Fehlers wurde in Abschnitt 7.1 beschrieben. Es wurde zu jedem Messzyklus die aktuelle Geschwindigkeit des Fahrzeuges und die geschätzte Zeit bis zur Kollision gespeichert. Beim Aufprall wurde ein Zeitstempel vergeben und rückwirkend zu jedem vergangenen Messzyklus die wahre verbleibende Zeit bis zur Kollision berechnet. Die Differenz aus geschätzter und berechneter Zeit (TTC-Fehler) wurde für drei exemplarische Versuche ausgewertet.

Abbildung 7.10 zeigt eine frontale Kollision, bei der sich das Objekt mit einer konstanten Geschwindigkeit bewegt. Außerdem wird eine Objektverfolgung mit einem Modell konstanter Geschwindigkeit angenommen. Die senkrechte Linie stellt den Zeitpunkt der detektierten Kollision mit dem Kontaktsensor dar. Je zeitlich näher der Systemzustand am Kollisionszeitpunkt ist, desto kleiner ist der Fehler und desto genauer kann der Unfallzeitpunkt geschätzt werden. Dies gilt für alle vier Algorithmen, denn je näher das



**Abbildung 7.9:** <u>Reale Sensordaten</u>: Positionsfehler (links) und Geschwindigkeitsfehler (rechts) bei einer frontalen Kollision mit (a),(b) konstanter Geschwindigkeit und einem Modell konstanter Geschwindigkeit, mit (c),(d) einer Vollbremsung und einem Modell konstanter Geschwindigkeit, mit (e),(f) einer Vollbremsung und einem Modell konstanter Beschleunigung.

Objekt am Fahrzeug ist, desto besser kann es mit dem polaren Messprinzip aufgelöst werden. Innerhalb der letzten 100 ms vor der Kollision ist der Fehler der geschätzten Zeit kleiner als 10 ms. Das hier angenommene Modell passt exakt zur Realität und das Filter befindet sich in einem eingeschwungenen Zustand. Daher haben die OOSM-Algorithmen mit ihrer direkten Integration der Messungen keinen Vorteil gegenüber der Messdatenverzögerung. In diesem Fall wirkt eine Messdatenverzögerung wie ein Tiefpassfilter und kann die Zukunft auf Modellbasis sehr gut prädizieren.

Abbildung 7.11 zeigt die frontale Kollision unter Ausführung einer Vollbremsung. Zur Objektverfolgung wird wie beim vorherigen Szenario ein Modell konstanter Geschwindigkeit benutzt. Das Filter ist auch in diesem Fall konsistent, da die sehr hohen Beschleunigungen im Prozessrauschen modelliert werden. Das Filter befindet sich jetzt aber in einem nicht eingeschwungenen Zustand. Deshalb steigt der Fehler zwischen 800 und 600 ms leicht an. Jedoch sind alle vier Algorithmen bis 600 ms vor der Kollision bezüglich ihres Fehlers sehr ähnlich. Ab diesem Zeitpunkt erreicht die erste Messung der Nahbereichsradare die Fusionseinheit und kann bei der Reprozessierung, der Retrodiktion und dem FPFD-Algorithmus direkt integriert werden. Diese genauen Messungen in radialer Entfernung ermöglichen es den OOSM-Algorithmen, der Prozessdynamik schneller zu folgen. Die Zustandsschätzung kann somit die Dynamik der Bremsung besser abbilden. Bei einer Auslösezeit zwischen 100 und 200 ms vor der Kollision hat die Messdatenverzögerung bei diesem Beispiel einen doppelt so großen Fehler in der Schätzung der Aufprallzeit.

Abbildung 7.12 zeigt den TTC-Fehler für das gleiche Bremsmanöver modelliert mit konstanter Beschleunigung. Bei diesem Filter geht der Fehler nach Eintreffen der Nahbereichsmessungen bei den OOS-Messungen gegen Null. In diesem Fall wird ein kleineres Prozessrauschen gewählt, da nur die Änderungen in der Beschleunigung modelliert werden müssen. Durch die angepasste Filtermodellierung haben alle vier Algorithmen einen geringeren Fehler als beim Modell kontanter Geschwindigkeit. Der relative Unterschied zwischen der Messdatenverzögerung und den OOSM-Algorithmen bleibt jedoch bestehen.

Die Nahbereichsradare sind aufgrund der höheren radialen Genauigkeit in Kombination mit der geringeren Latenz bei einer frontalen Kollision von entscheidender Bedeutung. Änderungen in der Geschwindigkeit können schneller in die Zustandsschätzung einfließen. Die plötzliche Verringerung des TTC-Fehlers der OOSM-Algorithmen ist somit nur auf das Eintreffen der ersten SRR-Messungen zurückzuführen und hat nichts mit dem kontinuierlich durchgeführten Bremsvorgang zu tun. Dies begründet den großen Vorteil der OOSM-Algorithmen.

Die schlechtere TTC-Schätzung der Messdatenverzögerung müsste sich im Laufe der Zeit wieder an die TTC-Schätzung der anderen Verfahren anpassen. Würden nach dem Anprall die verzögerten Daten abgewartet, so könnte eine vergleichbar gute Schätzung erreicht werden, sobald alle Messungen vorliegen. Dies wäre natürlich für eine korrekte Kollisionsklassifikation zu spät.

Bei zukünftigen Sicherheitssystemen wird die genaue Bestimmung der Kollisionszeit von immer größerer Bedeutung. Pre-Crash-Systeme der nächsten Generation benötigen eine exakte Auslösezeit um neue Schutzsysteme im Fahrzeug nicht zu früh, aber auch nicht zu spät zu aktivieren. Die Ergebnisse der TTC-Analyse wurden in [149] veröffentlicht.



Abbildung 7.10: <u>Reale Sensordaten</u>: TTC-Fehler bei einer frontalen Kollision mit konstanter Geschwindigkeit und einem Modell konstanter Geschwindigkeit.



**Abbildung 7.11:** <u>Reale Sensordaten</u>: TTC-Fehler bei einer frontalen Kollision mit Vollbremsung und einem Modell konstanter Geschwindigkeit.



Abbildung 7.12: <u>Reale Sensordaten</u>: TTC-Fehler bei einer frontalen Kollision mit Vollbremsung und einem Modell konstanter Beschleunigung.

### 7.3.5 Pre-Crash-Testkatalog

Im vorherigen Abschnitt wurden verschiedene Bewertungskriterien exemplarisch für ein Fahrmanöver angewendet und die OOSM-Algorithmen mit der Messdatenverzögerung verglichen. In diesem Teil wurde ein Fahrmanöverkatalog mit insgesamt 150 Fahrsituationen ausgewertet. Hierfür wurden 80 bzw. 70 Fahrmanöver gefahren, bei denen das System auslösen bzw. nicht auslösen soll. Es wurde wieder die Projektion der Schätzfehlerkovarianz aus Kapitel 6 zur Ermittlung einer Kollisionswahrscheinlichkeit herangezogen. Für beide Fälle wurde die gleiche Auslöseschwelle von  $p_{\text{Kollision}}^{(\psi_k)} > 90\%$  und die gleiche Auslösezeit von  $\tau_k(\mathbf{x}_k) < 200 \text{ ms gewählt}$ . Eine Auslösung wurde nur unter Erfüllung beider Voraussetzungen durchgeführt. Zur Vereinfachung wurde auf eine zeitliche Projektion der Schätzfehlerkovarianz verzichtet und nur der zeitliche Mittelwert  $\tau_k$  projiziert. Für die räumliche Projektion des Mittelwertes und der Schätzfehlerkovarianz wurde die Sigma-Punkt-Transformation gewählt. Die Parametrierung der Filter wurde dabei wie in den bisher beschriebenen Tests gewählt.

#### Evaluierung der Erkennungsrate

Im ersten Teil des Fahrmanöverkatalogs wurden Kollisionssituationen untersucht. Hierzu wurden insgesamt 80 Fahrmanöver bestehend aus sechs verschiedenen Kollisionssituationen durchgeführt. Abbildung 7.13 zeigt einen Überblick über die Kollisionsszenarien des Fahrmanöverkatalogs, der für die Evaluierung heutiger Pre-Crash-Systeme ausgelegt ist. Das Ergebnis der Detektionsrate über alle Kollisionen ist in Tabelle 7.5 zusammengefasst. Folgende Tests sind darin enthalten:



Abbildung 7.13: Pre-Crash-Fahrmanöverkatalog zur Evaluierung der Erkennungsrate mit folgenden Kollisionssituationen: (a) Zentrische Kollision, (b) Bremsmanöver (c) Kollision mit Versatz, (d) Kollision mit Querverkehr, (e) Kollision nach Spurwechsel, (f) Kollision bei Kurvenfahrt.

**Die zentrische Kollision** stellt die einfachste zu klassifizierende Kollision dar. Dabei fährt das Fahrzeug mittig auf ein stehendes Objekt. Die Geschwindigkeiten variieren zwischen 20, 40 und 60 km/h. Insgesamt wurden 32 Kollisionen dieser Art durchgeführt und es wurden keine signifikanten Unterschiede festgestellt. Bei einer Messdatenverzögerung werden zwar vier von 32 Kollisionen nicht erkannt, was an der verzögerten Integration der Messungen und dadurch größeren Unsicherheit der Klassifikation liegt. Die Performanz der Messdatenverzögerung unterscheidet sich insgesamt jedoch nicht stark von der Reprozessierung, der Retrodiktion und dem FPFD-Algorithums.

Tabelle 7.3 zeigt die durchschnittliche Auslösezeit  $\overline{\tau_k}$  und den dazugehörigen TTC-Fehler. Obwohl die Messdatenverzögerung fast genauso viele Kollisionen richtig klassifiziert, ist die Auslösezeit sehr viel kleiner. Die Messdatenverzögerung löst zwar bei vielen Kollisionen richtigerweise aus, aufgrund der größeren Unsicherheiten jedoch zeitlich später als die OOSM-Algorithmen. Da mechanische Schutzsysteme wie ein reversibler Gurtstraffer eine zeitliche Reaktionszeit zur Entfaltung ihrer vollen Wirkkraft haben, kann es wenige Millisekunden vor der tatsächlichen Kollision zu spät für eine Aktivierung sein. In diesen Versuchen wird auf eine untere minimale Auslöseschwelle verzichtet. Außerdem kann es bei einer Messdatenverzögerung durch die größeren Integrationsschritte zu größeren Verzögerungen bei der Innovation kommen. Im schlimmsten Fall, wenn die letzte Integration 150 ms vor der Kollision stattfindet, kann die Messdatenverzögerung erst nach einem weiteren Zyklus von 66 ms wieder auslösen.

Parameter	Verzögerung	Reprozessierung	Retrodiktion	FPFD
$\overline{\tau_k} \text{ [ms]}$ TTC-Fehler [ms]	$\begin{array}{c} 60\\ 25 \end{array}$	$\frac{138}{31}$	$\begin{array}{c} 139\\ 30 \end{array}$	138 30

**Tabelle 7.3**: <u>*Reale Sensordaten*</u>: Durchschnittliche Auslösezeit und TTC-Fehler für zentrische Kollisionen.

**Beim Bremsmanöver** wurde das Fahrzeug bei einer Geschwindigkeit von 40 km/h einer Vollbremsung unterzogen, so dass es gerade noch zu einer Kollision kommt. Aufgrund eines konstanten Geschwindigkeitsmodells werden in diesem Fall die Beschleunigungen über das Prozessrauschen modelliert. Bei diesem Szenario liefern alle vier Algorithmen ähnliche Ergebnisse. Wie später im Abschnitt 7.3.5 gezeigt wird, stellt ein Bremsmanöver, bei dem es zu keiner Kollision kommt, eine deutlich schwierigere Klassifikationsaufgabe dar.

Bei der Kollision mit Versatz fanden insgesamt 28 Fahrversuche statt. Hier werden deutliche Unterschiede zwischen der Messdatenverzögerung und den OOSM-Algorithmen sichtbar. Nur 15 von 28 Kollisionsmanövern werden richtig als Kollisionen klassifiziert. Daraus resultiert eine Erkennungsrate von 53,6%, die unter der Gesamterkennungsrate von 63,75% liegt.

Tabelle 7.4 zeigt die durchschnittliche Auslösezeit  $\overline{\tau_k}$  und den dazugehörigen TTC-Fehler. Im Vergleich zur zentrischen Kollision erkennen die OOSM-Algorithmen die Kollision erst 120 ms vorher und haben einen größeren TTC-Fehler. Der Grund hierfür liegt in der kleineren projizierten Schätzfehlerkovarianz. Das Resultat ist bei einer Kollision mit Versatz eine deutlich kleinere Kollisionswahrscheinlichkeit. Daher wird die Auslösewahrscheinlichkeit von 90 % zeitlich später und somit räumlich näher am Fahrzeug erreicht.

Parameter	Verzögerung	Reprozessierung	Retrodiktion	FPFD
$\overline{\tau_k} \; [ms]$	30	120	121	119
TTC-Fehler [ms]	41	47	48	47

**Tabelle 7.4:** <u>Reale Sensordaten</u>: Durchschnittliche Auslösezeit und TTC-Fehler für<br/>Kollisionen mit Versatz.

**Querverkehr** stellt die schwierigste Fahrsituation dieses Testkataloges dar. Dabei wird eine Rolle verdeckt hinter einem zweiten Fahrzeug in die Fahrbahn des Sensorfahrzeuges geworfen. Die Geschwindigkeit des Sensorfahrzeuges beträgt 30 km/h und ist einem innerstädtischen Bereich nachempfunden. Aufgrund der kurzen Reaktionszeiten ist das Filter nicht eingeschwungen und muss anhand weniger Messungen eine Entscheidung treffen. Außerdem gestaltet sich die Verfolgung einer Querbewegung für Radarsensoren schwieriger aufgrund der schlechteren lateralen Auflösung und aufgrund der geringen Geschwindigkeitskomponenten durch die Doppler-Messung.

Diese Fahrmanöver zeigen den Unterschied zwischen der Messdatenverzögerung und den OOSM-Algorithmen am deutlichsten. Mit einer Messdatenverzögerung kann keine der fünf Fahrszenen als Kollision erkannt werden. Wie die Experimente zur Schätzfehlerkovarianz in Abschnitt 7.3.1 gezeigt haben, ist die Unsicherheit bei der Messdatenverzögerung sehr viel größer als bei den OOSM-Algorithmen. Dies hat zur Folge, dass im nicht eingeschwungenen Zustand nach Projektion der Unsicherheiten die Auslöseschwelle bei der Messdatenverzögerung nicht überschritten wird und somit keine korrekte Klassifikation stattfindet.

**Der Spurwechsel** stellt eine Situation beim Überholvorgang mit plötzlich auftauchendem Hindernis dar. Der Geschwindigkeitsbereich dieser Versuche reicht von 20 bis 80 km/h. Aufgrund des Sichtbereiches der Radarsensoren ist die Beobachtungsdauer groß genug, so dass dieses Fahrmanöver einem Pre-Crash-System keine Probleme bereitet. Alle vier Algorithmen haben ähnliche Erkennungsleistungen.

**Die Kurvenfahrt** wurde mit einem fest definierten Lenkwinkel durchgeführt. Die Situation ist einem Kreisverkehr nachempfunden. Dabei wird das Objekt zuerst im SRR-Sensor, dann im Nahbereich des MMR-Sensors und schließlich im Fernbereich des MMR-Sensors gesehen. Die Messdatenverzögerung erkennt zwei von fünf Kollisionen, wohingegen die OOSM-Algorithmen alle fünf Kollisionen richtig erkennen. Aufgrund des Öffnungswinkels der Sensoren liefert der MMR-Sensor erst sehr spät erste Daten und deshalb ist dieses Fahrmanöver auch schwieriger zu klassifizieren als der Spurwechsel.

Die unterste Zeile der Tabelle 7.5 listet die Gesamterkennungsraten auf. Die Anzahl der Fahrmanöver pro Szenario wird anteilig in Anlehnung an die Häufigkeit der Szene im realen Unfallgeschehen gewählt [59, 137]. Die Reprozessierung und die OOSM-Algorithmen führen zu einer Erkennungsrate von über 90 %. Obwohl das Mehr-Schritt-OOSM-Problem eine Approximation darstellt, weicht die Erkennungsrate der Reprozessierung nur wenige Prozent von der Erkennungsrate der OOSM-Algorithmen ab. Außerdem sind kleine Abweichungen auf die unterschiedliche Algorithmik der Schätzfehlerkovarianz und die daraus resultierenden numerischen Unterschiede zurückzuführen. Bei Erhöhung der Datenmenge ist jedoch zu erwarten, dass alle OOSM-Algorithmen gleiche Klassifikationsergebnisse liefern. Die Messdatenverzögerung erzielt eine Erkennungsrate von 63 % und besitzt somit eine über 28 % schlechtere Detektionsleistung als die OOSM-Algorithmen.

Fahrmanöver	Anzahl	Verzögerung	Reprozess.	Retrodiktion	FPFD
Zentrisch	32	28	31	30	29
Bremsen	5	2	3	2	2
Versatz	28	15	28	28	28
Querverkehr	5	0	4	5	5
Spurwechsel	5	4	5	4	4
Kurvenfahrt	5	2	5	5	5
$\mathbf{Insgesamt}$	80	$51~(63,\!75\%)$	76 (95,00 $\%$ )	$74~(92,\!25\%)$	$73~(91,\!25\%)$

**Tabelle 7.5:** <u>*Reale Sensordaten*</u>: Gesamtergebnisse von 80 Kollisionen, bei denen Pre-Crash aktiviert werden soll. Die erkannten Kollisionen und die durchschnittliche Erkennungsrate sind angegeben.

#### Evaluierung der Falschalarmrate

Im zweiten Teil des Fahrmanöverkatalogs werden Situationen untersucht, bei denen es zu keiner Kollision kommt. Diese Fahrmanöver sind jedoch von den Dauertests zu unterscheiden. Bei den Fahrversuchen zur Vermeidung von Falschauslösungen handelt es sich um kritische Fahrsituationen, bei denen es nur knapp nicht zu einem Unfall kommt. Hierzu werden insgesamt 70 Fahrmanöver bestehend aus vier verschiedenen Fahrmanövern definiert. Der Arbeitspunkt, bestehend aus Auslöseschwelle und Auslösezeit bleibt gegenüber den Kollisionssituationen unverändert. In Abbildung 7.14 ist ein Überblick über den in dieser Arbeit benutzten Fahrmanöverkatalog der Szenarien, bei denen es nur sehr knapp nicht zu einer Kollision kommt, dargestellt. Tabelle 7.6 zeigt das Ergebnis der Falschalarme ermittelt durch folgende Tests:

**Vorbeifahren** ist das erste Szenario des Pre-Crash-Katalogs, bei dem das System nicht auslösen soll. Dabei handelt es sich um sehr knappe Vorbeifahrten mit einem Abstand



Abbildung 7.14: Pre-Crash-Fahrmanöverkatalog zur Evaluierung der Falschalarmrate: (a) Knappe Vorbeifahrt, (b) Bremsmanöver, (c) Überholmanöver, (d) Ausweichmanöver.

von unter 20 cm zum Außenspiegel. Das Szenario wurde mit den vier verschiedenen Geschwindigkeiten 10, 30, 50 und 70 km/h durchgeführt. Insgesamt wurden 32 Fahrten dieser Art durchgeführt. Dabei liefert die Messdatenverzögerung im Gegensatz zu den OOSM-Algorithmen keinen Falschalarm. Der Grund hierfür ist die Projektion der kleineren Unsicherheiten, die die OOSM-Algorithmen sensitiver und damit anfälliger für Falschalarme macht.

**Beim Bremsen** wurde wenige Meter vor dem Objekt bei einer Geschwindigkeit von 50 km/h eine Vollbremsung getätigt, so dass es nicht zu einer Kollision kommt. Dieses Szenario gehört mit zu den schwierigsten Entscheidungen für das Pre-Crash-System. Alle vier Algorithmen liefern Falschalarme.

**Das Überholmanöver** ist in Realität ein häufig vorkommendes Szenario. Es stellte aufgrund der langen Verfolgungszeiten für alle vier Algorithmen kein Problem dar, d.h. es kam zu keinem Falschalarm.

**Beim Ausweichen** wurde kurz vor dem Kollisionsobjekt mit maximalem Lenkeinschlag hochdynamisch am Objekt vorbeigefahren. Mit Geschwindigkeiten von 10 km/h bis zu 70 km/h kam es vereinzelt zu falschen Auslösungen. Die Tests ergaben, dass die meisten Falschalarme bei kleineren Geschwindigkeiten zustande kamen. Bei diesen Versuchen gelang es dem Fahrer später auszuweichen und die so berechnete Auslösewahrscheinlichkeit reichten für eine Aktivierung aus.

Die vorherigen vier Fahrmanöver des Pre-Crash-Katalogs zur Vermeidung von Falschauslösungen wurden auf einer abgesperrten Teststrecke gefahren. Zusätzlich zu diesen sehr kritischen Fahrmanövern wurde die Alltagstauglichkeit des Systems mit einem Dauertest überprüft. Dabei wurden Messfahrten auf Autobahnen, Landstraßen und im innerstädtischem Verkehr durchgeführt. Das System wurde dabei nicht an seine Grenzen gebracht, sondern in normalen Verkehrssituationen hinsichtlich der Falschalarmrate getestet. Bei über 5 000 Testkilometern kam es zu keiner Falschauslösung. Dies zeigt die Einsetzbarkeit des in dieser Arbeit entwickelten Pre-Crash-Systems.

Die unterste Zeile aus Tabelle 7.6 listet das Gesamtergebnis der Falschalarmraten auf. Durch die größeren Prädiktionsschritte mit weniger integrierten Messungen weist die Messdatenverzögerung eine größere Schätzfehlerkovarianz als die OOSM-Algorithmen auf. Nach Projektion dieser Unsicherheiten hat eine Messdatenverzögerung eine kleinere zeitliche und räumliche Kollisionswahrscheinlichkeit. Die Messdatenverzögerung besitzt somit bei gleicher Dimensionierung der Auslöseschwelle eine sehr viel schlechtere Erkennungsrate, aber auch eine etwas niedrigere Falschalarmrate. Um einen bewertenden Vergleich durchführen zu können, wird im folgenden Abschnitt die Falschalarmrate bei konstanter Erkennungsrate ausgewertet.

Fahrmanöver	Anzahl	Verzögerung	Reprozess.	Retrodiktion	FPFD
Vorbeifahren	32	0	3	2	3
Bremsen	5	2	4	3	3
Überholen	5	0	0	0	0
Ausweichen	28	1	6	7	5
Insgesamt	<b>70</b>	$3~(4,\!29\%)$	$13~(18,\!57\%)$	$12~(17,\!14\%)$	$11~(15,\!71\%)$

**Tabelle 7.6:** <u>Reale Sensordaten</u>: Gesamtergebnisse von 70 kritischen Fahrmanövern, bei denen Pre-Crash nicht auslösen soll. Die Falschalarme und die durchschnittliche Falschalarmrate sind angegeben.

### 7.3.6 Gesamtperformanz

Die bisherigen Ergebnisse mit einer erzielten Erkennungsrate aus Tabelle 7.5 und einer resultierenden Falschalarmrate aus Tabelle 7.6 sind mit einer konstanten räumlichen Auslöseschwelle von 90 % Kollisionswahrscheinlichkeit und einer festen zeitlichen Auslöseschwelle von 200 ms erzielt worden. Das Ergebnis war, dass die Messdatenverzögerung zwar eine sehr viel kleinere Erkennungsrate, jedoch auch eine kleinere Falschalarmrate aufweist. Dies macht einen direkten bewertenden Vergleich der beiden Algorithmen unmöglich.

Um einen Vergleich zu ermöglichen, wird im folgenden Abschnitt eine modifizierte ROC-Analyse durchgeführt. Hierzu wird die Erkennungsrate auf 90 % normiert und die Falschalarmrate bezüglich der Auslösezeit evaluiert. In einer ersten Analyse wird untersucht, wie hoch die Auslöseschwelle bei den einzelnen Algorithmen gesetzt werden muss, wenn eine Erkennungsrate von 90 % gefordert wird. Falls eine niedrige Auslöseschwelle nötig ist, um 90 % der Kollisionen zu erkennen, so steigt auch die Falschalarmrate. Die benötigte Auslöseschwelle hängt neben der geforderten Erkennungsrate auch von der Zeit bis zur Kollision ab. Es wird bei einer größeren TTC im Allgemeinen auch eine niedrigere Schwelle zu erwarten sein, weil hier die Unsicherheit über die Kollision noch größer ist. Daher wird im Folgenden die benötigte Auslöseschwelle in Abhängigkeit der TTC bei geforderter fester Erkennungsrate von  $90\,\%$  untersucht.

Abbildungen 7.15a und 7.15b zeigen die Auslöseschwellen, die eine Erkennungsrate von 90% bzw. 98% erzielen. Um diese Erkennungsraten zu erreichen, muss das Pre-Crash-System insbesondere bei einer Messdatenverzögerung mit deutlich kleineren Kollisionswahrscheinlichkeiten, also früher auslösen. Je früher jedoch ausgelöst wird, desto größer sind die Prädiktionsschritte und desto größer die Unsicherheiten. Das heißt, je länger die Prädiktionen, desto ungenauer sind die Modellaussagen über die Zukunft und desto größer wird die Falschalarmrate. So kann das Pre-Crash-System bei der Reprozessierung, bei der Retrodiktion sowie bei dem FPFD-Algorithmus 100 ms vor einer Kollision mit einer Auslöseschwelle von ca. 98% Kollisionswahrscheinlichkeit aktiviert werden. Im Gegensatz dazu muss ein Pre-Crash-System mit einer Messdatenverzögerung schon ab einer Auslösewahrscheinlichkeit von 62% aktiviert werden, um die gleiche Erkennungsrate zu erzielen.



Abbildung 7.15: <u>Reale Sensordaten</u>: Benötigte Auslöseschwelle zum Erzielen einer Erkennungsrate von (a) 90% und (b) 98%. Die Messdatenverzögerung muss auf Kosten einer höheren Falschalarmrate (siehe Abbildung 7.16) mit deutlich kleineren Schwellwerten auslösen, um die erwünschte Erkennungsrate zu erzielen.

Es fällt auf, dass der erwartete Effekt einer ansteigenden Schwelle bis zum Kollisionszeitpunkt eintrifft, mit Ausnahme einer kleinen Absenkung der Schwelle bei der Messdatenverzögerung kurz vor der Kollision. Dies liegt daran, dass die Wahrscheinlichkeit steigt, dass diesem Algorithmus aufgrund der größeren Innovationsschrittweiten von 66 ms keine aktuellen Messdaten vorliegen. Das Pre-Crash-System mit einer Messdatenverzögerung kann daher unmittelbar vor der Kollision die Situation nicht mehr auflösen. Dies käme somit einem Ausschalten des Systems gleich. Die Erkennungsrate kann nur dadurch erzielt werden, dass die Auslöseschwelle kurz vor dem Zusammenprall wieder sinkt. Eine zweite Untersuchung betrifft die Falschalarmrate bei fester geforderter Erkennungsrate. Bei einem realen System spielt die Auslösezeit eine entscheidende Rolle. Daher ist die Betrachtung der Falschalarmrate über der Zeit bei konstanter Erkennungsrate einer klassischen ROC-Kurve vorzuziehen.

Abbildung 7.16 zeigt die Falschalarmrate bei einer geforderten Erkennungsrate von 90 %. Durch die Wahl des Datensatzes mit überwiegend sehr schwierigen Situationen kommt es zu einer relativ großen absoluten Anzahl an Falschalarmen. Der Schwerpunkt der Analyse soll jedoch auf einem relativen Vergleich zwischen den OOSM-Algorithmen und der Messdatenverzögerung liegen. Somit ist die hohe Falschalarmrate auf die hohe Erkennungsrate sehr schwieriger Fahrmanöver zurückzuführen und ist nicht mit heutigen Pre-Crash-Systemen, bei denen eine Falschalarmrate von annähernd 0 % verlangt wird, vergleichbar. Bei einer Pre-Crash-Auslösezeit zwischen 100 und 300 ms weist die Messdatenverzögerung eine bis zu 20 % höhere Falschalarmrate auf und stellt das deutlich schlechtere Pre-Crash-System dar. Ein quantitativer Vergleich der Falschalarmraten für drei verschiedene Auslösezeiten ist in Tabelle 7.7 zusammengefasst.

Wie in Abschnitt 7.3.5 beschrieben, kommt es bei Dauertests in typischen alltäglichen Verkehrssituationen zu keiner Falschauslösung. Da das Ziel die Ansteuerung reversibler



**Abbildung 7.16:** <u>Reale Sensordaten</u>: Falschalarmrate bei einer konstanten Erkennungsrate von 90 %. Im Pre-Crash Auslösebereich zwischen 100 ms und 300 ms vor einer Kollision weist die Messdatenverzögerung eine bis zu 20 % höhere Falschalarmrate auf.

Algorithmus	Verzögerung	Reprozessierung	Retrodiktion	FPFD
Falschalarmrate ( $t_k = 100 \text{ ms}$ ) Falschalarmrate ( $t_k = 150 \text{ ms}$ ) Falschalarmrate ( $t_k = 200 \text{ ms}$ )	$21,2\%\ 33,3\%\ 48,5\%$	$15,2\%\ 21,2\%\ 24,2\%$	$15,2\ \%\ 21,2\ \%\ 27,3\ \%$	15,2% 18,0% 24,2%

**Tabelle 7.7:** <u>Reale Sensordaten</u>: Falschalarmrate bei konstanter Erkennungsrate von 90% für drei mögliche Auslösezeiten (vergleiche Abbildung 7.16).

Schutzmechanismen ist, wird eine kleine Falschalarmrate toleriert. Einige der gefahrenen Ausweichmanöver sind als so kritisch einzustufen, dass eine Auslösung unter Umständen sogar erwünscht ist. Dies gibt dem Fahrer eine positive Rückmeldung und somit das Vertrauen in funktionierende Sicherheitssysteme.

Würde man jedoch anstelle des reversiblen Gurtstraffers nicht-reversible Schutzsysteme ansteuern, müsste das System so parametriert werden, dass es unter keinen Umständen zu einer Falschauslösung kommt. Um eine Falschalarmrate von 0% zu garantieren, müsste jedoch die Auslöseschwelle so niedrig gewählt werden, dass nur sehr niedrige Erkennungsraten möglich sind.

Äquivalent zum Vergleich der hier untersuchten Falschalarmrate über der Zeit bei konstanter Erkennungsrate wäre ein Vergleich der Erkennungsrate über der Zeit bei konstanter Falschalarmrate. Bei der Dimensionierung eines Systems mit nicht-reversiblen Sicherheitssystemen könnte man so eine Falschalarmrate von 0% verlangen und die resultierende Erkennungsrate auswerten.

Die Alltagstauglichkeit wurde mit Dauertests erfolgreich unter Beweis gestellt. Weiterführende Evaluierungen sollten eine Falschalarmrate pro Zeit oder pro gefahrenen Kilometern angeben. Dabei könnten prototypisch mehrere Fahrzeuge mit dem in dieser Arbeit entwickelten OOSM-Pre-Crash-System ausgestattet werden und so die Falschalarme ausgewertet werden. Da bei solchen Tests von keinem Unfall ausgegangen werden kann, konzentrieren sich solche Experimente auf die Minimierung der Falschalarmrate. Die abschließenden Schritte würden die Entwicklung zur Serienreife darstellen.

# 7.4 Kapitelzusammenfassung

In diesem Kapitel wurde eine Auswertung des entwickelten Pre-Crash-Systems sowohl mit Simulationsdaten als auch mit realen Sensordaten präsentiert. Es wurde gezeigt, dass durch die direkte Integration von OOS-Messungen bei zeitkritischen Systemen eine höhere Erkennungsleistung des Pre-Crash-Systems im Vergleich zu heutigen Systemen erzielt werden konnte. Zu Simulationszwecken wurden ein Drei-Schritt-OOSM-Problem und ein Fünf-Schritt-OOSM-Problem evaluiert. Eine Analyse der OOSM-Einflussfaktoren ergab, dass die Überlegenheit der OOSM-Algorithmen im Vergleich zur Messdatenverzögerung umso deutlicher ist, je dynamischer das verwendete Fahrmanöver und je größer die OOSSchrittweite l ist. Die Gesamtergebnisse der Simulation wurden schließlich anhand einer ROC-Analyse präsentiert.

Die Auswertung realer Fahrversuche begann mit Experimenten zur vorgeschlagenen Prädiktion der Schätzfehlerkovarianz, mit Hilfe derer eine Kollisionswahrscheinlichkeit berechnet werden kann. Hierbei konnte gezeigt werden, dass eine Messdatenverzögerung deutlich größere Unsicherheiten im Vergleich zu den OOSM-Algorithmen liefert. Die Ursache hierfür sind größere Verzögerungen bis zur Integration einer Messung, so dass die verwendeten Daten bei der Messdatenverzögerung veraltet sind. Außerdem beinhaltet die Messdatenverzögerung insgesamt weniger integrierte Messungen und längere Prädiktionsschritte, was wiederum zu größeren Unsicherheiten und einem trägen System führt, welches dynamische Fahrmanöver nicht schnell genug abbilden kann. Es konnte gezeigt werden, dass die Unsicherheit der OOSM-Algorithmen bei Eintreffen der ersten Messungen eines zusätzlichen Sensors schlagartig sinkt, während bei der Unsicherheit der Messdatenverzögerung zunächst kein Unterschied feststellbar ist und nach einigen Messzyklen eine langsame, nur sehr geringe Verbesserung.

Diese Unterschiede haben direkte Auswirkungen auf die Auslöseschwelle, mit der ein Pre-Crash-System aktiviert wird. Bei den OOSM-Algorithmen wurde einige hundert Millisekunden vor dem Zusammenprall eine Kollisionswahrscheinlichkeit von nahezu 100 % ermittelt, so dass die Pre-Crash-Aktivierung mit einer sehr hohen Auslöseschwelle und somit sehr geringer Falschalarmwahrscheinlichkeit erfolgen kann. Bei der Messdatenverzögerung hingegen müsste eine Auslöseschwelle von ungefähr 76 % verwendet werden, was zu einer sehr unsicheren Kollisionsklassifikation führt und eine hohe Falschalarmrate in Kauf nimmt. Die Alternative wäre, dass ein auf Messdatenverzögerung basierendes System praktisch nie auslösen kann, da eine höhere Sicherheit in der Klassifikation nicht erreicht werden kann.

Mit Hilfe zusätzlicher Sensoren, nämlich einer Kontaktsensorik und eines Laserscanners, konnte eine TTC-Analyse sowie eine Untersuchung von Positions- und Geschwindigkeitsfehlern durchgeführt werden. Das Ergebnis beider Tests war, dass die Messdatenverzögerung bei zur Fahrdynamik passendem Modell vergleichbar gute Ergebnisse wie die OOSM-Algorithmen erzielte. Sobald jedoch beispielsweise ein dynamisches Fahrmanöver mit einem Modell konstanter Geschwindigkeit geschätzt wurde, erreichten die OOSM-Algorithmen einen weit geringeren Positions- und Geschwindigkeitsfehler, da sie aktuelle Messungen schneller in die Zustandsschätzung integrieren und somit die Dynamik des Systems besser abbilden können.

Den Schwerpunkt der Experimente stellte ein Pre-Crash-Testkatalog mit insgesamt 150 Fahrsituationen dar. Bei der Untersuchung der Kollisionen konnten die OOSM-Algorithmen ungefähr drei Viertel der Kollisionen korrekt klassifizieren, wohingegen dies mittels Messdatenverzögerung nur bei der Hälfte der Situationen gelang. Die Falschalarmrate der OOSM-Algorithmen war im Gegenzug jedoch auch etwas höher als diejenige der Messdatenverzögerung. Um eine abschließende Bewertung der beiden Algorithmen zu geben, wurde daher die Falschalarmrate bei fester Erkennungsrate von 90 % untersucht. Hierbei ergab sich, dass die Auslöseschwelle 200 ms vor dem Zusammenprall bei der Messdatenverzögerung so sehr abgesenkt werden muss, dass eine Falschalarmrate von fast 50 % erreicht wird. Die Falschalarmrate der OOSM-Algorithmen dagegen war nur ungefähr halb so groß.

Insgesamt konnte somit gezeigt werden, dass die OOSM-Algorithmen einen entscheidenden Vorteil im Vergleich zur Messdatenverzögerung darstellen. Die sofortige Integration chronologisch ungeordneter Sensordaten schlägt sich direkt in einer geringeren Unsicherheit der Zustandsschätzung, größeren Sensitivität des Systems gegenüber dynamischen Fahrmanövern und damit höheren Erkennungsrate bei geringerer Falschalarmrate nieder. Es ergab sich, dass die Auslösung des Pre-Crash-Systems im vorliegenden Fall mit einer Messdatenverzögerung praktisch nicht umsetzbar ist, während die OOSM-Algorithmen eine drohende Kollision zuverlässig und sicher vorhersagen konnten.

# Zusammenfassung und Ausblick

Im Rahmen dieser Arbeit wurde ein System zur Integration chronologisch ungeordneter Sensordaten für die Fahrzeugumfelderfassung vorgestellt. Die Verbesserung der Zustandsschätzung im Vergleich zu Standardansätzen konnte am Beispiel eines Pre-Crash-Systems gezeigt werden. Die Algorithmen wurden für die Nutzung mit wahrscheinlichkeitsbasierter Datenassoziation erweitert und erfolgreich angewendet. Des Weiteren wurde eine neuartige Situationsanalyse mittels Projektion der Schätzfehlerkovarianz vorgestellt. Durch die Berechnung einer räumlichen und zeitlichen Kollisionswahrscheinlichkeit konnte ein robusteres System mit reduzierter Anzahl an Heuristiken aufgebaut werden. Die experimentellen Untersuchungen ergaben eine höhere Erkennungsrate bei konstanter Falschalarmrate. Durch die zunehmende Bedeutung von Sensorfusionssystemen, die komplexe Verkehrssituationen präzise erkennen müssen, wird in Zukunft die Behandlung von OOSM-Algorithmen eine immer wichtigere Rolle spielen.

# 8.1 Entwickelte Fusionsalgorithmen und erzielte Ergebnisse

In der vorliegenden Arbeit wurden neue Signalverarbeitungsalgorithmen für ein Pre-Crash-System entwickelt und getestet. Dies schließt die Zustandsschätzung mit chronologisch ungeordneten Sensordaten ebenso ein wie eine neuartige Situationsbewertung. Das Ziel dieser Arbeit bestand in der Entwicklung einer Radar-Fusionsarchitektur mit Situationsbewertung zur Aktivierung eines reversiblen Gurtstraffers im Falle einer unvermeidbaren Kollision. Die Umgebung des Fahrzeuges wurde mit zwei Nahbereichsradaren und einem Mehrmodusradar erfasst.

Die Sensoren sind durch unterschiedliche Sichtbereiche, Genauigkeiten, Latenzen und Zykluszeiten charakterisiert. Aufgrund der Asynchronität der Sensoren entsteht bei der Fusion das sogenannte "Out-of-Sequence Measurement"-Problem, Messdaten erreichen bei einem solchen Sensoraufbau die Fusionseinheit nicht immer in zeitlicher Reihenfolge. Zustandsschätzer wie z.B. das Kalmanfilter erfordern Messdaten jedoch in chronologischer Reihenfolge, da aufgrund des Prozessrauschens keine Prädiktion in die Vergangenheit möglich ist. Ist die Bedingung chronologischer Messungen nicht mehr erfüllt, müssen alternative Algorithmen angewendet werden. Diese Verfahren verzichten auf ein Zwischenspeichern der Messungen und verwenden ein modifiziertes Prozessmodell, so dass alle eintreffenden Messungen direkt integriert werden können.

In dieser Arbeit wurden erstmalig für ein automobiles Sicherheitssystem OOSM-Algorithmen untersucht. Hierfür wurden vier Algorithmen zur Lösung des OOSM-Problems vorgestellt und getestet. In der Praxis wird meistens die Messdatenverzögerung verwendet, die sich jedoch in den durchgeführten Untersuchungen als der ungeeignetste und am wenigsten performante Algorithmus erwies. Als Referenz wurde das Reprozessieren, also Wiederaufbereiten aller Zustände vom Zeitpunkt der OOS-Messung bis zum aktuellen Zeitpunkt, verwendet. Analysen der Komplexität ergaben, dass der Aufwand für die OOSM-Algorithmen um wenige Prozent höher ist als bei der Messdatenverzögerung, aber deutlich unter dem Aufwand der Reprozessierung liegt.

Die aus der Literatur bekannten OOSM-Algorithmen wurden um eine wahrscheinlichkeitsbasierte Datenassoziation erweitert. Somit wurde ein neuartiges Verfahren entwickelt, um auch bei der Mehrobjektverfolgung Messungen außerhalb der chronologischen Reihenfolge direkt integrieren zu können. Es konnte nachgewiesen werden, dass auch bei probabilistischer Datenassoziation die hergeleiteten Algorithmen eine vergleichbar gute Performanz wie die exakte Reprozessierung bei geringeren Kosten zeigen.

Im Kapitel über die Situationsanalyse wurden neue Verfahren zur Berechnung von Kollisionswahrscheinlichkeiten entwickelt. Diese Verfahren erwiesen sich als genauer im Vergleich zu bisherigen Verfahren. Durch eine Projektion der Schätzfehlerkovarianz konnte sowohl eine räumliche als auch zeitliche Kollisionswahrscheinlichkeit berechnet werden, was mit herkömmlichen Methoden nicht möglich ist. Mit Hilfe der Kollisionswahrscheinlichkeit konnte ein drohender Unfall genauer vorhergesagt werden. Damit ist es möglich das Verfahren zu parametrieren und die Auslösung des Pre-Crash-Systems je nach geforderter Sicherheit anzupassen. Mit der Wahl der Auslöseschwelle wird das gewünschte Verhältnis aus Erkennungs- und Falschalarmrate festgelegt. Bei bisherigen Systemen kamen viele Heuristiken zum Einsatz und es war nicht möglich, einen Arbeitspunkt zu wählen. Der hier vorgeschlagene Ansatz ist präziser und zeichnet sich bei konstanter Falschalarmrate durch eine höhere Erkennungsleistung aus.

Im Kapitel über experimentelle Ergebnisse wurden die Zustandsschätzung und die Situationsbewertung im Verbund evaluiert. Die Simulationsergebnisse zeigten eine deutliche Verbesserung des hier vorgestellten Pre-Crash-Systems durch OOSM-Algorithmen im Vergleich zur Messdatenverzögerung. Das gilt insbesondere für dynamische Fahrmanöver und sehr zeitkritische Situationen, da die Messdatenverzögerung aufgrund der verspäteten Integration von Messungen nur veraltete Informationen zur Verfügung hat und längere Prädiktionsschritte durchführen muss. Dies führt zu einer trägen Zustandsschätzung mit großen Unsicherheiten.

Durch den Aufbau eines prototypischen Versuchsfahrzeuges mit umgebungserfassender Sensorik wurden die Simulationsergebnisse durch eine Auswertung realer Sensordaten gestützt. Die direkte Integration ungeordneter Sensordaten konnte die Erkennung einer drohenden Kollision deutlich verbessern. Einige hundert Millisekunden vor der Kollision stieg die Kollisionswahrscheinlichkeit mittels OOSM-Algorithmen auf fast 100 %, wohingegen mit Messdatenverzögerung nur 76 % erreicht werden konnte. Eine Auslösung des Pre-Crash-Systems muss somit bei Messdatenverzögerung auf Basis einer sehr unsicheren Kollisionsklassifikation erfolgen. Dies zeigt, dass die Realisierung eines Pre-Crash-Systems basierend auf Messdatenverzögerung im vorliegenden Fall fast unmöglich wäre, wohingegen sich OOSM-Algorithmen als sehr zuverlässig und performant erwiesen.

Mit Hilfe einer Kontaktsensorik und eines Laserscanners konnten die exakte Kollisionszeit und die exakte Position des Kollisionsobjekts als Referenz bestimmt werden. Damit konnte eine Evaluation der Positions- und Geschwindigkeitsfehler der verschiedenen Algorithmen durchgeführt werden. Die OOSM-Algorithmen erzielten einen weit geringeren Positions- und Geschwindigkeitsfehler. Schließlich wurde mit der Auswertung eines Fahrmanöverkatalogs die Praxistauglichkeit bewiesen. Hierbei ergab sich für die OOSM-Algorithmen eine um ungefähr 20 % geringere Falschalarmrate bei konstanter Erkennungsrate im Vergleich zur Messdatenverzögerung. Insgesamt wurde eine deutliche Überlegenheit der OOSM-Algorithmen gegenüber der Messdatenverzögerung festgestellt.

Mit den hier vorgestellten Ergebnissen wird für zukünftige zeitkritische FAS eine Signalverarbeitung mit OOSM-Algorithmen und eine Situationsbewertung mit Unsicherheitsprojektion für kollisionsberechnende Systeme empfohlen.

# 8.2 Diskussion

Der Schwerpunkt der in dieser Arbeit vorgestellten Signalverarbeitungsalgorithmen liegt auf einer schnellen und direkten Verarbeitung von Sensordaten. Dies wird insbesondere bei zeitkritischen Sicherheitssystemen benötigt und macht erweiterte OOSM-Algorithmen in einem solchen Pre-Crash-System unverzichtbar. Gerade bei sehr dynamischen Fahrmanövern ist die direkte Integration vorhandener Messungen wichtig, um reversible Schutzmechanismen schnell und präzise auslösen zu können.

Jedoch gibt es auch Anwendungen im Bereich der FAS, bei denen sich die OOSM-Algorithmen nicht lohnen oder sogar von Nachteil sein können. Ersteres ist der Fall, wenn zum Beispiel die Latenzen zu gering sind oder die Messunsicherheiten des Sensors, der OOS-Messungen liefert, zu groß sind. In diesem Fall kann unter Umständen eine Messdatenverzögerung für die Anwendung ausreichend sein. Deshalb muss die Wahl der Signalverarbeitungsverfahren in Abhängigkeit der Latenz, Zykluszeit und Messunsicherheiten aller Sensoren getroffen werden. Ein weiteres Kriterium zur Entscheidung für oder gegen OOSM-Algorithmen ist die zu Grunde liegende Anwendung. OOSM-Algorithmen sind besonders dann nötig, wenn diese sehr zeitkritisch ist. Im Fall einer wenig zeitkritischen Anwendung kann Messdatenverzögerung zu völlig ausreichenden Ergebnissen führen.

Zum Nachteil können OOSM-Algorithmen werden, wenn die Glättungseigenschaften einer Messdatenverzögerung erwünscht sind. Diese kann durch die Integration mehrerer Messungen zum gleichen Zeitpunkt wie ein Tiefpassfilter wirken. Im Gegensatz dazu kann eine Integration von OOS-Messungen zu einer korrekten aber unerwünschten sprunghaften Änderung des Zustandsvektors und dessen Schätzfehlerkovarianz führen. Diese Änderungen können sich nachteilig für bestimmte Aktoren erweisen und für einige Funktionen ist außerdem eine Tiefpassfilterung erwünscht. Als Beispiel sei hier die Anzeige von Fahrbahnverläufen für Navigationssysteme genannt. Aus diesem Grund wird eine Kosten-Nutzen-Analyse bezüglich OOSM-Algorithmen für jedes neue FAS und jede neue Sensorkonfiguration empfohlen.

# 8.3 Ausblick

Die in dieser Arbeit für Pre-Crash erfolgreich eingesetzten Algorithmen können in Zukunft für weitere FAS angewendet werden. So würden sich diese Algorithmen gerade im innerstädtischen Verkehr zum Beispiel bei einem Kreuzungsassistenten anbieten. Auch auf algorithmischer Seite wären Erweiterungen der OOSM-Algorithmen denkbar. In den folgenden Abschnitten sollen die theoretischen Weiterentwicklungsmöglichkeiten aufgezeigt werden.

Das Kalmanfilter mit OOSM und wahrscheinlichkeitsbasierter Datenassoziation könnte zusätzlich mit dem Datenassoziationsverfahren JIPDA (*engl.* "Joint Integrated Probabilistic Data Association") kombiniert werden. Bei dem in [101, 102] vorgestellten Verfahren erfolgt zusätzlich noch eine Existenzschätzung der zu verfolgenden Objekte. Die Algorithmen wurden in [83–85] für die Fahrzeugumfelderfassung angewendet. Außerdem wurde der Ansatz in [99] und [100] für eine generische Sensordatenfusion erweitert. Die Wahrscheinlichkeit, mit der das verfolgte Objekt existiert, könnte in die Entscheidung der hier vorgestellten Situationsbewertung mit einfließen. Dazu müsste die räumliche und zeitliche Kollisionswahrscheinlichkeit mit der Existenzwahrscheinlichkeit fusioniert werden.

Für den Einsatz von sicherheitskritischen Fahrerassistenzsystemen in kleineren Baureihen wäre aus Kostengründen eine Kombination der OOSM-Algorithmen mit einer Modellierung der Sensorauflösung von Interesse. Dies würde eine genauere Umgebungserfassung mit preisgünstigeren schmalbandigen Sensoren ermöglichen. Diese Modellierung, *engl.* Joint Probabilistic Data Association for possibly Merged Measurements (JPDAM), wurde erstmals in [34] vorgestellt und für Pre-Crash in [146, 154] angepasst.

Die vorliegende Arbeit berücksichtigt keine echtzeitfähige Implementierung der entwickelten Algorithmen auf einem Steuergerät. Speicher- und laufzeitbedingte Beschränkungen wurden nicht beachtet. Auch wenn bei der experimentellen Evaluierung dieser Arbeit keine Instabilitäten festgestellt wurden, wäre eine theoretische Untersuchung der numerischen Stabilität zu empfehlen. Bei einer Implementierung auf einem Steuergerät könnten die Matrixinvertierungen zu numerischen Problemen führen.

Bei der Herleitung der Zustandsschätzung wird angenommen, dass die Rauschprozesse gaußverteilt, mittelwertfrei, weiß und gegenseitig unkorreliert sind. Bei Verletzung dieser statistischen Annahmen sind für OOSM-Algorithmen keine Verfahren bekannt. Eine Anpassung der Signalverarbeitung für korrelierte Rauschprozesse wäre hierbei von Interesse.

Im Hinblick auf zukünftige Entwicklungen in der Automobilindustrie sind einige Anwendungen zu erwarten, bei denen OOSM-Algorithmen sinnvoll zum Einsatz kommen könnten. Durch gesetzliche Initiativen, wie zum Beispiel die der Europäischen Union [45], wird die Marktdurchdringung von FAS weiter voranschreiten. So müssen ab 2011 alle Neufahrzeuge mit einem elektronischem Stabilisierungsprogramm und ab 2013 alle Nutzfahrzeuge mit einem Notbremssystem sowie Spurhalteassistent ausgestattet sein [44]. Fahrerassistenzsysteme adressieren dadurch neue Zielbaureihen, nämlich einen verstärkten Einsatz im Kleinwagensegment, die überwiegend im innerstädtischen Verkehr zum Einsatz kommen. Im Oberklassensegment sind neue Sicherheitssysteme basierend auf einer Fusion aus Kamera und Radar zu erwarten. Ebenso getrieben durch neue Sicherheitsanforderungen wie ASIL, *engl.* Automotive Safety Integrity Level [60], werden Fusionsansätze weiter an Bedeutung gewinnen. Als zusätzliche Entwicklungen dürften innerstädtische Assistenzfunktionen genannt werden, ebenso wird die Fahrzeug-zu-Fahrzeug-Kommunikation ein wichtiger Forschungsschwerpunkt bleiben. All diese Systeme werden eine gemeinsame schnelle Sensordatenfusion mit OOSM-Algorithmen benötigen. In dieser Arbeit wurde der Vorteil einer sofortigen Integration aller Sensordaten bei zeitkritischen Systemen in der Automobilindustrie aufgezeigt und die entwickelten Algorithmen anhand eines Pre-Crash-Systems getestet.

Zusammenfassend lassen die Ergebnisse der vorliegenden Arbeit erwarten, dass die Zustandsschätzung mit direkter Integration chronologisch ungeordneter Sensordaten in Zukunft an Bedeutung gewinnen wird und für viele Fahrerassistenz- und Fahrzeugsicherheitssysteme erfolgreich eingesetzt werden kann.

# $\mathbf{A}$

# Anhang

## A.1 Schaltungsentwurf zur zeitlichen Kalibrierung

In der Sensorfusion spielt die zeitliche Synchronisierung eine wichtige Rolle. Um exakte Zeitstempel des Aufnahmezeitpunkts zu erhalten, wurde in der vorliegenden Arbeit die im folgenden beschriebene Hardwarelösung entwickelt.

Im verwendeten Versuchsaufbau werden die Daten des MMR über eine Messtechnikschnittstelle eines Field Programmable Gate Array (FPGA) ausgelesen. Daher sind die exakten Latenzen in der Praxis nicht feststellbar. Der verwendete Aufbau ist in Abbildung A.1 schematisch dargestellt. Die Idee der vorliegenden Hardwarelösung ist die fol-



Abbildung A.1: Messtechnik zur Aufnahme der Rohdaten des MMR-Sensors.

gende: Mit einer Laserdiodenschaltung wird die Drehung der Walze abgegriffen, was die Vergabe eines globalen Zeitstempels ermöglicht. Mit Hilfe dieses Aufbaus wird zu Beginn jedes Messzyklus ein Transistor-Transistor-Logik (TTL)-Signal erzeugt und entsprechend der Datenzuordnung ein Zeitstempel gesetzt. In Abbildung A.2 ist die Bohrung am Sensor dargestellt, mittels der das Signal abgegriffen werden kann. Die Platinenschaltung zur Zeitstempelgenerierung beinhaltet die folgenden vier Komponenten:

- Laserdiode mit Sende- und Empfangseinheit,
- Festspannungsregler zur Spannungsumwandlung,
- Konstantstromquelle zur Ansteuerung der Laserdiode und zur Regelung der Intensität,
- Komparatorbaustein zur Generierung eines Schwellwertschalters (Schmitt-Trigger).



Abbildung A.2: Gehäuse des Radarsensors mit Bohrung für Laserdiodenkopf.

Die Laserdiode ist für einen Temperaturbereich von 15°C bis 65°C ausgelegt. Die 12V Versorgungsspannung des Radarsensors stellt die Stromversorgung der Platine bereit, wobei die Spannung an der CAN-Schnittstelle des Sensors anliegt. Ein Festspannungsregler am Eingang der eigentlichen Schaltung versorgt die TTL-Schaltung mit der benötigten Spannung, gefolgt von einem 155 MHz-Laser Switch als SMD-Baustein (*engl.* "Surface Mounted Device"), der als Stromregler der Laserdiode fungiert. Die Laserdiode kann als Regelstrecke interpretiert werden und der SMD-Baustein als Regler, der für die Anpassung des Stroms zuständig ist, so dass die gleiche Intensität der Laserdiode auch bei unterschiedlichen Temperaturen garantiert werden kann. Dies umgeht das typische Problem der Instabilität unter Temperaturschwankungen bei derartigen Laserdioden, die eine Stromregelung für eine konstante Intensität erfordern.

Das ausgesendete Licht der Laserdiode wird von der Walze reflektiert und von der Photodiode registriert. Je nach Lichteinfall ergeben sich unterschiedliche Stromwerte. Die Walze beinhaltet für eine interne Lichtschrankendetektion eine Nut, mit Hilfe derer eine Walzendrehung detektiert werden kann. Die Laserdiode besitzt charakteristische Stromstärken, wodurch am Oszilloskop genau verfolgt werden kann, wann diese Nut die Laserdiode passiert. Im Anschluss ist zur Generierung eines eindeutigen Signals ein Komparator verbaut, der ab einem festgelegten Schwellwert schaltet. Hierzu wird mittels eines Pull-Down-Widerstandes ein Spannungswert geliefert, der die Eingangsspannung für den Komparatorbaustein darstellt. Mit einem Potentiometer kann dieser Schwellwert des Komparators sehr exakt vorgegeben werden, was zu einem digitalen 0/1-Signal führt. Um robuste Ergebnisse bezüglich Temperaturschwankungen zu erzielen wurden Temperaturmessungen in einer Klimakammer durchgeführt. Die Schaltung kann hierbei so eingestellt werden, dass sie Ausgangswerte zwischen 10°C und 85°C liefert. Zur Berücksichtigung von Witterungsverhältnissen und Fahrtwind wurde ein wasserdichtes Gehäuse verwendet, welches zusätzlich inklusive Schaltung mit Silikon versiegelt wurde. Das Bohrloch im Sensorgehäuse für den Diodenkopf wurde ebenfalls mit Silikon abgedichtet, damit keine Feuchtigkeit in den Sensor eindringen kann. Mit Hilfe der beschriebenen Schaltung
konnte somit die Drehung der Walze exakt abgegriffen werden und somit ein globaler Zeitstempel vergeben werden. Eine detaillierte Beschreibung des verwendeten Verfahrens zur zeitlichen Synchronisierung ist in [157] nachzulesen.

#### A.2 Hardware der Kontaktsensorik

Die Kenntnis der exakten Aufprallzeit ist in den durchgeführten Pre-Crash-Anwendungen wichtig, um eine Referenz für die Bewertung der geschätzten TTC verwenden zu können. Hierzu wird ein Linearpotentiometer benutzt, ein schlauchförmiger Sensor, welcher aus mehreren hintereinander geschalteten Widerständen besteht. Bei einem Anprall wird der Stromkreis an der Kontaktstelle geschlossen und die Spannung fällt an den Widerständen bis zur Kontaktstelle ab. Das Linearpotentiometer liefert 0V für ein Schließen des Stromkreises direkt nach der Anschlussstelle der Versorgungsspannung und den maximalen Spannungswert am Ende des Schlauches. Hierbei werden alle Widerstände zwischengeschaltet und die komplette Spannung fällt an den Widerständen ab. Dabei wurde für die Sensorauslegung dieser Arbeit eine Versorgungsspannung von 5V gewählt, was eine direkte Weiterleitung der Sensorausgangsspannung an einen Mikrocontroller möglich macht. Der Spannungswert wird mit Hilfe eines A/D-Wandlers konvertiert, so dass die digitale Objektposition zur weiteren Verarbeitung verwendet werden kann. Das TTL-Signals des Mikrocontrollers muss zusätzlich verstärkt werden, da die verwendete I/O-Karte "Logisch Eins" erst ab 11,5V erkennt. Daher wird jeder Ausgang des Mikrocontrollers mittels einer Emitterschaltung auf 12V verstärkt. In Abbildung A.3 ist ein Überblick über die angefertigte Platine zu sehen.

Die Treiberstufe für die 5V TTL-Ausgangsspannung des Mikrocontrollers wird mit 12V Bordnetzspannung versorgt. Liegt als Eingangsspannung der Schaltung eine "Logisch Eins" an, was 5V entspricht, so schaltet der Transistor durch und zieht den Ausgang auf 0V. Beim Anliegen einer "Logisch Null" sperrt der Transistor und am Ausgang liegen ungefähr 12V an. Diesen Pegel interpretiert die I/O-Karte wiederum als "Logisch Eins". Abbildung A.4 zeigt die genaue Schaltungsbelegung. Dies ist eine invertierende Logik, welche im Grundzustand jeden Eingang der I/O-Karte auf "Logisch Eins" setzt. Sobald ein Bit der I/O-Karte beim Zuschalten der Kontaktsensorik Null ist, deutet dies auf einen Fehlerfall hin.

Zum Digitalisieren der Spannungswerte der Kontaktsensorik wurde ein PIC18F2455 Mikrocontroller der Firma Microchip verwendet. Dieser ist in einem Gehäuse eingebettet, das nur eine begrenzte Anzahl an Schnittstellen besitzt, und es führen keine Ausgangsports des Controllers nach außen. Die Box beinhaltet einen Anschluss für die Spannungsversorgung sowie zwei Messkanäle und eine seriellen Schnittstelle zur Datenübertragung. Der Mikrocontroller besitzt einen integrierten 10 Bit A/D-Wandler mit insgesamt zehn zuschaltbaren Eingangskanälen, wobei für die Spannungswandlung der Kontaktsensorik nur ein Kanal erforderlich ist. Da hardwaretechnisch lediglich sechs Ausgangspins nach außen gelegt werden können, ist die Auflösung auf sechs Bit begrenzt, was für die Breite des Schlauches der Kontaktsensorik ist allerdings ausreicht. Daher können insgesamt  $2^6 = 64$  Schlauchabschnitte zur Positionsbestimmung von Kollisionsobjekten definiert werden.



Abbildung A.3: Platinenbestückungsplan der Treiberstufe.

Aufgrund der zur Verfügung stehenden Platine, bei der keine hardwaremäßigen Ausgangsports vorgesehen sind, musste das Ergebnis der Wandlung auf Ports verschoben werden, die normalerweise zur Programmierung des Mikrocontrollers dienen. Diese Ports der Registerbank B entsprechen RB0 bis RB2 und RB5 bis RB7, es stehen also nur sechs Bits zur Messwertausgabe zur Verfügung. Die Ausgabe des Wandlungsresultats, welche im Adressregister hinterlegt sind, wurde durch die folgende Bitverschiebung an die zur Verfügung stehen Ausgangsports angepasst: Aus dem zehn Bit gewandelten Wert des A/D-Bausteins werden die sechs höchstwertigsten Bits auf die Ausgangsports der Registerbank B geschoben. Abbildung A.5 fasst die komplette Beschaltung zum Einlesen der Kontaktsensorik zusammen. Details zu der verwendeten Hardwarelösung findet sich in [158].



Abbildung A.4: Auslegung der Emitterschaltung.



Abbildung A.5: Blockschaltbild der Komponentenverschaltung.

# Abkürzungsverzeichnis

ABS	Antiblockiersystem
ACC	Adaptive Cruise Control
ADAS	Advanced Driver Assistance Systems
ASIL	Automotive Saftey Integrity Level
BAS	Bremsassistent
CAN	Controller Area Network
Car2Car	Car-to-Car
Car2X	Car-to-Infrastructure
CMS	Collision Mitigation System
DARPA	Defense Advanced Research Projects Agency
DIN	Deutsches Institut für Normung
ESP	Elektronisches Stabilisierungsprogramm
FAS	Fahrerassistenzsysteme
FMCW	Frequency Modulated Continuous Wave
FoV	Field of View
FPFD	Forward-Prediction Fusion and Decorrelation
FPGA	Field Programmable Gate Array
GNN	Global Nearest Neighbor
IMM	Interacting Multiple Model
JIPDA	Joint Integrated Probabilistic Data Association

JPDA	Joint Probabilistic Data Association
JPDAM	Joint Probabilistic Data Association for possibly Merged Measurements
LIDAR	Light Detection and Ranging
LRR	Long Range Radar
LVDS	Low Voltage Differential Signaling
MHT	Multi-Hypothesis Tracking
MMR	Multi-Mode Radar
MSMTT	Multi-Sensor Multi-Target Tracking
NEES	Normalized Estimation Error Squared
OEM	Original Equipment Manufacturer
OOSM	Out-of-Sequence Measurement
PDA	Probabilistic Data Association
RADAR	Radio Detection and Ranging
RDU	Radar Decision Unit
RMSE	Root Mean Square Error
ROC	Receiver Operating Characteristic
SNN	Simple Nearest Neighbor
SRR	Short Range Radar
ТоҒ	Time-of-Flight
TTC	Time-to-Collision
TTL	Transistor-Transistor-Logik
UKF	Unscented Kalman Filter
USB	Universal Serial Bus
UWB	Ultra Wide Band

# Symbol verzeichnis

### Generelle Notation

<i>a</i>	Skalare Variable
a	Spaltenvektor
à	Erste Ableitung des Vektors ${\bf a}$
â	Erwartungswert
M	Matrix
$\mathbf{M}^{T}$	Transponierte der Matrix $\mathbf{M}$
$\mathbf{M}^{-1}$	Inverse der Matrix $\mathbf{M}$
$(\mathbf{M})_i$	$i\text{-te}$ Spalte der Matrix ${\bf M}$
$e^{\mathbf{M}}$	Matrixexponential
<i>k</i> <sub>0</sub>	Diskreter Zeitindex einer OOS-Messung
<i>k</i>	Diskreter Zeitindex
$t_k$	Diskreter Zeitpunkt $k$
<i>t</i>	Kontinuierliche Zeit
$(\cdot)_{k k-1}$	A priori (·) zum Zeitpunkt $t_k$ unter der Bedingung $Z^{k-1}$
$(\cdot)_{k k}$	$A$ posteriori $(\cdot)$ zum Zeitpunkt $t_k$ unter der Bedingung $Z^k$
$(\cdot)_{k,k-1}$	(·) zwischen den Zeitpunkten $t_k$ und $t_{k-1}$
$(\cdot)_{k,k-1 k}$	$(\cdot)$ zwischen $t_k$ und $t_{k-1}$ unter der Bedingung $Z^k$
<i>i</i>	Index für ein Objekt
<i>j</i>	Index für eine Messung

## Lateinische Buchstaben

$A(\cdot,\cdot)$	Menge von Hypothesen
A	Systemmatrix
<i>a</i>	Akzeptanzintervall
$B(\cdot)$	Menge von Tupeln einer Hypothese
В	Eingangsmatrix
<i>b</i>	Fahrzeugbreite
C	Ausgangsmatrix
C	Anzahl von Monte-Carlo-Simulationen
<i>c</i>	Gewichtungsfaktor
D	Dimension
<i>d</i>	Distanzmaß
<b>F</b>	Transitionsmatrix
$f(\mathbf{x})$	Transitionsfunktion
$\mathbf{F}^{-1}$	Rückwärtstransitionsmatrix
<i>g</i>	Gewichtungsfaktor
Н	Hypothese
$h(\mathbf{x})$	Messfunktion
н	Messmatrix
H*	Äquivalente Messmatrix
<i>I</i>	Einheitsmatrix
$\mathcal I$	Informationsmatrix
J	Jakobi-Matrix
К	Kalman-Verstärkungsmatrix
K*	Äquivalente Kalman-Verstärkungsmatrix
<i>L</i>	Latenz
<i>l</i>	Schrittweite einer nicht chronologischen Messung
<i>M</i>	Anzahl von Messungen, Dimension des Messraumes

$\mathcal{N}(\boldsymbol{\mu}, \boldsymbol{\Sigma})$	Multivariate Normal verteilung mit Mittelwert $\mu$ und Kovarian z $\Sigma$
<i>N</i>	Dimension des Zustandsraumes
$P_D$	Detektionswahrscheinlickeit eines Objektes
$p(\cdot)$	Wahrscheinlichkeit eines Ereignisses
Ρ	Kovarianz der Zustandsschätzung (Schätzfehlerkovarianz)
P*	Kovarianz der äquivalenten Zustandsschätzung
P <sup>ab</sup>	Kreuzkovarianz zwischen den Vektoren ${\bf a}$ und ${\bf b}$
Q	Kovarianz des Prozessrauschens
<i>q</i>	Spektrale Leistungsdichte des Prozessrauschens
<i>r</i>	Doppler-Geschwindigkeit
<i>r</i>	Entfernung, Radius in Polarkoordinaten
R	Kovarianz des Messrauschens
R*	Kovarianz des äquivalanten Messrauschens
S*	Äquivalente Kovarianz des Residuums
S	Kovarianz des Residuums (Innovationskovarianz)
s	Laplace-Parameter
т	Transformationsmatrix
<i>t</i>	Transformationsfunktion
U	Menge von Steuervektoren
u	Steuereingang
<i>V</i>	Volumen
<b>v</b>	Prozessrauschvektor
<i>v</i>	Geschwindigkeit
<i>W</i>	Gewicht eines Sigma-Punktes
$\mathbf{W}$	Gewichtungsmatrix, Kalman-Verstärkungsmatrix
w	Messrauschvektor
<b>w</b> *	Äquivalenter Messrauschvektor

x	Zustandsvektor
x*	Äquivalenter Zustandsvektor
y	Substitutionsvektor für Zustands- und Prozessrauschvektor
Z	Menge von Messungen, Zykluszeit
Z	Messvektor
<b>z</b> *	Äquivalenter Messvektor
Griechische Buch	staben
α	Parameter des Sigma-Punkt-Filters, Signifikanzniveau
β	Dichte des Hintergrundrauschen, Parameter des Sigma-Punkt- Filters
γ	Innovationsvektor (Residuum)
$\gamma^*$	Äquivalenter Innovationsvektor
$\Delta t$	Zeitspanne zwischen zwei Messzyklen
$\eta$	$\eta\text{-}\mathrm{Position}$ eines kartesischen Koordinaten systems
$\dot{\eta}$	Geschwindigkeit in Richtung der $\eta\text{-}\mathrm{Achse}$
κ	Parameter des Sigma-Punkt-Filters
λ	Parameter des Sigma-Punkt-Filters, Eigenwert
ξ	$\xi\text{-}\mathrm{Position}$ eines kartesischen Koordinaten systems
ξ	Geschwindigkeit in Richtung der $\xi\text{-Achse}$
σ	Standardabweichung
$\sigma^2$	Varianz
τ	$\tau\text{-}\mathrm{Position}$ einer zeitlichen Kollisionskoordinate, kontinuierliche Zeitverschiebung
$\varphi$	Winkel, Azimutwinkel in Polarkoordinaten
$\chi^2_N$	Chi-Quadrat-Verteilung mit Freiheitsgrad ${\cal N}$
<i>x</i>	Sigma-Punkt
$\psi$	$\psi\text{-}\textsc{Position}$ einer räumlichen Kollisionskoordinate
ω	$\omega\text{-}\textsc{Position}$ eines kartesischen Koordinatensystems

# Literaturverzeichnis

- ALBRECHT, Frank: Die rechtlichen Rahmenbedingungen bei der Implementierung von Fahrerassistenzsystemen zur Geschwindigkeitsbeeinflussung. In: *Deutsches Autorecht* (2005), S. 186–198
- [2] ANDERSON, Brian D. O.; MOORE, John B.: Optimal Filtering. Prentice Hall, 1979
- [3] ARULAMPALAM, Sanjeev; MASKELL, Simon; GORDON, Neil; CLAPP, Tim: A Tutorial on Particle Filters for Online Nonlinear/Non-Gaussian Bayesian Tracking. In: Transactions on Signal Processing 50 (2002), S. 174–188
- [4] BAR-SHALOM, Yaakov: Multitarget-Multisensor Tracking: Principles and Techniques. YBS, 1995
- BAR-SHALOM, Yaakov: Update with Out-of-Sequence Measurements in Tracking: Exact Solution. In: Proceedings of SPIE, Signal and Data Processing of Small Targets 4048 (2000), S. 541–556
- [6] BAR-SHALOM, Yaakov: Update with Out-of-Sequence Measurements in Tracking: Exact Solution. In: *IEEE Transaction on Aerospace and Electronic Systems* 38 (2002), Nr. 3, S. 769 – 777
- BAR-SHALOM, Yaakov; CHEN, Huimin: IMM Estimator with Out-of-Sequence Measurements. In: *IEEE Transactions on Aerospace and Electronic Systems* 41 (2005), Nr. 1, S. 90–98
- [8] BAR-SHALOM, Yaakov; CHEN, Huimin: Removal of Out-of-Sequence Measurements from Tracks. In: *IEEE Transaction on Aerospace and Electronic Systems* 45 (2009), S. 612–619
- [9] BAR-SHALOM, Yaakov; CHEN, Huimin; MALLICK, Mahendra: One-Step Solution for the Multistep Out-of-Sequence-Measurement Problem in Tracking. In: *IEEE Transaction on Aerospace and Electronic Systems* 40 (2004), Nr. 1, S. 27–37
- [10] BAR-SHALOM, Yaakov; LI, Xiao-Rong; KIRUBARAJAN, Thiagalingam: Estimation with Applications to Tracking and Navigation. John Wiley & Sons Inc., 2001

- [11] BAR-SHALOM, Yaakov; MALLICK, Mahendra; CHEN, Huimin ; WASHBURN, Robert: One-Step Solution for the General Out-of-Sequence-Measurement Problem in Tracking. In: Proceedings of the IEEE Aerospace Conference 4 (2002), S. 1551– 1559
- [12] BAR-SHALOM, Yaakov; TSE, Edison: Tracking in a Cluttered Environment With Probabilistic Data Association. In: Automatica 11 (1975), S. 451–460
- [13] BARTH, Matthew; BORIBOONSOMSIN, Kanok; VU, Alexander: Environmentally-Friendly Navigation. In: *IEEE Intelligent Transportation Systems Conference* (2007), S. 684–689
- BAYES, Thomas: An Essay towards solving a Problem in the Doctrine of Chance.
  In: Philosophical Transactions of the Royal Society of London 53 (1763), S. 370–418
- [15] BERTEKAS, Dimitri P.: The Auction Algorithm for Assignment and other Network Flow Problems. Massachusetts Institute of Technology, Laboratory for Information and Decision Systems, 1989
- [16] BERTOZZI, Massimo; BOMBINI, Luca; BROGGI, Alberto; BUZZONI, Michele; CAR-DARELLI, Elena; CATTANI, Stefano; CERRI, Pietro; COATI, Alessandro; DEBAT-TISTI, Stefano; FALZONI, Andrea; FEDRIGA, Rean Isabella; FELISA, Mirko; GATTI, Luca; GIACOMAZZO, Alessandro; GRISLERI, Paolo; LAGHI, Maria Chiara; MAZ-ZEI, Luca; MEDICI, Paolo; PANCIROLI, Matteo; PORTA, Pier Paolo; ZANI, Paolo; VERSARI, Pietro: VIAC: An Out of Ordinary Experiment. In: *IEEE Conference* on Intelligent Vehicles Symposium (2011), S. 175–180
- [17] BESADA-PORTAS, Eva; LOPEZ-OROZCO, Jose A.; BESADA, Juan ; DE LA CRUZ, Jesus M.: Multisensor Out-Of-Sequence Data Fusion for Estimating the State of Discrete Control Systems. In: *IEEE Transactions on Automatic Control* 54 (2009), S. 1728–1732
- [18] BESADA-PORTAS, Eva; LOPEZ-OROZCO, Jose A.; DE LA CRUZ, Jesus M.: Multisensor Out-Of-Sequence Data Fusion for Estimating the State of Dynamic Systems. In: Information, Decision and Control (2007), S. 348–353
- [19] BEWERSDORF, Cornelia: Zur Vereinbarkeit von nicht-übersteuerbaren Fahrerassistenzsystemen mit dem Wiener Übereinkommen über den Straßenverkehr vom 8. November 1968. In: Neue Zeitschrift für Verkehrsrecht (2003), S. 266–271
- BIERMAN, Gerald J.; THORNTON, Catherine L.: Numerical Comparison of Kalman Filter Algorithms: Orbit Determination Case Study. In: *Automatica* 13(1) (1977), S. 23–35
- [21] BISHOP, Richard: Intelligent Vehicle Technology and Trends. Artech House, 2005
- [22] BLACKMAN, Samuel S.: Multiple-Target Tracking with Radar Applications. Artech House, 1999

- [23] BLACKMAN, Samuel S.; POPOLI, Robert: Design and Analysis of Modern Tracking Systems. Artech House, 1986
- [24] BLOM, Henk A.P.: An Efficient Filter for Abruptly Changing Systems. In: IEEE Conference on Decision and Control (1984), Nr. 23, S. 656–658
- BLÖCHER, Hans-Ludwig; SCHNEIDER, Robert; STROHM, Karl: Automotive Radar
  Status, Trends, and Perspectives. In: Fachforum "Sensorik für Fahrerassistenzsysteme" (2006), Nr. 1, S. 21–22
- [26] BREUER, Jörg: Fahrerassistenzsysteme: Vom Tempomat bis zum Notbremsassistenten. In: Technischer Kongress von Verband der Deutschen Automobilindustrie (2007)
- [27] BROWN, Robert G.; HWANG, Patrick Y.: Introduction to Random Signals and Applied Kalman Filtering. John Wiley & Sons, 1996
- [28] BRÄNNSTRÖM, Mattias; SJÖBERG, Jonas; COELINGH, Erik: A Situation and Threat Assessment Algorithm for a Rear-End Collision Avoidance System. In: *IEEE Conference on Intelligent Vehicles Symposium* (2008), S. 102–107
- [29] BÜHREN, Markus; YANG, Bin: Simulation of Automotive Radar Target Lists using a Novel Approach of Object Representation. In: *IEEE Conference on Intelligent Vehicles Symposium* (2006), S. 314–319
- [30] BÜHREN, Markus; YANG, Bin: Extension of Automotive Radar Target List Simulation to consider further Physical Aspects. In: International Conference on Intelligent Transport Systems Telecommunications (2007), Nr. 7, S. 124–129
- [31] CHALLA, Subhash; EVANS, Robin J.; WANG, Xuezhi: Track-to-Track Fusion using Out-of-Sequence Tracks. In: International Conference on Information Fusion (2002), Nr. 5, S. 919–926
- [32] CHALLA, Subhash; EVANS, Robin J.; WANG, Xuezhi ; LEGG, Jonathan: A Fixed Lag Smoothing Framework for OOSM Problems. In: Communications in Information and Systems 2 (2002), Nr. 4, S. 327–350
- [33] CHALLA, Subhash; WANG, Xuezhi ; LEGG, Jonathan: A Fixed Lag Smoothing Framework for Target Tracking in Clutter using OOSM. In: *Defense Applications* of Signal Processing (2001)
- [34] CHANG, Kuo-Chu; BAR-SHALOM, Yaakov: Joint Probabilistic Data Association for Multitarget Tracking with Possibly Unresolved Measurements and Maneuvers. In: *IEEE Transactions on Automatic Control* 29 (1984), Nr. 7, S. 585–594
- [35] CHEN, Zhe: Bayesian Filtering: From Kalman Filters to Particle Filters, and Beyond / Communications Research Laboratory McMaster University. 2007. – Forschungsbericht

- [36] DARMS, Michael: Eine Basis-Systemarchitektur zur Sensordatenfusion von Umfeldsensoren für Fahrerassistenzsysteme, Technische Universität Darmstadt, Fachbereich Maschinenbau, Dissertation, 2007
- [37] DARMS, Michael: Conditional, Carnegie Mellon, TARTAN Racing, Winner of the Urban Challenge 2007. In: *Tagung Aktive Sicherheit durch Fahrerassistenz* (2008), Nr. 3
- [38] DEUTSCHES INSTITUT FÜR NORMUNG: DIN 70000. In: Straßenfahrzeuge; Fahrzeugdynamik und Fahrverhalten; Begriffe (ISO 8855:1991, modifiziert) (1994)
- [39] DEUTSCHLE, Stephan: "Wer fährt? Der Fahrer oder das System?". In: Straßenverkehrsrecht (2005), S. 249–254
- [40] DEZERT, Jean; BAR-SHALOM, Yaakov: Joint Probabilistic Data Association for Autonomous Navigation. In: *IEEE Transactions on Aerospace and Electronic Sys*tems 29 (1993), S. 1275–1286
- [41] DICKMANN, Jürgen; DIEWALD, Fabian; MÄHLISCH, Mirko; KLAPPSTEIN, Jens; ZUTHER, Sebastian; PIETZSCH, Sylvia; HAHN, Stefan; MUNZ, Michael: Environment Perception for Future Integrated Safety Systems. In: International Technical Conference on the Enhanced Safety of Vehicles (2009), Nr. 21
- [42] DIETMAYER, Klaus; KIRCHNER, Alexander ; KÄMPCHEN, Nico; MAURER, Markus (Hrsg.); STILLER, Christoph (Hrsg.): Fusionsarchitekturen zur Umfeldwahrnehmung für zukünftige Fahrerassistenzsysteme. Springer Verlag, 2005 (Fahrerassistenzsysteme mit maschineller Wahrnehmung). – 59–87 S.
- [43] DOMINIK, Hans: Short Range Radar Status of UWB Sensors and their Applications. In: European Microwave Conference (2007), Nr. 37, S. 1530–1533
- [44] EUROPEAN COMMISION: Progress during 2009 at the UN Economic Commission for Europe. In: CARS 21 Communication (2010)
- [45] EUROPEAN COMMISION OF MOBILITY & TRANSPORT: European Transport Policy for 2010: Time to Decide. In: *Commission of the European Communities* (2001)
- [46] FORTMANN, Thomas E.; BAR-SHALOM, Yaakov; SCHEFFE, Molly: Multi-Target Tracking using Joint Probabilistic Data Association. In: Decision and Control including the Symposium on Adaptive Processes 19 (1980), S. 807–812
- [47] FRANK, András: On Kuhn's Hungarian Method A Tribute from Hungary / Egerváry Research Group on Combinatorial Optimization. 2004 (2004-14). – Forschungsbericht
- [48] FREYMANN, Raymond: Möglichkeiten und Grenzen von Fahrerassistenz- und Aktiven Sicherheitssystemen. In: Aktive Sicherheit durch Fahrerassistenz, Lehrstuhl für Fahrzeugtechnik der Technischen Universität München (2005)

- [49] FÜRSTENBERG, Kay; BARAUD, Pierre; CAPORALETTI, Gabriella; CITELLI, Silvia; EITAN, Zafir; LAGES, Ulrich ; LAVERGNE, Christophe: Development of a Pre-Crash Sensorial System - The CHAMELEON Project. In: Joint VDI/VW Congress Vehicle Concepts for the 2nd Century of Automotive Technology (2001)
- [50] FÜRSTENBERG, Kay; RÖSSLER, Bernd: Intersection Driver Assistance System Results of the EC-Project INTERSAFE. In: *IEEE Conference on Intelligent Vehicles* Symposium (2007), S. 462–467
- [51] FÜRSTENBERG, Kay; WILLHOEFT, Volker ; DIETMAYER, Klaus: New Sensor for 360° Vehicle Surveillance - Innovative Approach to Stop & Go, Lane Assistance and Pedestrian Recognition. In: *IEEE Conference on Intelligent Vehicles Symposium* (2001)
- [52] GELB, Arthur: Applied Optimal Estimation. MIT Press, Cambridge MA, 1974
- [53] GIEBEL, Tobias; EIGEL, Thomas; JERHOT, Jiri; SEMMLER, Carsten: Verfahren und Vorrichtung zur integrierten Quer- und Längsführung eines Kraftfahrzeugs. In: *Deutsches Patentamt* (2009), Nr. DE102009008302A1
- [54] GORDON, Neil J.; SALMOND, David J.; SMITH, Adrian F. M.: Novel Approach to Nonlinear/Non-Gaussian Bayesian State Estimation. In: *Radar and Signal Processing* 140 (1993), S. 107–113
- [55] HALL, David; MCMULLEN, Sonja: Mathematical Techniques in Multisensor Data Fusion. Artech House, 2004
- [56] HILTON, Richard D.; MARTIN, David A.; BLAIR, William D.: Tracking with Time-Delayed Data in Multisensor Systems. In: *Final Report Naval Surface Warfare Center* (1993)
- [57] HOPSTOCK, Matthias; EHMANNS, Dirk ; SPANNHEIMER, Helmut; SPRINGER (Hrsg.): Development of Advanced Assistance Systems for Intersection Safety. Advanced Microsystems for Automotive Applications, 2005. – 521ff. S.
- [58] INFORMATIONSDIENST DER DEUTSCHEN GESELLSCHAFT FÜR DIE VEREINTEN NATIONEN E.V. (DGVN): Urbanisierung als Chance. In: *Weltbevölkerungsbericht* (2007), Nr. 63
- [59] INSTITUT FÜR FAHRZEUGSICHERHEIT: Retrospektive Sicherheitsanalyse von Pkw-Kollisionen mit Schwerverletzten. In: Gesamtverband der Deutschen Versicherungswirtschaft e. V. (1998)
- [60] INTERNATIONALE ORGANISATION FÜR NORMUNG: ISO 26262 ("Road vehicles Functional safety"). In: ISO TC22/SC3/WG16 (2009)
- [61] INTERSAFE-2: Cooperative Intersection Safety. (2011). http://www. intersafe-2.eu

- [62] ISARD, Michael; BLAKE, Andrew: Contour Tracking By Stochastic Propagation of Conditional Density. In: European Conference on Computer Vision (1996), S. 343–356
- [63] JANSSON, Jonas; JOHANSSON, Jonas; GUSTAFSSON, Frederik: Decision Making for Collision Avoidance Systems. In: Society of Automotive Engineering (2002)
- [64] JULIER, Simon J.; UHLMANN, Jeffrey K.: A New Extension of the Kalman Filter to Nonlinear Systems. In: International Symposium Aerospace/Defense Sensing, Simulation and Controls (1997)
- [65] JULIER, Simon J.; UHLMANN, Jeffrey K.; DURANT-WHYTE, Hugh F.: A New Approach for Filtering Nonlinear Systems. In: American Control Conference (1995), S. 1628–1632
- [66] KALMAN, Rudolph E.: A New Approach to Linear Filtering and Prediction Problems. In: Transactions of the ASME, Journal of Basic Engineering 82 (1960), S. 35–45
- [67] KÄMPCHEN, Nico: Feature-Level Fusion of Laser Scanner and Video Data for Advanced Driver Assistance Systems, University of Ulm, Dissertation, 2007
- [68] KÄMPCHEN, Nico; CLAUSS, Martin; GUENTER, Yvonne; SCHREIER, Ralf; STIE-GELER, Markus; TISCHLER, Karin; DIETMAYER, Klaus; GROSSMANN, Hans Peter; KABZA, Herbert; NEUMANN, Heiko; ROTHERMEL, Albrecht; STILLER, Christoph: Vernetzte Fahrzeug-Umfelderfassung für zukünftige Fahrerassistenzsysteme. In: Workshop Fahrerassistenzsysteme (2005), S. 139–150
- [69] KÄMPCHEN, Nico; DIETMAYER, Klaus: Data Synchronization Strategies for Multi-Sensor Fusion. In: World Congress on Intelligent Transport Systems (2003), Nr. 10
- [70] KÄMPCHEN, Nico; FÜRSTENBERG, Kay; DIETMAYER, Klaus: Ein Sensorfusionssystem für automotive Sicherheits- und Komfortapplikationen. In: Aktive Sicherheit durch Fahrerassistenz, Lehrstuhl für Fahrzeugtechnik der Technischen Universität München (2004)
- [71] KLEIN, Lawrence: Sensor and Data Fusion Concepts and Applications. 2. SPIE International Society for Optical Engine, 1999
- [72] KO-FAS: Kooperative Sensorik und kooperative Perzeption für die präventive Sicherheit im Straßenverkehr. (2011). www.ko-fas.de
- [73] KÖNIG, Matthias; MEINECKE, Marcel-Michael; WALDT, Nils; GONTER, Mark; MÜLLER, Stephan; ROHLING, Hermann; RITTER, Henning: A Sensor System for a Pre-Crash Deployment with extremely low False Alarm Rate. In: International Workshop on Intelligent Transportation (2008), Nr. 5, S. 61–66
- [74] KOPISCHKE, Stephan: Entwicklung einer Notbremsfunktion mit Rapid Prototying Methoden, Technische Universität Braunschweig, Dissertation, 2000

- [75] KURUTAS, Cem; ELSÄSSER, Konrad; SCHRAMM, Dieter; MANFREDHILLER: Modeling and Simulation of the Effect of Reversible Belt Pretensioners. In: *Mechatronics* (2006), S. 119–124
- [76] LANGER, Dirk; SWITKES, Joshua P.; STOSCHEK, Arne ; HUHNKE, Burkhard: Environment Perception in the 2007 Urban Challenge: Utility for Future Driver Assistance Systems. In: Workshop Fahrerassistenzsysteme (2008), Nr. 5, S. 68–77
- [77] LANZKRON, Paul; BAR-SHALOM, Yaakov: A Two-Step Method for Out-of-Sequence Measurements. In: Proceedings of the IEEE Aerospace Conference 3 (2004), S. 2041
- [78] LERRO, Don; BAR-SHALOM, Yaakov: Tracking With Debiased Consistent Converted Measurements Versus EKF. In: *IEEE Transactions on Aerospace and Electronic Systems* 29 (1993), Nr. 3, S. 1015–1022
- [79] LEVINSON, Jesse; ASKELAND, Jake; BECKER, Jan; DOLSON, Jennifer; HELD, David; KAMMEL, Sören; KOLTER, J. Zico; LANGER, Dirk; PINK, Oliver; PRATT, Vaughan; SOKOLSKY, Michael; STANEK, Ganymed; STAVENS, David Michael; TEICHMAN, Alex; THRUN, Moritz Werling S.: Towards Fully Autonomous Driving: Systems and Algorithms. In: *IEEE Conference on Intelligent Vehicles Symposium* (2011), S. 163–168
- [80] LONGBIN, Mo; XIAOQUAN, Song; YIYU, Zhou; KANG, Sun Z.; BAR-SHALOM, Yaakov: Unbiased Converted Measurements for Tracking. In: Aerospace and Electronic Systems 34 (1998), S. 1023 – 1027
- [81] LOPES, Samuel; FRISCH, Brian; BOEING, Adrian; VINSEN, Kevin; BRAUNL, Thomas: Autonomous Exploration of Unknown Terrain for Groups of Mobile Robots. In: *IEEE Conference on Intelligent Vehicles Symposium* (2011), S. 157–162
- [82] MÄHLISCH, Mirko: Filtersynthese zur simultanen Minimierung von Existenz-, Assoziations- und Zustandsunsicherheiten in der Fahrzeugumfelderfassung mit heterogenen Sensordaten, Universität Ulm, Fakultät für Ingenieurwissenschaften und Informatik, Dissertation, 2009
- [83] MÄHLISCH, Mirko; RITTER, Werner ; DIETMAYER, Klaus: De-cluttering with Integrated Probabilistic Data Association for Multisensor Multitarget ACC Vehicle Tracking. In: *IEEE Conference on Intelligent Vehicles Symposium* (2007), S. 178– 183
- [84] MÄHLISCH, Mirko; RITTER, Werner ; DIETMAYER, Klaus: Feature Level Video and Lidar Sensor Fusion for ACC Stop-and-Go using Joint Integrated Probabilistic Data Association. In: *European Congress on ITS* (2007), Nr. 6
- [85] MÄHLISCH, Mirko; SZCZOT, Magdalena; LÖHLEIN, Otto; MUNZ, Michael; DIET-MAYER, Klaus: Simultanous Processing of Multitarget State Measurements and Objects Individual Sensory Existence Evidence with the Joint Integrated Probabilistic Data Association Filter. In: International Workshop on Intelligent Transportation (2008), Nr. 5, S. 117–122

- [86] MAILE, Michael; AHMED-ZAID, Farid; BAI, Sue; CAMINITI, Lorenzo; MUDALIGE, Priyantha; PEREDO, Michael; POPOVIC, Zeljko: Objective Testing of a Cooperative Intersection Collision Avoidance System for Traffic Signal and Stop Sign Violations. In: *IEEE Conference on Intelligent Vehicles Symposium* (2011), S. 130–137
- [87] MALLICK, Mahendra; BAR-SHALOM, Jon Krant Y.: Multi-Sensor Multi-Target Tracking using Out-of-Sequence Measurements. In: International Conference on Information Fusion 1 (2002), Nr. 5, S. 135–142
- [88] MALLICK, Mahendra; BAR-SHALOM, Yaakov: Nonlinear Out-Of-Sequence Measurement Filter with Application to GMTI Tracking. In: *Proceedings of SPIE* 4728 (2002), S. 290–303
- [89] MALLICK, Mahendra; CORPALUPPI, Stefano; CARTHEL, Craig: Advances in Asynchronous and Decentralized Estimation. In: *Proceedings of the IEEE Aerospace Conference* 4 (2001), S. 1873–1888
- [90] MALLICK, Mahendra; MARRS, Alan: Comparison of the KF and Particle Filter based Out-of-Sequence Measurements Filtering Algorithms. In: International Conference on Information Fusion 1 (2003), Nr. 6, S. 422–429
- [91] MASKELL, Simon R.; EVERITT, Richard; WRIGHT, Robert; BRIERS, Mark: Multi-Target Out-Of-Sequence Data Association. In: International Conference on Information Fusion (2004), Nr. 7
- [92] MAUTHNER, Moritz; ELMENREICH, Wilfried; KIRCHNER, Alexander ; BOESEL, Diego: Out-Of-Sequence Measurements Treatment in Sensor Fusion Applications: Buffering versus Advanced Algorithms. In: Workshop Fahrerassistenzsysteme (2006), S. 20–30
- [93] MAZOR, Efim; AVERBUCH, Amir; BAR-SHALOM, Yaakov ; DAYAN, Joshua: Interacting Multiple Models Methods in Multitarget-Multisensor Tracking: Survey. In: *IEEE Transactions on Aerospace and Electronic Systems* 34 (1998), Nr. 1, S. 103–123
- [94] MCGEE, Leonard A.; SCHMIDT, Stanley F.: Discovery of the Kalman Filter as a Practical Tool for Aerospace and Industry / National Aeronautics and Space Administration. 1985 (86847). – Technical Memorandum
- [95] MENZEL, Wolfgang; PILZ, Dietmar: Mikrowellen-Reflektorantenne. In: Deutsches Patentamt (1999), Nr. WO 99/43049
- [96] MERWE, Rudolph van d.; WAN, Eric: Sigma-Point Kalman Filters for Probabilistic Inference in Dynamic State-Space Models. In: Workshop on Advances in Machine Learning (2003), Juni
- [97] MÜLLER, Stephan; RITTER, Henning; ROHLING, Hermann: Pre-Crash Application for Multiple Target Situations. In: International Radar Symposium IRS (2006), S. 1–4

- [98] MÜLLER, Stephan; RITTER, Henning; ROHLING, Hermann; MEINECKE, Marc M.: Signal Processing Strategies for a Multi Sensor Pre-Crash Application. In: VDI Gemeinschaftstagung (2006)
- [99] MUNZ, Michael; MÄHLISCH, Mirko; DICKMANN, Jürgen; DIETMAYER, Klaus: Probabilistic Modeling of Sensor Properties in Generic Fusion Systems for Modern Driver Assistance Systems. In: *IEEE Conference on Intelligent Vehicles Symposium* (2010)
- [100] MUNZ, Michael; MÄHLISCH, Mirko; DIETMAYER, Klaus: A Probabilistic Sensor-Independent Fusion Framework for Automotive Driver Assistance Systems. In: International Workshop on Intelligent Transportation (2009), Nr. 6
- [101] MUŠICKI, Darko; EVANS, Robin: Joint Integrated Probabilistic Data Association: JIPDA. In: International Conference on Information Fusion 2 (2002), Nr. 5, S. 1120–1125
- [102] MUŠICKI, Darko; EVANS, Robin: Joint Integrated Probabilistic Data Association: JIPDA. In: *IEEE Transactions on Aerospace and Electronic Systems* 40 (2004), Nr. 3, S. 1093–1099
- [103] NAAB, Karl: Sensorik- und Signalverarbeitungsarchitekturen für Fahrerassistenz und Aktive Sicherheit. In: Aktive Sicherheit durch Fahrerassistenz, Lehrstuhl für Fahrzeugtechnik der Technischen Universität München (2005)
- [104] NETTLETON, Eric W.; DURRANT-WHYTE, Hugh F.: Delayed and Asequent Data in Decentralized Sensing Networks. In: *Proceedings of SPIE* 4571 (2001), Nr. 1, S. 1–9
- [105] ORTON, Matthew; MARRS, Alan: A Bayesian Approach to Multi-Target Tracking and Data Fusion with Out-of-Sequence Measurements. In: International Seminar on Target Tracking: Algorithms and Application (2001), S. 1–5
- [106] ORTON, Matthew; MARRS, Alan: Particle Filters for Tracking with Out-of-Sequence Measurements. In: *IEEE Transactions on Aerospace and Electronic Sys*tems 41 (2005), Nr. 2, S. 693–702
- [107] OZGUNER, Umit; REDMILL, Keith; BIDDLESTONE, Scott; HSIEH, Ming F.; YAZICI, Ahmet; TOTH, Charles: Simulation and Testing Environments for the DARPA Urban Challenge. In: *IEEE International Conference on Vehicular Electronics and* Safety (2008), S. 222 – 226
- [108] PARK, PooGyeon; KAILATH, Thomas: New Square-Root Smoothing Algorithms. In: IEEE Transactions on Automatic Control 41 (1996), S. 727–732
- [109] PIETZSCH, Sylvia; AYCARD, Oliver; BURLET, Julien; VU, Trung D.; HACKBARTH, Thomas; APPENRODT, Nils; DICKMANN, Jürgen; RADIG, Bernd: Results of a Precrash Application based on Laserscanner and Short Range Radars. In: Intelligent Vehicles Symposium (2008), S. 367–372

- [110] POTTER, James E.; STERN, Robert G.: Statistical Filtering of Space Navigation Measurements. In: AIAA Guidance and Control (1963)
- [111] RANNACHER, Rolf: Einführung in die Numerische Mathematik (Vorlesungsskriptum); Institut für Angewandte Mathematik der Universität Heidelberg. (2006)
- [112] RASSHOFER, Ralph H.: Functional Requirements of Future Automotive Radar Systems. In: European Microwave Conference (2007), Nr. 37, S. 1538–1541
- [113] RHEAUME, Francois; BENASKEUR, Abder R.: Out-Of-Sequence Measurements Filtering using Forward Prediction. In: *Technical Report of Defence R&D Canada -Valcartier* TR-2005-485 (2007)
- [114] RHEAUME, Francois; BENASKEUR, Abder R.: Forward Prediction-Based Approach to Target-Tracking with Out-of-Sequence Measurements. In: *IEEE Conference on Decision and Control* (2008), S. 1326–1333
- [115] ROBINSON, Guner; ABOUTALIBS, Omar: Trade-Off Analysis of Multisensor Fusion Levels. In: National Symposium on Sensors and Sensor Fusion 2 (1990), Nr. 2, S. 21–34
- [116] ROLLMANN, Gerhard; BLÖCHER, Hans-Ludwig: The Impact of SARA for Further Advances in Automotive Microwave Sensing. In: *European Microwave Conference* (2007), Nr. 37, S. 1523–1525
- [117] SATTEL, Thomas; HESSE, Tobias; SONDERMANN-WÖLKE, Christoph: Automatisches Ausweichen in dynamischer Umgebung für Fahrerassistenzsysteme zur Kollisonsvermeidung. In: Tagung Aktive Sicherheit durch Fahrerassistenz (2008), Nr. 3
- [118] SAUST, Falko; WILLE, Joern Marten; LICHTE, Bernd; MAURER, Markus: Autonomous Vehicle Guidance on Braunschweig's Inner Ring Road within the Stadtpilot Project. In: *IEEE Conference on Intelligent Vehicles Symposium* (2011), S. 169–174
- [119] SCHNEIDER, Martin: Automotive Radar Status and Trends. In: German Microwave Conference (2005), S. 144–147
- [120] SCHNEIDER, Robert; BLÖCHER, Hans-Ludwig; STROHM, Karl M.: KOKON -Automotive High Frequency Technology at 77/79 GHz. In: European Microwave Conference (2007), Nr. 37, S. 1526–1529
- [121] SIEGLER, MG: Google Has A Secret Fleet Of Automated Toyota Priuses; 140,000 Miles Logged So Far. In: *Techcrunch.com* (2010)
- [122] SIMON, Dan: Optimal State Estimation. Wiley, 2006
- [123] SIMTD: Sichere Intelligente Mobilität Testfeld Deutschland. (2011). www.simtd.de
- [124] SKOLNIK, Merrill: Radar Handbook: Introduction to Radar Systems. McGraw-Hill Verlag, 2008

- [125] SKUTEK, Michael: Ein PreCrash-System auf Basis einer multisensorieller Umgebungserfassung, Technische Universität Chemnitz, Dissertation, 2006
- [126] SKUTEK, Michael; LINZMEIER, Dirk: Fusion von Sensordaten am Beispiel von Sicherheitsanwendungen in der Automobiltechnik. In: Automatisierungstechnik im Oldenbourg Verlag 7 (2005), Nr. 53, S. 295–305
- [127] SKUTEK, Michael; LINZMEIER, Dirk; APPPENRODT, Nils; WANIELIK, Gerd: A Precrash System based on Sensor Data Fusion of Laser Scanner and Short Range Radars. In: *Information Fusion* 2 (2005), S. 8pp.
- [128] SKUTEK, Michael; MEKHAIEL, Moheb ; WANIELIK, Gerd: A Precrash System based on Radar for Automotive Applications. In: Intelligent Vehicles Symposium (2003), S. 37–41
- [129] STATISTISCHES BUNDESAMT: Unfallentwicklung auf deutschen Straßen 2008. In: Statistisches Bundesamt Wiesbaden in Zusammenarbeit mit Gruppe Verkehrsunfälle (2008)
- [130] STATISTISCHES BUNDESAMT: Verkehrsunfälle 2010. In: Fachserie 8 Reihe 7 (2011)
- [131] STROHM, Karl; BLÖCHER, Hans-Ludwig; SCHNEIDER, Robert ; WENGER, Josef: Development of Future Short Range Radar Technology. In: *Radar Conference EURAD* (2005), S. 165–168
- [132] SUN, Zehang; MILLER, Ronald; BEBIS, George; DIMEO, David: A Real-Time Precrash Vehicle Detection System. In: *IEEE Workshop on Applications of Computer Vision* (2002), Nr. 6, S. 171–176
- [133] THRUN, Sebastian: Official Google Blog: What we're driving at. In: *Googleblog.blogspot.com* (2010)
- [134] THRUN, Sebastian u.a.: Stanley: The Robot that Won the DARPA Grand Challenge. In: Robotic Systems - Special Issue on the DARPA Grand Challenge 23 (2006)
- [135] TRANSPORTATION, Nevada D.: Assembly Bill No. 511 Committee on Transportation. (2011)
- [136] UNITED NATIONS: Vienna Convention on Read Traffic. In: United Nations Economic and Social Council's Conference (1968)
- [137] VERBAND DER SCHADENVERSICHERER E.V.: Fahrzeugsicherheit 90 Analyse von Pkw-Unfällen, Grundlagen für künftige Forschungsarbeiten. In: Büro für Kfz-Technik, München (1994)
- [138] WELCH, Greg; BISHOP, Gary: An Introduction to the Kalman Filter / University of North Carolina at Chapel Hill, Department of Computer Science. 2006. – Forschungsbericht

- [139] WENDER, Stefan: Multisensorsystem zur erweiterten Fahrzeugumfelderfassung, Universität Ulm, Fakultät für Ingenieurwissenschaften und Informatik, Dissertation, 2008
- [140] WENGER, Josef: Short Range Radar Being on the Market. In: European Microwave Conference (2007), Nr. 37
- [141] WINNER, Hermann; HAKULI, Stephan; WOLF, Gabriele (Hrsg.): Handbuch Fahrerassistenzsysteme. Vieweg + Teubner, 2009
- [142] XIE, Ming; CHEN, Hui; ZHANG, Xue Fei; GUO, Xi ; YU, Zhuo Ping: Development of Navigation System for Autonomous Vehicle to Meet the DARPA Urban Grand Challenge. In: *IEEE Intelligent Transportation Systems Conference* (2007), S. 767 – 772
- [143] YEOM, Seok-Won; KIRUBARAJAN, Thiagalingam; BAR-SHALOM, Yaakov: Track Segment Association, Fine-Step IMM and Initialization with Doppler for Improved Track Performance. In: Aerospace and Electronic Systems 40 (2004), Nr. 1, S. 293–309
- [144] ZHANG, Keshu; LI, X. Ron: Optimal Update with Out-of-Sequence Measurements for Distributed Filtering. In: International Conference on Information Fusion 2 (2002), Nr. 5, S. 1519–1526
- [145] ZHANG, Keshu; LI, X. Ron; CHEN, Huimin ; MALLICK, Mahendra: Multi-Sensor Multi-Target Tracking with Out-of-Sequence Measurements. In: International Conference on Information Fusion 1 (2003), Nr. 6, S. 672–679
- [146] ZUTHER, Sebastian; DICKMANN, Jürgen; DIETMAYER, Klaus: Influence of Sensor Resolution on Time Critical Automotive Applications. In: International Workshop on Intelligent Transportation (2010), Nr. 7
- [147] ZUTHER, Sebastian; DIETMAYER, Klaus: 360°-Environment Sensing and Signal Processing of an Automotive Pre-Crash Application. In: *IEEE International Con*ference on Vehicular Electronics and Safety (2009), S. 50–55

# Liste der eigenen Publikationen

#### Konferenzbeiträge

- [148] DICKMANN, Jürgen; APPENRODT, Nils; LÖHLEIN, Otto; MEKHAIEL, Moheb; MÄHLISCH, Mirko; MUNTZINGER, Marc. M.; RITTER, Werner; SCHWEIGER, Roland; HAHN, Stefan: Sensorfusion as a Key Technology for Future Driver Assistence Systems. In: VDI Fachtagung für Optische Technologien in der Fahrzeugtechnik (2008), Juni, Nr. 3
- [149] MUNTZINGER, Marc M.; AEBERHARD, Michael; DICKMANN, Jürgen; DIETMAYER, Klaus: Time-to-Collision Estimation for Pre-Crash with Out-of-Sequence Measurements. In: International Workshop on Intelligent Transportation (2010), März, Nr. 7, S. 149–154
- [150] MUNTZINGER, Marc M.; AEBERHARD, Michael; SCHRÖDER, Florian; SARHOLZ, Frederik; DIETMAYER, Klaus: Tracking in a Cluttered Environment with Out-of-Sequence Measurements. In: *IEEE International Conference on Vehicular Electronics and Safety* (2009), November, S. 56–61
- [151] MUNTZINGER, Marc M.; AEBERHARD, Michael; ZUTHER, Sebastian; SCHMID, Matthias; DICKMANN, Jürgen; DIETMAYER, Klaus: Reliable Automotive Pre-Crash System with Out-of-Sequence Measurement Processing. In: *IEEE Conference on Intelligent Vehicles Symposium* (2010), Juni, S. 1022–1027
- [152] MUNTZINGER, Marc M.; SCHRÖDER, Florian; ZUTHER, Sebastian; DIETMAYER, Klaus: Out-of-Sequence Measurements Treatment for an Automotive Pre-Crash Application. In: *IEEE International Conference on Intelligent Transportation Sys*tems (2009), Oktober, Nr. 12, S. 498–503
- [153] MUNTZINGER, Marc M.; ZUTHER, Sebastian ; DIETMAYER, Klaus: Probability Estimation for an Automotive Pre-Crash Application with Short Filter Settling Times. In: *IEEE Conference on Intelligent Vehicles Symposium* (2009), Juni, S. 411–416

[154] ZUTHER, Sebastian; BIGGEL, Matthias; MUNTZINGER, Marc M.; DIETMAYER, Klaus: Multi-Target Tracking for Merged Measurements of Automotive Narrow-Band Radar Sensors. In: *IEEE International Conference on Intelligent Transportation Systems* (2009), Oktober, Nr. 12, S. 455–460

### Patentanmeldungen

[155] MUNTZINGER, Marc M.; DICKMANN, Jürgen ; MÄHLISCH, Mirko: Verfahren und Vorrichtung zur Erfassung zumindest eines von einem Einsatzfahrzeug ausgehenden akustischen Sondersignals für ein Fahrzeug. In: *Deutsches Patentamt* (2010), Nr. DE102010022165A1

#### Betreute Studien- und Diplomarbeiten

- [156] AEBERHARD, Michael: Processing of Out-of-Sequence Measurements in Tracking for an Automotive Pre-Crash Application, L'École Supérieure d'Électricité Metz, Frankreich, Diplomarbeit, November 2009
- [157] BADEL, Maik: Sensorsynchronisation und Sensorfusion, Hochschule Regensburg, Studienarbeit, August 2008
- [158] BADEL, Maik: Pre-Crash mit erweiterter Kovarianz-Propagation und Evaluierung mittels Kontaktsensorik, Hochschule Regensburg, Diplomarbeit, September 2009
- [159] DE SOUZA, Gregory: Development of a Framework for Multi-Target Multi-Tracking Systems, University of Waterloo, Kanada, Diplomarbeit, Dezember 2007
- [160] SARHOLZ, Frederik: Konzeption und Realisierung einer Daten-Assoziation, Fakultät für Ingenieurwissenschaften und Informatik, Universität Ulm, Diplomarbeit, September 2008
- [161] SCHRÖDER, Florian: Konzeption und Realisierung der Zustandsschätzung dynamischer Systeme mit verzögerten Messungen, Fakultät für Ingenieurwissenschaften und Informatik, Universität Ulm, Diplomarbeit, Mai 2009

# Index

Aquivalente Messung, siehe Retrodiktion Filterinitialisierung, 37 Filterverfahren, siehe Schätzverfahren Antennenmonopuls, 17 **FMCW**, 18 ASIL, 167 FPFD, 63 Auslösewahrscheinlichkeit, 146 Ein-Schritt Problem, 63 Auswertung realer Fahrversuche, 143 Gleichungen, 66 l-Schritt Problem, 66 Bayesfilter, siehe Schätzverfahren Rechenaufwand, 70 Bewertungsmaße, 128 Speicherbedarf, 77 Buffering, siehe Messdatenverzögerung Fusion, 26 sequentielle-, 27 Datenassoziation, 39, siehe JPDA zentrale-, 26 Alle-Nachbarn-Verfahren, 41, 82 Datenassoziationsproblem, 81 Geschwindigkeitsfehler, 129 Ein-Nachbar-Verfahren, 40 GNN, 40 Suchbereiche, 40 Datenassoziationsproblem, 81 Hardwareaufbau, 171 Echtdatenauswertung, siehe Auswertung rea- $_{\rm IMM,\ 44}$ ler Fahrversuche Informationsfilter, siehe Schätzverfahren Ein-Schritt Verfahren, siehe Retrodiktion Experimente, siehe Auswertung realer Fahr- JIPDA, 105, 166 versuche JPDA, 41, 81, 82 Kalmanfiltergleichungen, 85 Fahrerassistenzsysteme, siehe FAS JPDAM, 105, 166 Fahrzeugsicherheit Aktive, 12 Kalibrierung Integrierte, 12 extrinsische-, 21 intrinsische-, 21 Passive, 11 Fahrzeugsicherheitssysteme, siehe FAS räumliche-, 20 FAS zeitliche-, 20 Überblick, 11 Kalmanfilter, siehe Schätzverfahren Einführung, 1, 11 Kollisionswahrscheinlichkeit, 129, siehe Si-Rechtliche Aspekte, 13 tuationsanalyse Zukünftige Systeme, 12 Komplexität Fernbereichsradar, siehe Radar **OOSM**, 67

OOSM mit JPDA, 103 Konsistenz, 130 Auswertungen, 136 Kontaktsensor Einführung, 22 Kovarianz, 29 l-Schritt Problem, siehe Retrodiktion Laserscanner Einführung, 21 Spezifikation, 19 Lidar, siehe Laserscanner Lineares Kalmanfilter, siehe Schätzverfahren Mehrmodusradar, siehe Radar Messdatenverzögerung, 45 Gleichungen, 47 Rechenaufwand, 68 Speicherbedarf, 76 Messmodell, 36 Messunsicherheiten, 19 Nahbereichsradar, siehe Radar NEES, siehe Konsistenz Objektverwaltung, 41 OOSM Ausblick, 166 Einführung, 2, 43 FPFD, siehe FPFD IMM, 44 JPDA Aquivalente Messung, 96 Einführung, 81 **FPFD**, 96 Laufzeit, 104 Modifizierte Retrodiktion, 86 Problemformulierung, 86 Speicherbedarf, 104 Kritik, 165 Messdatenverzögerung, siehe Messdatenverzögerung Problemformulierung, 2 Reprozessierung, siehe Reprozessierung Retrodiktion, siehe Retrodiktion

Out-of-Sequence Measurements, siehe OOSM PDA, 41, 82 Positionsfehler, 128 Pre-Crash Auslösewahrscheinlichkeit, 146 Einführung, 14 Entscheidungsmodul, 107 Gesamtauswertung, 157 Heutige Systeme, 15 Simulation, 122 Situationsanalyse, 107 Testkatalog, 152 Prozessmodell, 33 kontinuierliches, 62 Puls-Doppler, 17 Radar Einführung, 16 Fernbereichs-, 18 Frequenzregulierung, 16 Mehrmodus-, 18 Nahbereichs-, 17 Spezifikation, 19 Receiver Operating Characteristic, siehe ROC, siehe ROC Reprocessing, *siehe* Reprozessierung Reprozessierung, 47 Gleichungen, 47 Rechenaufwand, 69 Speicherbedarf, 76 Retrodiktion, 48 Eigenschaften, 61 Ein-Schritt Problem, 50 Gleichungen, 57, 58 Optimale Lösung, 50 Suboptimale Lösung, 57 Mehr-Schritt Problem, 58 Aquivalente Messung, 58 Gleichungen, 62 Rechenaufwand, 69 Speicherbedarf, 76 RMSE Auswertungen, 132, 138

Geschwindigkeitsfehler, 129

Positionsfehler, 128 ROC, 122, 131 Auswertungen, 140, 157 Schätzfehlerkovarianz Auswertungen, 143 Volumen, 128 Schätzfehlerprojektion, siehe Situationsanalvse Schätzverfahren, 27 Bayesfilter, 28 Informationsfilter, 32 Kalmanfilter, 28 -mit JPDA-Datenassoziation, 85 Datenassoziation, 39 Filterinitialisierung, 37 lineares-, 29 Messmodell, 36 Objektverwaltung, 41 Prozessmodell, 33 Sensordatenfusion, siehe Fusion Simulationsergebnisse, 98, 122, 131 Situationsanalyse, 107 Schätzfehlerprojektion, 111 Linearisierung, 112 Partikel, 117 räumliche-, 112, 115, 117 Sigma-Punkte, 114 zeitliche-, 114, 116, 118 Zustandsprojektion, 108 räumliche-, 109 zeitliche-, 110 SNN, 40 Time-to-Collision, siehe TTC TTC, 129 Auswertungen, 148 Unfallstatisik, 13 Unfallstatistik, 1 Urbanisierung, 1 Versuchsfahrzeug, 15 Vorwärts-Prädiktion Fusion und Dekorrelation, siehe FPFD

Wiederaufbereitung, siehe Reprozessierung

Zustandsprojektion, siehe Situationsanalyse Zustandsschätzung Algorithmik, siehe Schätzverfahren Einführung, 25