

# Heterogene Sensordatenfusion zur robusten Objektverfolgung im automobilen Straßenverkehr

Dissertation

Schriftliche Arbeit zur Erlangung des  
Doktorgrades in den Ingenieurwissenschaften  
an der Fakultät II - Informatik, Wirtschafts- und  
Rechtswissenschaften der  
Carl von Ossietzky-Universität Oldenburg

von

**Dirk Stüker**

Fertigstellung der Arbeit: 17. November 2003  
Tag der Disputation: 02. Februar 2004



*Für Marianne und Helmut*



# Vorwort

Die vorliegende Arbeit entstand während meiner dreijährigen Tätigkeit als Doktorand in der Elektronikforschung der Volkswagen AG in Wolfsburg. Teile sind im Rahmen der Forschungsinitiative INVENT (Intelligenter Verkehr und nutzergerechte Technik) mit dem Ziel, den Verkehr der Zukunft sicherer und effektiver zu machen, entstanden und wurden durch Mittel des Bundesministeriums für Bildung und Forschung unterstützt.

Meinem Doktorvater Prof. Dr.-Ing. Peter Jensch danke ich für die Möglichkeit der Promotion, die Förderung dieser Arbeit und die anregenden Gespräche.

Ebenso gilt mein Dank Prof. Dr.-Ing. Klaus Dietmayer für die freundliche Übernahme des Koreferats.

Für die freundliche Atmosphäre und die vielen fachlichen Gespräche bedanke ich mich bei meinen Kollegen der Fahrerassistenzelektronik. Mein besonderer Dank gilt Dr.-Ing. Alexander Kirchner und Dipl.-Ing. Kristian Weiß für die wertvollen fachlichen Diskussionen und das Korrekturlesen der Arbeit. Dipl.-Ing. Thomas Engel danke ich für die technische Unterstützung und seine Hilfsbereitschaft. Dem Team um Klaus Kowalewicz bin ich dankbar für den Aufbau und die Modifikationen des Versuchsträgers.

Die Dissertation wäre ohne die Geduld und Rücksicht und die stetige Unterstützung durch meine Frau Birke nicht zustande gekommen. Dafür bedanke ich mich von Herzen. Meiner gesamten Familie danke ich für ihr Verständnis während der Entstehung der Arbeit.



# Zusammenfassung

Zukünftige Fahrerassistenzsysteme benötigen neben der Information über den aktuellen Fahrzustand eine Umgebungserfassung und -modellierung. Je nach Komplexität der Assistenzfunktion wird diese einen unterschiedlichen Detaillierungsgrad aufweisen, wobei für Sicherheitssysteme – wie beispielsweise einen automatischer Bremsengriff – die höchsten Anforderungen gelten. Sowohl die geometrischen als auch die dynamischen Merkmale potenzieller Kollisionspartner müssen möglichst genau bestimmt werden.

Da keine heute verfügbare Sensorik in der Lage ist, allen Anforderungen gerecht zu werden, ist die Sensordatenfusion von heterogenen Sensoren erforderlich. Hierbei können die Vorteile von Radarsensoren bei der Bestimmung der dynamischen Objekteigenschaften mit den Vorteilen optischer Systeme bei der Bestimmung der geometrischen Merkmale kombiniert werden. Für eine optimale Fusion sind jedoch unterschiedliche Aspekte zu berücksichtigen, von denen im Anschluss an einen umfassenden Literaturüberblick drei behandelt werden: Die Verarbeitung asynchroner Sensordaten, ein verbessertes Sensormodell insbesondere für optische Sensoren und eine Fusionsarchitektur für variable Beobachtbarkeit von Zustandsgrößen.

Im Rahmen der Arbeit wird auf konkrete Modifikationsmöglichkeiten einer Kalman-Filter-Architektur eingegangen, um die Objektverfolgung insbesondere beim Wechsel der Perspektive – wie sie beispielsweise bei Überholmanövern auftritt – zu stabilisieren. Die Vorteile der vorgestellten Algorithmen werden anhand von realen Messdaten demonstriert.





# Abstract

Future driver assistance systems will require not only information about the current state of a vehicle but also a perception and modelling of the environment. Depending on the complexity of the assistance function it will have a variable scale of details. Safety systems – like automatic braking – have to meet the highest requirements. The geometric as well as the dynamic parameters of potential collision partners have to be calculated as precisely as possible.

Because no state-of-the-art sensor device is able to meet the whole variety of requirements, a sensor data fusion of heterogenous sensors is therefore essential. Here the advantages of radar sensors measuring the dynamic properties of objects can be combined with the advantages of optical sensors measuring their geometric dimension. In order to achieve an optimal fusion, however, different aspects have to be considered. Three of those are covered by this thesis and will be presented after a detailed bibliography: The processing of asynchronous sensor data, an improved sensor model for optical sensors in particular, and finally a fusion architecture for a varying observability of the state vector.

This thesis will show different possibilities to modify a Kalman filter architecture in order to stabilize object tracking especially when the perspective is changing – which is typical for overtaking manoeuvres. The advantages of the proposed algorithms will be demonstrated on the basis of real sensor data.



# Inhaltsverzeichnis

<b>1. Einleitung</b>	<b>1</b>
1.1. Thematik und Hintergrund . . . . .	2
1.2. Zielsetzung der Arbeit . . . . .	2
1.3. Gliederung . . . . .	3
<b>2. Sensorfusion für Fahrerassistenzsysteme</b>	<b>5</b>
2.1. Einführung und Begriffsbestimmung . . . . .	5
2.2. Sensorik . . . . .	7
2.2.1. Bildverarbeitung . . . . .	7
2.2.2. Radar . . . . .	8
2.2.3. Laser . . . . .	9
2.2.4. Gegenüberstellung . . . . .	10
2.3. Stand der Forschung . . . . .	11
2.3.1. LACOS . . . . .	11
2.3.2. Das Projekt Autonomes Fahren . . . . .	12
2.3.3. ARGO . . . . .	12
2.3.4. CHAMELEON . . . . .	12
2.3.5. CARSENSE . . . . .	13
2.3.6. Weitere Arbeiten . . . . .	13
2.4. Blick in die Zukunft . . . . .	13
<b>3. Verfahren zur Sensordatenfusion</b>	<b>15</b>
3.1. Mehrzielverfolgung mit einem Einzelsensor . . . . .	16
3.2. Mehrzielverfolgung mit einem Sensornetzwerk . . . . .	18
3.2.1. Synchrone Sensoren . . . . .	19
3.2.2. Asynchrone Sensoren . . . . .	21
3.3. Filter und Schätzverfahren . . . . .	24
3.3.1. Lineare stochastische Systeme . . . . .	25
3.3.2. Kalman-Filter und Varianten . . . . .	28
3.3.3. Information-Filter . . . . .	38
3.3.4. Filter-Adaption . . . . .	39
3.3.5. Multi-Modell-Verfahren . . . . .	42
3.4. Assoziationsverfahren . . . . .	46
3.4.1. Suchbereiche . . . . .	47
3.4.2. Zuweisungsverfahren . . . . .	50
3.5. Initialisierung . . . . .	58

3.6. Trackverwaltung . . . . .	59
<b>4. Versuchsträger und Fusionsarchitektur</b>	<b>61</b>
4.1. Versuchsträger . . . . .	61
4.2. Fusionsarchitektur . . . . .	63
4.2.1. Messdatenpuffer mit Track-Prädiktion . . . . .	63
4.2.2. Filteralgorithmus . . . . .	68
4.2.3. Korrelation der Sensordaten . . . . .	69
<b>5. Assoziation bei variabler Beobachtbarkeit</b>	<b>71</b>
5.1. Objektmodell und zeitliche Prädiktion . . . . .	71
5.2. Beobachtbarkeit des Zustandsvektors . . . . .	75
5.2.1. Beobachtbarkeit durch die verwendete Sensorik . . . . .	76
5.3. Sensormodell zur robusten Assoziation . . . . .	79
5.3.1. Rohdatenanalyse . . . . .	80
5.3.2. Assoziation . . . . .	82
5.3.3. Messwertprädiktion . . . . .	89
5.3.4. Adaption der Messunsicherheit . . . . .	94
5.4. Zusammenfassung . . . . .	107
<b>6. Adaptive Form- und Dynamikschätzung</b>	<b>111</b>
6.1. Problemanalyse . . . . .	111
6.1.1. Variabler Informationsgehalt . . . . .	112
6.1.2. Unbekannter maximaler Informationsgehalt . . . . .	113
6.1.3. Einfluss der Dimension des Zustandsvektors . . . . .	113
6.1.4. Konsequenzen für die Objektverfolgung . . . . .	114
6.2. Fusionsarchitektur für variable Beobachtbarkeit . . . . .	115
6.2.1. Funktionsweise des Filters für reduzierte Zustandsvektoren . . . . .	116
6.2.2. Partielle Beobachtung . . . . .	119
6.2.3. Erweiterung des Zustandsvektors um neue Merkmale . . . . .	122
6.2.4. Zusammenfassung der Filtergleichungen . . . . .	124
6.3. Demonstration an realen Messdaten . . . . .	126
6.3.1. Minimalinitialisierung . . . . .	126
6.3.2. Zustandserweiterung . . . . .	127
6.3.3. Partielle Assoziation . . . . .	127
6.3.4. Integration . . . . .	128
6.3.5. Quantitative Bewertung . . . . .	129
6.4. Zusammenfassung . . . . .	131
<b>7. Zusammenfassung und Ausblick</b>	<b>133</b>
7.1. Zusammenfassung . . . . .	133
7.2. Ausblick . . . . .	135
<b>A. Symbole und mathematische Notationen</b>	<b>137</b>
A.1. Konventionen . . . . .	137
A.2. Mathematische Notationen . . . . .	137
A.3. Symbolverzeichnis . . . . .	137

---

A.3.1. Skalare . . . . .	138
A.3.2. Mengen . . . . .	138
A.3.3. Vektoren und Vektorfunktionen . . . . .	138
A.3.4. Matrizen . . . . .	139
<b>Literaturverzeichnis</b>	<b>141</b>
<b>Sachregister</b>	<b>149</b>



# Abbildungsverzeichnis

3.1. Schematische Darstellung möglicher Fusionsebenen von zwei Sensoren	16
3.2. Rekursives Mehrziel-Tracking-System	17
3.3. Fusion synchronisierter Sensoren	19
3.4. Sensor-zu-Sensor-Track-Fusion	22
3.5. Asynchrone Sensor-zu-System-Track-Fusion	23
3.6. Verschiedene Schätzwerte der Dichtefunktion	26
3.7. Gegenüberstellung von EKF und UKF	32
3.8. Zustandskorrektur durch einen Pseudomesswert	36
3.9. Flussdiagramm des IMM-Algorithmus	43
3.10. Beobachtungen in überlappenden Suchbereichen	48
3.11. Klassifikation von Zuordnungsverfahren	50
3.12. Ergebnisse unterschiedlicher Zuordnungsverfahren	52
3.13. Durch JPDAF aufzulösende Konfliktsituation	54
3.14. Durch das JPDAF berücksichtigte Zuordnungen	55
3.15. Verbundhypothese	56
4.1. Versuchsträger mit heterogener Sensorik zur Umgebungserfassung	62
4.2. Systemarchitektur von Fahrerassistenzsystemen	64
4.3. Fusionsarchitektur mit Messdatenpuffer	65
4.4. Funktionsweise des Messdatenpuffers	67
5.1. Reales Fahrzeug und umschreibender Quader	72
5.2. Visualisierung des Objekt-Zustandsvektors	77
5.3. Lasermesswerte eines passierenden Fahrzeuges	81
5.4. Positions- und Dynamikschätzung des EKF	86
5.5. Formschätzung des EKF	87
5.6. NIS und ANIS des EKF	88
5.7. Einfluss der Zustandsschätzung auf die Messwertprädiktion	90
5.8. Beispiel einer Mehrfach-Messwertprädiktion	93
5.9. Positions- und Dynamikschätzung mit Mehrfach-Messwertprädiktion	95
5.10. Formschätzung mit Mehrfach-Messwertprädiktion	96
5.11. NIS und ANIS mit Mehrfach-Messwertprädiktion	97
5.12. Häufig detektierte Konturpunkte des Laserscanners	98
5.13. Erkennung der Hypothese „Objektkante“	99
5.14. Erkennung von Hypothese „flacher Aspektwinkel“	100
5.15. Hauptachsentransformation	101

---

5.16. Kovarianzadaption über die inverse Hauptachsentransformation . . . . .	103
5.17. Kovarianzadaption an einem konkreten Beispiel . . . . .	104
5.18. Kovarianzadaption am Rand des Sensor-Erfassungsbereiches . . . . .	105
5.19. Positions- und Dynamikschätzung mit MFP und Kovarianz-Adaption	106
5.20. Formschätzung mit MFP und Kovarianzadaption . . . . .	107
5.21. NIS und ANIS mit MFP und Kovarianz-Adaption . . . . .	108
6.1. Kalman-Filter-Fusionsarchitektur für variable Beobachtbarkeit . . . . .	115
6.2. Beispiel einer Laserscanner-Messung . . . . .	121
6.3. Verschiebung des Bezugspunktes durch Zustandserweiterung . . . . .	123
6.4. Minimalinitialisierung . . . . .	126
6.5. Zustandserweiterung . . . . .	127
6.6. Schematische Darstellung der partiellen Assoziation . . . . .	128
6.7. Einschränkung der geschätzten Zustandsgrößen . . . . .	128
6.8. Positions- und Dynamikschätzung mit Fusionsarchitektur für variable Beobachtbarkeit . . . . .	130
6.9. Formschätzung mit Fusionsarchitektur für variable Beobachtbarkeit .	131
6.10. NIS und ANIS mit Fusionsarchitektur für variable Beobachtbarkeit .	132



# 1. Einleitung

Der verstärkte Einzug von Elektroniksystemen hat in den letzten Jahren zu einer Flut von Innovationen im Fahrzeug geführt [Grell 2003]. Eine treibende Kraft ist das Bestreben, die Sicherheit für die Insassen eines Fahrzeug und andere Verkehrsteilnehmer stetig zu erhöhen. Während das Potenzial passiver Sicherheitssysteme wie Sicherheitsgurt und Airbag weitgehend erschöpft ist, stehen die Möglichkeiten der aktiven Sicherheit erst am Anfang.

Systeme zur Verbesserung der Fahrzeugdynamik wie das Anti-Blockiersystem (ABS), das Elektronische Stabilitätsprogramm (ESP) oder der Bremsassistent sind bereits für viele Fahrzeugmodelle im Markt erhältlich. Diese Systeme unterstützen den Fahrer basierend auf Informationen über den eigenen Fahrzustand bei der Fahrzeugführung. Erst die sensorische Erfassung der Fahrumgebung ermöglicht komplexe Fahrerassistenzsysteme, die sich in drei Klassen unterteilen lassen:

- Komfortsysteme zur Vereinfachung der Fahraufgabe: Applikationen wie die automatische Distanzregelung (ADR) und der Spurhalteassistent sowie adaptive Frontscheinwerfer und Nachtsicht entlasten den Fahrer.
- Warnsysteme zur Vermeidung von Fahrfehlern – die Spurverlassenswarnung ist ein Beispiel für diese Gattung.
- Sicherheitssysteme zur Vermeidung oder Verminderung von Unfallfolgen; Pre-crash-Systeme wie ein automatischer Bremsengriff oder automatische Ausweichmanöver schaffen neues Sicherheitspotenzial.

Die Basis aller Applikationen bildet die Umgebungserfassung und -modellierung, dabei ist in Abhängigkeit von der Komplexität der Assistenzfunktion ein unterschiedlicher Detaillierungsgrad des Modells erforderlich. Während einfache Assistenzfunktionen wie die Automatische Distanzregelung bereits mit einem einzelnen Radarsensor zu realisieren sind, wird für Sicherheitsfunktionen ein genaueres Abbild der Fahrumgebung benötigt. Sollen dynamische und geometrische Merkmale anderer Verkehrsteilnehmer bestimmt werden, ist es sinnvoll, die Vorteile unterschiedlicher Sensoren zu kombinieren und die Daten dieser heterogenen Sensorik miteinander zu fusionieren. Unabhängige Messmerkmale stabilisieren die Objektverfolgung und schaffen die Möglichkeit, Objekte durch ein mehrdimensionales Formmodell zu beschreiben.

## 1.1. Thematik und Hintergrund

Die Entwicklung von Algorithmen zur Objektverfolgung hatte zunächst ihren Schwerpunkt in der militärischen Verfolgung von Flugobjekten und seit mehr als vierzig Jahren wird an Verbesserungen von überwiegend radarbasierten Verfahren gearbeitet. Aufgrund der hohen Anforderungen der Automobilbranche wie einem minimalen Bauraum bei gleichzeitig geringen Kosten hat die Fahrumgebungserfassung eine vergleichsweise kurze Historie, die Mitte der 90er Jahre mit der Verfügbarkeit leistungsfähiger Signalprozessoren beginnt [Meinecke 2001]. Mit der Entwicklung von Radar-Sensoren für die Automobilindustrie liegt es nahe, die bekannten Tracking-Algorithmen entsprechend zu adaptieren. Es zeigt sich jedoch, dass hierbei grundsätzlich neue Phänomene zu berücksichtigen sind, die aus den besonderen Verhältnissen im Straßenverkehr resultieren [Stüker und Schmidt 2003]. Dies gilt insbesondere dann, wenn neben Radar-Sensoren auch optische Sensoren genutzt werden:

- Die Dimension von Flugobjekten ist vernachlässigbar klein gegenüber der Entfernung zum Sensor. Sprünge des Radar-Reflexionszentrums sind daher vom Messrauschen nicht zu unterscheiden. Dies ist bei der Verfolgung von Fahrzeugen nicht der Fall. Die Messgenauigkeit und Auflösung der Sensoren erfordert eine Zuordnung zur Fahrzeugkontur, um Schätzfehler zu vermeiden.
- Im realen Straßenverkehr liegt eine deutlich höhere Objektdichte vor. Die Zuordnung von Messwerten zu Objekten gestaltet sich dadurch sehr viel schwieriger.
- (Teil-)verdeckungen führen dazu, dass nicht alle Objektmerkmale (zum Beispiel Breite und Länge eines Fahrzeugs) gleichzeitig beobachtbar sind.

## 1.2. Zielsetzung der Arbeit

Die Arbeit befasst sich mit der Fusion von Sensordaten, wobei der Schwerpunkt auf einer robusten Objektverfolgung bei gleichzeitiger Schätzung der Form- und Dynamikparameter liegt. Weil die Sensordaten unterschiedlicher objekterkennender Sensoren mit verschiedenen Messmerkmalen verarbeitet werden, handelt es sich um eine heterogene Sensordatenfusion. Die Robustheit der Objektverfolgung ist dadurch gekennzeichnet, dass die Zuordnung der Messdaten zu einem Objekt trotz unterschiedlicher Randbedingungen wie wechselnde Perspektiven, Verdeckungen und variierende Messmerkmale möglich ist. Drei Aspekte werden in diesem Zusammenhang betrachtet: Die Verarbeitung asynchroner Sensordaten, ein verbessertes Sensormodell insbesondere für optische Sensoren und eine Fusionsarchitektur für variable Beobachtbarkeit von Zustandsgrößen.

Die Verarbeitung der asynchronen Sensordaten muss die unterschiedlichen Messzeitpunkte und Zykluszeiten berücksichtigen. Bei dem entwickelten Verfahren erfolgt eine nach den Messzeitpunkten sortierte Einbringung der Sensordaten in die Fusion

unter Berücksichtigung der erwarteten Messzeitpunkte der einzelnen Sensoren, wobei eine Betrachtung der verursachten zusätzlichen Verzögerung sowie des minimalen und maximalen Zeitversatzes zur Realzeit erfolgt. Durch eine zeitliche Prädiktion der fusionierten Sensordaten lässt sich die Verzögerung weiter verkleinern. Das Verfahren erweist sich gegenüber dem aus der Literatur bekannten Ansatz der Prädiktion von Sensordaten auf einen gemeinsamen Fusionszeitpunkt als vorteilhaft, weil die zeitliche Prädiktion auf der Basis eines komplexen Objektmodells unter Einbeziehung der Informationen aus allen fusionierten Sensordaten erfolgt.

Mögliche Verbesserungen des Sensormodells ergeben sich bei der Messwertprädiktion und der Bestimmung des Messrauschens. Aus der Literatur sind Multi-Modell-Verfahren und ein adaptives Prozessrauschen für den Objekt-Zustandsvektor bekannt. Diese Verfahren sind ungeeignet, die aufgrund eines bestimmten Aspektwinkels variierenden Messmerkmale zu beschreiben. In einem neuen Ansatz wird dargestellt, wie ein Multi-Hypothesenansatz auf die Messwertprädiktionen angewendet und das Messrauschen adaptiert werden kann. Die Bestimmung des Messrauschens in einer bestimmten Raumrichtung wird vorgestellt.

Schließlich wird auf die Besonderheiten der gleichzeitigen Form- und Dynamikschätzung eingegangen, wobei der unterschiedliche Informationsgehalt von Messvektoren – einerseits durch eine heterogene Sensorik, andererseits durch variierende Betrachtungswinkel – eine besondere Rolle spielt. Die aus der Literatur bekannten Verfahren unterschiedlicher Objektmodelle für unterschiedliche Bewegungszustände eines Objektes können auf die Problematik nicht übertragen werden, da der Zusammenhang mit der Messwertprädiktion nicht berücksichtigt wird. Ein neues adaptives Verfahren, das die Beobachtbarkeit von Zustandsgrößen des Zustandsvektors bei der Schätzung berücksichtigt, wird dargestellt. Das Objektmodell wird hierbei auf die beobachtbaren Merkmale reduziert und im Falle von neu beobachteten Merkmalen dynamisch erweitert. Eine Assoziation von unterschiedlich dimensionalen Messvektoren und Prädiktionen auf Basis der gemeinsamen Merkmale wird realisiert.

Neben der theoretischen Beschreibung werden die vorgestellten Algorithmen anhand von realen Messdaten verifiziert.

## 1.3. Gliederung

Der Einleitung schließt sich in [Kapitel 2](#) eine Übersicht über den derzeitigen Entwicklungsstand der Sensorfusion für Fahrerassistenzsysteme an. Nach einer kurzen Einführung und Begriffsbestimmung wird die aktuell verfügbare Sensorik vorgestellt. Verschiedene Konzepte zur Fahrumgebungserfassung werden anhand von relevanten Projekten erläutert. Mit einer Beschreibung aktueller Entwicklungstrends schließt das Kapitel.

In [Kapitel 3](#) erfolgt eine detaillierte Beschreibung bekannter Verfahren zur Objektverfolgung. Hierbei werden ausgehend von der Objektverfolgung mit einem Einzelsensor die Funktionskomponenten der multisensoriellen Datenerfassung vorge-

stellt. Die Darstellung unterschiedlicher Synchronisationskonzepte sowie verschiedener Filter- und Assoziationsverfahren bildet den Schwerpunkt des Kapitels.

[Kapitel 4](#) umfasst die Beschreibung des Versuchsträgers und die durch die Sensorik gegebenen Randbedingungen wie Erfassungsbereich, Reichweite und Zykluszeiten. Es wird eine Fusionsarchitektur mit Messdatenpuffer erläutert, die es ermöglicht, alle Sensordaten in zeitlicher Reihenfolge in die Fusion einzubringen und gleichzeitig die hierdurch unvermeidlichen Verzögerungen zu minimieren.

Auf die Möglichkeiten einer verbesserten Assoziation insbesondere bei optischen Sensoren durch ein erweitertes Sensormodell geht [Kapitel 5](#) ein. Hierzu wird zunächst das gewählte Objektmodell eingeführt und dessen Beobachtbarkeit durch die verwendete Sensorik untersucht. Durch eine veränderte Messwertprädiktion und eine gezielte Modifikation der Messunsicherheit wird eine robustere Objektverfolgung bei wechselnden Perspektiven erzielt. Voraussetzung für die angewendeten Verfahren ist, dass die Objektkontur über die initialen Messdaten beobachtbar ist. Eine Demonstration der erreichten Verbesserungen erfolgt am Beispiel von Laserscannerdaten.

Dem variierenden Informationsgehalt von Messvektoren widmet sich [Kapitel 6](#), wobei die partielle Beobachtung des Objekt-Zustandsvektors und dessen sukzessive Erweiterung im Vordergrund stehen. Das Kapitel enthält ein neues Kalman-Filter-Verfahren, das sich für das Tracking mit optischen Sensoren ebenso eignet wie für die Fusion heterogener Sensordaten. Die Verifikation anhand von realen Messdaten schließt das Kapitel ab.

In [Kapitel 7](#) findet sich eine Zusammenfassung der Arbeit und ein Ausblick auf zukünftige Arbeiten.

## 2. Sensorfusion für Fahrerassistenzsysteme

### 2.1. Einführung und Begriffsbestimmung

Unter einer *Beobachtung* (auch Messung) versteht man die Erfassung der Umgebung durch einen Sensor. Das Resultat einer Messung ist ein Messvektor, der sich aus den detektierten Messmerkmalen und dem Messzeitpunkt zusammensetzt, der für die Schätzung dynamischer Prozesse benötigt wird. Eine Beobachtung reduziert die Realwelt auf die durch den Sensor detektierbaren Merkmale.

Fahrerassistenzsysteme benötigen eine Repräsentation des realen Fahrzeugumfeldes in einem Rechner. Das *Umfeldmodell* enthält hierzu eine Menge mathematischer Beschreibungen von relevanten Objekten, aus der bei einer Detektion eine Instanz erzeugt wird. Die *Objektmodelle* beinhalten, über welche Zustandsgrößen (Form, Dynamik) ein Objekt repräsentiert wird, und stellen damit eine abstrakte Beschreibung der Realwelt dar.

Ziel der *Objektverfolgung*<sup>1</sup> ist es, die Beobachtungen eines Objektes so zusammenzufassen, dass das Ergebnis dem der Einzelmessung überlegen ist. Im Fall der Einzelzielverfolgung<sup>2</sup> werden alle Beobachtungen bei der Zustandsschätzung für das einzige verfolgte Objekt berücksichtigt. Bei der Mehrzielverfolgung<sup>3</sup> muss zuvor noch eine *Datenassoziation*, d. h. die Zuordnung von Beobachtungen zu Objekten, erfolgen.

Die Daten eines einzelnen Sensors sind häufig nicht ausreichend, um komplexe Objektmodelle zu stützen, sodass mehrere Sensoren in einem Netzwerk genutzt werden. Die Kombination von Beobachtungen verschiedener Sensoren zur Bestimmung des Objektzustandes bezeichnet man als *Fusion*.

Die Fusion kann unterschiedliche Zielsetzungen haben [Kirchner u. a. 2001]:

1. Die Erhöhung der Schätzgenauigkeit durch Verwendung der Daten von mehreren Sensoren mit identischen Erfassungsbereichen.
2. Die Vergrößerung des Gesamterfassungsbereiches durch unterschiedliche Detektionsbereiche.

---

<sup>1</sup> engl.: Target Tracking

<sup>2</sup> engl.: Single Target Tracking STT

<sup>3</sup> engl.: Multiple Target Tracking MTT

3. Eine erhöhte Ausfallsicherheit durch die Verwendung von mehreren Sensoren.
4. Eine erhöhte Robustheit gegenüber Umweltbedingungen durch Verwendung verschiedener Sensorprinzipien (beispielsweise Radar, Laser).
5. Die Erzeugung neuer Information durch die Kombination von unterschiedlichen Sensoren.
6. Eine Verbesserung der Informationsgewinnung durch Verarbeitung auf verschiedenen Abstraktionsebenen.
7. Die Erzeugung eines konsistenten Modells durch die Nutzung von divergenten Sensoren.

Vor allem in der Automobilbranche kommen zusätzliche Aspekte hinzu. So kann es kostentechnisch günstiger sein, einen teureren Sensor durch mehrere preiswerte zu ersetzen, wenn sich durch die Fusion die Datenqualität erhalten lässt. Ferner verhindern Designaspekte den Einsatz bestimmter Sensoren, sodass andere Sensoren vergleichbare Daten liefern müssen.

Die Sensorcharakteristik ist entscheidend für die *Fusionsarchitektur*, daher ist eine entsprechende Klassifikation nützlich. Generell unterscheidet man zwischen *homogenen* und *heterogenen* Sensornetzwerken. Erstere sind dadurch gekennzeichnet, dass alle Sensoren dasselbe physikalische Messprinzip verwenden und daher denselben Einschränkungen (z. B. Genauigkeit und Reichweite) unterliegen. In einem heterogenen Sensornetzwerk hingegen kommen unterschiedliche Sensoren zum Einsatz, sodass ggf. Schwächen eines Sensors durch die Stärken eines anderen ausgeglichen werden können.

Man unterscheidet bei der Fusion folgende Typen:

- *Redundante oder kompetitive Fusion*: Die Daten-Akquisition erfolgt durch mehrere identische Sensoren mit demselben Erfassungsbereich. Die Genauigkeit der Beobachtung lässt sich durch die zusätzlichen Messwerte steigern (das heißt der Unsicherheitsbereich verkleinert sich). Zudem ist eine erhöhte Ausfallsicherheit gegeben, da durch den Ausfall eines Sensors weder der Erfassungsbereich noch der Merkmalsraum der Beobachtungen eingeschränkt wird.
- *Komplementäre Fusion*: Wenn die Erfassungsbereiche der fusionierten Sensoren keine Überlappungsbereiche aufweisen, spricht man von komplementärer Fusion. Durch die Kombination der Sensordaten vergrößert sich der Gesamterfassungsbereich. Man spricht auch von komplementärer Fusion, falls sich die beobachteten Merkmale unterscheiden. Dies ist beispielsweise der Fall, wenn ein Sensor die Objekthöhe und ein anderer die Objektbreite vermisst. Die Fusion erweitert hier den Merkmalsraum der Beobachtung. Der Ausfall eines Sensors bei einer (ausschließlich) komplementären Fusion bewirkt stets einen Informationsverlust. Entweder reduziert sich der Erfassungsbereich oder die Anzahl der beobachteten Merkmale.

- *Kooperative Fusion*: Ergibt sich durch die Kombination von Beobachtungen verschiedener Sensoren ein *neues* Merkmal, so bezeichnet man die Fusion als kooperativ. Ein Beispiel hierfür stellt die Triangulation zweier entfernungs-messender Sensoren dar. Erst durch die Kombination beider *Entfernungen* lässt sich die *Position* eines Objektes ermitteln.

Häufig lässt sich die Fusionsarchitektur nicht eindeutig klassifizieren, da Erfassungsbereiche und Merkmale teilweise identisch, teilweise komplementär sind.

## 2.2. Sensorik

Für den automobilen Einsatz zur Fahrumgebungserfassung steht eine Vielzahl von Sensoren zur Verfügung, die sowohl in den detektierten Merkmalen als auch dem Messprinzip differieren. Einige der Technologien sind bereits in Serie umgesetzt, andere befinden sich in der Entwicklungsphase für den baldigen Serieneinsatz, der Großteil ist jedoch noch im Vorserien- oder Forschungsstadium. Drei Technologien sind derzeit Schwerpunkt unterschiedlichster Projekte zur Fahrumgebungserfassung: Radar, Bildverarbeitung und Laser [Vukotich und Kirchner 2001]. Auch innerhalb der Technologien ist eine Differenzierung möglich, sodass im Folgenden kurz auf die wesentlichen Merkmale eingegangen wird.

### 2.2.1. Bildverarbeitung

Der Mensch als Fahrzeugführer nimmt die wesentlichen Informationen über die Umgebung seines Fahrzeugs visuell wahr. Es scheint daher naheliegend, die menschliche Wahrnehmung durch geeignete Sensoren nachzubilden und die für das Verkehrsgeschehen relevanten Informationen durch entsprechende Algorithmen zu gewinnen. CCD<sup>4</sup>-Chips werden bereits in hohen Stückzahlen gefertigt und erfassen die Helligkeitsdaten eines rechteckigen Bildes. Der Erfassungsbereich der Kamera ist durch die Chipfläche und die vorgeschaltete Optik festgelegt (circa 30°-45°, je nach Anwendung). Durch die Verwendung von entsprechenden Filtern ist eine Farbdetektion möglich. Häufig weist das aufgenommene Bild sehr hohe Helligkeitsunterschiede auf (z. B. Tunneleinfahrt). In diesem Fall ist die Dynamik herkömmlicher CCD-Kameras (ca. 50-70 dB) nicht ausreichend. Neuere CMOS-Chips erreichen bereits 120 dB, während das menschliche Auge etwa 200dB Dynamik aufweist. Neben dem bildgebenden Sensor ist jedoch die nachfolgende Verarbeitung Gegenstand intensiver Forschungen. Hierbei muss zwischen zwei Systemansätzen unterschieden werden:

**Mono** Mono-Bildverarbeitungsalgorithmen arbeiten zumeist modellbasiert, sodass für Objekte im Bild (beispielsweise Fahrzeuge) ein geeignetes Muster (typische Merkmale) bekannt sein muss. Die Entfernung eines Objektes lässt sich aus dem bestimmten Öffnungswinkel sowie der Dimension des Musters bestimmen. Unter der

---

<sup>4</sup> Charge Coupled Device

Voraussetzung, dass sich die Kamera bewegt, ist eine 3D-Rekonstruktion der Umgebung möglich, ohne dass Modellannahmen getroffen werden. Da die Bilder in diesem Fall nacheinander aus unterschiedlichen Perspektiven aufgenommen werden, ist eine Auswertung analog zum Stereo-Ansatz möglich [Enkelmann 1991].

**Stereo** Bei der Stereo-Bildverarbeitung werden zwei Kameras verwendet, deren genaue Lagebeziehung zueinander bekannt ist. Aus synchron aufgenommenen Bildern werden zunächst bestimmte Merkmale - zumeist vertikale Kanten - extrahiert. Aus der Disparität (Verschiebung zwischen beiden Bildern) lässt sich ohne Modell die Entfernung bestimmen [Stiller u. a. 1997].

### 2.2.2. Radar

Durch ihre große Robustheit gegenüber Witterungseinflüssen sowie durch die direkte Geschwindigkeitsmessung sind Radarsensoren für den Einsatz in Multisensor Tracking Systemen prädestiniert [Blackman und Populi 1999, Kapitel 2] und haben sich vor allem im militärischen Bereich der Luftraumüberwachung durchgesetzt. In der Automobilbranche existieren aufgrund der Bauräume und Kosten andere Rahmenbedingungen, sodass sich die Technologien nicht direkt übernehmen lassen. Mit Erfolg wurden jedoch Fernbereichsradare für die automatische Distanzregelung<sup>5</sup> appliziert und sind derzeit in Oberklassefahrzeugen Serienstand. Im Entwicklungsstadium befinden sich derzeit noch Kurzstreckenradare [Knoll u. a. 2002], die über einen größeren Öffnungswinkel verfügen und damit weitergehende Applikationen ermöglichen.

Radarsensoren sind aktive Sensoren, denn es wird die Reflexion eines emittierten Signals empfangen und ausgewertet. Eine Unterscheidung ist hier über das Frequenzband möglich, in dem die Sendesignale liegen. Während die Fernbereichsradare aus dem Serieneinsatz im für den automobilen Einsatz freigegebenen 77 GHz Bereich liegen, senden die erwähnten Kurzstreckenradare im 24 GHz Bereich und liegen damit im Ka-Band. Eine Freigabe dieses Bereiches durch die Regulierungsbehörde für Telekommunikation und Post steht noch aus. Neben der Unterscheidung nach der Trägerfrequenz lassen sich die Sensoren auch in ihrem Funktionsprinzip unterscheiden:

#### Pulsradare

Beim Pulsradar werden kurze Signale (33ns-333ps) einer festen Trägerfrequenz ausgesendet und eine mögliche Objektreflexion in diskreten Zeitfenstern empfangen. Über die Laufzeit  $t$  ergibt sich die Entfernung  $r$  des Objektes unter Berücksichtigung der Lichtgeschwindigkeit  $c$  zu:

$$r = \frac{c t}{2}. \quad (2.1)$$

<sup>5</sup> engl.: ACC - Adaptive Cruise Control



Die relative Objektgeschwindigkeit  $\dot{r}$  ergibt sich aus der Frequenzverschiebung  $f_d$  und der Wellenlänge  $\lambda$  des emittierten Signals zu:

$$f_d = \frac{2 \dot{r}}{\lambda}. \quad (2.2)$$

Eine Winkelschätzung kann bei Pulsradaren durch Multilateration erfolgen. Hierbei werden eine Sende- und mehrere Empfangsantennen genutzt. Über die bekannte Lage der Empfänger und die unterschiedlichen Laufzeiten lässt sich auf die Winkellage schließen.

### Dauerstrichradar

Beim Dauerstrichradar<sup>6</sup> finden der Sende- und Empfangsvorgang gleichzeitig und ununterbrochen statt. Hierdurch ergibt sich eine längere Zielbeleuchtungszeit und somit ein Gewinn beim Signal-Rausch-Verhältnis. Die Reichweite und die Detektionswahrscheinlichkeit lassen sich hierdurch erhöhen. Im Gegensatz zum Pulsradar bleibt die Trägerfrequenz nicht konstant, sondern wird moduliert. Häufig geschieht dies linear (LFM - Linear Frequency Modulated Waveform). Die Entfernung und Geschwindigkeit ergeben sich hier durch die Phasenlage zwischen Sende- und Empfangssignal sowie die Frequenzverschiebung.

### Gepulstes Dauerstrichradar

Beide vorgenannten Messprinzipien werden im gepulsten Dauerstrichradar<sup>7</sup> vereint. Reduzierte Bauteilkosten bei gleicher Auswertung wie beim Dauerstrichradar sind die wesentlichen Merkmale und machen die Klasse zum prädestinierten Messverfahren für den Anwendungsbereich im Kraftfahrzeug.

### 2.2.3. Laser

Aufgrund ihrer Fähigkeit Konturen zu vermessen, sind Lasersensoren derzeit intensiver Forschungsgegenstand. Wie in [Hancock 1999] dargestellt, lassen sich deutliche Parallelen zur Radarsensorik erkennen. So lässt sich einerseits über einen Laserpuls ein Laufzeitverfahren realisieren. Ist die Laserleistung groß genug, um atmosphärische Störungen wie Nebel zu durchdringen, lassen sich auch Objekte jenseits dieser Störung detektieren. Analog zum Dauerstrichradar bietet sich darüber hinaus die Möglichkeit einer Frequenzmodulation des emittierten Laserlichtes. Zusätzlich ist eine Amplituden-Modulation realisierbar.

Bei der überwiegenden Mehrzahl der im Automobilbereich eingesetzten Lasersensoren handelt es sich um Pulslaser, die im Infrarotbereich (Wellenlänge ca. 900nm)

<sup>6</sup> engl.: CW - Continuous Wave

<sup>7</sup> engl.: PCW - Pulsed Continuous Wave

senden. Das wesentliche Merkmal zur Konturvermessung durch Lasersensorik liegt in der starken Fokussierbarkeit sowie in der Möglichkeit, die Strahlgeometrie durch optische Systeme zu modifizieren. Zwei unterschiedliche Systeme sollen an dieser Stelle hervorgehoben werden.

### Mehrstrahllaser

Beim Mehrstrahllaser existieren getrennte Sendeeinheiten, die nacheinander den Laserpuls erzeugen. Für jede Sendeeinheit ergibt sich über die Optik des Sensors ein in horizontaler und vertikaler Divergenz konfigurierbarer Strahl, der für unterschiedliche Sendeeinheiten variieren kann. Über einen gemeinsamen Empfänger wird das reflektierte Signal empfangen und die Laufzeit ermittelt. Vorteilhaft ist an diesem Verfahren die Möglichkeit, die Divergenz in unterschiedlichen Bereichen des Erfassungskegels den applikationsspezifischen Anforderungen anzupassen. Der maximale horizontale Öffnungswinkel des Erfassungskegels liegt üblicherweise bei  $30^\circ$ , der vertikale bei etwa  $3^\circ$ .

### Laserscanner

Im Gegensatz zum Mehrstrahllaser existiert beim Laserscanner lediglich eine Sendeeinheit, die vor einer bewegten Optik angebracht ist. Über einen Spiegel oder ein Prisma wird der emittierte Laserpuls abgelenkt und das reflektierte Signal von der Empfangseinheit ausgewertet. Da nur eine Sendeeinheit existiert, ist die Strahlgeometrie für den gesamten Erfassungsbereich festgelegt. Aufgrund der Rotationssymmetrie sind horizontale und vertikale Divergenz identisch (circa  $0,3^\circ$  bis  $0,7^\circ$ ). Um die Informationsqualität zu erhöhen, erfassen neuere Sensoren [Willhoft und Furstenberg 2001; Lages 2002] die Umgebung mit mehreren, übereinander liegenden Strahlen. Auf diese Weise lässt sich die Gesamtvertikaldivergenz steigern und eine höhere Robustheit gegenüber Nickbewegungen des Sensorträgers erreichen. Der mit Laserscannern realisierbare maximale horizontale Öffnungswinkel des Erfassungskegels ist meist durch den Anbauort am Fahrzeug limitiert. Rotierende Systeme erreichen hier theoretisch eine Rundumsicht ( $360^\circ$ ).

## 2.2.4. Gegenüberstellung

In [Tabelle 2.1](#) sind die typischen Merkmale der vorgestellten Sensoren noch einmal zusammengefasst. Es wird hier von einer Ausrichtung aller Sensoren in Fahrtrichtung ausgegangen, die Attribute Objektbreite und Objektlänge beziehen sich auf Fahrzeuge, die sich parallel zu dieser Ausrichtung fortbewegen. Dargestellt sind die tatsächlichen Messmerkmale, das heißt, diejenigen Merkmale, die sich aus einer Einzelmessung ohne Objektverfolgung ergeben. Merkmale, die sich durch die Objektverfolgung ergeben (z. B. Geschwindigkeit über die Positionsveränderung zwischen zwei Messungen), werden nicht berücksichtigt.

Sensor	Radar	Bildverarbeitung	Laser
Reichweite	++	+	0
Öffnungswinkel	-	+	++
Objekt- abstand	+ (Nahbereich 0)	0	++
Objekt- geschwindigkeit	++	nicht messbar	nicht messbar
Objektbreite	nicht messbar	++	++
Objektlänge	nicht messbar	nicht messbar	+ (abhängig vom Aspektwinkel)
Objekthöhe	nicht messbar	+	nicht messbar

**Tabelle 2.1.:** Vergleichstabelle automobiler Sensorik: Typische Merkmale von Bildverarbeitung, Radar und Lasersensor

Neben den in der Tabelle dargestellten quantifizierbaren Messmerkmalen ausgedehnter Objekte können mittels Bildverarbeitung zusätzliche Merkmale bestimmt werden (Objektfarbe, Bremslicht, Blinker, etc.). Darüber hinaus lässt sich über die Bildverarbeitung der Fahrspurverlauf ermitteln.

Wie sich aus der Tabelle leicht ablesen lässt, ist keine einzelne Sensortechnologie in der Lage, eine dreidimensionale Beschreibung der Fahrumgebung zu liefern, wie sie für moderne Fahrerassistenzsysteme nötig ist. Erst durch die Fusion der Daten unterschiedlicher Sensortechnologien ergibt sich ein deutlicher Informationsgewinn. Im Folgenden werden exemplarisch einige Forschungsprojekte vorgestellt, die sich mit dieser Problematik beschäftigen.

## 2.3. Sensorfusion für Fahrerassistenzsysteme – Stand der Forschung

Wie bereits dargestellt wird die Sensorfusion für Fahrerassistenzsysteme im Wesentlichen zu einer robusten Umgebungserfassung eingesetzt, wobei derzeit die Sensorik applikationsspezifisch konfiguriert wird [ATZ 10 - 2003]. In [Vukotich und Kirchner 2001] werden mögliche Synergien unterschiedlicher Applikationen aufgezeigt. Anhand einiger Projekte wird der aktuelle Stand der Forschung beschrieben.

### 2.3.1. LACOS

Unter anderem von der Volkswagen AG wurden im Rahmen des LACOS<sup>8</sup>-Projektes mehrere Fahrzeuge mit einer im Außenspiegel angebrachten Kamera sowie einem Fernbereichsradar ausgerüstet [Obojski u. a. 2000], um den Seitenbereich des Fahrzeuges und den nachfolgenden Verkehr zu überwachen. Über eine vorwärts gerichtete

<sup>8</sup> Lateral Control Support

Kamera bzw. Infrarotsensoren in den Spiegeln konnte ferner die Position des Fahrzeugs innerhalb der Fahrspur bestimmt werden. Die Sensordaten waren in diesem Projekt in zweifacher Hinsicht komplementär: Einerseits wurden unterschiedliche Merkmale detektiert (Spurvermessung, Objektvermessung), andererseits wiesen die Erfassungsbereiche der Sensoren keinen bzw. nur einen sehr eingeschränkten Überlappungsbereich auf. Die Fusion beschränkte sich daher bei diesem Projekt auf die Erweiterung des Detektionsbereiches.

### 2.3.2. Das Projekt Autonomes Fahren

Das Projekt „Autonomes Fahren“ der Volkswagen AG demonstrierte die Möglichkeit, Testfahrten auf einem Prüfgelände zu automatisieren, indem der Fahrer durch einen autonomen Roboter ersetzt wurde [Schmidt u. a. 2000; Weisser u. a. 1998]. Die Umgebungserfassung erfolgte über drei Laserscanner, einen Fernbereichsradarsensor sowie eine Stereo-Bildverarbeitung, die auch den Fahrspurverlauf detektierte. Zur Stützung der Eigentrajektorie wurde ein DGPS-System eingesetzt [Becker und Simon 2000]. Die Datenfusion wird in [Becker 2001] beschrieben. Nach der zeitlichen und räumlichen Datenangleichung<sup>9</sup> wurden die Sensordaten paarweise assoziiert, um anschließend eine Fusion der Daten durchzuführen.

### 2.3.3. ARGO

Eine Plattform für Sicherheitssysteme und Fahrerassistenzsysteme zur autonomen Fahrzeugführung entsteht im Rahmen des Projektes Argo der Universität Parma. Bisher wurden ausschließlich bildverarbeitende Systeme zur Umgebungserfassung eingesetzt, um einen Spurhalteassistent zu realisieren. Es wird eine Fusion zwischen einem Mono- und einem Stereosystem durchgeführt, wobei das Monosystem den Fahrspurverlauf erkennt und Objekte detektiert. Die Distanzschätzung wird durch das Stereosystem anschließend verbessert [Bertozzi und Broggi 1996; Benschair u. a. 2001].

### 2.3.4. CHAMELEON

Das EU-geförderte CHAMELEON-Projekt diente dem Aufbau und der Validierung eines prototypischen Precrash-Systems [Fuerstenberg u. a. 2001]. Die wesentlichen Projektziele waren dabei die Weiterentwicklung von verfügbaren Sensortechnologien sowie die Evaluation von unterschiedlichen Auslösealgorithmen. Die Umfelderkennung erfolgte über ein heterogenes Sensornetzwerk aus Laser-, Nah- und Fernbereichsradar und Farbkamera, wobei die Daten auf Objektebene fusioniert wurden. Dort, wo sich die Sensorsichtbereiche überlappten, war eine redundante Fusion zur Minimierung des Schätzfehlers möglich. Außerhalb erfolgte eine komplementäre Fusion zur Vergrößerung des Erfassungsbereiches. Ziel der Precrash-Algorithmen war

---

<sup>9</sup> engl.: Data Alignment

nicht die Vermeidung von Unfällen, sondern die Minimierung von Unfallfolgen im Falle einer unvermeidlichen Kollision über reversible Schutzmaßnahmen wie beispielsweise elektrische Gurtstraffer. Reversible Schutzmaßnahmen bieten sich bei der Untersuchung von Auslösealgorithmen an, da Fehlauflösungen keine Beschädigungen und folglich Kosten verursachen.

### 2.3.5. CARSENSE

Im Rahmen des CARSENSE-Projektes wurde die heute serienmäßig verfügbare Abstandsregelung auf den Niedergeschwindigkeitsbereich ausgedehnt (ACC Stop & Go). Ein monokulares Kamerasystem dient dazu, den Fahrspurverlauf zu schätzen, während die Daten eines Stereokamerasystems sowie Laserscannerdaten zur Objekterkennung eingesetzt werden. Die Fusion ermöglicht hier zum einen die Zuordnung von Objekten zu einer Fahrspur, umgekehrt können durch Verdeckung verursachte Fehler bei der Fahrspurerkennung durch die Objekterkennung reduziert werden [Langheim 2001],[Nashashibi 2000].

### 2.3.6. Weitere Arbeiten

[Kopischke 2000] entwickelte ein System zur Unfallfolgenminimierung, das eine automatische Notbremsung eines Fahrzeuges einleitet, sofern eine Kollision aus fahrphysikalischen Gründen durch ein vom Fahrer initiiertes Brems- oder Ausweichmanöver nicht mehr verhindert werden kann. Da bei höheren Geschwindigkeiten die Kollision ausschließlich durch ein Lenkmanöver zu vermeiden ist, ist der Nutzen eines solchen Systems stark abhängig von der Objektbreite. Eine prototypische Demonstration des Systems erfolgte mit einem Laserscanner.

Eine Weiterentwicklung des Notbremssystems in Form eines Kollisionsvermeidungssystems findet sich in [Ameling 2002]. In Ergänzung zum Bremsen werden hier auch Ausweichmanöver zugelassen, wobei die geometrischen Merkmale des Kollisionsobjektes zur Bestimmung eines geeigneten Manövers von Bedeutung sind. Die prototypische Implementation erfolgte mit zwei Laserscannern. Im Ausblick der Arbeit wird explizit auf den zu erwartenden Nutzen eines einheitlichen Umfeldmodells auf der Basis von fusionierten Sensordaten hingewiesen.

## 2.4. Blick in die Zukunft

Derzeit divergieren die Expertenmeinungen zum Thema Umgebungserfassung ([ATZ 09 - 2003]). Radarsensoren beherrschen momentan den Markt und es ist offen, ob sich die Laser- oder Radarsensorik etabliert oder beide Systeme in unterschiedlichen Marktsegmenten zum Einsatz kommen. Für komplexe Verkehrsszenarien wird die Spurinformaton von Bildverarbeitenden Sensoren zudem unverzichtbar sein. Die

Sensordatenfusion von heterogenen Sensoren zeichnet sich als deutlicher Entwicklungstrend vor allem für sicherheitsrelevante Fahrerassistenzsysteme ab [[ATZ 10 - 2003](#)].

## 3. Verfahren zur Sensordatenfusion

Im vorangegangenen Kapitel wurden grundlegende Begriffe erklärt und die Notwendigkeit der Sensordatenfusion für zukünftige Fahrerassistenzsysteme wurde begründet. Trotz der theoretischen Vorteile einer multisensoriellen Datenfusion gestaltet sich die Datenverarbeitung in der Praxis sehr komplex, da eine Vielzahl von Randbedingungen berücksichtigt werden muss. Zusätzliche Daten bedeuten nicht zwangsläufig eine bessere Schätzung (vgl. [Blair und Bar-Shalom 1996]).

**Abbildung 3.1** zeigt vereinfacht die Sensordatenverarbeitung von zwei objekterkennenden Sensoren und die möglichen Fusionsebenen. Zunächst erfolgt bei jedem Sensor eine *Signalverarbeitung*, wobei aus den Messdaten (beispielsweise Spannungen) geeignete Größen (beispielsweise Signallaufzeiten) ermittelt werden. Eine Fusion auf dieser Ebene kann zur Verbesserung der Signalqualität beitragen, setzt aber voraus, dass sich die Daten bereits auf dieser Ebene kombinieren lassen. Dies ist üblicherweise nur bei einem homogenen Sensornetzwerk gegeben. Ein typisches Beispiel ist die pixelweise Kombination zweier Grauwertbilder - man spricht hier von pixel-level Fusion (vgl. [Luo und Kay 1994]).


Die *Sensordatenverarbeitung* generiert aus den Signalen oder Pixeln Messmerkmale (beispielsweise Entfernungen, Kanten, Geschwindigkeiten), die ebenfalls miteinander fusioniert werden können, sofern sie aus demselben Merkmalsraum stammen. Durch *Abstraktion* lassen sich in der Regel neue Merkmalsvektoren berechnen (etwa Bounding Boxes). Auch auf dieser abstrakteren Ebene ist eine Fusion möglich.

Eine weitere Informationsverdichtung kann über eine *Interpretation* und *Klassifikation* erreicht werden. Während Ort und Dynamik von Objekten kontinuierliche Werte annehmen, erfolgt hier die Zuordnung zu diskreten Klassen (beispielsweise Pkw, Lkw). Die Klassifikationsergebnisse der einzelnen Sensoren lassen sich ebenfalls fusionieren.

Diese Arbeit beschäftigt sich ausschließlich mit der Sensordatenfusion zur Schätzung von kontinuierlichen Objektparametern (räumliche Lage, Dynamik, Formparameter), wie sie für eine robuste Objektverfolgung (Tracking) benötigt werden. Eine gegenüber dem Einzelsensor verbesserte Klassifikation lässt sich mit den fusionierten Daten realisieren (vgl. [Weiß u. a. 2003]).

Eine Reihe von Bedingungen ist insbesondere bei der Fusion in einem heterogenen Sensornetzwerk zu berücksichtigen, exemplarisch seien die folgenden genannt:

1. Zeitliche Synchronisierung der Sensoren,
2. unterschiedliche Datenstrukturen und Messmerkmale,



**Abbildung 3.1.:** Schematische Darstellung möglicher Fusionsebenen von zwei Sensoren

3. unterschiedliche Genauigkeiten und Auflösungen.

In diesem Kapitel werden zunächst die Details eines Mehrziel-Trackingsystems mit einem Einzelsensor erläutert, bevor auf die Konsequenzen für ein Multisensorsystem eingegangen wird.

### 3.1. Mehrzielverfolgung mit einem Einzelsensor

Abbildung 3.2 zeigt die typischen Funktionselemente eines rekursiven Mehrziel-Tracking-Systems für einen einzelnen Sensor.

Die Verarbeitung gliedert sich in folgende Schritte:



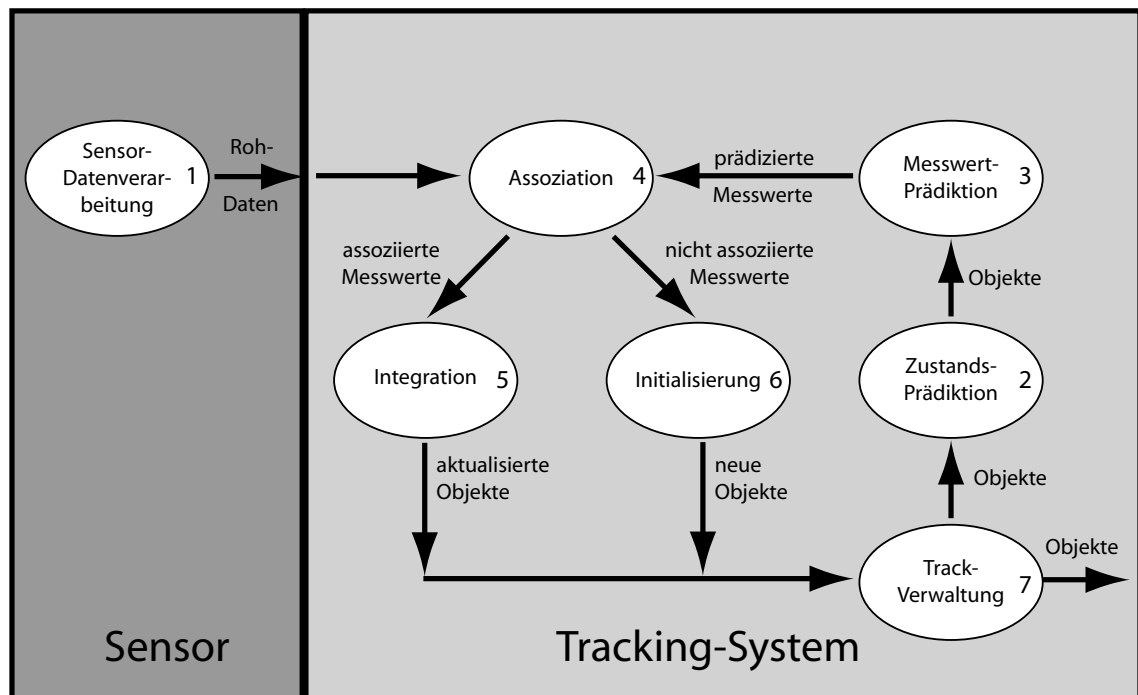


Abbildung 3.2.: Rekursives Mehrziel-Tracking-System

1. Zunächst erfolgt die *Sensordatenverarbeitung*, die typischerweise direkt vom Sensorsteuergerät ausgeführt wird. Hierbei werden die eigentlichen Sensordaten (wie etwa Signallaufzeiten) in Messdaten überführt, die zur Objektverfolgung eingebracht werden (beispielsweise Entfernungen). Die Messdaten werden anschließend an das Tracking-System übertragen. Für das Tracking-System sind dies die Rohdaten<sup>1</sup>, die zur Stützung der Objekttracks eingebracht werden.
2. Die Zustandsvektoren der in vorangegangenen Iterationen detektierten Objekte werden bei der *Zustandsprädiktion* auf den Messzeitpunkt prädiziert, das heißt, ihre Bewegung wird anhand der letzten Schätzung fortgeschrieben.
3. In der Regel befinden sich die Messwerte nicht im selben Merkmalsraum wie die Objekte (so kann etwa der Objektzustand Position und Geschwindigkeit beinhalten, obwohl die Messwerte lediglich Positionen liefern). Bei der *Messwertprädiktion* erfolgt daher die Abbildung der Zustandsvektoren der Objekte auf den Merkmalsraum der Messwerte. Die bei der Sensordatenverarbeitung erzeugten Rohdaten befinden sich somit in demselben Merkmalsraum.
4. Über ein Abstandsmaß erfolgt die *Assoziation* zwischen prädizierten Messwerten und den Rohdaten. Die Assoziation entscheidet, welche Messwerte zur Aktualisierung eines Objektzustandes benutzt werden und welche als nicht assoziierte Messwerte neue Objekte initialisieren müssen.

<sup>1</sup> Der Begriff Rohdaten findet in der Wissenschaft unterschiedliche Verwendung. Im Rahmen dieser Arbeit werden Sensordaten, die ausschließlich aus einer Einzelmessung generiert wurden, unabhängig vom Abstraktionsgrad als Rohdaten bezeichnet.

5. Bei der filterbasierten *Integration* erfolgt die Zustandsaktualisierung der Objekte. Da sich die Zustandsvektoren der Objekte und die Messwerte nicht in demselben Merkmalsraum befinden müssen, wird hierbei typischerweise die während der Messwertprädiktion ermittelte Messfunktion berücksichtigt. Ferner erfolgt eine Gewichtung nach Unsicherheit des Objektzustandes und der Messung.
6. Bei der *Initialisierung* werden aus unzugeordneten Messwerten die Zustandsvektoren von neuen Objekten gesetzt. Diese neuen Objekte werden beim nächsten Iterationsschritt berücksichtigt.
7. Die *Trackverwaltung* dient im Wesentlichen dazu, unbestätigte Tracks wieder zu entfernen. Wurde ein initialisiertes Objekt für einige Iterationen nicht beobachtet, so wird es verworfen. Auch das Zusammenfassen von mehreren Tracks<sup>2</sup> kann in der Trackverwaltung erfolgen.

Es sei an dieser Stelle darauf hingewiesen, dass die obige Darstellung lediglich eine Übersicht der erforderlichen Funktionen wiedergibt. Einzelne Assoziation- und Filterverfahren können Abweichungen zeigen, auf die im weiteren Verlauf des Kapitels eingegangen wird.

## 3.2. Mehrzielverfolgung mit einem Sensornetzwerk

Verwendet man statt eines einzelnen Sensors ein Netzwerk von Sensoren, so müssen die Daten der Sensoren in geeigneter Weise in die Zustandsschätzung der Objekte eingebracht werden. Die Zustandsschätzung der Objekte stellt nun eine Kombination der Sensordaten von unterschiedlichen Sensoren dar, die im Folgenden mit *Sensordatenfusion* bezeichnet wird. Der Begriff der Sensordatenfusion ist in der Literatur nicht einheitlich belegt. Eine allgemeine Definition findet sich in [Valet u. a. 2000]:

*Datenfusion ist ein formaler Rahmen, in dem Mittel und Werkzeuge zur Kombination von Daten aus unterschiedlichen Quellen ausgedrückt werden. Das Ziel ist die Erzeugung von Informationen von besserer Qualität; die exakte Definition von „besserer Qualität“ wird dabei von der Applikation abhängen.*

Zwei wesentliche Punkte bringt diese Definition zum Ausdruck: Zum Einen können sehr unterschiedliche „Mittel und Werkzeuge“ zum Einsatz kommen. Hierbei spielt auch die Systemarchitektur eine fundamentale Rolle. Zum Anderen wird auf die Bewertungsmaßstäbe hingewiesen, die häufig applikationsspezifisch angepasst werden müssen.

Eine grobe Klassifikation der Systemarchitektur ist nach [Bar-Shalom und Li 1995] durch folgende Merkmale möglich:

1. Synchronisierbarkeit der Sensoren: Arbeiten die Sensoren autark oder erfolgen die Messungen der Einzelsensoren zu synchronisierten Zeitpunkten?

<sup>2</sup> engl.: Merge


2. Reihenfolge der Messwerteinbringung: Werden die Messwerte von verschiedenen Sensoren innerhalb eines einzelnen Iterationsschrittes des Filteralgorithmus *parallel* eingebracht oder geschieht dies *sequenziell*?

Im Folgenden werden die verschiedenen Kombinationsmöglichkeiten näher untersucht und auf die Unterschiede zum Tracking mit einem Einzelsensor eingegangen.

### 3.2.1. Synchroner Sensoren

Synchrone Sensoren zeichnen sich dadurch aus, dass der Messvorgang gleichzeitig erfolgt. Da die Messwerte keinen zeitlichen Versatz zueinander aufweisen, können sie in der gleichen Iteration des Tracking-Systems eingebracht werden (siehe [Abbildung 3.3](#)). Jeder zusätzliche Messwert bringt einen Informationsgewinn, der die Unsicherheit der globalen Tracks verringert. Ein Objektmodell für die zeitliche Prädiktion ist nur für die globalen Tracks erforderlich, die Sensoren liefern Rohdaten.

Zwei unterschiedliche Integrationsverfahren sind möglich, um die neuen Messwerte zur Verbesserung der Zustandsschätzung einzubringen:



**Abbildung 3.3.:** Fusion synchronisierter Sensoren: Mit M sind die Messungen bezeichnet, mit T der fusionierte Track. Da die Messungen synchron erfolgen, können sie gleichzeitig eingebracht werden.

#### Parallele Fusion

Bei der parallelen Fusion werden alle einem Objekt zugeordneten Messwerte *gleichzeitig* eingebracht, die Integration wird nur ein einziges Mal durchlaufen. Die Schritte des Einzelsensortrackings finden sich wie folgt wieder:

1. Zunächst erfolgt die Messung synchron mit allen Sensoren. Je nach Fusionsebene werden die Signalverarbeitung, die Sensordatenverarbeitung, die Abstraktion und die Interpretation für die Rohdaten jedes einzelnen Sensors durchgeführt.

2. Die Zustandsprädiktion erfolgt in der gleichen Weise wie bei der Mehrzielverfolgung mit einem Einzelsensor. Alle Zustandsvektoren von Objekten werden anhand der letzten Zustandsschätzung fortgeschrieben.
3. Für alle Sensoren erfolgt die Messwertprädiktion für die Objekte im jeweiligen Sensorsichtbereich. Befindet sich ein Objekt in mehreren Sichtbereichen, so werden mehrere Messwerte prädiziert.<sup>3</sup>
4. Die Assoziation erfolgt für jeden Sensor und jedes Objekt in seinem Sichtbereich. Befindet sich ein Objekt in mehreren Sichtbereichen, so können Messwerte von unterschiedlichen Sensoren zugeordnet werden.
5. Für alle Objekte mit mindestens einem Messwert erfolgt die Integration im Filterschritt. Wurde einem Objekt mehr als ein Messwert zugewiesen, so werden die einzelnen Messwerte zu einem mehrdimensionalen Messvektor zusammengefasst, der in einem einzigen Iterationsschritt eingebracht wird.
6. Bei der Initialisierung ist zu beachten, dass nicht jeder unzugeordnete Messwert ein neues Objekt erzeugen muss. Falls ein neues Objekt von mehr als einem Sensor beobachtet wurde, können mehrere Messwerte zur Initialisierung herangezogen werden, sodass nur *ein* neues Objekt für *mehrere* Messwerte erzeugt wird.
7. Die Trackverwaltung gestaltet sich bei einem Sensornetzwerk komplexer. Neben dem Verwerfen von unbestätigten Tracks kommt der Verschmelzung eine größere Bedeutung zu, da möglicherweise bei der Initialisierung nicht erkennbar ist, dass zwei Messwerte von ein und demselben Objekt stammen. Ferner können Objekttracks auch durch zusätzliche Sensoren falsifiziert und so lokale Störungen eines Sensors beseitigt werden.

## Sequenzielle Fusion

Werden die Messwerte der einzelnen Sensoren nacheinander in die Zustandsschätzung eingebracht, so spricht man von einer sequenziellen Fusion. Im Vergleich zur parallelen Fusion ändert sich daher die Integration der Daten, die nicht mehr in einem einzigen Schritt über einen hochdimensionalen Messvektor erfolgt. Die Zustandsschätzung eines Objektes wird hier zunächst über den ersten assoziierten Messwert aktualisiert. Die verbesserte Zustandsschätzung wird nun über den zweiten assoziierten Messwert aktualisiert usw. Maximal ist die Anzahl der Aktualisierungen gleich der Anzahl der Sensoren.

Wichtig ist hierbei zu beachten, dass die Reihenfolge des Einbringens der Messwerte einen Einfluss auf die Zustandsschätzung haben kann. Dies ist beispielsweise der Fall, wenn Linearisierungen verwendet werden. Es empfiehlt sich, die Messwerte sortiert

---

<sup>3</sup> Auch bei identischem Merkmalsraum der Messvektoren verschiedener Sensoren ist in der Regel eine Messwertprädiktion für jeden Sensor durchzuführen, da die Messfunktionen in Abhängigkeit vom Anbauort des Sensors variieren.

nach Genauigkeit, beginnend mit dem besten, einzubringen (vgl. [Bar-Shalom und Li 1995]).

### 3.2.2. Asynchrone Sensoren

Synchronisierte Sensoren sind häufig Gegenstand theoretischer wissenschaftlicher Untersuchungen. In der Praxis lassen sich insbesondere heterogene Sensoren zur Fahrumgebungserfassung derzeit nicht synchronisieren. Zu unterschiedlich sind die Messverfahren, Zielbeleuchtungszeiten und Verarbeitungsschritte. Da eine Synchronisierung sich stets am langsamsten Sensor orientieren müsste, hätte dies ferner zur Folge, dass die Informationsdichte von schnelleren Sensoren nicht genutzt würde.

Es entstehen daher Verzögerungen, die durch die unterschiedlichen Verarbeitungsschritte sowie das Kommunikationsnetzwerk verursacht werden. Die Fusion gestaltet sich somit deutlich komplexer, weil die Rohdaten nicht in der Reihenfolge der Messungen vorliegen, die zeitliche Prädiktion der Objektzustände bei dem vorgestellten rekursiven Trackingsystem jedoch nur in positiver Zeitrichtung erfolgen kann. Das Fusionsverfahren sollte daher einerseits in der Lage sein, verspätet eingetroffene Messdaten verarbeiten zu können, andererseits sollte der zeitliche Versatz zwischen Realzeit und letztem Update der Objekt-Zustandsvektoren minimal sein.

#### Messwertprädiktion auf gemeinsamen Fusionszeitpunkt


Bei den bisher vorgestellten Tracking-Architekturen erfolgt die Fusion von einer Zentraleinheit<sup>4</sup>. Die vorverarbeiteten Sensordaten werden an diese Zentraleinheit übertragen, wo die einzelnen Schritte der Objektverfolgung durchgeführt werden. Diese Fusionsvariante wird daher auch als Sensor-zu-System-Track-Fusion bezeichnet.

Einen alternativen Ansatz stellt die Sensorebenen-Fusion<sup>5</sup> dar. Hierbei erfolgt das Tracking bereits auf der Sensorebene, wobei jeder Sensor über ein eigenes Tracking-Verfahren verfügt, das speziell auf diesen Sensor abgestimmt ist. Die Fusion besteht darin, auf der Seite der Zentraleinheit eine Track-zu-Track-Assoziation durchzuführen und die Tracks der einzelnen Sensoren zu globalen Tracks zusammenzufassen, wie dies [Abbildung 3.4](#) verdeutlicht. Die Zykluszeiten der Sensoren sowie der Fusion sind hierbei völlig unabhängig voneinander. Da Sensor-Tracks miteinander kombiniert werden, wird diese Fusionsvariante als Sensor-zu-Sensor-Track-Fusion bezeichnet.

Weil jeder Sensor hier über ein eigenes Objektmodell verfügt, kann in diesem Fall eine zeitliche Prädiktion der Daten auf einen prinzipiell beliebigen Zeitpunkt erfolgen. Durch diese zeitliche Prädiktion ist es folglich möglich, die Daten von Sensoren mit unterschiedlichen Verarbeitungszeiten und Wiederholraten auf einen konkreten Fusionszeitpunkt vorherzusagen. Da die Objektmodelle sensorabhängig variieren können, müssen alle Objektdaten auf eine einheitliche Darstellung abgebildet werden. Diese

<sup>4</sup> engl.: Central level fusion

<sup>5</sup> engl.: Sensor level fusion



**Abbildung 3.4.:** Sensor-zu-Sensor-Track-Fusion: Mit M sind die Messungen bezeichnet, mit T die Tracks. Jeder Sensor verfügt über eine eigene Objektverfolgung. Der fusionierte Track entsteht durch die Kombination mehrerer Sensor-Tracks.

beiden zur Fusion erforderlichen Schritte bezeichnet man als zeitliche und räumliche Datenangleichung.

Vorteilhaft ist bei diesem Verfahren das speziell auf den Sensor abgestimmte Objektmodell beim Tracking. Weiterhin wird die Zentraleinheit entlastet, da Informationen in der Regel mit einer geringeren Datenrate anfallen und lediglich eine Kombination der Tracks durchgeführt wird. Die Rechenkomplexität bei den Sensoren hingegen erhöht sich.

Das Verfahren hat jedoch auch einige Nachteile:


1. Die Informationen anderer Sensoren können beim Tracking nicht berücksichtigt werden. Es habe beispielsweise ein Sensor Stärken bei der Bestimmung der Längs- und Schwächen bei der Bestimmung der Quergeschwindigkeit von Objekten. Ein anderer Sensor vermesse hingegen die Quergeschwindigkeit von Objekten besser als deren Längsgeschwindigkeit. Da bei keinem Sensor Informationen über das Tracking des anderen Sensors vorliegen, ergeben sich für beide Sensoren Schwierigkeiten bei einer robusten Objektverfolgung, die sich anschließend auch in Form von erhöhten Unsicherheiten bei den globalen Tracks wiederfinden.
2. Wenn die Erfassungsbereiche der Sensoren komplementär liegen, muss in jedem Sensorerfassungsbereich ein neuer Track initialisiert werden. Dies hat zur Folge, dass in jedem Erfassungsbereich der Einschwingprozess des Filters erneut stattfinden muss, obwohl bereits Schätzwerte vorhanden sind.
3. Die Messwertgüte schwankt. Die Rohdaten von objekterkennenden Sensoren weisen typischerweise eine vom Messprinzip abhängige Unsicherheit auf, die beispielsweise bei einem in Polarkoordinaten messenden Sensor aus der Entfernungs- und Winkelunsicherheit resultiert. Werden getrackte Daten an die Zentraleinheit übertragen, so schwankt die Güte der einzelnen Tracks bereits dadurch, dass diese unterschiedliche Einschwingzeiten besitzen. Zusätzlich ergibt sich eine schwankende Güte durch die zeitliche Prädiktion auf das externe

Raster. Während beim Tracking im Sensor zu erwarten ist, dass sich die Unsicherheiten durch das Einbringen weiterer Messwerte verkleinern, gilt dies nicht für die zeitlich prädierten Tracks.

4. Die Information eines Messwertes wird nicht schnellstmöglich in die Fusion eingebracht. Durch die zeitliche Prädiktion entsteht eine Verzögerung.
5. Die einzelnen Sensortracks können zu unterschiedlichen Zeiten aktualisiert worden sein. Kann ein Track in einem Messzyklus nicht durch neue Messwerte gestützt werden, so wird dieser dennoch eine gewisse Zeit weiter prädiert.

### Retrodiktion der Messwerte

Sowohl bei synchronisierten Sensoren als auch bei der Messwertprädiktion auf einen gemeinsamen Fusionszeitpunkt werden die globalen Tracks periodisch aktualisiert. Um die Nachteile der Prädiktion der Sensortracks zu beseitigen, wäre es aus informationstheoretischer Sicht vorteilhaft, die Messdaten direkt sequenziell einzubringen, wie dies [Abbildung 3.5](#) verdeutlicht:



**Abbildung 3.5.:** Asynchrone Sensor-zu-System-Track-Fusion: Die Messungen sind mit M bezeichnet, der fusionierte Track mit T. Der globale Track wird direkt durch die verfügbaren Messwerte gestützt.

Sofern die Sensoren über einheitliche Updateraten verfügen und die Verarbeitungszeiten sowie die Transferzeiten zur Zentraleinheit übereinstimmen, lässt sich diese Architektur mit geringem Aufwand realisieren. Schwierigkeiten entstehen bei heterogenen Sensoren mit unterschiedlichen (möglicherweise sogar schwankenden) Updateraten.

Erreicht ein neuer Messwert die Zentraleinheit, der zeitlich vor dem zuletzt eingebrachten Messwert liegt, so müsste die Prädiktion rückwärts erfolgen. Man spricht in diesem Fall von Retrodiktion [[Bar-Shalom und Li 1993](#), Kapitel 8]. Auch neuere Veröffentlichungen beschäftigen sich noch mit diesem Verfahren, zu dem es zwar exakte mathematische Lösungen gibt [[Bar-Shalom 2002](#); [Mallick u. a. 2002](#); [Zhang u. a. 2002](#)], die sich jedoch in der Praxis schwer umsetzen lassen.

Berücksichtigt wird bei der Retrodiktion lediglich die Auswirkung eines veralteten Messwertes auf die Zustandsschätzung eines Objektes. Die folgenden Probleme bleiben jedoch ungelöst:

- Bestehende Objekttracks können bereits bei der Trackverwaltung verworfen worden sein, weil die erwartete Stützung durch einen weiteren Messwert ausblieb.
- Die veralteten Messwerte können zur Initialisierung von neuen Objekten führen, die wiederum einen erheblichen Einfluss auf die folgenden Assoziations-schritte haben.
- Falls das Filter mit variablen Zustandsvektoren arbeitet, kann ein veralteter Messwert zur Initialisierung zusätzlicher Merkmale und damit zu einem modifizierten Zustandsvektor führen. Auch dies hat einen Einfluss auf die weiteren Assoziations-schritte.

Der größte Vorteil des Verfahrens besteht darin, dass die Sensordaten umgehend in die Fusion eingehen und somit keine zeitliche Verzögerung auftritt. Die Verzögerung zwischen Tracks und Messdaten entspricht daher der Verarbeitungszeit des schnellsten Sensors.

Die Retrodiktion wird hauptsächlich in theoretischen Veröffentlichungen behandelt [[Bar-Shalom und Fortmann 1988](#)].

### 3.3. Filter und Schätzverfahren

Die Sensordatenfusion hat das Ziel, den unbekanntem Wert eines direkt oder indirekt beobachteten Objekt-Zustandes möglichst genau zu bestimmen. Eine anfängliche Schätzung der Zustandsparameter wird durch Hinzunahme von Messwerten modifiziert oder bestätigt.

Es gibt eine Reihe von Filtern, die eine solche Aufgabe erfüllen. [Tabelle 3.1](#) zeigt, dass bereits für die Gattung der  $g$ - $h$ -Filter diverse Varianten existieren. Den  $g$ - $h$ -Filtern ist gemeinsam, dass über ein rekursives Verfahren die Position und die Geschwindigkeit eines Objektes aus Messwerten geschätzt wird, wobei über die Koeffizienten  $g$  und  $h$  eine Gewichtung aus dem letzten Schätzwert und dem aktuellen Messwert erfolgt. Sie unterscheiden sich in der Bestimmung der Koeffizienten, die entweder über alle Filteriterationen konstant sein können oder – wie beim Kalman-Filter – mit jeder Iteration neu berechnet werden [[Brookner 1998](#)].

Statistische Filter haben sich seit Einführung des Kalman-Filters [[Kalman 1960](#)] bei der Objektverfolgung etabliert. Ihre Filterfunktion besteht darin, dass sie den Einfluss von störenden Rauschgrößen minimieren. Gleichzeitig liefern die Algorithmen statistische Schätzwerte für die interessierenden Zustandsgrößen. Im weiteren Verlauf werden ausschließlich statistische Verfahren betrachtet.



---

1.	<i>Wiener filter</i>
2.	<i>Fading-memory polynomial filter</i>
3.	<i>Expanding-memory (or growing memory) polynomial filter</i>
4.	<i>Kalman filter</i>
5.	<i>Bayes filter</i>
6.	<i>Least-squares filter</i>
7.	<i>Benedict-Bordner filter</i>
8.	<i>Lumped filter</i>
9.	<i>Discounted least squares g-h filter</i>
10.	<i>Critically damped g-h filter</i>
11.	<i>Growing memory filter</i>

---

**Tabelle 3.1.:** *g-h*-Filter nach [Brookner 1998]

Statistische Verfahren behandeln den Systemzustand als Zufallsvariable, die durch eine zugehörige bedingte Wahrscheinlichkeitsdichtefunktion (kurz: bedingte Dichtefunktion) dargestellt wird. Die Dichtefunktion stellt die Information, die aus den Messwerten, auf die sie bedingt ist, gewonnen werden kann, dar. Die Messwertrealisationen bestimmen die Form der Dichtefunktion. Anhand der Dichtefunktion lassen sich unterschiedliche optimale Schätzwerte definieren, die in [Abbildung 3.6](#) dargestellt sind.

- Conditional Mode - Maximum der Dichtefunktion
- Conditional Median - Flächensymmetrie
- Conditional Mean (Erwartungswert) - Schwerpunkt der Dichtefunktion

Umfasst der Schätzwert auch die Objektdynamik, so ist ein entsprechendes Modell bei der Schätzung zu berücksichtigen. Hierauf wird im Folgenden näher eingegangen.

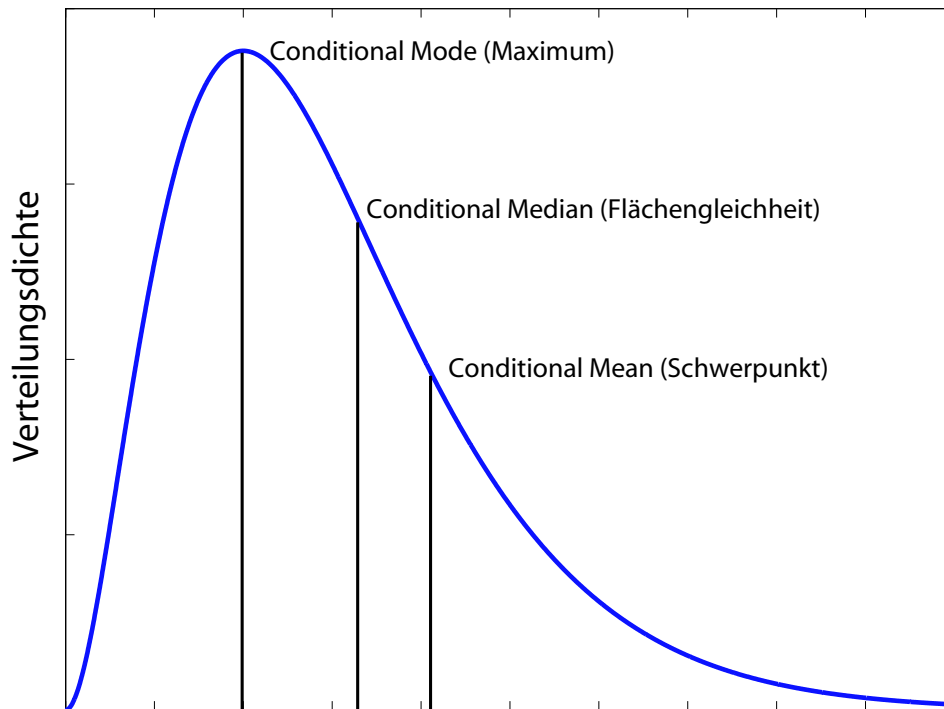
### 3.3.1. Lineare stochastische Systeme

Beim Tracking von bewegten Objekten umfasst der Zustandsvektor auch die Dynamikparameter wie Geschwindigkeiten und Beschleunigungen. Ein entsprechendes Modell ist nötig, um die Bewegung bei der Zustandsschätzung zu berücksichtigen. Die folgende Darstellung basiert auf [Bar-Shalom und Li 1993].

Die Bewegung eines Objektes lässt sich durch die *Dynamikgleichung* [Formel 3.1](#) eines zeitkontinuierlichen linearen stochastischen Systems beschreiben:

$$\dot{\mathbf{x}}(t) = \mathbf{A}(t) \mathbf{x}(t) + \mathbf{B}(t) \mathbf{u}(t) + \tilde{\mathbf{v}}(t). \quad (3.1)$$

Dabei haben die Bezeichner die folgenden Bedeutungen:



**Abbildung 3.6.:** Darstellung verschiedener Schätzwerte aus der Dichtefunktion

- $\mathbf{x}$   $n_x$ -dimensionaler Zustandsvektor,
- $\mathbf{u}$   $n_u$ -dimensionaler Eingangsvektor (auch Steuerungsvektor),
- $\tilde{\mathbf{v}}$  Prozessrauschen,  $n_x$ -dimensionaler Vektor,
- $\mathbf{A}$  Systemmatrix, Dimension  $n_x \times n_x$ ,
- $\mathbf{B}$  Steuerungsmatrix, Dimension  $n_x \times n_u$ ,

Für die Beobachtungen gilt die *Messgleichung*.

$$\mathbf{z}(t) = \mathbf{C}(t) \mathbf{x}(t) + \tilde{\mathbf{w}}(t) \text{ mit} \quad (3.2)$$

- $\mathbf{z}$   $n_z$ -dimensionaler Messvektor,
- $\tilde{\mathbf{w}}$  Messrauschen, Dimension  $n_z$ ,
- $\mathbf{C}$  Messmatrix, Dimension  $n_z \times n_x$

Ohne das Prozessrauschen  $\tilde{\mathbf{v}}$  und das Messrauschen  $\tilde{\mathbf{w}}$  spricht man von einem *deterministischen* System. Im stochastischen System werden beide Rauschterme als erwartungswertfreie, weiße und gegenseitig unabhängige stochastische Prozesse angenommen.

Objekterkennende Sensoren ermöglichen in der Regel keine kontinuierliche Beobachtung des Systems, sondern arbeiten in festen Abtastschritten, also zeitdiskret. Im zeitdiskreten Fall wird angenommen, dass der Steuerungsvektor in [Formel 3.1](#) abschnittsweise konstant ist. Er wird mit  $\mathbf{u}(k)$  bezeichnet und wirkt über die zeitdiskrete Steuerungsmatrix  $\mathbf{G}(k)$ .  $\mathbf{v}(k)$  beschreibt das zeitdiskrete Prozessrauschen.

Das dynamische Modell für ein *zeitdiskretes lineares stochastisches System* lässt sich schließlich wie folgt aufstellen:

$$\mathbf{x}(k+1) = \mathbf{F}(k) \mathbf{x}(k) + \mathbf{G}(k) \mathbf{u}(k) + \mathbf{v}(k) \quad \text{mit} \quad (3.3)$$

- F** Zustandsübergangsmatrix, Dimension  $n_x \times n_x$ ,  
**G** Steuerungsmatrix, Dimension  $n_x \times n_u$ ,  
**v** zeitdiskretes Prozessrauschen, Dimension  $n_x$ .

Das Prozessrauschen ist erwartungswertfrei und weiß mit Kovarianz **Q**, sodass gilt:

$$E[\mathbf{v}(k)] = \mathbf{0}, \quad (3.4)$$

$$E[\mathbf{v}(k)\mathbf{v}(j)'] = \mathbf{Q}(k) \delta_{kj}. \quad (3.5)$$

Der zeitdiskrete Messvektor ergibt sich aus dem Zustandsvektor über die zeitdiskrete Messmatrix **H**(*k*) und das zeitdiskrete Prozessrauschen **w**(*k*):

$$\mathbf{z}(k) = \mathbf{H}(k) \mathbf{x}(k) + \mathbf{w}(k). \quad (3.6)$$

Hierbei wird das Messrauschen ebenfalls als erwartungswertfrei und weiß angenommen:

$$E[\mathbf{w}(k)] = \mathbf{0}, \quad (3.7)$$

$$E[\mathbf{w}(k) \mathbf{w}(j)'] = \mathbf{R}(k) \delta_{kj}. \quad (3.8)$$

Außerdem sei es unkorreliert mit dem Prozessrauschen:

$$E[\mathbf{v}(k) \mathbf{w}(j)'] = \mathbf{0} \quad \text{für alle } k, j. \quad (3.9)$$

Das System ist vollständig durch den letzten Zustand beschrieben, sodass es sich um eine *Markow-Sequenz* handelt.

Die Matrizen **F**, **G**, **H**, **Q** und **R** werden als bekannt vorausgesetzt und können zeitvariant sein. Es interessiert der bedingte Erwartungswert des Systemzustandes  $\hat{\mathbf{x}}(j|k)$  zum Zeitpunkt *j*

$$\hat{\mathbf{x}}(j|k) \triangleq E[\mathbf{x}(j)|Z^k], \quad (3.10)$$

wobei

$$Z^k \triangleq \{\mathbf{z}(j)\}_{j=1}^k \quad (3.11)$$

die zum Zeitpunkt *k* verfügbaren Messwerte bezeichnet. Man unterscheidet

1. die *Zustandsschätzung* (hierbei gilt  $j = k$ ),
2. den *geglätteten Zustand* (hierbei gilt  $j < k$ ),

3. den *prädizierten Zustand* (hierbei gilt  $j > k$ ).

Der *Schätzfehler* wird wie folgt definiert:

$$\tilde{\mathbf{x}}(j|k) \triangleq \mathbf{x}(j) - \hat{\mathbf{x}}(j|k). \quad (3.12)$$

Die bedingte Kovarianzmatrix des Zustandes lautet:

$$\mathbf{P}(j|k) \triangleq E[(\mathbf{x}(j) - \hat{\mathbf{x}}(j|k))(\mathbf{x}(j) - \hat{\mathbf{x}}(j|k))' | Z^k] = E[\tilde{\mathbf{x}}(j|k) \tilde{\mathbf{x}}(j|k)' | Z^k]. \quad (3.13)$$

### 3.3.2. Kalman-Filter und Varianten

Haben sowohl der Zustand als auch die Messwerte normalverteilte Dichtefunktionen, so ist auch die auf die Messwerte bedingte Dichtefunktion des Zustandes normalverteilt und die in [Abbildung 3.6](#) auf Seite 26 dargestellten optimalen Schätzwerte fallen zusammen und stimmen ferner mit dem Least Squares und dem Minimum-Varianz-Schätzwert überein. Das Kalman-Filter ist ein rekursiver Algorithmus zur Bestimmung dieses Wertes, der alle bis zum aktuellen Zeitpunkt vorliegenden Messwerte berücksichtigt.

#### Standard Kalman-Filter

Die folgenden Betrachtungen verzichten auf den Steuerungsvektor, da dieser beim Tracking von dynamischen Objekten im Straßenverkehr nicht zur Verfügung steht. Der Schätzalgorithmus startet mit den Initialwerten für den Zustand  $\hat{\mathbf{x}}(0|0)$  und für die Kovarianz  $\mathbf{P}(0|0)$ , mit denen die  $n_x$ -dimensionale Normalverteilung vollständig beschrieben wird. Die Zustandsschätzung  $\mathbf{x}(k|k)$  zum Zeitpunkt  $k$  mit Kovarianz  $\mathbf{P}(k|k)$  wird unter Einbringung eines neuen Messwertes  $\mathbf{z}(k+1)$  für den Zeitpunkt  $k+1$  wie folgt aktualisiert:

1. Zunächst wird der (zeitlich) *prädizierte Zustand* aus der bisherigen Zustandsschätzung und der Systemmatrix bestimmt:

$$\hat{\mathbf{x}}(k+1|k) = \mathbf{F}(k) \hat{\mathbf{x}}(k|k). \quad (3.14)$$

Die zugehörige Kovarianzmatrix ergibt sich aus der prädizierten Zustandskovarianz und der Kovarianzmatrix des Prozessrauschens. Letztere beschreibt dabei die Modellunsicherheit, repräsentiert also Abweichungen vom Dynamikmodell.

$$\mathbf{P}(k+1|k) = \mathbf{F}(k) \mathbf{P}(k|k) \mathbf{F}(k)' + \mathbf{Q}(k). \quad (3.15)$$

2. Die *Messwertprädiktion* bestimmt über die Messmatrix  $\mathbf{H}$  den prädizierten Messwert:

$$\hat{\mathbf{z}}(k+1|k) = \mathbf{H}(k+1) \hat{\mathbf{x}}(k+1|k). \quad (3.16)$$

Man definiert die *Innovation*:

$$\boldsymbol{\nu}(k+1) \triangleq \mathbf{z}(k+1) - \hat{\mathbf{z}}(k+1|k). \quad (3.17)$$

Die zugehörige Innovationskovarianz ergibt sich über die Messmatrix aus der Zustandskovarianz sowie aus der Kovarianz des Messwertes.

$$\mathbf{S}(k+1) = \mathbf{H}(k+1) \mathbf{P}(k+1|k) \mathbf{H}(k+1)' + \mathbf{R}(k+1). \quad (3.18)$$

3. Man definiert die Filtermatrix:

$$\mathbf{W}(k+1) \triangleq \mathbf{P}(k+1|k) \mathbf{H}(k+1)' \mathbf{S}(k+1)^{-1}. \quad (3.19)$$

Schließlich werden der Systemzustand und die zugehörige Kovarianz aktualisiert:

$$\hat{\mathbf{x}}(k+1|k+1) = \hat{\mathbf{x}}(k+1|k) + \mathbf{W}(k+1) \boldsymbol{\nu}(k+1), \quad (3.20)$$

$$\mathbf{P}(k+1|k+1) = \mathbf{P}(k+1|k) - \mathbf{W}(k+1) \mathbf{S}(k+1) \mathbf{W}(k+1)'. \quad (3.21)$$

**Voraussetzungen:** Die initialen Schätzwerte für den Zustand  $\hat{\mathbf{x}}(0|0)$  und dessen Kovarianz  $\mathbf{P}(0|0)$  werden als bekannt vorausgesetzt, ebenso die Zustandsübergangsmatrix  $\mathbf{F}$  und die Messmatrix  $\mathbf{H}$ . Das Prozess- und Messrauschen ist erwartungswertfrei, weiß und die Kovarianzmatrix ist bekannt:

$$E[\mathbf{v}(k)] = \mathbf{0}, \quad (3.22)$$

$$E[\mathbf{v}(k) \mathbf{v}(j)'] = \mathbf{Q}(k) \delta_{kj}, \quad (3.23)$$

$$E[\mathbf{w}(k)] = \mathbf{0}, \quad (3.24)$$

$$E[\mathbf{w}(k) \mathbf{w}(j)'] = \mathbf{R}(k) \delta_{kj}. \quad (3.25)$$

Es bestehen keine Korrelationen zwischen den vorgenannten Größen:

$$E[\mathbf{x}(0) \mathbf{v}(k)'] = \mathbf{0}, \quad (3.26)$$

$$E[\mathbf{x}(0) \mathbf{w}(k)'] = \mathbf{0}, \quad (3.27)$$

$$E[\mathbf{v}(k) \mathbf{w}(j)'] = \mathbf{0}. \quad (3.28)$$

### Erweitertes Kalman-Filter (EKF)

Die Annahme einer linearen Systemmatrix sowie einer linearen Messmatrix ist in der Praxis häufig nicht erfüllt, sodass sich die Dynamik- und Messgleichungen wie folgt darstellen:

$$\mathbf{x}(k+1) = \mathbf{f}[k, \mathbf{x}(k)] + \mathbf{v}(k), \quad (3.29)$$

$$\mathbf{z}(k) = \mathbf{h}[k, \mathbf{x}(k)] + \mathbf{w}(k), \quad (3.30)$$

wobei  $\mathbf{f}$  die nicht-lineare Transferfunktion und  $\mathbf{h}$  die nicht-lineare Messfunktion beschreiben. Das Erweiterte Kalman-Filter dient dazu, diese nicht-linearen Funktionen durch geeignete Näherungen zu behandeln.

Die Zustandsprädiktion erfolgt beim Erweiterten Kalman-Filter gemäß [Formel 3.31](#). Der prädizierte Messwert ergibt sich aus [Formel 3.32](#).

$$\hat{\mathbf{x}}(k+1|k) = \mathbf{f}[k, \hat{\mathbf{x}}(k|k)], \quad (3.31)$$

$$\hat{\mathbf{z}}(k+1|k) = \mathbf{h}[k+1, \hat{\mathbf{x}}(k+1|k)]. \quad (3.32)$$

Um die prädizierte Zustandskovarianz  $\mathbf{P}(k+1|k)$  und die Innovationskovarianz  $\mathbf{S}(k+1)$  zu erhalten, werden die nicht-linearen Funktionen um den aktuellen bzw. prädizierten Schätzwert linearisiert, man erhält  $\mathbf{F}$  und  $\mathbf{H}$  als Jacobimatrizen.

$$\nabla_{\mathbf{x}} = \left( \frac{\partial}{\partial x_1}, \frac{\partial}{\partial x_2}, \dots, \frac{\partial}{\partial x_n} \right)', \quad (3.33)$$

$$\mathbf{F}(k) = [\nabla_{\mathbf{x}} \mathbf{f}(k, \mathbf{x})']'|_{\mathbf{x}=\hat{\mathbf{x}}(k|k)}, \quad (3.34)$$

$$\mathbf{H}(k+1) = [\nabla_{\mathbf{x}} \mathbf{h}(k+1, \mathbf{x})']'|_{\mathbf{x}=\hat{\mathbf{x}}(k+1|k)}. \quad (3.35)$$

Durch Ergänzung der Hessematrizen ist auch eine Linearisierung zweiter Ordnung möglich. Details finden sich bei [\[Bar-Shalom und Li 1993\]](#).

Die prädizierte Zustandskovarianz  $\mathbf{P}(k+1|k)$  ergibt sich jetzt anhand der linearisierten Zustandsübergangsmatrix  $\mathbf{F}(k)$  aus [Formel 3.15](#); analog berechnet sich die Innovationskovarianz über die linearisierte Messmatrix  $\mathbf{H}(k)$  aus [Formel 3.18](#). Die Berechnung der Filtermatrix ([Formel 3.19](#)) und des Zustands- und Kovarianzupdates erfolgen ebenfalls über die linearisierten Matrizen.

Die Näherung über die Linearisierungen führt dazu, dass der Erwartungswert nur noch genähert den Zustand beschreibt:

$$\hat{\mathbf{x}}(j|k) \approx E[\mathbf{x}(j)|Z^k]. \quad (3.36)$$

Es sind unterschiedliche Verfahren bekannt, die diesen Fehler minimieren und im weiteren Verlauf des Kapitels behandelt werden.

### Eigenschaften des Erweiterten Kalman Filters

Aufgrund der Linearisierungen liefert das EKF lediglich Näherungswerte für den Systemzustand und dessen Kovarianz. Ursache hierfür sind nach [\[De Geeter u. a. 1997\]](#) die beiden Hauptfehlerquellen:

1. Truncation Error: Dieser Fehler beruht bei der Linearisierung darauf, dass nur die erste Ableitung betrachtet wird und die Terme höherer Ordnung *abgeschnitten* werden. Wie bereits erwähnt ist die Hinzunahme dieser Terme möglich, führt jedoch zu einem erhöhten Rechenaufwand.

2. Base Point Error: Die Linearisierung erfolgt stets um den Schätzwert, nicht um den wahren Wert. Dies führt einerseits zu einem durch die Linearisierung bedingten Schätzfehler, des Weiteren kann dies dazu führen, dass das Filter nicht konvergiert.

### Unscented Kalman Filter (UKF)

Um die Linearisierungseffekte des EKF zu umgehen, lässt sich alternativ die *Unscented Transformation* verwenden. Der Hintergrund des Verfahrens ist der Ansatz, dass „es einfacher ist, eine Normalverteilung zu approximieren als eine beliebige nicht-lineare Funktion oder Transformation“ [Julier und Uhlmann 1997].

Während beim EKF die Kovarianzmatrizen des Systemzustandes und des Messwertes anhand von linearisierten Funktionen propagiert werden, die die beiden oben beschriebenen Fehlerquellen aufweisen, verzichtet man beim UKF vollständig auf die Linearisierung. An ihre Stelle tritt die Unscented Transformation, bei der für eine  $n_x$ -dimensionale Zufallsvariable  $2n_x + 1$  konkrete Punkte mit zugeordneten Gewichten gewählt werden, die die Kovarianzmatrix repräsentieren. Diese *Sigma-Punkte* werden über die nicht-linearen Funktionen transformiert, um anschließend den Erwartungswert und die transformierte Kovarianzmatrix zu rekonstruieren.

#### Funktionsweise der Unscented Transformation:

Gegeben sei die Zufallsvariable  $\mathbf{x}$  mit Dimension  $n_x$ , Erwartungswert  $\bar{\mathbf{x}}$  und Kovarianz  $\mathbf{P}_x$ , die über eine nicht-lineare Funktion  $\mathbf{y} = \mathbf{g}(\mathbf{x})$  propagiert wird. Gewählt werden  $2n_x + 1$  Sigma-Punkte  $\mathbf{p}_i$  und Faktoren  $w_i$  wie folgt ( $i = 1, 2, \dots, n_x$ ):

$$\mathbf{p}_0^x = \bar{\mathbf{x}} \quad (3.37)$$

$$\mathbf{p}_i^x = \bar{\mathbf{x}} + (\sqrt{(n_x + \kappa) \mathbf{P}_x})_i \quad (3.38)$$

$$\mathbf{p}_{i+n_x}^x = \bar{\mathbf{x}} - (\sqrt{(n_x + \kappa) \mathbf{P}_x})_i \quad (3.39)$$

$$w_0 = \kappa / (n_x + \kappa) \quad (3.40)$$

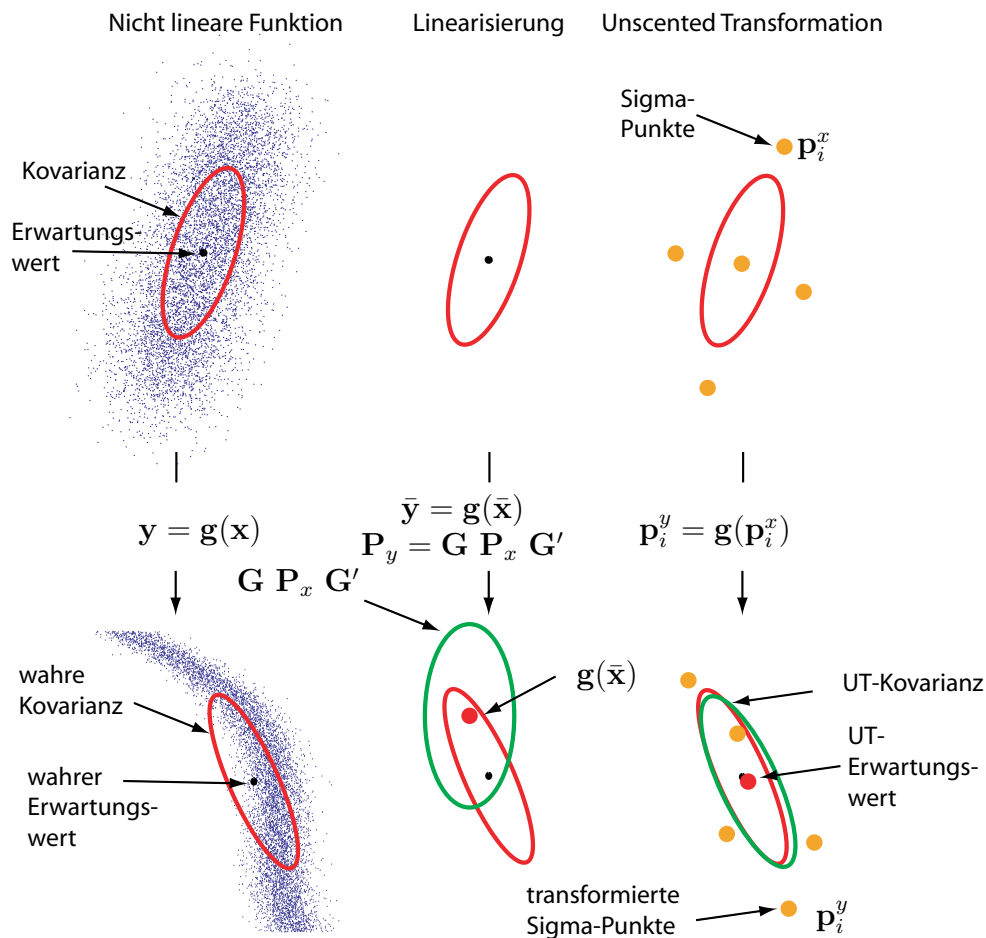
$$w_i = 1 / (2 (n_x + \kappa)) \quad (3.41)$$

$$w_{i+n_x} = 1 / (2 (n_x + \kappa)) \quad (3.42)$$

Der Parameter  $\kappa$  ist ein Skalierungsparameter (für Gaußverteilungen  $n_x + \kappa = 3$ ),  $(\sqrt{(n_x + \kappa) \mathbf{P}_x})_i$  entspricht der Quadratwurzel der  $i$ -ten Zeile der Kovarianzmatrix. Die gewählten Punkte werden zunächst transformiert

$$\mathbf{p}_i^y = \mathbf{g}(\mathbf{p}_i^x) \text{ für alle } i = 0, 1, \dots, 2n_x \quad (3.43)$$

und der transformierte Erwartungswert sowie dessen Kovarianz folgendermaßen ap-



**Abbildung 3.7.:** Propagierung von Erwartungswert und Kovarianz einer Gaußverteilung über eine nicht-lineare Funktion  $g$ . Gegenüberstellung von EKF und UKF nach [Wan und der Merwe 2000]

proximiert:

$$\bar{y} \approx \sum_{i=0}^{2n_x} w_i \mathbf{p}_i^y, \quad (3.44)$$

$$\mathbf{P}_y \approx \sum_{i=0}^{2n_x} w_i (\mathbf{p}_i^y - \bar{y}) (\mathbf{p}_i^y - \bar{y})'. \quad (3.45)$$

Abbildung 3.7 zeigt das Verfahren noch einmal schematisch. Für Gaußverteilte Zufallsvariablen liefert das Verfahren nach [Wan und der Merwe 2000] Genauigkeiten, die einer Taylor-Reihenentwicklung dritter Ordnung entsprechen.

### Funktionsweise des Unscented Kalman Filters:

Die zeitliche Prädiktion des Zustandsvektors sowie die Messwertprädiktion werden beim UKF ersetzt und die Berechnung der Filtermatrix geändert. Das Verfahren



basiert auf den folgenden Verarbeitungsschritten [Julier und Uhlmann 1997]:

1. Es wird ein erweiterter Zustandsvektor  $\hat{\mathbf{x}}^{\text{erw}}$  gebildet, um die Effekte des Prozessrauschens zu berücksichtigen<sup>6</sup>. Der neue Vektor hat die Dimension  $n_{\text{erw}} = 2 n_x$ .

$$\hat{\mathbf{x}}^{\text{erw}}(k|k) = \begin{pmatrix} \hat{\mathbf{x}}(k|k) \\ \mathbf{0}_{n_x \times 1} \end{pmatrix} \quad (3.46)$$

Die zugehörige Kovarianzmatrix lautet:

$$\mathbf{P}^{\text{erw}}(k|k) = \begin{pmatrix} \mathbf{P}(k|k) & \mathbf{0} \\ \mathbf{0} & \mathbf{Q}(k) \end{pmatrix} \quad (3.47)$$

2. Es werden über Formel 3.37 bis Formel 3.42 Sigma-Punkte für den erweiterten Vektor  $\hat{\mathbf{x}}^{\text{erw}}(k|k)$  mit Kovarianz  $\mathbf{P}^{\text{erw}}(k|k)$  gewählt und über die nicht-lineare Transferfunktion abgebildet:

$$\mathbf{p}_i^x(k+1|k) = \mathbf{f}(\mathbf{p}_i^x(k|k)). \quad (3.48)$$

3. Der prädizierte Erwartungswert des Zustandsvektors wird über die gewichtete Summe der transformierten Sigma-Punkte berechnet:

$$\hat{\mathbf{x}}(k+1|k) = \sum_{i=0}^{2n_{\text{erw}}} w_i \mathbf{p}_i^x(k+1|k). \quad (3.49)$$

4. Die prädizierte Zustandskovarianz wird bestimmt:

$$\mathbf{P}(k+1|k) = \sum_{i=0}^{2n_{\text{erw}}} w_i [\mathbf{p}_i^x(k+1|k) - \hat{\mathbf{x}}(k+1|k)] [\mathbf{p}_i^x(k+1|k) - \hat{\mathbf{x}}(k+1|k)]'. \quad (3.50)$$

5. Zu jedem transformierten Sigma-Punkt wird die Messwertprädiktion durchgeführt:

$$\hat{\mathbf{p}}_i^z(k+1|k) = \mathbf{h}(\mathbf{p}_i^x(k+1|k)). \quad (3.51)$$

6. Der prädizierte Messwert wird analog zum Zustandsvektor aus der gewichteten Summe ermittelt:

$$\hat{\mathbf{z}}(k+1|k) = \sum_{i=0}^{2n_{\text{erw}}} w_i \hat{\mathbf{p}}_i^z(k+1|k). \quad (3.52)$$

<sup>6</sup> In [Julier und Uhlmann 1997] wird eine allgemeinere Beschreibung für das nicht-lineare System verwendet als in Formel 3.31:  $\mathbf{x}(k+1) = \mathbf{f}[k, \mathbf{x}(k), \mathbf{v}(k)]$ . Die nicht-lineare Funktion schließt hier das Prozessrauschen ein.

7. Anschließend wird die Innovationskovarianz

$$\mathbf{S}(k+1) = \sum_{i=0}^{2n_x} w_i [\mathbf{p}_i^z(k+1|k) - \hat{\mathbf{z}}(k+1|k)] [\mathbf{p}_i^z(k+1|k) - \hat{\mathbf{z}}(k+1|k)]' + \mathbf{R}(k+1) \quad (3.53)$$

und die Kreuz-Kovarianzmatrix

$$\mathbf{P}_{x\nu}(k+1|k) = \sum_{i=0}^{2n_{\text{erw}}} w_i [\mathbf{p}_i^x(k+1|k) - \hat{\mathbf{x}}(k+1|k)] [\mathbf{p}_i^z(k+1|k) - \hat{\mathbf{z}}(k+1|k)]'$$

bestimmt.

8. Mit der Filtermatrix

$$\mathbf{W}(k+1) = \mathbf{P}_{x\nu}(k+1|k) \mathbf{S}(k+1)^{-1} \quad (3.54)$$

und der Innovation

$$\boldsymbol{\nu}(k+1) = \mathbf{z}(k+1) - \hat{\mathbf{z}}(k+1|k) \quad (3.55)$$

wird der Aktualisierungsschritt wie beim Standard Kalman-Filter gemäß [Formel 3.20](#) und [Formel 3.21](#) durchgeführt.

Neben den genannten Verbesserungen bei der Approximation der nicht-linearen Transfer- und Messfunktion ist auch die Komplexität des Verfahrens zu bewerten. Zur Prädiktion der Zustandskovarianz entfallen zwei Matrizenmultiplikationen der Größe  $n_x \times n_x$  (vgl. [Formel 3.31](#)) sowie der Dimension  $n_x \times n_y$  (vgl. [Formel 3.32](#)). Zusätzlicher Aufwand entsteht durch die Wahl der Sigma-Punkte und die Abbildung dieser  $4n_x$  Punkte sowohl über die Transferfunktion, als auch über die Messfunktion. Der Aufwand ist vergleichbar mit einem EKF, bei dem die Linearisierung der Funktionen numerisch erfolgt, wie dies bei komplexen Abbildungen der Fall ist<sup>7</sup>. Für eine rechenintensive komplexe Messfunktion, deren Linearisierung symbolisch bestimmbar ist, hat das UKF eine deutlich höhere Laufzeit. Schließlich ist anzumerken, dass das obige Verfahren nur funktioniert, falls der Messvektor für alle Sigma-Punkte die gleiche Dimension hat. Diese Einschränkung ist bei optischen Systemen nicht immer erfüllt.

Neuere Veröffentlichungen beschäftigen mit der weiteren Minimierung von Linearisierungseffekten bei trigonometrischen und Exponentialfunktionen [[Julier 2002](#)] sowie der Skalierung der Sigma-Punkte [[Julier und Uhlmann 2002](#)].

Als Anwendungsbeispiel zeigt [[Wada u. a. 2001](#)], wie mittels UKF der Fahrzeugzustand aus Inertialsensoren, Odometrie und DGPS geschätzt werden kann. Simulationen zeigen Verbesserungen gegenüber den EKF, eine Verifikation mit realen Sensordaten erfolgt nicht.

<sup>7</sup> In diesem Fall wird ebenfalls zur Gradientenbildung die nicht-lineare Funktion über ein iteratives Verfahren mehrfach berechnet.

### Constrained Kalman-Filter (CKF)

Die Zustandsgrößen unterliegen häufig physikalischen Randbedingungen, die der angenommenen Gaußverteilung widersprechen. Beispielsweise können geometrische Ausdehnungen wie Breite und Länge keine negativen Werte annehmen, sodass die Dichtefunktion an der Stelle Null eine Unstetigkeit aufweist. Auch durch die Näherungen beim EKF und UKF ergeben sich Fehler, die zu physikalisch unzulässigen Schätzgrößen führen können. Zustandsbeschränkungen können aber nicht nur dazu benutzt werden, Fehlschätzungen zu vermeiden, sondern die Schätzung selbst lässt sich durch Einbringung von Hintergrundwissen in Form von Zustandsbeschränkungen verbessern. Wird beispielsweise die Bewegung eines Fahrzeuges auf einer Straße mit bekanntem Verlauf geschätzt, so kann der Straßenverlauf als Zustandsbeschränkung für die Trajektorie des Fahrzeugs eingebracht werden. Es gibt unterschiedliche Verfahren, die Beschränkungen des Zustandsvektors zu modellieren und zu berücksichtigen.

#### Projektionsmethode:

[Simon und Chia 2002] beschäftigen sich ausführlich mit linearen Zustandsbeschränkungen. Eine lineare Beschränkung des Zustandes wird folgendermaßen dargestellt:

$$\mathbf{D} \mathbf{x} = \mathbf{d} \quad (3.56)$$

$\mathbf{D}$  ist eine  $s \times n_x$ -dimensionale Matrix,  $\mathbf{d}$  ein  $s \times 1$ -dimensionaler Vektor, wobei  $s \leq n_x$  die Anzahl der Beschränkungen ist.  $\mathbf{D}$  habe den Rang  $s$ , sodass keine lineare Abhängigkeit zwischen einzelnen Beschränkungen vorliegt. Gilt  $s = n_x$ , so ist der Zustand vollständig bekannt.


Die Zustandsbeschränkung wird nach dem Aktualisierungsschritt des Kalman Filters berücksichtigt. Hierzu wird die Projektionsmethode angewendet, die den unzulässigen Zustandsvektor auf die durch die Beschränkung definierte Hyperebene projiziert. Mathematisch bedeutet dies, dass der folgende Ausdruck minimiert wird:

$$\min_{\mathbf{x}^B} (\mathbf{x}^B - \hat{\mathbf{x}})' \mathbf{M} (\mathbf{x}^B - \hat{\mathbf{x}}), \text{ sodass } \mathbf{D} \mathbf{x}^B = \mathbf{d} \quad (3.57)$$

Hierbei ist  $\mathbf{M}$  eine beliebige positiv definite Gewichtsmatrix und  $\mathbf{x}^B$  der durch die Beschränkung korrigierte Zustandsvektor. Die Lösung von Formel 3.57 liefert:

$$\mathbf{x}^B = \hat{\mathbf{x}} - \mathbf{M}^{-1} \mathbf{D}' (\mathbf{D} \mathbf{M}^{-1} \mathbf{D}')^{-1} (\mathbf{D} \hat{\mathbf{x}} - \mathbf{d}) \quad (3.58)$$

Es lässt sich zeigen, dass die über die Maximum-Likelihood- bzw. Mean-Square-Methode bestimmten Zustandskorrekturen Sonderfälle der obigen Betrachtung mit  $\mathbf{M} = \mathbf{P}^{-1}$  bzw.  $\mathbf{M} = \mathbf{I}$  sind. Der korrigierte Zustandsvektor  $\mathbf{x}^B$  wird für die nachfolgenden Iterationen des Kalman-Filters benutzt.



**Abbildung 3.8.:** Korrektur des ungültigen Zustandsvektors  $\mathbf{x}^V$  durch den Pseudomesswert  $y^B$  zum gültigen Vektor  $\mathbf{x}^B$

### Pseudomesswerte:

[Richards 1995] beschreibt ein Verfahren, bei dem der ungültige Zustandsvektor durch einen Pseudomesswert korrigiert wird. Dieser Messwert wird so gewählt, dass durch eine Zustandsaktualisierung mit diesem Messwert der Zustandsvektor zurück in den Gültigkeitsbereich fällt. Dies ist in [Abbildung 3.8](#) visualisiert.

Die Zustandsbeschränkung wird bei [Richards 1995] durch die folgende Ungleichung ausgedrückt:

$$c_{\min} \leq \mathbf{C} \mathbf{x} \leq c_{\max}. \quad (3.59)$$

$c_{\min}$  und  $c_{\max}$  sind Skalare,  $\mathbf{C}$  eine  $1 \times n_x$  Matrix.

Bei der Korrektur durch den skalaren Pseudomesswert  $y^B$  wird auch die Zustandskovarianz, wie im Aktualisierungsschritt des Kalman-Filters vorgesehen, angepasst. Um den Einfluss der Korrektur auf die Zustandskovarianz so gering wie möglich zu halten, wird als Pseudomesswert der der Verletzung gegenüberliegende Extremwert mit einer entsprechend großen Varianz verwendet. Wird also das Maximum  $c_{\max}$  überschritten, wird  $c_{\min}$  als Messwert eingebracht und umgekehrt.

Die Varianz  $\mathbf{R}^B$  zum Pseudomesswert  $y^B$  berechnet sich gemäß [Formel 3.60](#). Der Ausdruck  $\mathbf{C} \hat{\mathbf{x}}^B$  entspricht hierbei dem Extremwert, den der Zustandsvektor nach der Korrektur annimmt,  $\hat{\mathbf{x}}^V$  ist der die Beschränkungen verletzende Zustandsvektor und  $\mathbf{P}$  die zugehörige Kovarianzmatrix:

$$\mathbf{R}^B = \mathbf{C} \mathbf{P} \mathbf{C}' \frac{(y^B - \mathbf{C} \hat{\mathbf{x}}^B)}{(\mathbf{C} \hat{\mathbf{x}}^B - \mathbf{C} \hat{\mathbf{x}}^V)}. \quad (3.60)$$

### Schwache Beschränkungen:

Beide vorgestellte Verfahren behandeln lineare Zustandsbeschränkungen und benutzen im Falle einer Nicht-Linearität die vom EKF bekannten Jacobi-Matrizen als Näherung. Um die Linearisierungseffekte zu minimieren, stellt [De Geeter u. a. 1997] das *Smoothly Constrained Kalman Filter* (SCKF) vor. Beschränkungen werden in diesem Fall durch die Gleichung

$$\mathbf{b} = \mathbf{c}_k(\hat{\mathbf{x}}) + \boldsymbol{\mu} \quad (3.61)$$

beschrieben, wobei  $\mu$  eine erwartungswertfreie Gaußverteilte Zufallsvariable mit Varianz  $\xi_k$  ist. Es wird unterschieden zwischen *starken* Beschränkungen, bei denen  $\xi_k = 0$  gilt (keine Unsicherheit), und *schwachen* Beschränkungen, bei denen  $\xi_k \neq 0$  gilt.

Auch in diesem Fall werden Pseudo-Messwerte eingebracht. Beim Aktualisierungsschritt des Kalman Filters wird die Innovation  $\mathbf{b} - \mathbf{c}_k(\hat{\mathbf{x}})$  verwendet. Im Gegensatz zu [Richards 1995] handelt es sich aber um ein iteratives Verfahren, bei dem die Varianz der Pseudomesswerte vergrößert wird. Auf diese Weise führt nicht ein einzelner Messwert zur vollständigen Korrektur des Zustandsvektors, sondern eine Folge. Da das Kalman-Filter als lineares Filter dieselbe Schätzung unabhängig davon liefert, ob ein Messwert einmal mit einfacher Varianz oder n-mal mit n-facher Varianz eingebracht wird, ergibt sich kein Vorteil, falls lineare Zustandsbeschränkungen vorliegen. Im Falle einer Nicht-Linearität reduziert sich jedoch der Base-Point-Error, also die Linearisierung um einen falschen Schätzwert, weil mehrfach linearisiert wird und bei jeder Iteration der Schätzwert verbessert wird.

### Fuzzy Kalman-Filter

Bei den bisher vorgestellten Verfahren wird jeder Messwert gemäß seiner Unsicherheit beim Aktualisierungsschritt des Filters eingebracht. Die Kovarianzen des Messwertes repräsentieren dabei seine Unsicherheit im Merkmalsraum, treffen jedoch keine Aussage über dessen Plausibilität. Beispielsweise gehen Messwerte von einem Sensor mit einer geringen Geisterzielrate ebenso ein wie die eines Sensors mit einer hohen Geisterzielrate.

[Horton und Jones 1995] ergänzen das Standard Kalman-Filter um Fuzzy Logik, um diesem Umstand gerecht zu werden. Die Modifikationen betreffen die Assoziation und den Aktualisierungsschritt.

**Der Fuzzy return processor** wird bei der Assoziation benutzt. Hierbei wird zunächst die Gültigkeit eines Messwertes über eine Fuzzy Zugehörigkeitsfunktion auf klassischen Assoziationsmerkmalen wie dem euklidischen Abstand bestimmt. Die Defuzzifizierung liefert einen Gültigkeitswert  $\beta_i^{\text{gültig}}$  für jeden Messwert  $\mathbf{z}_i$ . Andere unscharfe Merkmale wie beispielsweise Größe und Intensität werden genutzt, um anhand einer Fuzzy Regelbasis eine unscharfe Ähnlichkeit zu erhalten. Auch hier liefert die Defuzzifizierung eine Skalare Größe  $\beta_i^{\text{ähnlich}}$ . Empirisch ermittelte Gewichte werden benutzt, um beide Skalare miteinander zu kombinieren:

$$\beta_i = b_1 \beta_i^{\text{gültig}} + b_2 \beta_i^{\text{ähnlich}}, \text{ wobei } b_1 + b_2 = 1 \quad (3.62)$$

Die Messwerte werden zum *gewichteten mittleren Innovationsvektor* zusammengefasst:

$$\mathbf{z}^{gmI} = \sum_{i=1}^n \beta_i \mathbf{z}_i \quad (3.63)$$

**Der Fuzzy state correlator** bestimmt aus dem gewichteten mittleren Innovationsvektor den Korrekturvektor  $\mathbf{c}$ , der für die Zustandsaktualisierung im Kalman Filter benutzt wird. Hierzu wird jede Komponente des Messvektors zunächst fuzzyfiziert und anhand einer Regelbasis ein unscharfer Korrekturwert ermittelt. Die Regeln haben dabei den Aufbau

WENN (Merkmal <sub>$x$</sub>  ist *stark negativ*) UND (Merkmalsänderung <sub>$x$</sub>  ist *stark positiv*)  
DANN ( $c_i$  ist *null*).

Der unscharfe Korrekturwert wird anschließend defuzzifiziert, sodass sich ein *Fuzzy Äquivalent* zum Innovationsvektor  $\nu$  ergibt.

Positiv fällt an dem Ansatz auf, dass die Zustandsaktualisierung nicht über einen einzelnen Messwert erfolgt, sondern mehrere Messwerte bei der Assoziation berücksichtigt werden. Die Erstellung des gewichteten mittleren Innovationsvektors ist aber fraglich, wenn der Messwert neben einer Position auch Dynamikparameter wie die ortsabhängige Radialgeschwindigkeit umfasst. Die Modifikation der Innovation schließlich führt dazu, dass statistische Voraussetzungen des Kalman Filters wie die Normalverteilung der Messwerte verloren gehen und es erscheint insbesondere bei linearisierten Messfunktionen schwierig, den Einfluss eines Merkmals durch empirische Regeln zu definieren. Auf die Modifikation der Innovationskovarianz geht [Horton und Jones 1995] nicht ein.

### 3.3.3. Information-Filter

Das Information-Filter stellt eine duale Formulierung des Kalman-Filters dar und wird zum Beispiel in [Bar-Shalom und Li 1993] nicht als eigenes Filter, sondern als Optimierungsmaßnahme beschrieben.

Aufgrund der Annahme der Gaußverteilung des Systemzustandes entspricht die *Fisher Informationsmatrix*  $\mathfrak{S}(\mathbf{k})$  der Inversen der Zustandskovarianz

$$\mathfrak{S}(k) = \mathbf{P}(k|k)^{-1}. \quad (3.64)$$

Zwischen der Informationsmatrix  $\mathbf{N}(k|k) \triangleq \mathfrak{S}(k)$ , dem Informationsvektor  $\hat{\mathbf{n}}(k|k)$  und der Schätzung des Systemzustandes  $\hat{\mathbf{x}}(k|k)$  besteht folgender Zusammenhang:

$$\hat{\mathbf{n}}(k) = \mathbf{N}(k) \hat{\mathbf{x}}(k|k) \quad (3.65)$$

Während beim Kalman-Filter eine Rekursionsvorschrift für den Systemzustand und seine Kovarianz gegeben ist, erfolgt beim Information-Filter eine Rekursion für den Informationsvektor und dessen Kovarianz. Eine Herleitung findet sich in [Becker 2001].

Die Rekursion gliedert sich in folgende Schritte:

- Zunächst werden der Informationsbeitrag  $\mathbf{i}(k)$  einer neuen Messung und dessen Kovarianz  $\mathbf{I}(k)$  sowie ein Propagierungskoeffizient  $\mathbf{L}(k)$  berechnet:

$$\mathbf{i}(k+1) \triangleq \mathbf{H}'(k+1) \mathbf{R}^{-1}(k+1) \mathbf{z}(k+1), \quad (3.66)$$

$$\mathbf{I}(k+1) \triangleq \mathbf{H}'(k+1) \mathbf{R}^{-1}(k+1) \mathbf{H}(k+1), \quad (3.67)$$

$$\mathbf{L}(k+1|k) = \mathbf{P}^{-1}(k+1|k) \mathbf{F}(k+1) \mathbf{P}(k+1|k). \quad (3.68)$$

- Die Prädiktion des Informationsvektors und der Informationsmatrix ergeben sich zu

$$\hat{\mathbf{n}}(k+1|k) = \mathbf{L}(k+1|k) \hat{\mathbf{n}}(k|k), \quad (3.69)$$

$$\mathbf{N}(k+1|k) = [\mathbf{F}(k+1) \mathbf{N}^{-1}(k|k) \mathbf{F}(k+1)' + \mathbf{Q}(k+1)]^{-1}. \quad (3.70)$$

- Der Aktualisierungsschritt des Filters lautet:

$$\hat{\mathbf{n}}(k+1|k+1) = \hat{\mathbf{n}}(k+1|k) + \mathbf{i}(k+1), \quad (3.71)$$

$$\mathbf{N}(k+1|k+1) = \mathbf{N}(k+1|k) + \mathbf{I}(k+1). \quad (3.72)$$

Die Vorteile des Information-Filters liegen in einer trivialen Initialisierung, indem der Informationsvektor auf Null gesetzt wird. Die Informationsmatrix muss mit kleinen Werten initialisiert werden, um die Invertierbarkeit zu gewährleisten.

Des Weiteren ergeben sich Vorteile in der Komplexität des Algorithmus [Bar-Shalom und Li 1993]. Während beim Standard Kalman-Filter die Innovationskovarianz mit Dimension  $n_z \times n_z$  invertiert werden muss, wird beim Information-Filter die Zustandskovarianz mit Dimension  $n_x \times n_x$  invertiert. Ist die Dimension des Messvektors größer als die des Zustandsvektors, ergeben sich hier Vorteile. Die Invertierung der Kovarianzmatrix des Messvektors ist aufgrund der in der Regel vorhandenen Symmetrie zu vernachlässigen.

Nachteilig ist, dass Informationsvektor und Kovarianz keine physikalische Interpretation zulassen, was die Bewertung der Filterperformance erschwert.

In [Mutambara 1998] wird das Extended Information-Filter (EIF) vorgestellt, bei dem ebenso wie beim EKF Linearisierungen um die aktuelle Zustandsschätzung erfolgen. Die Äquivalenz wird anhand von Beispielen demonstriert. Da für die Linearisierungen der aktuelle Zustand benötigt wird, dieser aber beim Information-Filter nicht explizit vorliegt, ist in jedem Filterschritt eine weitere Matrixinversion erforderlich, um diesen zu berechnen.

### 3.3.4. Filter-Adaption

Alle vorgestellten Filter verfolgen ein Objekt mit einem festen Parametersatz. Dazu werden der Zustandsvektor der Objekte, die Übergangsfunktion sowie die Rauschterme so gewählt, dass eine stabile Verfolgung während typischer Objektmanöver

möglich ist. Obwohl sich das Kalman-Filter sehr robust gegenüber Verletzungen des Modells zeigt, wird die Schätzung eines solchen Filters stets suboptimal sein, da eine konkrete Parametrierung nicht nur die tatsächliche Objektbewegung, sondern auch die möglichen Alternativen abdecken muss. Verschiedene Verfahren zur Minimierung und Beseitigung des Problems werden im Folgenden vorgestellt.

### Varianzadaption

Eine Modellabweichung manifestiert sich in einer „großen“ Innovation, da die Prädiktion die wahre Objekttrajektorie nicht hinreichend genau beschreibt. Bei großen Abweichungen ist eine Assoziation schließlich nicht mehr möglich und es muss eine neue Objekthypothese aufgesetzt werden. Ein statistisches Abstandsmaß ergibt sich über das *normierte Innovationsquadrat*<sup>8</sup>, das auch als *quadrierter Mahalanobis-Abstand*  $\epsilon_\nu(k)$  bezeichnet wird.  $\epsilon_\nu(k)$  ist  $\chi^2$  verteilt mit  $n_z$  Freiheitsgraden.

$$\epsilon_\nu(k) = \boldsymbol{\nu}(k)' \mathbf{S}(k)^{-1} \boldsymbol{\nu}(k). \quad (3.73)$$

Ein Manöver lässt sich durch Überschreitung eines Schwellwerts  $\epsilon_{max}$  für den quadrierten Mahalanobis-Abstand erkennen. Details hierzu werden bei der Assoziation behandelt. Die folgenden zwei Verfahren erhöhen die Variabilität eines Dynamikmodells und führen so zu einer Verringerung des Mahalanobis-Abstandes [[Bar-Shalom und Li 1993](#)]:

**Bei der kontinuierlichen Rauschanpassung** wird bei der zeitlichen Prädiktion gemäß [Formel 3.15](#) ein zusätzlicher Skalierungsfaktor  $\psi(k)$  eingeführt:

$$\mathbf{P}(k+1|k) = \mathbf{F}(k) \mathbf{P}(k|k) \mathbf{F}(k)' + \psi(k) \mathbf{Q}(k). \quad (3.74)$$

Gilt  $\psi(k) > 1.0$ , so vergrößert sich die prädizierte Zustandskovarianz, sodass stärkere Abweichungen vom Modell abgedeckt werden. Als Folge vergrößert sich auch die Zustandskovarianz gemäß [Formel 3.18](#) und der Mahalanobis-Abstand verringert sich, da hier die Inverse der Innovationskovarianz gebildet wird. Der Skalierungsfaktor wird bei Überschreitung des Schwellwertes  $\epsilon_{max}$  gerade so gewählt, dass  $\epsilon_\nu(k) = \epsilon_{max}$  gilt.

**Bei der diskreten Rauschlevel-Umschaltung** erfolgt keine Skalierung der Kovarianzmatrix  $\mathbf{Q}$  des Prozessrauschens, sondern es werden diskrete Kovarianzmatrizen  $\mathbf{Q}_i$  benutzt, zwischen denen umgeschaltet wird. Statt des einfachen Mahalanobis-Abstandes verwendet man häufig einen gleitenden Durchschnitt über  $s$  Elemente<sup>9</sup>:

<sup>8</sup> engl.: Normalized Innovation Squared - NIS

<sup>9</sup> engl.: Average Normalized Innovation Squared - ANIS



$$\epsilon_{\nu}^s(k) = \sum_{j=k-s+1}^k \epsilon_{\nu}(j). \quad (3.75)$$

Die Umschaltung von einem Rauschlevel  $\mathbf{Q}_i$  zu einem höheren Rauschlevel  $\mathbf{Q}_{i+1}$  erfolgt, sobald eine Aufwärtsschwelle überschritten wird. Umgekehrt wird bei Unterschreitung einer Abwärtsschwelle auf ein geringeres Rauschlevel zurückgeschaltet. Beide Schwellwerte sind empirisch zu ermitteln. Eine Anwendung aus dem Bereich der Fahrumgebungserfassung findet sich in [Weiß 2003].

### Variabler Zustandsraum

Die Anpassung der Kovarianz des Prozessrauschens lässt zwar stärkere Abweichungen vom Modell zu, bewirkt jedoch über die Prädiktion der Zustandskovarianz (Formel 3.15 auf Seite 28) eine größere Unsicherheit bei der Zustandsschätzung. Da Zustandsraum und Systemmatrix fest sind, müssen diese so gewählt werden, dass sämtliche Objektmanöver abgedeckt werden. Dies führt zu einem Informationsverlust, da bei einfachen Manövern Parameter mitgeschätzt werden, deren Wert Null ist. Des Weiteren erhöht sich durch zusätzliche Parameter im Zustandsvektor auch die Komplexität des Filters.

Abhilfe schafft der variable Zustandsraum beim Tracking. Hierbei wird stets der minimale zur Objektverfolgung nötige Parametersatz verwendet. Reicht dieser nicht aus, so wird ein erweitertes Modell verwendet.

Ein Beispiel aus dem Automobilbereich findet sich in [Weiß u. a. 2003]. Hierbei werden unterschiedliche Bewegungszustände von Fahrzeugen über unterschiedliche Zustandsvektoren und Transferfunktionen geschätzt.

Die Umschaltung von einem Modell niedriger Ordnung zu einem höherer Ordnung erfolgt in der Regel über die bereits beschriebenen Innovationsschwellwerte. Da das Modell höherer Ordnung mehr Freiheitsgrade aufweist und bei höherer Dynamik auch größere Rauschterme verwendet werden, ist das Ende eines Manövers jedoch auf diese Weise schwieriger zu erkennen [Bar-Shalom und Li 1993, Kapitel 11]. Zu diesem Zweck wird daher ein Signifikanztest für die zusätzlichen Parameter durchgeführt. Hierzu betrachtet man

$$\epsilon_{\hat{\mathbf{a}}}(k) = \hat{\mathbf{a}}(k|k)' \mathbf{P}_a^m(k|k)^{-1} \hat{\mathbf{a}}(k|k), \quad (3.76)$$

wobei  $\hat{\mathbf{a}}(k|k)$  die Schätzung der ergänzten Parameter des erweiterten Modells und  $\mathbf{P}_a^m$  die entsprechenden Komponenten der Kovarianzmatrix sind. Fällt der gleitende Durchschnitt über  $p$  Elemente

$$\epsilon_{\hat{\mathbf{a}}}^p(k) = \sum_{j=k-p+1}^k \epsilon_{\hat{\mathbf{a}}}(j) \quad (3.77)$$

unter einen Schwellwert, so sind die Parameter nicht signifikant und das reduzierte Modell kann verwendet werden.

Eine weitere Schwierigkeit besteht in der verspäteten Manöverdetektion durch den gleitenden Durchschnitt. Dies bedeutet, dass die Umschaltung auf das erweiterte Modell erst erfolgt, nachdem das Manöver bereits begonnen hat. Der Einschwingvorgang des Filters wird damit erschwert. Werden die Messwerte zwischengespeichert, besteht die Möglichkeit, diese zur Initialisierung des erweiterten Modells heranzuziehen.

### 3.3.5. Multi-Modell-Verfahren

Die große Schwäche der bisher vorgestellten Schätzverfahren besteht in der Unimodalität<sup>10</sup>, das heißt, sie verfolgen stets nur ein einziges Modell, von dem angenommen wird, dass es den augenblicklichen Objektzustand am besten beschreibt.

Demgegenüber verwenden Multi-Modell-Verfahren mehrere Modelle zur Zustandsschätzung. Die Systeme werden als *hybrid* bezeichnet, da sie kontinuierliche Unsicherheiten (Rauschen) und diskrete Unsicherheiten (Modell oder Modus) kombinieren.

Hintergrund des Multi-Modell-Ansatzes ist, dass für unterschiedliche Bewegungszustände eines Objektes (beispielsweise stationär, beschleunigend, konstante Geschwindigkeit) unterschiedliche Filter verwendet werden, die nicht – wie beim Variablen Zustandsraum – alternativ sondern *gleichzeitig* an der Schätzung des Objektzustandes beteiligt sind. Man spricht von einer Filterbank. Die Innovationen der einzelnen Filter werden benutzt, um jedem Filter eine Gültigkeitswahrscheinlichkeit zuzuordnen. Die Gesamtschätzung der Filterbank stellt sich als nach Wahrscheinlichkeiten gewichtete Kombination der Einzelschätzungen dar.

Man unterscheidet Multi-Modell-Verfahren mit festem Modell und wechselnden Modellen. Erstere sind durch einen zeitinvarianten Modus gekennzeichnet. Dies bedeutet, dass die Objektbewegung einem konkreten Modell der Filterbank genügt, welches sich nicht ändert. Dies ist in der Praxis nur selten der Fall. Bei wechselnden Modellen hingegen können Übergänge von einem zu einem anderen Modell erfolgen, die als Markow Prozess (Markow Kette) mit bekannten Übergangswahrscheinlichkeiten angenommen werden. Unterschiedliche Verfahren wie der generalized pseudo-Bayesian Ansatz erster und zweiter Ordnung (GBP1 / GBP2) sowie das Interacting Multiple Model Filter (IMM) unterscheiden sich in der Berücksichtigung der Übergangswahrscheinlichkeiten, während es sich bei den parallel arbeitenden Filtern üblicherweise um EKF handelt. Alle drei Verfahren verfolgen aus Komplexitätsgründen nur eine fest begrenzte Anzahl von Modellübergangshypothesen, sodass sie im statistischen Sinne suboptimal sind.

Als einer der effizientesten suboptimalen Schätzer ([Mazor u. a. 1998]) wird hier das IMM-Filter dargestellt.

<sup>10</sup> Eine Verteilungsfunktion  $F$  heißt *unimodal* mit Modus  $m$ , wenn eine Zahl  $m$  existiert derart, dass  $F$  im Intervall  $]-\infty; m]$  konvex und im Intervall  $[m; \infty[$  konkav ist.

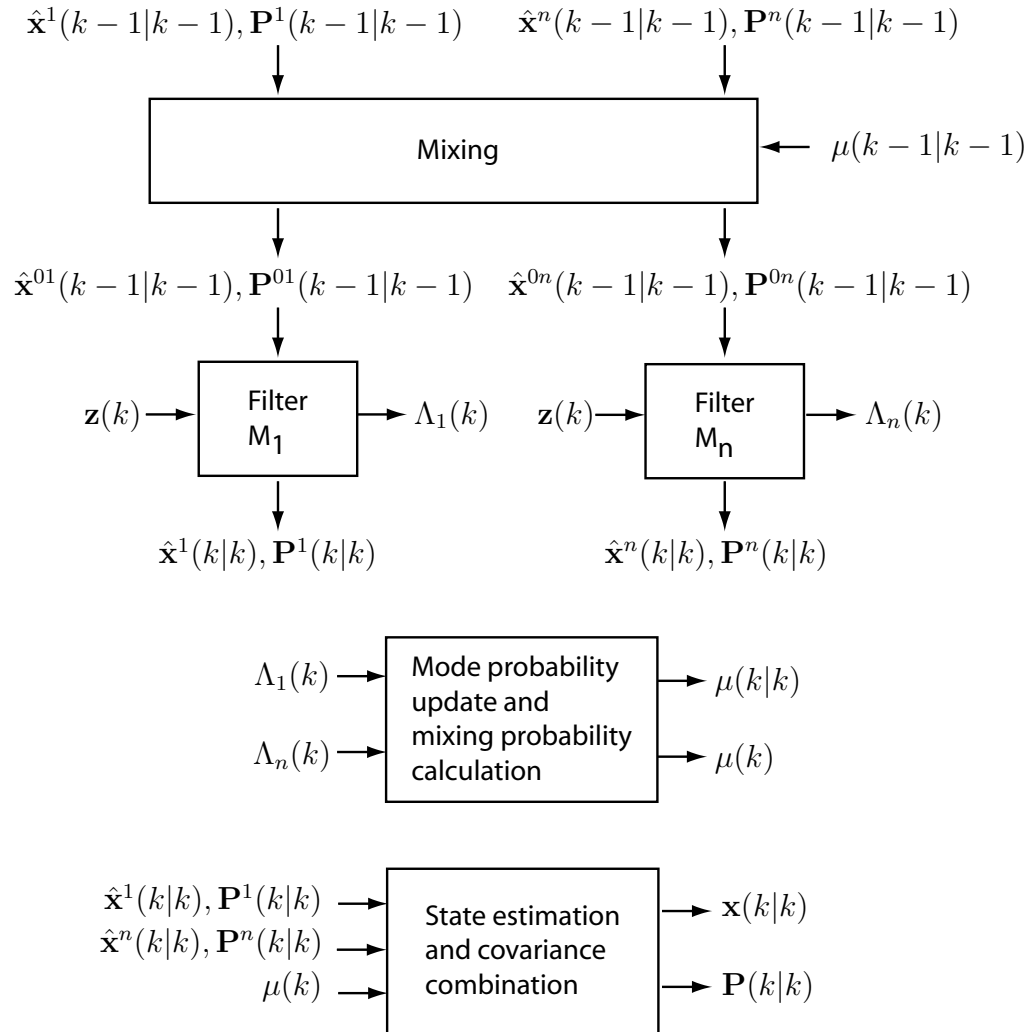


Abbildung 3.9.: Flussdiagramm des IMM-Algorithmus nach [Bar-Shalom und Li 1993]

### Interacting Multiple Modell (IMM)

Den schematischen Ablauf des IMM-Algorithmus zeigt [Abbildung 3.9](#). Zu erkennen ist, dass den parallel arbeitenden Filtern eine Interaktionsphase (auch Mischphase) vorgeschaltet ist und vor der Ausgabe die Modellwahrscheinlichkeiten aktualisiert werden.

Zu Beginn des Filterschritts  $k$  liegen die folgenden Größen aus dem letzten Filterschritt vor:

Hierbei bezeichnet der Index  $j = 1, 2, \dots, r$  das jeweilige Modell. Als a priori bekannt werden ferner die zeitinvarianten Übergangswahrscheinlichkeiten  $p_{ij}$  mit  $i, j = 1, 2, \dots, r$  vorausgesetzt, die die Wahrscheinlichkeit eines Übergangs von Mo-

$\hat{\mathbf{x}}^j(k-1 k-1)$	Zustandsschätzung Modell $j$ ,
$\mathbf{P}^j(k-1 k-1)$	Zustandskovarianz Modell $j$ ,
$\mu^j(k-1)$	Modellwahrscheinlichkeit für Modell $j$ .

dell  $i$  auf Modell  $j$  während eines Iterationsschrittes beschreiben.

Die einzelnen Phasen des IMM-Algorithmus werden nachfolgend basierend auf [Bar-Shalom und Li 1993; Blackman und Populi 1999] beschrieben:

- Bestimmung der Mischwahrscheinlichkeiten: Es wird die Wahrscheinlichkeit  $\mu_{i|j}(k-1|k-1)$  dafür bestimmt, dass Modell  $i$  zum Zeitpunkt  $k-1$  aktiv war, gegeben dass Modell  $j$  zum Zeitpunkt  $k$  aktiv ist.

$$\mu_{i|j}(k-1|k-1) = \frac{1}{\bar{c}_j(k-1)} p_{ij} \mu_i(k-1), \text{ wobei } i, j = 1, 2, \dots, r. \quad (3.78)$$

Hierbei beschreibt die Normierungskonstante

$$\bar{c}_j(k-1) = \sum_{i=1}^r p_{ij} \mu_i(k-1), \text{ wobei } j = 1, 2, \dots, r, \quad (3.79)$$

die Wahrscheinlichkeit für Modell  $j$  nach der Interaktion.

- Mischen: Für jedes Filter  $j = 1, 2, \dots, r$  wird nun den Mischwahrscheinlichkeiten entsprechend ein gemischter Zustand mit zugehöriger Kovarianz berechnet, der dem Filter als Eingang dient.

$$\hat{\mathbf{x}}^{0j}(k-1|k-1) = \sum_{i=1}^r \hat{\mathbf{x}}^i(k-1|k-1) \mu_{i|j}(k-1|k-1) \quad (3.80)$$

$$\begin{aligned} \mathbf{P}^{0j}(k-1|k-1) = & \sum_{i=1}^r \mu_{i|j}(k-1|k-1) \{ \mathbf{P}^i(k-1|k-1) \\ & + [\hat{\mathbf{x}}^i(k-1|k-1) - \bar{\mathbf{x}}^{0j}(k-1|k-1)] \\ & \cdot [\hat{\mathbf{x}}^i(k-1|k-1) - \bar{\mathbf{x}}^{0j}(k-1|k-1)]' \} \quad (3.81) \end{aligned}$$

Der Eingangszustandsvektor eines Filters  $j$  ergibt sich also aus den Schätzungen der letzten Iteration von *allen* Filtern. Je größer die Modellwahrscheinlichkeit von Modell  $i$  und je größer seine Übergangswahrscheinlichkeit auf das Modell  $j$  ist, umso größer ist der Einfluss der Zustandsschätzung auf den Eingangszustandsvektor vom Filter  $j$ .

- Assoziation: Die Datenassoziation kann für alle Modelle gemeinsam anhand eines kombinierten Modells erfolgen. Hierbei gibt es zwei Möglichkeiten:
  1. Die Eingangszustandsvektoren und Kovarianzen der einzelnen Filter lassen sich miteinander kombinieren und der gemeinsame Zustandsvektor

mit Kovarianz wird zeitlich prädiziert.

2. Jedes Filter prädiziert Eingangszustandsvektor und Kovarianz anhand des eigenen Modells und die prädizierten Zustandsvektoren und Kovarianzen werden miteinander kombiniert.

Die zweite Vorgehensweise ist insofern präziser, als die speziellen Modelleigenschaften der Filter genutzt werden. Jedes Filter  $j$  liefert in diesem Fall den zeitlich prädizierten Zustandsvektor  $\hat{\mathbf{x}}^j(k|k-1)$  mit Kovarianz  $\mathbf{P}^j(k|k-1)$ . Die Kombination erfolgt anhand der Modellwahrscheinlichkeiten  $\bar{c}_j$  nach der Interaktion:

$$\hat{\mathbf{x}}(k|k-1) = \sum_{j=1}^r \bar{c}_j(k-1) \hat{\mathbf{x}}^j(k|k-1), \quad (3.82)$$

$$\mathbf{P}(k|k-1) = \sum_{j=1}^r \bar{c}_j(k-1) \mathbf{P}^j(k|k-1). \quad (3.83)$$

- Filterupdate: Im Falle einer erfolgreichen Assoziation wird der Messwert  $\mathbf{z}(k)$  bei allen Filtern eingebracht und es ergeben sich die aktualisierten Zustandsschätzungen  $\hat{\mathbf{x}}^j(k|k)$  mit Kovarianz  $\mathbf{P}^j(k|k)$ . Bei der Zustandsaktualisierung ergaben sich die Innovationen  $\boldsymbol{\nu}^j(k)$  mit Kovarianz  $\mathbf{S}^j(k)$  für die einzelnen Modelle.
- Update der Modellwahrscheinlichkeiten: Die Likelihood-Funktion der Beobachtung, gegeben dass das Modell  $j$  aktiv ist, lautet bei  $m$  als Dimension des Messvektors:

$$\Lambda_j(k) = \frac{1}{\sqrt{(2\pi)^m |\mathbf{S}^j(k)|}} \exp\left(\frac{-\boldsymbol{\nu}^j(k)' \mathbf{S}^j(k)^{-1} \boldsymbol{\nu}^j(k)}{2}\right) \quad (3.84)$$

Der Exponent der exp-Funktion enthält den Mahalanobis-Abstand zwischen dem prädizierten Messwert und der Beobachtung. Es werden die Modellwahrscheinlichkeiten der  $j$  Filter aktualisiert:

$$\mu_j(k) = \frac{1}{c} \Lambda_j(k) \bar{c}_j, \text{ wobei} \quad (3.85)$$

$$c = \sum_{j=1}^r \Lambda_j(k) \bar{c}_j. \quad (3.86)$$

Eine kleiner Mahalanobis-Abstand bedeutet, dass der Messwert dicht bei der Prädiktion liegt. Damit stimmt die Zustandsprädiktion (also das Modell) gut mit der tatsächlichen Trajektorie im Zustandsraum überein und die Modellwahrscheinlichkeit ist entsprechend größer als bei einem großen Mahalanobis-Abstand.

- Kombination der Zustandsschätzungen und Kovarianzen: Die Schätzungen der einzelnen Filter und die Kovarianzen werden für die Benutzerausgabe kombi-

niert:

$$\hat{\mathbf{x}}(k|k) = \sum_{j=1}^r \hat{\mathbf{x}}^j(k|k) \mu_j(k), \quad (3.87)$$

$$\mathbf{P}(k|k) = \sum_{j=1}^r \mu_j(k) \cdot \left\{ \mathbf{P}^j(k|k) + [\hat{\mathbf{x}}^j(k|k) - \hat{\mathbf{x}}(k|k)] [\hat{\mathbf{x}}^j(k|k) - \hat{\mathbf{x}}(k|k)]' \right\}. \quad (3.88)$$

Die Kombination der Zustandsschätzungen und Kovarianzen ist kein Bestandteil der Rekursion und dient ausschließlich der Ausgabe.

Der IMM-Algorithmus hat sich beim Objekttracking von Flugkörpern etabliert und es sind Anwendungen aus dem Automobilbereich realisiert worden [Zhao und Thorpe 1998]. Die Herausforderungen liegen in den Designparametern des Algorithmus. Modelle und Übergangswahrscheinlichkeiten werden bisher empirisch gewählt, wobei typischerweise drei möglichst verschiedene Modelle gewählt werden<sup>11</sup>. Ein systematischer Ansatz, die optimale Modellmenge zu bestimmen, ist bisher nicht bekannt und in [Li 1994; Li u. a. 1999a, b; Li 2000] wird gezeigt, dass eine falsche Modellmenge die Schätzung sogar verschlechtern kann. Der IMM-Algorithmus zeigt daher ein erhebliches Potenzial, wird jedoch auch in den nächsten Jahren - insbesondere bei der Verfolgung von Objekten im Straßenverkehr - Forschungsgegenstand bleiben.

### 3.4. Assoziationsverfahren

Allen im vorangegangenen Abschnitt vorgestellten Fusionsarchitekturen ist gemeinsam, dass der Tracking-Prozess eine explizite Zuordnung zwischen Messwerten und Objekten bzw. deren prädizierten Messwerten voraussetzt. Die Assoziation gliedert sich dabei in zwei Teilschritte: Zunächst werden über *Suchbereiche*<sup>12</sup> gewisse Zuordnungen ausgeschlossen. Anschließend werden über ein *Zuweisungsverfahren* aus den zulässigen Zuordnungen jene bestimmt, die für ein gewähltes Kriterium optimal sind.

Zwei Fehler sind hierbei zu vermeiden [Singh und Bailey 1997]:

1. Verfehlte Zuordnungen (Typ I-Fehler): Obwohl eine Beobachtung zu einem Objekt gehört, findet keine Zuordnung statt.
2. Falsche Zuordnungen (Typ II-Fehler): Eine Beobachtung wird einem Objekt zugeordnet, von dem sie nicht stammt.

<sup>11</sup> Für die Darstellung des IMM-Filters für Zustandsvektoren aus unterschiedlichen Zustandsräumen sei auf [Blackman und Popoli 1999, Kapitel 4.5] verwiesen

<sup>12</sup> engl.: Gates

Durch Typ I-Fehler wird die Objektverfolgung in zweifacher Hinsicht gestört. Einerseits wird der korrekte Track eines Objektes nicht durch den zugehörigen Messwert gestützt, andererseits kann ein nicht zugeordneter Messwert zur Initialisierung eines neuen Objektes führen. Über Suchbereiche soll diese Problematik entschärft werden.

Durch Typ II-Fehler wird die Schätzung eines Objektzustandes verschlechtert, da die fehlerhaft zugeordnete Beobachtung den Zustandsvektor entsprechend modifiziert. Möglicherweise werden hierbei auch die Voraussetzungen eines Filters verletzt. Über das Zuordnungsverfahren sollen diese Fehler minimiert werden. Typ II-Fehler können bei entsprechender Störung der Zustandsschätzung Typ I-Fehler verursachen.

### 3.4.1. Suchbereiche

Intuitiv ist einsichtig, dass Beobachtungen, die *zu weit entfernt* von einem Objekt liegen, diesem nicht zuzuordnen sind. Es kann sich hierbei um Ausreißer und Geisterziele handeln, die die Zustandsschätzung des betrachteten Objektes sogar verschlechtern können. Auch neue Ziele müssen als solche identifiziert werden, um neue Tracks zu initialisieren.

Formal können sich der Zustandsraum der Objekte und der Merkmalsraum der Messwerte unterscheiden. Man definiert daher ein geeignetes Maß, um den Abstand zwischen dem prädizierten Messvektor und der Beobachtung zu quantifizieren und über einen Schwellwert den Suchbereich<sup>13</sup> zu einem prädizierten Messwert festzulegen. Die folgende Betrachtung beschränkt sich auf kontinuierlich verteilte Zustandsgrößen, eine Fusion auf Interpretations- bzw. Klassifikationsebene ist hiermit nicht durchführbar. Geeignete Verfahren finden sich beispielsweise in [Aziz 1999].

Abbildung 3.10 zeigt eine beispielhafte Konstellation von Prädiktionen, Suchbereichen und Beobachtungen. Die Beobachtungen 1 bis 3 lassen sich konfliktfrei zuweisen, da sie in den Suchbereich von genau einer Prädiktion fallen. Beobachtung 4 verursacht ebenfalls keinen Konflikt, da sie außerhalb aller Suchbereiche liegt und somit einen neuen Track initialisiert. Beobachtung 5 hingegen liegt im Suchbereich von Prädiktion 1 und 3, sodass beide Zuweisungen möglich wären. Solche Konfliktsituationen werden später vom Zuordnungsverfahren aufgelöst. Messwerte von bereits initialisierten Objekttracks werden von potenziellen neuen Objekttracks über die Suchbereiche separiert. Daher müssen die Bereiche einerseits groß genug gewählt werden, um die korrekten Messwerte einzufangen und andererseits klein genug, um neue Objekte zu identifizieren.

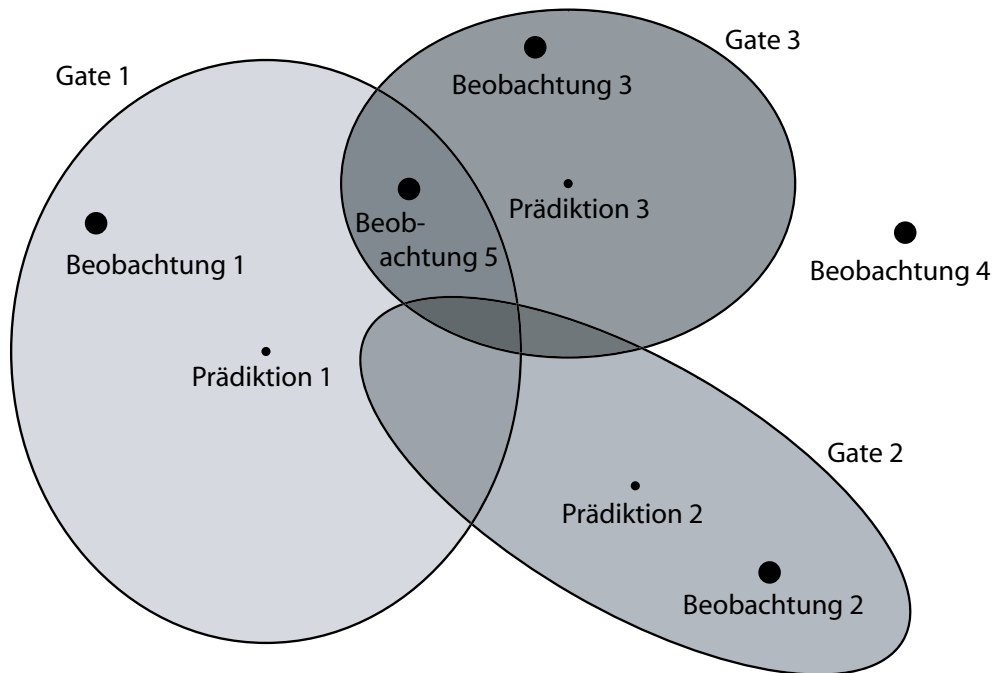
In der Regel verwendet man als Abstandsmaß zwischen den Vektoren  $\mathbf{y}$  und  $\hat{\mathbf{y}}$  eine Metrik  $d$ , sodass die folgenden Eigenschaften erfüllt sind:

$$d(\hat{\mathbf{y}}, \mathbf{y}) = 0 \Leftrightarrow \hat{\mathbf{y}} = \mathbf{y} \quad \text{Identitätsaxiom} \quad (3.89)$$

$$d(\hat{\mathbf{y}}, \mathbf{y}) = d(\mathbf{y}, \hat{\mathbf{y}}) \geq 0 \quad \text{Symmetrieeigenschaft} \quad (3.90)$$

$$d(\hat{\mathbf{y}}, \mathbf{y}) \leq d(\hat{\mathbf{y}}, \mathbf{z}) + d(\mathbf{z}, \mathbf{y}) \quad \text{Dreiecksungleichung} \quad (3.91)$$

<sup>13</sup>engl.: Gate



**Abbildung 3.10.:** Mögliche Konstellation zwischen Prädiktionen, Suchbereichen und Beobachtungen.

Offensichtlich erfüllt eine Reihe von Abstandsmaßen wie der Euklidische Abstand bzw. allgemeiner der Minkowski-Abstand beliebiger Ordnung [Aziz 1999, S. 24] diese Eigenschaften. Im Folgenden werden jedoch nur solche Suchbereiche näher betrachtet, die *statistische* Abstandsmaße benutzen, um neben der absoluten Abweichung zwischen Beobachtung und Prädiktion auch die Unsicherheiten zu berücksichtigen.

### Rechteckige Suchbereiche

Rechteckige Suchbereiche nach [Blackman und Populi 1999, Kapitel 6] sollten korrekterweise als komponentenweise Suchbereiche bezeichnet werden, da sie lediglich im zweidimensionalen kartesischen Raum Rechtecke beschreiben. Es muss für alle Komponenten die folgende Beziehung gelten:

$$|y_l - \hat{y}_l| = |\nu_l| \leq k\sqrt{s_{l,l}}, \quad l = 1, 2, \dots, n_y \quad (3.92)$$

Hierbei bezeichnen  $y_l$  und  $\hat{y}_l$  die  $l$ -te Komponente der beiden Vektoren  $\mathbf{y}$  und  $\hat{\mathbf{y}}$ ; der Differenzbetrag liefert die entsprechende Komponente der Innovation  $\nu$ .  $s_{l,l}$  bezeichnet das Diagonalelement der Innovationskovarianz. Für den Wert des Skalierungsfaktors wird typischerweise  $k \geq 3$  gewählt.

Da lediglich die Hauptdiagonale der Innovationskovarianz betrachtet wird, wird der Suchbereich von den Koordinatenachsen des Merkmalsraumes der Messwerte aufgespannt. Die Unsicherheiten werden bei dieser Betrachtungsweise als unabhängig angenommen.



### Elliptische Suchbereiche

Elliptische Suchbereiche ergeben sich im zweidimensionalen kartesischen Koordinatensystem, wenn die gesamte Kovarianzmatrix berücksichtigt wird. Allgemein wird der Unsicherheitsbereich nicht mehr von den Koordinatenachsen, sondern den Eigenvektoren der Innovationskovarianz aufgespannt.

Man verwendet als Maß den quadrierten Mahalanobis-Abstand nach [Formel 3.73](#) auf Seite 40.

$$d^2 = \boldsymbol{\nu}(k)' \mathbf{S}(k)^{-1} \boldsymbol{\nu}(k) \leq g. \quad (3.93)$$

Zur Bestimmung der Konstante  $g$  existieren zwei unterschiedliche Ansätze:

Ein Maximum-Likelihood Gate  $g_{ML}$  kann über die Detektionswahrscheinlichkeit  $p_d$ , die Neu- und Fehlziel-Dichten  $\beta_{NZ}$  und  $\beta_{FZ}$  und die Innovationskovarianz wie folgt bestimmt werden [[Blackman und Populi 1999](#), Kapitel 6]:

$$d^2 \leq g_{ML} = 2 \ln \left[ \frac{p_d}{(1 - p_d)(2\pi)^{M/2}(\beta_{NZ} + \beta_{FZ})\sqrt{|\mathbf{S}|}} \right]. \quad (3.94)$$

Dieser Ansatz lässt sich bei der Fahrumgebungserfassung nur schwer realisieren, da die nötigen Parameter schlecht zu quantifizieren sind. Die Neu- und Fehlzieldichten hängen sehr stark von Umgebung und Verkehrssituation ab. Die Detektionswahrscheinlichkeit eines Sensors ist von in der Regel unbekanntem Objekteigenschaften wie beispielsweise der Reflektivität abhängig und schwankt stark über den gesamten Erfassungsbereich eines Sensors.

Alternativ kann die Verteilungsdichte des Mahalanobis-Abstandes betrachtet werden. Für korrekte Beobachtung-Prädiktion-Paare ist  $d^2$  als Summe von mittelwertfreien, standardnormalverteilten Zufallsvariablen  $\chi^2$ -verteilt mit  $n_y$  Freiheitsgraden [[Blackman 1986](#)]. Nach [[Papula 2001](#), S. 738] lässt sich aus Freiheitsgrad  $n_y$  und einer vorgegebenen Wahrscheinlichkeit  $p$  mit  $0 < p < 1$  das zugehörige Quantil  $z_{(p;n_y)}$  der  $\chi^2$ -Verteilung bestimmen. Typischerweise verwendet man für  $p$  die Werte 0,95 oder 0,99:

$$d^2 \leq g_{\chi^2} = z_{(p;n_y)}. \quad (3.95)$$

Das Verfahren ist unabhängig von schwer bzw. nur empirisch zu ermittelnden Parametern und daher universeller einsetzbar.

Eine Schwierigkeit ergibt sich, falls der Track eines Objektes über mehrere Zyklen nicht durch weitere Messwerte gestützt werden konnte. In diesem Fall wächst nach [Formel 3.15](#) auf Seite 28 die Zustandskovarianz und gemäß [Formel 3.18](#) ergibt sich ebenfalls eine vergrößerte Innovationskovarianz. Diese wiederum verringert nach [Formel 3.93](#) den quadrierten Mahalanobis-Abstand. Die Folge ist, dass Objekte mit einem sehr unsicheren Zustandsvektor anderen Objekten die Messwerte *stehlen*. Um diesen Effekt zu reduzieren lässt sich noch ein *Strafterm* hinzufügen:

$$d^2 = \boldsymbol{\nu}(k)' \mathbf{S}(k)^{-1} \boldsymbol{\nu}(k) + \ln [|\mathbf{S}(k)|]. \quad (3.96)$$

Die Addition der logarithmierten Determinante der Innovationskovarianz führt dazu, dass Zuordnungen mit geringerer Unsicherheit bevorzugt werden. Nachteilig ist, dass der Schwellwert  $g$  sich nicht mehr aus den Quantilen der  $\chi^2$ -Verteilung bestimmen lässt, sondern empirisch festgelegt werden muss.

### 3.4.2. Zuweisungsverfahren

Über die Anwendung der Suchbereiche werden bereits diejenigen Messwerte selektiert, die für eine Zuordnung in Frage kommen. Die Rechenkomplexität wird hierdurch bereits reduziert. Aufgabe des Zuweisungsverfahrens ist es, die *optimale* Zuordnung zu finden. Es handelt sich hierbei um ein Optimierungsproblem, bei dem entweder ein Kostenminimum oder ein Gütemaximum zu erzielen ist.

Abbildung 3.11 zeigt eine mögliche Klassifikation von Zuordnungsverfahren, die im Folgenden vorgestellt werden.



Abbildung 3.11.: Klassifikation von Zuordnungsverfahren

Zunächst lassen sich Assoziationsverfahren danach unterscheiden, ob Einfach- oder Mehrfachhypothesen verfolgt werden. Beim Einfach-Hypothesen-Tracking erfolgt die Zuordnung der Messwerte zu den Prädiktionen in jedem Iterationsschritt neu, ohne dass die Historie berücksichtigt wird. Beim Mehrfach-Hypothesen-Tracking hingegen

werden im Falle von mehrdeutigen Zuordnungen während einer Iteration mehrere Hypothesen verfolgt und während der folgenden Iterationen aufgelöst.

Aufgrund der geringeren Komplexität kommen zumeist Einfach-Hypothesen-Zuordnungsverfahren zum Einsatz. Diese lassen sich weiter differenzieren in Ein-Nachbar-Verfahren<sup>14</sup> und Alle-Nachbarn-Verfahren<sup>15</sup>. Erstere sind dadurch gekennzeichnet, dass jedem Objekt (jeder Prädiktion) der optimale Messwert zugeordnet wird, während die anderen Messwerte keinen Einfluss auf die Zustandsschätzung haben. Es findet eine eindeutige Zuordnung statt. Bei letzteren hingegen werden alle Messwerte gewichtet in die Zustandsschätzung eines Objektes eingebracht.

Zu allen Verfahren sind suboptimale Algorithmen bekannt, die durch Approximationen die Rechenkomplexität reduzieren.

### Ein-Nachbar-Verfahren

Mathematisch wird das *Asymmetrische Zuordnungsproblem* wie folgt beschrieben: Gegeben sind  $m$  Beobachtungen  $\mathbf{z}_i(k+1)$ ,  $i = 1, 2, \dots, m$  sowie  $n$  prädizierte Messwerte  $\hat{\mathbf{z}}_j(k+1|k)$ ,  $j = 1, 2, \dots, n$  mit den Abständen  $d_{ij}$ <sup>16</sup>. Es gilt  $m \leq n$ , das heißt, es existieren mehr Prädiktionen als Beobachtungen. Gesucht ist die binäre Zuordnungsmatrix  $\mathbf{X} = x_{ij}$ , sodass die Kosten  $c = \sum_{i=1}^m \sum_{j=1}^n d_{ij} x_{ij}$  minimiert werden, wobei die folgenden beiden Bedingungen erfüllt sein müssen [Bertsekas u. a. 1993].

$$\sum_{j=1}^n x_{ij} = 1, \text{ für alle } i = 1, 2, \dots, m, \quad (3.97)$$

$$\sum_{i=1}^m x_{ij} \leq 1, \text{ für alle } j = 1, 2, \dots, n \quad (3.98)$$

### Iterativer Nearest-Neighbour-Algorithmus

Das einfachste Zuordnungsverfahren ist der iterative Nearest-Neighbour-Algorithmus, bei dem sukzessive die Zuweisung mit den geringsten Kosten durchgeführt wird, bis alle Beobachtungen zugewiesen sind. Der Aufwand liegt nach [Duden Informatik 1993, S. 541] in der Klasse  $O(n^2 \log_2 n)$ . Das Verfahren liefert jedoch nur eine Näherungslösung, wie aus [Abbildung 3.12](#) zu entnehmen ist:

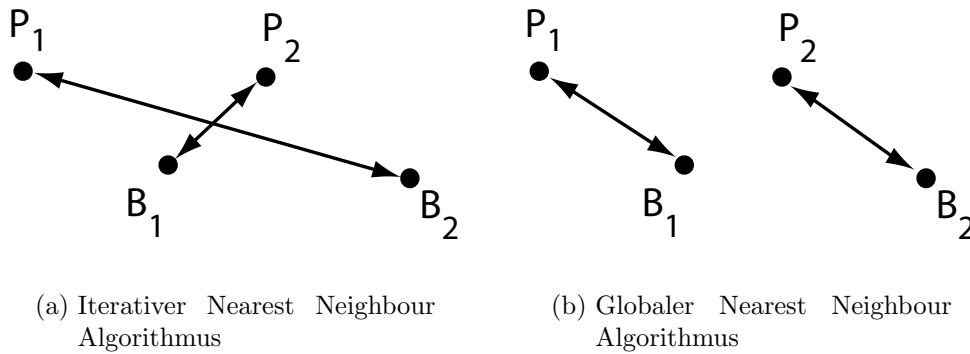
### Globale Nearest-Neighbour-Algorithmen

Globale Nearest-Neighbour-Algorithmen liefern das gesuchte globale Minimum der Kostenfunktion, benötigen jedoch deutlich mehr Rechenzeit. Der Brute-Force-Ansatz liegt in der Aufwandsklasse  $O\left(\frac{n!}{(n-m)!}\right)$ . Deutlich schneller ist bereits der Munkres-

<sup>14</sup> engl.: Unique Neighbour Approach

<sup>15</sup> engl.: All Neighbour Approach

<sup>16</sup> Über die Suchbereiche ausgeschlossene Zuordnungen werden entsprechend gekennzeichnet.



**Abbildung 3.12.:** Ergebnisse unterschiedlicher Zuordnungsverfahren zwischen Beobachtungen (B) und Prädiktionen (P). Unter der Annahme, dass beide Beobachtungen in beide Suchbereiche fallen verfehlt der iterative Nearest-Neighbour-Algorithmus die optimale Zuordnung  $\{B_1-P_1, B_2-P_2\}$ .

Algorithmus, der in der Aufwandsklasse  $O(\min(n, m)^2 \cdot \max(n, m))$  liegt [Blackman und Populi 1999, Kapitel 6.5].

Zum Standard hat sich die Klasse der *Auktionsalgorithmen* entwickelt, deren Funktionsweise an Auktionen angelehnt ist:  $m$  Personen konkurrieren hierbei um  $n$  Objekte, deren Preis  $p_j$  sich verändert. Jedes Objekt  $j$  hat für eine Person  $i$  einen bestimmten Wert  $a_{ij}$ . Der Gewinn  $\pi_i$  einer Person  $i$  beim Erwerb von Objekt  $j$  ergibt sich aus dem erzielten Auktionspreis  $p_j$  und dem Wert für die Person:

$$\pi_i = a_{ij} - p_j. \quad (3.99)$$

Auktionsalgorithmen maximieren den Gesamtgewinn und liefern die zugehörigen Person-Objekt-Zuordnungen. Die optimale Lösung lässt sich mit einer Komplexität von  $O(n \min(m, n \log n))$  finden [Bertsekas u. a. 1995].

Die Übertragung auf das Zuordnungsproblem von Messwerten ist möglich. Beobachtungen (Personen) konkurrieren um prädizierte Messwerte (Objekte). Da der Auktionsalgorithmus den Gewinn maximiert, die Abstandssumme jedoch zu minimieren ist, muss die Abstandsfunktion durch eine zu maximierende Funktion ersetzt werden (beispielsweise  $d_{ij}^{\text{auktion}} = d_{\max} - d_{ij}$ ).

Es existiert eine Vielzahl von suboptimalen Auktionsalgorithmen, wobei über ein Preisinkrement  $\epsilon$  die Laufzeit des Algorithmus auf der einen Seite und die Güte der Zuordnungen (die Abweichung vom Optimum) auf der anderen Seite gesteuert werden kann [Bertsekas u. a. 1993; Bertsekas 2001]. Die Algorithmen unterscheiden sich darin, wie sich die Objektpreise während einer Auktion verändern. So führen große Preisinkremente (wie bei wirklichen Auktionen) zu einem schnelleren Ende, dafür wird möglicherweise nicht der erreichbare Preis erzielt (die beste Zuordnung gefunden). Andere Verfahren [Bertsekas und Castanon 1993] führen *umgekehrte Auktio-*

nen<sup>17</sup> ein, bei denen die Objekte ihren Preis senken, um um die Bieter zu konkurrieren. Die suboptimalen Verfahren sind im Worst-Case teilweise sogar aufwendiger als der Optimale Algorithmus, erreichen aber in Monte-Carlo-Versuchen eine deutliche Beschleunigung.

### Alle-Nachbarn-Verfahren

Abbildung 3.12 b) offenbart eine Schwäche der Ein-Nachbar-Verfahren: Zwar ist die erreichte Zuordnung optimal im Sinne der Summe der Abstände, anschaulich ist aber fraglich, ob nicht beide Beobachtungen vom Objekt mit Prädiktion 2 stammen und das Objekt mit Prädiktion 1 nicht detektiert wurde. Alle-Nachbarn-Verfahren tragen diesem Umstand Rechnung, indem alle Messwerte innerhalb des Zuordnungsbereiches gewichtet eingebracht werden. Unterschiedliche Verfahren hierzu werden im Folgenden in Kürze dargestellt.

### Probabilistic Data Association Filter (PDAF)

Der PDAF-Ansatz beruht auf der Annahme, dass alle Beobachtungen innerhalb eines Suchbereiches entweder zur Prädiktion des entsprechenden Objektes gehören oder zufällig verwechselt sind ([Roecker und Phillis 1993]). Bei  $m$  Messwerten innerhalb des Suchbereiches werden  $m + 1$  Hypothesen untersucht: Entweder stammt kein Messwert vom Objekt (Hypothese  $H_0$ ) oder es stammt Messwert  $j$  vom Objekt (Hypothese  $H_j, j = 1, 2, \dots, m$ )<sup>18</sup>.

Für jedes Objekt wird ein gewichteter Innovationsvektor aus den  $m$  Beobachtungen innerhalb des Suchbereiches bestimmt:

$$\boldsymbol{\nu}(k+1) = \sum_{j=1}^m \beta_j(k+1) \boldsymbol{\nu}_j(k+1). \quad (3.100)$$

Hierbei ist  $\boldsymbol{\nu}_j$  die Innovation des  $j$ -ten Messwertes und  $\beta_j$  die Wahrscheinlichkeit, dass der Messwert zu dem Objekt gehört. Der Wert  $\beta_0$  gibt die Wahrscheinlichkeit an, dass kein Messwert zu dem Objekt gehört. Eine genaue Herleitung der Wahrscheinlichkeiten findet sich in [Bar-Shalom und Fortmann 1988]. Die Summe der Wahrscheinlichkeiten ist 1:

$$\sum_{j=0}^m \beta_j(k+1) = 1. \quad (3.101)$$

Die Zustandsaktualisierung im Filter erfolgt mit dem gewichteten Innovationsvektor nach Formel 3.20 auf Seite 29. Die Zustandskovarianz wird nach dem Filterschritt inkrementiert:

$$\mathbf{P}(k+1|k+1) = \mathbf{P}^0(k+1|k+1) + \mathbf{dP}(k+1) \quad (3.102)$$

<sup>17</sup> engl.: Reverse Auctions

<sup>18</sup> Es mag irritieren, dass beim Ein-Hypothesen-Tracking mehrere Hypothesen untersucht werden. Hintergrund ist, dass vor dem Aktualisierungsschritt des Filters die Hypothesen zu einer Einzelhypothese zusammengefasst werden.

Hierbei bezeichnet  $\mathbf{P}^0(k+1)$  die Zustandskovarianz nach dem Filterschritt gemäß Formel 3.21. Für das Inkrement  $d\mathbf{P}(k+1)$  gilt:


$$d\mathbf{P}(k+1) = \mathbf{W}(k+1) \left[ \sum_{j=1}^m \beta_j(k+1) \boldsymbol{\nu}_j(k+1) \boldsymbol{\nu}_j(k+1)' - \boldsymbol{\nu}(k+1) \boldsymbol{\nu}(k+1)' \right] \mathbf{W}(k+1)' \quad (3.103)$$

Das Inkrement dient dazu, die Unsicherheit der Zuordnung zu berücksichtigen und hängt daher von der Streuung der Beobachtungen ab.

Das PDAF verbessert die Objektverfolgung bei zufälligen Störungen um die Messwertprädiktion eines Objektes. Tritt jedoch bei dichtem Abstand von mehreren Objekten eine Konfliktsituation wie in [Abbildung 3.12 b\)](#) auf, wobei die Beobachtungen in mehrere Suchbereiche fallen, ist die Wahrscheinlichkeitsberechnung fehlerhaft, weil der Einfluss anderer Objekte nicht eingeht. Die Folge sind schlechte Tracking-Ergebnisse [[Roecker und Phillis 1993](#)].

### Joint Probabilistic Data Association Filter (JPDAF)


Das JPDAF unterscheidet sich lediglich in der Berechnung der Wahrscheinlichkeiten vom PDAF. Es werden jetzt alle Beobachtungen und alle Objekte / Prädiktionen in die Berechnung eingeschlossen. Ein Beispiel soll die Funktionsweise verdeutlichen: [Abbildung 3.13](#) zeigt eine Konfliktsituation, bei der zwei Beobachtungen zwei Prädiktionen zuzuordnen sind. Eine der Beobachtungen liegt innerhalb der Suchbereiche beider Prädiktionen. Aufgrund der annähernd gleichen Abstände der beiden Beobachtungen zur zweiten Prädiktion würden bei Anwendung des PDAF-Algorithmus beide Messwerte in etwa gleich stark in den gewichteten Innovationsvektor und damit in die Zustandsaktualisierung eingehen. Beim JPDAF-Algorithmus hingegen wird das Gewicht der ersten Beobachtung in Abhängigkeit von der Wahrscheinlichkeit, dass diese zur ersten Prädiktion gehört, reduziert. Beim JPDAF-Algorithmus



**Abbildung 3.13.:** Beispiel einer Konfliktsituation, die durch den JPDAF-Algorithmus aufgelöst wird. Die Beobachtung B1 lässt sich anhand der Suchbereiche beider Prädiktionen P1 und P2 zuordnen.

sind die untersuchten Hypothesen alle durchführbaren Zuweisungen. Durchführbare Zuweisungen sind alle Zuweisungskombinationen, bei denen eine Beobachtung maximal einer Prädiktion zugewiesen wird, die also konfliktfrei sind. [Abbildung 3.14](#) zeigt

die konfliktfreien Zuweisungen für das oben angeführte Beispiel. Es müssen nicht alle Prädiktionen einen Messwert zugeordnet bekommen (Detektionswahrscheinlichkeit  $< 1$ ) und nicht alle Messwerte müssen Objekten zugeordnet werden (Rauschen und Geisterziele).



**Abbildung 3.14.:** Durchführbare Zuordnungen, die beim JPDAF-Algorithmus berücksichtigt werden.

Für jede Prädiktion  $i$  und Beobachtung  $j$  ist über die Innovation  $\nu_{ij}$  sowie die Innovationskovarianz  $\mathbf{S}_{ij}$  die Gaußsche Likelihood-Funktion beschrieben:

$$g_{ij} = \frac{e^{-\nu_{ij}^2/2}}{(2\pi)^{n_y/2} \sqrt{|S_{ij}|}}. \quad (3.104)$$

Hierbei bezeichnet  $n_y$  die Dimension des Innovationsvektors. Aus den Einzelwahrscheinlichkeiten und der Detektionswahrscheinlichkeit ergibt sich die gemeinsame

Wahrscheinlichkeit einer Hypothese. Die gemeinsame Wahrscheinlichkeit für Hypothese (a) aus [Abbildung 3.14](#) ergibt sich zu  $p(H_{(a)}) = g_{11} g_{22} p_D \beta$ . Hierbei ist  $p_D$  die Detektionswahrscheinlichkeit und  $\beta$  eine Normierungskonstante. Ein detailliertes Beispiel findet sich in [[Blackman und Populi 1999](#), Kapitel 6.6.2], eine theoretische Betrachtung in [[Bar-Shalom und Li 1995](#), Kapitel 6.2].

Die Wahrscheinlichkeit  $\beta_{ij}$  für eine Zuordnung wird aus der Summe der Wahrscheinlichkeiten der Hypothesen bestimmt, die diese Zuordnung stützen. Die Zuordnung von Prädiktion 1 und Beobachtung 1 wird beispielsweise durch die Hypothesen (a) und (c) gestützt, sodass  $\beta_{11} = p(H_{(a)}) + p(H_{(c)})$ .

Der gewichtete Innovationsvektor lässt sich jetzt für jede Prädiktion  $i$  berechnen:


$$\nu_i(k+1) = \sum_{j=1}^m \beta_{ij}(k+1) \nu_j(k+1). \quad (3.105)$$

Der Aktualisierungsschritt im Filter wird analog zum PDAF mit dem gewichteten Innovationsvektor durchgeführt und nach der Aktualisierung der Zustandskovarianz wird ebenfalls wie beschrieben ein Kovarianzinkrement berechnet.

Der JPDAF-Algorithmus ist sehr aufwändig, sodass verschiedene suboptimale Varianten existieren [[Roecker und Phillis 1993](#)].

### Dempster-Shafer

Alle bisherigen Assoziationsmethoden basieren auf der klassischen Bayesschen Wahrscheinlichkeitstheorie und unterstützen ausschließlich Einzelhypothesen (beispielsweise: „Prädiktion 1 lässt sich Beobachtung 2 zuordnen“), für die die Eintrittswahrscheinlichkeit untersucht wird. Die Dempster-Shafer-Theorie lässt zusätzlich Verbundhypothesen zu (beispielsweise in [Abbildung 3.15](#): „Zu Prädiktion 1 lassen sich wahrscheinlich Beobachtung 1 oder 2 zuordnen“). Weiterhin sind auch Negationen von Hypothesen möglich (beispielsweise: „Prädiktion 1 lässt sich Beobachtung 2 *nicht* zuordnen“). Schließlich kann die Aussagekraft eines Sensors modifiziert werden, um auszudrücken, dass einem Sensor mehr vertraut wird als einem anderen [[Wu u. a. 2002](#)].



**Abbildung 3.15.:** Verbundhypothese: Zu Prädiktion 1 lassen sich wahrscheinlich Beobachtung 1 oder 2 zuordnen.

Während in der Wahrscheinlichkeitstheorie die Summe über alle Hypothesenwahr-



scheinlichkeiten 1 ergibt,

$$\sum_{i=1}^n p(H_i) = 1, \quad (3.106)$$

werden in der Dempster Shafer Theorie den Einzelhypothesen *Wahrscheinlichkeitsmassen*<sup>19</sup>  $m(H_i)$ , deren Summe kleiner sein kann. Zusätzlich kann die Unsicherheit der Hypothesenwahrscheinlichkeiten über eine Wahrscheinlichkeitsmasse der Unsicherheit  $A$ <sup>20</sup> ausgedrückt werden:

$$\sum_{i=1}^n p(H_i) \leq 1, \quad (3.107)$$

$$\sum_{i=1}^n p(H_i) + m(A) = 1. \quad (3.108)$$

Die Dempster-Shafer Regel kombiniert die einzelnen Wahrscheinlichkeitsmassen miteinander. Die Summe der Massen aller Einzelhypothesen, die eine Hypothese stützen, ergibt die *Glaubwürdigkeit*<sup>21</sup>  $\text{bel}(H_k)$  einer Hypothese (vgl. gewichteter Innovationsvektor beim JPDAF):

$$\text{bel}(H_k) = \sum_{B \subseteq H_k} m(B). \quad (3.109)$$

Falls die Wahrscheinlichkeitsmasse der Unkenntnis den Wert Null hat, entspricht die Dempster-Shafer Regel der klassischen Wahrscheinlichkeitstheorie.

Die Mächtigkeit des Verfahrens und damit die Hypothesenvielfalt hat eine entsprechende Rechenkomplexität zur Folge, sodass in der Praxis die Menge der betrachteten Hypothesen eingeschränkt wird. Zudem lässt sich die Unsicherheit von Hypothesen schwer quantifizieren. Eine Möglichkeit besteht darin, Ähnlichkeitsmaße zwischen Messwerten und Objekten zu untersuchen (dies ist zum Beispiel bei Geometrieermessenden Sensoren möglich). In [Gruyer und Berge-Cherfaoui 1999b, a; Gruyer u. a. 2000] wird hierzu eine Fuzzy-Regelbasis verwendet.

### Mehrfach-Hypothesen-Tracking (MHT)

Die Haupteinschränkung des Einfach-Hypothesen Tracking besteht darin, dass alle während einer Filteriteration betrachteten Hypothesen vor dem Aktualisierungsschritt des Filters zu einer wahrscheinlichkeitsgewichteten Gesamthypothese zusammengefasst werden. Die Historie der Zuordnungen ist hierbei bedeutungslos, die Verfahren werden daher auch als *Zero-Scan-Algorithmen* bezeichnet. Beim MHT hingegen erfolgt eine *verzögerte Entscheidung*<sup>22</sup> wobei die Zuordnungen über mehrere Filterschritte einfließen. Diese Verfahren werden daher auch als *Multiple-Scan Algorithmen* bezeichnet [Reid 1979].

<sup>19</sup> engl.: basic probability assignment bpa

<sup>20</sup> engl.: Ignorance

<sup>21</sup> engl.: belief

<sup>22</sup> engl.: deferred decision

MHT Algorithmen basieren zumeist auf [Reid 1979]. Hierin werden alle Assoziations-hypothesen (in [Abbildung 3.14](#) beispielsweise fünf) in einen Hypothesenbaum aufgenommen, der sich mit jeder Filteriteration und neuen Messwerten vergrößert. Für jede Hypothese wird die wahrscheinlichste Zuordnung ausgewählt. Um die Rechenkomplexität in Grenzen zu halten, werden Hypothesen mit einer Wahrscheinlichkeit unterhalb eines Schwellwertes entfernt und Hypothesen mit ähnlichen Schätzungen des Zustandsvektors kombiniert.

Ein optimaler Algorithmus müsste alle Hypothesen verfolgen, dies ist jedoch aufgrund des exponentiell wachsenden Hypothesenbaumes nicht durchführbar. Unterschiedliche Algorithmen variieren daher vor allem in der Begrenzungstechnik<sup>23</sup> mit dem Ziel einer möglichst frühzeitigen Eliminierung von unwahrscheinlichen Hypothesen.

Dem theoretischen Nutzen des MHT steht eine erhebliche Rechenkomplexität gegenüber, die eine Nutzung in Echtzeit-Applikationen fraglich erscheinen lässt. Vorteile ergeben sich durch das Verfahren vor allem dann, wenn die Auflösung eines Sensors eine eindeutige Assoziation erschwert. Wenn Einzel-Hypothesen-Tracking offensichtliche Schwächen offenbart, scheint daher der Mehraufwand gerechtfertigt.

### 3.5. Initialisierung

Ein Messwert, der keiner Prädiktion zugeordnet werden konnte, initialisiert eine neue Objekthypothese. Zu diesem Zweck wird der Messvektor  $\mathbf{z}(k+1)$  auf den initialen Objekt-Zustandsvektor  $\hat{\mathbf{x}}(0|0)$  abgebildet. Falls der Messvektor nicht im Tracking-Koordinatensystem vorliegt, wird der Zustandsvektor  $\hat{\mathbf{x}}^S(0|0)$  zunächst über die Funktion  $\mathbf{j}$  in Sensorkoordinaten bestimmt und anschließend unter Berücksichtigung des Sensor-Koordinatensystems über die Funktion  $\mathbf{s}$  in das Tracking-Koordinatensystem transformiert. Der schematische Vorgang ist in [Formel 3.110](#) dargestellt.

$$\mathbf{z}(k+1) \xrightarrow{\mathbf{j}} \hat{\mathbf{x}}^S(0|0) \xrightarrow{\mathbf{s}} \hat{\mathbf{x}}(0|0) \quad (3.110)$$

Für den Messvektor  $\mathbf{z}(k+1)$ , den Zustandsvektor  $\hat{\mathbf{x}}(0|0)$  und die Messfunktion  $\mathbf{h}$  gilt die Beziehung

$$\mathbf{h}(\hat{\mathbf{x}}(0|0)) = \mathbf{z}(k+1), \quad (3.111)$$

dennoch ist im Allgemeinen  $\mathbf{h}^{-1} = \mathbf{s} \circ \mathbf{j}$  nicht erfüllt, weil die Funktion  $\mathbf{h}$  keine Umkehrung besitzt. Notwendige Bedingung für die Umkehrbarkeit ist die Injektivität<sup>24</sup>, diese wird jedoch offensichtlich verletzt, falls der Messvektor beispielsweise nur die Position, nicht aber die Dynamikparameter des Zustandsvektors erfasst.

Die Funktion  $\mathbf{t} = \mathbf{s} \circ \mathbf{j}$  wird daher so gewählt, dass [Formel 3.111](#) erfüllt ist. Diejenigen Elemente des Zustandsvektors, die nicht durch diese Bedingung festgelegt sind, werden mit situationsabhängigen Erfahrungswerten belegt. Zur Bestimmung

<sup>23</sup> engl.: pruning

<sup>24</sup> Eine Abbildung  $f : A \rightarrow B$  heißt *injektiv*, falls gilt:  $\forall a_1, a_2 \in A : a_1 \neq a_2 \Rightarrow f(a_1) \neq f(a_2)$ .

der initialen Zustandskovarianz, wird die resultierende Funktion  $\mathbf{t}$  um den Messwert linearisiert

$$\mathbf{T} = \nabla_{\mathbf{z}} \mathbf{t}(\mathbf{z})|_{\mathbf{z}=\mathbf{z}(\mathbf{k}+1)}, \quad (3.112)$$

um über  $\mathbf{T}$  die Messunsicherheit  $\mathbf{R}(k+1)$  abzubilden.

$$\mathbf{R}(k+1) \xrightarrow{\mathbf{T}} \mathbf{P}(0|0) \quad (3.113)$$

Sind nicht alle Elemente des Zustandsvektors durch [Formel 3.111](#) festgelegt, so sind auch die entsprechenden Elemente der linearisierten Funktion  $\mathbf{T}$  null, sodass auch in der initialen Kovarianzmatrix Erfahrungswerte gesetzt werden müssen. Die initiale Zustandskovarianz ergibt sich daher zu

$$\mathbf{P}(0|0) = \mathbf{T} \mathbf{R}(k+1) \mathbf{T}' + \mathbf{P}_{\text{init}}, \quad (3.114)$$

wobei in der  $n_x \times n_x$  dimensionalen Matrix  $\mathbf{P}_{\text{init}}$  Elemente nur dann mit einem Wert ungleich Null besetzt werden, wenn die entsprechende Zeile in der Matrix  $\mathbf{T} \mathbf{R}(k+1) \mathbf{T}'$  ausschließlich Nullen enthält.

Falls der initiale Zustandsvektor nur empirisch festgelegt werden kann, besteht eine Alternative im MHT während der Startphase der Objekttracks. Bei der Initialisierung werden hier mehrere Hypothesen aufgesetzt und über die folgenden Messwerte die unpassenden verworfen.

## 3.6. Trackverwaltung

Die wichtigste Aufgabe der Trackverwaltung besteht in dem Verwerfen überflüssiger Objekthypothesen. Selbst wenn sich einem Objekt keine neuen Messwerte zuordnen lassen, wird der zugehörige Zustandsvektor in jeder Filteriteration neu prädiert und möglicherweise auch in der Assoziation berücksichtigt, wodurch die Komplexität unnötig steigt. Eine Strategie zur Reduzierung der verfolgten Objekte ist daher erforderlich.

Unter verschiedenen Bedingungen ist es sinnvoll, Objekte zu entfernen:

1. Das Objekt hat den Detektionsbereich aller Sensoren verlassen, sodass keine Stützung durch Messwerte möglich ist.
2. In  $n$  Filterschritten konnten weniger als  $m < n$  Messwerte erfolgreich assoziiert werden.
3. Das Objekt wurde länger als eine bestimmte Zeitschwelle nicht mehr beobachtet.
4. Obwohl das Objekt im Erfassungsbereich mehrerer Sensoren liegt, wird es nur durch einen einzelnen Sensor gestützt (Geisterziel).

5. Das Filter läuft für dieses Objekt über mehrere Iterationen nicht konsistent (Modellfehler).
6. Zwei Objekte sind statistisch nicht zu unterscheiden und sollten zusammengefasst werden (Merge).
7. Es liegt eine physikalisch widersprüchliche Situation vor (Beispiel: Ein Fahrzeug kann nicht innerhalb eines anderen liegen).

Eine zyklische Überprüfung der Kriterien ist sinnvoll, sodass üblicherweise die Trackverwaltung in jeder Filteriteration durchlaufen wird. Eine schnellstmögliche Reduzierung der Objekthypothesen ist so gewährleistet.

## 4. Versuchsträger und Fusionsarchitektur

Nachdem in den vorangegangenen Kapiteln der aktuelle Entwicklungsstand der Sensorfusion für Fahrerassistenzsysteme beschrieben und auf unterschiedliche Verfahren eingegangen wurde, widmet sich dieses Kapitel der konkreten Realisierung auf der Basis eines Versuchsträgers.

Durch die verfügbare Sensorik und insbesondere die fehlende Synchronisierbarkeit sind die im vorangegangenen Kapitel eingeführten Besonderheiten einer asynchronen Fusion zu berücksichtigen. Aufgrund der bereits angeführten Schwächen wird hierzu weder eine Messwert-Prädiktion auf einen gemeinsamen Fusionszeitpunkt eingesetzt, noch eine Retrodiktion für verspätete Sensordaten durchgeführt. Über einen Messdatenpuffer mit einer Track-Prädiktion wird eine alternative Architektur dargestellt und deren Konsequenzen auf das zeitliche Verhalten der Fusion untersucht.

Es wird erläutert, warum von den im vorangegangenen Kapitel dargestellten Filterverfahren das Erweiterte Kalman-Filter benutzt wird, bevor im weiteren Verlauf der Arbeit Detailuntersuchungen erfolgen. Die in dieser Arbeit vernachlässigte Korrelation der Sensordaten wird thematisiert und auf weiterführende Literatur verwiesen.

### 4.1. Versuchsträger

Um den Hintergrund der Fusionsarchitektur darzustellen wird zunächst auf das Versuchsfahrzeug und auf die durch die verfügbare Sensorik gegebenen Rahmenbedingungen eingegangen. [Abbildung 4.1](#) zeigt das Fahrzeug mit dem an der Front montierten Sensorträger und diversen Sensoren zur Fahrumgebungserfassung. Im weiteren Verlauf der Arbeit werden die folgenden Sensorprinzipien verwendet:

- Laserscanner: Insgesamt drei Laserscanner stehen zur Verfügung um den Bereich vor und neben dem Fahrzeug zu erfassen. Die beiden seitlich angebrachten Sensoren detektieren Fahrzeuge bis zu einer Entfernung von circa 80m und arbeiten bei einer Zykluszeit von 62,5ms. Der Öffnungswinkel des Erfassungsbereiches ist durch den Anbauort limitiert und liegt bei circa 245°. Der frontal ausgerichtete Laserscanner detektiert Fahrzeuge bis zu einer Entfernung von circa 120m bei einer Zykluszeit von 100ms. Der Öffnungswinkel ist auch hier



**Abbildung 4.1.:** Versuchsträger mit heterogener Sensorik zur Umgebungserfassung. Verschiedene Lasersysteme, ein Fernbereichsradar sowie eine Mono-Bildverarbeitung (Kamera befindet sich vor dem Innen Spiegel) kommen zum Einsatz.

durch den Anbauort beschränkt und liegt bei circa  $170^\circ$ . Die Laserscanner detektieren eine Fahrzeugkontur und liefern ausgezeichnete Punkte als Messvektor zurück. Die Sensorhardware führt ausschließlich eine Segmentierung durch, sodass Rohdaten in die Fusion eingebracht werden.

- Fernbereichsradar: Der frontal ausgerichtete Fernbereichsradar detektiert Fahrzeuge bis zu einer Entfernung von circa 120m bei einer Zykluszeit von 30ms. Der Öffnungswinkel des Detektionsbereiches hängt vom Radarquerschnitt des Ziels ab und liegt bei etwa  $6^\circ$ . Der Radarsensor liefert stabilisierte, getrackte Objekte, die durch ihre Position und Geschwindigkeit beschrieben werden.
- Mono-Bildverarbeitung: Die ebenfalls frontal ausgerichtete Kamera hat einen Öffnungswinkel von  $27^\circ$ . Die Bildverarbeitung detektiert Fahrzeuge in diesem Bereich bis zu einer Entfernung von circa 80m und hat eine Zykluszeit von circa 100ms. Die Messdaten umfassen den Fahrzeugabstand sowie die Fahrzeugbreite und sind durch ein Tracking stabilisiert.

Die Messzeitpunkte der Sensoren sind nicht synchronisierbar, jeder Sensor versieht die aufgenommenen Messdaten jedoch mit einem globalen Zeitstempel, sodass der zeitliche Versatz bekannt ist. Aufgrund der Beschreibung ist zudem offensichtlich,

dass die Messmerkmale divergieren und der Erfassungsbereich unterschiedliche Überlappungsbereiche aufweist. So liegt horizontal der Detektionsbereich des Radars innerhalb des Video-Detektionsbereiches, dieser wird wiederum auch von den Lasersensoren abgedeckt. Der Bereich des vorne mittig angebrachten Laserscanners wird wiederum von den beiden seitlichen eingeschlossen. Die Sensoren sind auf einen unidirektionalen Datenfluss ausgerichtet, das heißt es besteht keine Möglichkeit des Datenaustausches unter den einzelnen Sensoren.

## 4.2. Fusionsarchitektur

Aktuelle Fahrerassistenzsysteme im Komfortbereich wie die automatische Distanzregelung basieren auf einem Einzelsensor und sind in der Regel autark, das heißt Synergieeffekte bleiben ungenutzt, weil kein Datenaustausch stattfindet. Zumeist ist die gesamte Verarbeitungskette von der Sensorik bis zur Ansteuerung der Mensch-Maschine-Schnittstelle in einem einzigen Steuergerät [Kirchner und Schwitters 2003]. Eine mögliche zukünftige Systemarchitektur nach [Stüker und Schmidt 2003] zeigt [Abbildung 4.2](#): Zunächst werden alle Sensordaten in der Wahrnehmungsebene fusioniert, um ein konsistentes Umfeldmodell aufzubauen. Basierend auf den geometrischen und dynamischen Objekteigenschaften kann eine Klassifikation der Umfeldobjekte [Weiß u. a. 2003] und eine Interpretation der Verkehrsszene erfolgen. Das resultierende Umfeldmodell ist die gemeinsame Basis aller Applikationen. In der Applikation ist die Selektion relevanter Objekte sowie der Regler oder Warnalgorithmus implementiert.

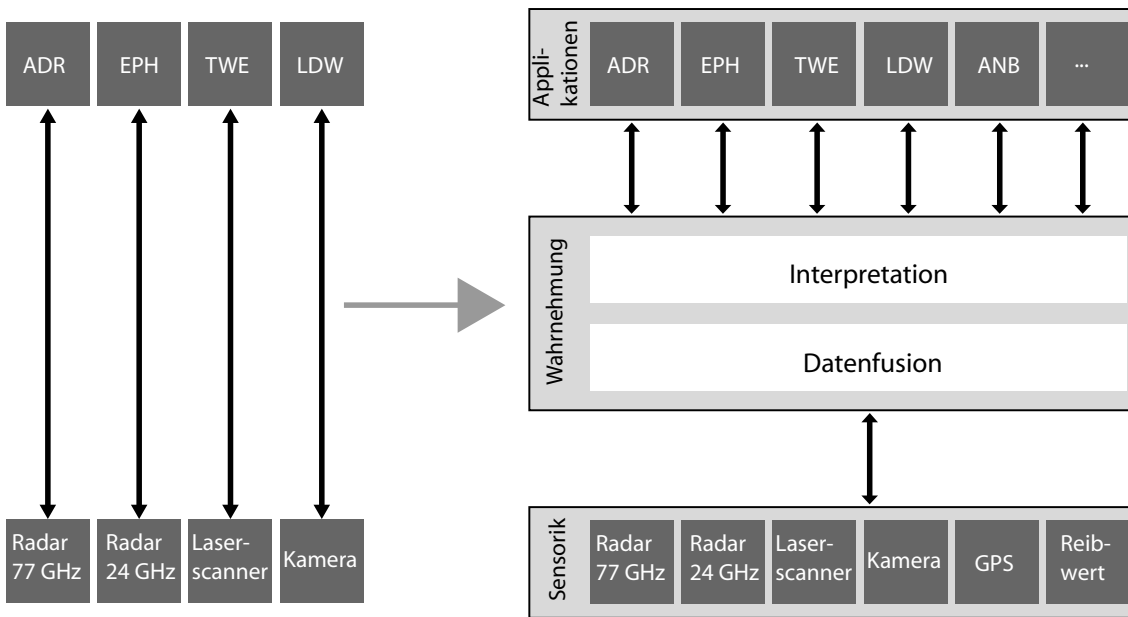
Ziel dieser Arbeit ist die Sensordatenfusion von heterogenen Sensordaten unter den durch die Sensorik des Versuchsträgers gegebenen Randbedingungen. Hierdurch wird die untere Schicht der Wahrnehmungsebene realisiert, die die Basis für die Klassifikation von Objekten und die Interpretation der Verkehrsszene darstellt. Obwohl die Klassifikation eine entsprechende Schätzgüte der Sensordatenfusion voraussetzt, kann diese auch umgekehrt - durch adaptive Dynamikmodelle - zur Verbesserung der Schätzung beitragen [Weiß 2003]. Die im Rahmen dieser Arbeit vorgestellten Verfahren schließen entsprechende Klassifikationsalgorithmen nicht aus, sie werden jedoch nicht explizit behandelt.

Der Rahmen der Fusionsarchitektur ist durch das Synchronisationskonzept und die Filterarchitektur vorgegeben, sodass diese im Folgenden näher diskutiert werden. Die weiteren Kapitel widmen sich den Details der Filterarchitektur, die innerhalb einer Umgebungserfassung im automobilen Straßenverkehr zu berücksichtigen sind.

### 4.2.1. Synchronisationskonzept: Messdatenpuffer mit Track-Prädiktion

Aufgrund der Asynchronität der Sensoren ist ein geeignetes Verfahren zu entwickeln, um die Sensordaten in der Reihenfolge der Messzeitpunkte in die Fusion einbringen





**Abbildung 4.2.:** Systemarchitektur von Fahrerassistenzsystemen heute (links) und zukünftig (rechts) (ADR - Automatische Distanzregelung, EPH - Einparkhilfe, TWE - Totwinkel-Erkennung, LDW - Lane Departure Warning, ANB - Automatische Notbremsung)

zu können. Sowohl die Messwertprädiktion auf einen gemeinsamen Fusionszeitpunkt als auch die Retrodiktion sollten wegen der im vorangegangenen Kapitel erwähnten Nachteile nicht eingesetzt werden. Das Konzept des *Messdatenpuffers mit Track-Prädiktion* sorgt dafür, dass sämtliche Messdaten in der Reihenfolge der Akquisition eingehen, gleichzeitig aber der resultierende Zeitversatz zwischen Realzeit und dem jüngsten Messzeitpunkt minimiert wird.

Nur ein zentralisiertes Tracking ermöglicht ein Sensor-Erfassungsbereich übergreifendes Tracking ohne eine direkte Sensor-Sensor-Kommunikation. Die globalen Tracks sind daher in einer Zentraleinheit zu verwalten, in der die im vorangegangenen Kapitel vorgestellten Mechanismen der Trackverwaltung gezielt eingesetzt werden können.

Weil die Verarbeitungszeiten der Sensoren in einem heterogenen Sensornetzwerk schwanken, ist ferner ein Messdatenpuffer erforderlich und es entsteht eine zusätzliche Verzögerung bis zum Einbringen der Messdaten in die Fusion. Diese Differenzzeit lässt sich für die ausgegebenen Tracks über eine zeitliche Prädiktion der Objektzustände beliebig reduzieren. Dabei ist die Funktionalität der zeitlichen Prädiktion wie im letzten Kapitel beschrieben bereits Bestandteil eines Trackingsystems. Den schematischen Aufbau der neuen Fusionsarchitektur zeigt [Abbildung 4.3](#).

Es ergeben sich bei diesem Konzept folgende Vorteile:

1. Sofern die Messdaten als Rohdaten vorliegen, gehen sie auch als solche in die Fusion ein. Die Unsicherheit erhöht sich nicht durch eine mit Modellfehlern behaftete, zeitliche Prädiktion.



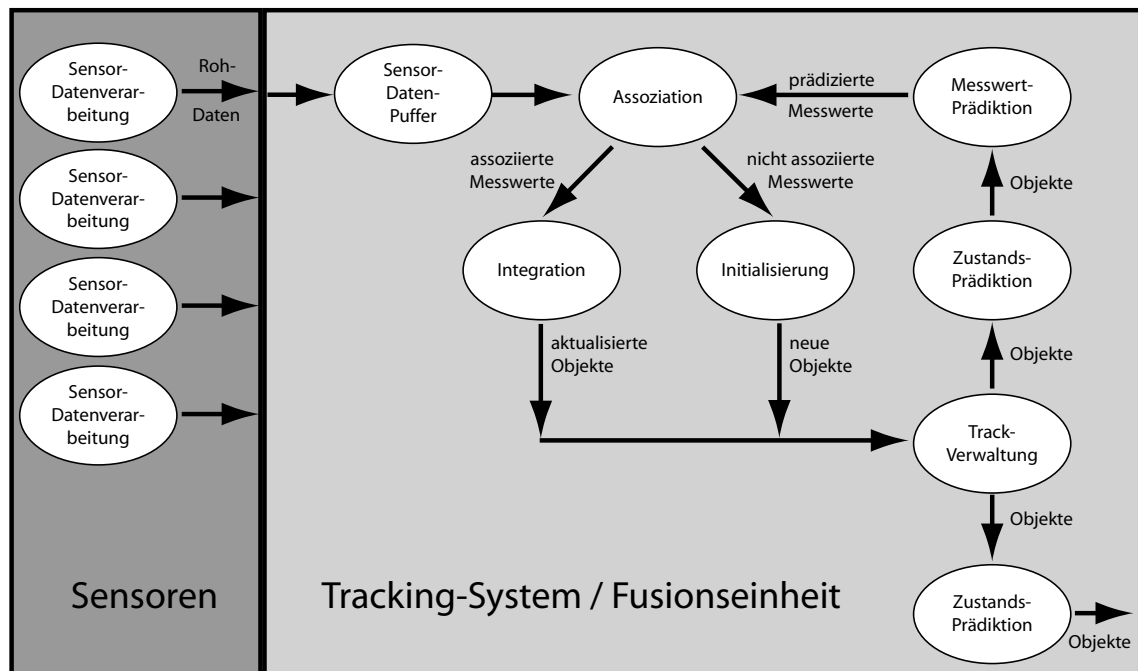


Abbildung 4.3.: Fusionsarchitektur mit Messdatenpuffer

2. Die Messunsicherheit ergibt sich ausschließlich aus der Sensorcharakteristik und ist damit zwar orts-, aber nicht zeitabhängig. Für ein ortsfestes Objekt ist die Unsicherheit eines Messwertes konstant.
3. Die zeitliche Reihenfolge der Messwerte bleibt erhalten. Auf diese Weise wird zu demjenigen Messzeitpunkt ein Objekt initialisiert, zu dem ein Objekt erstmalig detektiert wurde.
4. Globale Tracks ermöglichen ein durchgängiges Tracking auch bei komplementären Sensorerfassungsbereichen.
5. Die zeitliche Prädiktion der globalen Tracks vor der Ausgabe wird durch die fusionierten Messwerte aller Sensoren gestützt, sodass eine höhere Informationsdichte vorliegt und gegebenenfalls ein komplexeres Objektmodell genutzt werden kann.
6. Durch die zeitliche Prädiktion der globalen Tracks kann unabhängig von den Zykluszeiten der Sensoren eine periodische Ausgabe der Objektdaten mit einem beliebigen Zeitraster erfolgen. Hierdurch ergibt sich für eine nachgeschaltete Applikation ein von der Sensorkonfiguration unabhängiges Zeitverhalten, das selbst bei Ausfall von Sensoren erhalten bleibt.

Ein *Zeitversatz* zwischen der Realzeit und dem jüngsten Messzeitpunkt eines fusionierten Sensordatensatzes ist unvermeidlich<sup>1</sup> und setzt sich für jeden Sensor aus dem

<sup>1</sup> Es ist wichtig, dass bei dieser Definition der Zeitversatz sich nicht ändert, wenn ein älterer Sensordatensatz später fusioniert wird.

Messvorgang, der Verarbeitung und der Datenübertragung zusammen. Alle eingesetzten Sensoren arbeiten sequenziell, sodass ein neuer Messvorgang erst beginnt, nachdem die Verarbeitung des vorangegangenen Datensatzes abgeschlossen ist. Die aus Transfer- und Latenzzeit auf dem CAN-Bus verursachte Verzögerung bei der Datenübertragung wird vernachlässigt. Somit bestimmt die *Zykluszeit* eines Sensors einerseits die Zeit zwischen zwei Messungen, andererseits stellt sie für jeden Sensor eine untere Schranke für den Zeitversatz zur Realzeit dar.

Bei der Retrodiktion wird jeder Sensordatensatz unverzögert fusioniert, das heißt, er geht direkt in die Fusion ein, obwohl die älteren Daten von Sensoren mit einer größeren Zykluszeit erst später eintreffen. Ein älterer Datensatz kann durch die Retrodiktion nachträglich eingebracht werden. Somit ist der resultierende Zeitversatz minimal. Im vorangegangenen Kapitel wurde bereits dargestellt, dass diese Vorgehensweise vor allem bei der Mehrzielverfolgung Nachteile mit sich bringt, weil der Einfluss der Trackverwaltung (Initialisierung und Verwerfen von Objekten) bei der Retrodiktion unberücksichtigt bleibt.

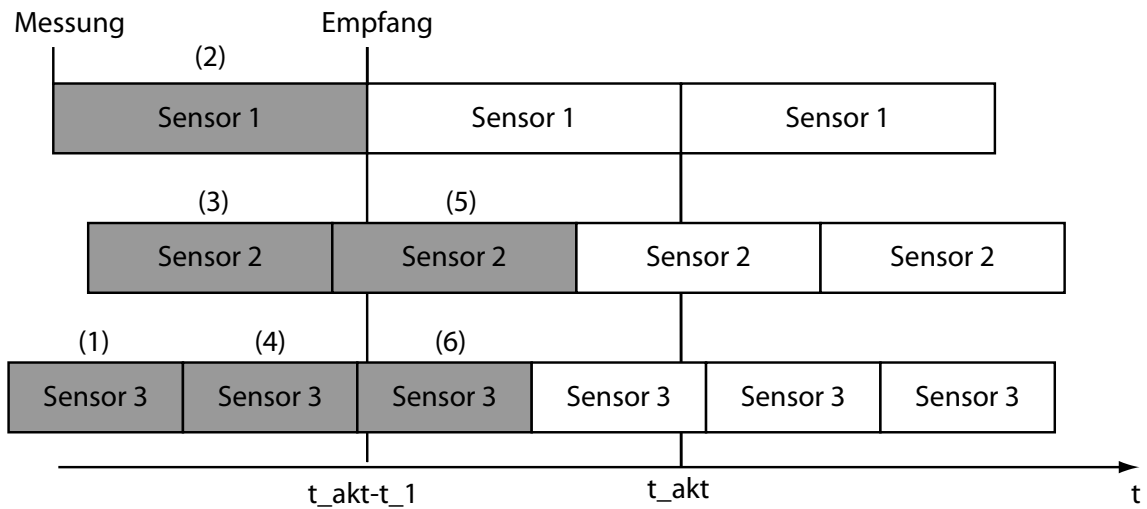
Durch die Fusionsarchitektur mit Messdatenpuffer wird jeder Sensordatensatz zunächst in den Messdatenpuffer gestellt und erst wenn sichergestellt ist, dass kein älterer Sensordatensatz eintrifft, fusioniert. Durch den Messdatenpuffer ergibt sich folglich eine zusätzliche Verzögerung, die zu minimieren ist. Um den aus der Verwendung des Messdatenpuffers resultierenden maximalen Zeitversatz bestimmen zu können, ist das maximale Alter<sup>2</sup> der Sensordatensätze im Puffer zu ermitteln. Dieses wird im Folgenden abgeschätzt.

Anhand von [Abbildung 4.4](#) soll die Funktionsweise des Messdatenpuffers und das maximale Alter der Sensordatensätze ermittelt werden. Es wird davon ausgegangen, dass von jedem Sensor neben dem Messzeitpunkt des letzten Datensatzes auch der Messzeitpunkt des nächsten Datensatzes bekannt ist. Vernachlässigt man die Datentransferzeit, so stimmt diese bei einer sequenziellen Verarbeitung mit dem letzten Empfangszeitpunkt überein. Alternativ lässt sich der Wert aus dem letzten Messzeitpunkt bei bekannter Zykluszeit berechnen. Auf diese Weise ergibt sich für jeden Sensor ein *erwarteter nächster Messzeitpunkt*. Ein Sensordatensatz wird fusioniert, wenn kein erwarteter nächster Messzeitpunkt eines anderen Sensors vor dem Messzeitpunkt des Sensordatensatzes liegt.

[Abbildung 4.4](#) zeigt eine mögliche Konstellation bei der Umgebungserfassung mit drei heterogenen Sensoren. Die Sensoren  $S_1$  bis  $S_3$  haben absteigende Zykluszeiten  $\Delta t_1$  bis  $\Delta t_3$ , die Zykluszeit von Sensor  $S_1$  ist somit maximal. Die Funktionsweise des Messdatenpuffers wird anhand des zeitlichen Ablaufs beschrieben.

1. Der erste empfangene Datensatz stammt von Sensor 3. Weil die erwarteten Messzeitpunkte von Sensor 1 und Sensor 2 hinter dem des empfangenen Datensatzes liegen, kann dieser direkt in die Fusion eingebracht werden (1). Es entsteht keine zusätzliche Verzögerung, sodass das Alter des Sensordatensatzes der Zykluszeit  $\Delta t_3$  von Sensor 3 entspricht.

<sup>2</sup> Das Alter eines Datensatzes im Messdatenpuffer ist die Zeitdifferenz zwischen Realzeit und Messzeitpunkt.



**Abbildung 4.4.:** Visualisierung der Funktionsweise des Messdatenpuffers: Die Reihenfolge der zur Realzeit  $t_{akt}$  fusionierten Messdaten ist gekennzeichnet.

2. Es wird ein Datensatz von Sensor 2 empfangen. Da der erwartete Messzeitpunkt von Sensor 1 vor dem empfangenen Datensatz liegt, kann dieser noch nicht in die Fusion eingebracht werden. Er wird in den Messdatenpuffer verschoben.
3. Ein weiterer Datensatz von Sensor 3 wird empfangen. Auch dessen Messzeitpunkt liegt hinter dem erwarteten Messzeitpunkt von Sensor 1, sodass dieser Datensatz ebenfalls in den Messdatenpuffer verschoben wird.
4. Der erwartete Datensatz von Sensor 1 wird empfangen und kann direkt in die Fusion eingebracht werden (2), weil keine älteren Messungen mehr vorliegen können (wegen  $\Delta t_1$  maximal). Es entsteht keine zusätzliche Verzögerung, sodass das Alter des Sensordatensatzes der Zykluszeit  $\Delta t_1$  von Sensor 1 entspricht.
5. Die gepufferten Daten können nun in der Reihenfolge ihres Messzeitpunktes in die Fusion eingebracht werden. Zunächst ist dies Sensor 2 (3), dann Sensor 3 (4). Das Alter beider Datensätze ist kleiner als  $\Delta t_1$ .
6. Der nächste empfangene Datensatz von Sensor 3 wird in den Puffer verschoben, weil der erwartete Messzeitpunkt von Sensor 2 zeitlich zurückliegt.
7. Nach dem Empfang des Datensatzes von Sensor 2 kann dieser direkt in die Fusion eingebracht werden (5), bevor der gepufferte Datensatz von Sensor 3 eingebracht wird (6). Dessen Alter ist kleiner als die Zykluszeit von Sensor 2.

Das beschriebene Verfahren macht deutlich, dass die maximale Verzögerung immer dann entsteht, wenn auf einen Datensatz des Sensors mit der längsten Zykluszeit

gewartet wird. Dieser Datensatz kann grundsätzlich unverzögert in die Fusion eingebracht werden, weil definitionsgemäß keine älteren Datensätze erwartet werden können. Das maximale Alter der Sensordatensätze anderer Sensoren ist somit ebenfalls durch die Zykluszeit des langsamsten Sensors nach oben beschränkt. Somit gilt für die zusätzliche Verzögerung durch den Messdatenpuffer:

$$0 \leq \Delta t_{\text{Verzögerung}} \leq \max_{i=1,2,\dots,n} \Delta t_i - \min_{i=1,2,\dots,n} \Delta t_i = \Delta t_1 - \Delta t_n. \quad (4.1)$$

Die durch den Puffer verursachte zusätzliche Verzögerung wird somit durch die Differenz der maximalen und minimalen Zykluszeit der Sensoren nach oben beschränkt. Es ist besonders darauf hinzuweisen, dass sich im Optimalfall durch die Verwendung des Puffers keine zusätzliche Verzögerung ergibt.

Der maximale Zeitversatz zwischen der Realzeit und dem jüngsten Messzeitpunkt eines fusionierten Sensordatensatzes ergibt sich aus folgender Betrachtung: Das maximale Alter eines Sensordatensatzes im Messdatenpuffer ist durch die Zykluszeit  $\Delta t_1$  des langsamsten Sensors gegeben. Der letzte zuvor fusionierte Sensordatensatz kann maximal eine Zykluszeit  $\Delta t_n$  des schnellsten Sensors zurück liegen. Somit kann der Zeitversatz vor der Fusion auf maximal  $\Delta t_1 + \Delta t_n$  anwachsen. Nach der Fusion eines Sensordatensatzes ist der maximale Zeitversatz durch das maximale Alter der Datensätze im Messdatenpuffer – und somit durch die maximale Zykluszeit  $\Delta t_1$  – gegeben. Der minimale Zeitversatz liegt vor, wenn ein Sensordatensatz des schnellsten Sensors unverzögert fusioniert wurde. Für den resultierenden Zeitversatz gilt somit unter Berücksichtigung der für die Fusion benötigte Rechenzeit  $\Delta t_{\text{Fusion}}$ :

$$\Delta t_n + \Delta t_{\text{Fusion}} \leq \Delta t_{\text{Zeitversatz}} \leq \Delta t_1 + \Delta t_n + \Delta t_{\text{Fusion}}. \quad (4.2)$$

Der maximale und minimale Zeitversatz einer Objektzustandsschätzung zur Realzeit ist aufgrund der obigen Betrachtung bei teilweise komplementären Sensorerfassungsbereichen abhängig davon, in welchen Erfassungsbereichen sich ein Objekt befindet. In unterschiedlichen Überlappungsbereichen kann daher der Zeitversatz variieren. Für ein einzelnes Objekt gilt die obige Abschätzung zudem nur unter den idealen Bedingungen, dass das Objekt in jedem Messzyklus erfasst wird. Eine Detektionsrate der Sensoren von 100% wird daher angenommen und es dürfen keine Verdeckungen auftreten.

#### 4.2.2. Filteralgorithmus

Zur modellbasierten Objektverfolgung soll in der Fusionsarchitektur ein unimodales Erweitertes Kalman-Filter eingesetzt werden. Die im vorangegangenen Kapitel beschriebenen Multi-Modell-Verfahren eignen sich, falls aufgrund eines veränderten Bewegungszustandes ein Objekt nicht mehr stabil verfolgt werden kann. Bei der Objektverfolgung im automobilen Straßenverkehr zeigt sich jedoch, dass sich selbst bei passendem Dynamikmodell Assoziationsprobleme ergeben können. Aufgrund dessen werden verschiedene neue Modifikationen des Erweiterten Kalman-Filters in [Kapitel 5](#) und [Kapitel 6](#) vorgestellt. Die Modifikationen sind aber keinesfalls auf das

Erweiterte Kalman-Filter beschränkt, sondern ebenso für Multi-Modell-Verfahren möglich.

Während die allgemeine Funktionsweise des Filters im [vorangegangenen Kapitel](#) beschrieben wurde, findet sich das konkrete Objektmodell im [nächsten Kapitel](#).

### 4.2.3. Korrelation der Sensordaten

Obwohl bei der gewählten Architektur die Fehler durch eine modellbasierte Prädiktion minimiert werden, verbleiben aus informationstheoretischer Sicht zwei Fehlerquellen.

#### Korrelation durch Einbringen getrackter Daten

Die Information eines Messwertes darf beim Filterprozess lediglich einmal eingebracht werden. Zwar kann dies wie in [Abbildung 3.1](#) auf Seite 16 gezeigt auf sehr unterschiedlichen Abstraktionsebenen geschehen, es muss jedoch sichergestellt sein, dass ein Messwert nicht auf mehreren Wegen in die Zustandsschätzung eines Objektes eingebracht wird und die Schätzung damit verfälscht. Bei der verfügbaren Sensorik liefern der Radarsensor und die Bildverarbeitung getrackte Daten, sodass innerhalb des Sensors bereits ein Tracking von Objekten erfolgt. Dies bedeutet, dass ein Messvektor, der zum Zeitpunkt  $k$  zur Fusionseinheit übertragen wird, bereits eine Schätzung aller vorliegenden Sensor-Rohdaten bis zu diesem Zeitpunkt darstellt. Wird dasselbe Objekt zum Zeitpunkt  $k + 1$  wieder an die Fusionseinheit übertragen, so besteht die Zustandsschätzung aus den Rohdaten bis zum Zeitpunkt  $k$  und einem weiteren Messwert des Zeitpunktes  $k + 1$ . Die Rohdaten bis zum Zeitpunkt  $k$  fließen somit erneut in die Fusion ein. Die Folge ist ein Tiefpassverhalten, das sich durch Kenntnis des im Sensor implementierten Objektmodells beseitigen lässt [[Chong u. a. 2000](#)]. Da diese Information lediglich dem Hersteller vorliegt, ist dies jedoch nicht möglich.

Im weiteren Verlauf dieser Arbeit werden daher schwerpunktmäßig Laserscanner-Daten genutzt, bei denen es sich um Rohdaten handelt. Bei der Demonstration von Fusionsergebnissen, in die auch Radar- und Bildverarbeitungsdaten eingehen, werden auch diese als Rohdaten behandelt. Da Manöver mit einer geringen Dynamik untersucht werden, ist das Tiefpassverhalten dabei zu vernachlässigen.

#### Korrelation durch gemeinsames Prozessrauschen

Auch durch das gemeinsame Prozessrauschen sind zwei Tracks von unterschiedlichen Sensoren korreliert und der Schätzwert ist aus theoretischer Sicht nicht mehr optimal [[Chang u. a. 1997](#); [Chong u. a. 2000](#)]. Auch in diesem Fall ist eine detaillierte Berücksichtigung nur mit Kenntnis der Sensormodelle möglich. Zudem ist der Effekt bisher ausschließlich in Monte-Carlo-Versuchen untersucht worden und scheint bei

realen Messdaten nur eine untergeordnete Rolle zu spielen. Auch diesem Effekt wird im Rahmen dieser Arbeit nicht nachgegangen.

## 5. Assoziation bei variabler Beobachtbarkeit

Nachdem sich das vorangegangene Kapitel mit der Filterarchitektur beschäftigt, beschreibt dieses Kapitel das Objektmodell sowie dessen Beobachtbarkeit durch die Sensoren. Da einige Objektmerkmale ausschließlich durch optische Sensoren detektiert werden können, wird auf Besonderheiten bei der Assoziation eingegangen, die sich bei deren Einbindung in die Fusion ergeben. In einem neuartigen Sensormodell wird der im dritten Kapitel dargestellte Multi-Modell-Ansatz für die Objektverfolgung auf die Messwertprädiktion übertragen, sodass diskrete Hypothesen für mögliche Assoziationen verfolgt werden. Zudem erläutert das Kapitel, wie die aus der Literatur bekannte Adaption des Prozessrauschens auch auf Messvektoren angewendet werden kann. Anstelle einer Skalierung erfolgt eine Adaption der Kovarianzmatrix des Messrauschens in einer bestimmten Raumrichtung. Durch die Kombination beider Verfahren lässt sich die Objektverfolgung während eines Perspektivenwechsels, bei flachen Aspektwinkeln und beim Verlassen des Sensorsichtbereiches verbessern.

### 5.1. Objektmodell und zeitliche Prädiktion


Bei einer Fusionsarchitektur nach [Abbildung 4.2](#) auf Seite 64 muss das Objektmodell detailliert genug sein, um sehr unterschiedlichen Applikationsanforderungen zu genügen. Die Unsicherheit einer Schätzung vergrößert sich aber durch jeden weiteren Modellparameter, wenn nicht zusätzliche Messwerte zur Verfügung stehen, sodass das Modell möglichst minimal sein sollte. Das gewählte Modell wird also einen Kompromiss dieser diametralen Anforderungen sein.

Applikationsseitig stellt die Kollisionsvermeidung die höchsten Anforderungen, da hier einerseits die Dynamik eines potenziellen Kollisionspartners sehr genau bekannt sein muss, andererseits vor allem die Kenntnis der Hinderniskontur den Auslösezeitpunkt bestimmt [[Kopischke 2000](#); [Jansson u. a. 2001](#)].


Das Minimalmodell soll eine Fahrzeugbewegung in der Ebene beschreiben. Zwar existiert hierzu eine Vielzahl an detaillierten Fahrzeugmodellen [[Mitschke 1972](#)], die nötigen Parameter lassen sich jedoch durch die verwendete Sensorik nicht sicher schätzen; dies gilt insbesondere für die Gierrate (Winkeländerung um die Hochachse). Es wird daher eine Bewegung in der  $xy$ -Ebene mit einer gleichförmigen Geschwindigkeit unabhängig in beiden Koordinatenrichtungen angenommen. Während ein reales Fahrzeug nicht holonome Zwangsbedingungen (Abhängigkeiten zwischen

den Geschwindigkeitskomponenten) aufweist, lässt sich hiermit eine Obermenge der möglichen Bewegungen eines Fahrzeuges beschreiben. Das Modell ist hinreichend genau, um beispielsweise Fahrzeuge auf Autobahnen zu verfolgen [Kirchner 2000].


Die Objektgeometrie wird durch einen umschreibenden Quader geschätzt, wie in [Abbildung 5.1](#) visualisiert. Im Gegensatz zu [Kirchner 2000] werden Länge und Breite nicht in Richtung der Koordinatenachsen angenommen, sondern der Quader kann eine beliebige Orientierung um die Hochachse einnehmen. Das Objektmodell hat auf diese Weise einen Freiheitsgrad mehr, sodass die durch das Modell festgelegte Grundfläche in der  $xy$ -Ebene die tatsächlich vom Objekt eingenommene Fläche besser approximiert. Diese Eigenschaft ist wesentlich für sicherheitsrelevante Applikationen wie beispielsweise eine Kollisionsvermeidung, da der Auslösezeitpunkt stark von der Objektgeometrie abhängt. Wird ein Objekt zu groß vermessen, so kann dies zu einem verfrühten Auslösezeitpunkt oder schlimmstenfalls zu einer Fehlauflösung führen. Eine Fehlauflösung liegt vor, wenn keine Kollision mit einem Objekt droht, aber aufgrund der fehlerhaften Objektbeschreibung ein Ausweichmanöver eingeleitet wird.



(a) Fahrzeug und Quadermodell aus Vogelperspektive



(b) Fahrzeug und Quadermodell aus seitlicher Perspektive



(c) Fahrzeug und Quadermodell von vorn

**Abbildung 5.1.:** Reales Fahrzeug und umschreibender Quader

Der Objektzustandsvektor  $\mathbf{x}_{\text{obj}}$  besteht damit aus der Position  $x, y$ , dem Gierwinkel  $\psi$ , den Parametern für Breite, Länge und Höhe  $b, l, h$  sowie den Geschwindigkeitskomponenten in  $x$ - und  $y$ -Richtung  $v_x, v_y$

$$\mathbf{x}_{\text{obj}} = [x, y, \psi, b, l, h, v_x, v_y]'. \quad (5.1)$$



Die Position bezieht sich auf den Schnittpunkt der Diagonalen des Grundflächenrechtecks.

Da sich nicht nur das Objekt, sondern auch der Sensorträger während der Zeit  $\Delta t$  bewegt, führt die erforderliche Kompensation der Eigenbewegung zu einer Koordinatentransformation, sodass der zeitliche Prädiktionsschritt des Zustandsvektors über zwei Abbildungen erfolgt:

$$\begin{aligned}\hat{\mathbf{x}}_{\text{obj}}(k|k) &\xrightarrow{\mathbf{f}} \hat{\mathbf{x}}_{\text{obj}}^*(k+1|k) \xrightarrow{\mathbf{e}} \hat{\mathbf{x}}_{\text{obj}}(k+1|k) \\ \mathbf{P}_{\text{obj}}(k|k) &\xrightarrow{\mathbf{F}} \mathbf{P}_{\text{obj}}^*(k+1|k) \xrightarrow{\mathbf{E}} \mathbf{P}_{\text{obj}}(k+1|k)\end{aligned}$$

Unter der Annahme eines linearen Bewegungsmodells mit konstanter Geschwindigkeit, konstanter Ausdehnung und konstantem Gierwinkel ändert sich nach Ablauf der Zeit  $\Delta t$  ausschließlich die Position des Objektes:

$$\hat{\mathbf{x}}_{\text{obj}}^*(k+1|k) = \hat{\mathbf{x}}_{\text{obj}}(k|k) + \begin{pmatrix} v_x \Delta t \\ v_y \Delta t \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{pmatrix}. \quad (5.2)$$

Somit ergibt sich diese Transfermatrix in Abhängigkeit von der Zeit  $\Delta t$ :

$$\mathbf{F}_{\text{obj}} = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 & 0 & \Delta t & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & \Delta t \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{pmatrix} \quad (5.3)$$

und es gilt

$$\hat{\mathbf{x}}_{\text{obj}}^*(k+1|k) = \mathbf{f}(\hat{\mathbf{x}}_{\text{obj}}(k|k)) = \mathbf{F}_{\text{obj}} \hat{\mathbf{x}}_{\text{obj}}(k|k). \quad (5.4)$$

Zur Prädiktion der Zustandskovarianz gemäß [Formel 3.15](#) auf Seite 28 muss die Kovarianzmatrix des Prozessrauschens aufgestellt werden, um Modellabweichungen zu berücksichtigen. Modellabweichungen resultieren aus einer beschleunigten Bewegung, einer Winkeländerung sowie einer sich ändernden Ausdehnung<sup>1</sup>. Die mögliche Beschleunigung des Objektes sei als normalverteilter Rauschprozess mit den beiden

<sup>1</sup> Die Geometrie eines Fahrzeugs ist zwar fest, wenn aber beispielsweise ein Laserscanner das Ziel nickwinkelbedingt in unterschiedlichen Höhen abtastet und sich hier Differenzen ergeben, so ist dieser Fehler auf das Modell und nicht auf das Messrauschen zurückzuführen.

Varianzen  $\sigma_{a_x}$  und  $\sigma_{a_y}$  für die beiden Koordinatenrichtungen angenommen. Für die Position und die Geschwindigkeit in Koordinatenrichtung wird eine Rauschverstärkung von  $\frac{1}{2}\Delta t^2$  respektive  $\Delta t$  angenommen. Auch die Varianz der Winkeländerung  $\sigma_\psi$  und die Varianzen der Geometrieparameter  $\sigma_b$ ,  $\sigma_l$  und  $\sigma_h$  werden mit dem Wert  $\Delta t$  verstärkt. Es resultiert diese Kovarianzmatrix für das Prozessrauschen:

$$\mathbf{Q}_{\text{obj}} = \begin{pmatrix} \frac{1}{4}\Delta t^4\sigma_{a_x}^2 & 0 & 0 & 0 & 0 & 0 & \frac{1}{2}\Delta t^3\sigma_{a_x}^2 & 0 \\ 0 & \frac{1}{4}\Delta t^4\sigma_{a_y}^2 & 0 & 0 & 0 & 0 & 0 & \frac{1}{2}\Delta t^3\sigma_{a_y}^2 \\ 0 & 0 & \Delta t^2\sigma_\psi^2 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & \Delta t^2\sigma_b^2 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & \Delta t^2\sigma_l^2 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & \Delta t^2\sigma_h^2 & 0 & 0 \\ \frac{1}{2}\Delta t^3\sigma_{a_x}^2 & 0 & 0 & 0 & 0 & 0 & \Delta t^2\sigma_{a_x}^2 & 0 \\ 0 & \frac{1}{2}\Delta t^3\sigma_{a_y}^2 & 0 & 0 & 0 & 0 & 0 & \Delta t^2\sigma_{a_y}^2 \end{pmatrix} \quad (5.5)$$

und es ergibt sich

$$\mathbf{P}_{\text{obj}}^*(k+1|k) = \mathbf{F}_{\text{obj}} \mathbf{P}_{\text{obj}}(k|k) \mathbf{F}_{\text{obj}}' + \mathbf{Q}_{\text{obj}}. \quad (5.6)$$

Die Eigenbewegung des Sensorträgers  $\Delta \mathbf{x}_{\text{ego}}$  setzt sich aus einer translatorischen und rotatorischen Komponente zusammen und lässt sich über die Parameter  $\Delta x$ ,  $\Delta y$  und  $\Delta \psi$  beschreiben. Die drei Werte sind ebenfalls Schätzgrößen, sodass bei der Transformation die zugehörige Kovarianzmatrix  $\Delta \mathbf{P}_{\text{ego}}$  zu berücksichtigen ist. Die Funktion  $\mathbf{e}$  bildet den zusammengesetzten Vektor

$$\hat{\mathbf{x}}_{\text{obj}}^{\text{ego}}(k+1|k) = [\hat{\mathbf{x}}_{\text{obj}}^*(k+1|k)', \Delta \mathbf{x}'_{\text{ego}}]'. \quad (5.7)$$

auf den prädizierten Zustandsvektor  $\hat{\mathbf{x}}_{\text{obj}}(k+1|k)$  ab. Dieser ergibt sich zu:

$$\begin{aligned} \hat{\mathbf{x}}_{\text{obj}}(k+1|k) &= \mathbf{e}(\hat{\mathbf{x}}_{\text{obj}}^{\text{ego}}(k+1|k)) \\ &= \begin{pmatrix} \cos(\Delta\psi)(x^* - \Delta x) + \sin(\Delta\psi)(y^* - \Delta y) \\ -\sin(\Delta\psi)(x^* - \Delta x) + \cos(\Delta\psi)(y^* - \Delta y) \\ \psi^* - \Delta\psi \\ b^* \\ l^* \\ h^* \\ v_x^* \\ v_y^* \end{pmatrix}. \quad (5.8) \end{aligned}$$

Die Funktion  $\mathbf{e}$  wird um den aktuellen Zustand linearisiert. Dabei ergibt sich unter Zuhilfenahme der Abkürzungen  $c = \cos(\Delta\psi)$ ,  $s = \sin(\Delta\psi)$ ,  $dx = (\Delta x - x)$  und

$dy = (\Delta y - y)$  die Matrix

$$\mathbf{E} = \left[ \nabla_{\mathbf{x}} \mathbf{e}(\mathbf{x}) \right]' \Big|_{\mathbf{x}=\hat{\mathbf{x}}_{\text{obj}}^{\text{ego}}(k|k)}$$

$$= \begin{pmatrix} c & s & 0 & 0 & 0 & 0 & 0 & 0 & -c & -s & dx & s - dy & c \\ -s & c & 0 & 0 & 0 & 0 & 0 & 0 & s & -c & dx & c + dy & s \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & & -1 & \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & & 0 & \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & & 0 & \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & & 0 & \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & & 0 & \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & & 0 & \end{pmatrix}. \quad (5.9)$$

Weil Objekt- und Eigenbewegung unabhängig voneinander sind, hat der zusammengesetzte Vektor  $\hat{\mathbf{x}}_{\text{obj}}^{\text{ego}}(k+1|k)$  die blockdiagonale Kovarianzmatrix:

$$\mathbf{P}_{\text{obj}}^{\text{ego}}(k+1|k) = \begin{pmatrix} \mathbf{P}_{\text{obj}}^*(k+1|k) & \mathbf{0} \\ \mathbf{0} & \mathbf{P}_{\text{ego}} \end{pmatrix}, \quad (5.10)$$

wobei  $\mathbf{P}_{\text{ego}}$  die zum Vektor  $\Delta \mathbf{x}_{\text{ego}}$  gehörige Kovarianzmatrix ist.

Somit lässt sich schließlich die prädierte Objekt-Zustandskovarianz bestimmen:

$$\mathbf{P}_{\text{obj}}(k+1|k) = \mathbf{E} \mathbf{P}_{\text{obj}}^{\text{ego}}(k+1|k) \mathbf{E}'. \quad (5.11)$$

## 5.2. Beobachtbarkeit des Zustandsvektors

Die Kombination von Radar, Laserscanner und Monobildverarbeitung erlaubt es, sämtliche Parameter des Zustandsvektors  $\mathbf{x}_{\text{obj}} = [x, y, \psi, b, l, h, v_x, v_y]'$  zu schätzen. Dennoch beinhalten die Messwerte eines einzelnen Sensors lediglich Informationen über einen Teil der Parameter. Der Begriff der Beobachtbarkeit wird daher formalisiert.

*Vollständige Beobachtbarkeit* definiert [Bar-Shalom und Li 1993, Kapitel 1]:

*Ein (deterministisches) System ist vollständig beobachtbar, wenn sein initialer Zustand vollständig und eindeutig aus einer endlichen Anzahl von Messungen und der Kenntnis über die Steuerung rekonstruiert werden kann<sup>2</sup>.*

Für ein lineares zeitvariantes System lässt sich die Beobachtbarkeit aus der *Beobachtbarkeitsmatrix*<sup>3</sup> ermitteln. Diese wird über die Systemtransferfunktion  $\mathbf{F}$  und die

<sup>2</sup> Aufgrund des Determinismus ist mit dem initialen Zustand der Zustand zu jedem beliebigen Zeitpunkt bekannt.

<sup>3</sup> engl.: observability matrix

Messmatrix  $\mathbf{H}$  wie folgt berechnet [Chen u. a. 1990; Chen 1991]:

$$\mathbf{M} \triangleq \begin{pmatrix} \mathbf{H}(k) \\ \mathbf{H}(k+1) \mathbf{F}(k) \\ \mathbf{H}(k+2) \mathbf{F}(k+1) \mathbf{F}(k) \\ \vdots \\ \mathbf{H}(k+n_x-1) \mathbf{F}(k+n_x-2) \cdots \mathbf{F}(k) \end{pmatrix}. \quad (5.12)$$

Hat die Beobachtbarkeitsmatrix den Rang der Dimension des Zustandsvektors  $n_x$  für alle  $k$ , so ist das System vollständig beobachtbar. Die Dimension der Beobachtbarkeitsmatrix  $\mathbf{M}$  ist  $(n_x n_y \times n_x)$  und hängt damit von der Dimension des Messvektors  $n_y$  ab. Ist diese minimal ( $n_y = 1$ ), so ist offensichtlich, dass  $\mathbf{M}$  gerade die minimale Dimension  $(n_x \times n_x)$  und damit eine notwendige Bedingung für einen Rang von  $n_x$  erfüllt. Für höherdimensionale Messvektoren können bereits  $m$  Messwerte für die Beobachtbarkeit ausreichen, falls gilt:  $m n_y \geq n_x$ .

Die Beobachtbarkeitsmatrix lässt sich anschaulich interpretieren: Der Rang der Messmatrix  $\mathbf{H}$  gibt an, wie viele Parameter des Zustandsvektors durch eine einzelne Messung festgelegt sind. Über das Produkt mit der Transfermatrix  $\mathbf{F}$  werden auch die dynamischen Parameter berücksichtigt, die nicht direkt beobachtet, sondern erst durch das dynamische Modell geschätzt werden (etwa Geschwindigkeiten anhand der Positionsänderung). Ein zusätzlicher Parameter des Zustandsvektors lässt sich nur dann schätzen, wenn ein neuer Messwert eine Abhängigkeit mit diesem aufweist. Exakt diese Beziehung findet sich ebenfalls in der Beobachtbarkeitsmatrix wieder: Eine neue Zeile erhöht den Rang nur dann, wenn keine lineare Abhängigkeit mit den vorangegangenen Zeilen existiert.


[Chen 1991] definiert die *lokale Beobachtbarkeit* über eine schwächere Bedingung: Ein System ist für die Zeitspanne  $k$  bis  $(k + n_x - 1)$  beobachtbar, falls Formel 5.12 für diese Zeitspanne den Rang  $n_x$  hat. Die Abschwächung lässt somit zu, dass der Initialzustand nicht zu jedem Zeitpunkt aus den Messwerten bestimmt werden kann<sup>4</sup>.

Der Rang der Beobachtbarkeitsmatrix gibt lediglich Aufschluss darüber, *ob* das System beobachtbar ist, trifft jedoch keine Aussage über die *Qualität* der Beobachtbarkeit. [Ham und Brown 1983] stellen hierzu ein Verfahren vor, bei dem die Zustandskovarianzmatrix zunächst normiert wird und über die Eigenwerte und -vektoren eine Bewertung über die Qualität der Beobachtbarkeit erfolgt. Die Normierung stellt eine Vergleichbarkeit trotz unterschiedlicher physikalischer Einheiten sicher.

### 5.2.1. Beobachtbarkeit durch die verwendete Sensorik

Im Folgenden wird gezeigt, dass mit der eingesetzten Sensorik eine lokale Beobachtbarkeit für das gewählte Objektmodell erzielt werden kann, eine vollständige Beobachtbarkeit jedoch nicht gegeben ist.

<sup>4</sup> Aufgrund des Determinismus kann auch in diesem Fall der Systemzustand zu jedem beliebigen Zeitpunkt bestimmt werden, sobald er für eine Zeitspanne beobachtet wurde.



**Abbildung 5.2.:** Lage eines durch den Zustandsvektor  $(x, y, \psi, b, l, h, v_x, v_y)$  gegebenen Objektes im Raum. Da die Höhe in Richtung der  $z$ -Achse zeigt, ist sie nicht dargestellt. Gezeigt werden auch die Messvektoren von Laserscanner  $(x_1, y_1, x_2, y_2, x_3, y_3)'$  und Bildverarbeitung  $(x_1, y_1, x_2, y_2, h)'$  unter der Annahme, dass sich die Sensoren im Ursprung befinden.

Abbildung 5.2 verdeutlicht die geometrischen Beziehungen. Wird das dargestellte Objekt von einem im Ursprung befindlichen Laserscanner erfasst, so wird die Lage der Eckpunkte vermessen. Der Messvektor  $\mathbf{z}(k)$  ist durch die Koordinaten der Eckpunkte  $(x_1, y_1, x_2, y_2, x_3, y_3)'$  definiert. Die Messfunktion lautet somit:

$$\mathbf{h}_{\text{Laser}}(\mathbf{x}) = \begin{pmatrix} x_1 \\ y_1 \\ x_2 \\ y_2 \\ x_3 \\ y_3 \end{pmatrix} = \begin{pmatrix} -\frac{l}{2} \cos(\psi) + \frac{b}{2} \sin(\psi) + x \\ -\frac{l}{2} \sin(\psi) - \frac{b}{2} \cos(\psi) + y \\ -\frac{l}{2} \cos(\psi) - \frac{b}{2} \sin(\psi) + x \\ -\frac{l}{2} \sin(\psi) + \frac{b}{2} \cos(\psi) + y \\ -\frac{l}{2} \cos(\psi) - \frac{b}{2} \sin(\psi) + x \\ -\frac{l}{2} \sin(\psi) + \frac{b}{2} \cos(\psi) + y \end{pmatrix}. \quad (5.13)$$

Die Linearisierung ergibt

$$\mathbf{H}_{\text{Laser}} = \begin{pmatrix} 1 & 0 & \frac{l}{2} \sin(\psi) + \frac{b}{2} \cos(\psi) & \frac{1}{2} \sin(\psi) & -\frac{1}{2} \cos(\psi) & 0 & 0 & 0 \\ 0 & 1 & -\frac{l}{2} \cos(\psi) + \frac{b}{2} \sin(\psi) & -\frac{1}{2} \cos(\psi) & -\frac{1}{2} \sin(\psi) & 0 & 0 & 0 \\ 1 & 0 & \frac{l}{2} \sin(\psi) - \frac{b}{2} \cos(\psi) & -\frac{1}{2} \sin(\psi) & -\frac{1}{2} \cos(\psi) & 0 & 0 & 0 \\ 0 & 1 & -\frac{l}{2} \cos(\psi) - \frac{b}{2} \sin(\psi) & \frac{1}{2} \cos(\psi) & -\frac{1}{2} \sin(\psi) & 0 & 0 & 0 \\ 1 & 0 & \frac{l}{2} \sin(\psi) - \frac{b}{2} \cos(\psi) & -\frac{1}{2} \sin(\psi) & -\frac{1}{2} \cos(\psi) & 0 & 0 & 0 \\ 0 & 1 & -\frac{l}{2} \cos(\psi) - \frac{b}{2} \sin(\psi) & \frac{1}{2} \cos(\psi) & -\frac{1}{2} \sin(\psi) & 0 & 0 & 0 \end{pmatrix}. \quad (5.14)$$

Die Bildverarbeitung liefert neben der durch die beiden Eckpunkte gegebenen Breite auch die Objekthöhe, sodass sich die folgende Messfunktion ergibt

$$\mathbf{h}_{\text{BV}}(\mathbf{x}) = \begin{pmatrix} x_1 \\ y_1 \\ x_2 \\ y_2 \\ h \end{pmatrix} = \begin{pmatrix} -\frac{l}{2} \cos(\psi) + \frac{b}{2} \sin(\psi) + x \\ -\frac{l}{2} \sin(\psi) - \frac{b}{2} \cos(\psi) + y \\ -\frac{l}{2} \cos(\psi) - \frac{b}{2} \sin(\psi) + x \\ -\frac{l}{2} \sin(\psi) + \frac{b}{2} \cos(\psi) + y \\ h \end{pmatrix} \quad (5.15)$$

und die Linearisierung die folgende Matrix liefert:

$$\mathbf{H}_{\text{BV}} = \begin{pmatrix} 1 & 0 & \frac{l}{2} \sin(\psi) + \frac{b}{2} \cos(\psi) & \frac{1}{2} \sin(\psi) & -\frac{1}{2} \cos(\psi) & 0 & 0 & 0 \\ 0 & 1 & -\frac{l}{2} \cos(\psi) + \frac{b}{2} \sin(\psi) & -\frac{1}{2} \cos(\psi) & -\frac{1}{2} \sin(\psi) & 0 & 0 & 0 \\ 1 & 0 & \frac{l}{2} \sin(\psi) - \frac{b}{2} \cos(\psi) & -\frac{1}{2} \sin(\psi) & -\frac{1}{2} \cos(\psi) & 0 & 0 & 0 \\ 0 & 1 & -\frac{l}{2} \cos(\psi) - \frac{b}{2} \sin(\psi) & \frac{1}{2} \cos(\psi) & -\frac{1}{2} \sin(\psi) & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \end{pmatrix} \quad (5.16)$$

Mit der Transfermatrix aus [Formel 5.3](#) ergibt sich folgende Beziehung:

$$\text{Rang} \begin{pmatrix} \mathbf{H}_{\text{BV}} \\ \mathbf{H}_{\text{Laser}} \mathbf{F} \end{pmatrix} = \text{Rang} \begin{pmatrix} \mathbf{H}_{\text{Laser}} \\ \mathbf{H}_{\text{BV}} \mathbf{F} \end{pmatrix} = 8. \quad (5.17)$$

Somit sind bereits die Messwerte von Laserscanner und Bildverarbeitung unabhängig von ihrer Reihenfolge hinreichend für die lokale Beobachtbarkeit<sup>5</sup>. Die Radarmesswerte verbessern die Geschwindigkeitsschätzung durch die hohe Updaterate und die direkten Geschwindigkeitsmesswerte, ohne Laserscanner und Bildverarbeitung lässt sich jedoch weder vollständige noch lokale Beobachtbarkeit erzielen.

Aber auch mit Laserscanner und Bildverarbeitung ist nicht zu jedem Zeitpunkt das Beobachtbarkeitskriterium erfüllt und somit nur eine lokale Beobachtbarkeit

<sup>5</sup> Tatsächlich genügen bereits die drei vom Laserscanner detektierten Eckpunkte und die von der Bildverarbeitung detektierte Höhe.

gegeben. Wird das Objekt aufgrund des Aspektwinkels nur von einer Seite gesehen, so liegen alle Messwerte auf der dem Sensor zugewandten Seite. Wird beispielsweise die Breite beobachtet, so lautet die Messfunktion für alle Punkte:

$$\mathbf{h}_{\text{Breite}} = \begin{pmatrix} -\frac{l}{2} \cos(\psi) - \lambda \frac{b}{2} \sin(\psi) + x \\ -\frac{l}{2} \sin(\psi) + \lambda \frac{b}{2} \cos(\psi) + y \end{pmatrix}. \quad (5.18)$$

Der Parameter  $\lambda$  bezeichnet die Lage eines Punktes auf der beobachteten Kante und liegt im Intervall  $[-1; 1]$ . Die lineare Abhängigkeit der Messvektoren bewirkt auch in der Beobachtbarkeitsmatrix eine lineare Abhängigkeit, sodass sich ein reduzierter Rang von sieben ergibt. Das Ergebnis ist wenig überraschend, da sich ohne einen Messwert für die Objektlänge auch die Position des Objektes nicht schätzen lässt – das Gleichungssystem ist unterbestimmt.

Aus den Betrachtungen geht hervor, dass die Beobachtbarkeit für ein Objekt einerseits von der Sensorkonfiguration, andererseits von der Lage im Zustandsraum – und damit von der Eigenverdeckung – abhängt. Eine Beobachtung durch optische Sensoren ist bei dem gewählten Objektmodell eines umschreibenden Quaders zwingend erforderlich, die variable Beobachtbarkeit führt jedoch zu zwei Schwierigkeiten:

1. Die Eigenverdeckung erschwert die korrekte Messwertprädiktion und führt damit zu Typ I Fehlern bei der Assoziation (vgl. [Abschnitt 3.4](#) auf Seite 46), sodass ein zum Objekt gehörender Messwert nicht zugeordnet wird.
2. Die partielle Beobachtbarkeit verhindert, dass der Zustandsvektor sich aus einer einzelnen Messung initialisieren lässt. Eine sukzessive Initialisierung ist erforderlich, bei der ausgehend von initial beobachteten Merkmalen eine Assoziation stattfindet und bei der Beobachtung zusätzlicher Merkmale eine Erweiterung des Zustandsvektors stattfindet.

Im weiteren Verlauf dieses Kapitels wird die Assoziationsproblematik ausschließlich anhand des Sensormodells thematisiert, wobei davon ausgegangen wird, dass eine vollständige Initialisierung des Zustandsvektors möglich ist. Das nächste Kapitel geht auf die Besonderheiten bei der Initialisierung und der Erweiterung des Zustandsvektors ein, die über die Modifikationen am Sensormodell hinaus auch das Filter betreffen.

### 5.3. Sensormodell zur robusten Assoziation

Bei der gewählten Fusionsarchitektur sind das Objektmodell, die zeitliche Prädiktion und das Filter sensorunabhängig, sodass bei Einbringen von Messdaten eines beliebigen Sensors dieselben Funktionsblöcke durchlaufen werden. Sensorspezifisch sind hingegen die Messwertprädiktion und die Assoziation, die im Folgenden exemplarisch für den Laserscanner beschrieben werden. Der eingesetzte Laserscanner

eignet sich besonders zur Untersuchung von Algorithmen, weil ungetrackte Rohdaten geliefert werden und das Objektmodell ohne Höhe vollständig beobachtbar ist (die im vorangegangenen Unterkapitel eingeführte Beobachtbarkeitsmatrix hat den Rang sieben). Die Ergebnisse lassen sich aus der Vogelperspektive leicht interpretieren und sind auf andere optische Systeme (beispielsweise Multibeam-Laser oder Stereo-Bildverarbeitung) übertragbar. Aufgrund des großen horizontalen Öffnungswinkels lassen sich bereits mit einem einzelnen Sensor Effekte untersuchen, die sich sonst erst bei der Fusion mehrerer Sensoren ergeben. Im Wesentlichen betrifft dies die Beobachtung eines Objektes aus unterschiedlichen Perspektiven.

Die Entwicklung des Sensormodells für den Laserscanner wird in diesem Unterkapitel anhand von realen Messdaten illustriert. Hierzu wird anhand der Rohdaten des Sensors zunächst ein naheliegendes Assoziationsverfahren vorgestellt, um seine Schwächen aufzuzeigen. Es schließt sich die Vorstellung eines neuen Sensormodells an, mit dem sich signifikante Verbesserungen erzielen lassen.


### 5.3.1. Rohdatenanalyse

Es erscheint vorteilhaft, wenn ein optischer Sensor in der Lage ist, die Kontur eines Fahrzeuges zu vermessen. Objektkanten lassen sich – im Gegensatz zu Radarreflexionszentren – exakt über das Objektmodell bestimmen und abhängige Merkmale wie Konturpunkte präzisieren. In der Praxis stellen sich die Messwerte jedoch komplexer dar, wie [Abbildung 5.3](#) zeigt. Visualisiert sind die Messwerte eines Laserscanners, der ein von links nach rechts passierendes Fahrzeug erfasst. Um den Einfluss der Eigenbewegung auszuschließen, wurde der Sensorträger während der Messung nicht bewegt. Der Laserscanner vermisst die Kontur des Fahrzeuges und überträgt den linken, dichtesten und rechten Konturpunkt als Messvektor.


Die detaillierte Analyse der Messdaten verdeutlicht die folgenden Aspekte:

1. Die Kontur wird zu klein vermessen, die äußeren Konturpunkte liegen zu dicht zusammen. Ursächlich ist zum einen das Messprinzip des Sensors, das bei einer diskreten Winkelschrittweite von  $0,5^\circ$  einen Konturpunkt nur dann detektiert wenn eine ausreichende Reflexion vorliegt. Da an den äußeren Kanten der Laserstrahl nicht vollständig auf die Kontur trifft, wird die Reflexion nicht detektiert. Das Objekt erscheint circa eine Divergenz zu klein. Dieser systematische Fehler lässt sich bei der Messwertprädiktion berücksichtigen.
2. Der dichteste Punkt zeigt stärkere Winkelschwankungen als die äußeren Konturpunkte. Dies ist vor allem in den Bereichen höherer Punktdichten beim Anfahren des beobachteten Objektes zu sehen. Erklären lässt sich dies ebenfalls über das Messprinzip. Von allen Konturpunkten wird derjenige mit der minimalen Entfernung selektiert. Bei dem polaren Messprinzip des Sensors führt ein Rauschen in der Entfernungsmessung hier zwangsläufig zu einem Rauschen im Winkel. Das Verhalten ist daher in der Kovarianzmatrix des Messrauschens zu berücksichtigen.






- (a) Messaufbau zur Rohdatenanalyse: Ein Fahrzeug quert vor dem ruhenden mit einem Laserscanner ausgestatteten Versuchsträger. Der Erfassungsbereich des Sensors ist gekennzeichnet.



- (b) Konturpunkte einer mit dem Laserscanner aufgezeichneten Messreihe: Der linke Konturpunkt ist jeweils rot, der dichteste grün und der rechte blau dargestellt. Jeder Messvektor besteht aus einem Punkt-Tripel aus einem linken, dichtesten und rechten Konturpunkt.



- (c) Die Messvektoren zu diskreten Zeitpunkten aus (a) verdeutlichen den Perspektivenwechsel. Das Verlassen des Sichtbereiches ist deutlich zu erkennen.

**Abbildung 5.3.:** Lasermesswerte eines von links nach rechts passierenden Fahrzeuges. Das Fahrzeug beschleunigt aus dem Stand bis zum Verlassen des Sensorsichtbereiches. Der Sensor befindet sich im Ursprung des Koordinatensystems.

3. Der rechte Konturpunkt beschreibt – entgegen der Objektbewegung – keine geradlinige Bewegung, sondern wandert bei Annäherung des Fahrzeuges nach innen. Ursache ist die gekrümmte Fahrzeugfront, die nicht dem Quadermodell entspricht.
4. Der linke Konturpunkt springt bei der Vorbeifahrt plötzlich von der hinteren rechten auf die hintere linke Fahrzeugecke. Der plötzliche Sprung ist in diesem Fall auf das nur minimal gekrümmte Heck zurückzuführen. Der Übergang erfolgt nicht direkt nach dem Passieren des Scanners, sondern erst wenige Messzyklen später.
5. Die Fahrzeugbreite und -länge sind zunächst vollständig zu erkennen. Beim Annähern verschwindet die Front und es wird lediglich die Seite beobachtet. Nach dem Passieren des Laserscanners wird erneut die vollständige Fahrzeugkontur detektiert bevor die Seite aufgrund des ungünstigen Aspektwinkels verschwindet. Das Fahrzeugheck verschwindet schließlich an der Sichtbereichsgrenze des Laserscanners.

Während die ersten beiden Punkte sensorspezifisch sind und über das Sensormodell und die Messunsicherheit berücksichtigt werden können, spiegeln die weiteren Punkte typische Probleme optischer Sensoren wieder. Zwar sind optische Systeme in der Lage, wichtige Konturmerkmale zu detektieren, die Merkmale sind jedoch in starkem Maße abhängig vom aktuellen Aspektwinkel.

### 5.3.2. Assoziation

Die Assoziation bei optischen Sensoren weist einige grundsätzliche Unterschiede im Vergleich zu Radarsensoren auf. Letztere zeichnen sich dadurch aus, dass der Messvektor radiale Entfernung und Geschwindigkeit eines Reflexionszentrums beinhaltet. Aufgrund der - verglichen mit optischen Sensoren - ungenaueren Winkelmessung werden mögliche Zuordnungen über Suchbereiche (vgl. [Unterabschnitt 3.4.1](#)) bestimmt, die sowohl die Entfernung als auch die Geschwindigkeit berücksichtigen. Weisen verschiedene Objekte mit identischer Entfernung dieselbe Geschwindigkeit auf (wie beispielsweise stehende Objekte), so sind häufig unterschiedliche Zuordnungen möglich, die über geeignete Zuweisungsverfahren (vgl. [Unterabschnitt 3.4.2](#)) aufgelöst werden müssen. Erst die Anwendung des Zuweisungsverfahrens liefert die korrekte bzw. wahrscheinlichste Zuordnung für einen Messwert, während Suchbereiche die Komplexität der Bestimmung reduzieren.

Optische Sensoren zur Fahrumgebungserfassung detektieren diverse Konturmerkmale von Objekten, messen jedoch in der Regel nicht deren Geschwindigkeit. Über die Konturmerkmale und die genauere Winkelmessung ist jedoch gewöhnlich eine korrekte Zuordnung möglich. Je mehr unabhängige Parameter über Suchbereiche berücksichtigt werden können, umso geringer ist die Wahrscheinlichkeit, dass sich für einen Messwert mehrere mögliche Zuordnungen ergeben. Die wesentliche Aufgabe der Assoziation bei optischen Sensoren wird daher über Suchbereiche gelöst, während dem Zuweisungsverfahren eine untergeordnete Rolle zukommt.

### Suchbereiche für optische Sensoren

Da optische Sensoren in der Regel eine höhere Genauigkeit bei der Winkelmessung aufweisen, als Radarsensoren, verursachen Typ II - Fehler, bei denen eine Beobachtung einem falschen Objekt zugeordnet wird, eine stärkere Störung der Trajektorien-schätzung des betroffenen Objektes. Suchbereiche müssen daher möglichst klein gewählt werden, um solche Fehler zu vermeiden. Die Berücksichtigung von mehreren Merkmalen zur Definition des Suchbereiches hat andererseits zur Folge, dass *alle* Merkmale zuzuordnen sein müssen. Der Suchbereich muss daher *groß genug* gewählt werden, um korrekte Zuordnungen zuzulassen. In [Unterabschnitt 3.4.1](#) wurden rechteckige und elliptische Suchbereiche vorgestellt, die auf die Verwendbarkeit hin untersucht werden.

**Rechteckige Suchbereiche** sind für optische Sensoren schlecht geeignet. Zwar ergibt sich eine geringere Rechenkomplexität als bei elliptischen Suchbereichen, weil nur die Diagonalelemente der Innovationskovarianz berücksichtigt werden (siehe [Formel 3.92](#) auf Seite 48). Da optische Sensoren jedoch polare Messeigenschaften besitzen, erweist sich dies als nachteilig. Nimmt man das Messrauschen in Entfernung und Winkel als unabhängig voneinander an, so ergibt die Transformation der Unsicherheiten in kartesische Koordinaten Abhängigkeiten, die bei ausschließlicher Auswertung der Hauptdiagonale nicht berücksichtigt werden. Dies gilt sowohl für die linearisierte als auch die Unscented Transformation. Die detaillierte Herleitung der Kovarianzmatrix des Messrauschens erfolgt im nächsten Abschnitt.

**Elliptische Suchbereiche** berücksichtigen die Innovationskovarianz vollständig und sind daher besser zur Bestimmung möglicher Zuordnungen geeignet. Da sich Detektionswahrscheinlichkeit sowie Neu- und Fehlziel-Dichten nicht begründet quantifizieren lassen, wird die Suchbereichsgröße über die Verteilungsdichte des Mahalanobis-Abstandes definiert. Um den Suchbereich ausreichend robust gegenüber Abweichungen einzelner Merkmale zu wählen, sollte ein 99%-Konfidenzbereich gewählt werden, sodass sich die folgende Bedingung für den Suchbereich ergibt:

$$d_{\text{Suchbereich}}^2 = \boldsymbol{\nu}(k)' \mathbf{S}(k)^{-1} \boldsymbol{\nu}(k) \leq z_{(0,99;n_z)}. \quad (5.19)$$

### Zuweisungsverfahren für optische Sensoren

Obwohl Suchbereiche bei optischen Sensoren selten zu Mehrdeutigkeiten führen, müssen auch diese geeignet behandelt werden. Zumeist rühren Mehrdeutigkeiten daher, dass zunächst ein Typ I - Fehler vorliegt, bei dem ein Messwert dem richtigen Objekt nicht zugeordnet werden kann und eine neue Objekthypothese aufgesetzt wird. Beide Objekthypothesen *konkurrieren* um die nachfolgenden Messwerte, wobei sich in der Regel bei dem jüngeren Objekt aufgrund der größeren Unsicherheiten kleinere Mahalanobisabstände ergeben. Um zu verhindern, dass das jüngere Objekt

bei der Zuweisung bevorzugt wird, lässt sich ein Strafterm berücksichtigen:

$$d_{\text{Zuweisung}}^2 = \boldsymbol{\nu}(k)' \mathbf{S}(k)^{-1} \boldsymbol{\nu}(k) + \ln(|\mathbf{S}(k)|). \quad (5.20)$$

Wichtig ist, dass der Strafterm nicht bereits bei der Bestimmung der Suchbereiche berücksichtigt wird, wie dies in [Blackman und Populi 1999, Kapitel 6] dargestellt ist, da  $d_{\text{Zuweisung}}^2$  nicht mehr  $\chi^2$ -verteilt ist. Der oben definierte Suchbereich stellt sicher, dass alle Messwert-Prädiktionspaare mit einer statistischen Sicherheit assoziierbar sind. Das Zuweisungsverfahren bevorzugt unter allen möglichen Kombinationen diejenigen mit kleinerer Unsicherheit. Durch dieses Verfahren lässt sich zumeist eine Zuordnung zu einem neu initialisierten Objekt verhindern.

Obwohl theoretisch suboptimal liefert bereits der iterative Nächster-Nachbar-Algorithmus aufgrund der durch den Suchbereich stark reduzierten Mehrdeutigkeiten zumeist die optimale Lösung. Die höhere Rechenkomplexität für optimale Verfahren, Alle-Nachbarn-Algorithmen und Multi-Hypothesen-Tracking ist daher unangemessen.

## Anwendung auf reale Messdaten

Das eingeführte Assoziationsverfahren wird anhand der oben dargestellten Messreihe für Laserscannerdaten näher untersucht. Aufgrund des polaren Messprinzips des Laserscanners wird für die Konturpunkte ein unabhängiger Fehler für die Winkel- und Entfernungsmessung angenommen. Dieser wird mit  $\sigma_\phi = 0,7^\circ$  und  $\sigma_r = 0,4\text{m}$  für die äußeren Konturpunkte und den doppelten Werten für den dichtesten Punkt konservativ abgeschätzt. Die Abschätzung basiert auf der Divergenz des Laserstrahls einerseits und der Reflektivitätsabhängigkeit der Entfernungsmessung andererseits. Die polare Kovarianzmatrix  $\mathbf{R}^{\text{polar}}$  wird über die Linearisierung der Transformation auf kartesische Koordinaten transformiert. Somit ergibt sich:

$$\mathbf{R}^{\text{polar}} = \begin{pmatrix} \sigma_r^2 & 0 \\ 0 & \sigma_\phi^2 \end{pmatrix} \quad \mathbf{R}^{\text{kartesisch}} = \begin{pmatrix} \sigma_x^2 & \sigma_{xy}^2 \\ \sigma_{xy}^2 & \sigma_y^2 \end{pmatrix}, \quad (5.21)$$

wobei die Linearisierung an der Stelle  $\mathbf{z} = [r_0, \phi_0]'$  die folgenden Größen liefert:

$$\begin{aligned} \sigma_x^2 &= \sigma_r^2 \cos^2(\phi_0) + \sigma_\phi^2 r_0^2 \sin^2(\phi_0) \\ \sigma_y^2 &= \sigma_r^2 \sin^2(\phi_0) + \sigma_\phi^2 r_0^2 \cos^2(\phi_0) \\ \sigma_{xy}^2 &= \cos(\phi_0) \sigma_r^2 \sin(\phi_0) - r_0^2 \sin(\phi_0) \sigma_\phi^2 \cos(\phi_0). \end{aligned} \quad (5.22)$$

Der gesamte Messvektor  $\mathbf{z}(k)$  ist durch die Koordinaten des linken, dichtesten und rechten Konturpunktes wie folgt gegeben:

$$\mathbf{z}(k) = (x_l, y_l, x_d, y_d, x_r, y_r)'. \quad (5.23)$$


Die Messunsicherheit  $\mathbf{R}(k)$  ist durch die zusammengesetzte Kovarianzmatrix gegeben:

$$\mathbf{R}(k) = \begin{pmatrix} \mathbf{R}_l^{\text{kartesisch}} & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \mathbf{R}_d^{\text{kartesisch}} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \mathbf{R}_r^{\text{kartesisch}} \end{pmatrix}. \quad (5.24)$$

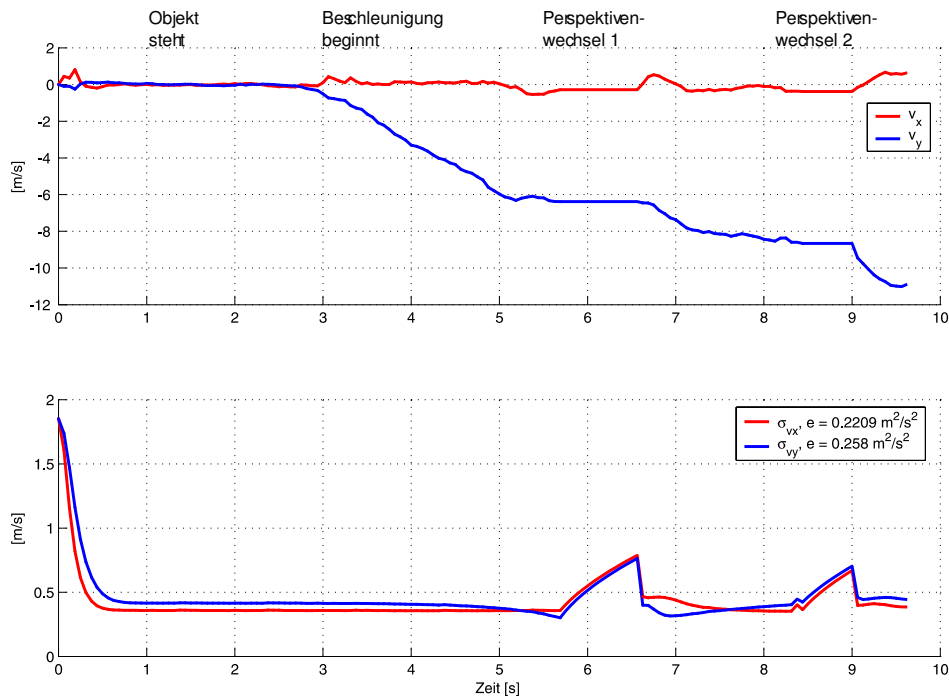
Die Messwertprädiktion bestimmt aus dem Objektmodell den linken, dichtesten und rechten Objektpunkt unter Berücksichtigung, dass das Objekt in den Messwerten eine Divergenz zu schmal erscheint. Die Sichtbereichsgrenze des Laserscanners wird bei der Prädiktion ebenfalls berücksichtigt. Es wird lediglich eine Objektinitialisierung zu Beginn des Trackings zugelassen, um einen Einfluss durch Fehlinitialisierungen zu vermeiden. Das Ergebnis der Objektverfolgung für die oben beschriebene Messreihe zeigt [Abbildung 5.4](#).

**Die Auswertung** offenbart deutliche Schwächen des vorgestellten Assoziationsverfahrens, wobei eine Einteilung in unterschiedliche Phasen vorgenommen werden kann:

1. Während der ersten Sekunden steht das Fahrzeug und das Filter zeigt den zu erwartenden Einschwingvorgang. Dies lässt sich an den sinkenden Standardabweichungen ablesen, die schnell auf ein konstantes Niveau fallen.
2. Nach ca. drei Sekunden beschleunigt das Fahrzeug, was an der y-Komponente des Geschwindigkeitsvektors abzulesen ist. Das Filter folgt der Bewegung ohne erkennbare Störungen, wie aus den unverändert niedrigen Standardabweichungen hervorgeht.
3. In der Zeitspanne von ca. 5,6s bis 6,6s ist die Objektverfolgung massiv gestört und es werden nur noch vereinzelt Messwerte erfolgreich assoziiert. Die Folge sind eine deutlich vergrößerte Standardabweichungen der Position und Geschwindigkeit sowie eine erkennbar fehlerhafte Schätzung der Geschwindigkeitskomponente in y-Richtung. Die beschleunigte Bewegung ist in der Grafik nicht zu erkennen.
4. Bis zum Zeitpunkt 8,5s stabilisiert sich die Objektverfolgung durch erfolgreich assoziierte Messwerte und die Standardabweichungen sinken auf das Niveau vor der Störung. Die Geschwindigkeit in x-Richtung zeigt ein deutlich erkennbares Überschwingen.
5. In der Zeitspanne von ca. 8,5s bis 9,0s kann kein Messwert assoziiert werden. Erneut wachsen die Unsicherheiten von Position und Geschwindigkeit an und insbesondere die Schätzung der Geschwindigkeitskomponente in y-Richtung ist fehlerhaft, da sie erneut eine konstante Geschwindigkeit widerspiegelt.
6. Bis zum Verlassen des Sichtbereiches werden Messwerte assoziiert und die Objektverfolgung stabilisiert sich wiederum. Die Standardabweichungen fallen erneut auf das Niveau vor den Störungen. Obwohl sich das Objekt geradlinig




(a) Objektkoordinaten und Orientierung mit Standardabweichungen.



(b) Geschwindigkeitskomponenten mit Standardabweichungen.

**Abbildung 5.4.:** Geschätzte Position und Geschwindigkeit mit Standardabweichungen. Die mittlere quadratische Standardabweichung ist in der Legende mit  $e$  angegeben.



**Abbildung 5.5.:** Geschätzte Formparameter mit Standardabweichungen. Die mittlere quadratische Standardabweichung ist in der Legende mit  $e$  angegeben.

bewegt und die Messwerte der Bewegung folgen, ergibt sich jedoch eine anwachsende Geschwindigkeit in x-Richtung.

Eine quantitative Bewertung der Assoziation ermöglicht die Betrachtung des normierten Innovationsquadrates (NIS), das in [Abbildung 5.6](#) zu sehen ist. Die Darstellung ist auf den zulässigen Suchbereich normiert. Eine Assoziation findet nur bis zur eingezeichneten Schwelle statt. Die Abbildung zeigt weiterhin das über fünf Werte gemittelte Innovationsquadrat (ANIS)<sup>6</sup>, welches häufig als Konsistenzkriterium eines Filters eingesetzt wird [[Bar-Shalom und Li 1993](#), Kapitel 5.4]. Die Größe ist  $\chi^2$ -verteilt mit 5  $n_z$  Freiheitsgraden<sup>7</sup>. Bei Werten kleiner Eins wird das Filter als *konsistent* bezeichnet.

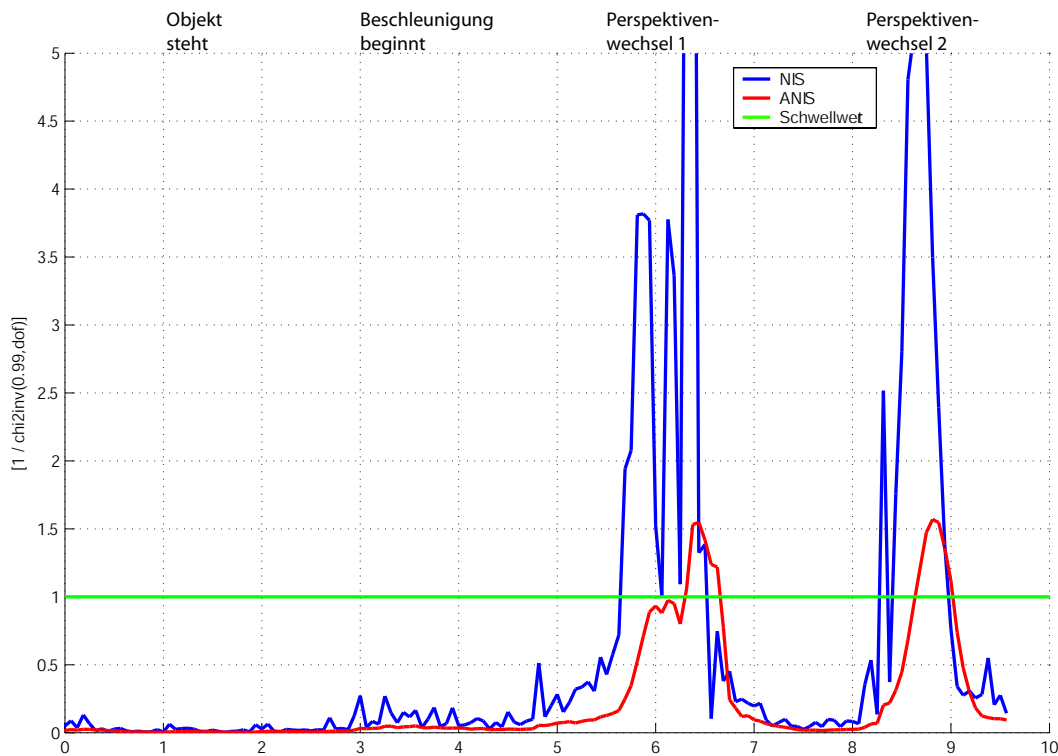
Die Grafik verdeutlicht, die beschriebenen Effekte. In den Phasen in denen ein stabiles Tracking erfolgt, zeigen sich geringe Abstandswerte und das Filter ist konsistent. Die Konsistenz des Filters wird in den Bereichen, in denen keine Assoziation stattfindet, gestört.

**Die Ursache** für die gestörte Objektverfolgung lässt sich leicht eingrenzen, wenn man die beobachtete Kontur analysiert:

1. Zunächst wird das Objekt mit beiden Kanten (Länge und Breite) beobachtet,

<sup>6</sup> engl.: Average Normalized Innovation Squared.

<sup>7</sup> engl.: degree of freedom - dof



**Abbildung 5.6.:** Normiertes Innovationsquadrat (NIS) und Durchschnitt über 5 Werte (ANIS). Falls das normierte Innovationsquadrat unterhalb der eingezeichneten Schwelle liegt, werden Messdaten assoziiert. Liegt der Durchschnittswert unterhalb der Schwelle, ist das Filter konsistent.

bevor nur noch die Seite sichtbar ist. Die eindeutige Prädiktion der drei Punkte während der Übergangsphase ist offensichtlich fehlerhaft.

2. Während nur die dem Sensor zugewandte Objektseite beobachtbar ist, springt der dichteste Punkt auf der Fahrzeugkontur, da alle Punkte einen ähnlichen Abstand zum Sensor aufweisen. Obwohl der dichteste Punkt exakt prädiziert werden kann, zeigt der reale Messwert deutliche Abweichungen, die eine erfolgreiche Assoziation verhindern.
3. Nach dem Passieren des Sensors ist das Fahrzeugheck wieder sichtbar. Zwar erfolgt der Perspektivenwechsel sprunghaft, wie über das Objektmodell zu erwarten, die Schwierigkeit besteht hier jedoch darin, den Zeitpunkt des Wechsels zu prädizieren.
4. Bei weiterer Entfernung des Objektes vom Sensor wird der Betrachtungswinkel der Fahrzeugseite flacher und der rechte Punkt springt auf der Kontur. Eine genaue Messwertprädiktion ist hier nicht möglich.
5. Beim Verlassen des Sichtbereiches wandern die Messpunkte in positive  $x$ -Richtung. Offensichtlich hat diese Bewegung einen Einfluss auf die Geschwin-



digkeitsschätzung des Objektes, obwohl die Sichtbereichsgrenze bei der Prädiktion berücksichtigt wurde.

Zusammenfassend lassen sich zwei grundsätzliche Phänomene erkennen, die eine robuste Assoziation bei optischen Sensoren im automobilen Straßenverkehr erschweren:

- Die *Messwertprädiktion* ist stark abhängig vom Betrachtungswinkel und entspricht insbesondere bei einem Wechsel der Perspektive häufig nicht der Messwertrealisation.
- Die *Messunsicherheit* schwankt, da in Abhängigkeit von der Perspektive nicht nur unterschiedliche Merkmale detektiert werden, sondern diese auch unterschiedlich gut beobachtbar sind.

Im Folgenden werden daher Verfahren entwickelt, die diese Probleme beseitigen.

### 5.3.3. Messwertprädiktion

Die Berücksichtigung von Verdeckungsinformationen bei der Messwertprädiktion vereinfacht sich, wenn der zeitlich prädierte Zustandsvektor des Objektes im Koordinatensystem des Sensors vorliegt. Hierzu wird der Zustandsvektor  $\hat{\mathbf{x}}_{\text{obj}}(k+1|k)$  über die Funktion  $\mathbf{s}^{-1}$  in das Koordinatensystem des Sensors transformiert, von wo die Abbildung auf den Messwert  $\hat{\mathbf{z}}(k+1|k)$  über die Funktion  $\mathbf{l}$  erfolgt (vgl. [Abschnitt 3.5](#)).

$$\hat{\mathbf{x}}_{\text{obj}}(k+1|k) \xrightarrow{\mathbf{s}^{-1}} \hat{\mathbf{x}}_{\text{obj}}^S(k+1|k) \xrightarrow{\mathbf{l}} \hat{\mathbf{z}}(k+1|k) \quad (5.25)$$

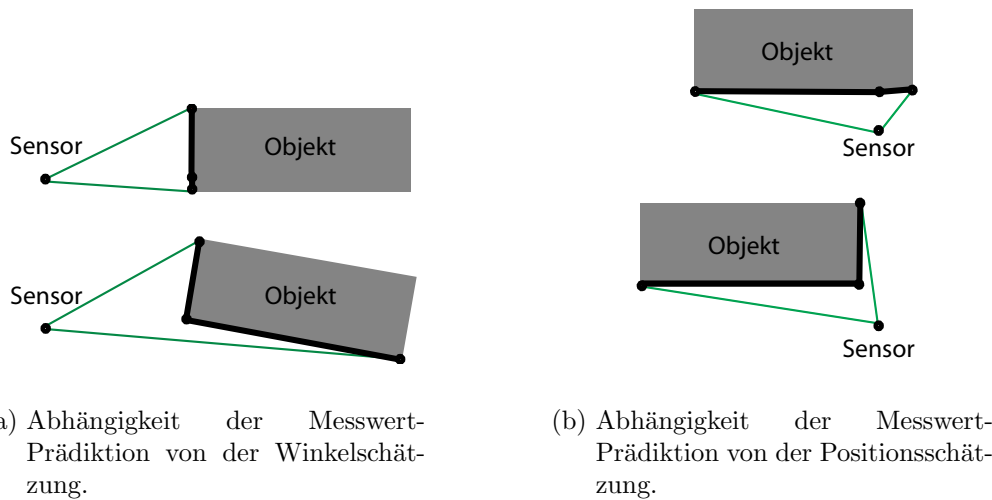
Die Messfunktion  $\mathbf{h}$  ist die Verkettung der beiden obigen Funktionen:

$$\mathbf{h} = \mathbf{l} \circ \mathbf{s}^{-1}. \quad (5.26)$$

Da die Sensoren mit dem Versuchsträger fest verbunden sind, ändert sich die Koordinatentransformation  $\mathbf{s}^{-1}$  nicht und die Messwertprädiktion wird durch die vom Zustandsvektor abhängige Funktion  $\mathbf{l}$  bestimmt.

Der linke, dichteste und rechte Konturpunkt sind mathematisch eindeutig definiert, sodass über das Objektmodell zu jedem prädierten Zustandsvektor die exakten Koordinaten der Punkte ermittelbar sind<sup>8</sup>. Den Einfluss der Zustandsschätzung auf die Prädiktion zeigt [Abbildung 5.7](#). Das Sprungverhalten der prädierten Punkte führt zu einer Fallunterscheidung in der Messfunktion, wobei an den Übergangsstellen eine Unstetigkeit auftritt. Diese Unstetigkeit führt dazu, dass eine kleine Änderung im Zustandsvektor eine große Änderung an der Lage der prädierten Punkte bewirkt.

<sup>8</sup> Durch den linken, dichtesten und rechten Konturpunkt sind Länge, Breite und Orientierung des Objektes festgelegt. Die von anderen optischen Systemen gelieferten Messgrößen sind von diesen Punkten abhängig, sodass das Verfahren nicht auf den Laserscanner beschränkt ist.



**Abbildung 5.7.:** Einfluss der Zustandsschätzung auf die Messwertprädiktion beim Laserscanner.

Weil die Prädiktion nicht auf dem wahren Zustand  $\mathbf{x}(k+1)$ , sondern auf der zeitlich prädizierten Schätzung  $\hat{\mathbf{x}}(k+1|k)$  erfolgt, kann bereits aus einem kleinen Schätzfehler  $\tilde{\mathbf{x}}(k+1)$  eine fehlerhafte Prädiktion folgen und die Assoziation schlägt fehl. Da der Schätzfehler eine während der Objektverfolgung unbekannte Größe ist, ist es unmöglich, jederzeit die korrekte Messwertprädiktion zu finden.

### Mehrfach-Messwertprädiktion

Multi-Modell-Verfahren zur verbesserten Zustandsschätzung sind seit geraumer Zeit bekannt und haben sich bei der dynamischen Objektverfolgung bewährt (vgl. [Unterabschnitt 3.3.5](#) auf Seite 42). Es wird bei diesem Ansatz angenommen, dass die Objektbewegung zu jedem Zeitpunkt durch ein Modell aus einer Menge von Modellen beschrieben werden kann. Unterschiedliche Manöver eines Objektes werden durch unterschiedliche Modelle abgedeckt, wobei a priori unbekannt ist, welches Modell zu welchem Zeitpunkt die Objektbewegung am besten beschreibt.

Es lässt sich für die Messwertprädiktion ein analoger Ansatz wählen: Zu jedem zeitlich prädizierten Zustandsvektor wird eine Menge von hypothetischen Messwertprädiktionen berechnet. Man nimmt an, dass zu jedem Zeitpunkt genau eine Prädiktion einer Messwertrealisation zugeordnet werden kann. Im Filterschritt werden lediglich die Innovation und die Messfunktion der erfolgreich zugeordneten Prädiktion eingebracht. Im Unterschied zum Multi-Modell-Verfahren wird nur die am besten passende Hypothese (die Prädiktion mit dem geringsten Abstand zur Messwertrealisation) benutzt. Dieser Ansatz lässt sich dadurch rechtfertigen, dass die Mehrfach-Messwertprädiktion gerade dann eingesetzt werden soll, wenn sich bei einer geringen Änderung des Zustandsvektors sehr verschiedene Prädiktionen ergeben. Der Abstand der Messwertrealisation zu den verschiedenen Prädiktionen wird daher stark variieren und idealerweise nur eine Prädiktion das Kriterium des Suchbereiches er-

füllen. Darüber hinaus ist das mehrfache Einbringen eines Messvektors auch über unterschiedliche Messfunktionen aus informationstheoretischer Sicht unzulässig, da der Messwert in diesem Fall stärker gewichtet würde, ohne dass zusätzliche Information zur Verfügung stünde.

Das verbal vorgestellte Verfahren wird formalisiert. Gegeben ist ein Sensormodell mit einer abschnittsweise definierten Messfunktion:

$$\mathbf{h}(\mathbf{x}) = \begin{cases} \mathbf{h}_1(\mathbf{x}) & , \text{ falls } \mathbf{x} \in X_1 \\ \mathbf{h}_2(\mathbf{x}) & , \text{ falls } \mathbf{x} \in X_2 \\ \vdots & \\ \mathbf{h}_n(\mathbf{x}) & , \text{ falls } \mathbf{x} \in X_n \end{cases} \quad (5.27)$$

Die Funktion ist für alle  $\mathbf{x} \in X$  definiert und die Teilmengen  $X_i$  sind disjunkt:

$$\begin{aligned} X_i &\subseteq X, \\ X_i \cap X_j &= \emptyset \text{ für alle } i, j \in [1, 2, \dots, n] \text{ mit } i \neq j, \\ \bigcup_{i=1}^n X_i &= X. \end{aligned} \quad (5.28)$$

Eine *Mehrfach-Messwertprädiktion*  $\hat{Z}(k+1|k)$  aus  $m$  Messwerten wird wie folgt definiert:

$$\begin{aligned} \hat{Z}(k+1|k) &\triangleq \{\hat{\mathbf{z}}_1(k+1|k), \hat{\mathbf{z}}_2(k+1|k), \dots, \hat{\mathbf{z}}_m(k+1|k)\}, \text{ wobei} \\ \hat{\mathbf{z}}_j(k+1|k) &\triangleq \mathbf{h}_{i_j}(\hat{\mathbf{x}}(k+1|k)), \\ i_j &\in \{1, 2, \dots, n\}, \quad j = \{1, 2, \dots, m\}, \quad m \leq n. \end{aligned} \quad (5.29)$$

Hierbei ist sicherzustellen, dass der Definitionsbereich der Funktion  $\mathbf{h}_{i_j}$  den Zustandsvektor  $\hat{\mathbf{x}}(k+1|k)$  umfasst. Dies bedeutet, dass eine Funktion  $\mathbf{h}_{i_j}$ , obwohl sie bei der Einfach-Messwertprädiktion aufgrund der Fallunterscheidung nur für den Bereich  $X_{i_j}$  angewendet wird, darüber hinaus *definiert* ist.

$$\hat{\mathbf{x}}(k+1|k) \in \text{def}(\mathbf{h}_{i_j}) \supseteq X_{i_j} \quad (5.30)$$

Das Suchbereichskriterium aus [Formel 5.19](#) wird auf die Mehrfach-Messwertprädiktion angewendet, indem die Bedingung für jede der enthaltenen Prädiktionen geprüft wird. Hierbei werden die Einzelinnovationen und Innovationskovarianzen betrachtet<sup>9</sup>:

$$\boldsymbol{\nu}_j(k+1) \triangleq \mathbf{z}(k+1) - \hat{\mathbf{z}}_j(k+1|k), \quad (5.31)$$

$$\mathbf{H}_j(k+1) \triangleq [\nabla_{\mathbf{x}} \mathbf{h}_{i_j}(\mathbf{x})]'|_{\mathbf{x}=\hat{\mathbf{x}}(k+1|k)}, \quad (5.32)$$

$$\mathbf{S}_j(k+1) \triangleq \mathbf{H}_j(k+1) \mathbf{P}(k+1|k) \mathbf{H}_j(k+1)' + \mathbf{R}(k+1), \quad (5.33)$$

$$d_{\text{Suchbereich } j}^2 \triangleq \boldsymbol{\nu}_j(k+1)' \mathbf{S}_j(k+1)^{-1} \boldsymbol{\nu}_j(k+1). \quad (5.34)$$

<sup>9</sup> Um die Darstellung zu vereinfachen, wird auf den Messvektor-Index und den Objektindex an dieser Stelle verzichtet.

Es ergibt sich eine reduzierte Mehrfach-Messwertprädiktion  $\hat{Z}_{\text{Suchbereich}}(k+1|k)$ , die lediglich diejenigen  $p$  Prädiktionen beinhaltet, die das Suchbereichskriterium erfüllen. Für  $p = 0$  kann kein Messwert assoziiert werden.

$$\begin{aligned} \hat{Z}_{\text{Suchbereich}}(k+1|k) &\triangleq \{\hat{\mathbf{z}}_{l_1}(k+1|k), \hat{\mathbf{z}}_{l_2}(k+1|k), \dots, \hat{\mathbf{z}}_{l_p}(k+1|k)\}, \text{ wobei} \\ d_{\text{Suchbereich } l_j}^2 &\leq z_{(0,99;n_z)}, \\ l_j &\in \{1, 2, \dots, m\}, \quad j = \{1, 2, \dots, p\}, \quad p \leq m. \end{aligned} \quad (5.35)$$

Vor der Anwendung des Zuweisungsverfahrens werden die Strafterme für die einzelnen Prädiktionen berücksichtigt (vgl. [Formel 5.20](#)):

$$d_{\text{Zuweisung } j}^2 \triangleq \boldsymbol{\nu}_j(k+1)' \mathbf{S}_j(k+1)^{-1} \boldsymbol{\nu}_j(k+1) + \ln |\mathbf{S}_j(k+1)|. \quad (5.36)$$

Das Zuweisungsverfahren bestimmt aus der reduzierten Mehrfach-Messwertprädiktion den Index  $l_{\text{opt}} \in \{l_1, l_2, \dots, l_p\}$  der Prädiktion mit dem geringsten Abstand zum Messwert:

$$\hat{\mathbf{z}}(k+1|k) = \hat{\mathbf{z}}_{l_{\text{opt}}}(k+1|k), \text{ mit } d_{\text{Zuweisung opt}} = \min_{i=l_1, l_2, \dots, l_p} d_{\text{Zuweisung } i}. \quad (5.37)$$

Die zum Aktualisierungsschritt des Filters benötigte Innovation und deren Kovarianz ergeben sich zu:

$$\boldsymbol{\nu}(k+1) = \boldsymbol{\nu}_{l_{\text{opt}}}(k+1) \quad (5.38)$$

$$\mathbf{S}(k+1) = \mathbf{S}_{l_{\text{opt}}}(k+1) \quad (5.39)$$

Somit liegen alle Größen für den Aktualisierungsschritt vor. Weitere Modifikationen am Filter sind nicht erforderlich.

## Anwendung der Mehrfach-Messwertprädiktion


Eine Mehrfach-Messwertprädiktion soll beim Laserscanner zu einer stabilen Assoziation während der Perspektivenwechsel genutzt werden, also immer dann, wenn zunächst zwei Kanten sichtbar sind und nach dem Wechsel nur noch eine oder umgekehrt. Unabhängig davon, ob der Perspektivenwechsel aus einer Winkel- oder Positionsänderung resultiert (vgl. [Abbildung 5.7](#)), wächst die Wahrscheinlichkeit einer falschen Prädiktion mit einem geringeren Winkelunterschied zwischen einer sichtbaren der benachbarten Objektecke. Dieser Zusammenhang kann genutzt werden, um zu entscheiden, ob zusätzliche Prädiktionen erforderlich sind.

Die Mehrfach-Messwertprädiktion beim Laserscanner lässt sich in zwei Teilschritte zerlegen:

1. Zunächst wird wie bei der Einfach-Messwertprädiktion der aufgrund des prädierten Zustandsvektors zu erwartende Messvektor prädiert (im Folgenden als *Primärprädiktion* bezeichnet). Der linke und rechte Konturpunkt sind Objektecken. Die Winkellage dieser Objektecken wird ermittelt.

- Die benachbarten Ecken des linken resp. rechten Konturpunktes werden bestimmt und die Winkellage mit der des korrespondierenden Konturpunktes verglichen. Ist der Winkelunterschied kleiner als eine vorgegebene Schwelle, so wird der linke resp. rechte Konturpunkt der Primärprädiktion durch den benachbarten Eckpunkt ersetzt. Der resultierende Messvektor wird als zusätzliche *Sekundärprädiktion* ergänzt.

Das Vorgehen ist in [Abbildung 5.8](#) illustriert. Ein Mehraufwand durch zusätzliche Messwertprädiktionen ergibt sich nur dann, wenn aufgrund eines erwarteten Perspektivenwechsels die Möglichkeit besteht, dass die Primärprädiktion nicht erfolgreich assoziiert werden kann. Die erhöhte Komplexität relativiert sich jedoch insofern, als eine Neuinitialisierung im Falle einer gescheiterter Assoziation einen größeren Mehraufwand bedeutet. Während sich im ersten Fall ausschließlich für die Messwertprädiktion und Assoziation eine höhere Komplexität für wenige Iterationen ergibt, wird eine zusätzliche Objekthypothese von allen Elementen des Tracking-systems verarbeitet. Neben dem zusätzlichen Aufwand innerhalb des Sensormodells sind hier auch die zeitliche Prädiktion und die Trackverwaltung betroffen.



(a) Primärprädiktion und benachbarte Objektecke

(b) Resultierende Sekundärprädiktion

**Abbildung 5.8.:** Beispiel einer Mehrfach-Messwertprädiktion: Aus der Perspektive des Sensors besteht nur ein geringer Winkelunterschied zwischen der rechten Ecke der Primär-Messwertprädiktion und der verdeckten hinteren Ecke. Die Sekundärprädiktion resultiert aus der Annahme, dass der rechte Messpunkt möglicherweise auf die hintere Ecke fällt.

Ein weiterer Vorteil ergibt sich durch die verbesserte Schätzung, da sämtliche Information in die Zustandsschätzung eines einzelnen Objektes fließt. Wird aufgrund einer gescheiterten Assoziation ein neues Objekt initialisiert, so ist dessen initiale Unsicherheit hoch und es erfolgt zunächst der Einschwingvorgang des Filters.

Das Ergebnis der Anwendung auf die obige Messreihe ist in [Abbildung 5.9](#) bis [Abbildung 5.11](#) dargestellt. Es ist eine deutliche Verbesserung gegenüber der Einfach-Messwertprädiktion erkennbar. Im Detail lassen sich diese wie folgt quantifizieren:


- Die Anzahl der nicht assoziierbaren Messwerte sinkt von 21 auf 11. Die Perspektivenwechsel beim Entfernen des Objektes vom Sensor (Zeitraum 8,5-9,0s) werden hierbei besser stabilisiert als die beim Annähern (Zeitraum 5,6-6,6s). Die Ursache ist in [Abbildung 5.3](#) auf Seite 81 erkennbar. Bei der Annäherung wandert der rechte Messpunkt kontinuierlich nach innen, während die Mehrfach-Messwertprädiktion das sprunghafte Verhalten beim Entfernen berücksichtigt.
- Der Zeitraum, in dem das Filterkonsistenz gegeben ist, ist deutlich ausgedehnt. Oberhalb von 8s tritt keine Inkonsistenz mehr auf, obwohl zwei Messwerte nicht assoziiert werden können. Der Zeitraum um 6s verbessert sich geringfügig. Der ANIS-Graph zeigt hier einen flacheren Anstieg, woraus abzulesen ist, dass Messwerte und Prädiktionen einen geringeren Abstand aufweisen.
- Die mittlere quadratische Standardabweichung der Position reduziert sich in  $x$ -Richtung um 35% und in  $y$ -Richtung um 38%. Der Wert für den Gierwinkel reduziert sich um 1%. Dies ist vor allem auf die Stabilisierung im Zeitraum 8,5-9,0s zurückzuführen.
- Die mittlere quadratische Standardabweichung der Geschwindigkeit reduziert sich in beide Koordinatenrichtungen um 8%. Dieses Ergebnis korrespondiert mit der Positionsschätzung.
- Die Breiten- und Längenschätzungen zeigen keine signifikante Veränderung gegenüber der Einfach-Messwertprädiktion. Da die Größen keine Dynamik aufweisen, bringen die zehn zusätzlichen Messwerte keinen Gewinn bei der Schätzung.

Um die Ergebnisse der Einzelmessreihe zu verifizieren, wurde diese mehrmals durchgeführt. Die Größenordnungen der obigen Verbesserungen konnten hierbei bestätigt werden.


Trotz des messbaren Gewinns ist das Ergebnis der Mehrfach-Messwertprädiktion suboptimal. Es verbleibt eine reduzierte Anzahl von Typ I Assoziationsfehlern und auch die ansteigende Geschwindigkeit in  $x$ -Richtung beim Verlassen des Sensorkegels. Eine fehlerhafte Prädiktion ist hier offensichtlich nicht die einzige Fehlerquelle.

#### 5.3.4. Adaption der Messunsicherheit

Die bisherige Betrachtung thematisiert, *ob* ein Zustandsvektor beobachtbar ist, die *Qualität* einer Beobachtung wurde jedoch nicht bewertet. Mehrfach-Messwertprädiktionen als diskrete Hypothesen dienen bislang dazu, das Sprungverhalten der äußeren Konturpunkte beim Perspektivenwechsel zu erfassen. Wie die Rohdatenanalyse (vgl. [Abbildung 5.3](#) auf Seite 81) zeigt, treten jedoch auch kontinuierliche Unsicherheiten auf, die sich darin äußern, dass ein Konturpunkt nicht sprunghaft von einer Objektecke auf die nächste springt, sondern zuvor eine stärkere Streuung aufweist.




(a) Objektkoordinaten und Orientierung mit Standardabweichungen.



(b) Geschwindigkeitskomponenten mit Standardabweichungen.

**Abbildung 5.9.:** Geschätzte Position und Geschwindigkeit mit Standardabweichungen bei Anwendung der Mehrfach-Messwertprädiktion. Die mittlere quadratische Standardabweichung ist in der Legende mit  $e$  angegeben.



**Abbildung 5.10.:** Geschätzte Formparameter mit Standardabweichungen bei Anwendung der Mehrfach-Messwertprädiktion. Die mittlere quadratische Standardabweichung ist in der Legende mit  $e$  angegeben.


Dies ist in [Abbildung 5.12](#) dargestellt<sup>10</sup>. Eine Berücksichtigung der Streuung über zusätzliche Mehrfach-Messwertprädiktionen wäre denkbar, jedoch würde hierdurch die Komplexität der Prädiktion und Assoziation erheblich gesteigert. Aufgrund der statistischen Suchbereiche ist alternativ eine Adaption der beteiligten Varianzen und Kovarianzen denkbar.

Bisher wurde davon ausgegangen, dass die Messunsicherheit eines Konturpunktes ausschließlich aus dem Messprinzip resultiert und infolgedessen aus den beiden unabhängigen Varianzen der Entfernung und des Winkels zusammengesetzt ist. Dies ist offensichtlich nicht der Fall, denn sowohl die Entfernungsunsicherheit als auch die Winkelunsicherheit sind abhängig vom Betrachtungswinkel und damit korreliert. Wie der vorangegangene Unterabschnitt zeigt, ist das bisher angenommene Messrauschen zu klein und verhindert damit eine statistisch gesicherte Assoziation über den Mahalanobisabstand. Daher ist es erforderlich, das Messrauschen in geeigneter Weise zu adaptieren, um die Streuung der Messwerte korrekt zu berücksichtigen und die Assoziation hierdurch zu stabilisieren.

Diverse Verfahren zur Varianz-Adaption sind bekannt (vgl. [Unterabschnitt 3.3.4](#) ab Seite 39). Diese Verfahren wurden eingeführt, um Modellabweichungen in der Dyna-

<sup>10</sup> Es sei darauf hingewiesen, dass die dargestellten Schwankungen im statischen Fall deutlich schwächer ausgeprägt sind als bei einer dynamischen Szene.






**Abbildung 5.11.:** Normiertes Innovationsquadrat (NIS) und Durchschnitt über 5 Werte (ANIS) bei Anwendung der Mehrfach-Messwertprädiktion. Falls das normierte Innovationsquadrat unterhalb der eingezeichneten Schwelle liegt, werden Messdaten assoziiert. Liegt der Durchschnittswert unterhalb der Schwelle, ist das Filter konsistent.


mik berücksichtigen zu können. Hierbei wird die Kovarianzmatrix des Prozessrauschens entweder über einen Faktor skaliert oder zwischen diskreten Kovarianzmatrizen umgeschaltet. Eine Übertragung auf die Kovarianzmatrix des Messrauschens erscheint jedoch aus folgenden Gründen nicht möglich:

- Die Skalierung der Kovarianzmatrix vergrößert den Unsicherheitsbereich insgesamt, ohne dabei die räumliche Lage zu ändern. Jede Raumrichtung wird gleichermaßen vergrößert.
- Die Abhängigkeit vom Aspektwinkel würde eine Vielzahl von diskreten Kovarianzmatrizen erfordern. Eine geeignete Umschaltung zwischen diesen erscheint aufwändig.
- Im Gegensatz zum Objekt besitzen Rohdaten keine Historie. Eine Adaption muss daher für die aktuelle Filteriteration und nicht für zukünftige Filteriterationen erfolgen.

Es ist daher ein alternativer Algorithmus zu entwickeln, der die folgenden Teilprobleme löst:



- (a) Während der linke und dichteste Konturpunkt gut beobachtbar sind, schwankt der Entfernungsmesswert des rechten Konturpunktes stark.




- (b) Während der linke und rechte Konturpunkt gut beobachtbar sind, schwankt der Winkelmesswert des dichtesten Konturpunktes stark.

**Abbildung 5.12.:** Häufig detektierte Konturpunkte des Laserscanners bei ungünstigem Betrachtungswinkel. Blau: linker Konturpunkt, Grün: dichtester Konturpunkt, Rot: rechter Konturpunkt.

1. Der Aspektwinkel muss ermittelt werden.
2. Die Kovarianzmatrix ist unter Berücksichtigung des Aspektwinkels zu adaptieren.

### Bestimmung des Aspektwinkels

Die Bedingungen für die Notwendigkeit einer Kovarianzadaption wurden bereits aufgezeigt. Im Falle eines steilen Aspektwinkels auf eine Kante muss die (Teil-)kovarianzmatrix des dichtesten Punktes in [Formel 5.24](#) modifiziert werden. Im Falle eines flachen Winkels sind die (Teil-)kovarianzmatrizen der äußeren Punkte betroffen. Zunächst erscheint es trivial, für ein Objekt den Aspektwinkel für die dem Sensor zugewandten Seiten zu bestimmen. Doch obwohl der Aspekt- und damit der Gierwinkel des Objektes die Ursache für die beschriebenen Messunsicherheiten darstellt,



**Abbildung 5.13.:** Erkennung von Hypothese 2: Der Messvektor entspricht einer Objektkante. Entscheidungskriterium ist der Abstand des dichtesten Punktes von der durch die beiden äußeren Punkte definierten Geraden.


darf und kann dieser nicht für die Adaption der Messunsicherheit herangezogen werden. Aus informationstheoretischer Sicht ist die Berücksichtigung unzulässig, weil in diesem Fall Adaption gerade so erfolgt, dass ein Messwert dem *gewünschten* Objekt zugeordnet werden kann. Darüber hinaus müsste zunächst eine grobe Assoziation vorgenommen werden, um zu entscheiden, welche Messwertunsicherheit anhand welcher Objektwinkel adaptiert wird. Anschließend müsste dann erneut eine Assoziation stattfinden.

Es ist also erforderlich, den Aspektwinkel ausschließlich aus den Größen des Messvektors zu ermitteln. Hierbei sollen im Folgenden drei Hypothesen unterschieden werden:

**Hypothese 1:** Linker, dichtester und rechter Messpunkt entsprechen den Objektecken. In diesem Fall wird die Kovarianzmatrix des Messrauschens wie im vorangehenden Abschnitt hergeleitet unter der Annahme von unabhängigen Winkel- und Entfernungsfehlern bestimmt. Diese Standardhypothese wird immer dann angewendet, wenn keine der anderen Hypothesen greift.

**Hypothese 2:** Die beiden äußeren Messpunkte entsprechen Objektecken, der dichteste Punkt liegt auf der verbindenden Kante. In diesem Fall ist die Kovarianzmatrix des dichtesten Punktes derart anzupassen, dass seine Unsicherheit entlang der Kante heraufgesetzt wird. Die Unsicherheit der anderen Messpunkte wird aus unabhängigen Winkel- und Entfernungsfehlern bestimmt. Die Erkennung der Hypothese erfolgt über den Abstand des dichtesten Punktes von der durch die beiden äußeren Punkte definierten Kante, wie dies in [Abbildung 5.13](#) dargestellt ist. Wird ein von der Entfernungsunsicherheit des Sensors abhängiger Schwellwert unterschritten, gilt die Hypothese als gültig.

**Hypothese 3:** (Mindestens) ein äußerer Punkt liegt auf einer Kante, die unter einem flachen Winkel  $\gamma$  betrachtet wird, wie dies in [Abbildung 5.14](#) dargestellt ist. Überschreitet der Winkel einen Schwellwert, so ist die Unsicherheit des betroffenen äußeren Punktes entlang der Kante heraufzusetzen. Die Unsicherheit der anderen Punkte wird aus unabhängigen Winkel- und Entfernungsfehlern bestimmt.



**Abbildung 5.14.:** Erkennung von Hypothese 3: Der Betrachtungswinkel  $\alpha$  vom Sensor auf die durch den dichtesten und äußeren Punkt definierte Kante ist sehr flach.

Falls Hypothese 2 oder 3 erkannt wird, steht fest, für welchen Messpunkt die Unsicherheit adaptiert werden muss, wobei hiervon gemäß [Formel 5.24](#) nur eine  $2 \times 2$  Teilmatrix der Kovarianz des Messrauschens betroffen ist. Mit der Richtung der Kante, auf der der Punkt liegt, ist zusätzlich bekannt, in welche Raumrichtung die Unsicherheit erhöht werden muss.

### Kovarianzadaption in beliebiger Raumrichtung

Die Standardabweichung entlang einer vermuteten Objektkante und damit der dadurch definierten Raumrichtung lässt sich über typische Dimensionen von Fahrzeugen abschätzen. Es ist ein Verfahren zu entwickeln, mit dem sich hieraus die Varianzen und Kovarianzen im Koordinatensystem des Sensors ableiten lassen. Da das Verfahren auf den Abbildungseigenschaften der *Hauptachsentransformation* basiert, wird diese zunächst vorgestellt.


**Hauptachsentransformation:** Durch die Hauptachsentransformation werden  $p$  Merkmale durch eine lineare Abbildung in  $p$  orthogonale Komponenten überführt. Aus der Orthogonalität folgt, dass die Kovarianzen der transformierten Komponenten Null sind. [Abbildung 5.15](#) verdeutlicht das Verfahren. Die Hauptachse  $\mathbf{h}_1$  definiert das Merkmal mit der größten Varianz,  $\mathbf{h}_2$  das mit der zweitgrößten, usw.

Die entsprechende Kovarianzmatrix wird dabei wie folgt abgebildet:

$$\mathbf{C}_{e_1 \dots e_p} = \begin{pmatrix} \sigma_{e_1}^2 & \sigma_{e_2 e_1}^2 & \dots & \sigma_{e_p e_1}^2 \\ \sigma_{e_2 e_1}^2 & \sigma_{e_2}^2 & \dots & \sigma_{e_p e_2}^2 \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{e_p e_1}^2 & \sigma_{e_p e_2}^2 & \dots & \sigma_{e_p}^2 \end{pmatrix} \xrightarrow{\mathbf{A}} \begin{pmatrix} \sigma_{h_1}^2 & 0 & \dots & 0 \\ 0 & \sigma_{h_2}^2 & 0 & \dots & 0 \\ & & \ddots & & \\ 0 & \dots & & & \sigma_{h_p}^2 \end{pmatrix} \quad (5.40)$$

Hierbei sind die Hauptachsen  $h_1$  bis  $h_p$  durch die Eigenvektoren der Kovarianzmatrix  $\mathbf{C}_{e_1 \dots e_p}$  festgelegt. Unter der Voraussetzung, dass alle Eigenvektoren  $h_i$  normiert sind, entsprechen die zugehörigen Eigenwerte  $\lambda_i$  den Varianzen der Hauptachsen.

Die in [Abbildung 5.15](#) dargestellte Ellipse ist über die Hauptachsen und die korrespondierenden Varianzen definiert. Allgemein wird der  $p$ -dimensionale  $n\sigma$ -Hyperellipsoid von den  $p$  Hauptachsen aufgespannt, wobei die Achsenabschnitte der  $n$ -fachen



**Abbildung 5.15.:** Hauptachsentransformation: Die beiden Merkmale  $\mathbf{e}_1$  und  $\mathbf{e}_2$  werden in ein neues Koordinatensystem abgebildet. Die neuen Merkmale  $\mathbf{h}_1$  und  $\mathbf{h}_2$  sind unkorreliert.

Standardabweichung entlang der Hauptachse entsprechen. Der  $n\sigma$ -Hyperellipsoid wird dabei durch die Gleichung

$$\left(\frac{x_1}{\sigma_{x1}}\right)^2 + \left(\frac{x_2}{\sigma_{x2}}\right)^2 + \dots + \left(\frac{x_p}{\sigma_{xp}}\right)^2 = n \quad (5.41)$$

definiert.

Jede  $p \times p$ -dimensionale, symmetrische Matrix  $\mathbf{A}$  kann nach dem Jordan'schen Zerlegungssatz wie folgt

$$\mathbf{A} = \mathbf{V} \mathbf{\Lambda} \mathbf{V}' = \sum_{j=1}^p \lambda_j \mathbf{v}_j \mathbf{v}_j' \quad (5.42)$$

zerlegt werden. Dabei ist

$$\mathbf{\Lambda} = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_p) \quad (5.43)$$

eine Diagonalmatrix aus den Eigenwerten  $\lambda_j$  und

$$\mathbf{V} = (\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_p) \quad (5.44)$$

eine Matrix aus den normierten Eigenvektoren  $\mathbf{v}_j$  von  $\mathbf{A}$ .

Die folgenden Punkte sind für die weitere Entwicklung der Kovarianzadaption elementar:

- Die Eigenvektoren einer Kovarianzmatrix stehen orthogonal zueinander und

definieren die Hauptachsen eines  $p$ -dimensionalen Hyperellipsoides.

- Die Eigenwerte entsprechen den Varianzen entlang der durch die normierten Eigenvektoren gegebenen Hauptachsen.
- Alle Kovarianzen nehmen nach der Hauptachsentransformation den Wert Null an.
- Über die Eigenwerte und normierten Eigenvektoren ist eine Kovarianzmatrix eindeutig bestimmt.


**Kovarianzadaption:** Mit den genannten Eigenschaften ist die Kovarianzadaption in beliebiger Raumrichtung möglich. Das Verfahren wird im Folgenden als *inverse Hauptachsentransformation* bezeichnet, da aus der Lage der Hauptachsen und den Varianzen die Kovarianzmatrix bestimmt wird. Die folgende Vorgehensweise definiert die Kovarianz eines Punktes im Raum  $\mathbb{R}^2$  in beliebiger Richtung, wie es zur Behandlung der Hypothesen 2 und 3 erforderlich ist:

1. Unter der Annahme unabhängiger Winkel und Entfernungsunsicherheit wird die Kovarianzmatrix  $R_{\text{Punkt}}$  für den gemäß der ausgewählten Hypothese zu betrachtenden Messpunkt nach [Formel 5.22](#) aufgestellt und der Flächeninhalt  $f$  der  $3\sigma$ -Ellipse berechnet. Die  $n\sigma$ -Ellipse umschließt nach [\[Abramowitz und Stegun 1974\]](#) die Fläche, in der sich  $(1 - \exp(-n^2/2)) \cdot 100\%$  der Messpunkte befinden. Die  $1/2/3$ - $\sigma$ -Ellipse umfasst somit 39, 3/86/98, 9% der Messwerte.<sup>11</sup> Die normierten Eigenvektoren und -werte der Kovarianzmatrix  $R_{\text{Punkt}}$  seien mit  $\mathbf{v}_1, \mathbf{v}_2, \lambda_1, \lambda_2$  gegeben. Für den Flächeninhalt der  $3\sigma$ -Ellipse gilt:

$$f = 9 \pi \sqrt{\lambda_1 \lambda_2}. \quad (5.45)$$

2. Es wird die Raumrichtung mit der größten Unsicherheit gewählt. Diese ist bei Hypothese 2 und 3 durch die Kante festgelegt, auf der sich der Punkt befindet, dessen Kovarianzmatrix modifiziert werden soll. Die Raumrichtung wird durch den normierten Vektor  $\mathbf{v}_1^{\text{neu}}$  festgelegt.
3. Man schätzt die Varianz  $\lambda_1^{\text{neu}}$  in dieser Richtung ab. Für Hypothese 2 ergibt sich die Abschätzung aus dem Abstand des linken vom rechten Konturpunkt. Für Hypothese 3 kann eine Abschätzung über typische Fahrzeugdimensionen erfolgen. Die  $3\sigma$ -Umgebung sollte hier ca. der halben Fahrzeuglänge entsprechen.
4. Die zu  $\mathbf{v}_1^{\text{neu}}$  orthogonale Raumrichtung wird mit  $\mathbf{v}_2^{\text{neu}} = (v_1^{\text{neu}}(2), -v_1^{\text{neu}}(1))'$  definiert, wobei  $v_1^{\text{neu}}(i)$  die  $i$ -te Komponente des Vektors  $\mathbf{v}_1^{\text{neu}}$  bezeichnet.

<sup>11</sup>Man beachte den Unterschied zur 1-dimensionalen Normalverteilung, bei der in den  $1/2/3 - \sigma$ -Bereich 68, 3/95, 5/99, 7 % der Messwerte fallen.



**Abbildung 5.16.:** Schematische Darstellung der Kovarianzadaption über die inverse Hauptachsentransformation: Die Unsicherheitsellipse wird durch Drehung und Stauchung bzw. Streckung in eine flächengleiche Unsicherheitsellipse überführt.

5. Die Varianz  $\lambda_2^{\text{neu}}$  der Raumrichtung  $\mathbf{v}_2^{\text{neu}}$  wird gerade so bestimmt, dass der Flächeninhalt der durch  $\lambda_1^{\text{neu}}$  und  $\lambda_2^{\text{neu}}$  definierten  $3\sigma$ -Ellipse  $f$  ergibt.

$$\lambda_2^{\text{neu}} = \frac{f^2}{81 \pi^2 \lambda_1^{\text{neu}}} \quad (5.46)$$

6. Die Kovarianzmatrix wird nach dem Jordan'schen Zerlegungssatz berechnet:


$$\mathbf{R}_{\text{Punkt}}^{\text{neu}} = \lambda_1^{\text{neu}} \mathbf{v}_1^{\text{neu}} \mathbf{v}_1^{\text{neu}'} + \lambda_2^{\text{neu}} \mathbf{v}_2^{\text{neu}} \mathbf{v}_2^{\text{neu}'} \quad (5.47)$$

Das Vorgehen ist in [Abbildung 5.16](#) veranschaulicht. Die Ausgangsellipse wird bei der Transformation in die neue Raumrichtung  $\mathbf{v}_1^{\text{neu}}$  gedreht. Gleichzeitig erfolgt eine Streckung in Richtung von  $\mathbf{v}_1^{\text{neu}}$ , die aufgrund der geforderten Flächengleichheit der Ellipsen eine Stauchung in der orthogonalen Richtung  $\mathbf{v}_2^{\text{neu}}$  bewirkt.


Die adaptierte Kovarianz ersetzt die dem betrachteten Punkt entsprechende Teilkovarianzmatrix in [Formel 5.24](#). Es sei darauf hingewiesen, dass durch die Adaption der Kovarianzmatrix  $\mathbf{R}_{\text{Punkt}}$  zwar der Flächeninhalt der  $3\sigma$ -Ellipse erhalten bleibt, die Gesamtvarianz (Spur der Kovarianzmatrix) wird sich im Allgemeinen jedoch ändern. Die Forderung nach Flächengleichheit ermöglicht die gezielte Untersuchung des Potenzials der Richtungsadaption der Kovarianzmatrix. Ergänzend kann eine Skalierung der Kovarianzmatrix erfolgen.

### Anwendung auf reale Messdaten

Für jeden eintreffenden Messvektor, wird vor der Assoziation geprüft, ob eine der drei obigen Hypothesen zutrifft und eine Kovarianzadaption erforderlich ist. In diesem Fall wird die entsprechende Teilkovarianzmatrix des Messvektors ersetzt. Die weiteren Filterschritte werden mit der modifizierten Kovarianzmatrix durchgeführt. Die theoretische Verbesserung bei der Assoziation verdeutlicht [Abbildung 5.17](#).



- (a) Gescheiterte Assoziation ohne Kovarianzadaption. Der rechte Konturpunkt – und damit der gesamte Messvektor – kann nicht zugeordnet werden.

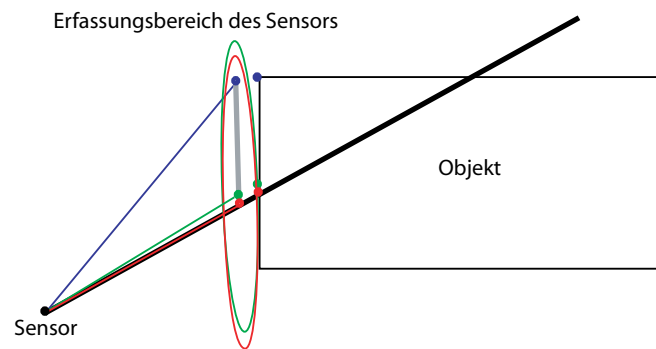


- (b) Korrekte Assoziation bei Anwendung der Kovarianzadaption über die inverse Hauptachsentransformation.

**Abbildung 5.17.:** Veranschaulichung der Kovarianzadaption an einem konkreten Beispiel: Die drei prädizierten Messpunkte auf der Objektkontur lassen sich erst durch die Anwendung der Kovarianzadaption über die inverse Hauptachsentransformation zuordnen.

Neben der flächenerhaltenden Kovarianzadaption im Falle einer der drei oben beschriebenen Hypothesen ist eine weitere Modifikation sinnvoll. Es zeigte sich in den bisherigen Auswertungen der realen Messdaten beim Austritt des Objektes aus dem Erfassungsbereich des Sensors ein Anstieg der Geschwindigkeit in  $x$ -Richtung. Dieses Verhalten lässt sich anhand von [Abbildung 5.18](#) erklären. Verlässt das Fahrzeug den Erfassungsbereich, so ist bei optischen Sensoren der Messpunkt exakt zu präzisieren. Liegt die wahre Objektposition - und damit der Messwert - vor bzw. hinter der Prädiktion, so resultiert daraus jedoch eine Abweichung entlang der detektierten Objektkante. Bei den aufgenommenen Messdaten erfolgt die Bewegung parallel zur  $y$ -Achse, sodass diese Abweichung zu einer Geschwindigkeit in  $x$ -Richtung führt.






**Abbildung 5.18.:** Veranschaulichung der Kovarianzadaption am Rand des Sensor-Erfassungsbereiches. Die Unsicherheit des rechten und dichtesten Punktes wird in Richtung der detektierten Kante erhöht.


Reduzieren lässt sich dieser Effekt, wenn für die Punkte am Rand des Sichtbereiches die Unsicherheit in Richtung der detektierten Kante deutlich erhöht wird, wie dies in [Abbildung 5.18](#) gezeigt ist.

Wird die Kovarianzadaption über die inverse Hauptachsentransformation ergänzend zur Mehrfach-Messwertprädiktion eingesetzt, so lassen sich deutliche Verbesserungen bei der Objektverfolgung erzielen. Es sei darauf hingewiesen, dass sich beide Verfahren ergänzen und daher der kombinierte Einsatz sinnvoll ist. Das Ergebnis der Anwendung auf die obige Messreihe zeigt [Abbildung 5.19](#) bis [Abbildung 5.21](#). Sie lassen sich wie folgt quantifizieren:

- Die Anzahl der nicht assoziierbaren Messwerte sinkt von 21 im ersten Ansatz auf drei. Die verbliebenen drei nicht assoziierbaren Messwerte stammen von der gekrümmten Front des verfolgten Fahrzeuges. Da das Objektmodell einen Quader beschreibt, kann in diesem Fall keine passende Prädiktion erfolgen.
- Über den gesamten Messzeitraum ist das Filter konsistent. Der durch die nicht assoziierten Messwerte verursachte Anstieg des mittleren normierten Innovationsquadrates zum Zeitraum 5,8-6,0s bleibt unterhalb der  $\chi^2$ -Schwelle.
- Die mittlere quadratische Standardabweichung der Position reduziert sich in  $x$ -Richtung um 82% und in  $y$ -Richtung um 43%. Der entsprechende Wert des Gierwinkels verringert sich um 20%. Dies ist das Resultat der zusätzlich assoziierten Messwerte und dem damit verbundenen Informationsgewinn.
- Die mittlere quadratische Standardabweichung der Geschwindigkeit verringert sich um 39% in  $x$ - und um 16% in  $y$ -Richtung. Durch die zusätzlichen Messwerte wird die beschleunigte Bewegung des verfolgten Fahrzeuges besser abgebildet.
- Während die mittlere quadratische Standardabweichung der Breite annähernd konstant bleibt verschlechtert sich der Wert der Länge um 70%. Dieses überraschende Ergebnis ist darauf zurückzuführen, dass durch die Kovarianzadaption der linke Konturpunkt zu Beginn der Messung entlang der Fahrzeugkontur




(a) Schätzung von Objektkoordinaten und Orientierung mit Standardabweichungen.



(b) Schätzung der Geschwindigkeitskomponenten mit Standardabweichungen.

**Abbildung 5.19.:** Geschätzte Position und Geschwindigkeit mit Standardabweichungen bei Anwendung der Kovarianz-Adaption und Mehrfach-Messwertprädiktion. Die mittlere quadratische Standardabweichung ist in der Legende mit  $e$  angegeben.




**Abbildung 5.20.:** Geschätzte Formparameter mit Standardabweichungen bei Anwendung der Kovarianz-Adaption und Mehrfach-Messwertprädiktion. Die mittlere quadratische Standardabweichung ist in der Legende mit  $e$  angegeben.

eine erhöhte Unsicherheit erhält. Während dies beim Entfernen vom Sensor zur Stabilisierung der Assoziation beiträgt verschlechtert es offensichtlich die Schätzung beim Annähern. Der mittlere Schätzfehler vergrößert sich für die Breite und Länge weniger stark um 7% und 9%. Als Referenzwerte wurden hier die maximale Breite und Länge des beobachteten Fahrzeuges angenommen.

- Der Geschwindigkeitsanstieg in  $x$ -Richtung beim Verlassen des Sensorsichtbereiches ist deutlich reduziert. Die Abweichung von Null ist kleiner als die Standardabweichung. Dieses Ergebnis ist auf die vergrößerte Unsicherheit der Messwerte am Rand des Sensorerfassungsbereiches in dieser Koordinatenrichtung zurückzuführen. Wie erwartet verfälschen diese Messwerte die Geschwindigkeitsschätzung weniger stark.

## 5.4. Zusammenfassung

Im Rahmen dieses Kapitels wurde zunächst das gewählte Objektmodell als Quader mit unabhängigen Geschwindigkeitskomponenten in der Ebene eingeführt. Anhand der Definition für vollständige und lokale Beobachtbarkeit wurde gezeigt, dass das gewählte Modell im Allgemeinen nicht vollständig, sondern nur lokal beobachtbar



**Abbildung 5.21.:** Normiertes Innovationsquadrat (NIS) und Durchschnitt über 5 Werte (ANIS) bei Anwendung der Mehrfach-Messwertprädiktion und Kovarianz-Adaption. Falls das normierte Innovationsquadrat unterhalb der eingezeichneten Schwelle liegt, werden Messdaten assoziiert. Liegt der Durchschnittswert unterhalb der Schwelle, ist das Filter konsistent.

ist. Hierbei spielt einerseits die Sensorkonfiguration, andererseits die Lage des Objektzustandsvektors im Merkmalsraum eine Rolle.

Im Hauptteil des Kapitels wurde anhand eines Laserscanners auf typische Assoziationsprobleme eingegangen, die sich aus wechselnden Aspektwinkeln bei lokaler Beobachtbarkeit ergeben. Deutliche Verbesserungen bei der Assoziation und damit der Zustandsschätzung lassen sich durch ein erweitertes Sensormodell erzielen. Zwei grundsätzlich unterschiedliche Phänomene kommen hierbei zum Tragen:

1. Ein sprunghafter Perspektivenwechsel erfolgt, wenn eine Objektkante plötzlich durch die Eigenverdeckung des Objektes nicht mehr sichtbar ist. Dieses Verhalten lässt sich über diskrete Hypothesen bei der Mehrfach-Messwertprädiktion berücksichtigen. Im Gegensatz zu aus der Literatur bekannten Multi-Modell-Filtern beziehen sich die Hypothesen nicht auf das Objektmodell, sondern die Messwertprädiktion.
2. Wird der Aspektwinkel auf eine Objektkante beispielsweise durch das Entfernen des Objektes kontinuierlich ungünstiger, so zeigen die Messwerte eine Messunsicherheit, die nicht allein aus dem Messprinzip des Sensors resultiert.

Vielmehr ist die Lage des Objektes im Merkmalsraum entscheidend. Mit der Kovarianz-Adaption über die inverse Hauptachsentransformation wurde ein Verfahren dargestellt, mit dem sich auch dieser Effekt berücksichtigen lässt. Im Gegensatz zu der aus der Literatur bekannten Adaption des Prozessrauschens erfolgt keine Skalierung des Messrauschens, sondern eine Transformation in eine bestimmte Raumrichtung.

Die Auswertung der gemeinsamen Anwendung von Mehrfach-Messwertprädiktion und Kovarianz-Adaption zeigt eine deutliche Stabilisierung der Objektverfolgung insbesondere während der Perspektivenwechsel. Diese lässt sich an einem reduzierten normierten Innovationsquadrat und damit einer verbesserten Filterkonsistenz ablesen. Es wurde gezeigt, dass sich bei gleicher räumlicher Unsicherheit (gleicher Fläche der  $3\sigma$ -Ellipse) erkennbare Vorteile bei der Zustandsschätzung ergeben.

Trotz der genannten Vorteile gibt bei der Anwendung des Verfahrens Grenzen. Die Assoziation ist nicht in jedem Fall erfolgreich, es verbleiben wenige gescheiterte Assoziationen. Die Analyse zeigt, dass hierbei üblicherweise mindestens ein Konturpunkt assoziierbar ist, aufgrund des gemeinsamen Suchbereiches über alle Punkte, die Assoziation aber dennoch scheitert. Weiterhin setzt die Mehrfach-Messwertprädiktion voraus, dass die vollständige Fahrzeugkontur bekannt ist, also bereits vor einem Perspektivenwechsel detektiert wurde. Dies ist häufig nicht der Fall. Diese Effekte lassen sich über eine alleinige Modifikation des Sensormodells nicht lösen, sondern erfordern zusätzlich eine Veränderung des Filters. Diese ist Thema des folgenden Kapitels.



## 6. Adaptive Form- und Dynamikschätzung

Das vorangegangene Kapitel schildert Verfahren, mit denen sich bei einem Perspektivenwechsel die Objektverfolgung stabilisieren lässt. In dem gewählten Beispiel sind die Position und die geometrischen Zustandsgrößen des Objektes bereits durch den ersten Messvektor beobachtbar, sodass alle Zustandsgrößen mit Ausnahme der Dynamikparameter initialisiert werden können. Die Dynamikparameter werden über das kinematische Modell anhand der Positionsveränderung geschätzt. Eine eingeschränkte Beobachtbarkeit durch die Objekteigenverdeckung und das Verlassen des Sichtbereiches lässt sich durch Mehrfach-Messwertprädiktionen und die Kovarianzadaption berücksichtigen.

Die vorgestellten Verfahren können jedoch nicht angewendet werden, wenn der Zustandsvektor eines Objektes zunächst *partiell* beobachtet und später ein *zusätzliches* Messmerkmal detektiert wird, das eine Abhängigkeit mit einer zusätzlichen Zustandsgröße aufweist. Da die neue Zustandsgröße unbekannt ist, ist eine Berücksichtigung bei der Prädiktion nicht möglich und die Assoziation scheitert. Dieses Problem kann bereits bei einem einzelnen Sensor – wie beispielsweise einem Laserscanner – auftreten. Es ist jedoch in der Regel unvermeidlich, wenn heterogene Sensordaten miteinander fusioniert werden sollen und jeder Sensor nur eine Teilmenge der Zustandsgrößen beobachtet.

In diesem Kapitel wird daher auf die bei der Objektverfolgung zu berücksichtigenden Besonderheiten eingegangen und eine Kalman-Filter-Fusionsarchitektur vorgestellt, mit der sich die variable Beobachtbarkeit von Zustandsgrößen im Filterprozess berücksichtigen lässt. Eine Bewertung der Fusion erfolgt anhand von realen Messdaten eines heterogenen Sensornetzwerkes bei einem Überholmanöver.

### 6.1. Problemanalyse

Das Beispiel aus [Abbildung 5.3](#) auf Seite 81 zeigt ein passierendes Fahrzeug, dessen geometrische Zustandsgrößen zu Beginn der Objektverfolgung vollständig beobachtet werden. Die Perspektive wechselt bei der weiteren Objektbewegung und reduziert die Messmerkmale bis zum Verlassen des Sensorsichtbereiches auf einen einzelnen Punkt. Kehrt man die Objektbewegung um, so lässt sich die Bewegung in mehrere Phasen unterteilen, die die speziellen Erfordernisse an eine robuste Objektverfolgung verdeutlicht:

1. Das Objekt tritt an der Sichtbereichsgrenze des Laserscanners in den Erfassungsbereich ein. Während die linke Objekthecke detektiert wird, ist der rechte Konturpunkt durch die Sichtbereichsgrenze festgelegt.
2. Sobald das Fahrzeug weiter in den Sichtbereich vorgedrungen ist, wird die Breite des Fahrzeuges sichtbar und die Länge ist aufgrund der Sichtbereichsgrenze beschränkt.
3. Bei weiterer Annäherung wird auch die Fahrzeuglänge beobachtbar, sodass die zweidimensionale Fahrzeugkontur geschätzt werden kann.
4. Anschließend treten die im vorangegangenen Kapitel diskutierten Eigenverdeckungen auf, die auf eine reduzierte Beobachtbarkeit des zuvor vollständig beobachteten Zustandsvektors zurückzuführen sind.

Es lässt sich demnach feststellen, dass Zustandsgrößen der geometrischen Ausdehnung des verfolgten Objektes sukzessive detektiert werden und die Anzahl der beobachtbaren Zustandsgrößen dadurch während der Objektverfolgung zunimmt. Es ist zudem darauf hinzuweisen, dass sich bestimmte Zustandsgrößen möglicherweise erst bei Beobachtung anderer Zustandsgrößen schätzen lassen. So ist bei dem gewählten Objektmodell der Gierwinkel nur dann beobachtbar, wenn die Objektlänge oder Breite gesehen wird.

Eine ähnliche Situation kann bei der Sensordatenfusion vorliegen. Kombiniert man beispielsweise die in [Abschnitt 4.1](#) auf Seite 61 beschriebene Sensorik (Laserscanner, Bildverarbeitung, Radar) zu einem heterogenen Netzwerk, so weist der Radarsensor die größte Reichweite auf, liefert aber keine Konturinformation, sondern lediglich die Position eines Reflexionszentrums. Die Bildverarbeitung liefert keine Längeninformation und der Laserscanner keine Höheninformation. Aufgrund der unterschiedlichen Reichweiten der Sensoren ist damit auch in diesem Fall der Objektzustand erst im Nahbereich vollständig beobachtbar.

Die Beobachtbarkeit schwankt bei der Fusion in stärkerem Maße als bei der Objektverfolgung mit einem Einzelsensor, da sie nicht nur von der (Eigen-)verdeckung und dem Aspektwinkel abhängt, sondern auch von der beteiligten Sensorhardware. Weil die zu behandelnden Phänomene jedoch grundsätzlich dieselben sind, wird im Folgenden nicht zwischen der Objektverfolgung mit einem Einzelsensor und der Sensordatenfusion unterschieden. Diese Phänomene werden im Folgenden näher diskutiert.

### 6.1.1. Variabler Informationsgehalt

Unterschiedliche Messvektoren können unterschiedliche Informationen über die Objektkontur liefern. Dies kann durch die Objektlage im Zustandsraum verursacht sein



oder aus der durch das Messprinzip eines Sensors gegebenen eingeschränkten Merkmalsdetektion resultieren. Formal gibt

$$\text{Rang}(\mathbf{M}_k) \triangleq \text{Rang} \begin{pmatrix} \mathbf{H}(k+1) \\ \mathbf{H}(k+1) \mathbf{F}(k) \\ \mathbf{H}(k+1) \mathbf{F}(k)^2 \\ \vdots \\ \mathbf{H}(k+1) \mathbf{F}(k)^{n_x-1} \end{pmatrix} \quad (6.1)$$

Aufschluss darüber, wieviele Größen des Zustandsvektors  $\hat{\mathbf{x}}(k|k)$  beobachtbar sind, wenn sich weder der Informationsgehalt der Messungen ( $\mathbf{H}$  konstant) noch das kinematische Modell ( $\mathbf{F}$  konstant) ändert. Die Matrix  $\mathbf{M}_k$  unterscheidet sich insofern von der im vorangegangenen Kapitel eingeführten Beobachtbarkeitsmatrix  $\mathbf{M}$ , als nur die linearisierte Messmatrix  $\mathbf{H}(k+1)$  und die aktuelle Systemtransferfunktion  $\mathbf{F}(k)$  des Filterschritts  $k$  betrachtet werden.

Falls  $\text{Rang}(\mathbf{M}_k) < \dim(\hat{\mathbf{x}}(k|k))$  gilt, ist der Objektzustand nur *partiell beobachtbar*. Anschaulich entspricht die partielle Beobachtung des Quader-Objektmodells beispielsweise der Beobachtung eines Rechtecks, einer Kante oder eines Punktes. Der variable Informationsgehalt führt zu Assoziationsproblemen, wenn zusätzliche Merkmale detektiert werden, die sich aus dem bisherigen Zustandsvektor nicht präzisieren lassen.

### 6.1.2. Unbekannter maximaler Informationsgehalt

Es ist a priori nicht bekannt, ob alle Zustandsgrößen des Objektmodells beobachtbar sein werden. Nähert sich beispielsweise der Versuchsträger einem anderen Fahrzeug zentral an, so ist dessen Länge zu keiner Zeit beobachtbar. Formal bedeutet dies:

$$\text{Rang} \begin{pmatrix} \mathbf{H}(1) \\ \mathbf{H}(2) \mathbf{F}(1) \\ \mathbf{H}(3) \mathbf{F}(2) \mathbf{F}(1) \\ \vdots \\ \mathbf{H}(k) \mathbf{F}(k-1) \cdots \mathbf{F}(1) \end{pmatrix} < n_x. \quad (6.2)$$

Aus der obigen Bedingung folgt, dass weder die vollständige noch die lokale Beobachtbarkeit des Systems zu einem beliebigen Zeitpunkt gegeben ist. Dies ist jedoch Voraussetzung für die Anwendung des Kalman-Filters, da die Gleichungen zur Schätzung andernfalls unterbestimmt sind.

### 6.1.3. Einfluss der Dimension des Zustandsvektors

Zunächst erscheint es ausreichend, nicht beobachtete Größen im Zustandsvektor auf Null zu setzen und die Schätzung in der bekannten Form durchzuführen. Auf diese

Weise lassen sich Rechtecke, Kanten und Punkte darstellen. Dieses Vorgehen ist jedoch aus folgenden Gründen nicht zielführend:

- Das Nullsetzen einer Zustandsgröße beeinflusst nicht die (linearisierte) Messfunktion. Da die Abhängigkeit zwischen Zustandsgröße und Messvektor bestehen bleibt, wird jede abhängige Zustandsgröße mitgeschätzt.
- Durch das Mitschätzen der nicht beobachtbaren Zustandsgrößen können diese auch unzulässige Werte annehmen (Beispielsweise könnte die Schätzung von Ausdehnungsparametern negative Werte liefern). Es wäre erforderlich, nach jedem Filterschritt Zwangsbedingungen anzuwenden, um den Zustandsvektor auf die zulässige Hyperebene im Zustandsraum zurückzubringen. Aufgrund der in der Regel erforderlichen Linearisierungen ergibt sich hieraus ein zusätzlicher Schätzfehler.
- Die Information des Messvektors wird gewichtet nach den Unsicherheiten auf den Zustandsvektor verteilt. Je größer die Dimension des Zustandsvektors, umso schlechter ist die Schätzung der einzelnen Zustandsgrößen.

#### 6.1.4. Konsequenzen für die Objektverfolgung

Aus dem Vorangegangenen lassen sich die folgenden Forderungen für die Objektverfolgung aufstellen:

- Die Dimension des Zustandsvektors sollte derart gewählt werden, dass alle beobachteten Zustandsgrößen erfasst, jedoch keine zusätzlichen geschätzt werden.
- Die Assoziation darf nur auf prädizierbaren Messmerkmalen erfolgen. Ein Messmerkmal ist prädizierbar, wenn alle Zustandsgrößen, von denen das Messmerkmal abhängt, beobachtet wurden.
- Eine Anpassung der Dimension des Zustandsvektors ist erforderlich, wenn neue Zustandsgrößen beobachtet werden.
- Im Filterschritt muss sichergestellt werden, dass nicht mehr Zustandsgrößen des Zustandsvektors aktualisiert werden, als durch den aktuellen Messvektor beobachtbar sind.

Im Folgenden wird eine Erweiterung der bekannten Filterarchitektur vorgestellt, die diese Anforderungen umsetzt.

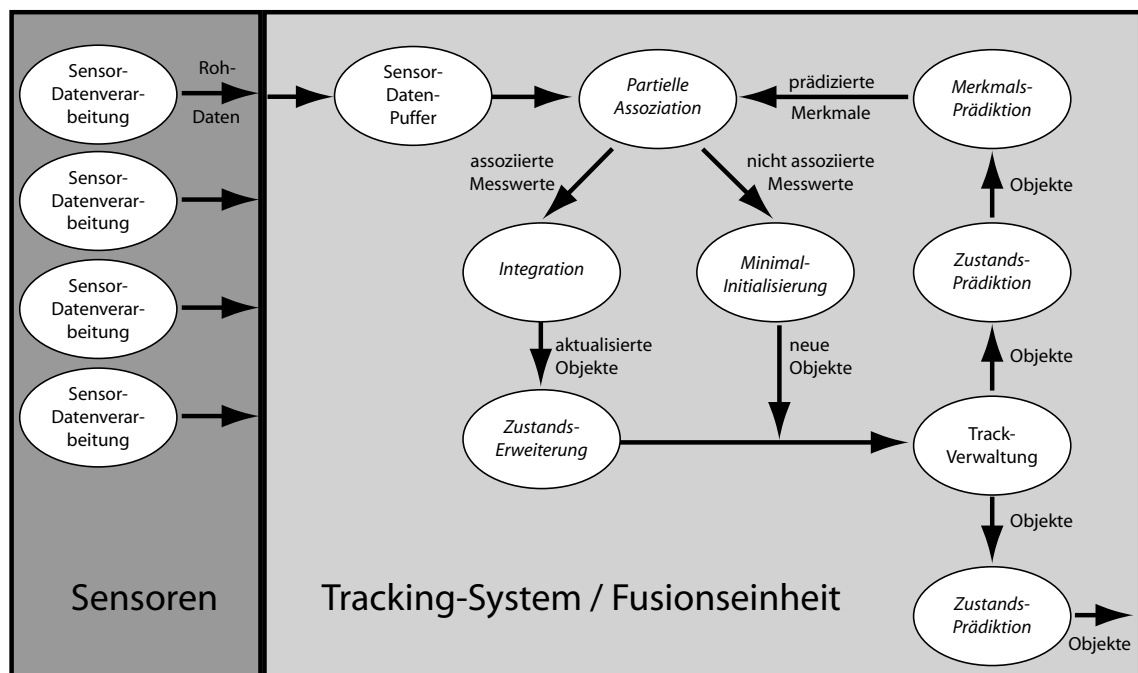


Abbildung 6.1.: Kalman-Filter-Fusionsarchitektur für variable Beobachtbarkeit. Kursiv dargestellt sind die gegenüber Kapitel 4 modifizierten Funktionsblöcke.

## 6.2. Fusionsarchitektur für variable Beobachtbarkeit

Die Berücksichtigung der im vorangegangenen Abschnitt genannten Forderungen innerhalb der Fusionsarchitektur führt zu diversen Modifikationen, die in Abbildung 6.1 schematisch dargestellt sind.

Die von den Modifikationen betroffenen Funktionselemente werden zunächst kurz vorgestellt und im Anschluss detailliert erläutert.

- **Minimal-Initialisierung:** Die Forderung nach einem minimalen Zustandsvektor, der nur die beobachteten Zustandsgrößen enthält, führt zu einer neuen Initialisierung, die ausschließlich beobachtbare Zustandsgrößen berücksichtigt.
- **Zustands-Prädiktion:** Die Prädiktion variiert für die unterschiedlich dimensionalen Zustandsvektoren.
- **Merkmals-Prädiktion:** Aus einem Objekt-Zustandsvektor lässt sich nur dann ein vollständiger Messvektor prädiere, wenn sämtliche Zustandsgrößen, die zu seiner Bestimmung erforderlich sind, bereits beobachtet wurden. Ist dies nicht der Fall, so kann nur ein auf die beobachtbaren Merkmale reduzierter Messvektor prädiert werden.
- **Partielle Assoziation:** Falls der Messvektor nicht vollständig prädiert werden kann, darf die Assoziation auch lediglich die prädierten Merkmale berücksichtigen. Auch die Umkehrung gilt: Wenn ein Messvektor weniger Merkmale

enthält, als prädiziert wurden, so ist die Assoziation auf die gemeinsamen Merkmale von Prädiktion und Messvektor zu beschränken.

- **Integration:** Da die einzelnen Messvektoren unterschiedlicher Sensoren unterschiedliche Informationen liefern, muss der Filterschritt derart modifiziert werden, dass lediglich die beobachtbaren Zustandsgrößen geschätzt werden.
- **Zustandserweiterung:** Liefert ein Messvektor eine neue Zustandsgröße des Zustandsvektors, so ist dessen Dimension um diese Größe zu erweitern. Die nächsten Iterationen des Filters erfolgen mit dem erweiterten Zustandsvektor.

Die Funktionsweise der Fusionsarchitektur für variable Beobachtbarkeit wird in drei Schritten erläutert. Zunächst wird die Behandlung eines auf die beobachtbaren Zustandsgrößen reduzierten Zustandsvektors diskutiert. Es schließt sich die partielle Beobachtbarkeit an, bevor auf die Zustandserweiterung eingegangen wird.

### 6.2.1. Funktionsweise des Filters für reduzierte Zustandsvektoren

Wie bereits dargestellt, variiert der Informationsgehalt einer Messung in Abhängigkeit vom Sensor-Messprinzip, dem Aspektwinkel und der (Eigen-)verdeckung eines Objektes. Es kann somit erst bei Vorliegen eines konkreten, nicht assoziierten Messvektors  $\mathbf{z}(k+1)$  entschieden werden, welche Zustandsgrößen des initialen Zustandsvektors  $\hat{\mathbf{x}}(0|0)$  sich bestimmen lassen.

Es scheint wenig zielführend, beliebige Teilmengen von Zustandsgrößen bei der Initialisierung zuzulassen, da die Position der Größen im Zustandsvektor variieren würde und diese bei der Zustands- und Merkmalsprädiktion zu berücksichtigen wäre. Mit der Position der Zustandsgrößen würde sich die Position der Varianzen und Kovarianzen verschieben, die Systemmatrix und die linearisierte Messmatrix wären für jede Kombination gezielt aufzustellen. Durch einen alternativen Ansatz lässt sich das Verfahren deutlich vereinfachen.

Es wird die Funktionsweise der Kalman-Filter-Fusionsarchitektur für variable Beobachtbarkeit für einen reduzierten Zustandsvektor erläutert, ohne dass eine Zustandserweiterung erforderlich ist. Dies ist beispielsweise der Fall, wenn ein Objekt ausschließlich vom Radar erfasst wird und daher keine Konturinformation zur Verfügung steht.

#### Minimal-Initialisierung

Die maximale Anzahl von Zustandsgrößen des Zustandsvektors ist bekannt. Hierbei ist die Position der Zustandsgrößen durch das Objektmodell festgelegt. Um ihre Position beizubehalten und um zu kennzeichnen, dass bestimmte Zustandsgrößen nicht initialisiert wurden, wird der binäre *Initialisierungsvektor*  $\mathbf{i}(k)$  eingeführt. Der Initialisierungsvektor hat die Dimension  $n_x$  des Objekt-Zustandsvektors und nimmt

an den Stellen, an denen eine Zustandsgröße initialisiert wurde, den Wert Eins an, sonst ist der Wert Null. Er kennzeichnet die initialisierten Zustandsgrößen bis zum Zeitpunkt  $k$ , dies bedeutet, dass im Verlauf der Objektverfolgung zusätzliche Zustandsgrößen initialisiert werden können.

Drei Fälle sind bei der Belegung des Initialisierungsvektors  $\mathbf{i}(0)$  über den Messvektor  $\mathbf{z}(0)$  zu unterscheiden:

1. Es besteht ein direkter funktionaler Zusammenhang zwischen einem Messmerkmal und der  $j$ -ten Zustandsgröße. Die initiale Zustandsgröße  $x_j$  wird über die Funktion bestimmt und die  $j$ -te Komponente  $i_j$  des Initialisierungsvektors  $\mathbf{i}(0)$  wird mit dem Wert Eins belegt.
2. Die  $j$ -te Zustandsgröße kann nicht direkt aus einem Messmerkmal berechnet werden, lässt sich aber über das Dynamikmodell aus einer Folge von Messvektoren schätzen. Dies gilt beispielsweise für die Geschwindigkeit, die sich aus der Positionsveränderung über der Zeit schätzen lässt. Die initiale Zustandsgröße  $x_j$  wird mit einem empirischen Wert belegt und die  $j$ -te Komponente  $i_j$  des Initialisierungsvektors  $\mathbf{i}(0)$  auf den Wert Eins gesetzt.
3. Falls kein direkter funktionaler Zusammenhang zwischen Messvektor und Zustandsgröße  $x_j$  besteht und auch über das Dynamikmodell die Größe nicht geschätzt werden kann, erhält die  $j$ -te Komponente  $i_j$  des Initialisierungsvektors  $\mathbf{i}(0)$  den Wert Null. Dies ist etwa der Fall, wenn die Länge eines Objektes aufgrund des Aspektwinkels nicht beobachtbar ist.

Unabhängig von der Anzahl der initialisierten Zustandsgrößen ist deren Position im Zustandsvektor durch dieses Verfahren festgelegt. Hierdurch werden die Zustands- und Merkmalsprädiktion vereinfacht. Ein *vollständiger* Zustandsvektor liegt vor, wenn die folgende Bedingung erfüllt ist:

$$\sum_{j=1}^{n_x} i_j = \dim(\hat{\mathbf{x}}(k|k)) = n_x, \quad (6.3)$$

andernfalls wird der Zustandsvektor im Folgenden als *reduziert* bezeichnet. Die initiale Zustandskovarianzmatrix  $\mathbf{P}(0|0)$  muss für alle Zustandsgrößen, die im Initialisierungsvektor als initialisiert gekennzeichnet sind, mit entsprechenden Varianzen und Kovarianzen belegt werden (vgl. [Kapitel 3](#)). Alle Varianzen und Kovarianzen von nicht initialisierten Zustandsgrößen sind mit dem Wert Null zu belegen.

### Zustandsprädiktion

Da nicht initialisierte Zustandsgrößen auf den Wert Null gesetzt werden und alle Zustandsgrößen eine feste Position haben, kann auch für die reduzierten Zustandsvektoren dieselbe Systemfunktion (und die in [Formel 5.3](#) auf Seite 73 definierte

Transfermatrix  $\mathbf{F}$ ) verwendet werden. Es gilt somit für alle reduzierten und vollständigen Objekt-Zustandsvektoren:

$$\hat{\mathbf{x}}(k+1|k) = \mathbf{F}(k) \hat{\mathbf{x}}(k|k). \quad (6.4)$$

Bei der Prädiktion der Zustandskovarianz ist zu berücksichtigen, dass eine Rauschverstärkung  $\mathbf{Q}(k)$  nur auf bereits initialisierten Zustandsgrößen anzuwenden ist. Dies lässt sich über den Initialisierungsvektor  $\mathbf{i}(k)$  durch folgende Gleichung erreichen:

$$\mathbf{P}(k+1|k) = \mathbf{F}(k) \mathbf{P}(k|k) \mathbf{F}(k)' + \text{diag}(\mathbf{i}(k)) \mathbf{Q}(k) \text{diag}(\mathbf{i}(k)). \quad (6.5)$$

Durch die Matrizenmultiplikation mit  $\text{diag}(\mathbf{i}(k))$  ist sichergestellt, dass sämtliche Rauschkomponenten, die nicht beobachtete Zustandsgrößen betreffen, den Wert Null annehmen, während die anderen Komponenten der Matrix  $\mathbf{Q}(k)$  unverändert bleiben.

### Merkmalsprädiktion

Mit der vorgestellten Sensorik (Radar, Laser, Bildverarbeitung) lässt sich aus den Messvektoren in jedem Fall die Position und Geschwindigkeit von Objekten schätzen. Die Messvektoren liefern jedoch einen unterschiedlichen Informationsgehalt über die geometrische Ausdehnung des verfolgten Objektes, sodass ein Punkt-, Kanten-, Rechteck- oder Quadermodell erforderlich ist. Das konkrete Modell ist aus den Werten des Initialisierungsvektors  $\mathbf{i}(k)$  abzulesen.

Solange keine Modellerweiterung nötig ist (siehe Beschreibung unten), lässt sich der Messvektor auch aus einem reduzierten Zustandsvektor vollständig bestimmen, weil bei der Initialisierung gerade die Zustandsgrößen initialisiert wurden, die eine Abhängigkeit mit dem Messvektor aufweisen. Da alle Merkmale des Messvektors prädiziert werden können, weist die Merkmalsprädiktion keine Unterschiede zu der bislang beschriebenen Messwertprädiktion auf. Da die nicht initialisierten Merkmale den Wert Null haben, ist durch den Zustandsvektor das Punkt-, Kanten-, Rechteck oder Quadermodell beschrieben, ohne dass eine Fallunterscheidung notwendig wäre. Für den prädizierten Messvektor eines reduzierten Zustandsvektors gilt daher:

$$\hat{\mathbf{z}}(k+1|k) = \mathbf{h}(k+1, \mathbf{x}(k+1|k)). \quad (6.6)$$

Bei der Bestimmung der linearisierten Messmatrix  $\mathbf{H}(k)$  werden die nicht beobachteten Zustandsgrößen als Konstanten betrachtet. Daher nehmen die partiellen Ableitungen den Wert Null an. Bezeichnet man die linearisierte Messmatrix für den vollständigen Zustandsvektor mit  $\mathbf{H}_{\text{vollständig}}(k+1)$ , so ergibt sich die linearisierte Messmatrix für reduzierte Zustandsvektoren über den Initialisierungsvektor:

$$\mathbf{H}_{\text{vollständig}}(k+1) = [\nabla_{\mathbf{x}} \mathbf{h}(k+1, \mathbf{x})']|_{\mathbf{x}=\hat{\mathbf{x}}(k+1|k)}, \quad (6.7)$$

$$\mathbf{H}(k+1) = \mathbf{H}_{\text{vollständig}}(k+1) \text{diag}(\mathbf{i}(k)). \quad (6.8)$$

Die Matrizenmultiplikation mit  $\text{diag}(\mathbf{i}(k))$  stellt hier sicher, dass alle Spalten der linearisierten Messmatrix den Wert Null annehmen, die eine partielle Ableitung einer nicht beobachteten Zustandsgröße enthalten, während alle anderen Elemente der Matrix unverändert bleiben.

Da alle Merkmale des Messvektors prädiziert werden können, ist keine Modifikation der Assoziation erforderlich.

### Integration

Der Integrationsschritt des Filters wird mit den oben bestimmten Matrizen durchgeführt. Die Innovation ergibt sich gemäß [Formel 3.17](#) auf Seite 29, für die Innovationskovarianz gilt:

$$\mathbf{S}(k+1) = \mathbf{H}(k+1) \mathbf{P}(k+1|k) \mathbf{H}(k+1)' + \mathbf{R}(k+1). \quad (6.9)$$

Es sei an dieser Stelle darauf hingewiesen, dass der erste Summand für reduzierte Zustandsvektoren einen reduzierten Rang haben kann, da die Matrix  $\mathbf{P}(k+1)$  bereits einen reduzierten Rang aufweist<sup>1</sup>. Durch Addition des Messrauschens  $\mathbf{R}(k+1)$  bleibt die Matrix  $\mathbf{S}(k+1)$  jedoch invertierbar. Dies ist zur Berechnung der Filtermatrix

$$\mathbf{W}(k+1) = \mathbf{P}(k+1|k) \mathbf{H}(k+1)' \mathbf{S}(k+1)^{-1} \quad (6.10)$$

erforderlich. Die auf Null gesetzten Elemente in  $\mathbf{P}(k+1|k)$  und  $\mathbf{H}(k+1)$  führen dazu, dass die Zeilen der Filtermatrix  $\mathbf{W}(k+1)$  für alle nicht beobachteten Zustandsgrößen ebenfalls Null sind. Auch im Filterschritt

$$\hat{\mathbf{x}}(k+1|k+1) = \hat{\mathbf{x}}(k+1|k) + \mathbf{W}(k+1) \boldsymbol{\nu}(k+1), \quad (6.11)$$

$$\mathbf{P}(k+1|k+1) = \mathbf{P}(k+1|k) - \mathbf{W}(k+1) \mathbf{S}(k+1) \mathbf{W}(k+1)' \quad (6.12)$$

werden nicht beobachtete Merkmale daher nicht mitgeschätzt.

### 6.2.2. Partielle Beobachtung

Der [Unterabschnitt 6.2.1](#) beschreibt die Modifikationen am Tracking-System, falls über den Messvektor bei der Initialisierung nicht alle Zustandsgrößen des Zustandsvektors festgelegt sind. Es wird davon ausgegangen, dass die Merkmale, die bei der Initialisierung beobachtbar waren, auch bei der weiteren Objektverfolgung beobachtbar sind.

Eine andere Situation liegt vor, falls bei der Initialisierung eine Anzahl von Zustandsgrößen initialisiert wird und bei der weiteren Objektverfolgung Messvektoren weniger Informationen beinhalten. Dies kann durch Verdeckungen hervorgerufen sein oder

<sup>1</sup> Es gilt:  $\text{Rang}(\mathbf{A} \ \mathbf{B}) \leq \min(\text{Rang}(\mathbf{A}), \text{Rang}(\mathbf{B}))$ .

bei der Fusion von Sensordaten heterogener Sensoren auftreten, falls durch einen Sensor weniger Zustandsgrößen beobachtbar sind als durch einen anderen.

Zwei Fälle sind hierbei zu unterscheiden:

1. Die Dimension von Prädiktion und Messwert stimmt überein, aus dem Messvektor lassen sich aber nicht alle beobachteten Zustandsgrößen schätzen. Dies ist beispielsweise der Fall, wenn ein Objekt nur von einer Seite beobachtet wird und somit nur die Länge oder Breite sichtbar ist, während die andere Größe verdeckt ist.
2. Es werden mehr Merkmale prädiziert, als im Messvektor vorhanden sind. Dies ist beispielsweise der Fall, wenn anhand des Zustandsvektors Länge und Breite prädiziert werden, der Messvektor aber lediglich eine der beiden Größen beinhaltet.

### Partielle Assoziation bei partieller Beobachtbarkeit

Falls die Dimension von Prädiktion und Messwert übereinstimmen (Fall 1), ist keine Modifikation der Assoziation erforderlich. Werden jedoch mehr Merkmale prädiziert, als der Messvektor beinhaltet (Fall 2), sodass die Dimension der Prädiktion größer ist als die des Messwertes, muss die Assoziation angepasst werden. Formal bedeutet dies:

$$\dim(\mathbf{z}(k+1)) < \dim(\hat{\mathbf{z}}(k+1|k)). \quad (6.13)$$

Die Assoziation wird in diesem Fall auf der Basis der gemeinsamen Merkmale von Prädiktion und Messwert durchgeführt. Die Messwertprädiktion  $\hat{\mathbf{z}}(k+1|k)$  wird daher auf diejenigen Merkmale reduziert, die in  $\mathbf{z}(k+1)$  vorkommen. Die einzelnen Komponenten der Messwertprädiktion seien mit  $\hat{z}_j(k+1|k)$ , die des Messvektors mit  $z_j(k+1)$  bezeichnet. Es gilt daher

$$\hat{\mathbf{z}}_{\text{reduziert}}(k+1|k) = [\hat{z}_{i_1}(k+1|k); \hat{z}_{i_2}(k+1|k); \dots; \hat{z}_{i_{n_z}}(k+1|k)], \quad (6.14)$$

wobei  $\hat{z}_{i_j}(k+1|k)$  und  $z_j(k+1)$  dasselbe Messmerkmal beschreiben. Da die Prädiktion reduziert wird, muss auch die korrespondierende linearisierte Messmatrix  $\mathbf{H}(k+1)$  entsprechend reduziert werden. Bezeichnet man die  $i$ -te Zeile dieser Matrix mit  $\mathbf{h}_i(k+1)$ , lässt sich die reduzierte linearisierte Messmatrix  $\mathbf{H}_{\text{reduziert}}(k+1)$  folgendermaßen berechnen:

$$\mathbf{H}_{\text{reduziert}}(k+1) = [\mathbf{h}_{i_1}(k+1); \mathbf{h}_{i_2}(k+1); \dots; \mathbf{h}_{i_{n_z}}(k+1)]. \quad (6.15)$$

Die Innovation ergibt sich in diesem Fall zu

$$\boldsymbol{\nu}(k+1) \triangleq \mathbf{z}(k+1) - \hat{\mathbf{z}}_{\text{reduziert}}(k+1|k), \quad (6.16)$$

ihre Kovarianz zu

$$\mathbf{S}(k+1) = \mathbf{H}_{\text{reduziert}}(k+1) \mathbf{P}(k+1|k) \mathbf{H}_{\text{reduziert}}(k+1)' + \mathbf{R}(k+1). \quad (6.17)$$




Im Folgenden wird auf den Index reduziert verzichtet und mit  $\mathbf{H}(k+1)$  die zur Prädiktion  $\hat{\mathbf{z}}(k+1|k)$  passende Matrix bezeichnet.

### Integration

Die Schätzung aller beobachteten Zustandsgrößen des Zustandsvektors ist möglich, wenn der Informationsgehalt des Messvektors ausreicht. In diesem Fall gilt für die Beobachtbarkeitsmatrix  $\mathbf{M}_k$  für die Filteriteration  $k$  nach [Formel 6.1](#) auf Seite 113 die Beziehung:

$$\text{Rang}(\mathbf{M}_k) = \sum_{j=1}^{n_x} i_j. \quad (6.18)$$

Ist der Rang kleiner als die Anzahl der initialisierten Zustandsgrößen, würden im Integrationsschritt des Filters mehr Zustandsgrößen geschätzt, als durch den Messvektor tatsächlich festgelegt sind. Das Gleichungssystem ist in diesem Fall unterbestimmt. Um den Einfluss des Messvektors auf bestimmte Zustandsgrößen auszuschließen, können, wie bei der Behandlung reduzierter Zustandsvektoren bereits beschrieben, zusätzliche Spalten der linearisierten Messmatrix  $\mathbf{H}(k+1)$  auf den Wert Null gesetzt werden. Die entsprechenden Zustandsgrößen werden für den Filterschritt als Konstanten behandelt und nicht mitgeschätzt (vgl. [Abbildung 6.2](#)).



**Abbildung 6.2.:** Beispiel einer Laserscanner-Messung. Der linke, dichteste und rechte Konturpunkt sind rot, grün und blau markiert. Da eine Abhängigkeit der Prädiktion von der Objektlänge besteht, würde die Länge im Integrationsschritt des Filters geschätzt, ohne dass der Messvektor Informationen über die Länge beinhaltet. Dies kann durch Nullsetzen der korrespondierenden Elemente der linearisierten Messmatrix verhindert werden.

Das Vorgehen ist vorteilhaft, um die Positionsschätzung zu verbessern. Falls die Länge eines Objektes initialisiert wurde, später aber nicht mehr beobachtet wird, bewirkt die Modifikation der linearisierten Messmatrix, dass die Information des Messvektors ausschließlich zur Schätzung der Position verwendet wird.

Um den Einfluss des Messvektors auf bestimmte Zustandsgrößen zu begrenzen, wird der binäre *Schätzgrößenvektor*  $\mathbf{m}(k+1)$  eingeführt. Er hat die Dimension des Zustandsvektors  $n_x$  und nimmt an den Stellen, wo eine Zustandsgröße durch den aktuellen Messvektor geschätzt werden soll, den Wert Eins an, sonst den Wert Null. Unter Berücksichtigung des Schätzgrößenvektors ergibt sich die neue linearisierte

Messmatrix  $\mathbf{H}_m(k+1)$  und die neue Innovationskovarianz zu:

$$\mathbf{H}_m(k+1) = \mathbf{H}(k+1) \text{diag}(\mathbf{m}(k+1)) \quad (6.19)$$

$$\mathbf{S}_m(k+1) = \mathbf{H}_m(k+1) \mathbf{P}(k+1|k) \mathbf{H}_m(k+1)' + \mathbf{R}(k+1). \quad (6.20)$$

Im Integrationsschritt des Kalman-Filters sind die modifizierten Matrizen zu berücksichtigen, sodass für die Filtermatrix  $\mathbf{W}(k+1)$  gilt:

$$\mathbf{W}(k+1) = \mathbf{P}(k+1|k) \mathbf{H}_m(k+1)' \mathbf{S}_m(k+1)^{-1}. \quad (6.21)$$

Es sei darauf hingewiesen, dass lediglich der direkte Einfluss des Messvektors auf den Zustandsvektor durch das Nullsetzen der linearisierten Messmatrix ausgeschlossen wird. Ist ein Merkmal mit einem zu schätzenden anderen korreliert, so kann sich der Wert des Merkmals dennoch im Integrationsschritt ändern.

### 6.2.3. Erweiterung des Zustandsvektors um neue Merkmale

Das Gegenteil der partiellen Beobachtung liegt vor, wenn ein Messvektor mehr Informationen beinhaltet, als aus dem Zustandsvektor prädictiert werden können. Dies ist beispielsweise der Fall, wenn ein Objekt zunächst nur von einer Seite beobachtet wird und daher über das Kantenmodell geschätzt wird, bevor eine weitere Objektseite detektiert wird. Der Initialisierungsvektor kennzeichnet die Länge in diesem Fall als nicht initialisiert, sodass sie im Integrationsschritt nicht aktualisiert wird. Ändert sich der Aspektwinkel auf das Objekt, sodass die Länge sichtbar wird, kann diese aufgrund der fehlenden Information im Zustandsvektor nicht prädictiert werden. Zwei Modifikationen am Filter sind in diesem Fall erforderlich: Einerseits muss die Assoziation auf die prädictierten Merkmale reduziert, andererseits muss der Zustandsvektor um neue Merkmale erweitert werden. Beide Schritte werden nun vorgestellt.


#### Partielle Assoziation bei erweiterter Beobachtbarkeit

Falls der Messvektor  $\mathbf{z}(k+1)$  mehr Merkmale beinhaltet als die entsprechende Prädiktion  $\hat{\mathbf{z}}(k+1|k)$ , so ist der Messvektor auf die assoziierbaren Merkmale zu reduzieren. Es gilt die Beziehung

$$\dim(\mathbf{z}(k+1)) > \dim(\hat{\mathbf{z}}(k+1|k)). \quad (6.22)$$

Die einzelnen Komponenten der Messwertprädiktion seien wie oben mit  $\hat{z}_j(k+1|k)$ , die des Messvektors mit  $z_j(k+1)$  bezeichnet. Es gilt daher:

$$\mathbf{z}_{\text{reduziert}}(k+1) = [z_{i_1}(k+1); z_{i_2}(k+1); \dots; z_{i_{n_{\hat{\mathbf{z}}}}}(k+1)], \quad (6.23)$$



**Abbildung 6.3.:** Weil der Bezugspunkt  $(x, y)$  des gewählten Objektmodells der Mittelpunkt des Grundflächenrechtecks ist, erfährt dieser bei der Erweiterung von Kantenmodell auf Rechteckmodell eine Translation um  $(\Delta x, \Delta y)$ . Dieselbe Situation liegt bei der Erweiterung von Punkt- auf Kantenmodell vor.

wobei  $z_{ij}(k+1)$  und  $\hat{z}_j(k+1|k)$  dasselbe Merkmal beschreiben und  $n_z$  die Dimension der Prädiktion ist. Weil die Prädiktion nicht verändert wird, ist keine Modifikation der linearisierten Messmatrix  $\mathbf{H}(k+1)$  erforderlich, da aber die Dimension des Messvektors verändert wird, sind die entsprechenden Varianzen und Kovarianzen aus der Kovarianzmatrix des Messrauschens  $\mathbf{R}(k+1)$  zu entfernen.

### Zustandserweiterung

Die Bestimmung der neuen Zustandsgrößen des Objekt-Zustandsvektors kann bereits nach erfolgreicher Assoziation durchgeführt werden. Hierzu werden drei Erweiterungsparameter festgelegt:

1. Der  $n_x$ -dimensionale *Erweiterungsvektor*  $\hat{\mathbf{x}}_{\text{erw}}(k+1)$  definiert ein oder mehrere neue Zustandsgrößen. Der Erweiterungsvektor wird im Integrationsschritt des Filters addiert. Da zuvor nicht initialisierte Zustandsgrößen den Wert Null haben, wird im Erweiterungsvektor der Initialwert der neuen Zustandsgröße angegeben. Zu beachten ist, dass die Initialisierung von Breite oder Länge eine Translation des Objekt-Bezugspunktes bewirkt, wie dies in [Abbildung 6.3](#) exemplarisch dargestellt ist. Diese Translation ist in den ersten beiden Komponenten des Erweiterungsvektors anzugeben.
2. In der  $n_x \times n_x$ -dimensionalen *Erweiterungsmatrix*  $\mathbf{P}_{\text{erw}}(k+1)$  werden die Initialwerte für die Varianz und Kovarianzen der neuen Zustandsgröße definiert.

Zumeist wird lediglich die Varianz des Merkmals  $i$  zu definieren sein, sodass die Matrix  $\mathbf{P}_{\text{erw}}(k+1)$  nur an der Stelle  $(i, i)$  die neue Varianz enthält, während alle anderen Positionen den Wert Null haben. Auch wenn eine Translation des Objekt-Bezugspunktes im vorangegangenen Schritt erforderlich sein sollte, ist keine Transformation der Kovarianzmatrix erforderlich, da diese translationsinvariant ist.

3. Der  $n_x$ -dimensionale Initialisierungsvektor  $\mathbf{i}_{\text{erw}}(k+1)$  definiert, welche Merkmale im Integrationsschritt des Filters neu initialisiert und in folgenden Filteriterationen mitgeschätzt werden. Wird Merkmal  $i$  neu initialisiert, so nimmt die  $i$ -te Komponente des Vektors  $\mathbf{i}_{\text{erw}}(k+1)$  den Wert Eins an, alle anderen Positionen haben den Wert Null.

Soll keine Zustandserweiterung erfolgen, werden die  $\hat{\mathbf{x}}_{\text{erw}}(k+1)$ ,  $\mathbf{P}_{\text{erw}}(k+1)$  und  $\mathbf{i}_{\text{erw}}(k+1)$  mit dem neutralen Element bezüglich Addition in entsprechender Dimension belegt (Nullvektor bzw. Nullmatrix).

Die linearisierte Messmatrix  $\mathbf{H}(k+1)$  und damit die Innovationskovarianz  $\mathbf{S}(k+1)$  beziehen sich auf den prädizierten Zustandsvektor. Würde der Zustandsvektor vor der Integration erweitert, so wären diese Größen neu zu berechnen, daher erfolgt die Zustandserweiterung erst während der Integration über die folgenden Gleichungen:

$$\hat{\mathbf{x}}(k+1|k+1) = \hat{\mathbf{x}}(k+1|k) + \mathbf{W}(k+1) \boldsymbol{\nu}(k+1) + \hat{\mathbf{x}}_{\text{erw}}(k+1), \quad (6.24)$$

$$\begin{aligned} \mathbf{P}(k+1|k+1) &= \mathbf{P}(k+1|k) - \mathbf{W}(k+1) \mathbf{S}(k+1) \mathbf{W}(k+1)', \\ &\quad + \mathbf{P}_{\text{erw}}(k+1) \end{aligned} \quad (6.25)$$

$$\mathbf{i}(k+1) = \mathbf{i}(k) + \mathbf{i}_{\text{erw}}(k+1). \quad (6.26)$$

#### 6.2.4. Zusammenfassung der Filtergleichungen

Abschließend werden die Filtergleichungen der modifizierten Funktionsblöcke der Kalman-Filter-Fusionsarchitektur für variable Beobachtbarkeit nach [Abbildung 6.1](#) zusammengefasst.

##### Initialisierung

Initialisiert wird der Zustandsvektor  $\hat{\mathbf{x}}(0|0)$  mit Kovarianz  $\mathbf{P}(0|0)$ . Der binäre Initialisierungsvektor  $\mathbf{i}(0)$  gibt an, welche Zustandsgrößen initialisiert wurden und in weiteren Filteriterationen geschätzt werden. Sind alle Elemente des Initialisierungsvektors Eins, so ist der Zustandsvektor *vollständig*, andernfalls wird er als *reduziert* bezeichnet.

##### Zustandsprädiktion

Die Zustandsprädiktion erfolgt wie beim erweiterten Kalman-Filter. Bei der Bestimmung der prädizierten Zustandskovarianz wird der Initialisierungsvektor  $\mathbf{i}(k)$

berücksichtigt:

$$\hat{\mathbf{x}}(k+1|k) = \mathbf{F}(k) \hat{\mathbf{x}}(k|k), \quad (6.27)$$

$$\mathbf{P}(k+1|k) = \mathbf{F}(k) \mathbf{P}(k|k) \mathbf{F}(k)' + \text{diag}(\mathbf{i}(k)) \mathbf{Q}(k) \text{diag}(\mathbf{i}(k)). \quad (6.28)$$

### Merkmalsprädiktion

Die Messwertprädiktion wird durch eine Merkmalsprädiktion ersetzt, bei der alle aus dem Zustandsvektor ermittelbaren Merkmale des Messvektors prädiziert werden. Die Dimension des prädizierten Merkmalsvektors  $\hat{\mathbf{z}}(k+1|k)$  kann daher kleiner sein als die des Messvektors. Bei der Bestimmung der linearisierten Messmatrix wird der Initialisierungsvektor berücksichtigt:

$$\hat{\mathbf{z}}(k+1|k) = \mathbf{h}(k, \hat{\mathbf{x}}(k+1|k)), \quad (6.29)$$

$$\mathbf{H}(k+1) = [\nabla_{\mathbf{x}} \mathbf{h}(k+1, \mathbf{x})']_{\mathbf{x}=\hat{\mathbf{x}}(k+1|k)} \text{diag}(\mathbf{i}(k)). \quad (6.30)$$

### Assoziation

Die Assoziation erfolgt auf der Basis der gemeinsamen Merkmale von Prädiktion  $\hat{\mathbf{z}}(k+1|k)$  und Messvektor  $\mathbf{z}(k+1)$ . Der Vektor mit der größeren Dimension wird auf die des kleineren reduziert, sodass die Innovation

$$\boldsymbol{\nu}(k+1) = \mathbf{z}(k+1) - \hat{\mathbf{z}}(k+1|k) \quad (6.31)$$

berechnet werden kann. Falls die Prädiktion auf die Dimension des Messvektors gekürzt wird, ist die linearisierte Messmatrix  $\mathbf{H}(k+1)$  entsprechend zu reduzieren.

### Zustandserweiterung

Beinhaltet der Messvektor Informationen, die bei der Assoziation nicht berücksichtigt wurden, können diese genutzt werden, um den reduzierten Zustandsvektor zu erweitern. In diesem Fall wird die neue Zustandsgröße im *Erweiterungsvektor*  $\mathbf{x}_{\text{erw}}(k+1)$  gesetzt, die Varianz wird in der *Erweiterungsmatrix*  $\mathbf{P}_{\text{erw}}(k+1)$  definiert und der binäre Vektor  $\mathbf{i}(k+1)$  kennzeichnet neue Zustandsgrößen.

### Integration mit Zustandserweiterung

Falls der Informationsgehalt der Messung nicht ausreicht, um alle initialisierten Zustandsgrößen zu schätzen, kann der binäre *Schätzgrößenvektor*  $\mathbf{m}$  genutzt werden, um den Einfluss des Messvektors auf bestimmte Zustandsgrößen einzuschränken. Stimmt der Schätzgrößenvektor mit dem Initialisierungsvektor überein, so werden alle initialisierten Zustandsgrößen geschätzt. Der Schätzgrößenvektor wird bei der Berechnung der Innovationskovarianz und der Filtermatrix berücksichtigt:

$$\mathbf{S}(k+1) = (\mathbf{H}(k+1) \text{diag}(\mathbf{m})) \mathbf{P}(k+1|k) (\mathbf{H}(k+1) \text{diag}(\mathbf{m}))', \quad (6.32)$$

$$\mathbf{W}(k+1) = \mathbf{P}(k+1|k) (\mathbf{H}(k+1) \text{diag}(\mathbf{m}))' \mathbf{S}(k+1)^{-1}. \quad (6.33)$$

Im Integrationsschritt des Filters werden die zu erweiternden Zustandsgrößen berücksichtigt:

$$\hat{\mathbf{x}}(k+1|k+1) = \hat{\mathbf{x}}(k+1|k) + \mathbf{W}(k+1) \boldsymbol{\nu}(k+1) + \hat{\mathbf{x}}_{\text{erw}}(k+1), \quad (6.34)$$

$$\begin{aligned} \mathbf{P}(k+1|k+1) &= \mathbf{P}(k+1|k) - \mathbf{W}(k+1) \mathbf{S}(k+1) \mathbf{W}(k+1)', \\ &\quad + \mathbf{P}_{\text{erw}}(k+1) \end{aligned} \quad (6.35)$$


$$\mathbf{i}(k+1) = \mathbf{i}(k) + \mathbf{i}_{\text{erw}}(k+1). \quad (6.36)$$

## 6.3. Demonstration an realen Messdaten

Um die Funktionsweise der Fusionsarchitektur für variable Beobachtbarkeit zu illustrieren wird nachfolgend ein Überholmanöver untersucht, bei dem das überholende Fahrzeug vom linken Laserscanner, der Bildverarbeitung und dem Radarsensor des in [Abschnitt 4.1](#) vorgestellten Versuchsträgers erfasst wird. Die Sensordaten werden fusioniert und die unterschiedlichen Funktionsblöcke der Fusionsarchitektur werden für die Phasen des Manövers erklärt, in denen die beobachtbaren Zustandsgrößen variieren. Eine quantitative Darstellung der einzelnen Zustandsgrößen des Objekt-Zustandsvektors wird am Ende des Abschnitts gegeben.

### 6.3.1. Minimalinitialisierung


Bei Eintritt in den Detektionsbereich des Laserscanners wird zunächst nur eine Ecke des Objektes erfasst (vgl. [Abbildung 6.4](#)). Es wird ein punktförmiges Objekt initialisiert, sodass nur die Position und Geschwindigkeit geschätzt werden. Das punktförmige Objekt hat keinen Gierwinkel und keine geometrische Ausdehnung. Nur der rechte Konturpunkt des Messvektors des Laserscanners stützt in den nachfolgenden Filteriterationen die Objektbewegung.




**Abbildung 6.4.:** Illustration der Minimalinitialisierung. Da das Objekt zum Zeitpunkt des Eintritts in den Detektionsbereich des Laserscanners lediglich als punktförmiges Objekt erfasst wird, wird zunächst nur ein punktförmiges Objekt initialisiert. Geschätzt werden die Zustandsgrößen  $x, y, v_x, v_y$ .

### 6.3.2. Zustandserweiterung

Die Zustandserweiterung ist zu zwei Zeitpunkten erforderlich. Zunächst wird die Breite initialisiert, wenn diese vollständig detektiert wird. Dies ist der Fall, wenn die Breite nicht mehr durch die Grenze des Sichtbereiches beschränkt wird. Die Länge kann initialisiert werden, wenn auch diese Größe vollständig erfasst wird. Die Situationen sind in [Abbildung 6.5](#) dargestellt.



(a) Erste Zustandserweiterung vom Punkt- auf das Kantenmodell.




(b) Zweite Zustandserweiterung vom Kanten- auf das Rechteckmodell.

**Abbildung 6.5.:** Visualisierung der Zustandserweiterung nachdem vom Laserscanner eine neue Zustandsgröße detektiert wurde.

### 6.3.3. Partielle Assoziation


Wenn sich das überholende Fahrzeug entfernt, beinhaltet die Messwertprädiktion des Laserscanners den linken, dichtesten und rechten Konturpunkt des Objektmodells. Tatsächlich werden aber vom Sensor lediglich die beiden Ecken des Fahrzeuges erfasst. Während dieser Fall im vorangegangenen Kapitel über die Mehrfachprädiktion behandelt wurde, ist dies aufgrund der partiellen Assoziation bei der Fusionsarchitektur für variable Beobachtbarkeit nicht notwendig. Es werden lediglich die passenden Punkte aus Messvektor und Prädiktion assoziiert und in die Schätzung eingebracht. [Abbildung 6.6](#) verdeutlicht die Situation.



**Abbildung 6.6.:** Schematische Darstellung der partiellen Assoziation: Während die Prädiktion die hervorgehobenen drei Eckpunkte des Objektes umfasst, besteht der Messvektor nur aus den vorderen Ecken. Bei der partiellen Assoziation wird daher die Messwertprädiktion und die linearisierte Messmatrix auf die passenden Punkte reduziert.

### 6.3.4. Integration

In [Abbildung 6.6](#) liegt bereits der Fall vor in dem sich aus dem Messvektor nicht mehr alle initialisierten Zustandsgrößen des Zustandsvektors schätzen lassen. Da die Länge in dem Beispiel nicht mehr beobachtet wird, wird der Einfluss des Messvektors auf diese Größe über den Schätzgrößenvektor verhindert. Die gleiche Situation liegt vor, wenn Bildverarbeitung und Radar das Objekt erfassen. In beiden Fällen wird die Anzahl der zu schätzenden Zustandsgrößen eingeschränkt, beim punktförmigen Radarobjekt wird auch der Einfluss des Messvektors auf die Breite und den Gierwinkel verhindert. Die Situation ist in [Abbildung 6.7](#) verdeutlicht.



**Abbildung 6.7.:** Das überholende Fahrzeug befindet sich in den Erfassungsbereichen aller drei Sensoren (farblich hervorgehoben, nicht maßstäblich). Eine Einschränkung der geschätzten Zustandsgrößen ist erforderlich. Da durch Bildverarbeitungs- und Radarmessvektor nicht alle Zustandsgrößen des Objektzustandsvektors festgelegt sind, wird über den Schätzgrößenvektor die Anzahl der geschätzten Zustandsgrößen reduziert.




### 6.3.5. Quantitative Bewertung

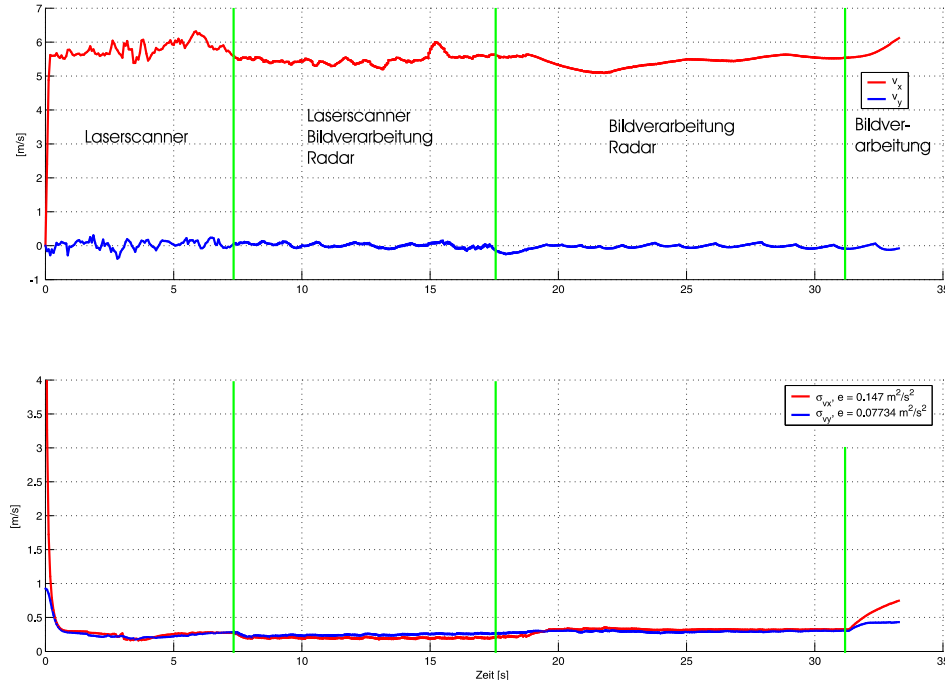
Zur quantitativen Bewertung wurde der Objekt-Zustandsvektor am Ausgang der Trackverwaltung nicht zeitlich prädiziert, sondern so ausgegeben, wie er in der nächsten Filteriteration verwendet wird. In [Abbildung 6.8](#) ist der Verlauf der Positions- und Geschwindigkeitsschätzung dargestellt, [Abbildung 6.9](#) zeigt die Formparameter. Das Szenario lässt sich in verschiedene Phasen unterteilen:

1. Zunächst erfasst nur der Laserscanner das Objekt und der Zustandsvektor wird als punktförmiges Objekt initialisiert. Sukzessive erfolgt die Erweiterung um beobachtbare Merkmale. Zum Zeitpunkt von circa 1.5s werden die Breite und der Gierwinkel initialisiert, ab 2.5s kommt die Länge hinzu. Es ist ersichtlich, dass bei Initialisierung der Länge und damit der Assoziation eines dritten Punktes die Standardabweichung des Gierwinkels deutlich sinkt.
2. Nahezu gleichzeitig erfassen auch Bildverarbeitung (7,36s) und Radar (7,38s) das Objekt. Die Sensordaten der drei Sensoren werden fusioniert. Die Schwankungen der Geschwindigkeitsschätzung in beide Koordinatenrichtungen verringern sich. Der Fehler der Breitenschätzung verringert sich durch die zusätzliche Information der Bildverarbeitung, während die Standardabweichung aufgrund der Winkel- und Pixeldiskretisierung mit zunehmender Entfernung wächst. Die Standardabweichung des Gierwinkels bleibt mit circa  $1^\circ$  konstant.
3. Bei circa 17,5s erfasst der Laserscanner das Objekt zum letzten Mal. Die Entfernungsunsicherheit zeigt einen Anstieg auf ein höheres Niveau. Auch die Standardabweichung der Geschwindigkeit in  $x$ -Richtung steigt an.
4. Bei etwa 31,5s erfasst der Radarsensor das Objekt zum letzten Mal. Da die Sensordaten der Bildverarbeitung in einer Entfernung von über 120m sehr große Schwankungen aufweisen und entsprechend unsicherheitsbehaftet sind wächst die Standardabweichung der  $x$ -Position und -Geschwindigkeit erneut an. Die  $y$ -Position des Fahrzeuges zeigt keine entsprechend große Störung.

Den wesentlichen Fortschritt gegenüber der Mehrfachprädiktion dokumentiert [Abbildung 6.10](#). Das normierte Innovationsquadrat liegt durch die partielle Assoziation während der gesamten Objektverfolgung um zwei Zehnerpotenzen unter der Assoziationsschwelle. Die erkennbaren Maximalwerte liegen in dem Übergangsbereich, von der Frontal- auf die Seiten- und schließlich auf die Heckansicht des Fahrzeuges. Im Gegensatz zur Mehrfachprädiktion genügt jedoch bei dem gewählten Ansatz ein einzelner assoziierter Punkt des Laserscanner-Messvektors, um einen Objekttrack weiter zu stützen. Dadurch ist es in diesem Szenario möglich, die Entfernungsunsicherheit des Laserscanners auf den 0,15m zu reduzieren, ohne dass dies zu Assoziationsproblemen führt. Insgesamt zeigt das gewählte Beispiel, dass eine robuste Objektverfolgung von circa 20m hinter dem Versuchsträger bis zur maximalen Reichweite der Sensoren von circa 170m möglich ist.

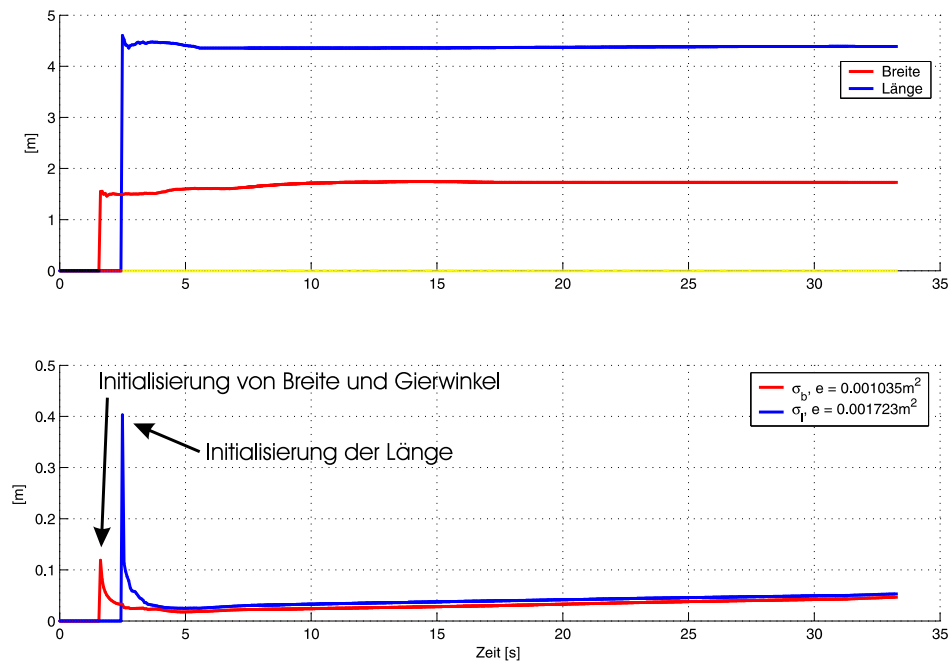


(a) Schätzung von Objektkoordinaten und Orientierung mit Standardabweichungen.



(b) Schätzung der Geschwindigkeitskomponenten mit Standardabweichungen.

**Abbildung 6.8.:** Geschätzte Position und Geschwindigkeit mit Standardabweichungen bei Anwendung der Fusionsarchitektur für variable Beobachtbarkeit. Die mittlere quadratische Standardabweichung ist in der Legende mit  $e$  angegeben.




**Abbildung 6.9.:** Geschätzte Formparameter mit Standardabweichungen bei Anwendung der Fusionsarchitektur für variable Beobachtbarkeit. Die unterschiedliche Farbgebung der Zeitachse kennzeichnet unterschiedliche Formmodelle (Punkt, Kante, Rechteck). Die mittlere quadratische Standardabweichung ist in der Legende mit  $e$  angegeben.

## 6.4. Zusammenfassung

Im Rahmen dieses Kapitels wurden zunächst die Besonderheiten einer Objektverfolgung im automobilen Straßenverkehr erörtert, wie sie sich bei variierenden Perspektiven und insbesondere der Sensordatenfusion in einem heterogenen Netzwerk ergeben. Als wesentlicher Aspekt wurde hierbei der variierende Informationsgehalt der Messvektoren identifiziert, der die Schätzung einer festen Anzahl von Zustandsgrößen mit einem festen Objektmodell, wie im vorangegangenen Kapitel vorgestellt, in Frage stellt. Um die Schätzgenauigkeit zu erhöhen und die Beobachtbarkeit zu gewährleisten, wurde die Forderung nach einem minimalen Zustandsvektor aufgestellt, der nur die beobachtbaren Zustandsgrößen beinhaltet und bei Bedarf erweitert wird.

Im Hauptteil des Kapitels wurde eine neue Kalman-Filter Fusionsarchitektur vorgestellt, die die Forderungen nach der Minimalität des Zustandsvektors realisiert, indem ergänzend zu den Schätzgrößen Zustandsvektor und Kovarianzmatrix ein binärer Initialisierungsvektor benutzt wird. Dieser Vektor kennzeichnet eine Teilmenge des bekannten maximalen Objektmodells als zu schätzende Zustandsgrößen. Ein weiterer binärer Schätzgrößenvektor wurde eingeführt, um bei Verdeckung einer zuvor beobachteten Zustandsgröße, den Einfluss des Messvektors auf diese Größe zu reduzieren.



**Abbildung 6.10.:** Normiertes Innovationsquadrat (NIS) bei Anwendung der Fusionsarchitektur für variable Beobachtbarkeit.

Die Demonstration anhand von realen Sensordaten dokumentiert die einzelnen Erweiterungsphasen des Zustandsvektors um neue beobachtbare Zustandsgrößen und zeigt eine deutlich erhöhte Robustheit bei der Assoziation. Diese manifestiert sich in einem signifikant reduzierten normierten Innovationsquadrat über die gesamte Objektverfolgung und insbesondere während der wechselnden Aspektwinkel. Die Verbesserung konnte erzielt werden, obwohl die Unsicherheit der Laserscanner-Messwerte gegenüber dem vorangegangenen Kapitel sogar reduziert wurde und ein ähnlicher Perspektivenwechsel bei der Objektverfolgung stattfand.

# 7. Zusammenfassung und Ausblick

## 7.1. Zusammenfassung

Moderne Fahrerassistenzsysteme zeigen einen Entwicklungstrend vom reinen Komfortsystem, das den Fahrer unterstützt und bei Routinetätigkeiten entlastet, zum Warn- und Sicherheitssystem, das aktiv zur Verminderung oder Vermeidung von Unfallfolgen beiträgt. Der Schritt von der Abstandsregelung zum Precrash- oder Kollisionsvermeidungssystem stellt hierbei einen erheblichen Anspruch an die sensorische Umfelderkennung, wobei neben der Dynamik von Objekten auch deren Formparameter zu berücksichtigen sind. Da derzeit keine einzelne Sensortechnologie eine Informationsdichte liefert, wie sie für derartige Applikationen benötigt wird, zeichnet sich der Trend einer multisensoriellen Umfelderkennung mit einer Fusion von zumeist heterogenen Sensordaten ab.

Die Herausforderung an die Umfelderkennung und Sensordatenfusion liegt darin, dass ein komplexes Objektmodell erforderlich ist, jedoch mit keiner verfügbaren Sensorik (Radar, Laser, Video) die Möglichkeit besteht, alle Zustandsgrößen gleichzeitig zu beobachten. Die Beobachtbarkeit ist darüber hinaus abhängig von der Perspektive, aus der ein Objekt betrachtet wird. Die Kombination von heterogenen Sensoren schafft die Möglichkeit, ein komplexes Objektmodell zu stützen, führt aber zu Besonderheiten, die für eine robuste Objektverfolgung im automobilen Straßenverkehr zu berücksichtigen sind. Drei wesentliche Aspekte wurden im Rahmen der vorliegenden Arbeit thematisiert: Die Verarbeitung asynchroner Sensordaten, ein verbessertes Sensormodell insbesondere für optische Sensoren und eine Fusionsarchitektur für variable Beobachtbarkeit von Zustandsgrößen.

Die Fusion asynchroner Sensordaten, wird bei der Fahrumgebungserfassung in aktuellen Projekten zumeist durch eine Messwertprädiktion auf einen gemeinsamen Fusionszeitpunkt realisiert. Die wesentlichen Erschwernisse des Verfahrens liegen in der zeitlichen Prädiktion, die lediglich die Messdaten eines einzelnen Sensors berücksichtigt, in der resultierenden schwankenden Unsicherheit der Tracks eines Sensors und in der Verzögerung, die sich aus einem festen Fusionsraster ergibt. Der vor allem aus theoretischen Untersuchungen bekannte alternative Ansatz einer asynchronen Fusion mit einer Retrodiktion zur Einbringung von zeitlich zurückliegenden Messdaten schafft neue Probleme, da die Auswirkungen von neu initialisierten Objekten und bereits verworfenen Tracks nicht berücksichtigt werden können.

Im Rahmen dieser Arbeit beinhaltet die Fusionsarchitektur mit einer zentralisierten Objektverfolgung mittels Kalman-Filter einen Messdatenpuffer, der es ermöglicht, eine Sortierung der Sensordaten nach ihrem Messzeitpunkt vorzunehmen. Auf diese

Weise lassen sich negative Zeitschritte durch das Einbringen von veralteten Datensätzen verhindern. Eine Besonderheit bei diesem Verfahren stellt die Berücksichtigung der erwarteten Messzeitpunkte dar, über die sich die durch den Messdatenpuffer verursachte zusätzliche Verzögerung auf die Differenz zwischen der maximalen und der minimalen Sensorzykluszeit beschränken lässt. Gleichzeitig lässt sich erreichen, dass bestimmte Datensätze unverzögert in die Fusion eingebracht werden können. Der zeitliche Versatz zur Realzeit lässt sich bei der vorgestellten Architektur prinzipiell beliebig reduzieren, indem eine zeitliche Prädiktion der Objekttracks erfolgt. Im Gegensatz zu der aus der Literatur bekannten Prädiktion der Sensordaten ergibt sich hier der Vorteil, dass das prädizierte Objekt die Informationen mehrerer Sensoren beinhaltet und somit ein komplexeres Modell gestützt werden kann und die Unsicherheiten durch die Fusion bereits reduziert sind.

Innerhalb des Sensormodells werden die sensorspezifischen Eigenschaften berücksichtigt. Ein wesentlicher Punkt ist hierbei das Zusammenspiel von Objektmodell und der Beobachtbarkeit durch die verwendete Sensorik. Das im Rahmen dieser Arbeit eingeführte Objektmodell eines orientierten Quaders mit geradlinig gleichförmiger Bewegung ist durch die verwendete Sensorik beobachtbar, vorausgesetzt, dass ein entsprechender Aspektwinkel die Beobachtung aller Formparameter des Zustandsvektors ermöglicht. Trotz dieses theoretischen Ergebnisses bereitet vor allem die Assoziation von Messdaten optischer Sensoren Schwierigkeiten, weil einerseits abhängig vom Aspektwinkel unterschiedliche Zustandsgrößen beobachtet werden und andererseits die Messunsicherheit mit dem Aspektwinkel variiert. Beide Effekte lassen sich durch die aus der Literatur bekannten Verfahren nicht lösen. Multi-Modell-Verfahren und die Adaption des Prozessrauschens können eingesetzt werden, um Abweichungen der Objektdynamik von einem konkreten Modell abzubilden. Die Ursache von gescheiterten Assoziationen liegt dabei ausschließlich in der Objektbewegung, nicht in Messgrößen, die sich in Abhängigkeit von der Lage eines Objektes im Zustandsraum ändern. Auch alternative Assoziationsverfahren zur Auflösung von Mehrdeutigkeiten bei der Zuordnung können nicht eingesetzt werden, da solche nicht existieren.

Aus diesem Grund ist im Rahmen dieser Arbeit ein alternatives Sensormodell beschrieben und beispielhaft für den Laserscanner dargestellt worden. Der aus der Literatur bekannte Multi-Modell-Ansatz wird auf die Messwertprädiktion übertragen. Die Mehrfach-Messwertprädiktion, bei der diskrete Hypothesen für die prädizierten Messvektoren aufgestellt werden, erhöht die Robustheit bei einem Perspektivenwechsel. Analog zu der bekannten Adaption des Prozessrauschens lässt sich auch das Messrauschen sinnvoll adaptieren. Im Gegensatz zu der bekannten Skalierung beschreibt diese Arbeit ein Verfahren, mit dem die räumliche Lage der Messunsicherheit vorgegeben werden kann. Auf diese Weise lässt sich die mit dem Aspektwinkel variierende Messunsicherheit berücksichtigen. Eine Verbesserung ergibt sich durch dieses Verfahren vor allem bei flachen Aspektwinkeln und falls ein Objekt den Sensorsichtbereich verlässt.

Der schwankende Informationsgehalt von heterogenen Sensoren bei der Fahrumgebungserfassung führt dazu, dass bestimmte Zustandsgrößen eines Objektes nicht durch jeden Sensor beobachtbar sind. Teilweise ist die Beobachtbarkeit von Zustandsgrößen, vor allem der Formparameter, auch vom Aspektwinkel abhängig. Aus

der Literatur sind Verfahren bekannt, bei denen man für unterschiedliche Bewegungszustände unterschiedliche Objektmodelle verwendet. Hierbei ändern sich die dynamischen Parameter und die zeitliche Prädiktion eines Objektes, das Sensormodell ist von den Änderungen nicht betroffen. Diese Verfahren lassen sich daher nicht einsetzen, um variierende Messmerkmale zu behandeln. Auch das Sensormodell mit Mehrfach-Messwertprädiktionen setzt voraus, dass die Dimension von Messvektor und Prädiktion übereinstimmen.

Durch die im Rahmen dieser Arbeit entwickelte Fusionsarchitektur für variable Beobachtbarkeit lässt sich eine deutlich robustere Objektverfolgung erzielen, die sich in einem signifikant reduzierten normierten Innovationsquadrat manifestiert. Die vorgestellte Architektur ist dadurch gekennzeichnet, dass die maximale Anzahl der im Zustandsvektor vorhandenen Zustandsgrößen durch das Objektmodell festgelegt ist, aber in Abhängigkeit von den berücksichtigten Messdaten auf die beobachtbaren Merkmale reduzierte Zustandsvektoren geschätzt werden können. Die Kalman-Filter-Fusionsarchitektur für variable Beobachtbarkeit ermöglicht es, das Mitschätzen von nicht beobachtbaren Zustandsgrößen zu verhindern und den Zustandsvektor dynamisch zu erweitern, wenn zusätzliche Merkmale beobachtet werden. Durch die Einführung von zusätzlichen Binärvektoren lässt sich der modifizierte Kalman-Filter-Algorithmus mit geringem Aufwand umsetzen. Neben der verbesserten Schätzung durch die reduzierte Dimension der Zustandsvektoren resultiert aus der partiellen Assoziation eine robustere Objektverfolgung. Sie ermöglicht die Assoziation von unterschiedlich dimensionalen Messvektoren und Prädiktionen auf der Basis gemeinsamer Merkmale. Dadurch führen einzelne nicht assoziierbare Merkmale nicht zu einer Fehlassociation und neue Merkmale im Messvektor werden zur Erweiterung des Zustandsvektors genutzt. Eine Mehrfach-Messwertprädiktion ist folglich nicht mehr erforderlich.

## 7.2. Ausblick

Die robuste Objektverfolgung durch eine heterogene Sensordatenfusion schafft die Voraussetzung für weitere Untersuchungen. Das verwendete Dynamikmodell könnte für hochdynamische Situationen wie etwa Ausweichmanöver erweitert werden. Eine Klassifikation unterschiedlicher Bewegungszustände von Fahrzeugen stellt daher eine sinnvolle Ergänzung zu den vorgestellten Verfahren dar. Die Berücksichtigung des Spurverlaufs schafft darüber hinaus die Möglichkeit einer Situationsinterpretation mit der eine neue Qualität des Umfeldmodells geschaffen wird. Außerdem könnte das Umfeldmodell um geeignete Modelle für die durch die Sensoren detektierbare Infrastruktur – wie beispielsweise Leitplanken – erweitert werden.





# A. Symbole und mathematische Notationen

## A.1. Konventionen

Skalare:	Kleinbuchstaben	Beispiel: $a$
Mengen:	Großbuchstaben	Beispiel: $X$
Vektoren:	fettgedruckte Kleinbuchstaben	Beispiel: $\mathbf{x}$
Matrizen:	fettgedruckte Großbuchstaben	Beispiel: $\mathbf{A}$

Die Elemente eines Zeilenvektors werden durch ein Komma getrennt (Beispiel:  $\mathbf{x} = (x_1, x_2, \dots, x_n)$ ). Bei einem Spaltenvektor erfolgt die Trennung durch ein Semikolon (Beispiel:  $\mathbf{y} = (y_1; y_2; \dots; y_n)$ ).

## A.2. Mathematische Notationen

$\mathbf{x}'$	Transponierter Vektor $\mathbf{x}$
$\mathbf{A}'$	Transponierte Matrix $\mathbf{A}$
$\mathbf{A}^{-1}$	Inverse der Matrix $\mathbf{A}$
$ \mathbf{A} $	Determinante der Matrix $\mathbf{A}$
$\bar{\mathbf{x}}$	Erwartungswert der Zufallsvariable $\mathbf{x}$
$\hat{\mathbf{x}}$	Schätzwert der Zufallsvariable $\mathbf{x}$
$\tilde{\mathbf{x}}$	Schätzfehler der Zufallsvariable $\mathbf{x}$
$\nabla_{\mathbf{x}}$	Differentialoperator $\left(\frac{\partial}{\partial x_1}, \frac{\partial}{\partial x_2}, \dots, \frac{\partial}{\partial x_n}\right)'$
$\text{def}(f)$	Definitionsbereich der Funktion $f$
$\text{diag}(\mathbf{x})$	Diagonalmatrix $\mathbf{A}$ mit $a_{ii} = x_i$ für $i = 1, 2, \dots, n$ und $a_{ij} = 0$ , falls $i \neq j$
$\text{dim}(\mathbf{x})$	Dimension des Vektors $\mathbf{x}$
$\text{rang}(\mathbf{A})$	Rang der Matrix $\mathbf{A}$
$\text{spur}(\mathbf{A})$	Spur der Matrix: $\sum_{i=1}^n a_{ii}$

## A.3. Symbolverzeichnis

Im Folgenden sind die abschnittsübergreifend verwendeten Variablen aufgelistet:

### A.3.1. Skalare

$b$	Objektbreite
$l$	Objektlänge
$h$	Objekthöhe
$\epsilon_\nu$	Normiertes Innovationsquadrat (Mahalanobisabstand)
$k$	Diskreter Zeitindex
$n_x$	Dimension des Zustandsvektors $\mathbf{x}$
$n_u$	Dimension des Steuerungsvektors $\mathbf{u}$
$n_z$	Dimension des Messvektors $\mathbf{z}$
$\psi$	Gierwinkel des Objektes
$v_x$	Objektgeschwindigkeit in $x$ -Richtung
$v_y$	Objektgeschwindigkeit in $y$ -Richtung
$x$	$x$ -Koordinate des Objektzustandsvektors
$y$	$y$ -Koordinate des Objektzustandsvektors

### A.3.2. Mengen

$\hat{Z}$	Mehrfach-Messwertprädiktion
-----------	-----------------------------

### A.3.3. Vektoren und Vektorfunktionen

$\mathbf{f}$	Zustandsübergangsfunktion
$\mathbf{h}$	Messfunktion
$\mathbf{i}$	binärer Initialisierungsvektor
$\nu$	Innovation
$\mathbf{m}$	binärer Schätzgrößenvektor
$\mathbf{x}$	Zustandsvektor
$\bar{\mathbf{x}}$	Erwartungswert des Zustandsvektors
$\tilde{\mathbf{x}}$	Schätzfehler des Zustandsvektors
$\mathbf{s}$	Transformation vom Sensor in das Trackingkoordinatensystem
$\mathbf{u}$	Steuerungsvektor
$\mathbf{v}$	Prozessrauschen
$\mathbf{w}$	Messrauschen
$\mathbf{z}$	Messvektor

**A.3.4. Matrizen**

<b>F</b>	Zustandsübergangsmatrix
<b>G</b>	Steuerungsmatrix
<b>H</b>	(linearisierte) Messmatrix
<b>M</b>	Beobachtbarkeitsmatrix
<b>P</b>	Kovarianzmatrix des Zustandsvektors
<b>Q</b>	Kovarianzmatrix des Systemrauschens
<b>R</b>	Kovarianzmatrix des Messrauschens
<b>S</b>	Innovationskovarianz
<b>W</b>	Kalman-Filtermatrix



# Literaturverzeichnis

- Abramowitz und Stegun 1974** ABRAMOWITZ, Milton ; STEGUN, Irene A.: *Handbook of Mathematical Functions*. Dover Publications, 1974. – ISBN 0486612724 Seite(n): [102](#)
- Ameling 2002** AMELING, Christian: *Steigerung der aktiven Sicherheit von Kraftfahrzeugen durch ein Kollisionsvermeidungssystem*, Universität der Bundeswehr Hamburg, Fachbereich Maschinenbau, Dissertation, 2002 Seite(n): [13](#)
- ATZ 09 - 2003** *Sensorik in Sicherheits- und Assistenzsystemen*. S. 836–840. In: *ATZ-Automobiltechnische Zeitschrift*, September 2003, ISSN 0001-2785 Seite(n): [13](#)
- ATZ 10 - 2003** *Heutige Fahrerassistenz-Systeme und ihr Potenzial für die Zukunft*. S. 956–964. In: *ATZ - Automobiltechnische Zeitschrift*, Oktober 2003, ISSN 0001-2785 Seite(n): [11](#), [14](#)
- Aziz 1999** AZIZ, Ashraf Mamdouh A.: *New Data Fusion Algorithms for distributed multi-sensor multi-target environments*, Naval Postgraduate School, Monterey, California, Dissertation, 1999 Seite(n): [47](#), [48](#)
- Bar-Shalom 2002** BAR-SHALOM, Yaakov: Update with Out-of-Sequence Measurements in Tracking: Exact Solution. In: *IEEE Transactions on Aerospace and Electronic Systems* Bd. 38, IEEE - Institute of Electrical and Electronics Engineers, Inc., Januar 2002, S. 769–778. – ISSN 0018-9251 Seite(n): [23](#)
- Bar-Shalom und Fortmann 1988** BAR-SHALOM, Yaakov ; FORTMANN, Thomas E.: *Tracking and Data Association*. Academic Press, 1988. – ISBN 0-12-079760-7 Seite(n): [24](#), [53](#)
- Bar-Shalom und Li 1995** BAR-SHALOM, Yaakov ; LI, Xiao-Rong: *Multitarget-Multisensor Tracking: Principles and Techniques*. 3. YBS Publishing, 1995. – ISBN 0-9648312-0-1 Seite(n): [18](#), [21](#), [56](#)
- Bar-Shalom und Li 1993** BAR-SHALOM, Yaakow ; LI, Xiao-Rong: *Estimation and Tracking: Principles, Techniques and Software*. Artech House, 1993. – ISBN 0-89006-643-4 Seite(n): [23](#), [25](#), [30](#), [38](#), [39](#), [40](#), [41](#), [43](#), [44](#), [75](#), [87](#)
- Becker und Simon 2000** BECKER, Jan C. ; SIMON, Andreas: Sensor and Navigation Data Fusion for an Autonomous Vehicle. In: *Proceedings of the IEEE*

- Intelligent Vehicles Symposium 2000*, IEEE - Institute of Electrical and Electronics Engineers, Inc., October 2000, S. 156–161. – ISBN 0-7803-6363-9 Seite(n): 12
- Becker 2001** BECKER, Jan-Carsten: *Fusion der Daten der objekterkennenden Sensoren eines autonomen Straßenfahrzeugs*, Technische Universität Carolo-Wilhelmina zu Braunschweig, Fakultät für Maschinenbau und Elektrotechnik, Dissertation, November 2001 Seite(n): 12, 38
- Bensrhair u. a. 2001** BENSRAIR, A. ; BERTOZZI, M. ; BROGGI, A. ; MICHÉ, P. ; MOUSSET, S. ; TOULMINET, G.: A Cooperative Approach to Vision-Based Vehicle Detection. In: *Proceedings of the IEEE Conference on Intelligent Transportation Systems*, IEEE - Institute of Electrical and Electronics Engineers, Inc., August 2001, S. 207–212. – ISBN 0-7803-7194-1 Seite(n): 12
- Bertozzi und Broggi 1996** BERTOZZI, Massimo ; BROGGI, Alberto: Real-Time Lane and Obstacle Detection on the Gold System. In: *Proceedings of the IEEE Intelligent Vehicles Symposium*, IEEE - Institute of Electrical and Electronics Engineers, Inc., September 1996, S. 213–218. – ISBN 0-7803-3652-6 Seite(n): 12
- Bertsekas 2001** BERTSEKAS, Dimitri P.: Auction Algorithms. In: *Encyclopedia of Optimization*. Kluwer Academic Press, 2001. – URL <http://www.mit.edu:8001//people/dimitrib/publ.html>. – Zugriffsdatum: 20.08.2003 Seite(n): 52
- Bertsekas und Castanon 1993** BERTSEKAS, Dimitri P. ; CASTANON, David A.: A Forward/Reverse Auction Algorithm for Asymmetric Assignment Problems. In: *Computational Optimization and Applications* 1 (1993), Januar, S. 277–297 Seite(n): 52
- Bertsekas u. a. 1993** BERTSEKAS, Dimitri P. ; CASTANON, David A. ; TSAKNAKIS, Haralampos: Reverse Auction and the Solution of Inequality Constrained Assignment Problems. In: *SIAM Journal on Optimization* Bd. 3, URL <http://www.mit.edu:8001//people/dimitrib/publ.html>. – Zugriffsdatum: 20.08.2003, 1993, S. 268–299 Seite(n): 51, 52
- Bertsekas u. a. 1995** BERTSEKAS, Dimitri P. ; PALLOTTINO, Stefano ; SCUTELLA, Maria G.: Polynomial Auction Algorithms for Shortest Paths. In: *Computational Optimization and Applications* Bd. 4, 1995, S. 99–125 Seite(n): 52
- Blackman 1986** BLACKMAN, S. S.: *Multiple Target Tracking with Radar Applications*. Norwood, MA, 1986. – ISBN 0890061793 Seite(n): 49
- Blackman und Populi 1999** BLACKMAN, Samuel ; POPULI, Robert: *Design and Analysis of Modern Tracking Systems*. Artech House, 1999. – ISBN 1-58053-006-0 Seite(n): 8, 44, 46, 48, 49, 52, 56, 84
- Blair und Bar-Shalom 1996** BLAIR, W. D. ; BAR-SHALOM, Y.: Tracking Maneuvering Targets with Multiple Sensors: Does More Data Always Mean Better Estimates? In: *IEEE Transactions on Aerospace and Electronic Systems* Bd. 32, IEEE - Institute of Electrical and Electronics Engineers, Inc., Januar 1996, S. 450–456. – ISSN 0018-9251 Seite(n): 15

- Brookner 1998** BROOKNER, Eli: *Tracking and Kalman Filtering made easy*. John Wiley and Sons, 1998. – ISBN 0-471-18407-1 Seite(n): [24](#), [25](#)
- Chang u. a. 1997** CHANG, K. C. ; SAHA, R. K. ; BAR-SHALOM, Y.: On Optimal Track-to-Track Fusion. In: *IEEE Transactions on Aerospace and Electronic Systems* Bd. 33, IEEE - Institute of Electrical and Electronics Engineers, Inc., Oktober 1997, S. 1271–1276. – ISSN 0018-9251 Seite(n): [69](#)
- Chen 1991** CHEN, Zhe: Local observability and its application to multiple measurement estimation. In: *Transactions on Industrial Electronics* Bd. 38, IEEE - Institute of Electrical and Electronics Engineers, Inc., Dezember 1991, S. 491–496. – ISSN 0278-0046 Seite(n): [76](#)
- Chen u. a. 1990** CHEN, Zhe ; JIANG, Ke ; HUNG, James C.: Local Observability Matrix and its application to observability analysis. In: *16th Annual Conference of IEEE: IECON '90*, IEEE - Institute of Electrical and Electronics Engineers, Inc., November 1990, S. 100–103 Seite(n): [76](#)
- Chong u. a. 2000** CHONG, Chee-Yee ; MORI, S. ; BARKER, W. H. ; CHANG, Kuo-Chu: Architectures and Algorithms for Track Association and Fusion. In: *IEEE Transactions on Aerospace and Electronic Systems* Bd. 15, IEEE - Institute of Electrical and Electronics Engineers, Inc., Januar 2000, S. 5–13. – ISSN 0885-8985 Seite(n): [69](#)
- De Geeter u. a. 1997** DE GEETER, J. ; VAN BRUESSEL, H. ; DE SCHUTTER, J. ; DECRETON, M.: A Smoothly Constrained Kalman Filter. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* Bd. 19, IEEE - Institute of Electrical and Electronics Engineers, Inc., Oktober 1997, S. 1171–1177. – ISSN 0162-8828 Seite(n): [30](#), [36](#)
- Duden Informatik 1993** CLAUS, Volker (Hrsg.) ; SCHWILL, Andreas (Hrsg.): *Duden Informatik*. 2. Auflage. Hermann Engesser, 1993. – ISBN 3-411-05232-5 Seite(n): [51](#)
- Enkelmann 1991** ENKELMANN, W.: Obstacle detection by evaluation of optical flow fields from image sequences. In: *Image and Vision Computing*, 1991, S. 160–168 Seite(n): [8](#)
- Fuerstenberg u. a. 2001** FUERSTENBERG, Kay C. ; BARAUD, Pierre ; CAPORALLETTI, Gabriella ; CITELLI, Silvia ; EITAN, Zafrir ; LAGES, Ulrich ; LAVERGNE, Christophe: Development of a Pre-Crash Sensorial System - The CHAMELEON Project. In: *VDI-Berichte 1653: Fahrzeugkonzepte Für Das 2. Jahrhundert Automobiltechnik*. Wolfsburg, Germany, 2001, S. 289–310 Seite(n): [12](#)
- Grell 2003** GRELL, Detlef: Rad am Draht. In: *c't* 14 (2003), Juli, S. 170–183 Seite(n): [1](#)
- Gruyer und Berge-Cherfaoui 1999a** GRUYER, D. ; BERGE-CHERFAOUI, V.: Matching and Decision for Vehicle Tracking in Road Situations. In: *Proceedings of*

- the IEEE/RSJ International Conference on Intelligent Robots and Systems* Bd. 1, IEEE - Institute of Electrical and Electronics Engineers, Inc., Oktober 1999, S. 29–34. – ISBN 0-7803-5184-3 Seite(n): 57
- Gruyer und Berge-Cherfaoui 1999b** GRUYER, D. ; BERGE-CHERFAOUI, V.: Multi-Objects Association in Perception of Dynamical Situation. In: *Proceedings of the Fifteenth Conference on Uncertainty in Artificial Intelligence*. Stockholm, Suede, July-August 1999 Seite(n): 57
- Gruyer u. a. 2000** GRUYER, D. ; ROYERE, C. ; CHERFAOUI, V.: Credibilist Multi-Sensors Fusion for the Mapping of Dynamic Environment. In: *Proceedings of the Third International Conference on Information Fusion FUSION 2000* Bd. 1. Paris, France, Juli 2000, S. 16–23. – ISBN 2-7257-0000-0 Seite(n): 57
- Ham und Brown 1983** HAM, Fredric M. ; BROWN, R. G.: Observability, Eigenvalues and Kalman Filtering. In: *IEEE Transactions on Aerospace and Electronic Systems* 19 (1983), Nr. 2, S. 269–273 Seite(n): 76
- Hancock 1999** HANCOCK, John A.: *Laser Intensity-Based Obstacle Detection and Tracking*, Carnegie Mellon University, The Robotics Institute, Dissertation, Januar 1999 Seite(n): 9
- Horton und Jones 1995** HORTON, M. J. ; JONES, R. A.: Fuzzy logic extended rule set for multitarget tracking, SPIE - The International Society for Optical Engineering, 1995, S. 106–117 Seite(n): 37, 38
- Jansson u. a. 2001** JANSSON, J. ; JOHANSSON, J. ; GUSTAFSSON, F.: Collision Avoidance by Braking. In: *SAE World Congress 2001*, URL <http://www.control.isy.liu.se/~fredrik/vehicular.html>. – Zugriffsdatum: 17.03.2003, 2001 Seite(n): 71
- Julier 2002** JULIER, Simon S.: The Scaled Unscented Transformation. In: *Proceedings of the American Control Conference* Bd. 6, IEEE - Institute of Electrical and Electronics Engineers, Inc., 2002, S. 4555–4559. – ISSN 0743-1619 Seite(n): 34
- Julier und Uhlmann 1997** JULIER, Simon S. ; UHLMANN, Jeffrey K.: A New Extension of the Kalman Filter to Nonlinear Systems. In: *Proceedings of the SPIE AeroSense Symposium*, SPIE - The International Society for Optical Engineering, April 1997 Seite(n): 31, 33
- Julier und Uhlmann 2002** JULIER, Simon S. ; UHLMANN, Jeffrey K.: Reduced Sigma Point Filters for the Propagation of Means and Covariances through nonlinear Transformations. In: *Proceedings of the IEEE American Control Conference*, Mai 2002, S. 887–892 Seite(n): 34
- Kalman 1960** KALMAN, R. E.: A New Approach to Linear Filtering and Prediction Problems. In: *Transactions on the ASME - Journal of Basic Engineering* 82 (Series D) (1960), S. 35–45 Seite(n): 24



- Kirchner u. a. 2001** KIRCHNER, A. ; WEISSER, H. ; SCHARNHORST, Th. ; STÜCKER, D.: Sensor Fusion - a Research Perspective. In: *Konferenzband: Sicherheit im Automobil (Vehicle Safety)*. München : Verlag Moderne Industrie, März 2001 Seite(n): [5](#)
- Kirchner 2000** KIRCHNER, Alexander: *Sensordatenverarbeitung eines Laserscanners für autonome Fahrfunktionen von Kraftfahrzeugen*, Universität der Bundeswehr, Hamburg, Institut für Automatisierungstechnik, Dissertation, Juni 2000. – ISBN 3-18-343812-7 Seite(n): [72](#)
- Kirchner und Schwitters 2003** KIRCHNER, Alexander ; SCHWITTERS, Frank: Vernetzte und modulare Auslegung von Fahrerassistenzfunktionen. In: *VDI-Konferenzband: Elektronik im Kraftfahrzeug*. Baden-Baden : VDI, September 2003 Seite(n): [63](#)
- Knoll u. a. 2002** KNOLL, Peter M. ; WINNER, Hermann ; KALLENBACH, Rainer: Surround Sensing - Collision Warning Systems - Vehicle Guidance. In: *3. Braunschweiger Symposium*, Februar 2002 Seite(n): [8](#)
- Kopischke 2000** KOPISCHKE, Stefan: *Entwicklung Einer Automatischen Notbremsfunktion mit Rapid Prototyping Methoden*, Technische Universität Braunschweig, Fachbereich für Maschinenbau und Elektrotechnik, Dissertation, Februar 2000 Seite(n): [13](#), [71](#)
- Lages 2002** LAGES, Ulrich: Laser Scanner for Obstacle Detection. In: *6th International Conference - Advanced Microsystems for Automotive Applications*, März 2002 Seite(n): [10](#)
- Langheim 2001** LANGHEIM, J.: CARSENSE - New Environment Sensing for Advanced Driver Assistance Systems. In: *Proceedings of the IEEE Intelligent Vehicles Symposium*. Korea : IEEE - Institute of Electrical and Electronics Engineers, Inc., 2001 Seite(n): [13](#)
- Li 1994** LI, X. R.: Multiple-Model Estimation with Variable Structure: Some Theoretical Considerations. In: *Proceedings of the 33rd IEEE Conference on Decision and Control* Bd. 2, IEEE - Institute of Electrical and Electronics Engineers, Inc., Dezember 1994, S. 1199–1204. – ISBN 0-7803-1968-0 Seite(n): [46](#)
- Li 2000** LI, X. R.: Multiple-Model Estimation with Variable Structure. Part II. Model-Set Adaptation. In: *IEEE Transactions on Automatic Control* Bd. 45 Issue 11, IEEE - Institute of Electrical and Electronics Engineers, Inc., November 2000, S. 2047–2060. – ISSN 0018-9286 Seite(n): [46](#)
- Li u. a. 1999a** LI, X. R. ; ZHANG, Youmin ; ZHI, Xiaorong: Multiple-Model Estimation with Variable Structure. Part IV. Design and Evaluation of Model-Group Switching Algorithm. In: *IEEE Transactions on Aerospace and Electronic Systems* Bd. 35 Issue 1, IEEE - Institute of Electrical and Electronics Engineers, Inc., Januar 1999, S. 242–254. – ISSN 0018-9251 Seite(n): [46](#)

- Li u. a. 1999b** LI, X. R. ; ZWI, Xiaorong ; ZWANG, Youmin: Multiple-Model Estimation with Variable Structure. Part III. Model-Group Switching Algorithm. In: *IEEE Transactions on Aerospace and Electronic Systems* Bd. 35 Issue 1, IEEE - Institute of Electrical and Electronics Engineers, Inc., Januar 1999, S. 225–241. – ISSN 0018-9251 Seite(n): [46](#)
- Luo und Kay 1994** LUO, Ren C. ; KAY, Michael G.: *Multisensor Integration and Fusion for Intelligent Machines and Systems*. Ablex Publishing Corporation, 1994. – ISBN 0-89391-863-6 Seite(n): [15](#)
- Mallick u. a. 2002** MALLICK, M. ; KRANT, J. ; BAR-SHALOM, Y.: Multi-Sensor Multi-Target Tracking Using Out-of-Sequence Measurements. In: *Proceedings of the Fifth International Conference on Information Fusion* Bd. 1, IEEE - Institute of Electrical and Electronics Engineers, Inc., Juli 2002, S. 135–142. – ISBN 0-9721844-1-4 Seite(n): [23](#)
- Mazor u. a. 1998** MAZOR, E. ; AVERBUCH, A. ; BAR-SHALOM, Y. ; DAYAN, J.: Interacting Multiple Model Methods in Target Tracking: A Survey. In: *IEEE Transactions on Aerospace and Electronic Systems* Bd. 34, IEEE - Institute of Electrical and Electronics Engineers, Inc., Januar 1998, S. 102–123. – ISSN 0018-9251 Seite(n): [42](#)
- Meinecke 2001** MEINECKE, Marc-Michael: *Zum optimierten Sendesignalwurf für Automobilradare*, Technische Universität Hamburg-Harburg, Dissertation, 2001. – ISBN 3-8265-9223-9 Seite(n): [2](#)
- Mitschke 1972** MITSCHKE, Manfred: *Dynamik der Kraftfahrzeuge*. Berlin : Springer Verlag, 1972 Seite(n): [71](#)
- Mutambara 1998** MUTAMBARA, Arthur G. O.: Comparison of State and Information Based Sensor Fusion. In: *Proceedings of the SPIE Conference on Sensor Fusion and Decentralized Control in Robotic Systems* Bd. 3523, SPIE, November 1998, S. 67–75 Seite(n): [39](#)
- Nashashibi 2000** NASHASHIBI, F.: /Sup RT/m@ps: A Framework for Prototyping Automotive Multi-Sensor Applications. In: *Proceedings of the IEEE Intelligent Vehicles Symposium*. Dearborn, USA : IEEE - Institute of Electrical and Electronics Engineers, Inc., Oktober 2000, S. 99–103. – ISBN 0-7803-6363-9 Seite(n): [13](#)
- Obojski u. a. 2000** OBOJSKI, M. A. ; ROCH, H. ; VIVO, G.: Development and Test of Vehicles Based on the LACOS Concept: The Car Manufacturer Experience. In: *Proceedings of the IEEE Conference on Intelligent Transportation Systems*, IEEE - Institute of Electrical and Electronics Engineers, Inc., November 2000 Seite(n): [11](#)
- Papula 2001** PAPULA, Lothar: *Mathematik für Ingenieure und Naturwissenschaftler*. 4. Vieweg, 2001. – ISBN 3-528-34937-9 Seite(n): [49](#)

- Reid 1979** REID, D. B.: An algorithm for tracking multiple targets. In: *IEEE Transactions on Automatic Control* Bd. AC-24, IEEE - Institute of Electrical and Electronics Engineers, Inc., Dezember 1979, S. 843–854. – ISSN 0018-9286 Seite(n): [57](#), [58](#)
- Richards 1995** RICHARDS, P. W.: Constrained Kalman Filtering Using Pseudo-Measurements. In: *IEE Colloquium on Algorithms for Target Tracking*, IEEE - Institute of Electrical and Electronics Engineers, Inc., 1995, S. 75–79 Seite(n): [36](#), [37](#)
- Roecker und Phillis 1993** ROECKER, J. A. ; PHILLIS, G. L.: Suboptimal joint probabilistic data association. In: *IEEE Transactions on Aerospace and Electronic Systems* Bd. 29, IEEE - Institute of Electrical and Electronics Engineers, Inc., April 1993, S. 510–517. – ISSN 0018-9251 Seite(n): [53](#), [54](#), [56](#)
- Schmidt u. a. 2000** SCHMIDT, R. ; WEISSER, H. ; SCHULENBERG, P. ; GÖLLINGER, H.: Autonomous Driving on Vehicle Test Tracks: Overview, Implementation and Results. In: *Proceedings of the IEEE Intelligent Vehicles Symposium*. Dearborn, USA : IEEE - Institute of Electrical and Electronics Engineers, Inc., Oktober 2000, S. 152–155. – ISBN 0-7803-6363-9 Seite(n): [12](#)
- Simon und Chia 2002** SIMON, Dan ; CHIA, Tien L.: Kalman Filtering with State Equality Constraints, IEEE - Institute of Electrical and Electronics Engineers, Inc., Januar 2002, S. 128–136. – ISSN 0018-9251 Seite(n): [35](#)
- Singh und Bailey 1997** SINGH, R.-N.P. ; BAILEY, W. H.: Fuzzy logic applications to multisensor-multitarget correlation. In: *IEEE Transactions on Aerospace and Electronic Systems* Bd. 33, IEEE - Institute of Electrical and Electronics Engineers, Inc., Juli 1997, S. 752–769. – ISSN 0018-9251 Seite(n): [46](#)
- Stiller u. a. 1997** STILLER, C. ; PÖCHMÜLLER, W. ; HÜRTGEN, B.: Stereo Vision in Driver Assistance Systems. In: *Proceedings of the IEEE Conference on Intelligent Transportation Systems*. Boston, Massachusetts : IEEE - Institute of Electrical and Electronics Engineers, Inc., November 1997, S. 888–893. – ISBN 0-7803-4269-0 Seite(n): [8](#)
- Stüker und Schmidt 2003** STÜKER, Dirk ; SCHMIDT, Rolf: Potenzial optischer Sensoren zur Fahrumgebungserfassung. In: *VDI-Berichte 1731: Optische Technologien in der Fahrzeugtechnik*, VDI, Juni 2003, S. 41–50. – ISBN 3-18-091731-8 Seite(n): [2](#), [63](#)
- Valet u. a. 2000** VALET, L. ; MAURIS, G. ; BOLON, Ph.: A Statistical Overview of Recent Literature in Information Fusion. In: *Proceedings of the Third International Conference on Information Fusion* Bd. 1, IEEE - Institute of Electrical and Electronics Engineers, Inc., Juli 2000, S. MoC3-22–MoC3-29. – ISBN 2-7257-0000-0 Seite(n): [18](#)
- Vukotich und Kirchner 2001** VUKOTICH, A. ; KIRCHNER, Alexander: Sensor Fusion for Driver-Assistance-Systems. In: *Elektronik im Kraftfahrzeug*. Baden-Baden, Germany, 2001 Seite(n): [7](#), [11](#)

- Wada u. a. 2001** WADA, M. ; YOON, Kang S. ; HASHIMOTO, H.: Nonlinear Filter Road Vehicle Model Development. In: *Proceedings of the IEEE Conference on Intelligent Transportation Systems*, IEEE - Institute of Electrical and Electronics Engineers, Inc., August 2001, S. 734–739. – ISBN 0-7803-7194-1 Seite(n): 34
- Wan und der Merwe 2000** WAN, Eric A. ; MERWE, Rudoph V. der: The Unscented Kalman Filter for Nonlinear Estimation. In: *Proceedings of the Symposium on Adaptive Systems for Signal Processing, Communication and Control*, IEEE - Institute of Electrical and Electronics Engineers, Inc., Oktober 2000 Seite(n): 32
- Weiß 2003** WEISS, Kristian: Sensordatenfusion und adaptive Filterung für die Fahrumgebungserfassung zukünftiger Fahrerassistenzsysteme. In: *6. Magdeburger Maschinenbau-Tage: Intelligente technische Systeme und Prozesse*. Magdeburg, 24.- 26. September 2003 Seite(n): 41, 63
- Weiß u. a. 2003** WEISS, Kristian ; STÜKER, Dirk ; KIRCHNER, Alexander: Target Modelling and Dynamic Classification for Adaptive Sensor Data Fusion. In: *Proceedings of the IEEE Intelligent Vehicles Symposium*. Ohio : IEEE - Institute of Electrical and Electronics Engineers, Inc., Juni 2003 Seite(n): 15, 41, 63
- Weisser u. a. 1998** WEISSER, Hubert ; SCHULENBERG, Peter J. ; BERGHOLZ, Ralf ; LAGES, Ulrich: Autonomous Driving on Vehicle Test Tracks: Overview, Motivation, and Concept. In: *Proceedings of the IEEE Intelligent Vehicle Symposium 1998*. Stuttgart, Germany, 1998, S. 439–443 Seite(n): 12
- Willhoeft und Fuerstenberg 2001** WILLHOEFT, V. ; FUERSTENBERG, K.: Multilevel-Extension for Laserscanners. In: *Proceedings of the IEEE Conference on Intelligent Transportation Systems*, IEEE - Institute of Electrical and Electronics Engineers, Inc., August 2001, S. 446–450. – ISBN 0-7803-7194-1 Seite(n): 10
- Wu u. a. 2002** WU, Huadong ; SIEGEL, Mel ; STIEFELHAGEN, Rainer ; YANG, Jie: Sensor Fusion Using Dempster-Shafer Theory. In: *Proceedings of the IEEE Technology Conference on Instrumentation and Measurement*, IEEE - Institute of Electrical and Electronics Engineers, Inc., Mai 2002 Seite(n): 56
- Zhang u. a. 2002** ZHANG, Keshu ; LI, X. R. ; YUNMIN, Zhu: Optimal Update with Out-of-Sequence Measurements for Distributed Filtering. In: *Proceedings of the Fifth International Conference on Information Fusion* Bd. 2, IEEE - Institute of Electrical and Electronics Engineers, Inc., Juli 2002, S. 1519–1526. – ISBN 0-9721844-1-4 Seite(n): 23
- Zhao und Thorpe 1998** ZHAO, Liang ; THORPE, Charles: Qualitative and Quantitative Car Tracking from a Range Image Sequence. In: *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Santa Barbara, CA : IEEE - Institute of Electrical and Electronics Engineers, Inc., Juni 1998, S. 496–501. – URL [http://www.ri.cmu.edu/pubs/pub\\_544.html](http://www.ri.cmu.edu/pubs/pub_544.html) Seite(n): 46

# Sachregister

- Alle-Nachbarn-Verfahren, 51, 53
- ANIS, 40
- ARGO, 12
- Assoziation, 17
  - partielle, 120
- Assoziationsverfahren, 46
- Asynchrone Sensoren, 21
- Auktionsalgorithmus, 50, 52
- Autonomes Fahren, 12
  
- Base Point Error, 31
- Beobachtbarkeit, 75
  - lokale, 76
  - partielle, 113
  - vollständige, 75
- Beobachtbarkeitsmatrix, 75
- Beobachtung, 5
- Bildverarbeitung, 7
  - Mono, 7
  - Stereo, 8
  
- Carsense, 13
- Chameleon, 12
- CKF, 35
- Constrained Kalman-Filter, 35
  
- Dauerstrichradar, 9
- Dempster-Shafer, 50, 56
  
- Ein-Nachbar-Verfahren, 51
- Einfach-Hypothesen-Tracking, 50
- Einzelzielverfolgung, 5
- EKF, 29
- Erweitertes Kalman-Filter, 29
- Erweiterungsmatrix, 123
- Erweiterungsvektor, 123
  
- Filter-Adaption, 39
  
- Fusion, 5
  - kompetitive, 6
  - komplementäre, 6
  - kooperative, 7
  - parallele, 19
  - redundante, 6
  - sequenzielle, 20
- Fusionsebene, 15
- Fuzzy Kalman-Filter, 37
  
- Gate, 47
- gh-Filter, 24
  
- Hauptachsentransformation, 100
  - inverse, 102
  
- IMM, 43
- Information-Filter, 38
- Initialisierung, 18, 58
- Initialisierungsvektor, 116
- Innovation, 29
- Innovationskovarianz, 29
- Innovationsquadrat
  - normiertes, 40
- Integration, 18
- Interacting Multiple Model, 43
  
- Joint Probabilistic Data Association Filter, 54
- Jordan'scher Zerlegungssatz, 101
- JPDAF, 50, 54
  
- Kalman-Filter, 28
  - Constrained, 35
  - Erweitertes, 29
  - Fuzzy, 37
  - Smoothly Constrained, 36
  - Unscented, 31

- Kovarianzadaption
  - in beliebiger Raumrichtung, 100
- LACOS, 11
- Laser, 9
- Laserscanner, 10
- Lateral Control Support, 11
- Lineares stochastisches System, 25
- Mahalanobis-Abstand, 40, 49
- Mehrfach-Hypothesen-Tracking, 50, 57
- Mehrfach-Messwertprädiktion, 90
- Mehrstrahlaser, 10
- Mehrzielverfolgung, 5
- Messung, 5
- Messwertprädiktion, 17, 28
  - Mehrfach-, 90
- Minimal-Initialisierung, 115, 116
- Multi-Modell-Verfahren, 42
- Multiple Target Tracking, 5
- Multiple-Scan-Algorithmus, 57
- Munkres-Algorithmus, 50
- Nearest-Neighbour-Algorithmus
  - globaler, 51
  - iterativer, 51
- NIS, 40
- Normalized Innovation Squared, 40
- Normiertes Innovationsquadrat, 40
- Nächster-Nachbar-Algorithmus
  - globaler, 51
  - iterativer, 51
- Objektmodell, 5, 71
- Objektverfolgung, 5
- Observability matrix, 75
- Partielle Assoziation, 120
- PDAF, 50, 53
- Probabilistic Data Association Filter, 53
- Projektionsmethode, 35
- Pseudomesswerte, 36
- Pulsradar, 8
- Radar, 8
- Rauschanpassung, 40
- Rauschlevel-Umschaltung, 40
- Retrodiktion, 23
- Rohdaten, 17
- Schätzgrößenvektor, 121
- SCKF, 36
- Sensordatenfusion, 18
- Sensornetzwerk
  - asynchrones, 21
  - heterogenes, 6
  - homogenes, 6
  - synchrones, 19
- Single Target Tracking, 5
- Smoothly Constrained Kalman Filter, 36
- Suchbereich, 47
  - elliptisch, 49
  - rechteckiger, 48
- Synchrone Sensoren, 19
- Target Tracking, 5
- Trackverwaltung, 18, 59
- Truncation Error, 30
- Typ I-Fehler, 46
- Typ II-Fehler, 46
- UKF, 31
- Unimodalität, 42
- Unscented Kalman-Filter, 31
- Unscented Transformation, 31
- Variabler Zustandsraum, 41
- Varianzadaption, 40
- Verbundhypothese, 56
- Zero-Scan-Algorithmus, 57
- Zustandsbeschränkungen, 35
- Zustandserweiterung, 123
- Zustandsprädiktion, 17, 28
- Zustandsvektor
  - erweiterung, 122
  - reduzierter, 117
  - vollständiger, 117
- Zuweisungsverfahren, 50

# Lebenslauf

Dirk Stüker,

geboren am 20. Mai 1973 in Heessen, jetzt Hamm

08/79	-	07/83	Grundschule Selmigerheideschule in Hamm
08/83	-	06/92	Gymnasium Hammonense in Hamm, Abschluss Abitur
08/92	-	10/93	Zivildienst am Ev. Krankenhaus, Hamm
10/93	-	08/00	Studium der Informatik an der Carl-von-Ossietzky-Universität Oldenburg
01/92	-	12/98	Selbstständige Softwareentwicklung
10/96	-	02/97	Studienaufenthalt an der University of Exeter, England
07/98	-	05/99	Ausbildung zum Microsoft Certified Professional – Systems Engineer
02/00	-	08/00	Diplomarbeit in der Abteilung Prozessinformatik mit dem Titel: „Entwurf und Realisierung einer Architektur zur Steuerung autonomer Roboter in dynamischen Umgebungen“
seit		09/00	Mitarbeiter der Volkswagen AG, Elektronikforschung, Fahrerassistenzelektronik