




Filtersynthese zur simultanen Minimierung von Existenz-, Assoziations- und Zustandsunsicherheiten in der Fahrzeugumfelderfassung mit heterogenen Sensordaten

Mirko Mählich



Filtersynthese zur simultanen Minimierung von Existenz-, Assoziations- und Zustandsunsicherheiten in der Fahrzeugumfelderfassung mit heterogenen Sensordaten

DISSERTATION

zur Erlangung des akademischen Grades eines

**DOKTOR-INGENIEURS
(DR.-ING.)**


der Fakultät für Ingenieurwissenschaften
und Informatik der Universität Ulm

von

MIRKO MÄHLISCH
aus **KARL-MARX-STADT (heute Chemnitz)**

1. Gutachter: Prof. Dr.-Ing. Klaus C.J. Dietmayer, Universität Ulm
2. Gutachter: Prof. Dr.-Ing. Christoph Stiller, Universität Karlsruhe (TH)
Amtierender Dekan: Prof. Dr.-Ing. Michael Weber, Universität Ulm

Ulm, 25. August 2009



Diese Arbeit ist unter der Creative Commons Lizenz BY-NC-ND
(Namensnennung, nicht kommerziell, keine Bearbeitung), Version 3.0, lizenziert:
<http://creativecommons.org/licenses/by-nc-nd/3.0/de>

ISBN: 978-3-941543-03-4

Vorwort

Die vorliegende Dissertation entstand während meiner Zeit als wissenschaftlicher Mitarbeiter am Institut für Mess-, Regel- und Mikrotechnik der Universität Ulm.

Herrn Prof. Dr.-Ing. Klaus C.J. Dietmayer möchte ich für die Betreuung der Arbeit, die Schaffung einer äußerst modernen, angenehmen und motivierenden Arbeitsumgebung sowie für die Möglichkeit der Ergebnisvorstellung auf zahlreichen internationalen Fachkonferenzen danken.

Mein Dank für die freundliche Übernahme des Koreferates und das Interesse an meiner Arbeit gilt Herrn Prof. Dr.-Ing. Christoph Stiller vom Institut für Mess- und Regelungstechnik mit Maschinenlaboratorium (MRT) der Universität Karlsruhe (TH).

Für die vielen Diskussionen, die gemeinsamen Konferenzbesuche, die kollegiale Atmosphäre und die letztlich daraus entstandenen Freundschaften möchte ich mich stellvertretend für alle Kollegen des Instituts bei Thorsten Weiß, Dr. Stefan Wender, Michael Munz und Dr. Nico Kämpchen bedanken.

Ich danke Phillip Kaim, Rüdiger Hering, Andreas Wachtel, Michael Schwarz, Tobias Kauderer, Ulrich Probst und Stefan Reinhart für die wertvollen studentischen Beiträge zu dieser Arbeit.

Für die technische Unterstützung beim Aufbau des Versuchsträgers danke ich stellvertretend Herrn Franz Degenhard und Herrn Oliver Betz.

Meine Promotion auf dem in dieser Arbeit vorgestellten Thema wurde durch eine Drittmittelfinanzierung der Daimler AG ermöglicht. Ich danke Dr. Werner Ritter, Dr. Jürgen Dickmann, Dr. Ulrich Kreßel und Roland Schweiger für die fachliche und organisatorische Unterstützung während dieser Kooperation.

Besonders möchte ich mich bei meinen Eltern für ihre kontinuierliche Ermutigung und Unterstützung bedanken, ohne die diese Arbeit und der Weg bis dahin sicher nicht möglich gewesen wären.

Ulm, 16. Dezember 2009

Summary

Filter Synthesis for Simultaneous Minimization of Detection, Association, and State Uncertainties in Automotive Environment Perception with Heterogeneous Sensor Data

Future driver assistance systems with safety critical actuator interventions will depend on reliable environmental perception subsystems.

The presented work analyzes the classical system architecture for multi object environment perception consisting of separate modules for detection, data association, and state estimation with respect to early decision making and the usage of thresholds and heuristics. Within this common processing chain several intolerable error sources resulting from the improper handling of uncertainties and ambiguities are identified.

The reason behind these drawbacks is the inability of the state space model underlying recursive Bayesian state estimation to inherently represent all existing uncertainty domains in multi sensor multi target tracking. While coding state uncertainties with probability density functions this model cannot describe object existence uncertainties and data association ambiguities.

For the first time in an automotive context, a parametric knowledge representation based on Mahler's Random Finite Set Statistics (FISST) theory is used successfully. This approach allows the simultaneous representation of all three uncertainty domains in a single probabilistic knowledge base. For the chosen parametric model, the Multi-Object Multi-Bernoulli distribution on random sets, automotive transition and measurement models get developed. It is shown that under certain assumptions, the resulting FISST filtering equations correspond to the Joint Integrated Probabilistic Data Association Filter (JIPDAF) introduced by Mušicki et. al.

Instead of using a Poisson clutter distribution with the inadequate necessity of an a priori known occurrence rate of false positives, a non-parametric model is developed and incorporated in the filtering equations. In this model sensors assign an individual feature based false alarm probability to each measurement. As a result, the clutter model can automatically adapt to different situations like changing weather and daylight conditions or even to the exchange of sensors with different measurement principles without adjusting the central fusion unit's code or parameters.

The presented filter handles detection, data association and state estimation within a holistic algorithm and replaces the classical modularized system architecture. Particularly, the algorithm is free of early decisions, thresholds and heuristics for the price of an increased modelling effort. Besides the elimination of error sources, there is also the benefit of a less expensive optimization procedure due to the reduced number of system parameters.

Independent from FISST theory, the complex filtering equations are re-established using graph theory. A real-time capable implementation strategy utilizing complexity reduction techniques for the exponential run time behaviour is suggested. The work also analyzes the transmission behaviour of the JIPDAF from the model parameters and the data inputs to the existence probability output.

A prototype perception system based on the developed filtering techniques is demonstrated with a test vehicle setup consisting of one video and one lidar sensor. In addition to the JIPDA filter, other major system components like a sensor host vehicle motion estimation using inertial sensor data, a spatiotemporal sensor cross calibration procedure, and an object detection algorithm based on cascaded Adaboost classifiers are presented. The test car implementation of the prototype system is capable of detecting and tracking other cars up to distances of 200 meters regardless of whether they are moving or standing.

With the prototype system data the filter is checked for consistency in real traffic scenarios. A Receiver Operating Characteristics (ROC) study using manually tagged ground truth data based on the prototype system's sensor records reveals a superior perception performance of the JIPDAF outputs compared to the raw detections.

Inhaltsverzeichnis

Vorwort	v
Summary	vii
Inhaltsverzeichnis	ix
Symbolverzeichnis	xiii
1 Einleitung	1
1.1 Motivation	1
1.2 Technische Problemformulierung für die Fahrzeugumfelderfassung	3
1.3 Inhalt und Aufbau der Arbeit	6
2 Theoretische Grundlagen	7
2.1 Theorie der bayesschen Zustandsschätzung	7
2.1.1 Probabilistische Wissensrepräsentation für das Umfeldmodell	7
2.1.2 Informationsgehalt der Wissensbasis	8
2.1.3 Berechnung einer Wissensbasis aus unsicheren Messdaten für statische Systeme	10
2.1.4 Berechnung der Wissensbasis für dynamische Systeme	11
2.1.5 Extraktion von Schätzwerten aus einer probabilistischen Wissensbasis	14
2.2 Implementierungen der bayesschen Zustandsschätzung	15
2.2.1 Das Kalman-Filter	15
2.2.2 Das Extended-Kalman-Filter	18
2.2.3 Das Partikelfilter	18
2.2.4 Weitere bayessche Filteralgorithmen	22

2.3	Die klassische Systemarchitektur zur Verfolgung mehrerer Objekte	24
2.3.1	Objektdetektion und Segmentierung	24
2.3.2	Datenassoziation	27
2.3.3	Zustandsfilterung	30
2.3.4	Objektvalidierung und Objektmanagement	30
2.3.5	Diskussion und Kritik	33
3	Filterung auf Basis endlicher Zufallsmengen	37
3.1	Statistik für endliche Zufallsmengen	38
3.1.1	Metazustände und Metamessungen	38
3.1.2	Wissensrepräsentation mit Wahrscheinlichkeitsdichtefunktionen für endliche Zufallsmengen	38
3.1.3	Wahrscheinlichkeitsgenerierende Funktionale	40
3.1.4	Differentiationsregeln für endliche Mengen	40
3.2	Filteralgorithmen für endliche Zufallsmengen	41
3.2.1	Das Multiobjekt-Bayes-Filter	41
3.2.2	Funktionalformen der Multiobjekt-Bayes-Filtergleichungen	42
3.2.3	Transitionswahrscheinlichkeiten und Likelihood-Funktionen der Messung für endliche Zufallsmengen	43
3.2.4	Das integrierte probabilistische Datenassoziationsfilter	45
3.2.5	Das probabilistische Hypothesendichtefilter	46
3.2.6	Das kardinalisierte probabilistische Hypothesendichtefilter	47
3.2.7	Diskussion und Kritik	48
3.3	Das Multiobjekt-Multi-Bernoulli-Filter	50
3.3.1	Die Multiobjekt-Multi-Bernoulli-Verteilung	50
3.3.2	Prädiktion der Multiobjekt-Multi-Bernoulli-Verteilung	52
3.3.3	Innovation der Multiobjekt-Multi-Bernoulli-Verteilung	54
3.3.4	Die „Joint Integrated Probabilistic Data Association“ - Approximation	59
3.3.5	Eine graphentheoretische Interpretation und ein Implementierungsvorschlag für die JIPDA - Filtergleichungen	64
3.3.6	Komplexitätsbetrachtungen	70
3.3.7	Zustandsschätzer für eine Multiobjekt-Multi-Bernoulli-Wissensbasis . .	74

3.3.8	Implikationen für eine generische Sensorfusionsarchitektur	74
3.3.9	Diskussion, Kritik und Erweiterungsvorschläge	78
4	Ein multisensorielles Prototypsystem für ACC-Funktionen	83
4.1	Versuchsaufbau und Spezifikation der Umfeldsensorik	84
4.1.1	Ein qualitativer Vergleich zwischen Radar- und Lidarsensoren	84
4.1.2	Heterogene Sensordatenfusion	86
4.2	Sensorkalibrierung und Sensorsynchronisation	87
4.2.1	Koordinatendefinitionen	88
4.2.2	Lage- und Orientierungsbestimmung der Sensoren am Fahrzeug	89
4.2.3	Erweiterungen für Radarsensorik	95
4.2.4	Diskussion	98
4.3	Datenvorverarbeitung der Umgebungssensoren	100
4.3.1	Aufwandsreduktion durch Aufmerksamkeitssteuerung	100
4.3.2	Objektdetektion	107
4.4	Eigenbewegungsschätzung für das Sensorfahrzeug	112
4.4.1	Prozessmodellierung	112
4.4.2	Messmodellierung für das ESP-System	118
4.4.3	Filterung durch das Extended-Kalman-Filter	124
4.4.4	Optimierung und Evaluierung	126
4.4.5	Diskussion	130
4.5	Prozess- und Messmodellierung	131
4.5.1	Das Prozessmodell der Zustandsgrößen	131
4.5.2	Das Existenz-Prozessmodell	136
4.5.3	Die Zustandsmessmodelle	136
4.5.4	Messmodelle für die Existenzkomponente	139
4.5.5	Diskussion und Kritik	143
4.6	Beispielszenen zum Einsatz des Prototypsystems	144
5	Experimente	149
5.1	Das Übertragungsverhalten des JIPDA-Filters	149
5.1.1	Die Assoziationsdistanz	151

5.1.2	Die sensorische Falschalarmwahrscheinlichkeit der Messung	155
5.1.3	Die sensorische Detektionswahrscheinlichkeit	155
5.1.4	Die Persistenzwahrscheinlichkeit	156
5.2	Untersuchungen zur Effizienzsteigerung durch Hypothesenverwurf	158
5.3	Die Detektionsleistung des JIPDA-Filters	159
5.3.1	Versuchsumgebung	159
5.3.2	Ergebnisse	161
5.4	Ein Konsistenztest ohne Referenzdaten für Filterverfahren mit gewichteten Innovationen	164
5.4.1	Stand der Technik	164
5.4.2	Der NPCCS-Test	164
5.4.3	Ergebnisse	167
6	Zusammenfassung und Ausblick	171
6.1	Weiterführende Arbeiten	171
6.2	Resümee	174
A	Herleitungen	177
B	Errata	191
C	Literaturverzeichnis	193
C.1	Verwendete Literatur	193
C.2	Publikationen	201
C.3	Patente und Patentanmeldungen	204
C.4	Betreute Studien- und Diplomarbeiten	205

Symbolverzeichnis

Abkürzungen

ACC	Abstandsregeltempomat (engl. „Adaptive Cruise Control“)
AKF	Autokorrelationsfunktion, Autokorrelationsfolge
ASIL	Automotive Safety Integrity Level
BMF	Glaubwürdigkeitsfunktion (engl. „Belief Mass Function“)
CART	engl. „Classification and Regression Trees“
CCD	Charge-Coupled Device
CD	Committee Draft
CMOS	Complementary Metal–Oxide–Semiconductor
CPHD	kardinalisierte probabilistische Hypothesendichtefunktion (engl. „Cardinalized Probability Hypothesis Density“)
EAP	A-Posteriori Erwartungswert (engl. „Expected A-Posteriori“)
EKF	Erweitertes Kalman-Filter (engl. „Extended-Kalman-Filter“)
ESP	Elektronisches Stabilitätsprogramm
FIR	Ferninfrarot
FISST	Statistik für endliche Zufallsmengen (engl. „Finite Set Statistics“)
FMCW	frequenzmoduliertes Dauerstrichradar (engl. „Frequency Modulated Continuous Wave“)
FOV	Sichtbereich (engl. „Field-of-View“)
FWA	Flat-World-Assumption
GM	gaußsche Mischung (engl. „Gaussian Mixture“)
GPC	Ground-Plane Constraint
GPS	Global Positioning System
HMM	verborgenes Markov Modell (engl. „Hidden Markov Model“)
IMM	Interacting Multiple Model [61]
IMU	Messeinheit mit Inertialsensorik (engl. „Inertial Measurement Unit“)
IPDA	integrierte probabilistische Datenassoziation (engl. „Integrated Probabilistic Data Association“)
JIPDA	vereinheitlichte integrierte probabilistische Datenassoziation (engl. „Joint Integrated Probabilistic Data Association“)
JoTT	vereinheitlichte Zieldetektion- und Verfolgung (engl. „Joint Target-Detection and Tracking“)
JPDA	vereinheitlichte probabilistische Datenassoziation (engl. „Joint Probabilistic Data Association“)

LDS	Leistungsdichtespektrum
LIDAR	Light Detection and Ranging
LUT	Nachschlagetabelle (engl. „Lookup Table“)
LZI	linear zeitinvariant
MAP	Ereignis mit maximaler a-posteriori Wahrscheinlichkeit (engl. „Maximum A-Posteriori“)
MEMS	elektromechanisches Mikrosystem (engl. „Micro Electro Mechanical System“)
MHD	Mahalanobis-Distanz [52]
ML	Maximum Likelihood
MMBV	Multiobjekt-Multi-Bernoulli-Verteilung
MMSE	minimaler mittlerer quadratischer Fehler (engl. „Minimum Mean Squared Error“)
NEES	normiertes Schätzfehlerquadrat (engl. „Normalized Estimation Error Squared“)
NIR	Nahinfrarot
NIS	normiertes Innovationsquadrat (engl. „Normalized Innovation Squared“)
NN	Nearest Neighbor
NPCS	normiertes projiziertes Korrekturvektorquadrat (engl. „Normalized Projected Correction Squared“)
o.E.d.A.	ohne Einschränkung der Allgemeinheit
PDF	Wahrscheinlichkeitsdichtefunktion (engl. „Probability Density Function“)
PF	Partikelfilter
PHD	probabilistische Hypothesendichtefunktion
RADAR	Radio Detection and Ranging
ROC	Receiver Operating Characteristics
RTK	Realtime Kinematic
SMC	sequenzielle Monte-Carlo-Verfahren
SNN	Single Nearest Neighbor
SNR	Signal-zu-Rausch-Verhältnis (engl. „Signal To Noise Ratio“)
SPKF	Sigma-Punkt-Kalman-Filter
TBD	Verfolgung vor der Detektion (engl. „Track Before Detect“)
TOF	Flugzeit (engl. „Time of Flight“)
UKF	Unscented-Kalman-Filter
UTC	koordinierte Weltzeit (engl. „Coordinated Universal Time“)
WDF	Wahrscheinlichkeitsdichtefunktion
WGF	wahrscheinlichkeitsgenerierendes Funktional

Lateinische Buchstaben

$\ddot{y}$	Quereschleunigung
$\mathbb{1}^+(\cdot)$	Heaviside-Funktion
A	Systemmatrix
B	Eingangsmatrix

D	Durchgriff
E	Eigenvarianzmatrix
F	Transitionsmatrix
G	Gewichtsmatrix
H	Messmatrix
K	Kalman-Verstärkung
P	Schätzfehlerkovarianz
p	Parametervektor
Q	Kovarianz des Prozessrauschens
R	Kovarianz des Messrauschens
S	Innovationskovarianz
u	Steuereingang
v	Prozessrauschvektor
w	Messrauschvektor
x	Zustandsvektor
y	Differenzmessung
z	Messvektor
$\mathcal{N}(\mathbf{x}, \boldsymbol{\mu}, \boldsymbol{\Sigma})$	Dichtefunktion der Normalverteilung mit Mittelwertvektor $\boldsymbol{\mu}$ und Kovarianz $\boldsymbol{\Sigma}$ an der Stelle $\mathbf{x}$
$\mathcal{U}(\cdot)$	Dichtefunktion der Gleichverteilung (auch uniforme Verteilung)
$\mathbf{1}_S(\cdot)$	Indikatorfunktion der Menge S
Z	Messwerthistorie
<i>A</i>	Amplitude, Stellsignalmenge für die Aktorik
<i>a</i>	Tangentialbeschleunigung
<i>c</i>	Anzahl der Falschalarme
$c(\mathbf{z})$	Dichtefunktion der Falschalarme im Messraum
c_i, c_j	Bildkoordinaten des optischen Zentrums in Pixel
$D(\mathbf{x})$	probabilistische Hypothesendichtefunktion
$D_{EUK}(\cdot, \cdot)$	euklidischer Abstand
$D_{MH}(\cdot, \cdot)$	Mahalanobis-Distanz
$E_p\{\cdot\}$	Erwartungswert des Arguments bezüglich der Dichtefunktion p
$f(\mathbf{x})$	Transitionsfunktion
$f_{\chi^2}^d(\cdot, n)$	Zähldichtefunktion der χ^2 -Verteilung mit n Freiheitsgraden
f_i, f_j	horizontale und vertikale Brennweiten in Pixel
$f_{\chi^2}(\cdot, n)$	Dichtefunktion der χ^2 -Verteilung mit n Freiheitsgraden
$g(\mathbf{z})$	Testfunktion im Messraum
$h(\mathbf{x})$	Messfunktion, Testfunktion im Zustandsraum
$h(\tau), h(\kappa)$	Impulsantwort
$H(j\omega), H(s), H(z)$	Übertragungsfunktion
$H[p]$	Entropie-Funktional der Wahrscheinlichkeits(dichte)funktion p
$h_r(\cdot)$	relative Häufigkeit des Arguments
<i>i</i>	horizontale Bildposition in Pixel
<i>j</i>	vertikale Bildposition in Pixel
$J[p]$	Negentropie-Funktional der Wahrscheinlichkeits(dichte)funktion p
<i>K</i>	Verstärkungsfaktor

k	diskreter Zeitindex
$L(\cdot)$	Leistungsübertragungsfunktion
l_R	Radstand
l_S	Spurbreite
N	Anzahl der Messungen
o	systematischer Fehler (Offset)
$p(\cdot)$	Wahrscheinlichkeit des Ereignisses
$Q_{\chi^2}(p, n)$	p-Quantil der χ^2 -Verteilung mit n Freiheitsgraden
r	euklidische Distanz, Abstand, Radius in Polarkoordinaten
R_{HL}, R_{HR}	Raddrehzahlen (HL: hinten-links, HR: hinten-rechts)
R_{VL}, R_{VR}	Raddrehzahlen (VL: vorne-links, VR: vorne-rechts)
$S(\cdot)$	Leistungsdichtespektrum
t	kontinuierliche Zeit
T_S	Abtastperiode
t_x, t_y, t_z	Verschiebungen in Richtung der Koordinatenachsen
u	Eingangs- oder Anregungssignal
U_R	Radumfang
v	Tangentialgeschwindigkeit
w	Gewicht, Objektbreite
z	Integrationsvariable der z-Transformation, skalarer Messwert

Griechische Buchstaben

α	Dekorrelations- oder Dämpfungskoeffizient
$\alpha_x, \alpha_y, \alpha_z$	Drehwinkel um die Koordinatenachsen
$\beta(S)$	Glaubwürdigkeitsfunktion
β_{vj}	Assoziationsgewicht
γ	Innovationsvektor (auch Residuum)
$\chi^2(\cdot, n)$	Chi-Quadrat-Verteilungsfunktion mit n Freiheitsgraden
$\ddot{\varphi}$	Gierbeschleunigung
δ	Seitenverhältnis Breite zu Höhe
$\delta_{\mathbf{y}}(\mathbf{x})$	Dirac-Stoß an der Stelle $\mathbf{y}$
δ_{ij}	Kronecker-Delta-Funktion
$\dot{\varphi}$	Gierrate
ϵ	normiertes Schätzfehlerquadrat (engl. „Normalized Estimation Error Squared“)
ϵ^ν	normiertes Innovationsquadrat (engl. „Normalized Innovation Squared“)
η	Objektexistenzrate, Erwartungswert der Objektanzahl
$\gamma(\mathbf{x})$	Transitionsfunktion für das Objekt $\mathbf{x}$
$\Gamma(X)$	Transitionsoperator für die endliche Zufallsmenge der Objekte
κ	diskrete Zeitverschiebung
λ	Falschalarmrate
$\Lambda_z(\cdot)$	Likelihood-Funktion der Messung z
μ	Objektentstehungsrate

Ω	normierte Kreisfrequenz (Radiant pro Messperiode)
ω	zeitbezogene Kreisfrequenz (Radiant pro Sekunde)
ω_0	Eigenfrequenz
$\phi(\tau), \phi(\kappa)$	Autokorrelationsfunktion, Autokorrelationsfolge
σ	Standardabweichung
σ^2	Varianz
τ	kontinuierliche Zeitverschiebung
$\Upsilon(X)$	Detektionsoperator für die endliche Zufallsmenge der Objekte
$\varepsilon(\mathbf{x})$	Epsilon-Umgebung um $\mathbf{x}$
φ	Orientierungswinkel, Azimuthwinkel in Polarkoordinaten
ϱ	Mahalanobisdistanz-Schwellwert für die Assoziationstore (sog. „Gating“-Parameter)
ϑ	Elevationswinkel des 3D-Polarkoordinatensystems

Integraltransformationen

$\mathcal{F}\{\cdot\}$	Operator für die (diskrete) Fourier-Transformation
$\mathcal{G}\{\cdot\}$	wahrscheinlichkeitsgenerierendes Funktional
$\mathcal{L}\{\cdot\}$	Operator für die Laplace-Transformation
$\mathcal{Z}\{\cdot\}$	Operator für die z-Transformation

Indizes für Koordinatensysteme

BK	kartesisches Bildkoordinaten
FK	kartesisches Fahrzeugkoordinaten
KK	kartesisches Kamerakoordinaten
LK	kartesisches Lidarkoordinaten
LP	polare Lidarkoordinaten
MK	kartesisches Markerkoordinaten
OK	kartesisches Objektkoordinaten
RK	kartesisches Radarkoordinaten
RP	polare Radarkoordinaten
SK	kartesisches Straßenkoordinaten

Spezielle Mengen

$\mathbb{X}$	Menge aller Zustandsvektoren (Zustandsraum)
$\mathbb{Z}$	Menge aller Messvektoren (Messraum)
$\mathbb{R}$	Menge der reellen Zahlen
C	Menge der Falschalarme (engl. „Clutter“)
DO	Menge der existierenden und detektierten Objekte (engl. „Detected Objects“)

FN	Menge der nicht detektierten Objekte (engl. „False Negatives“)
S	beliebige Teilmenge des Zustandsraumes
TN	Menge der nicht existierenden Objekte (engl. „True Negatives“)
V	Menge der Objekthypothesen des Umfeldmodells
X	endliche Zufallsmenge der Objekte im Zustandsraum
Z	endliche Zufallsmenge der Messwerte

Spezielle Wahrscheinlichkeiten

$\mathcal{N}_i^j(\mathbf{x})$	normalverteilte sensorische Likelihood des Objektzustandes $\mathbf{x}$, gegeben die Messung $\mathbf{z}^j$
$\mathcal{N}_{k k-1}^v(\mathbf{x})$	normalverteilte a-priori Aufenthaltswahrscheinlichkeitsdichtefunktion der v -ten Objekthypothese des Umfeldmodells
$\mathcal{N}_{k-1 k-1}^v(\mathbf{x})$	normalverteilte a-posteriori Aufenthaltswahrscheinlichkeitsdichtefunktion der v -ten Objekthypothese des Umfeldmodells im vorherigen Zeitschritt
$\mathcal{N}_t(\mathbf{x})$	normalverteilte Transitionswahrscheinlichkeit
$\mathcal{N}_{\varrho\sigma}(\mathbf{x})$	Normalverteilung, die außerhalb des ϱ -Sigma-Hyperellipsoiden zu Null gesetzt und zu einer WDF renormiert wird (auch: „gesockelte Normalverteilung“)
$p^D(\mathbf{x})$	Detektionswahrscheinlichkeit
$p^F(\mathbf{z}_j)$	sensorische Falschalarmwahrscheinlichkeit der Messung $\mathbf{z}_j$
$p^G(\cdot)$	allgemeine Generatorwahrscheinlichkeit
$p^P(\mathbf{x})$	Persistenzwahrscheinlichkeit
$p^S(\mathbf{x})$	Teilungswahrscheinlichkeit (engl. „Spawning“)
$p^T(\mathbf{x}_k \mathbf{x}_{k-1})$	Transitionswahrscheinlichkeit
$p^{\exists,v}$	Existenzwahrscheinlichkeit des Objektes v des Umfeldmodells

Schreibweisen

$\langle a, b \rangle$	inneres Produkt der Vektoren a und b (auch: Skalarprodukt)
$\text{rang}(\cdot)$	Rang einer Matrix
$\mathbf{y} \sim p(\mathbf{y})$	Die Zufallsvariable $\mathbf{y}$ ist nach der Dichtefunktion p verteilt
$D_{KL}[g h]$	Kullback-Leibler-Distanz der Funktionen g und h
$p(X) \circ\!\!\!\bullet G_p[h]$	Transformation der FISST-Wahrscheinlichkeitsdichtefunktion $p(X)$ in das wahrscheinlichkeitsgenerierende Funktional $G_p[h]$.
$q(x) = 1 - p(x)$	Wahrscheinlichkeit des Komplements des Ereignisses x (Gegenereignis)
$rd(\cdot)$	Rundungsoperator
$\text{sup}(f(\cdot))$	Träger der Funktion f (engl. „support“), Teilmenge des Definitionsbereichs für die f ungleich Null ist

Kapitel 1

Einleitung

1.1 Motivation

Neben alternativen Antriebskonzepten sind heute Fahrerassistenzsysteme und integrierte Sicherheitssysteme die entscheidenden Innovationsfelder in der Automobilindustrie. Seit der Einführung der ersten Abstandsregeltempomaten auf Basis vorausschauender Sensoren im Jahr 1998 hat die Komplexität der Assistenzfunktionen und der unterlegten elektronischen Systeme stark zugenommen. Mittlerweile sind zusätzlich automatische Einparksysteme, Nachtsichtassistenten auf Infrarotbasis, automatische Fernlichtsteuerungen, automatische Verkehrszeichenerkennung, Kollisionswarner, Notbremssysteme zur Kollisionsvermeidung und Unfallfolgenminderung, umfeldsensorisch ausgelöste oder vorkonfigurierte Insassenschutzsysteme sowie Spurhalteassistenten und Spurverlassenswarner in vielen Fahrzeugen verfügbar.

Bereits heute basieren einige dieser Systeme auf mehreren heterogenen Sensortechnologien. Zukünftige Fahrerassistenzsysteme werden im zunehmenden Maße auf Algorithmen zur Sensordatenfusion aufbauen, um die notwendige Komplexität und Informationsfülle der Umfeldbeschreibung bereitzustellen oder um aus Sicherheitsgründen einen gewissen Grad an sensorischer Redundanz zu realisieren.

Generische Sensordatenfusion

Auf dem Markt finden sich heute zwei Ausprägungen von Sensorfusionssystemen. Sogenannte „One-Box“-Systeme (z.B. [1]) bringen sowohl die Sensormodule als auch die Verarbeitungseinheit zur Fusion und Funktion in einem Gehäuse unter. Durch die hohe Integration bieten sich hier Kosten- und Bauraumvorteile. Im Premiumsegment werden dagegen separate Fusions- und Funktionssteuergeräte verwendet, die mit den Sensoren über eine Netzwerkarchitektur kommunizieren. Aus Sicht der Automobilhersteller ergeben sich durch die Flexibilität bei der Auswahl der Sensorkonfiguration Vorteile bei der Wettbewerbsdifferenzierung. Zusätzlich entstehen Vorteile bei der Wertschöpfung durch die Fusions- und Funktionskomponente.

Die Algorithmen zur Datenfusion sind in heutigen Implementierungen sensor- und funktions-spezifisch ausgelegt. Wenn diese Abhängigkeiten überwunden werden könnten, also ein und

der selbe generische Fusionsalgorithmus für verschiedene Sensorkonfigurationen und Funktionen zur Verfügung stünde, würden sich zusätzliche Vorteile durch eine Reduzierung der Entwicklungs- und Absicherungsaufwände ergeben. Weiterhin könnte ein solches System einen maßgeblichen Beitrag zur schnellen und effizienten Kaskadierung von Fahrerassistenzsystemen durch die verschiedenen Baureihen eines Automobilherstellers leisten.

Aus betriebswirtschaftlicher Sicht sollten daher Algorithmen zur Sensorfusion in der Fahrzeugumfelderfassung auf eine hohe Wiederverwendbarkeit mit verschiedenen Sensoren und Sensorkombinationen ohne Softwareänderungen ausgelegt werden, um eine Gleichteilstrategie eventuell in der Hardware, auf jeden Fall aber in der Software, zu ermöglichen.

Sicherheitsanforderungen für zukünftige Fahrerassistenzsysteme

Zukünftige Fahrerassistenzsysteme werden verstärkt sicherheitskritische Eingriffe ausführen. Während bei Komfortsystemen, wie den Abstandsregeltempomaten, den Nachtsichtassistenten oder der Verkehrszeichenerkennung, informierende oder warnende Ausgaben bzw. leicht zu übersteuernde Eingriffe erfolgen, werden zukünftige integrierte Sicherheitssysteme entweder massive aktorische Interventionen in die Fahrzeugführung vornehmen oder aber in so kurzen Zeitskalen ablaufen, dass Korrekturen des Fahrers unmöglich werden. In diesem Fall wird die Wiener Straßenverkehrskonvention [89] §8 Abs. 5 tangiert:

„Every driver shall at all times be able to control his vehicle or to guide his animals.“

In der Zukunft sind auch Systemauslegungen des autonomen Fahrens denkbar, bei denen keine permanente auf den Verkehr gerichtete Aufmerksamkeit des Fahrers mehr gefordert wird. Im Fall einer nicht maschinell auflösbaren Problemsituation würde während der Übergabezeit an den möglicherweise abgelenkten Fahrer ebenfalls ein Konflikt mit der Wiener Straßenverkehrskonvention entstehen.

Im unbedingt zu vermeidenden Fall von Systemfehlern jeder Art sind bei den genannten Systemen schwerwiegende Folgen für Leib und Leben des Fahrers und der anderen Verkehrsteilnehmer nicht ausgeschlossen. Insofern stellen derartige Funktionen offene Fragen an die Rechtsprechung und die Produkthaftung. Ohne Zweifel ist für diese Systeme aber ein besonders sorgfältiger Entwicklungs- und Herstellprozess notwendig, der durch die gerade entstehende ISO 26262 („Road Vehicles – Functional Safety“, [36], Status: „Committee Draft“, CD) standardisiert werden soll. Bezüglich der Kritikalität eines Systems legt die ISO 26262 drei Kriterien fest. Die Tabellen 1.1, 1.2 und 1.3 zeigen die verschiedenen Systemklassifizierungen hinsichtlich des Schweregrades einer möglichen Verletzung, der Beherrschbarkeit durch den Fahrer und der Fehlerhäufigkeit.

Ist ein System nach jedem dieser Kriterien eingestuft, erfolgt eine Zuordnung in eines der vier „Automotive Safety Integrity Level“ (ASIL). Für Systeme auf dem niedrigsten Level ASIL-A (z.B.: E1-C0-S0) genügen dann herkömmliche Qualitätssicherungsstandards während der Entwicklung und Produktion. Im höchsten Level ASIL-D (z.B.: E4-C3-S3) muss das System den anspruchsvollsten Kriterien bezüglich beispielsweise Daten- & Algorithmenredundanz, Dokumentation, formaler Verifikation, Mess- & Bauteiltoleranzen, Selbstdiagnosefähigkeiten, „Design-Reviewing“, Komponententests und anderen genügen.

Tabelle 1.1: Schweregrad der Verletzung, Auszug ISO/CD 26262-3 6.4.4.2

Klasse	S0	S1	S2	S3
Beschreibung	keine Verletzungen	leichte und moderate Verletzungen	schwere und lebensbedrohliche Verletzungen (Überleben wahrscheinlich)	lebensbedrohliche und tödliche Verletzungen (Überleben unsicher)

Tabelle 1.2: Fehlerhäufigkeit, Auszug ISO/CD 26262-3 6.4.4.3

Klasse	E1	E2	E3	E4
Beschreibung	sehr niedrige Wahrscheinlichkeit	niedrige Wahrscheinlichkeit	mittlere Wahrscheinlichkeit	hohe Wahrscheinlichkeit

Tabelle 1.3: Beherrschbarkeit durch den Fahrer, Auszug ISO/CD 26262-3 6.4.4.4

Klasse	C0	C1	C2	C3
Beschreibung	immer beherrschbar	leicht beherrschbar	normal beherrschbar	schwer beherrschbar oder unbeherrschbar

Die Kriterien der Verletzungsschwere und der Beherrschbarkeit durch den Fahrer sind maßgeblich von der Funktionsauslegung und der Art des Aktoreingriffs bestimmt. Im Kriterium der Fehlerhäufigkeit stellt die Fahrzeugumfelderfassung jedoch unabhängig von der konkreten Funktion eine kritische Komponente dar:

*„Die schwierigere Aufgabe [als Fehler im Herstellprozess zu vermeiden] liegt darin, die Umgebungserfassung so zu entwickeln, **dass mögliche Fehler bzw. Unzulänglichkeiten erkannt werden**, so dass eine fehlerhafte Reaktion verhindert werden kann. Die ISO 26262 gibt keinerlei Anforderungen an die Performance einer Funktion.“*

Dr. Jürgen Schwarz, Risikobewertung als Grundlage zur Verantwortung, 2008

Es müssen daher wesentliche Ziele des Entwurfs von Algorithmen zur Fahrzeugumfelderfassung sein, Fehlerquellen in der Verarbeitungskette zu erkennen, zu eliminieren und eine Fähigkeit zur Selbstdiagnose, also ein Fehlerbewusstsein im System zu schaffen. Damit können eventuelle Unzulänglichkeiten und Mehrdeutigkeiten bei der sensorischen Umfelderfassung erkannt und Reaktionen ausgeschlossen werden, die auf ungenügender und damit fehleranfälliger Sensorinformation basieren.

1.2 Technische Problemformulierung für die Fahrzeugumfelderfassung

Unabhängig von der zu realisierenden Assistenzfunktion ist die dazu notwendige Datenverarbeitung eine während des Betriebs ständig neu zu berechnende Abbildung f von Sensordatenströmen $\mathbf{Z}_{1:k} = \{\mathbf{z}_1, \dots, \mathbf{z}_k\}$ auf Aktionen $A = \{a_1, \dots, a_m\}$:

$$f : \mathbf{Z}_{1:k} \longrightarrow A. \quad (1.1)$$




Abbildung 1.1: Datenverarbeitungskette für Fahrerassistenzsysteme.

Dabei können die Messvektoren $\mathbf{z}_k$ Daten der im Fahrzeug verbauten Umgebungs-, Inertial- und Innenraumsensoren sowie drahtlos kommunizierte Umfeldinformationen anderer Fahrzeuge oder der Infrastruktur enthalten. Bei invasiven Funktionen beinhaltet die Menge der Aktionen A die Stellsignale für die Aktorik. Für die informierenden und warnenden Assistenzfunktionen entspricht die Aktionsmenge einer haptischen, akustischen oder visuellen Informationsübermittlung an den Fahrer.

Die direkte Angabe einer derartigen Abbildung f erweist sich als schwierig. Angelehnt an die vermutete Arbeitsweise des menschlichen Gehirns [87] wird deshalb eine symbolische Zwischenschicht verwendet, welche die Sensordaten zu einem dynamischen Fahrzeug-, Fahrer- und Umfeldmodell abstrahiert. Das Umfeldmodell beinhaltet die Typen, Positionen und Dynamikdaten der für die Funktion relevanten anderen Verkehrsteilnehmer sowie die Lage der Straße zum Sensorfahrzeug. Der dynamische Zustand des Fahrzeugs ist im Fahrzeugmodell abgebildet. Das vollständige Fahrermodell beinhaltet das typische Fahrverhalten und eine Intentions-, Konditions- und Aufmerksamkeitserkennung. Die Aktionen können dann durch eine Situationsanalyse auf Basis dieser Modelle, also der Interpretation und Bewertung der Verkehrskonstellation auf einer höheren Abstraktionsebene, abgeleitet werden (Abbildung 1.1). Eingeschränkte Funktionen sind mit einer Teilmenge dieser Module realisierbar, aber komplexe Umgebungen wie stark frequentierte Kreuzungen und intelligente Funktionen, wie zum Beispiel die maschinelle Realisierung des „vorausschauenden Fahrens“, erfordern alle Komponenten.

Diese Arbeit und das hier vorgestellte Prototypsystem befassen sich ausschließlich mit der Signalverarbeitung zur Umgebungserfassung und Fahrzeugmodellierung. Das mathematische Werkzeug zur Erstellung dieser Modelle ist die Parameter- und Zustandsschätzung für eine unbekannte endliche und veränderliche Anzahl von Objekten aus unsicheren und mehrdeutigen Messdaten. Es soll zunächst der Begriff der Unsicherheit für die Messdaten näher spezifiziert werden.

Solange nicht alle Verkehrsteilnehmer mit RFID-Transpondern oder anderen drahtlosen Kommunikationseinrichtungen ausgestattet sind, müssen mit der für automotiv Anwendungen verfügbaren Sensortechnologie drei verschiedene Typen von Unsicherheiten in der Objektsensierung unterschieden werden. Obwohl es sich im zivilen Straßenverkehr um ein kooperatives Umfeld handelt, stellt sich zunächst das Problem der Detektionsunsicherheit, da alle in automotiv

tiven Anwendungen verwendeten Sensortechnologien, wie Video, Radar, Lidar und Ultraschall, Fehldetektionen und Falschdetektionen von Objekten aufweisen.

Die Ursachen für Falschdetektionen liegen bei Radarsensoren beispielsweise in Mehrwegeausbreitungseffekten oder atmosphärischen Störungen und bei der Lidar-Technologie in Dunst- und Staubwolken. Für kamerabasierte Sensorik können Hintergrundmuster mit temporären Ähnlichkeiten zu den gesuchten Objekten oder Fehlkorrespondenzen und repetitive Muster [46] bei Stereo- und Flussalgorithmen [43] die Ursache für Falschdetektionen sein. Fehldetektionen entstehen bei Lidar-Sensoren z.B. durch ungünstige Einfallswinkel auf das vermessene Objekt oder durch temporäre Nickbewegungen des Sensorfahrzeuges. Bei Videosensoren können zum Beispiel temporär ungünstige Beleuchtungsverhältnisse für Fehldetektionen verantwortlich sein.

Die Detektionsunsicherheit ergibt sich somit aus der Tatsache, dass bei allen Sensortechnologien Messungen nicht zwingend von real existierenden Objekten hervorgerufen werden müssen und reale Objekte existieren können, obwohl die Sensoren keine Messdaten erfasst haben. Die zweite Unsicherheitsdomäne ist die der gemessenen Zustandsgrößen und Parameter, wie Positionen, Geschwindigkeiten, Drehraten und Abmessungen. Sie resultiert aus den Messfehlern der Sensoren, für die beispielsweise Diskretisierungsfehler bei Zeit- und Amplitudenmessungen ursächlich sind. Die dritte Unsicherheitsdomäne, die Assoziationsunsicherheit, steht im Zusammenhang mit den beiden ersten Unsicherheitsdomänen. Durch die Messfehler und die Detektionsunsicherheit ist die Zuordnung zwischen Messdaten und Objektrepräsentationen im Umfeldmodell im Allgemeinen nicht eindeutig, das heißt es existieren mehrere wahrscheinliche disjunkte Zuordnungshypothesen.

Die Fahrzeugumfelderfassung ist somit ein Beobachter der Objektzustände des Fahrzeugumfeldes, der diese drei Unsicherheiten simultan minimiert.

„Modellfreie“ Umgebungserfassungssysteme

Abzugrenzen von der Umfelderfassung in diesem Sinne sind Signalverarbeitungsverfahren, die lediglich die Sensordaten in eine andere Repräsentation transformieren, ohne dabei die Sensordaten auf die oben beschriebene semantische Zwischenebene des Umfeldmodells zu heben.

Die Berechnung des optischen Flusses, das Erstellen eines Stereo-Korrespondenzbildes oder die zeitliche Akkumulierung von Abstandsmessungen sind demnach keine Algorithmen zur Umfelderfassung, sondern Transformationsvorschriften für die Eingabedaten in einen Merkmalsraum, der erwartungsgemäß eine verbesserte Objektextraktion ermöglicht, die aber im Nachgang immer noch stattfinden muss, damit das Ergebnis für eine Assistenzfunktion verwendbar wird. Die Extraktion von typisierten Objekten muss dabei nicht unbedingt den verschiedenen Klassen von Verkehrsteilnehmern (PKW, LKW, Fußgänger, ...) entsprechen, sondern kann lediglich eine Unterscheidung zwischen „relevant“ und „irrelevant“ oder zwischen „existent“ und „nicht existent“ bedeuten. Auch können direkt Situationen wie „Fahrkorridor frei“ oder „Hindernis im Weg“ erkannt werden.

Es können aber keine sogenannten „modellfreien“ Umgebungserfassungssysteme existieren, da die originären oder transformierten Sensordaten immer auf ein Umfeldmodell, eine Situation

oder eine Aktion abgebildet werden müssen. Diese Abbildung kann nur mit Vorwissen, also einem Modell verwirklicht werden, das die Erscheinungsform der interessierenden Objekte oder Situationen in den eventuell transformierten Sensordaten beschreibt. Der wirkliche Vorteil der beschriebenen Verfahren besteht mithin nicht in ihrer vermeintlichen Modellfreiheit, sondern in der Möglichkeit, nach der Transformation der Daten sehr einfache Modelle und Heuristiken im Vergleich zur ursprünglichen Sensordatenrepräsentation erfolgreich anwenden zu können.

1.3 Inhalt und Aufbau der Arbeit

Die Umfelderkennung und Fahrzeugmodellierung wird im Rahmen dieser Arbeit am Beispiel eines intelligenten ACC- und Notbremssystems der nächsten Generation ausgelegt. Dabei sollen Fahrzeuge auf Autobahnen und Landstraßen erkannt und verfolgt werden. Im Gegensatz zu heute verfügbaren Systemen sollen auch Fahrzeuge auf benachbarten Fahrspuren verfolgt und dauerhaft stehende Fahrzeuge in großen Distanzen erkannt werden. Diese Erkennung muss in Reichweiten von über 150 Metern gewährleistet sein, damit auch bei hohen Differenzgeschwindigkeiten, zum Beispiel beim Auffahren auf ein Stauende, genug Zeit für eine komfortable Reaktion bleibt. Zusätzlich müssen die Objektrepräsentationen des Umfeldmodells hochgenaue Positions- und Geschwindigkeitsangaben beinhalten, damit eine aussagekräftige Prädiktion der Verkehrsszene in die Zukunft für die nachfolgende Situationsanalyse ermöglicht wird. Letztlich ist die Robustheitsanforderung offensichtlich, da die gesundheitlichen, materiellen und rechtlichen Konsequenzen einer Vollbremsung auf ein nicht vorhandenes aber fälschlicherweise erkanntes Objekt unabsehbar sind.

Nach der Einleitung rekapituliert Kapitel 2 die theoretischen Grundlagen der dynamischen Zustandsschätzung. Weiterhin wird die auf diesen Werkzeugen beruhende klassische Systemarchitektur zur Umfelderkennung unter Detektions-, Assoziations- und Zustandsgrößenunsicherheit beschrieben und kritisch analysiert. Aus der Kritik am herkömmlichen Vorgehen leitet Kapitel 3 unter Zuhilfenahme der Schätztheorie für endliche zufällige Mengen ein Filterverfahren ab, das die festgestellten Probleme eliminiert. Im Anschluss beschreibt Kapitel 4 ein Prototypensystem, das aus einem Video- und einem Lidarsensor besteht und das vorgeschlagene Filterverfahren verwendet. Das Kapitel 5 analysiert das Filterverfahren anhand simulierter Experimente und belegt die Funktionsfähigkeit des Gesamtsystems und die Steigerung der Erkennungsperformanz durch die vorgeschlagenen Verfahren anhand realer Sensordaten.

Kapitel 2

Theoretische Grundlagen

Dieses Kapitel gibt einen kompakten Überblick über die Grundlagen der Schätztheorie und deren Verwendung zur Zustandsschätzung in dynamischen Systemen. Aufbauend auf diesen Grundlagen wird die klassische Architektur für Wahrnehmungssysteme unter Existenz-, Assoziations- und Zustandsgrößenunsicherheit vorgestellt.

2.1 Theorie der bayesschen Zustandsschätzung

2.1.1 Probabilistische Wissensrepräsentation für das Umfeldmodell

Sind die das Umfeld beschreibenden Größen zeitinvariant, wie z.B. die Abmessungen von Fahrzeugen, spricht man von Parametern. Zeitvariante Größen wie Positionen und Geschwindigkeiten werden als Zustände bezeichnet. Im Folgenden wird jedoch für beide Fälle vereinfachend der Begriff Zustand verwendet.

Zur Wissensrepräsentation wird der tatsächliche Wert des unbekannten Zustands x als Realisierung eines Zufallsprozesses aufgefasst. Der Ereignishorizont X ist die Menge aller möglichen elementaren Ausgänge x des Zufallsexperiments. Im diskreten Fall, zum Beispiel bei einer Detektions- oder Klassifikationsaufgabe, sind folgende Ereignishorizonte in der Fahrzeugumfelderfassung gebräuchlich:

$$\text{Detektion: } X = \{\text{„relevantes Objekt“}, \text{„Hintergrund“}\}, \quad (2.1)$$

$$\text{Klassifikation: } X = \{\text{„PKW“}, \text{„LKW“}, \text{„Fußgänger“}, \text{„Zweirad“}, \text{„unbekannt“}\}. \quad (2.2)$$

Das unscharfe Wissen über die sensorisch erfasste Realität wird durch eine Zuordnung von Wahrscheinlichkeitswerten $p : x \rightarrow p(x)$, $x \in X$ charakterisiert, die die Kolmogorov-Axiome erfüllt:

$$0 \leq p(x) \leq 1 \quad (2.3)$$

$$p\left(\bigcup_x x\right) = 1 \quad (2.4)$$

$$x \cap y = \emptyset \implies p(x \cup y) = p(x) + p(y). \quad (2.5)$$

In Anwesenheit der oben beschriebenen sensorischen Unsicherheiten wird somit die Existenzunsicherheit und das unscharfe Wissen über den Objekttyp durch Angabe einer Zähldichtefunktion p (engl. „Probability Mass Function“, PMF) für diskrete Ereignismengen, wie (2.1) und (2.2), mathematisch repräsentiert. Bei der Modellierung der Unsicherheit des dynamischen Objektzustandes mit n Komponenten, beispielsweise Positionen und Geschwindigkeiten, ist p die Wahrscheinlichkeitsdichtefunktion (engl. „Probability Density Function“, PDF) eines multivariaten Zufallsprozesses, dessen Ereignishorizont der n -dimensionale euklidische Raum $\mathbf{x} \in \mathbb{R}^n$ ist.

Die Wissensbasis des Wahrnehmungssystems besteht aus der Angabe dieser Wahrscheinlichkeitsfunktionen p für jedes relevante Objekt. Zum Vergleich verschiedener Ansätze zur Umfelderkennung und zur Beurteilung der Aussagekraft einer Umfeldrepräsentation für nachfolgende Module, wie die Situationsanalyse, ist eine Quantifizierung der Güte eines Umfeldmodells erforderlich.

2.1.2 Informationsgehalt der Wissensbasis

Intuitiv besitzt eine probabilistische Wissensrepräsentation einen minimalen Informationsgehalt, wenn sie jedem Elementarereignis die gleiche Wahrscheinlichkeit zuordnet. Das Gegenteil zu dieser Gleichverteilung $\mathcal{U}$ (auch uniforme Verteilung) ist die Zuordnung der gesamten Wahrscheinlichkeitsmasse zu einem einzigen Elementarereignis. Für einen endlichen diskreten Ereignishorizont entspricht diese Repräsentation der absoluten Sicherheit über den Ausgang des Zufallsexperiments der Kronecker-Delta Funktion (auch Einheitsimpulsfunktion) und im kontinuierlichen Fall der Dirac'schen Delta-Distribution. Ein kontinuierliches Maß für den Informationsgehalt einer Wissensbasis zwischen diesen beiden Extremen bietet die Informationstheorie nach Shannon.

Information der Wissensrepräsentation für endliche diskrete Ereignishorizonte

Die Shannon-Entropie ist das Funktional

$$H[p] = - \sum_{i=1}^{|X|} p(x_i) \log_b p(x_i) \quad \text{mit } b \in \mathbb{R}, x \in X, 0 \cdot \log_b 0 \stackrel{!}{=} 0. \quad (2.6)$$

Für $b = 2, 3, e, 10$ wird die Shannon-Entropie in Bits, Trits, Nats oder Hartley gemessen. Sie ist ein Maß für die Unsicherheit der Wissensbasis p , und damit im Kontext der sensorischen Umfelderkennung das Gegenteil von Information. Die Negentropie quantifiziert direkt die Information der Wissensbasis:

$$J[p] = H[\mathcal{U}] - H[p] = \log_b |X| + \sum_{i=1}^{|X|} p(x_i) \log_b p(x_i). \quad (2.7)$$

Die Negentropie $J[p]$ nimmt unter allen Funktionen p gemäß (2.3)-(2.5) bei einer Gleichverteilung $\mathcal{U} : p(x) = |X|^{-1}$ den minimalen und bei der Einheitsimpulsfunktion den maximalen Wert an. Die Shannon-Entropie verhält sich genau umgekehrt. Es gilt zwar immer $H[p] \geq 0$

und $J[p] \geq 0$, die absoluten Werte dieser Funktionale hängen aber von der Kardinalität des Ereignishorizonts $|X|$ und der Bemessungseinheit b ab. Um ein normiertes von $|X|$ und b unabhängiges Maß für Information und Unsicherheit der Wissensbasis zu erhalten, werden (2.6) und (2.7) mit ihren Maximalwerten normiert. Da $\max\{J[p]\} = \max\{H[p]\} = H[\mathcal{U}]$ gilt, ergeben sich daraus die normierte Entropie

$$H_n[p] = \frac{H[p]}{H[\mathcal{U}]} = - \sum_{i=1}^{|X|} p(x_i) \log_{|X|} p(x_i) \quad (2.8)$$

und die normierte Negentropie

$$J_n[p] = \frac{J[p]}{H[\mathcal{U}]} = 1 + \sum_{i=1}^{|X|} p(x_i) \log_{|X|} p(x_i). \quad (2.9)$$

Die normierte Negentropie erfüllt die Anforderungen an ein quantitatives Informationsmaß einer probabilistischen Wissensrepräsentation für diskrete Entscheidungsalternativen. Sie hat unabhängig von der Kardinalität des Ereignishorizonts $|X|$ den Wert Null bei einer Gleichverteilung und den Wert Eins im deterministischen Fall.

Informationsmaße für kontinuierliche Ereignishorizonte

Ein Abstandsmaß zwischen zwei Wahrscheinlichkeits(dichte)funktionen p und q ist durch die Kullback-Leibler-Divergenz (auch relative Entropie, KL-Entropie, KL-Information) für den diskreten und den kontinuierlichen Fall definiert:

$$D_{KL}[p||q] = \sum_{i=1}^{|X|} p(x_i) \log_b \frac{p(x_i)}{q(x_i)} \quad (2.10)$$

$$D_{KL}[p||q] = \int p(x) \log_b \frac{p(x)}{q(x)} dx. \quad (2.11)$$

Die KL-Divergenz ist keine echte Metrik, da sie die Symmetriebedingung verletzt: $D_{KL}(p||q) \neq D_{KL}(q||p)$. Es ist durch einfache Rechnung leicht ersichtlich (Anhang A, Lemma 1, Seite 177), dass die im vorherigen Abschnitt definierte Negentropie (2.7) die KL-Divergenz der Wahrscheinlichkeitsfunktion p zur Gleichverteilung $\mathcal{U}$ ist. Die Shannon-Entropie (2.6) ist der Erwartungswert der KL-Divergenz zwischen den $|X|$ verschiedenen Einheitsimpulsfunktionen δ_{x_i} und der Wahrscheinlichkeitsfunktion p (Anhang A, Lemma 2, Seite 177):

$$J[p] = D_{KL}[p||\mathcal{U}] \quad (2.12)$$

$$H[p] = E_i\{D_{KL}[\delta_{x_i}||p]\}. \quad (2.13)$$

Die Negentropie lässt sich daher als Abstandsmaß zur absoluten Unwissenheit und die Shannon-Entropie als mittlerer Abstand zur absoluten Sicherheit interpretieren. Statt der Erwartungswertbildung, also der Abstandsmessung zu allen möglichen sicheren Ereignissen, kann auch die bekannte Realität (engl. „Ground Truth“) in Form einer einzigen Einheitsimpulsfunktion repräsentiert werden. In diesem Fall ist die KL-Divergenz ein Werkzeug zur Evaluierung einer

Wissensrepräsentation gegen Referenzdaten. Diese Konzepte sind nicht auf den allgemeinen kontinuierlichen Fall mit unendlich ausgedehnten Ereignishorizonten $X = \mathbb{R}^n$ übertragbar, da hier beide Bezugswerte δ und $\mathcal{U}$ nicht mehr als echte Funktionen existieren [31] und (2.11) divergiert. Praktisch berechenbar werden diese Ausdrücke daher nur mit Einschränkungen. Eine Negentropie kann für ein Gebiet mit einem begrenzten Hypervolumen V (Lebesgue-Maß) bestimmt werden, da hier die Gleichverteilung $\mathcal{U}_V(x) = V^{-1}$ existiert. Eine Definition der diracschen Delta-Distribution ist der Grenzwert der Normalverteilungsdichte für verschwindende Varianzen:

$$\delta(x) = \lim_{\sigma \rightarrow 0} \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{x^2}{2\sigma^2}\right). \quad (2.14)$$

Für die sensorische Objekterfassung von Punktzielen wurde hier vorgeschlagen [58], eine von Null verschiedene Standardabweichung in der Größe eines Drittels der typischen Objektanmessungen anzusetzen, damit $D_{KL}(\delta||p)$ auch in kontinuierlichen Ereignishorizonten berechenbar wird. Damit spiegelt der 6σ -Bereich der Normalverteilung genau die Objektanmessungen wieder.

Ein anderer Ansatz vergleicht nur noch Dichtefunktionen innerhalb einer Äquivalenzklasse, wie zum Beispiel alle Funktionen, die in ihren ersten und zweiten statistischen Momenten übereinstimmen (vgl. Standard-Entropie, Boltzmann-Entropie). Diese Ansätze sind für die Bewertung einer Wissensrepräsentation untauglich, da verschiedene Verfahren zur Umfelderkennung gerade unterschiedliche Erwartungswerte und Unsicherheiten ausgeben werden.

2.1.3 Berechnung einer Wissensbasis aus unsicheren Messdaten für statische Systeme

Wenn die Messung einer interessierenden Größe $\mathbf{x}$ nicht unsicherheitsbehaftet ist, $\mathbf{x}$ aus einem einzigen Messdatum $\mathbf{z}$ vollständig beobachtbar ist und die Funktionsweise des Messsystems bekannt ist, dann ergibt sich die Messung aus einer eindeutigen Abbildung der Realität $\mathbf{x}$:

$$\mathbf{z} = h(\mathbf{x}). \quad (2.15)$$

Zur umgekehrten Bestimmung der Realität aus den gemessenen Daten kann in diesem Fall die Umkehrfunktion h^{-1} verwendet werden. Ist der Messprozess unsicherheitsbehaftet, kann der Messprozess nur noch durch eine statistische Abhängigkeit $p(\mathbf{z}|\mathbf{x})$ zwischen der Messung und den tatsächlichen Zustandsgrößen beschrieben werden. Wurde eine konkrete Messung $\mathbf{z}$ aufgezeichnet, so kann die bedingte Wahrscheinlichkeit $p(\mathbf{z}|\mathbf{x})$ dieser konkreten Messung für jedes mögliche Modell $\mathbf{x}$ ausgewertet werden. Durch diese Variation des Modells für einen festen Messwert entsteht die Likelihoodfunktion der Messung:

$$\Lambda_{\mathbf{z}}(\mathbf{x}) = p(\mathbf{z}|\mathbf{x}). \quad (2.16)$$

Normiert man diese Funktion so, dass sie sich über alle Ereignisse $\mathbf{x}$ zu Eins integriert, spricht man von der Rückschlusswahrscheinlichkeitsfunktion:

$$p(\mathbf{x}|\mathbf{z}) = \frac{p(\mathbf{z}|\mathbf{x})}{\int p(\mathbf{z}|\mathbf{y})d\mathbf{y}}. \quad (2.17)$$

Die Wahrscheinlichkeit $p(\mathbf{x}|\mathbf{z})$ ist die aus der Messung $\mathbf{z}$ und dem Messmodell $p(\mathbf{z}|\mathbf{x})$ berechnete probabilistische Wissensbasis. Die ingenieurtechnische Herausforderung besteht hier in der Angabe eines adäquaten Messmodells $p(\mathbf{z}|\mathbf{x})$, das den tatsächlichen Messprozess ausreichend charakterisiert.

2.1.4 Berechnung der Wissensbasis für dynamische Systeme

Im Bereich der statischen Systeme wurden zwei Informationsquellen zur Berechnung der Wissensbasis verwendet. Diese sind die Information aus der aktuellen Messung $\mathbf{z}_k$ und die a-priori Information des Messmodells $p(\mathbf{z}|\mathbf{x})$ über die Arbeitsweise des Messinstruments. Im Fall zeitveränderlicher Systeme stehen prinzipiell zwei weitere Informationsquellen, die Kenntnis der Zustandshistorie des Systems und das a-priori Wissen über die Systemdynamik, zur Verfügung. Auf die Betrachtung eines zusätzlichen Steuereingangs $\mathbf{u}_k$ wird im Folgenden aus Kompaktheitsgründen verzichtet.

Die Wissensbasis zum Zeitpunkt k unter Kenntnis aller Messungen $\mathbf{Z}_{1:k} = (\mathbf{z}_0, \dots, \mathbf{z}_k)$ bis zu diesem Zeitpunkt wird über den Satz von Bayes berechnet [17, 90]:

$$p(\mathbf{x}_k|\mathbf{Z}_{1:k}) = \frac{p(\mathbf{Z}_{1:k}|\mathbf{x}_k)p(\mathbf{x}_k)}{p(\mathbf{Z}_{1:k})} = \frac{p(\mathbf{z}_k, \mathbf{Z}_{1:k-1}|\mathbf{x}_k)p(\mathbf{x}_k)}{p(\mathbf{z}_k, \mathbf{Z}_{1:k-1})} \quad (2.18)$$

$$= \frac{p(\mathbf{z}_k|\mathbf{Z}_{1:k-1}, \mathbf{x}_k)p(\mathbf{Z}_{1:k-1}|\mathbf{x}_k)p(\mathbf{x}_k)}{p(\mathbf{z}_k|\mathbf{Z}_{1:k-1})p(\mathbf{Z}_{1:k-1})}. \quad (2.19)$$

Der Term $p(\mathbf{Z}_{1:k-1}|\mathbf{x}_k)$ wird durch die entsprechende Bayes-Formel in (2.19) ersetzt:

$$p(\mathbf{x}_k|\mathbf{Z}_{1:k}) = \frac{p(\mathbf{z}_k|\mathbf{Z}_{1:k-1}, \mathbf{x}_k)p(\mathbf{x}_k|\mathbf{Z}_{1:k-1})p(\mathbf{Z}_{1:k-1})p(\mathbf{x}_k)}{p(\mathbf{z}_k|\mathbf{Z}_{1:k-1})p(\mathbf{Z}_{1:k-1})p(\mathbf{x}_k)} \quad (2.20)$$

$$= \frac{p(\mathbf{z}_k|\mathbf{Z}_{1:k-1}, \mathbf{x}_k)p(\mathbf{x}_k|\mathbf{Z}_{1:k-1})}{p(\mathbf{z}_k|\mathbf{Z}_{1:k-1})}. \quad (2.21)$$

Für die Funktionsweise des Messgerätes muss weiterhin angenommen werden, dass die aktuelle Messung ausschließlich vom aktuellen Systemzustand und nicht von der Zustands- oder Messwerthistorie abhängt:

$$p(\mathbf{z}_k|\mathbf{X}_{1:k}, \mathbf{Z}_{1:k-1}) = p(\mathbf{z}_k|\mathbf{x}_k). \quad (2.22)$$

Damit vereinfacht sich (2.21) weiter zu:

$$p(\mathbf{x}_k|\mathbf{Z}_{1:k}) = \frac{p(\mathbf{z}_k|\mathbf{x}_k)p(\mathbf{x}_k|\mathbf{Z}_{1:k-1})}{p(\mathbf{z}_k|\mathbf{Z}_{1:k-1})} = \frac{p(\mathbf{z}_k|\mathbf{x}_k)p(\mathbf{x}_k|\mathbf{Z}_{1:k-1})}{\int p(\mathbf{z}_k|\mathbf{x}_k)p(\mathbf{x}_k|\mathbf{Z}_{1:k-1})d\mathbf{x}_k}. \quad (2.23)$$

Da die Größen der Zustands- und Messwerthistorien $\mathbf{X}_{1:k}$ und $\mathbf{Z}_{1:k}$ linear mit der Zeit über alle Schranken wachsen, können diese Historien nicht mit endlicher Speicherkapazität erfasst werden. Deshalb lässt sich mit technisch umsetzbaren Messsystemen nur eine eingeschränkte Klasse von dynamischen Systemen beobachten, die die Markov-Eigenschaft besitzt (Markov-Kette, Markov-Prozess, [7]). O.E.d.A. kann man sich auf Markov-Prozesse erster Ordnung beschränken (siehe „Markovisierung“, [103]), bei denen der aktuelle Zustand ausschließlich

vom direkt vorhergehenden Zustand abhängig ist, statt von einem Teil oder der gesamten vorherigen Messwert- oder Zustandshistorie:

$$p(\mathbf{x}_k | \mathbf{X}_{1:k-1}, \mathbf{Z}_{1:k-1}) = p(\mathbf{x}_k | \mathbf{x}_{k-1}). \quad (2.24)$$

Systeme, die die Markov-Bedingung (2.24) erfüllen, haben folgende äquivalente Eigenschaften:

1. Es existiert ein endlicher Zustandsvektor, in dem das gesamte Wissen der Zustandshistorie des Systems repräsentiert werden kann.
2. Neben den im Zustandsvektor enthaltenen Größen enthält das System keine weiteren Informationsspeicher oder Gedächtniseinheiten.
3. Die Art und Weise, in der das System einen bestimmten Zustand erreicht hat, ist für die weitere Entwicklung des Systemzustands in der Zukunft bedeutungslos.

Unter dieser Bedingung lässt sich die a-priori Wissensbasis $p(\mathbf{x}_k | \mathbf{Z}_{1:k-1})$ in (2.23) mit der Chapman-Kolmogorov Gleichung rekursiv aus der Wissensbasis zum vorherigen Zeitpunkt berechnen:

$$p(\mathbf{x}_k | \mathbf{Z}_{1:k-1}) = \int_X p(\mathbf{x}_k | \mathbf{x}_{k-1}) p(\mathbf{x}_{k-1} | \mathbf{Z}_{1:k-1}) d\mathbf{x}_{k-1}. \quad (2.25)$$

Dieses Pfadintegral summiert die Wahrscheinlichkeiten der Zustandsübergänge aller möglichen vorherigen Zustände $\mathbf{x}_{k-1}$ in den Zustand $\mathbf{x}_k$. Die Wahrscheinlichkeit eines Pfades von $\mathbf{x}_{k-1}$ nach $\mathbf{x}_k$ ist das Produkt der Wahrscheinlichkeit für den Ausgangszustand $p(\mathbf{x}_{k-1} | \mathbf{Z}_{1:k-1})$, also der vorherigen Wissensbasis, und der Transitions Wahrscheinlichkeit von $\mathbf{x}_{k-1}$ zu $\mathbf{x}_k$ (2.24).

Symbolisiert man die bedingte Wahrscheinlichkeit $p(\mathbf{x} | \mathbf{y})$ durch einen Pfeil $\mathbf{y} \rightarrow \mathbf{x}$ (lies: $\mathbf{y}$ bedingt $\mathbf{x}$), lassen sich aus (2.22) und (2.24) die statistischen Zusammenhänge bei einem messtechnisch beobachteten Markov-Prozess schematisch darstellen:

$$\begin{array}{ccccccc} \dots & \longrightarrow & \mathbf{x}_{k-3} & \longrightarrow & \mathbf{x}_{k-2} & \longrightarrow & \mathbf{x}_{k-1} & \longrightarrow & \mathbf{x}_k & \longrightarrow & \dots \\ & & \downarrow & & \downarrow & & \downarrow & & \downarrow & & \\ & & \mathbf{z}_{k-3} & & \mathbf{z}_{k-2} & & \mathbf{z}_{k-1} & & \mathbf{z}_k & & \end{array} \quad (2.26)$$

Da die Markov-Kette der Systemzustände nur indirekt über die Messwerte beobachtet werden kann, wird dieses Modell auch verborgenes Markov-Modell (engl. „Hidden Markov Model“, HMM) genannt.

Die rekursive bayessche Zustandschätzung besteht damit aus zwei Schritten. Zunächst wird die Wissensbasis im Prädiktionsschritt (2.25) auf den nächsten Messzeitpunkt vorausberechnet. Im Anschluss wird die Information aus der aktuellen Messung im Korrekturschritt über den Satz von Bayes in die Wissensbasis eingebracht (2.23). Für den Fall, dass keine a-priori Wissensbasis vorliegt, also $p(\mathbf{x}_k | \mathbf{Z}_{1:k-1}) = \mathcal{U}(\mathbf{x}_k)$, reduziert sich die bayessche Zustandschätzung auf den statischen Fall. Wie eingangs erwähnt, ist andernfalls die Kenntnis der Transitions Wahrscheinlichkeiten (2.24) zusätzlich zur Likelihoodfunktion der Messung (2.22) nötig.

Modelle für die bayessche Zustandsschätzung

Für die Modellierung der Systemdynamik und des Messgerätes können stochastische Differenzgleichungen verwendet werden:

$$\mathbf{x}_k = f(\mathbf{x}_{k-1}, \mathbf{v}_k) \quad (2.27)$$

$$\mathbf{z}_k = h(\mathbf{x}_k, \mathbf{w}_k). \quad (2.28)$$

Die Funktionen f bzw. h sind dabei das Prozessmodell (auch System- oder Transitionsmodell) bzw. das Messmodell, die neben den Systemzuständen vom Prozessrauschvektor $\mathbf{v}_k$ und vom Messrauschvektor $\mathbf{w}_k$ abhängen. Diese Störgrößen modellieren zum einen tatsächliche zufällige Einflüsse in den physikalischen Prozessen und zum anderen Modellfehler in f und h . Mit diesen Modellen lassen sich die Transitionswahrscheinlichkeit und die Likelihoodfunktion der Messung angeben:

$$p(\mathbf{x}_k | \mathbf{x}_{k-1}) = \int_V \delta(\mathbf{x}_k - f(\mathbf{x}_{k-1}, \mathbf{v}_k)) p(\mathbf{v}_k) d\mathbf{v}_k \quad (2.29)$$

$$p(\mathbf{z}_k | \mathbf{x}_k) = \int_W \delta(\mathbf{z}_k - h(\mathbf{x}_k, \mathbf{w}_k)) p(\mathbf{w}_k) d\mathbf{w}_k. \quad (2.30)$$

Aus den Annahmen (2.22) und (2.24) ergeben sich Konsequenzen für das Prozess- und Messmodell.

Zum einen müssen die Modelle f und h in dem Sinne perfekt sein, dass sie die Prozesse im Mittel richtig beschreiben. Dies ist gleichbedeutend mit der Forderung, dass die stochastischen Störgrößen im Mittel keinen Einfluss ausüben dürfen. Wäre dies der Fall, würde ein systematischer Fehler über das Prozessrauschen $\mathbf{v}_k$ oder das Messrauschen $\mathbf{w}_k$ in die Gleichungen eingehen, der wiederum einem Determinismus und damit einem Systemzustand entsprechen würde. Dies widerspricht aber der Annahme, dass die Wahrscheinlichkeiten (2.22) und (2.24) ausschließlich vom modellierten Systemzustand $\mathbf{x}$ abhängen.

Eine weitere Konsequenz ist die Tatsache, dass die Störgrößen gegenseitig und zeitlich von sich selbst statistisch unabhängig sein müssen. Das Ausmaß der statistischen Abhängigkeiten könnte wiederum durch Parameter beschrieben werden, die neben dem modellierten Zustand $\mathbf{x}$ notwendig wären, um das System vollständig zu beschreiben. Ein solcher Parameter ist zum Beispiel die gegenseitige Information (engl. „Mutual Information“, [73]). Dies würde ebenfalls den Annahmen (2.22) und (2.24) widersprechen, die die vollständige Charakterisierung des Systems durch den modellierten Systemzustand $\mathbf{x}$ fordern. Um die bayessche Zustandsschätzung auch bei statistisch abhängigen Störgrößen zu verwenden, müssen die Abhängigkeiten beschreibenden Parameter in den Zustandsvektor aufgenommen werden, um die Annahmen zu erfüllen. Diese Vorgehensweise wird in Abschnitt 4.4 (Seiten 112 ff.) am Beispiel diskutiert.

Sensorfusion

Es ist möglich, die Messungen mehrerer Sensoren zum Zeitpunkt k in die Wissensbasis einzubringen. Für die Sensoren a und b ergibt sich aus der Bayes-Formel analog zur Herleitung von

(2.23):

$$p(\mathbf{x}_k | \mathbf{Z}_{1:k}^a, \mathbf{Z}_{1:k}^b) = \frac{p(\mathbf{z}_k^a, \mathbf{z}_k^b | \mathbf{x}_k) p(\mathbf{x}_k | \mathbf{Z}_{1:k-1}^a, \mathbf{Z}_{1:k-1}^b)}{p(\mathbf{z}_k^a, \mathbf{z}_k^b | \mathbf{Z}_{1:k-1}^a, \mathbf{Z}_{1:k-1}^b)} \quad (2.31)$$

$$= \frac{p(\mathbf{z}_k^a | \mathbf{z}_k^b, \mathbf{x}_k) p(\mathbf{z}_k^b | \mathbf{x}_k) p(\mathbf{x}_k | \mathbf{Z}_{1:k-1}^a, \mathbf{Z}_{1:k-1}^b)}{p(\mathbf{z}_k^a, \mathbf{z}_k^b | \mathbf{Z}_{1:k-1}^a, \mathbf{Z}_{1:k-1}^b)}. \quad (2.32)$$

Mit der Unabhängigkeitsbedingung

$$p(\mathbf{z}_k^a | \mathbf{z}_k^b, \mathbf{x}_k) = p(\mathbf{z}_k^a | \mathbf{x}_k) \quad (2.33)$$

lassen sich zwei unabhängige Likelihood-Funktionen der Messungen verwenden:

$$p(\mathbf{x}_k | \mathbf{Z}_{1:k}^a, \mathbf{Z}_{1:k}^b) = \frac{1}{C} p(\mathbf{z}_k^a | \mathbf{x}_k) p(\mathbf{z}_k^b | \mathbf{x}_k) p(\mathbf{x}_k | \mathbf{Z}_{1:k-1}^a, \mathbf{Z}_{1:k-1}^b). \quad (2.34)$$

Aufgrund der Assoziativität der Multiplikation ist es dabei unerheblich, ob zuerst die beiden Likelihood-Funktionen multipliziert und danach in einem einzigen Korrekturschritt verarbeitet werden oder ob zwei sequenzielle Einzelinnovationen auf die a-priori Wissensbasis angewendet werden. Die Annahme (2.33) verlangt die gegenseitige statistische Unabhängigkeit der Messrauschgrößen $\mathbf{w}_k^a$ und $\mathbf{w}_k^b$ mit der gleichen Argumentation wie im vorherigen Abschnitt. Dies ist gleichbedeutend mit der Forderung, dass die Messfehler beider Sensoren keine gegenseitige Systematik aufweisen.

2.1.5 Extraktion von Schätzwerten aus einer probabilistischen Wissensbasis

Die gesamte aus der Kombination von Messungen und Modellwissen verfügbare Information über den Zustand $\mathbf{x}$ eines beobachteten Systems ist in der probabilistischen Wissensbasis $p(\mathbf{x}|\cdot)$ enthalten, die mit (2.17) oder (2.23) berechnet wurde. Wenn nachgeschaltete Systeme nicht in der Lage sind, diese unscharfe probabilistische Wissensrepräsentation weiter zu verarbeiten, muss die Wissensrepräsentation in eine konkrete Schätzung des Systemzustandes umgewandelt werden. Ein Zustandsschätzer (engl. „Estimator“) ist eine Abbildung aus der Menge der Funktionen p gemäß (2.3)-(2.5) in die Menge der Elementarereignisse X . Eine naheliegende Strategie ist die Auswahl des plausibelsten Ereignisses $\hat{\mathbf{x}}$, dem innerhalb der Wissensrepräsentation p die größte Wahrscheinlichkeit zugeordnet wurde. Für statische Systeme (2.16),(2.17) spricht man vom Maximum-Likelihood Schätzer (ML):

$$\hat{\mathbf{x}}^{\text{ML}} = \underset{\mathbf{x}}{\operatorname{argmax}} \Lambda_{\mathbf{z}}(\mathbf{x}) = \underset{\mathbf{x}}{\operatorname{argmax}} p(\mathbf{x}|\mathbf{z}). \quad (2.35)$$

Der Maximum-A-Posteriori Schätzer (MAP) wählt das plausibelste Ereignis für dynamische Systeme (2.23):

$$\hat{\mathbf{x}}_k^{\text{MAP}} = \underset{\mathbf{x}}{\operatorname{argmax}} p(\mathbf{x}_k | \mathbf{Z}_{1:k}). \quad (2.36)$$

In einer zweiten Strategie wird der Schätzwert $\hat{\mathbf{x}}$ ausgewählt, der den erwarteten quadratischen Schätzfehler $|\hat{\mathbf{x}} - \mathbf{x}|^2$ minimiert (engl. „Minimum Mean Squared Error“, MMSE), wenn der

wahre Wert des Zustandes $\mathbf{x}$ eine Realisierung des durch die Wissensbasis p beschriebenen Zufallsprozesses ist:

$$\hat{\mathbf{x}}^{\text{MMSE}} = \underset{\hat{\mathbf{x}}}{\operatorname{argmin}} E\{|\hat{\mathbf{x}} - \mathbf{x}|^2\}, \quad \mathbf{x} \sim p. \quad (2.37)$$

Die Extremwertaufgabe wird durch Nullsetzen der ersten Ableitung gelöst:

$$\frac{\partial}{\partial \hat{\mathbf{x}}} E\{|\hat{\mathbf{x}} - \mathbf{x}|^2\} = E\left\{\frac{\partial}{\partial \hat{\mathbf{x}}} |\hat{\mathbf{x}} - \mathbf{x}|^2\right\} = E\{2|\hat{\mathbf{x}} - \mathbf{x}|\} = 2|\hat{\mathbf{x}} - E\{\mathbf{x}\}| = 0. \quad (2.38)$$

Damit ist der MMSE-Schätzer gleich dem Erwartungswert der Wissensrepräsentation:

$$\hat{\mathbf{x}}^{\text{MMSE}} = E\{\mathbf{x}\}, \quad \mathbf{x} \sim p. \quad (2.39)$$

Wurde die Wissensbasis unter Verwendung von probabilistischen Vorwissen mit dem Satz von Bayes (2.23) berechnet, wie z.B. im Fall dynamischer Systeme, trägt der MMSE-Schätzer auch den Namen A-Posteriori-Erwartungswertschätzer (engl. „Expected A-Posteriori Estimator“, EAP):

$$\hat{\mathbf{x}}_k^{\text{EAP}} = \int_X \mathbf{x}_k p(\mathbf{x}_k | \mathbf{Z}_{1:k}) d\mathbf{x}_k. \quad (2.40)$$

Ist der Informationsgehalt der Wissensbasis sehr hoch, also p sehr nahe an der Einheitsimpulsfunktion bzw. Dirac-Distribution, entstehen durch Verwendung dieser Schätzwerte nur kleine Fehler. Im Falle sehr unsicheren Wissens und speziell bei multimodalen Wahrscheinlichkeitsfunktionen p kann die Anwendung eines Schätzers sehr große Fehler zum wahren Zustand $\mathbf{x}$ hervorrufen. Es ist daher immer von Vorteil, so lange wie möglich die vollständige probabilistische Wissensrepräsentation in einem informationsverarbeitenden System beizubehalten.

2.2 Implementierungen der bayesschen Zustandsschätzung

Da sich der Fall der statischen Parameterschätzung aus dem Fall der dynamischen Zustandsschätzung mit uniformer a-priori Information ableiten lässt, werden die folgenden Betrachtungen o.E.d.A. für den dynamischen Fall durchgeführt. Für endlich diskrete Ereignishorizonte lässt sich die Wissensbasis p vollständig mit endlicher Kapazität speichern. Die Integrale in (2.25) und (2.23) werden zu Summen. Daher lassen sich die rekursiven Filtergleichungen im diskreten Fall, z.B. zur Lösung einer Klassifikationsaufgabe nach (2.2), direkt implementieren. Im Gegensatz dazu kann eine beliebige Wahrscheinlichkeitsdichtefunktion auf einem unendlich mächtigen Träger (z.B. dem euklidischen Raum $\mathbb{R}^n$) nicht mit endlicher Speicherkapazität erfasst werden. In den folgenden Abschnitten werden daher die geläufigsten Verfahren zur numerischen und analytischen Repräsentation kontinuierlicher Wahrscheinlichkeitsdichtefunktionen und die darauf angepassten Filtergleichungen vorgestellt.

2.2.1 Das Kalman-Filter

Die rekursiven Filtergleichungen (2.25) und (2.23) verwenden im kontinuierlichen Fall drei Wahrscheinlichkeitsdichtefunktionen. Diese sind die zu berechnende Wissensbasis $p(\mathbf{x}_k | \mathbf{Z}_{1:k})$,

die Transitionswahrscheinlichkeiten $p(\mathbf{x}_k|\mathbf{x}_{k-1})$ und die durch den Zustand $\mathbf{x}$ bedingte Wahrscheinlichkeit der Messung $p(\mathbf{z}_k|\mathbf{x}_k)$. Das Kalman-Filter [42] stellt alle diese Funktionen parametrisch in Form von Dichtefunktionen der Normalverteilung, also gaußschen Glockenkurven mit Mittelwert $\boldsymbol{\mu}$ und Kovarianz $\boldsymbol{\Sigma}$, dar.

$$\mathcal{N}(\mathbf{x}, \boldsymbol{\mu}, \boldsymbol{\Sigma}) = (2\pi)^{-\frac{\dim(\mathbf{x})}{2}} |\boldsymbol{\Sigma}|^{-\frac{1}{2}} \cdot \exp \left[-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{x} - \boldsymbol{\mu}) \right] \quad (2.41)$$

Für das Prozessmodell (2.27) zwischen zwei sukzessiven Messzeitpunkten wird die additive Überlagerung einer linearen deterministischen Bewegung im Zustandsraum, gegeben durch die Transitionsmatrix $\mathbf{F}$, und einer normalverteilten stochastischen Diffusion $\mathbf{v}$ mit Kovarianz $\mathbf{Q}$ modelliert:

$$\mathbf{x}_k = f(\mathbf{x}_{k-1}, \mathbf{v}_k) = \mathbf{F}_k \mathbf{x}_{k-1} + \mathbf{v}_k, \quad \mathbf{v}_k \sim \mathcal{N}(\cdot, \mathbf{0}, \mathbf{Q}_k). \quad (2.42)$$

Analog ist die fehlerbehaftete Messung $\mathbf{z}$ eine additive Überlagerung eines durch die Matrix $\mathbf{H}$ gegebenen deterministischen Messprozesses und eines normalverteilten stochastischen Messfehlers $\mathbf{w}$ mit Kovarianz $\mathbf{R}$:

$$\mathbf{z}_k = \mathbf{H}_k \mathbf{x}_k + \mathbf{w}_k, \quad \mathbf{w}_k \sim \mathcal{N}(\cdot, \mathbf{0}, \mathbf{R}_k). \quad (2.43)$$

Aus der Forderung nach perfekten Modellen (Seite 13) folgt für (2.42) und (2.43) die Forderung nach mittelwertfreiem Prozess- und Messrauschen, also

$$E\{\mathbf{v}_k\} = E\{\mathbf{w}_k\} = \mathbf{0}. \quad (2.44)$$

Die weiterhin der bayesschen Zustandschätzung zugrundeliegende Forderung nach gegenseitiger und zeitlicher statistischer Unabhängigkeit des Prozess- und Messrauschens, wird durch eine verschwindende Autokorrelationen der Rauschsequenzen $\mathbf{v}_k$ und $\mathbf{w}_k$ für die Zeitverschiebungen $\kappa \neq 0$ (weißes Rauschen)

$$\phi^{\mathbf{v}\mathbf{v}}(\kappa) = E_k\{\mathbf{v}_k \mathbf{v}_{k-\kappa}^T\} = \mathbf{Q}\delta(\kappa), \quad \phi^{\mathbf{w}\mathbf{w}}(\kappa) = E_k\{\mathbf{w}_k \mathbf{w}_{k-\kappa}^T\} = \mathbf{R}\delta(\kappa) \quad (2.45)$$

und eine verschwindende Kreuzkorrelation beider Störgrößen sichergestellt:

$$\phi^{\mathbf{v}\mathbf{w}}(\kappa) = E_k\{\mathbf{v}_k \mathbf{w}_{k-\kappa}^T\} = \mathbf{0}, \quad \forall \kappa. \quad (2.46)$$

Mit diesen Annahmen lassen sich die Wissensbasis, die Transitionswahrscheinlichkeiten und die Likelihood-Funktion der Messung als Dichtefunktionen der Normalverteilung angeben:

$$p(\mathbf{x}_k|\mathbf{Z}_{1:k}) = \mathcal{N}(\mathbf{x}_k, \hat{\mathbf{x}}_k, \hat{\mathbf{P}}_k) \quad (2.47)$$

$$p(\mathbf{x}_k|\mathbf{x}_{k-1}) = \mathcal{N}(\mathbf{x}_k, \mathbf{F}_k \mathbf{x}_{k-1}, \mathbf{Q}_k) \quad (2.48)$$

$$p(\mathbf{z}_k|\mathbf{x}_k) = \mathcal{N}(\mathbf{z}_k, \mathbf{H}_k \mathbf{x}_k, \mathbf{R}_k). \quad (2.49)$$

Die Wissensbasis ist in jedem Zeitschritt durch den Schätzwert $\hat{\mathbf{x}}_k$ und die Schätzfehlerkovarianz $\hat{\mathbf{P}}_k$ parametrisiert. Zu deren Berechnung muss neben den Messungen Modellwissen über die Dynamik in Form der Transitionsmatrix $\mathbf{F}_k$ und der Prozessrauschkovarianz $\mathbf{Q}_k$ eingebracht werden. Zusätzlich ist Modellwissen über den Messprozess in Form der Messmatrix $\mathbf{H}_k$ und der Messfehlerkovarianz $\mathbf{R}_k$ nötig.

Der Prädiktionsschritt

Zur Zustandsprädiktion werden (2.47) und (2.48) in die Chapman-Kolmogorov-Gleichung (2.25) eingesetzt:

$$p(\mathbf{x}_k | \mathbf{Z}_{1:k-1}) = \int_X \mathcal{N}(\mathbf{x}_k, \mathbf{F}_k \mathbf{x}_{k-1}, \mathbf{Q}_k) \mathcal{N}(\mathbf{x}_{k-1}, \hat{\mathbf{x}}_{k-1}, \hat{\mathbf{P}}_{k-1}) d\mathbf{x}_{k-1}. \quad (2.50)$$

Für das Integral (2.50) ergibt sich mit Lemma 7 (Anhang A, Seite 180):

$$\begin{aligned} p(\mathbf{x}_k | \mathbf{Z}_{1:k-1}) &= \mathcal{N}(\mathbf{x}_k, \mathbf{F}_k \hat{\mathbf{x}}_{k-1}, \mathbf{F}_k \hat{\mathbf{P}}_{k-1} \mathbf{F}_k^T + \mathbf{Q}_k) \\ &= \mathcal{N}(\mathbf{x}_k, \hat{\mathbf{x}}_{k|k-1}, \hat{\mathbf{P}}_{k|k-1}). \end{aligned} \quad (2.51)$$

Damit ist das Ergebnis der Prädiktion einer Normalverteilung als Wissensbasis mit normalverteilten Transitionswahrscheinlichkeiten wieder eine Normalverteilung mit den Parametern:

$$\hat{\mathbf{x}}_{k|k-1} = \mathbf{F}_k \hat{\mathbf{x}}_{k-1} \quad (2.52)$$

$$\hat{\mathbf{P}}_{k|k-1} = \mathbf{F}_k \hat{\mathbf{P}}_{k-1} \mathbf{F}_k^T + \mathbf{Q}_k. \quad (2.53)$$

Die Gleichungen (2.52) und (2.53) sind die Prädiktionsgleichungen des Kalman-Filters.

Der Innovationschritt

Für den Korrekturschritt mit der aktuellen Messung $\mathbf{z}$ werden die Normalverteilungsdichten (2.47) und (2.49) in die Bayes-Formel (2.23) eingesetzt. Es ergibt sich:

$$p(\mathbf{x}_k | \mathbf{Z}_{1:k}) = \frac{\mathcal{N}(\mathbf{z}_k, \mathbf{H}_k \mathbf{x}_k, \mathbf{R}_k) \mathcal{N}(\mathbf{x}_k, \hat{\mathbf{x}}_{k|k-1}, \hat{\mathbf{P}}_{k|k-1})}{\int \mathcal{N}(\mathbf{z}_k, \mathbf{H}_k \mathbf{y}_k, \mathbf{R}_k) \mathcal{N}(\mathbf{y}_k, \hat{\mathbf{x}}_{k|k-1}, \hat{\mathbf{P}}_{k|k-1}) d\mathbf{y}_k}. \quad (2.54)$$

Mit Lemma 7 (Anhang A, Seite 180) lässt sich (2.54) in

$$p(\mathbf{x}_k | \mathbf{Z}_{1:k}) = \frac{\mathcal{N}(\mathbf{z}_k, \mathbf{H}_k \mathbf{x}_k, \mathbf{R}_k) \mathcal{N}(\mathbf{x}_k, \hat{\mathbf{x}}_{k|k-1}, \hat{\mathbf{P}}_{k|k-1})}{\mathcal{N}(\mathbf{z}_k, \mathbf{H}_k \hat{\mathbf{x}}_{k|k-1}, \mathbf{H}_k \hat{\mathbf{P}}_{k|k-1} \mathbf{H}_k^T + \mathbf{R}_k)} \quad (2.55)$$

umformen. Mit Lemma 8 (Anhang A, Seite 181) und der Abkürzung

$$\mathbf{S}_k = \mathbf{H}_k \hat{\mathbf{P}}_{k|k-1} \mathbf{H}_k^T + \mathbf{R}_k \quad (2.56)$$

ergibt sich daraus:

$$\begin{aligned} p(\mathbf{x}_k | \mathbf{Z}_{1:k}) &= \mathcal{N}(\mathbf{x}_k, \hat{\mathbf{x}}_{k|k-1} + \hat{\mathbf{P}}_{k|k-1} \mathbf{H}_k^T \mathbf{S}_k^{-1} (\mathbf{z}_k - \mathbf{H}_k \hat{\mathbf{x}}_{k|k-1}), \hat{\mathbf{P}}_{k|k-1} - \hat{\mathbf{P}}_{k|k-1} \mathbf{H}_k^T \mathbf{S}_k^{-1} \mathbf{H}_k \hat{\mathbf{P}}_{k|k-1}) \\ &= \mathcal{N}(\mathbf{x}_k, \hat{\mathbf{x}}_{k|k}, \hat{\mathbf{P}}_{k|k}). \end{aligned} \quad (2.57)$$

Mit dem Innovationsresiduum γ_k und der Kalman-Verstärkung $\mathbf{K}_k$

$$\gamma_k = \mathbf{z}_k - \mathbf{H}_k \hat{\mathbf{x}}_{k|k-1} \quad (2.58)$$

$$\mathbf{K}_k = \hat{\mathbf{P}}_{k|k-1} \mathbf{H}_k^T \mathbf{S}_k^{-1} \quad (2.59)$$

schließen die Korrekturformeln für die Parameter der a-posteriori Wissensbasis die Kalman-Filter Rekursion ab:

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k \gamma_k \quad (2.60)$$

$$\hat{\mathbf{P}}_{k|k} = \hat{\mathbf{P}}_{k|k-1} - \mathbf{K}_k \mathbf{H}_k \hat{\mathbf{P}}_{k|k-1}. \quad (2.61)$$

Statt mit (2.61) sollte die Korrektur der Schätzfehlerkovarianz $\hat{\mathbf{P}}_{k|k}$ mit der äquivalenten aber numerisch stabileren Joseph-Form [5] implementiert werden. Bei normalverteilten Zufallsgrößen entspricht der Mittelwert $\hat{\mathbf{x}}_{k|k}$ gleichzeitig dem ML- und dem MMSE-Schätzwert (Abschnitt 2.1.5, [5]).

2.2.2 Das Extended-Kalman-Filter

Sind die Voraussetzungen des Kalman-Filters dahingehend nicht erfüllt, dass das Messmodell oder das Prozessmodell oder beide nichtlinear sind, ergeben sich aus dem Prädiktions- und Innovationschritt keine gaußschen Glockenkurven als resultierende Dichtefunktionen mehr. Um dennoch die effiziente Kalman-Filterrekursion einsetzen zu können, linearisiert das Extended-Kalman-Filter (EKF, [42, 5]) diese Modelle am Arbeitspunkt der aktuellen Zustandsschätzung. Alle weiteren Voraussetzungen des Kalman-Filters, insbesondere das normalverteilte, additive, mittelwertfreie, weiße und gegenseitig unkorrelierte Mess- und Prozessrauschen, bleiben bestehen. Die nichtlinearen Prozess- und Messmodelle f und h

$$\mathbf{x}_k = f(\mathbf{x}_{k-1}) + \mathbf{v}_k, \quad \mathbf{v}_k \sim \mathcal{N}(\cdot, \mathbf{0}, \mathbf{Q}_k) \quad (2.62)$$

$$\mathbf{z}_k = h(\mathbf{x}_k) + \mathbf{w}_k, \quad \mathbf{w}_k \sim \mathcal{N}(\cdot, \mathbf{0}, \mathbf{R}_k) \quad (2.63)$$

werden direkt in den Kalman-Filtergleichungen (2.52) und (2.58) anstelle der Matrizen $\mathbf{F}_k$ und $\mathbf{H}_k$ verwendet. Für die Störgrößen wird deren Erwartungswert Null eingesetzt. In den Berechnungen der Kovarianzmatrizen (2.53), (2.59) und (2.61) werden anstatt der Matrizen $\mathbf{F}_k$ und $\mathbf{H}_k$ die Jacobimatrizen von f und h verwendet:

$$\mathbf{F}_k = \mathbf{J}_k^{\mathbf{F}} = \left. \frac{\partial}{\partial \mathbf{x}} f(\mathbf{x}) \right|_{\mathbf{x}=\hat{\mathbf{x}}_{k-1|k-1}} \quad \mathbf{H}_k = \mathbf{J}_k^{\mathbf{H}} = \left. \frac{\partial}{\partial \mathbf{x}} h(\mathbf{x}) \right|_{\mathbf{x}=\hat{\mathbf{x}}_{k|k-1}}. \quad (2.64)$$

Dies entspricht einer Taylor-Serienentwicklung der Funktionen f und h bis zur ersten Ordnung am Arbeitspunkt der aktuellsten Zustandsschätzung. Eine Herleitung dieser Vorgehensweise sowie eine Version des EKF mit einer Serienentwicklung bis zur zweiten Ordnung findet sich in [5], Seiten 384 ff.

Durch den Abbruch der Taylor-Reihe entsteht beim EKF ein Approximationsfehler jeweils für die prädizierte und die mit der Messung korrigierte Wissensbasis. Aufgrund dieser Fehler berechnet das EKF nicht die Bayes-optimale Wissensbasis nach (2.25) und (2.23) und ist daher ein Suboptimalfilter.

2.2.3 Das Partikelfilter

Neben der parametrischen Darstellung von Dichtefunktionen existiert auch die Möglichkeit, eine numerische Repräsentation der Wissensbasis in der bayesschen Zustandsschätzung zu ver-

wenden.

Monte-Carlo Integration und Importance Sampling

Ein Verfahren zur Berechnung des Erwartungswertes einer Funktion $f(\mathbf{x})$ einer Zufallsvariablen $\mathbf{x}$ mit Dichtefunktion $p(\mathbf{x})$ ist die Monte-Carlo-Integration:

$$E_p\{f(\mathbf{x})\} = \int f(\mathbf{x})p(\mathbf{x})d\mathbf{x} \approx \frac{1}{N} \sum_{i=1}^N f(\mathbf{x}^i), \quad \mathbf{x}^i \sim p. \quad (2.65)$$

Dabei wird $f(\mathbf{x})$ an N nach der Dichtefunktion p gezogenen Stützstellen $\mathbf{x}^i$ ausgewertet und das arithmetische Mittel dieser Funktionswerte berechnet. Mit Wahrscheinlichkeit Eins konvergiert dieser Mittelwert für $N \rightarrow \infty$ gegen den tatsächlichen Erwartungswert von $f(\mathbf{x})$. Dieses Prinzip der Darstellung einer Funktion durch eine endliche Anzahl von Stützstellen ist für das Partikelfilter namensgebend.

Können keine Stützstellen nach der Dichtefunktion p gezogen werden, sondern lediglich nach einer zu p ähnlichen Dichtefunktion q , so ist dennoch eine Monte-Carlo Berechnung des Erwartungswertes möglich, indem die Abweichung zwischen p und q in einem entsprechend gewichteten Mittelwert berücksichtigt wird:

$$E_p\{f(\mathbf{x})\} \approx \frac{1}{N} \sum_{i=1}^N w^i f(\mathbf{x}^i), \quad w^i = \frac{p(\mathbf{x}^i)}{q(\mathbf{x}^i)}, \quad \mathbf{x}^i \sim q, \quad \sup(q) = \sup(p). \quad (2.66)$$

Der Träger von q muss dabei gleich dem Träger von p sein, damit das Korrekturgewicht w immer existiert. Die Äquivalenz des derart berechneten Erwartungswertes zu (2.65) lässt sich durch die Erweiterung mit einer multiplikativen Eins im ursprünglichen Integral zeigen:

$$E_p\{f(\mathbf{x})\} = \int f(\mathbf{x}) \frac{p(\mathbf{x})}{q(\mathbf{x})} q(\mathbf{x}) d\mathbf{x} = \int [f(\mathbf{x})w(\mathbf{x})] q(\mathbf{x}) d\mathbf{x}. \quad (2.67)$$

Mit q lassen sich die Positionen der Stützstellen derart steuern, dass viele Stützstellen in Regionen des Zustandsraumes X gezogen werden, in denen das Produkt aus f und p betragsmäßig groß ist. Dadurch kann mit weniger Stichproben eine schnellere Konvergenz des Schätzwertes gegenüber der Stichprobengenerierung nach p erreicht werden. Diese Konzentration der Partikel in den wichtigen Bereichen des Zustandsraumes trägt auch den Namen „Methode der wesentlichen Stichprobe“ (engl. „Importance Sampling“).

Anwendung zur bayesschen Zustandsschätzung

Alle in Abschnitt 2.1.5 (Seiten 14 ff.) aufgeführten Zustandsschätzer lassen sich als Erwartungswerte auf der a-posteriori Wissensbasis darstellen. Für den EAP-Schätzer (2.40) gilt beispielsweise:

$$\hat{\mathbf{x}}_k^{EAP} = E_p\{f(\mathbf{x})\} = \int f(\mathbf{x}_k) p(\mathbf{x}_k | \mathbf{Z}_{1:k}) d\mathbf{x}_k, \quad \text{mit } f(\mathbf{x}_k) = \mathbf{x}_k. \quad (2.68)$$

Von der a-posteriori Wissensbasis $p(\mathbf{x}_k|\mathbf{Z}_{1:k})$ können in einem rekursiven Filterverfahren keine Stichproben wie in (2.65) gezogen werden, da diese Funktion beim Eintreffen der Messung $\mathbf{z}_k$ noch unbekannt ist. Daher wird der Erwartungswert (2.68) analog zu (2.67) mit der vorerst nicht näher bestimmten Dichtefunktion zur Steuerung der Stichprobengenerierung $q(\mathbf{x}_k|\mathbf{X}_{1:k-1}, \mathbf{Z}_{1:k})$ erweitert. Zusätzlich wird für die unbekannte a-posteriori Wissensbasis $p(\mathbf{x}_k|\mathbf{Z}_{1:k})$ die bayessche Korrekturformel (2.23) in den Erwartungswert (2.68) eingesetzt [17, 76]:

$$\hat{\mathbf{x}}_k^{EAP} = \int \mathbf{x}_k \frac{p(\mathbf{z}_k|\mathbf{x}_k)p(\mathbf{x}_k|\mathbf{Z}_{1:k-1})}{p(\mathbf{z}_k|\mathbf{Z}_{1:k-1})q(\mathbf{x}_k|\mathbf{X}_{1:k-1}, \mathbf{Z}_{1:k})} q(\mathbf{x}_k|\mathbf{X}_{1:k-1}, \mathbf{Z}_{1:k}) d\mathbf{x}_k \quad (2.69)$$

$$= \frac{1}{p(\mathbf{z}_k|\mathbf{Z}_{1:k-1})} \int \mathbf{x}_k w_k(\mathbf{x}_k) q(\mathbf{x}_k|\mathbf{X}_{1:k-1}, \mathbf{Z}_{1:k}) d\mathbf{x}_k, \quad w_k(\mathbf{x}_k) = \frac{p(\mathbf{z}_k|\mathbf{x}_k)p(\mathbf{x}_k|\mathbf{Z}_{1:k-1})}{q(\mathbf{x}_k|\mathbf{X}_{1:k-1}, \mathbf{Z}_{1:k})} \quad (2.70)$$

$$= \frac{\int \mathbf{x}_k w_k(\mathbf{x}_k) q(\mathbf{x}_k|\mathbf{X}_{1:k-1}, \mathbf{Z}_{1:k}) d\mathbf{x}_k}{\int p(\mathbf{z}_k|\mathbf{x}_k)p(\mathbf{x}_k|\mathbf{Z}_{1:k-1}) d\mathbf{x}_k} = \frac{\int \mathbf{x}_k w_k(\mathbf{x}_k) q(\mathbf{x}_k|\mathbf{X}_{1:k-1}, \mathbf{Z}_{1:k}) d\mathbf{x}_k}{\int w_k(\mathbf{x}_k) q(\mathbf{x}_k|\mathbf{X}_{1:k-1}, \mathbf{Z}_{1:k}) d\mathbf{x}_k} \quad (2.71)$$

$$= \frac{E_q\{\mathbf{x}_k w_k(\mathbf{x}_k)\}}{E_q\{w_k(\mathbf{x}_k)\}}. \quad (2.72)$$

Mit (2.65) lassen sich die zwei Erwartungswerte im Zähler und Nenner durch N gewichtete Stützstellen approximieren:

$$\hat{\mathbf{x}}_k^{EAP} \approx \frac{\frac{1}{N} \sum_{i=1}^N \mathbf{x}_k^i w_k^i}{\frac{1}{N} \sum_{i=1}^N w_k^i}, \quad \mathbf{x}_k^i \sim q \quad (2.73)$$

$$= \sum_{i=1}^N \mathbf{x}_k^i \bar{w}_k^i, \quad \text{mit } \mathbf{x}_k^i \sim q, \quad \bar{w}_k^i = \frac{w_k^i}{\sum_{j=1}^N w_k^j}. \quad (2.74)$$

Aufgrund der Normierung in (2.74) summieren sich alle Stützstellengewichte unabhängig von ihrer Anzahl N zu Eins. Damit ein rekursives Verfahren entsteht, muss die Steuerfunktion zur Stichprobengenerierung q und damit auch die von ihr abgeleiteten Stützstellengewichte $\bar{w}_k$ (2.70) aus der Stützstellenrepräsentation des vorherigen Zeitschrittes $k-1$ und der aktuellen Messung bestimmbar sein. Die einzelnen Varianten des Partikelfilters unterscheiden sich in der Wahl der Stichprobengenerierungsfunktion q .

Das SIR-Partikelfilter

Für die Generierung der Stichproben verwendet das SIR-Filter („Sequential Importance Resampling“) die aus dem vorherigen Zeitschritt prädizierte a-priori Wissensbasis:

$$q(\mathbf{x}_k|\mathbf{X}_{1:k-1}, \mathbf{Z}_{1:k}) = p(\mathbf{x}_k|\mathbf{Z}_{1:k-1}). \quad (2.75)$$

O.E.d.A. wird davon ausgegangen, dass eine ungewichtete Stützstellenrepräsentation $\bar{w}_{k-1}^i = N^{-1}$ (2.65) der a-posteriori Wissensbasis des vorherigen Zeitschrittes vorliegt. Um von der a-priori Wissensbasis Stichproben zu generieren, muss die Chapman-Kolmogorov Gleichung (2.25) auf diese ungewichtete Stützstellenrepräsentation (2.74) der a-posteriori Wissensbasis

des vorherigen Zeitschrittes angewendet werden. Dies geschieht, indem für jede der N Stützstellen der vorherigen a-posteriori Wissensbasis das Prozessmodell (2.27) mit jeweils M verschiedenen Stichproben des Prozessrauschens angewendet wird [58]. Gehen die Stützstellenzahl N der vorherigen Wissensbasis und die Anzahl der Prozessrauschstichproben M gegen unendlich, konvergiert diese Partikelapproximation gegen die tatsächliche Prädiktion der Wissensbasis $p(\mathbf{x}_k | \mathbf{Z}_{1:k-1})$:

$$\int_X p(\mathbf{x}_k | \mathbf{x}_{k-1}) p(\mathbf{x}_{k-1} | \mathbf{Z}_{1:k-1}) d\mathbf{x}_{k-1} = \lim_{N \rightarrow \infty, M \rightarrow \infty} \frac{1}{MN} \sum_{j=1}^M \sum_{i=1}^N \delta[\mathbf{x}_k - f(\mathbf{x}_{k-1}^i, \mathbf{v}_k^j)]$$

mit $\mathbf{v}_k^j \sim p(\mathbf{v})$, $\mathbf{x}_{k-1}^i \sim p(\mathbf{x}_{k-1} | \mathbf{Z}_{1:k-1})$. (2.76)

Da sich bei jedem Prädiktionsschritt die Anzahl der Stützstellen um den Faktor M vervielfacht, kann in der Praxis nur eine einzige Stichprobe des Prozessrauschens für jedes Partikel verwendet werden, damit die Stützstellenanzahl konstant bleibt. Für $M = 1$ und $N < \infty$ ergibt sich:

$$\int_X p(\mathbf{x}_k | \mathbf{x}_{k-1}) p(\mathbf{x}_{k-1} | \mathbf{Z}_{1:k-1}) d\mathbf{x}_{k-1} \approx \frac{1}{N} \sum_{i=1}^N \delta[\mathbf{x}_k - f(\mathbf{x}_{k-1}^i, \mathbf{v}_k^i)]$$

mit $\mathbf{v}_k^i \sim p(\mathbf{v})$, $\mathbf{x}_{k-1}^i \sim p(\mathbf{x}_{k-1} | \mathbf{Z}_{1:k-1})$. (2.77)

Für das unnormierte Partikelgewicht w_k^i ergibt sich aus (2.70) und (2.75):

$$w_k^i = \frac{p(\mathbf{z}_k | \mathbf{x}_k^i) p(\mathbf{x}_k^i | \mathbf{Z}_{1:k-1})}{p(\mathbf{x}_k^i | \mathbf{Z}_{1:k-1})} = p(\mathbf{z}_k | \mathbf{x}_k^i). \quad (2.78)$$

Das der Likelihoodfunktion der Messung entsprechende Partikelgewicht wird im Anschluss gemäß (2.74) normiert. Die a-posteriori Wissensrepräsentation zum Zeitschritt k ergibt sich mit den normierten Partikelgewichten zu:

$$p(\mathbf{x}_k | \mathbf{Z}_{1:k}) \approx \sum_{i=1}^N \bar{w}_k^i \delta(\mathbf{x}_k - \mathbf{x}_k^i). \quad (2.79)$$

Für den Prädiktionsschritt wurde eingangs jedoch eine ungewichtete Stützstellenrepräsentation vorausgesetzt. Um diesen Ausgangszustand für den nächsten Rekursionsschritt herzustellen, wird eine Neuapproximation der Stützstellen vorgenommen (engl. „Resampling“). Statt der Multiplikation der Dirac-Distribution mit dem Partikelgewicht wird bei dieser Neuapproximation jede mit $\bar{w}_k^i$ gewichtete Stützstelle $\mathbf{x}_k^i$ durch $\text{rd}(\bar{w}_k^i \cdot N)$ Kopien mit den Einheitsgewichten N^{-1} ersetzt:

$$p(\mathbf{x}_k | \mathbf{Z}_{1:k}) \approx \sum_{i=1}^N \bar{w}_k^i \delta(\mathbf{x}_k - \mathbf{x}_k^i) \quad (2.80)$$

$$= \frac{1}{N} \sum_{i=1}^N (\bar{w}_k^i N) \delta(\mathbf{x}_k - \mathbf{x}_k^i) \quad (2.81)$$

$$\approx \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^{\text{rd}(\bar{w}_k^i \cdot N)} \delta(\mathbf{x}_k - \mathbf{x}_k^i), \text{ mit } \sum_{i=1}^N \text{rd}(\bar{w}_k^i \cdot N) \stackrel{!}{=} N. \quad (2.82)$$

Aufgrund des Rundungsoperators rd entsteht jedoch ein Neuapproximationsfehler. Erwartungswerte und Momente der Stützstellenrepräsentation sollten deshalb vor der Neuapproximation berechnet werden.

Zusammenfassend besteht der Prädiktionsschritt des SIR-Partikelfilters aus der Anwendung des Prozessmodells (2.27) mit jeweils einer Prozessrauschstichprobe auf jedes Partikel des vorherigen Zeitschrittes. Im Innovationsschritt wird für diese neuen Partikelpositionen die Likelihood-Funktion der Messung (2.28) ausgewertet und eine Neuapproximation der Stützstellen gemäß (2.82) vorgenommen.

Die optimale Wahl der Stichprobengenerierungsfunktion wäre die a-posteriori Wissensbasis selbst [76]. Zur Verbesserung der Stichprobengenerierung verwendet das Partikelfilter mit Hilfszuständen (engl. „Auxiliary Particle Filter“, [72]) eine vorläufige prädizierte und mit der aktuellen Messung bewertete Wissensbasis zur Neuapproximation der Stützstellen im vorherigen Zeitschritt.

Im Gegensatz zum Kalman-Filter sind für das Partikelfilter keine Annahmen hinsichtlich der Linearität des Prozess- oder Messmodells oder der Normalverteilung der Störgrößen gemacht worden. Das Partikelfilter eignet sich daher insbesondere für Filterprobleme, bei denen diese Annahmen nicht erfüllt sind.

2.2.4 Weitere bayessche Filteralgorithmen

Dieser Abschnitt gibt ohne Herleitungen einen Überblick über die Konzepte anderer bayesscher Filteralgorithmen.

Das Sigma-Punkt-Kalman-Filter

Das Sigma-Punkt-Kalman-Filter (SPKF, auch Unscented-Kalman-Filter, UKF, [37, 90]) ist ein hybrider Ansatz aus parametrischer und numerischer Repräsentation. Wie beim Kalman-Filter werden die initialen Zustandsunsicherheiten, die Statistiken des Prozess- und Messrauschens und die a-priori und a-posteriori Wissensbasen in jedem Zeitschritt normalverteilt modelliert. Für die Mess- und Prozessmodelle (2.27),(2.28) sind im Gegensatz zum Kalman-Filter nichtlineare Funktionen des Zustandsvektors zulässig. Im Vergleich zum Extended-Kalman-Filter (Abschnitt 2.2.2) wird die Dichtefunktion des Zustandsvektors nicht durch eine analytische Approximation in Form einer Taylor-Entwicklung durch die nichtlinearen Modelle propagiert. Stattdessen erzeugt das SPKF zuerst einen erweiterten Zustandsvektor, der neben den Zustandsgrößen auch die Störgrößen des entsprechenden Modells enthält. Der Mittelwert und die Fehlerkovarianz des erweiterten Zustandsvektors ergeben sich durch blockweise Konkatenation der Ausgangsgrößen. Von der Dichtefunktion des erweiterten Zustandsvektors generiert das SPKF N Stützstellen derart, dass der empirische Mittelwert und die empirische Kovarianz der Stützstellenrepräsentation mit denen der ursprünglichen Dichtefunktion übereinstimmen. Im Anschluss wird diese Stützstellenrepräsentation punktwise durch das vollständige nichtlineare Mess- oder Prozessmodell propagiert. Durch Berechnung der empirischen Erwartungswerte und Kovarianzen kann die resultierende Stützstellenapproximation wieder in eine parametri-

sche Normalverteilung überführt werden. Mit den so berechneten Zustands- oder Messwertprädiktionen wird wie im regulären Kalman-Filter weitergerechnet.

MischverteilungsfILTER

Speziell bei Prozessmodellen ergeben sich Nichtlinearitäten durch verschiedene Manövervarianten des beobachteten Objektes. Für jede diskrete Manöveralternative, die über ein individuelles Prozessmodell oder einen individuellen Modellparametersatz oder beide verfügt, bildet sich in der prädizierten Wissensbasis möglicherweise eine separate Region mit hoher Aufenthaltswahrscheinlichkeit im Zustandsraum heraus. Diese multimodale a-priori Wissensbasis kann weder mit einer gaußschen noch mit einer Partikelapproximation stabil repräsentiert werden. Der Grund hierfür liegt bei der Partikelapproximation im Neuapproximationsschritt (2.82), der eine Vervielfachung hoch gewichteter Stützstellen auf Kosten der Existenz niedrig gewichteter Stützstellen darstellt. Dieses „Überleben der Stärksten“ führt über mehrere Filterschritte zum Kollaps sämtlicher Nebenmaxima einer Stützstellenrepräsentation. Das Kalman-Filter in allen seinen Varianten ist aufgrund der unimodalen Dichtefunktion der Normalverteilung ebenfalls für das Problem ungeeignet. Ein MischverteilungsfILTER (z.B. engl. „Interacting Multiple Model“, IMM, [8]) besteht aus mehreren separaten bayesschen Filtern für jede Modellalternative und einer diskreten Wahrscheinlichkeitsfunktion auf den Modellalternativen. Die gesamte Wissensbasis ist daher die mit der Modellwahrscheinlichkeit gewichtete Konvexkombination der Zustandsdichtefunktionen der Einzelfilter. Zur Berücksichtigung von Manöverwechseln des beobachteten Objektes wird jeder der Einzelfilter vor dem Prädiktionsschritt mit einer gewichteten Überlagerung der Zustandsschätzungen aller Einzelmodelle initialisiert. Die Gewichte ergeben sich aus den Modellwahrscheinlichkeiten und den Modellwechselwahrscheinlichkeiten. Zusätzlich werden die Modellwahrscheinlichkeiten selbst aus den Güten der Messwertprädiktionen der verschiedenen Modelle während des Betriebs ständig neu berechnet. Diese Vorgehensweise kann analog bei multimodalen Messmodellen verwendet werden.

2.3 Die klassische Systemarchitektur zur Mehrobjektverfolgung unter Detektions-, Assoziations- und Messgrößenunsicherheit

In nahezu allen bekannten Ansätzen zur Fahrzeugumfelderfassung hat sich eine einheitliche Systemarchitektur etabliert, welche die Teilprobleme der Objektdetektion, der Datenassoziation und der Objektverfolgung in spezialisierten Modulen löst (Abbildung 2.1). Der folgende




Abbildung 2.1: Die klassische Systemarchitektur zur Fahrzeugumfelderfassung in Anwesenheit von Detektions-, Assoziations- und Messgrößenunsicherheit. Jede dieser Unsicherheitsdomänen wird durch ein separates Modul aufgelöst.

Abschnitt gibt überblicksartig den Stand der Technik für jedes dieser Teilmodule wieder und setzt die verwendeten Verfahren in Beziehung zur Schätztheorie. Es wird ersichtlich, dass in der klassischen Systemarchitektur die Detektions-, Klassifikations- und Assoziationsaufgaben in der Regel durch separate ML-Schätzer und die Zustandsschätzung durch ein rekursives Bayes-Filter berechnet werden.

2.3.1 Objektdetektion und Segmentierung

Das Modul zur Objektdetektion überführt die Sensorrohdaten, wie z.B. Videobilder, Distanz- und Dopplerprofile, in eine Liste individuell erkannter Objekte. Neben den Rohdaten können auch vorverarbeitete Repräsentationen der Rohdaten wie Gradientenbilder, Stereobilder und Spektren zur Objektdetektion verwendet werden.

Merkmalsextraktion

Als **Basismerkmale** zur Musterklassifikation sind die Rohsignalintensitäten und -perioden (z.B. Bildhelligkeit, Doppler, Rückstreuquerschnitt, Echopulsbreite), deren Orts- und Zeitableitungen (z.B. Kantenbilder und optischer Fluss) sowie deren Orts- und Zeitspektren gebräuchlich. Neben diesen Basismerkmalen werden auch komplexere Merkmale verwendet.

Clusterverfahren werden in der Fahrzeugumfelderfassung ebenfalls häufig zur Objektdetektion eingesetzt. Räumliche Bereiche mit homogenem optischem Fluss, homogenen Abstandsmessungen aus Stereo- oder Strahlsensorik oder homogenen Textureigenschaften werden dabei zu Objektkandidaten zusammengefügt. Für jeden Cluster werden Merkmale wie das Volumen, die Form und die räumliche Verteilung von anderen Merkmalen innerhalb des Clusters zur Entscheidung extrahiert.

Korrelationsbasierte Verfahren (engl. „Template Matching“) unterhalten eine Datenbank von charakteristischen Repräsentanten der Objektklassen in einem ersten Merkmalsraum. Diese Repräsentanten sind entweder durch einzelne Punkte oder durch parametrische Funktionen (engl. „Deformable Templates“) in diesem Merkmalsraum beschrieben. Der eigentliche Merkmalsraum für die Detektions- bzw. Klassifikationsentscheidung wird im Anschluss durch die Abstände des zu untersuchenden Musters zu jedem der Repräsentanten aufgespannt. Die Herausforderung dieser Verfahren besteht in der Wahl der Repräsentanten und der Definition einer Metrik zur Abstandsberechnung.

Eine Spezialform der Korrelationsverfahren ist die Extraktion von **Wavelet-Merkmalen**. Dabei wird das Orts- oder Zeitrohsignal des Sensors mit räumlich oder zeitlich begrenzten Basisfunktionen gefaltet. Der Entscheidungsmerkmalsraum wird hier durch die Faltungssummen aller Wavelettypen an verschiedenen aber festgelegten Positionen im zu untersuchenden Mustersignal aufgespannt.

Entscheidungsmechanismen im Merkmalsraum

Ein Detektionsalgorithmus ist ein binärer Klassifikationsalgorithmus für die extrahierten Merkmalsvektoren.

Die ersten Erkennungsverfahren waren regelbasierte Entscheidungssysteme (auch **Expertensysteme**). Allgemein wird dabei durch eine Schwellwertoperation für jedes Merkmal eine binäre Entscheidung herbeiführt. Die auf den Merkmalen basierenden Einzelentscheidungen werden im Anschluss durch logische Verknüpfungen zusammengeführt. Charakteristisch für ein Expertensystem sind die manuelle Auswahl der Merkmale, der Entscheidungsschwellwerte und die manuelle Festlegung der Verknüpfungslogik. Betrachtet man die konkreten Merkmalswerte, beispielsweise Breiten, Höhen und Intensitätswerte, als Punkt in einem Merkmalsraum, wird durch jeden Schwellwert eine achsenparallele Trennhyperebene definiert, die positive und negative Merkmalsvektoren separiert. Durch die logische Kombination der Einzelentscheidungen lassen sich komplexere Bereiche im Merkmalsraum für eine positive Entscheidung ausselektieren. Innerhalb dieser Bereiche werden die Rückschlusswahrscheinlichkeiten (2.17) zu Eins und außerhalb zu Null gesetzt. Dieses manuelle Vorgehen ist nur bei sehr niedrigdimensionalen Merkmalsräumen, bei physikalisch interpretierbaren Merkmalen und bei guter Separation der




Abbildung 2.2: Verteilung der positiven (o) und negativen (x) Merkmalsvektoren einer vorklassifizierten Lernstichprobe im 2D-Merkmalraum (3σ -Ellipsen) und die optimale Trennfunktion C .

zu unterscheidenden Objektklassen im Merkmalsraum adäquat.

Probabilistische Verfahren geben direkt die auf die Merkmalswerte f bedingten Rückschlusswahrscheinlichkeiten auf die Objektklassen $p(\mathbf{x}|f(\mathbf{z}))$ an. Dies kann beispielsweise durch Berechnung der Rückschlusswahrscheinlichkeiten aus einer vorklassifizierten Lernstichprobe erfolgen. Für diskrete Merkmale kann $p(\mathbf{x}|f(\mathbf{z}))$ direkt aus den relativen Häufigkeiten des Merkmals in den Objektklassen approximiert werden. Für stetige Merkmale kann das gleiche Verfahren nach einer Diskretisierung angewendet werden. Alternativ wird eine parametrische Verteilung in die Merkmalshäufigkeiten eingepasst, zum Beispiel mit dem „Expectation-Maximization“-Algorithmus (EM, [19]).

Sind die Rückschlusswahrscheinlichkeiten für eine konkrete Merkmalsausprägung ermittelt, wird die diskrete Entscheidung beispielsweise mit dem ML-Schätzer (2.35) berechnet. Abbildung 2.2 zeigt eine exemplarische Verteilung der positiven und negativen Merkmalsvektoren in einem zweidimensionalen Merkmalsraum und deren durch Normalverteilungen approximierte Dichtefunktionen. Zusätzlich ist die optimale Trennfunktion C bezüglich des Fehlklassifikationsrisikos dargestellt, die Gebiete des Merkmalsraumes separiert, in denen der ML-Schätzer für oder gegen die Objektexistenz entscheidet.

Lernende Verfahren übergehen die probabilistische Repräsentation und verwenden eine auf den Merkmalswerten basierende direkte Entscheidungsregel. Die Struktur dieser Trennfunktion ist in der Regel vorgegeben, ihre Parameter werden jedoch unter Minimierung der Fehlerstatistik einer Teststichprobe angepasst. Bekannte Vertreter dieser Verfahren sind die neuronalen Netze, bei denen die Struktur der Entscheidungsregel durch die Neuronentypen und die Netztopologie vorgegeben ist. Die gelernten Parameter der Entscheidungsregel sind die Synapsengewichte und die Aktivierungsschwellwerte. Andere Vertreter sind die Polynomklassifikatoren, bei denen die Trennfunktion durch ein Polynom in den Merkmalswerten festgelegt ist. Die gelernten Parameter sind hier die Polynomkoeffizienten. Die Supportvektormaschinen (SVN,

[14]), Hyperpermutationsnetzwerke (HPN, [68]) und die neuronalen Zeitverzögerungsnetzwerke (TDNN, [104]) sind weitere Vertreter dieser Algorithmenklasse.

Eine Weiterentwicklung der Lernverfahren sind die **strukturadaptiven Lernverfahren**. Hier werden nicht nur die Parameter der Entscheidungsregel fehlerminimierend angepasst, sondern auch deren Struktur. Das Boosting-Verfahren [25] bestimmt neben der Parameteroptimierung auch die Anzahl der verwendeten Merkmale und wählt deren Typen aus einem Merkmalsvorrat automatisch aus. Dadurch entfällt die manuelle Merkmalsauswahl. Eine Weiterentwicklung dieses Verfahrens ordnet mehrere derartige Boosting-Klassifikatoren in einem Entscheidungsbaum an. Diese Anordnung, d.h. die Anzahl und Tiefe der Verzweigungen, ist hier ebenfalls ausschließlich datengetrieben. Es entfällt somit auch die manuelle Festlegung der Topologie der Entscheidungsregel und alle bestimmenden Faktoren, d.h. Topologie, Merkmale und Parameter, werden voll automatisch extrahiert. Nicht zuletzt deshalb sind diese Verfahren zurzeit dominierend in der kameragestützten Objektdetektion.

Trotz immer weiter optimierter Detektionsverfahren lassen sich bei realen Daten mit keiner der beschriebenen Methoden Falschalarme und Fehldetektionen vermeiden. In Abbildung 2.2 sind diese Fehler durch Merkmalsvektoren ersichtlich, die sich auf der „falschen Seite“ der Trennfunktion befinden. In realen hochdimensionalen Merkmalsräumen lassen sich die Ursachen dieser Fehlklassifikationen in der Regel nicht feststellen. Speziell ist dabei unklar, ob die Lernstichprobe die tatsächlichen Merkmalstatistiken nicht adäquat wiedergibt und der Klassifikator damit falsch parametrisiert ist oder ob das Problem prinzipiell im verwendeten Merkmalsraum mit der Struktur der gewählten Trennfunktion nicht separierbar ist.

Die Leistung der Objektdetektion kann mit „Receiver Operating Characteristics“-Kurven (ROC) beschrieben werden (siehe Abschnitt 5.3, Seiten 159 ff.).

2.3.2 Datenassoziation

Für die Datenassoziation wird o.E.d.A. vorausgesetzt, dass bereits ein Umfeldmodell aus der Historie vorliegt. Nachdem eine Anzahl von Messdaten Z aufgezeichnet wurde, besteht die Aufgabe der Datenassoziation in der Zuordnung der Messungen zu den Objektrepräsentationen des Umfeldmodells. Diese Zuordnung ist nicht trivial, da einerseits die Objektzustände im Umfeldmodell mit einem Schätzfehler und andererseits die gemessenen Objektzustände mit einem Messfehler behaftet sind. Diese Fehler führen zu Positionsabweichungen von korrespondierenden Objekten und Messungen und können zu Mehrdeutigkeiten bei der Zuordnung führen. Bei der Verfolgung einer zeitlich veränderlichen Anzahl von Objekten müssen zusätzlich Messwerte ausgewiesen werden, für die keine Zuordnung zu einem bekannten Objekt möglich war, und die daher potenziell neu erschienene Objekte repräsentieren. Ebenso müssen Objekte des Umfeldmodells gekennzeichnet werden, für die keine Messungen zugeordnet werden konnten und die daher in der Realität den sensorischen Überwachungsbereich eventuell verlassen haben.

Dieses Datenassoziationsproblem kann unter Vernachlässigung der Detektionsunsicherheit in Form eines bipartiten Graphen $G = (V, E)$ mit Kantenmenge E und zweigeteilter Knotenmenge $V = (X, Z)$ dargestellt werden. Die Knotenuntermenge $X = \{1, \dots, n\}$ enthält die Indizes der n Objekte im Umfeldmodell und die Knotenuntermenge $Z = \{1, \dots, m\}$ die Indizes der vom Sensor aufgezeichneten m Messungen. Eine Zuordnung (engl. „Matching“) ist im Sinne




Abbildung 2.3: Darstellung einiger gültiger Zuordnungen von drei Messungen zu zwei Objekten als bipartite Graphen. Die Indexknoten der Objekte des Umfeldmodells sind in Kreisen und die Indexknoten der Messungen in Quadraten dargestellt. Kardinalitätsunterschiede werden durch das Spezialelement $\textcircled{S}$ ausgeglichen.

des Datenassoziationsproblems gültig, wenn alle Kanten $e \in E$ nur jeweils Knoten aus X und Z verbinden und keine Kante innerhalb dieser Mengen verläuft, also $e \in X \times Z$. Besitzen die Objektmenge X und die Messmenge Z unterschiedliche Kardinalitäten wird jeweils die Menge mit der geringeren Anzahl von Elementen durch Spezialelemente $\textcircled{S}$ aufgefüllt. Weiterhin schließen einfache Assoziationsverfahren Mehrfachdetektionen des gleichen Objektes aus und modellieren eine ideale Objekttrennfähigkeit des Sensors. In diesem Fall wird für die Kantenmenge E zusätzlich gefordert, dass in ihr nur „1-zu-1“-Zuordnungen enthalten sind, also jeder Knoten $v \in V$ den Grad Eins besitzt. Abbildung 2.3 zeigt mehrere gültige Zuordnungen für den Fall zweier Objekte im Umfeldmodell $|X| = 2$ und dreier Messungen $|Z| = 3$.

Nach der Prädiktion des Umfeldmodells auf den aktuellen Messzeitpunkt k kann die Likelihood der Assoziation eines bestimmten Objektes i zu einer bestimmten Messung $\mathbf{z}^j$ und damit die Likelihood der Graphenkante $e = (i, j)$ berechnet werden. Diese Likelihood ist die Wahrscheinlichkeit des Auftretens der Messung $\mathbf{z}^j$, gegeben die Menge aller bisher für das Objekt i aufgezeichneten Messungen $\mathbf{Z}_{1:k-1}^i$:

$$\Lambda(e = (i, j)) = p(\mathbf{z}_k^j | \mathbf{Z}_{1:k-1}^i) \quad (2.83)$$

$$= \int p(\mathbf{z}_k^j | \mathbf{x}_k^i) p(\mathbf{x}_k^i | \mathbf{Z}_{1:k-1}^i) d\mathbf{x}_k^i. \quad (2.84)$$

Dieser Term entspricht der Normierung in (2.23). Dabei ist $p(\mathbf{x}_k^i | \mathbf{Z}_{1:k-1}^i)$ die auf den Zeitpunkt k prädizierte probabilistische Wissensrepräsentation über den Zustand des Objektes i im Umfeldmodell (2.25). Im Kontext der Kalman-Filterung erfolgt die Wissensrepräsentation ausschließlich mit Normalverteilungen (Abschnitt 2.2.1). In diesem Fall werden das Messmodell $p(\mathbf{z}_k^j | \mathbf{x}_k^i)$ und die Wissensrepräsentation durch die Normalverteilungsdichten (2.49) und (2.47) ersetzt:

$$\Lambda(e = (i, j)) = \int \mathcal{N}(\mathbf{z}_k^j, \mathbf{H}_k \mathbf{x}_k^i, \mathbf{R}_k^j) \mathcal{N}(\mathbf{x}_k^i, \hat{\mathbf{x}}_{k|k-1}^i, \hat{\mathbf{P}}_{k|k-1}^i) d\mathbf{x}_k^i. \quad (2.85)$$

Durch Lemma 7 (Anhang A, Seite 180) ergibt sich:

$$\Lambda(e = (i, j)) = \mathcal{N}(\mathbf{z}_k^j, \mathbf{H}_k \hat{\mathbf{x}}_{k|k-1}^i, \mathbf{H}_k \hat{\mathbf{P}}_{k|k-1}^i \mathbf{H}_k^T + \mathbf{R}_k^j) \quad (2.86)$$

$$= \mathcal{N}(\boldsymbol{\gamma}^{ij}, \mathbf{0}, \mathbf{S}^{ij}) \quad (2.87)$$

mit dem Residuum γ und der Residuumkovarianz $\mathbf{S}$:

$$\gamma^{ij} = \mathbf{z}_k^j - \mathbf{H}_k \hat{\mathbf{x}}_{k|k-1}^i \quad (2.88)$$

$$\mathbf{S}^{ij} = \mathbf{H}_k \hat{\mathbf{P}}_{k|k-1}^i \mathbf{H}_k^T + \mathbf{R}_k^j. \quad (2.89)$$

Da die Assoziationen e von einzelnen Objekten zu einzelnen Messungen innerhalb der Gesamtzuordnung E gegenseitig disjunkte aber gleichzeitige Ereignisse sind, ergibt sich die Likelihood der Gesamtzuordnung aus dem Produkt der Kanten-Likelihoods:

$$\Lambda(E) = \prod_{e \in E} \Lambda(e). \quad (2.90)$$

Aus den Potenzgesetzen, (2.41), (2.86) und (2.90) ergibt sich (Lemma 9, Anhang A, Seite 182):

$$\Lambda(E) = (2\pi)^{-\frac{\dim(\mathbf{z}^j)N}{2}} \exp \left[-\frac{1}{2} \sum_{(i,j) \in E} [(\gamma^{ij})^T (\mathbf{S}^{ij})^{-1} \gamma^{ij} + \ln |\mathbf{S}^{ij}|] \right]. \quad (2.91)$$

Es ist leicht ersichtlich, dass diejenige Gesamtzuordnung E eine maximale Likelihood $\Lambda(E)$ aufweist, die den Summenterm in (2.91) minimiert. Infolge dessen erhält jede Kante $e = (i, j)$ des vollständigen bipartiten Graphen G das Kantengewicht:

$$w^{ij} = (\gamma^{ij})^T (\mathbf{S}^{ij})^{-1} \gamma^{ij} + \ln |\mathbf{S}^{ij}|. \quad (2.92)$$

Der erste Summand entspricht der quadrierten Mahalanobis-Distanz [52] zwischen Messung und Objekt. Kanten, die Spezialelemente zum Kardinalitätsausgleich enthalten, erhalten ein einheitliches Gewicht, das größer als das größte Kantengewicht ohne Spezialelemente ist. Die Aufgabe, unter allen gültigen Zuordnungen E diejenige mit der größten Plausibilität auszuwählen entspricht dann dem Auffinden einer gewichtsminimalen vollständigen Zuordnung (engl. „Bipartite Minimum Weight Perfect Matching“) in G . Negiert man alle Kantengewichte, entspricht das Problem dem „Bipartite Maximum Weight Perfect Matching“-Problem.

Um diese maximale Zuordnung zu finden, also den ML-Schätzer (2.35)

$$\hat{E}^{\text{ML}} = \underset{E}{\operatorname{argmax}} \Lambda(E) \quad (2.93)$$

auf das Datenassoziationsproblem anzuwenden, existieren mehrere Algorithmen. Der triviale Ansatz zählt alle möglichen Zuordnungen E auf, um das Maximum zu identifizieren. Es existieren

$$N = \frac{\max\{m, n\}!}{(\max\{m, n\} - \min\{m, n\})!} \quad (2.94)$$

verschiedene gültige Zuordnungen. Damit ist die Laufzeit (uniformes Zeitkomplexitätsmaß) des trivialen Ansatzes im besten Fall konstant ($L_{triv}^{bc} \in O(1)$), da für $m = 0$ und/oder $n = 0$ nur eine einzige Zuordnung E existiert. Im ungünstigsten Fall ($m = n$) ist die Laufzeit exponentiell in der Anzahl der Messungen bzw. Objekte, da hier $n!$ Zuordnungen existieren. Mit der Stirling-Formel [84] lässt sich für die „worst-case“-Laufzeit des trivialen Algorithmus $L_{triv}^{wc} \in O(n^n)$ abschätzen:

$$\sqrt{2\pi n} \left(\frac{n}{e}\right)^n \leq n! \leq \sqrt{2\pi n} \left(\frac{n}{e}\right)^n e^{\frac{1}{12n}}. \quad (2.95)$$

Das Problem einer gewichtsmaximalen vollständigen Zuordnung in bipartiten Graphen liegt trotz der exponentiellen „worst-case“-Komplexität des trivialen Algorithmus in der Klasse der in Polynomialzeit lösbaren Probleme P. Der Kuhn-Munkres Algorithmus (auch ungarische Methode, [24, 135]) erreicht eine WC-Komplexität von $O(\max\{m, n\}^3)$.

Da (2.92) ein statistisches Distanzmaß ist, wird der Maximum-Likelihood Schätzer für das Datenassoziationsproblem auch als „Global Nearest Neighbour“-Verfahren (GNN) bezeichnet. Sogenannte „Greedy“-Verfahren [79], die immer die Gewichtsmaximale unter den noch nicht zu E hinzugefügten Kanten auswählen, bis die Zuordnung vollständig ist, ermitteln nicht die global gewichtsmaximale Zuordnung $\hat{E}^{\text{ML}}$, sondern ein lokales Optimum [79]. Diese sehr schnellen aber suboptimalen Verfahren tragen auch den Namen „Nearest Neighbour“-Algorithmen (NN).

Wurde eine Zuordnung E gewählt, werden alle Kanten, die nur Indexknoten verbinden, an die Zustandsfilterstufe weitergereicht (Abbildung 2.1). Messungen, die mit dem Spezialelement verbunden wurden, initialisieren neue Objekte im Umfeldmodell. Objekte, die mit Spezialelementen verbunden wurden, sind Kandidaten für eine Löschung aus dem Umfeldmodell.

2.3.3 Zustandsfilterung

Die Zustandsfilterbank enthält pro Objekt im Fahrzeugumfeldmodell ein rekursives Bayes-Filter. Diese können beispielsweise mit den Varianten aus Abschnitt 2.2 implementiert sein. Für die Datenassoziation mussten die Wissensrepräsentationen der einzelnen Objekte bereits auf den aktuellen Messzeitpunkt prädiert werden (2.84). Mit den von der Datenassoziation berechneten Paarungen von Objekten und Messungen werden jetzt die Filterinnovationen für jedes Objekt berechnet.

2.3.4 Objektvalidierung und Objektmanagement

Da die Anzahl der Objekte zeitveränderlich ist, müssen sie dynamisch in das Umfeldmodell aufgenommen oder gelöscht werden. In diesem Abschnitt werden Merkmale und Entscheidungsregeln für die Löschung und Validierung von Objekten besprochen.

Allgemeine Objektgüterkmale

Ein neues Objekt und damit ein neues Zustandsfilter werden für jede Messung initialisiert, für die innerhalb der Datenassoziationsstufe kein zugehöriges Objekt ermittelt werden konnte. Aufgrund der Präsenz von Falschdetektionen ist es aber möglich, dass ein durch eine solche Messung initialisiertes Objekt in der Realität überhaupt nicht existiert. Für diesen Fall wird jedes Objekt zunächst in den Zustand „vorläufig“ gesetzt. Objekte in diesem Zustand werden nicht in das Umfeldmodell ausgegeben, sondern lediglich intern gespeichert. Unter der Annahme, dass Falschdetektionen nur sporadisch auftreten, erhält ein von einer Falschdetektion initialisiertes Objekt in der Zukunft keine regelmäßigen Innovationen mehr. Daher wird für den Übergang des Objektes i in den Zustand „bestätigt“ und damit für die Ausgabe des Objektes in das Umfeldmodell gefordert, dass die absolute Anzahl der erfolgreichen Messwertassoziationen

seit der Objektinitialisierung N_{EA} größer als ein Schwellwert T_1 ist:

$$\text{Regel 1 : } N_{EA}(i) > T_1. \quad (2.96)$$

Die Zustandsunsicherheiten von Objekten, die von sporadischen Falschalarmen initialisiert wurden und die daher keine oder wenige weitere Innovationen erhalten, wachsen durch das Prozessrauschen immer weiter an. Zusätzlich wandern die falschen Objektrepräsentationen aufgrund der mangelnden Innovationen unkontrolliert durch den Zustandsraum. Durch diese Effekte können auch Falschobjekte sporadisch Innovationen von weiteren Falschdetektionen erhalten und irgendwann trotzdem den Schwellwert aus Regel 1 überschreiten. Deshalb wird zusätzlich gefordert, dass das Verhältnis von erfolgreichen Messewertassoziationen N_{EA} zur Gesamtanzahl an Filterschritten und damit zum Alter A des Objektes größer als ein weiterer Schwellwert T_2 ist:

$$\text{Regel 2 : } \frac{N_{EA}(i)}{A(i)} > T_2. \quad (2.97)$$

Bei Sensorfusionssystemen vervielfachen sich diese Regeln mit der Anzahl der Sensoren. Zusätzlich sollen oft keine Objekte ausgegeben werden, deren Zustandsunsicherheiten größer als eine Schwelle ist, die noch als aussagekräftig angesehen wird. Ein skalares Maß für einen derartigen Test ist das Volumen des 1σ -Hyperellipsoiden der Schätzfehlerkovarianz $\mathbf{P}$ des Objektes:

$$\text{Regel 3 : } \frac{\pi^{\frac{1}{2} \dim(\mathbf{x})}}{\Gamma(1 + \frac{1}{2} \dim(\mathbf{x}))} \sqrt{\det \mathbf{P}} < T_3. \quad (2.98)$$

Ein weiteres Merkmal für das tatsächliche Vorhandensein oder Nichtvorhandensein eines Objektes trotz erfolgreicher Assoziationen ist die aus der Zustandsfilterung ermittelte Objektdynamik und speziell deren Übereinstimmung mit dem Prozessmodell. Hier wird die Annahme verwendet, dass Falschdetektionen über der Zeit keine Trajektorien im Messraum ausbilden, die denen der gesuchten Objektklasse ähnlich sind. Ist die Dichtefunktion der räumlichen Verteilung von Falschalarmen $p(\mathbf{z}|\nexists\mathbf{x})$ bekannt, kann das Likelihood-Verhältnis der beiden Hypothesen Objektdetektion und Falschdetektion gegen einen Schwellwert verglichen werden:

$$\text{Regel 4 : } \frac{\mathcal{N}(\mathbf{z}^j, \mathbf{H}\hat{\mathbf{x}}^i, \mathbf{S}^{ij})}{p(\mathbf{z}^j|\nexists\mathbf{x})} > T_4. \quad (2.99)$$

Diese Regeln zum Ausschluss der Ausgabe von falschen Objekten an nachfolgende Module können mit anderen Schwellwerten und umgekehrten Ungleichheitszeichen ebenfalls zum Löschen von Objekten aus dem Umfeldmodell verwendet werden.

Koaleszenz von Objektrepräsentationen

Neben der Möglichkeit, dass zu Falschobjekten sporadisch weitere Falschdetektionen assoziiert werden, können Falschobjekte während der Datenassoziation auch korrekten Objektrepräsentationen ihre zugehörigen Messungen entziehen. Die Zustandsunsicherheiten eines von einem Falschalarm initiierten Objektes ($\hat{\mathbf{x}}^1, \hat{\mathbf{P}}^1$) können durch fehlende Innovationen sehr groß werden (Abbildung 2.4). Obwohl sich ein solches Falschobjekt in einer viel größeren euklidischen Distanz zu einer Messung befindet, kann die zur Assoziation verwendete statistische




Abbildung 2.4: Mehrdeutige Assoziationssituation im Messraum eines Sensors: Der minimale euklidische Abstand besteht zwischen der Messung $\mathbf{z}$ und der Objektrepräsentation $\hat{\mathbf{x}}^2$. Der minimale statistische Abstand (2.92) besteht zwischen der Messung $\mathbf{z}$ und der Objektrepräsentation $\hat{\mathbf{x}}^1$.

Distanz (2.92) dieser Messung zum Falschobjekt kleiner werden als zu einem anderen tatsächlich zugehörigen Objekt. Dies ist insbesondere der Fall, wenn gleichzeitig bei dem tatsächlich vorhandenen Objekt ($\hat{\mathbf{x}}^2, \hat{\mathbf{P}}^2$) entweder das Messrauschen sehr stark realisiert wird und/oder der Schätzwert und damit die Messwertprädiktion $\mathbf{H}\hat{\mathbf{x}}^2$ gerade weit vom tatsächlichen Objektzustand entfernt ist. Infolge dessen wird bei „1-zu-1“-Assoziationen das Falschobjekt die Innovation der Messung erhalten und das physisch vorhandene Objekt nicht. Aufgrund der im Vergleich zum Messrauschen $\mathbf{R}$ hohen Zustandsunsicherheit des Falschobjektes wird die Kalman-Verstärkung (2.59) die Innovation stark zu Gunsten der Messung gewichtet und damit die falsche Objektrepräsentation in die Nähe des echten Objektes bewegen. Zudem wird die Zustandsunsicherheit des Falschobjektes stark verringert und die der richtigen Objektrepräsentation mangels Innovation vergrößert. Dies kann nach einigen Filterschritten dazu führen, dass beide Objektrepräsentationen ihre Rollen tauschen und nunmehr das vormals falsche Objekt ein real vorhandenes Objekt repräsentiert und die vormals richtige Objektrepräsentation zum „Geisterobjekt“ wird. Steigt die Zustandsunsicherheit des vormals richtigen Objektes immer weiter an, kann der Wechsellvorgang erneut in umgekehrter Richtung beginnen. Da hier letztendlich mehrere Objektrepräsentationen von den Messungen eines einzigen real vorhandenen Objektes gespeist werden, spricht man vom Zusammenfall von Objektrepräsentationen oder Objekt-Koaleszenz [9, 10, 71].

Als Ausschlussregel für derartige Situationen kann eine minimale euklidische Distanzschwelle für zwei Objektrepräsentationen im Zustandsraum verwendet werden, die typischerweise in der Größe der Objektabmessungen angesetzt wird. Unterschreiten zwei Repräsentationen diesen Abstand, wird eine von beiden aus dem Umfeldmodell gelöscht:

$$\text{Regel 5 : } D_{EUK}(\hat{\mathbf{x}}^j, \hat{\mathbf{x}}^i) > T_5, \forall i \neq j. \quad (2.100)$$

Zustandsbeschränkungen

Neben den bereits vorgestellten Objektgütemerkmalen liefert auch der Anwendungskontext Beschränkungen für plausible Objektrepräsentationen. Es können zum Beispiel nur Objekte

verfolgt werden, die sich innerhalb der Sichtbereiche der Sensoren (engl. „Field of View“, FOV) befinden:

$$\text{Regel 6 : } \hat{\mathbf{x}} \in FOV. \quad (2.101)$$

Verallgemeinert können Zustandsbeschränkungen nicht nur für die Position, sondern auch für Geschwindigkeiten und Abmessungen von Objekten bestehen. Es ist beispielsweise unwahrscheinlich, dass eine Objektbeschreibung mit einer Geschwindigkeit von mehr als 250 km/h ein reales Fahrzeug repräsentiert. Zustandsbeschränkungen können auch aus digitalen Karten entnommen werden [102].

In realen klassischen Wahrnehmungssystemen wird nur eine Teilmenge der hier vorgestellten Regeln verwendet. In gut separierbaren Umgebungen mit großer Signal-zu-Falschalarmrate (engl. „Signal-to-Clutter Ratio“, SCR) ist ein derartiges Regelsystem adäquat. In [102] wurde statt der regelbasierten Entscheidung erneut ein Klassifikationsalgorithmus auf den vorgestellten Merkmalen, den Zustandsgrößen und den Merkmalen aus der Detektionsstufe trainiert. Die Ausgaben dieses Klassifikators wurden im Anschluss zeitlich tiefpassgefiltert und zur Entscheidungsfindung verwendet.

2.3.5 Diskussion und Kritik

In der beschriebenen modularen Systemarchitektur (Abb. 2.1) findet an den Schnittstellen eine Informationsverdichtung zur Objekt- oder Trackliste statt. Diese Informationsreduktion erlaubt eine schnelle rechnergestützte Verarbeitung. Ein weiterer Vorteil ist die getrennte Parametrisierung und Optimierung sowie die Austauschbarkeit der einzelnen Komponenten.

Modellwechsel

Jedes der Module in Abbildung 2.1 verwendet ein mathematisches Modell, das auf die jeweilige Unsicherheitsdomäne spezialisiert ist. Das unscharfe Wissen wird in jedem Modul durch eine Wahrscheinlichkeitsfunktion auf diesen mathematischen Modellen repräsentiert.

Innerhalb der Detektionsphase wird häufig ein binäres Modell verwendet (2.1). Hier werden die Existenz, die Beobachtbarkeit und die Relevanz eines Objektes zum symbolischen Ereignis $\exists \mathbf{x}$ zusammengefasst. Das Gegenereignis $\nexists \mathbf{x}$ ist die Vereinigung der Nicht-Existenz, Nicht-Beobachtbarkeit und Nicht-Relevanz. Ein Detektionsalgorithmus ordnet diesen Ereignissen anhand der gemessenen Merkmale zunächst Rückschlusswahrscheinlichkeiten zu, die die Detektionsunsicherheit beschreiben (Abb. 2.5/links). Innerhalb der Datenassoziationsstufe besteht der ebenfalls diskrete Ereignishorizont aus der Menge der gültigen Zuordnungen E (Abschnitt 2.3.2). Für die Datenassoziation wurde aber implizit die tatsächliche Existenz der vermessenen Objekte und der Objekte im Umfeldmodell angenommen. Daher muss die probabilistische Wissensrepräsentation $p^\exists$ aus der Detektionsstufe durch die Berechnung eines ML-Schätzwertes (2.35), also durch eine Detektionsentscheidung, auf die impliziten Existenzannahmen des Modells in der Assoziationsstufe angepasst werden (Abb. 2.5/rechts).

In der Zustandsfilterstufe ist der Ereignishorizont der kontinuierliche n -dimensionale Zustandsraum. Die Unsicherheitsdomäne der Zustandsgrößen wird durch eine Aufenthaltswahrschein-




Abbildung 2.5: Nach der frühen Detektionsentscheidung gehen die Datenassoziation und die Objektverfolgung von der sicheren Existenz des Objektes aus.




Abbildung 2.6: Berechnung des ML-Schätzwertes für die Wahrscheinlichkeitsfunktion auf den Zuordnungshypothesen während der Datenassoziation. Die Objektverfolgung verwendet diese Zuordnung zur Berechnung der Innovationen.

lichkeitsdichtefunktion im Zustandsraum beschrieben (siehe Abschnitt 2.2). Da diese Funktion die Wahrscheinlichkeits-Axiome (2.3) bis (2.5) erfüllt, integriert sie sich über den gesamten Zustandsraum zu Eins. Das bedeutet, dass dieses Modell die Objektexistenz implizit als sicheres Ereignis annimmt. Das Modell ist daher ebenfalls nicht in der Lage, Existenzunsicherheiten zu repräsentieren. Außerdem ist das Modell der Aufenthaltswahrscheinlichkeitsdichtefunktion im Zustandsraum nicht in der Lage, Assoziationsunsicherheiten zu repräsentieren. Deshalb muss das unscharfe Wissen aus der vorherigen Verarbeitungsstufe, der Datenassoziation, wieder in eine für die Zustandsfilterung kompatible Repräsentation umgewandelt werden. Dies geschieht durch die Berechnung des ML-Schätzwertes, der eine Entscheidung zu Gunsten der plausibelsten Gesamtzuordnung unter Vernachlässigung aller weniger wahrscheinlichen Datenassoziationen darstellt (Abb. 2.6).

Charakteristisch für die Modellwechsel zwischen den Modulen sind demnach die Umwandlungen der vorliegenden probabilistischen Wissensrepräsentationen in für die nachfolgende Stufe kompatible deterministische Wissensrepräsentationen durch die frühe Entscheidung für eine Modellalternative und die ausschließliche Weiterverwendung dieses Schätzwertes.




Abbildung 2.7: Normierte Negentropie über der Rückschlusswahrscheinlichkeit für die Objektexistenz. Die Anwendung des ML-Schätzers, d.h. die Konvertierung in eine deterministische Repräsentation, erhöht den Informationsgehalt der resultierenden Wissensbasis.

Die Nachteile von frühen Detektions- und Assoziationsentscheidungen

Frühe Detektions- oder Assoziationsentscheidungen zu Gunsten des ML-Schätzwertes $\hat{\mathbf{x}}^{\text{ML}}$ des jeweiligen Modells sind mit der Wahrscheinlichkeit beziehungsweise mit der relativen Häufigkeit $1 - p(\hat{\mathbf{x}}^{\text{ML}})$ falsch.

Aus informationstheoretischer Sicht wird der Informationsgehalt der gesamten Wissensrepräsentation mit jeder Entscheidung erhöht. Für das Beispiel der Detektionsrückschlusswahrscheinlichkeiten aus Abbildung 2.5 zeigt Abbildung 2.7 die normierte Negentropie (2.9) der Wissensbasis vor und nach der Detektionsentscheidung. Der Informationszuwachs ΔJ stammt aber weder aus der Messwerthistorie, noch aus der aktuellen Messung oder einem Sensormodell und ist analog mit Wahrscheinlichkeit $p(\nexists \mathbf{x})$ falsch. Mit der gleichen Argumentation führt auch eine Assoziationsentscheidung nicht substanzielle Zusatzinformation in die Wissensbasis ein.

Fehlentscheidungen in der Detektionsstufe sind zunächst nicht reversibel, da sie zum Beispiel bei Falschdetektionen neue Objekte in das Umfeldmodell einführen, die in der Realität nicht vorhanden sind. Fehldetektionen können zu verspäteten oder ganz fehlenden Objekten im Umfeldmodell führen. Eine Fehllassoziation kann eine Objektrepräsentation vervielfachen, wenn die Innovation mit der falschen Messung zu einer zu großen statistischen Distanz zur nächsten korrekten Messung führt. Für diese korrekte Messung muss dann eine neue Objektrepräsentation im Umfeldmodell initialisiert werden.

Die Ursache der Probleme

Ausgehend von statistischen Zustandsbeobachtern, die ursprünglich für technische Anlagen entwickelt wurden, bei denen es weder Zweifel an deren Existenz noch an der Zugehörigkeit der Messdaten zu diesen Anlagen gab, wurden die rekursiven Schätzverfahren durch Zusatzmodule für die maschinelle Wahrnehmung unter Detektions- und Assoziationsunsicherheit erweitert. Bei diesem „Bottom-Up“-Ansatz mit seinen frühen Entscheidungen ist das berechnete Umfeldmodell mit einer Wahrscheinlichkeit fehlerhaft, die dem Signal-zu-Rausch-Verhältnis entspricht.

Die Forschung auf dem Gebiet der Objektverfolgung für Fahrerassistenzsysteme beschäftigte sich in der Vergangenheit entweder mit der Portierung dieses Konzeptes auf immer neue Sensortechnologien, wie Laserscanner und bildgebende Radarsensoren, oder aber mit der immer genaueren Repräsentation der Zustandsunsicherheiten, beispielsweise durch Partikelfilter, Sigma-Punkt-Kalman-Filter und gridbasierte Methoden für nichtlineare Modelle sowie Mischverteilungsfiler (z.B. IMM) für multimodale Modelle. Im praktischen Einsatz im Straßenverkehr hat sich allerdings unabhängig von der Sensortechnologie gezeigt, dass die auftretenden Probleme in der Fahrzeugumfelderfassung in der Regel auf Fehler in den beiden anderen Unsicherheitsdomänen zurückzuführen sind, d.h. aus Falsch- und Fehldetektionen oder aus Fehlassoziationen resultieren. Daher wird in der klassischen Systemarchitektur versucht, diese Fehler mit heuristischen Regelsystemen des Objektmanagements zu korrigieren (Abschnitt 2.3.4). Diese Vorgehensweise ist aber weder theoretisch fundiert, noch lassen sich die vielen Schwellwertparameter T_i der Regeln leicht optimieren, so dass Gesamtsysteme oft auf Teststecken nach dem „Try-and-Error“-Prinzip parametrisiert werden. Es ist ebenfalls nicht ersichtlich, ob auftretende Probleme mit der verwendeten Sensortechnologie prinzipiell unvermeidbar sind oder ob sie nur auf die suboptimale Datenverarbeitung zurückzuführen sind.

Als Problemursache wurde der Wechsel der Unsicherheitsmodelle in der Modulararchitektur identifiziert. Die Modelle sind einzeln nicht in der Lage, alle drei Unsicherheitsdomänen zu repräsentieren. Die Fehler entstehen durch das Verwerfen der probabilistischen Wissensrepräsentationen von Stufe zu Stufe in Folge der Modell Anpassungen. Außerdem wird im klassischen System ausschließlich in der Domäne der Zustandsunsicherheiten die Bayes-optimale rekursive Zustandsschätzung unter Verwendung von Wissen aus der Historie und einem Prozessmodell verwendet, während die beiden anderen Unsicherheiten immer zeitlokal betrachtet werden.

Abhilfe würde ein einziges mathematisches Umfeldmodell schaffen, das gleichzeitig alle Unsicherheitsdomänen repräsentiert. Mit einer derartigen „Top-Down“-Modellierung, die die tatsächliche mathematische Struktur des Wahrnehmungsproblems unter Existenz-, Assoziations- und Messgrößenunsicherheit beschreibt, könnte unscharfes Wissen in allen drei Unsicherheitsdomänen ohne frühe Entscheidungen durch die Zeit propagiert werden. Weiterhin könnten für nachfolgende Systeme Bayes-optimale Schätzwerte in allen Unsicherheitsdomänen extrahiert werden.

Ein Verfahren zur gleichzeitigen Behandlung der Assoziations- und Zustandsunsicherheiten ist das vereinheitlichte probabilistische Datenassoziationsfilter (engl. „Joint Probabilistic Data Association Filter“, JPDAF, [20]). Dieses Verfahren ist aber weiterhin nicht in der Lage, Existenzunsicherheiten zu modellieren und benötigt daher zwar keine Assoziationsentscheidungen, aber weiterhin Detektionsentscheidungen. Das JPDAF wird sich als Spezialfall der im nächsten Kapitel vorgestellten Algorithmen erweisen.

Kapitel 3

Filterung auf Basis endlicher Zufallsmengen

Ab 1993 wurde die Statistik für endliche Zufallsmengen (engl. „Finite Set Statistics“, FISST) von Ronald P.S. Mahler und I.R. Goodman als Werkzeug zur vereinheitlichten Mehrobjektverfolgung bei niedrigem Signal-zu-Rausch Verhältnis entwickelt [53, 54, 58]. Der Hauptanwendungsbereich dieser Verfahren ist die militärische Luftüberwachung von Flugobjekten mit Tarntechnologie (engl. „stealth“). Im atmosphärischen Hintergrundrauschen und in Präsenz von Störsignalen sind derartige Objekte in einer einzigen Messung überhaupt nicht vom Hintergrund zu unterscheiden.

Lediglich die zeitliche Überwachung von minimalen Abweichungen von der Statistik des Hintergrundrauschens ermöglicht eine Objektdetektion. Würden hier zeitlokale Detektions- und Assoziationsentscheidungen getroffen, wäre das resultierende Umfeldmodell permanent falsch und unbrauchbar. Die alternative Vorgehensweise der zusätzlichen zeitlichen Filterung von Detektions- und Assoziationsmehrdeutigkeiten trägt daher auch den Namen „Track-before-Detect“ (TBD).

In der Fahrzeugumfelderfassung findet die Wahrnehmung in einem kooperativen Umfeld statt. Trotzdem erscheint eine Portierung von TBD-Verfahren sinnvoll, da eine Minimierung oder der Ausschluss von Fehlern neue invasive Funktionen zum Beispiel im Sicherheitsbereich ermöglicht. Weiterhin erleichtert die systematische Modellierung des Gesamtproblems aufgrund der geringeren Anzahl von freien Parametern die Systemauslegung und -absicherung.

In diesem Kapitel werden zuerst die Grundkonzepte der FISST-Theorie, die darauf basierenden Filterverfahren und effiziente Implementierungsstrategien betrachtet. In einem separaten Abschnitt wird eine besonders praktikable FISST-Approximation und deren Adaption für die Fahrzeugumfelderfassung vorgestellt.

In Abschnitt 3.3.5, Seiten 64 ff., wird eine graphentheoretische Interpretation des vorgeschlagenen Filterverfahrens präsentiert, die unabhängig von der FISST-basierten Herleitung ist, jedoch zu den exakt gleichen Filtergleichungen führt.

3.1 Statistik für endliche Zufallsmengen

In den folgenden Abschnitten 3.1.1 bis 3.1.4 werden die mathematischen Grundkonzepte der FISST-Theorie kompakt vorgestellt. Dazu sind in [58] detaillierte Herleitungen und Beispiele zu finden. Das in dieser Arbeit vorgeschlagene Filter wird dann unter Verwendung dieser Methoden in Abschnitt 3.3 hergeleitet.

3.1.1 Metazustände und Metamessungen

Statt jedes einzelne Objekt des Sensorumfeldes separat und unabhängig mit einem Zustandsvektor $\mathbf{x}^i$ zu modellieren, wird die gesamte Objektkonstellation als endliche Menge von Zustandsvektoren repräsentiert:

$$X = \{\mathbf{x}^1, \dots, \mathbf{x}^n\}, \quad n < \infty. \quad (3.1)$$

In der klassischen Umfeldmodellierung existierte für jedes Objekt jeweils eine separate Aufenthaltswahrscheinlichkeitsfunktion im Zustandsraum. In der FISST-Modellierung werden den verschiedenen Realisierungen der endlichen Zufallsmenge X , also im Kontext der Fahrzeugumfelderfassung ganzen Verkehrssituationen, Wahrscheinlichkeiten zugeordnet, die die Kolmogorov-Axiome (2.3) bis (2.5) erfüllen. Damit sind sowohl die in der Zufallsmenge enthaltenen Zustandsvektoren $\mathbf{x}^i$ als auch deren Anzahl n Zufallsvariablen. Innerhalb dieses Ereignishorizontes X können Hypothesen mit unterschiedlichen Kardinalitäten koexistieren. Speziell ist auch die leere Menge $X = \emptyset$ eine zulässige Realisierung, die die Hypothese repräsentiert, dass sich gerade gar kein Objekt im Überwachungsbereich befindet. Durch diese Modellierung ist die FISST-Theorie in der Lage, gleichzeitig unscharfes Wissen über die Zustände von Objekten und deren Existenz mit einer einzigen Wahrscheinlichkeitsfunktion abzubilden.

Analog zu diesem Metaobjektzustand wird auch eine Metamessung als endliche Zufallsmenge von Messvektoren modelliert:

$$Z = \{\mathbf{z}^1, \dots, \mathbf{z}^m\}, \quad m < \infty. \quad (3.2)$$

Im Gegensatz zur Multiobjektrepräsentation durch einen Vektor von n Zustandsvektoren, impliziert die Mengennotation keine Reihenfolge der Elemente. Dies ist gleichbedeutend mit der Interpretation, dass die Mengennotation gleichzeitig und gleichberechtigt alle $n!$ Permutationen, Reihenfolgen oder Anordnungen der Elemente repräsentiert:

$$p(\mathbf{x}^1, \dots, \mathbf{x}^n) = \begin{cases} \frac{1}{n!} \cdot p(\{\mathbf{x}^1, \dots, \mathbf{x}^n\}) & \text{für } \mathbf{x}^1 \neq \mathbf{x}^2 \neq \dots \neq \mathbf{x}^n \\ 0 & \text{sonst} \end{cases}. \quad (3.3)$$

Durch diese Eigenschaft ist die FISST-Modellierung in der Lage, neben Existenz- und Zustandsunsicherheiten auch Assoziationsunsicherheiten inhärent zu berücksichtigen.

3.1.2 Wissensrepräsentation mit Wahrscheinlichkeitsdichtefunktionen für endliche Zufallsmengen

Während sich bei diskreten Ereignishorizonten eine direkte Abbildung von Ereignissen auf ihre Eintrittswahrscheinlichkeiten angeben lässt, ist die Eintrittswahrscheinlichkeit eines der

unendlich vielen Elementarereignisse eines kontinuierlichen multivariaten Ereignishorizontes gleich Null. Für jedes Punktereignis wird stattdessen eine Wahrscheinlichkeitsdichte angegeben, die der ersten Ableitung der Wahrscheinlichkeitsfunktion an diesem Punkt entspricht.

Für endliche Zufallsmengen wird die Dichtefunktion analog abgeleitet. Das Äquivalent der Wahrscheinlichkeitsfunktion für endliche Zufallsmengen ist die Glaubwürdigkeitsfunktion β (engl. „Belief Mass Function“, BMF). Sie ordnet jeder beliebigen Teilmenge S des Zustandsraumes die Inklusionswahrscheinlichkeit des gesamten Metazustandes X in S zu:

$$\beta_X(S) = \Pr(X \subseteq S), \quad S \subseteq \mathbb{R}^{\dim(\mathbf{x})}. \quad (3.4)$$

Die Wahrscheinlichkeitsdichtefunktion für Zufallsmengen wird analog durch Differentiation der Glaubwürdigkeitsfunktion nach der endlichen Zufallsmenge erzeugt [96]. Zunächst wird die Ableitung nach einer einelementigen Zufallsmenge $X = \{\mathbf{x}\}$ durch den Grenzwert eines Differenzenquotienten definiert. Hier wird die Differenz zwischen der Glaubwürdigkeit der disjunkten Vereinigung einer beliebigen Menge S mit der Epsilon-Umgebung um $\mathbf{x}$ und der Glaubwürdigkeit der Menge S allein durch das Hypervolumen (Lebesgue-Maß) der Epsilon-Umgebung $\varepsilon(\mathbf{x})$ geteilt:

$$\frac{d\beta_X}{d\mathbf{x}}(S) = \lim_{|\varepsilon(\mathbf{x})| \searrow 0} \frac{\beta_X(S \uplus \varepsilon(\mathbf{x})) - \beta_X(S)}{|\varepsilon(\mathbf{x})|}. \quad (3.5)$$

Das offensichtliche Kriterium der disjunkten Vereinigung, ohne das der Zähler eventuell verschwinden würde, ist automatisch immer erfüllt, wenn für S die leere Menge eingesetzt wird. Damit gilt:

$$p(X = \{\mathbf{x}\}) = \lim_{|\varepsilon(\mathbf{x})| \searrow 0} \frac{\beta_X(\emptyset \cup \varepsilon(\mathbf{x})) - \beta_X(\emptyset)}{|\varepsilon(\mathbf{x})|} = \frac{d\beta_X}{d\mathbf{x}}(\emptyset). \quad (3.6)$$

Ableitungen nach mehrelementigen Mengen können rekursiv mit der einelementigen Ableitung (3.6) berechnet werden. Für die Differentiation nach der leeren Menge ergibt (3.6) den unbestimmten Ausdruck 0/0. Es gilt [32]:

$$p(X) = \frac{d\beta_X}{dX}(\emptyset) = \begin{cases} \beta_X(\emptyset) & \text{für } X = \emptyset \\ \frac{d\beta_X}{d\mathbf{x}^1} \left(\dots \frac{d\beta_X}{d\mathbf{x}^{n-1}} \left(\frac{d\beta_X}{d\mathbf{x}^n}(\emptyset) \right) \right) & \text{für } X = \{\mathbf{x}^1, \dots, \mathbf{x}^n\} \end{cases} \quad (3.7)$$

Das Mengenintegral der Wahrscheinlichkeitsdichtefunktion summiert die Wahrscheinlichkeitsdichten aller Realisierungen X , die komplett in einer beliebigen Teilmenge S des Zustandsraumes enthalten sind. Diese Marginalisierung entspricht der totalen Wahrscheinlichkeit, dass X in S enthalten ist und damit wieder der Glaubwürdigkeit $\beta_X(S)$:

$$\begin{aligned} \beta_X(S) &= \int_S p(X) dX \\ &= \sum_{n=0}^{\infty} \frac{1}{n!} \int_{\underbrace{S \times \dots \times S}_n} p(\{\mathbf{x}^1, \dots, \mathbf{x}^n\}) d\mathbf{x}^1 \dots d\mathbf{x}^n. \end{aligned} \quad (3.8)$$

Innerhalb des Summenterms, also bei feststehender Kardinalität n , werden durch die Integration über den Raum S^n alle $n!$ Permutationen der gleichen Punkte $\mathbf{x}^1 \dots \mathbf{x}^n$ konstruiert. Da die Objektreihenfolge aber in der Mengennotation irrelevant ist, wird die Mehrfachaufzählung durch den Vorfaktor $n!^{-1}$ korrigiert.

3.1.3 Wahrscheinlichkeitsgenerierende Funktionale

Wahrscheinlichkeitsgenerierende Funktionale (WGF) sind Integraltransformationen für Wahrscheinlichkeitsdichtefunktionen. Sie erlauben eine Kompaktifizierung der FISST-Filtergleichungen im Vergleich zur Verwendung von Wahrscheinlichkeitsdichtefunktionen. Insofern ist die Analogie zur Fourier- oder Laplace-Transformation zulässig, die ebenfalls Integraltransformationen von Funktionen sind und beispielsweise komplizierte Faltungsintegrale im Bildraum in einfache Multiplikationen überführen. Für die FISST-Modellierung sind wahrscheinlichkeitsgenerierende Funktionale wie folgt definiert:

$$G_p[h] = \mathcal{G}_{X \rightarrow h}\{p(X)\} = \int_X h^X p(X) dX = \langle h^X, p \rangle = E_p\{h^X\}. \quad (3.9)$$

Für eine beliebige Testfunktion $0 \leq h(\mathbf{x}) \leq 1$ auf dem Einziel-Zustandsraum wird die Potenz in (3.9) definiert als:

$$h^X = \prod_{i=1}^{|X|} h(\mathbf{x}^i). \quad (3.10)$$

Neben der eigentlichen Definition durch die Integraltransformation kann ein WGF nach (3.9) alternativ auch als Funktionsskalarprodukt von h^X und p geschrieben werden. In der linearen Algebra lässt sich das WGF somit als Koordinate des Vektors p bezüglich des Basisvektors h^X interpretieren. Eine weitere Definitionsmöglichkeit ist der Erwartungswert der Funktion h^X bezüglich p . Eine darüber hinaus gehende intuitive Interpretation der WGF existiert nicht. Die Glaubwürdigkeitsfunktion $\beta_X(S)$ ist allerdings ein Spezialfall eines WGF, wenn für h die Indikatorfunktion $\mathbf{1}_S(\mathbf{x})$ der Menge S

$$\mathbf{1}_S(\mathbf{x}) = \begin{cases} 1 & \text{für } \mathbf{x} \subseteq S \\ 0 & \text{sonst} \end{cases} \quad (3.11)$$

eingesetzt wird:

$$\beta_X(S) = G_p[\mathbf{1}_S] = \int_X \mathbf{1}_S^X p(X) dX = \int_S p(X) dX. \quad (3.12)$$

Dieser Zusammenhang ist für das WGF namensgebend. Da die Indikatorfunktion der leeren Menge die Nullfunktion ist, können die Definitionsgleichungen der Mengen-Wahrscheinlichkeitsdichtefunktionen (3.6) und (3.7) auch in Funktionalschreibweise angegeben werden:

$$p(\mathbf{x}) = \frac{d\beta_x}{d\mathbf{x}}(\emptyset) = \frac{dG_p}{d\mathbf{x}}[0], \quad p(X) = \frac{d\beta_X}{dX}(\emptyset) = \frac{dG_p}{dX}[0]. \quad (3.13)$$

Für die informationserhaltende Transformation einer FISST-WDF in ein FISST-WGF nach (3.9) wird im Folgenden auch die von der Fourier- und Laplace-Transformation bekannte Schreibweise verwendet:

$$p(X) \circ \bullet G_p[h]. \quad (3.14)$$

3.1.4 Differentiationsregeln für endliche Mengen

Die FISST-Theorie stellt Differentiationsregeln für zufällige Mengen bereit ([58], S. 395), von denen im Folgenden nur die für diese Arbeit relevanten aufgeführt werden. Dabei wird die allgemeinere Funktionalschreibweise anstelle von Glaubwürdigkeitsfunktionen verwendet.

1. Ableitung einer Konstanten:

$$\frac{d}{dX}K = 0 \quad (3.15)$$

2. Linearitätsregel:

$$\frac{d}{dX}f[h] = \begin{cases} f[h] & \text{für } X = \emptyset \\ f(\mathbf{x}) & \text{für } X = \{\mathbf{x}\} \\ 0 & \text{für } |X| > 1 \end{cases} \quad (3.16)$$

3. Summenregel:

$$\frac{d}{dX}(a \cdot f[h] + b \cdot g[h]) = a \frac{df}{dX}[h] + b \frac{dg}{dX}[h] \quad (3.17)$$

4. Zweierproduktregel:

$$\frac{d}{dX}(f[h] \cdot g[h]) = \sum_{W \subseteq X} \frac{df}{dW}[h] \cdot \frac{dg}{d(X \setminus W)}[h] \quad (3.18)$$

5. allgemeine Produktregel:

$$\frac{d}{dX}(f_1[h] \cdot \dots \cdot f_n[h]) = \sum_{W_1 \uplus \dots \uplus W_n = X} \frac{df_1}{dW_1}[h] \cdot \dots \cdot \frac{df_n}{dW_n}[h] \quad (3.19)$$

3.2 Filteralgorithmen für endliche Zufallsmengen

Dieser Abschnitt gibt einen kompakten Überblick über die in der Literatur beschriebenen FISST-basierten Filtervarianten. Es werden lediglich die grundlegenden Ansätze ohne Herleitungen präsentiert.

3.2.1 Das Multiobjekt-Bayes-Filter

Die in Abschnitt 2.1.4 (Seiten 11 ff.) präsentierte Herleitung der bayesschen Filterrekursion setzt nicht voraus, dass der Messraum oder der Zustandsraum reelle Vektorräume sind. Deshalb können mit der Definition einer Mengen-Wahrscheinlichkeitsdichtefunktion (3.7) und der Mengenintegration (3.8) anstatt des vektoriellen Zustandes $\mathbf{x}_k$ und der vektoriellen Messung $\mathbf{z}_k$ analog die endlichen Zufallsmengen X_k und Z_k verwendet werden. Für die Zustands- und Messwerthistorien werden die Vektorhistorien $\mathbf{X}_{1:k}$ und $\mathbf{Z}_{1:k}$ durch Mengenhistorien $X_{1:k}$ und $Z_{1:k}$ ersetzt. Damit ergeben sich strukturell mit (2.25) und (2.23) identische bayessche Filtergleichungen:

$$p(X_k | Z_{1:k-1}) = \int p(X_k | X_{k-1}) p(X_{k-1} | Z_{1:k-1}) dX_{k-1} \quad (3.20)$$

$$p(X_k | Z_{1:k}) = \frac{p(Z_k | X_k) p(X_k | Z_{1:k-1})}{\int p(Z_k | X_k) p(X_k | Z_{1:k-1}) dX_k}. \quad (3.21)$$

Das universelle bayessche Prinzip zur Informationsverknüpfung, das Grundlage aller Einzel-Filterverfahren ist, wird in der FISST-Theorie somit beibehalten. Es wird lediglich das unterlegte mathematische Modell ausgetauscht, bzw. der Ereignishorizont um die Detektions- und Assoziationsalternativen erweitert. Die eigentliche Herausforderung besteht in der Angabe von Transitions- und Messmodellen für Metazustände und Metamessungen, in der effizienten Implementierung der Filtergleichungen und in der Definition von Metazustandsschätzern.

Mit einer Partikelimplementierung des Multiobjekt-Bayes-Filters [82, 83, 95, 91] lassen sich beliebige Wahrscheinlichkeitsdichten, Transitions- und Messwahrscheinlichkeiten verarbeiten. Aus Effizienzgründen liegt aber auch in der FISST-Domäne die Verwendung von parametrischen Wahrscheinlichkeitsdichten nahe, so dass die resultierenden Filterverfahren analog zum Kalman-Filter nur auf den Verteilungsparametern operieren.

3.2.2 Funktionalformen der Multiobjekt-Bayes-Filtergleichungen

Der temporale Informationsfluss von der a-posteriori Wissensbasis des vorherigen Zeitschrittes durch die Prädiktion (3.20) zur a-priori Wissensbasis des aktuellen Zeitschrittes und weiter durch die Innovation (3.21) zur a-posteriori Wissensbasis des aktuellen Zeitschrittes kann alternativ auch im Bildraum der wahrscheinlichkeitsgenerierenden Funktionale erfolgen:

$$\begin{array}{ccccc}
 p(X_{k-1}|Z_{1:k-1}) & \xrightarrow{(3.20)} & p(X_k|Z_{1:k-1}) & \xrightarrow{(3.21)} & p(X_k|Z_{1:k}) \\
 \circ \downarrow & & \circ \downarrow & & \circ \downarrow \\
 G_{k-1|k-1}[h] & \xrightarrow{(3.26)} & G_{k|k-1}[h] & \xrightarrow{(3.29)} & G_{k|k}[h].
 \end{array}$$

Die dazu notwendigen Prädiktions- und Innovationsoperationen auf WGFs werden im Folgenden vorgestellt.

Funktionaldarstellung des Prädiktionschrittes des Multiobjekt-Bayes Filters

Das WGF des prädierten Metazustandes ergibt sich durch Einsetzen der Multi-Objekt Prädiktionsgleichung (3.20) in die WGF-Definitionsgleichung (3.9):

$$G_{k|k-1}[h] = \mathcal{G}_{X \rightarrow h} \{p(X_k|Z_{1:k-1})\} \quad (3.22)$$

$$G_{k|k-1}[h] = \int h^{X_k} p(X_k|Z_{1:k-1}) dX_k = \int h^{X_k} \int p(X_k|X_{k-1}) p(X_{k-1}|Z_{1:k-1}) dX_{k-1} dX_k \quad (3.23)$$

$$G_{k|k-1}[h] = \int \left(\int h^{X_k} p(X_k|X_{k-1}) dX_k \right) p(X_{k-1}|Z_{1:k-1}) dX_{k-1} \quad (3.24)$$

$$G_{k|k-1}[h] = \int G_{k|k-1}[h|X_{k-1}] p(X_{k-1}|Z_{1:k-1}) dX_{k-1}. \quad (3.25)$$

Die WGF-Transformation der Prädiktionsgleichung (3.20) lautet damit:

$$\begin{array}{c}
 p(X_k|Z_{1:k-1}) = \int p(X_k|X_{k-1})p(X_{k-1}|Z_{1:k-1})dX_{k-1} \\
 \circ \\
 \bullet \\
 G_{k|k-1}[h] = \int G_{k|k-1}[h|X_{k-1}] p(X_{k-1}|Z_{1:k-1})dX_{k-1}.
 \end{array} \tag{3.26}$$

Dabei wurde das noch nicht näher bestimmte WGF der Multiobjekt-Transitionswahrscheinlichkeit verwendet:

$$p(X_k|X_{k-1}) \circ \bullet G_{k|k-1}[h|X_{k-1}]. \tag{3.27}$$

Funktionaldarstellung des Multiobjekt-Bayes Korrektors

Mit der Definition eines Funktionals F in Abhängigkeit von der Indikatorfunktion h im Zustandsraum und der Indikatorfunktion g im Messraum:

$$F[g, h] = \int h^{X_k} \cdot G_k[g|X_k] \cdot p(X_k|Z_{1:k-1})dX_k \tag{3.28}$$

ergibt sich das WGF der a-posteriori Wissensrepräsentation (3.21) zu (Beweis siehe [58], Anhang G.25, pp. 757 ff.):

$$\begin{array}{c}
 p(X_k|Z_{1:k}) = \frac{p(Z_k|X_k)p(X_k|Z_{1:k-1})}{\int p(Z_k|X_k)p(X_k|Z_{1:k-1})dX_k} \\
 \circ \\
 \bullet \\
 G_{k|k}[h] = \frac{\frac{dF}{dZ_k}[0, h]}{\frac{dF}{dZ_k}[0, 1]}.
 \end{array} \tag{3.29}$$

Hier wurde das noch nicht näher bestimmte WGF der Multiobjekt-Messfunktion verwendet:

$$p(Z_k|X_k) \circ \bullet G_k[g|X_k]. \tag{3.30}$$

3.2.3 Transitionswahrscheinlichkeiten und Likelihood-Funktionen der Messung für endliche Zufallsmengen

Im Gegensatz zur herkömmlichen bayesschen Zustandsfilterung (Abschnitt 2.1.4, Seiten 11 ff.) müssen in der FISST-Theorie die Prozess- und Messmodelle $p(X_k|X_{k-1})$ und $p(Z_k|X_k)$ neben den räumlichen Transformationen der Punktelemente auch Kardinalitätswechsel, d.h. dass Verschwinden und Neuerscheinen von Objekten statistisch beschreiben. Für das Prozessmodell können dabei die in Abbildung 3.1 gezeigten Fälle auftreten. Abbildung 3.2 zeigt Ursachen für mögliche Kardinalitätsunterschiede zwischen dem Metazustand und der Metamessung zu




Abbildung 3.1: Mögliche Ursachen für Kardinalitätswechsel im Prozessmodell für zwei sukzessive Zeitpunkte.




Abbildung 3.2: Mögliche Ursachen für Kardinalitätsunterschiede im Messraum und Zustandsraum. Der Fall „Trennfähigkeit“ bedeutet hier eine mangelnde Trennfähigkeit. Statt einer echten Mehrfachdetektion kommt für den vierten Fall auch ein Segmentzerfall der Messdaten in Betracht.

einem Zeitpunkt k im FISST-Messmodell. Es ist leicht ersichtlich, dass die möglichen Ereignisse, die zu Kardinalitätswechseln führen, für das Prozess- und Messmodell strukturell identisch sind. Neben diesen Kardinalitätswechseln müssen sowohl das Prozess- als auch das Messmodell über alle Assoziationshypothesen der beiden beteiligten Zufallsmengen marginalisieren. Im Prozessmodell entspricht dies der Fragestellung, welches Objekt der Menge X_k welchem Objekt der Menge X_{k+1} im nächsten Zeitschritt entspricht. Im Messmodell entspricht diese Fragestellung dem bereits erörterten Datenassoziationsproblem.

Aufgrund dieser Gemeinsamkeiten können die FISST-Transitionswahrscheinlichkeit und die FISST-Likelihood der Metamessung exakt identisch unter jeweiliger Kontextinterpretation der verwendeten Wahrscheinlichkeiten abgeleitet werden. Es haben sich vorrangig in der militärischen Luftüberwachung zwei Standardmodelle für die Prädiktion und die Messung etabliert, die nahezu durchgängig implizit oder explizit in der Literatur verwendet werden.

Das Standard-Prädiktionsmodell

1. Die Bewegung der realen Objekte im Zustandsraum ist durch die Transitionswahrscheinlichkeit $p(\mathbf{x}_{k+1}|\mathbf{x}_k)$ (2.29) charakterisiert. Es gilt die Markov-Eigenschaft (2.24).
2. Ein reales Objekt „überlebt“ mit der eventuell zustandsabhängigen Persistenzwahrschein-

lichkeit $p^P(\mathbf{x})$ vom Zeitpunkt k zum Zeitpunkt $k + 1$ und verschwindet mit Wahrscheinlichkeit $q^P(\mathbf{x}) = 1 - p^P(\mathbf{x})$.

3. Die Häufigkeit des Erscheinens neuer Objekte in einzelnen Regionen des Zustandsraumes ist durch die Wahrscheinlichkeitsdichte $b(\mathbf{x})$ beschrieben. Die Anzahl neu entstehender Objekte ist poissonverteilt mit bekannter Entstehungsrate μ pro Zeit- und Zustandsraumhypervolumeneinheit.
4. Der Objektentstehungsprozess, das Verschwinden von Objekten und die Objekttransition sind für jeweils zwei Objekte paarweise statistisch unabhängig.
5. Persistente Objekte zerteilen sich spontan mit Teilungswahrscheinlichkeit $p^S(\mathbf{x})$ und bleiben mit Wahrscheinlichkeit $q^S(\mathbf{x}) = 1 - p^S(\mathbf{x})$ als einzelnes Objekt erhalten.

Die letzte Modelleigenschaft wird im Militärkontext beispielsweise für den Abschuss von Raketen oder das Aussetzen von Beibooten benötigt. Im Automobilkontext ist ein Teilungsmodell in den meisten Anwendungen (engl. „spawning“) inadäquat.

Das Standard-Messmodell

1. Keine Messung wird von mehr als einem realen Objekt generiert.
2. Ein reales Objekt generiert entweder mit Wahrscheinlichkeit $p^D(\mathbf{x}) \stackrel{abk.}{=} p(\exists \mathbf{z} | \exists \mathbf{x})$ eine Messung oder mit Wahrscheinlichkeit $q^D(\mathbf{x}) = 1 - p^D(\mathbf{x})$ keine Messung.
3. Die Messfehler der Objektmessungen sind Realisierungen des rauschadditiven Messmodells $p(\mathbf{z} | \mathbf{x})$ (2.30).
4. Falschalarme treten in ihrer Anzahl poissonverteilt mit bekannter Ereignisrate λ pro Zeit- und Messraumhypervolumeneinheit auf. Die räumliche Verteilung ist durch die bekannte Dichtefunktion $c(\mathbf{z}) \stackrel{abk.}{=} p(\mathbf{z} | \nexists \mathbf{x})$ charakterisiert.
5. Der Detektionsprozess realer Objekte und der Falschalarmprozess sind statistisch unabhängig.

3.2.4 Das integrierte probabilistische Datenassoziationsfilter

Obwohl das von Mušicki et al. vorgestellte IPDAF („Integrated Probabilistic Data Association Filter“, [65]) lediglich ein einziges Ziel verfolgt und damit kein Mehrziel-Filter darstellt, wurde bei diesem Verfahren erstmals die simultane bayessche Schätzung der Objektexistenz und des Objektzustandes unter Berücksichtigung von Fehl- und Falschalarmen und der Möglichkeit des Verschwindens des Objektes demonstriert. Challa et al. konnten später zeigen [16], dass sich das IPDAF aus der FISST-Theorie unter den folgenden Abänderungen des Standardmodells (Abschnitt 3.2.3) herleiten lässt:

1. Es ist maximal ein Objekt präsent. Damit besteht der Ereignishorizont nur aus den unendlich vielen Ereignissen $X = \{x\}$ und dem Einzelereignis $X = \emptyset$.
2. Für die geschlossene Lösung müssen alle Modelle linear und gaußverteilt sein.
3. Die Verteilung der Falschalarms im Überwachungsbereich des Zustandsraumes ist uniform.

Im IPDA-Filter wird daher die folgende parametrische Mengen-Wahrscheinlichkeitsdichtefunktion für den Metazustand verwendet:

$$p(X) = \begin{cases} 1 - p^\exists & \text{für } X = \emptyset \\ p^\exists \cdot \mathcal{N}(\mathbf{x}, \hat{\mathbf{x}}, \hat{\mathbf{P}}) & \text{für } X = \{\mathbf{x}\} \\ 0 & \text{für } |X| > 1 \end{cases} \quad (3.31)$$

Aufgrund der Modellbeschränkung auf ein einziges Objekt muss zum Einsatz des IPDA-Filters für die Mehrobjektverfolgung eine klassische Datenassoziation (Abschnitt 2.3.2) vorgeschaltet werden. Das Bestätigen und Verwerfen von Objekthypothesen kann aber bereits ohne heuristische Regelsysteme sondern auf Basis der Existenzwahrscheinlichkeit $p^\exists$ durchgeführt werden. Während das ursprüngliche IPDA-Filter von Mušicki nur das Verschwinden von Objekten modellierte, wurde das Filter von Mahler um ein explizites Geburtsmodell erweitert („Joint Target-Detection and Tracking Filter“, JoTT, [58], pp. 514 ff.). Die im Rahmen dieser Arbeit durchgeführte Untersuchung dieses Ansatzes im Automobilkontext ist in [120] beschrieben.

3.2.5 Das probabilistische Hypothesendichtefilter

Unter den Annahmen des Standardmodells und der zusätzlichen Annahme, dass die gefilterte Mengen-WDF zu jedem Zeitpunkt einer Multiobjekt-Poissonverteilung

$$p(X) = e^{-\eta} \cdot \eta^n \cdot \prod_{i=1}^n p(\mathbf{x}_i), \quad n = |X| \quad (3.32)$$

mit Objekt-Existenzrate η entspricht, ist die probabilistische Hypothesendichtefunktion (engl. „Probability Hypothesis Density“, PHD) eine suffiziente Statistik des Metazustandes. Die PHD-Funktion ist das erste statistische Moment der Mengen-Wahrscheinlichkeitsdichte und daher ein Multiobjekt-Analogon zum Erwartungswert. Die PHD-Funktion ordnet jedem Punkt $\mathbf{x}$ des Einziel-Zustandsraumes die Summe der Wahrscheinlichkeitsdichten aller möglichen Metazustände zu, die ein Element an diesem Punkt enthalten:

$$D(\mathbf{x}) = \sum_{n=0}^{\infty} \frac{1}{n!} \int p(\{\mathbf{x}, \mathbf{y}_1, \dots, \mathbf{y}_n\}) d\mathbf{y}_1 \dots d\mathbf{y}_n. \quad (3.33)$$

Die Mehrfachaufzählungen des gleichen Metazustandes werden durch den Vorfaktor $n!^{-1}$ ausgeglichen. Das Integral der PHD-Funktion über eine beliebige Teilmenge des Zustandsraumes entspricht dem Erwartungswert der Anzahl der Objekte in diesem Gebiet [58]. Zusätzlich wird

die Verteilung dieser erwarteten Anzahl von Objekten im Zustandsraum durch die Form der PHD-Funktion angeben. Die PHD-Funktion ist daher eine Intensitätsfunktion.

Das PHD-Filter [55, 23] propagiert die PHD-Funktion anstatt der vollständigen Mengen-WDF durch die Zeit. Ist für $p(\mathbf{x}_i)$ in (3.32) eine allgemeine Dichtefunktion zulässig, kann das PHDF als Partikelfilter implementiert werden (engl. „Sequential Monte Carlo Probability Hypothesis Density Filter“, SMC-PHDF, [105, 81, 97, 75]).

Für lineare Modelle und gaußverteilte Zustandsunsicherheiten wurden geschlossene Lösungen mit gaußschen Mischverteilungen entwickelt (engl. „Gaussian Mixture Probability Hypothesis Density“, GM-PHD, [94]).

Erdinc et al. [22] stellten eine mangelnde Glättungseigenschaft des PHDF bei der Schätzung der Anzahl der beobachteten Objekte fest, die auf die starken Modellannahmen und die ausschließliche Propagation des ersten statistischen Moments der Wahrscheinlichkeitsdichte zurückzuführen sind. Diese Limitierung konnte auch im Rahmen dieser Arbeit für das PHD-Filter im Automobilkontext beobachtet werden [119, 123].

3.2.6 Das kardinalisierte probabilistische Hypothesendichtefilter

Als Antwort auf die von Erdinc et al. festgestellten Einschränkungen des PHDF entwickelte Mahler das kardinalisierte probabilistische Hypothesendichtefilter (CPHD, [56]), für das ebenfalls geschlossene analytische Approximationen mit gaußschen Mischverteilungen folgten [98]. Für die Mengen-Wahrscheinlichkeitsdichte wird nicht mehr eine Poissonverteilung in der Anzahl der Objekte gefordert, sondern es ist eine beliebige marginale Zähldichtefunktion $p(n)$ für die Objektanzahl zulässig:

$$p(n) = \frac{1}{n!} \int p(\mathbf{x}_1, \dots, \mathbf{x}_n) d\mathbf{x}_1 \dots d\mathbf{x}_n. \quad (3.34)$$

Damit ergibt sich für die Dichtefunktion des Metazustandes:

$$p(X) = n! \cdot p(n) \cdot \prod_{i=1}^N p(\mathbf{x}_i). \quad (3.35)$$

Dieses weniger restriktive Modell erfordert die Propagierung der gesamten Zähldichte $p(n)$, ihres wahrscheinlichkeitsgenerierenden Funktional und der Intensitätsfunktion $D(\mathbf{x})$ durch die Zeit. Während beim PHDF nur der EAP-Schätzer für die Anzahl der existierenden Objekte in Form des Integrals der Hypothesendichtefunktion verwendet werden kann, ist das CPHD-Filter in der Lage, zusätzlich den MAP-Schätzer auf die berechnete kardinale Zähldichte $p(n)$ anzuwenden, der bei niedrigem SNR stabilere Schätzwerte für die Anzahl der Objekte liefert.

Eine Spezialisierung des CPHDF ist das Binomialfilter [57]. Hier wird die Zähldichte der Objektanzahl parametrisch durch die ersten beiden statistischen Momente repräsentiert, um die Funktionsweise des Kalman-Filters zu imitieren. Mit dem Erwartungswert η und der Varianz σ_η^2 der diskreten Objektanzahl ergibt sich für $p(n)$ die Binomialverteilung:

$$p(n) = \binom{N}{n} q^n (1-q)^{N-n}, \text{ mit } q = 1 - \frac{\sigma_\eta^2}{\eta}, \quad N = \frac{\eta}{q}. \quad (3.36)$$

3.2.7 Diskussion und Kritik

Die genannten FISST-Filterverfahren nutzen das in Abschnitt 3.2.3 vorgestellte Standardmodell. Dabei ist es insbesondere fraglich, wie adäquat das Poisson-Falschalarmmodell für die realen Daten in der Fahrzeugumfelderfassung ist. Dieses Modell fordert eine zeitlich homogene Falschalarmrate und eine a-priori bekannte Falschalarmverteilungsfunktion im Messraum. Betrachtet man die Variabilität der Situationen, in denen Fahrzeugumfelderfassung funktionieren soll, erscheinen diese Annahmen sehr unrealistisch. Eine konstante Falschalarmrate und eine konstante Falschalarmverteilung in verschiedenen urbanen und außerstädtischen Umgebungen oder bei Tag und Nacht oder bei Schön- und Schlechtwetter zu identifizieren ist unabhängig von der konkreten Sensortechnologie nahezu unmöglich. Eine aufwändige Alternative wäre die Identifikation von Modellparametern für verschiedene Umgebungssituationen, die dann aber ebenfalls sensorisch erkannt werden müssten. Ein für die Fahrzeugumfelderfassung taugliches Falschalarmmodell sollte daher keine derartigen fixen Parameter aufweisen.

Die Unabhängigkeitsannahme zwischen Falschalarmprozess und Objektdetektionsprozess im Standardmodell lässt sich nur bei Punktzielen aufrecht erhalten. Ausgedehnte Ziele im Nahbereich des Sensors verdecken signifikante Bereiche des Hintergrundes, so dass sich die Auftretenswahrscheinlichkeiten von Falschalarmen in diesen Gebieten sicherlich verändern. Daher ist in diesen Fällen die Unabhängigkeitsannahme nicht haltbar.

Das Standardmodell nimmt weiterhin eine „1-zu-1“-Beziehung von realen Objekten zu Messungen an. In der Realität kommen für viele Sensoren „1-zu-n“-Relationen in Frage, weil pro Objekt mehrere Messungen erzeugt werden. Dies ist zum Beispiel bei Segmentzerfällen in Abstandprofilen von Laserscannern oder der Erfassung mehrerer Reflexionszentren eines PKW mit Radarsensorik der Fall. Umgekehrt können bei moderaten Ortsauflösungen „n-zu-1“-Beziehungen entstehen, wenn beispielsweise mehrere Objekte in die gleichen Entfernungstore (engl. „Range Gates“) eines Radarsensors fallen.

Das IPDA-Verfahren erfüllt nicht den Anspruch der simultanen Auflösung der Existenz-, Assoziations- und Zustandsunsicherheiten, da eine explizite Datenassoziationsentscheidung benötigt wird. Die Filterverfahren, die auf der Hypothesendichtefunktion basieren, behandeln die Existenzunsicherheit durch Schätzung der Randverteilungsfunktion der Objektanzahl, entweder in numerischer Repräsentation (CPHD), als Poissonverteilung (PHD) oder als Binomialverteilung (Binomialfilter). Der Hauptvorteil der PHD-Filterfamilie ist die Abwesenheit einer Datenassoziationsstufe mit expliziten Zuordnungsentscheidungen. Die resultierende PHD-Funktion lässt zunächst keine Rückschlüsse auf einzelne Objektidentitäten zu. Da aber in vielen Funktionen individuelle Objektbeschreibungen benötigt werden, muss nach dem Filterverfahren ein Objektextraktionsalgorithmus auf die PHD-Funktion angewendet werden. Dazu wird zunächst der Erwartungswert η der Anzahl der Objekte bestimmt. Bei Mischverteilungssapproximationen der PHD-Funktion können die η Komponenten mit den größten Gewichten als Zustandsschätzungen gewählt werden. Bei Partikelapproximationen kann eine gaußsche Mischverteilung beispielsweise mit dem EM-Algorithmus [19, 22, 123] eingepasst werden. Dieser Objektextraktionsschritt entspricht einer Art Datenassoziation, weil an jeden Punkt der PHD-Funktion der PHD-Intensitätswert auf die einzelnen Objekthypothesen, also z.B. die Komponenten der Mischverteilung, aufgeteilt werden muss. In diesem Objektextraktionsschritt, der Zuordnungsentscheidungen enthält, können wie bei der expliziten Datenassoziation in der




Abbildung 3.3: Zeitliches Ablaufschema der klassischen Systemarchitektur im Vergleich zur PHD-Filterfamilie. Die Module, in denen Entscheidungen getroffen werden müssen, und damit die Fehlerquellen, liegen bei PHD-Filtern nicht auf dem zeitlichen Propagationspfad. Deshalb können im Gegensatz zur klassischen Architektur Fehlentscheidungen die zukünftigen Schätzergebnisse nicht verfälschen.

klassischen Systemarchitektur Fehler entstehen. Der Vorteil der PHD-Filterfamilie liegt darin, dass die möglicherweise fehlerhaften Zuordnungsentscheidungen nach, anstatt vor der rekursiven Filterung erfolgen und damit die zukünftigen Schätzergebnisse nicht negativ beeinflusst werden (Abbildung 3.3).

3.3 Das Multiobjekt-Multi-Bernoulli-Filter

In diesem Abschnitt wird das praktisch äußerst relevante Multiobjekt-Multi-Bernoulli-Filter [58] als Approximation des Multiobjekt-Bayes-Filters vorgestellt. Die in der Literatur beschriebenen Filtergleichungen werden für die Fahrzeugumfelderfassung hinsichtlich der Modellierung von Falschalarmen angepasst.

Der Vorteil der PHD-Filterfamilie ist die Möglichkeit, Wissen ohne frühe Entscheidungen und dadurch ohne Entscheidungsfehler durch die Zeit propagieren zu können. Die PHD-Filterfamilie verarbeitet eine einzige Kardinalitätsstatistik $p(n)$ für die Gesamtzahl der Objekte in der beobachteten Szene. Es fehlt jedoch die Information, wie diese Gesamtkardinalitätsstatistik der zufälligen endlichen Mengen auf einzelne Objekte bezogen werden kann. Deshalb müssen im Nachgang noch fehleranfällige Objektextraktionsalgorithmen auf die geschätzte PHD-Funktion angewendet werden (Abbildung 3.3). Das Multiobjekt-Multi-Bernoulli-Filter führt im Gegensatz zu PHD-Filtern eine Kardinalitätsstatistik für jedes einzelne Objekt mit. Dadurch ist eine vollständig entscheidungsfreie Filterung mit individualisierten Objektlisten als Ausgabe möglich, die jedoch einen höheren Rechenaufwand und das Mitführen einer höheren Anzahl von Verteilungsparametern erfordert.

3.3.1 Die Multiobjekt-Multi-Bernoulli-Verteilung

Die Multiobjekt-Multi-Bernoulli-Verteilung (MMBV) ist eine spezielle parametrische Verteilung für endliche Zufallsmengen Y , deren Glaubwürdigkeitsfunktion $\beta_Y(S)$ zunächst durch V verschiedene Existenzwahrscheinlichkeiten $p_1^G, \dots, p_V^G$ und V verschiedene Aufenthaltswahrscheinlichkeitsdichtefunktionen $f_1^G(\mathbf{y}), \dots, f_V^G(\mathbf{y})$ gegeben ist. Man kann die V Komponenten dieser Funktion als virtuelle Objektgeneratoren verstehen, die jeweils mit Wahrscheinlichkeit p_v^G ein einziges Objekt $\mathbf{y}$ erzeugen, dessen Koordinaten im Vektorraum $\mathbb{R}^m$, $m = \dim(\mathbf{y})$ eine Realisierung der Dichtefunktion $f_v^G(\mathbf{y})$ sind. Mit Wahrscheinlichkeit $q_v^G = 1 - p_v^G$ erzeugen die Generatoren alternativ kein Objekt. Weiterhin sind die einzelnen Objektgeneratoren in der Generationswahrscheinlichkeit und in den Koordinaten der generierten Objekte paarweise statistisch unabhängig.

Die Wahrscheinlichkeit, dass die generierte Objektmenge $Y = \{\mathbf{y}_1, \dots, \mathbf{y}_n\}$ in einer Region S des Vektorraumes enthalten ist, ergibt sich aufgrund der Unabhängigkeitsannahme der Generatoren aus dem Produkt der Inklusionswahrscheinlichkeiten der Einzelobjekte in S . Dabei können für jeden Generator die Inklusionswahrscheinlichkeiten der zwei disjunkten Ereignisse „Objektgeneration“ und „keine Objektgeneration“ addiert werden. Die Inklusionswahrscheinlichkeit des Generators v für den Fall „Objektgeneration“ ergibt sich aus dem Produkt der Generationswahrscheinlichkeit p_v^G und der Wahrscheinlichkeit, dass die Realisierung von $f_v^G(\mathbf{y})$ in

S enthalten ist. Im Fall „keine Objektgeneration“ wird die leere Menge erzeugt, die mit Wahrscheinlichkeit Eins eine Teilmenge von S ist, so dass sich hier die Inklusionswahrscheinlichkeit q_v^G ergibt. Für jeden einzelnen Generator ergibt sich somit die Glaubwürdigkeitsfunktion:

$$\beta_{\mathbf{y}_v}(S) = \begin{cases} q_v^G & \text{für } \mathbf{y}_v = \emptyset, \text{ da } \Pr(\emptyset \subseteq S) = 1 \forall S \\ p_v^G \cdot \int_S f_v^G(\mathbf{y}) d\mathbf{y} & \text{für } \mathbf{y}_v = \mathbf{y}, \text{ da } \Pr(\mathbf{y} \subseteq S) = \int_S f_v^G(\mathbf{y}) d\mathbf{y} \end{cases} \quad (3.37)$$

Mit der Unabhängigkeitsannahme können die Einzelglaubwürdigkeitsfunktionen der Generatoren multipliziert werden. Es entsteht die Glaubwürdigkeitsfunktion des durch die MMBV charakterisierten Punktprozesses

$$\beta_Y(S) = \prod_{v=1}^V \beta_{\mathbf{y}_v}(S) = \prod_{v=1}^V q_v^G + p_v^G \int_S f_v^G(\mathbf{y}) d\mathbf{y}. \quad (3.38)$$

mit dem zugehörigen wahrscheinlichkeitsgenerierenden Funktional (3.9):

$$G[h] = (q^G + p^G \langle f^G, h \rangle)^V. \quad (3.39)$$

Durch Mengen-Differentiation (3.7) des wahrscheinlichkeitsgenerierenden Funktional (3.39) erhält man die Mengen-Wahrscheinlichkeitsdichtefunktion der Multiobjekt-Multi-Bernoulli-Verteilung (Lemma 10, Anhang A, Seite 182):

$$G[h] = (q^G + p^G \langle f^G, h \rangle)^V$$



$$p(Y) = \sum_{1 \leq i_1 \neq \dots \neq i_n \leq V} \prod_{j=1}^n p_{i_j}^G f_{i_j}^G(\mathbf{y}_j) \prod_{l \in \{1, \dots, V\} \setminus \{i_1, \dots, i_n\}} q_l^G. \quad (3.40)$$

In (3.40) wird dabei über alle Möglichkeiten summiert, unter Beachtung der Reihenfolge n verschiedene Elemente $i_1, \dots, i_n$ aus den V Generatoren auszuwählen.

Neben den Unsicherheiten, ob und wo ein Objekt generiert wurde, kodiert die MMBV-Modellierung zusätzlich die Unsicherheit darüber, welches Element einer zufälligen endlichen Menge von welchem Generator erzeugt wurde. In der MMBV-PDF entspricht dies der Summation über alle Möglichkeiten, den n Elementen von Y genau n der V Generatoren unter Beachtung aller möglichen Reihenfolgen zuzuordnen.

Alternativ zur Generatorinterpretation kann auch eine Hypotheseninterpretation als unscharfe Wissensrepräsentation verwendet werden. Dabei werden V Objekthypothesen formuliert. Die Wahrscheinlichkeit, dass das v -te Objekt tatsächlich an der Stelle $\mathbf{y}$ existiert, ist dann $p_v^G f_v^G(\mathbf{y})$. Die Wahrscheinlichkeit, dass das v -te Objekt nicht existiert, ist q_v^G . Für die Wahrscheinlichkeitsdichte der Multiobjekt-Multi-Bernoulli-Verteilung lässt sich außerdem zeigen [58], dass die Anzahl der Hypothesen (Generatoren) immer größer oder gleich der Anzahl realer Objekte sein muss, da für (3.40) gilt:

$$p(Y) = 0, \text{ für } |Y| > V. \quad (3.41)$$

3.3.2 Prädiktion der Multiobjekt-Multi-Bernoulli-Verteilung

Im Folgenden werden die Filtergleichungen für die Multiobjekt-Multi-Bernoulli-Verteilung für eine gaußsche Repräsentation der Aufenthaltswahrscheinlichkeitsdichtefunktionen der einzelnen Objekthypothesen vorgestellt. Die Wissensbasis des Wahrnehmungssystems besteht dabei zum Zeitpunkt $k-1$ aus V Objekthypothesen mit den individuellen Objektexistenzwahrscheinlichkeiten $p_{k-1|k-1}^{\exists,1}, \dots, p_{k-1|k-1}^{\exists,v}$ und den Normalverteilungsparametern:

$$\hat{\mathbf{x}}_{k-1|k-1}^1, \hat{\mathbf{P}}_{k-1|k-1}^1, \dots, \hat{\mathbf{x}}_{k-1|k-1}^V, \hat{\mathbf{P}}_{k-1|k-1}^V. \quad (3.42)$$

Das WGF dieser Wissensrepräsentation zum Zeitpunkt $k-1$ lautet (3.39):

$$\begin{aligned} G_{k-1|k-1}[h] &= \prod_{v=1}^{|V|} q_{k-1|k-1}^{\exists,v} + p_{k-1|k-1}^{\exists,v} \langle \mathcal{N}(\cdot, \hat{\mathbf{x}}_{k-1|k-1}^v, \hat{\mathbf{P}}_{k-1|k-1}^v), h \rangle \\ &= (q_{k-1|k-1}^{\exists} + p_{k-1|k-1}^{\exists} \langle \mathcal{N}_{k-1|k-1}, h \rangle)^V. \end{aligned} \quad (3.43)$$

Für die gaußschen Wahrscheinlichkeitsdichtefunktionen (2.47) bis (2.49) stehen hier und im Folgenden die Kompaktschreibweisen:

$$\mathcal{N}_{k-1|k-1}^v \stackrel{abk.}{=} \mathcal{N}(\mathbf{x}_{k-1}, \hat{\mathbf{x}}_{k-1|k-1}^v, \hat{\mathbf{P}}_{k-1|k-1}^v), \quad (3.44)$$

$$\mathcal{N}_{k|k-1}^v \stackrel{abk.}{=} \mathcal{N}(\mathbf{x}_k, \hat{\mathbf{x}}_{k|k-1}^v, \hat{\mathbf{P}}_{k|k-1}^v), \quad (3.45)$$

$$\mathcal{N}_t \stackrel{abk.}{=} \mathcal{N}(\mathbf{x}_k, \mathbf{F}_k \mathbf{x}_{k-1}, \mathbf{Q}_k) \quad \text{und} \quad (3.46)$$

$$\mathcal{N}_l \stackrel{abk.}{=} \mathcal{N}(\mathbf{z}_k, \mathbf{H}_k \mathbf{x}_k, \mathbf{R}_k). \quad (3.47)$$

Um die Prädiktion der Wissensbasis effizient in WGF-Schreibweise anzugeben, wird zuerst eine WGF-Darstellung des FISST-Transitionsmodells benötigt [58].

Funktionaldarstellung der Transitionswahrscheinlichkeit des Standardmodells

Die im Standardmodell (Abschnitt 3.2.3) für die Überwachung von Lufträumen und Truppenbewegungen adäquate Poissonverteilung neu erscheinender Objekte, die sich durch eine bekannte Objektgeburtsrate pro Volumen und Zeit auszeichnet, wird in der Anpassung für die Fahrzeugumfelderfassung nicht verwendet. Vielmehr wird nach dem Innovationsschritt eine datengetriebene Instanziierung neuer Objekte vorgenommen. Für die Prädiktion wird daher angenommen, dass das Umfeldmodell inklusive aller neu instanziierten Objekte als MMBV parametrisch vorliegt. Die im Transitionsmodell zu berücksichtigenden Fälle reduzieren sich damit auf das Verschwinden von Objekten und die Bewegung von persistenten Objekten im Zustandsraum. Das Transitionsmodell Γ bildet den Metazustand zum Zeitpunkt $k-1$ auf den Metazustand zum Zeitpunkt k ab:

$$X_k = \Gamma(X_{k-1}) = \gamma(\mathbf{x}_{k-1}^1) \cup \dots \cup \gamma(\mathbf{x}_{k-1}^n). \quad (3.48)$$

Die Funktion $\Gamma(X)$ ist das Multiobjekt-Äquivalent des Einzelobjekt-Prozessmodells (2.27). Für jedes einzelne Objekt lautet die Transitionsfunktion γ :

$$\mathbf{x}_k = \gamma(\mathbf{x}_{k-1}) = \begin{cases} \mathbf{x} \sim p(\mathbf{x}_k | \mathbf{x}_{k-1}) & \text{mit Wahrscheinlichkeit } p^P(\mathbf{x}_{k-1}) \\ \emptyset & \text{mit Wahrscheinlichkeit } 1 - p^P(\mathbf{x}_{k-1}) \end{cases}. \quad (3.49)$$

Die Wahrscheinlichkeit $p^P(\mathbf{x}_{k-1})$ beschreibt die Persistenzwahrscheinlichkeit eines Objektes mit Zustand $\mathbf{x}_{k-1}$ vom Zeitschritt $k-1$ zum Zeitschritt k . Die Transitionswahrscheinlichkeit $p(\mathbf{x}_k|\mathbf{x}_{k-1})$ beschreibt die Zustandsübergänge eines einzelnen Objektes (vgl. (2.29), Seite 13). Die Funktionen $p^P(\mathbf{x}_{k-1})$ und $p(\mathbf{x}_k|\mathbf{x}_{k-1})$ sind Modellparameter, die für die jeweilige Applikation spezifiziert werden müssen.

Die Glaubwürdigkeitsfunktion des Transitionsmodells ist die Inklusionswahrscheinlichkeit des Metazustandes X_k in eine beliebige Teilmenge S des Zustandsraumes, gegeben der vorherige Metazustand X_{k-1} :

$$\beta_{X_k}(S|X_{k-1}) = \Pr(X_k \subseteq S|X_{k-1}) = \Pr(\Gamma(X_{k-1}) \subseteq S). \quad (3.50)$$

Aufgrund der Unabhängigkeitsannahme des Standardmodells kann die Inklusionswahrscheinlichkeit des Metazustandes in die Inklusionswahrscheinlichkeiten der Einzelobjekte faktorisiert werden:

$$\beta_{X_k}(S|X_{k-1}) = \Pr(\gamma(\mathbf{x}_{k-1}^1) \subseteq S) \cdot \dots \cdot \Pr(\gamma(\mathbf{x}_{k-1}^n) \subseteq S) \quad (3.51)$$

$$= \prod_{i=1}^n q^P(\mathbf{x}_{k-1}^i) + p^P(\mathbf{x}_{k-1}^i) \int_S p(\mathbf{x}_k|\mathbf{x}_{k-1}^i) d\mathbf{x}_k. \quad (3.52)$$

Folglich ist die Transitionswahrscheinlichkeit ebenfalls eine MMBV. Das zugehörige wahrscheinlichkeitsgenerierende Funktional (siehe (3.39)) lautet:

$$\boxed{G_{k|k-1}[h|X_{k-1}] = (q^P + p^P \langle p^T, h \rangle)^{X_{k-1}}}, \text{ mit } p^T(\mathbf{x}_{k-1}^i) \stackrel{abk.}{=} p(\mathbf{x}_k|\mathbf{x}_{k-1}^i). \quad (3.53)$$

Die Parameter-Prädiktionsgleichungen des Multiobjekt-Multi-Bernoulli-Filters

In die Funktionalform des Bayes-Prädiktors (3.26) kann nun der im vorherigen Abschnitt ermittelte Ausdruck (3.53) für das WGF der Transitionswahrscheinlichkeit des Standardmodells eingesetzt werden. Zusätzlich wird für die allgemeine Transitionswahrscheinlichkeit p^T das gaußsche Modell $\mathcal{N}_t$ (3.46) verwendet:

$$G_{k|k-1}[h] = \int (q^P + p^P \langle p^T, h \rangle)^{X_{k-1}} p(X_{k-1}|Z_{1:k-1}) dX_{k-1} \quad (3.54)$$

$$= G_{k-1|k-1}[q^P + p^P \langle \mathcal{N}_t, h \rangle]. \quad (3.55)$$

Es ergibt sich das kompakte Resultat, dass das WGF der prädizierten Wissensbasis $G_{k|k-1}[h]$ gleich dem WGF der a-posteriori Wissensbasis $G_{k-1|k-1}[h]$ des vorherigen Zeitschrittes mit dem WGF des verwendeten Transitionsmodells $G_{k|k-1}[h|X_{k-1}]$ als Argument ist. Durch die Verwendung des WGF als Integraltransformationen wird hier die Integration innerhalb des Bayes-Prädiktors (3.20) in einen algebraischen Ausdruck verwandelt.

Auf das MMBV-WGF der a-posteriori Wissensbasis des vorherigen Zeitschrittes (3.43) wird die Prädiktionsgleichung (3.55) angewendet:

$$G_{k|k-1}[h] = G_{k-1|k-1}[q^P + p^P \langle \mathcal{N}_t, h \rangle] \quad (3.56)$$

$$= (q_{k-1|k-1}^\exists + p_{k-1|k-1}^\exists \langle \mathcal{N}_{k-1|k-1}, q^P + p^P \langle \mathcal{N}_t, h \rangle \rangle)^V. \quad (3.57)$$

Durch Umformung und durch Einsetzen der entsprechenden Normalverteilungen (Lemma 11, Anhang A, Seite 184) ergibt sich das WGF der prädizierten Multiobjekt-Multi-Bernoulli-Verteilung:

$$G_{k|k-1}[h] = \left(1 - p^P p_{k-1|k-1}^\exists + p^P p_{k-1|k-1}^\exists \langle \mathcal{N}_{k|k-1}, h \rangle\right)^V. \quad (3.58)$$

Mit der Definition der prädizierten Existenzwahrscheinlichkeit

$$p_{k|k-1}^{\exists,v} = p^P(\hat{\mathbf{x}}_{k-1}^v, \hat{\mathbf{P}}_{k-1}^v) \cdot p_{k-1|k-1}^{\exists,v} \quad (3.59)$$

lässt sich (3.58) weiter vereinfachen:

$$G_{k|k-1}[h] = \left(1 - p_{k|k-1}^\exists + p_{k|k-1}^\exists \langle \mathcal{N}_{k|k-1}, h \rangle\right)^V \quad (3.60)$$

$$= \left(q_{k|k-1}^\exists + p_{k|k-1}^\exists \langle \mathcal{N}_{k|k-1}, h \rangle\right)^V. \quad (3.61)$$

Die Prädiktion der MMBV ist damit bei Verwendung des Standardmodells somit wieder eine MMBV. Die Berechnung der a-priori Aufenthaltswahrscheinlichkeitsdichte $\mathcal{N}_{k|k-1}^v$ (3.45) wird mit den regulären Kalman-Prädiktorgleichungen (2.52) und (2.53) durchgeführt:

$$\hat{\mathbf{x}}_{k|k-1}^v = \mathbf{F}_k \hat{\mathbf{x}}_{k-1}^v \quad (3.62)$$

$$\hat{\mathbf{P}}_{k|k-1}^v = \mathbf{F}_k \hat{\mathbf{P}}_{k-1}^v \mathbf{F}_k^T + \mathbf{Q}_k. \quad (3.63)$$

3.3.3 Innovation der Multiobjekt-Multi-Bernoulli-Verteilung

In diesem Abschnitt finden einige ausgezeichnete Mengen Verwendung. Die Menge der Messungen Z lässt sich in die Menge der Falschalarne C (engl. „Clutter“) und die Menge der objektgenerierten Messungen TP (engl. „True Positives“) disjunkt zerlegen. Ebenso lässt sich die Menge der Objekthypothesen des Umfeldmodells V in die Menge der real gar nicht existierenden Objekte TN (engl. „True Negatives“), die Objekte der existierenden aber nicht detektierten Objekte FN (engl. „False Negatives“) und die Menge der existierenden und detektierten Objekte DO (engl. „Detected Objects“) disjunkt zerlegen. Sind anstatt der Mengen geordnete Aufzählungen der Elemente unter Beachtung der Reihenfolge gemeint, werden die Mengensymbole mit einem Stern versehen (z.B.: DO^*).

Funktionaldarstellung des FISST-Messmodells

Das FISST Standard-Sensormodell lautet [58]:

$$Z = \Upsilon(X) \cup C = \Upsilon(\mathbf{x}^1) \cup \dots \cup \Upsilon(\mathbf{x}^n) \cup C. \quad (3.64)$$

Dabei ist Υ der Detektionsoperator und C die zufällige endliche Menge der Falschalarne. Analog zum Prozessmodell gilt für die Glaubwürdigkeitsfunktion der Messmenge im Messraum mit der Unabhängigkeitsannahme zwischen Fehl- und Falschdetektionsprozess im Standardmodell:

$$\beta_Z(S|X_k) = \Pr(Z \subseteq S|X_k) = \Pr(\Upsilon(\mathbf{x}^1) \subseteq S) \cdot \dots \cdot \Pr(\Upsilon(\mathbf{x}^n) \subseteq S) \cdot \Pr(C \subseteq S). \quad (3.65)$$

Für den Fehldetektionsprozess wird das Standardmodell mit der zustandsabhängigen Detektionswahrscheinlichkeit $p^D(\mathbf{x})$ und der Fehldetektionswahrscheinlichkeit $q^D(\mathbf{x}) = 1 - p^D(\mathbf{x})$ verwendet. Diese Größe muss als einzige im Sensormodell a-priori bekannt sein.

$$\mathbf{z}_k = \Upsilon(\mathbf{x}_k) = \begin{cases} \mathbf{z} \sim p(\mathbf{z}_k|\mathbf{x}_k) & \text{mit Wahrscheinlichkeit } p^D(\mathbf{x}_k) \\ \emptyset & \text{mit Wahrscheinlichkeit } 1 - p^D(\mathbf{x}_k) \end{cases} . \quad (3.66)$$

Das WGF der Messmenge, die von realen Objekten (engl. „True Positives“, TP) erzeugt wurde, ist mit der gaußschen Likelihood-Funktion der Messung $p(\mathbf{z}_k|\mathbf{x}_k) = \mathcal{N}_l(\mathbf{z}_k, \mathbf{H}_k\mathbf{x}_k, \mathbf{R}_k)$ (2.49),(3.47) die MMBV:

$$G_{TP}[g|X_k] = (q^D + p^D \langle \mathcal{N}_l, g \rangle)^{X_k} . \quad (3.67)$$

Das WGF des Sensormodells $G_k[g|X_k]$ ergibt sich nach (3.65) aus dem Produkt des WGF der korrekten Detektionen G_{TP} und dem noch nicht näher spezifizieren WGF der Falschalarme G_C :

$$G_k[g|X_k, Z_k] = G_C[g|Z_k] \cdot G_{TP}[g|X_k] \quad (3.68)$$

$$= G_C[g|Z_k] \cdot (q^D + p^D \langle \mathcal{N}_l, g \rangle)^{X_k} . \quad (3.69)$$

Das WGF der a-posteriori Wissensbasis

Zur Berechnung des wahrscheinlichkeitsgenerierenden Funktionals der a-posteriori Wissensbasis nach (3.29) muss zunächst das Funktional $F[g, h]$ mit dem Sensormodell (3.69) bestimmt werden:

$$F[g, h] = \int h^{X_k} \cdot G_k[g|X_k, Z_k] \cdot p(X_k|Z_{1:k-1}) dX_k \quad (3.70)$$

$$= \int h^{X_k} \cdot G_C[g|Z_k] \cdot (q^D + p^D \langle \mathcal{N}_l, g \rangle)^{X_k} \cdot p(X_k|Z_{1:k-1}) dX_k \quad (3.71)$$

$$= G_C[g|Z_k] \cdot \int h^{X_k} \cdot (q^D + p^D \langle \mathcal{N}_l, g \rangle)^{X_k} \cdot p(X_k|Z_{1:k-1}) dX_k \quad (3.72)$$

$$= G_C[g|Z_k] \cdot \int [h(q^D + p^D \langle \mathcal{N}_l, g \rangle)]^{X_k} \cdot p(X_k|Z_{1:k-1}) dX_k . \quad (3.73)$$

Mit dem WGF der prädizierten Wissensbasis (3.23) ergibt sich daraus:

$$F[g, h] = G_C[g|Z_k] \cdot G_{k|k-1}[h(q^D + p^D \langle \mathcal{N}_l, g \rangle)] . \quad (3.74)$$

In diesen Ausdruck kann der im vorherigen Abschnitt gefundene Term für das WGF der prädizierten Multiobjekt-Multi-Bernoulli-Verteilung (3.61) eingesetzt werden:

$$F[g, h] = G_C[g|Z_k] \cdot (q_{k|k-1}^\exists + p_{k|k-1}^\exists \langle \mathcal{N}_{k|k-1}, h(q^D + p^D \langle \mathcal{N}_l, g \rangle) \rangle)^V . \quad (3.75)$$

Durch elementare Umformungen und die Annahme, dass die Zustandsabhängigkeit der Detektionswahrscheinlichkeit in Abhängigkeit von den Normalverteilungsparametern ausreichend gut

beschrieben ist, also wenn $p^{D,v}(\mathbf{x}_k) = p^D(\hat{\mathbf{x}}_{k|k-1}^v, \hat{\mathbf{P}}_{k|k-1}^v)$ gilt, erhält man (Lemma 12, Anhang A, Seite 185):

$$F[g, h] = G_C[g|Z_k] \cdot (q_{k|k-1}^\exists + p_{k|k-1}^\exists q^D \langle \mathcal{N}_{k|k-1}, h \rangle + p_{k|k-1}^\exists p^D \langle \mathcal{N}_{k|k-1}, h \langle \mathcal{N}_l, g \rangle \rangle)^V. \quad (3.76)$$

Da es sich bei der Existenzwahrscheinlichkeit $p_{k|k-1}^\exists$ im Folgenden einheitlich um den prädierten Verteilungsparameter der MMBV-Approximation handelt (3.59), wird zur Vereinfachung in diesem Abschnitt nur noch die Kurzschreibweise $p^\exists \stackrel{abk.}{=} p_{k|k-1}^\exists$ verwendet.

Um das WGF der a-posteriori Wissensbasis gemäß (3.29) zu berechnen, ist das Funktional $F[g, h]$ nach der Messmenge Z zu differenzieren:

$$\frac{\delta F}{\delta Z}[g, h] = \frac{\delta \left[G_C[g|Z_k] \cdot (q^\exists + p^\exists q^D \langle \mathcal{N}_{k|k-1}, h \rangle + p^\exists p^D \langle \mathcal{N}_{k|k-1}, h \langle \mathcal{N}_l, g \rangle \rangle)^V \right]}{\delta Z}[g, h]. \quad (3.77)$$

Mit der Zweierproduktregel (3.18) ergibt sich:

$$\frac{\delta F}{\delta Z}[g, h] = \sum_{C \subseteq Z} \frac{\delta G_C[g|Z_k]}{\delta C}[g] \cdot \frac{\delta \left[(q^\exists + p^\exists q^D \langle \mathcal{N}_{k|k-1}, h \rangle + p^\exists p^D \langle \mathcal{N}_{k|k-1}, h \langle \mathcal{N}_l, g \rangle \rangle)^V \right]}{\delta(Z \setminus C)}[g, h]. \quad (3.78)$$

Hier wird über alle Zerlegungsalternativen der Messmenge Z in die Teilmenge der Falschalarme C und die Teilmenge der objektgenerierten Messungen $TP = Z \setminus C$ summiert. Nach (3.13) erhält man für die Ableitung des Falschalarmmodells bei $g = 0$ die Wahrscheinlichkeitsdichtefunktion der zufälligen endlichen Falschalarmmenge:

$$\frac{\delta G_C[g|Z_k]}{\delta C}[0] = p(C|Z_k). \quad (3.79)$$

Die WDF der Objektdetektionen ergibt sich mit Lemma 14 (Anhang A, Seite 185) für $g = 0$ zu:

$$\begin{aligned} & \frac{\delta \left[(q^\exists + p^\exists q^D \langle \mathcal{N}_{k|k-1}, h \rangle + p^\exists p^D \langle \mathcal{N}_{k|k-1}, h \langle \mathcal{N}_l, g \rangle \rangle)^V \right]}{\delta TP}[0, h] \\ &= \sum_{DO^* \subseteq V: |DO^*| = |TP|} (p^\exists p^D \langle h, \mathcal{N}_l \mathcal{N}_{k|k-1} \rangle)^{DO^*} \cdot (q^\exists + p^\exists q^D \langle h, \mathcal{N}_{k|k-1} \rangle)^{V \setminus DO^*}. \end{aligned} \quad (3.80)$$

Für das WGF der a-posteriori Wissensbasis folgt aus (3.29) und (3.77) bis (3.80):

$$\begin{aligned} G_{k|k}[h] &= \frac{\frac{\delta F}{\delta Z_k}[0, h]}{\frac{\delta F}{\delta Z_k}[0, 1]} \\ &= \frac{\sum_{C \subseteq Z} p(C|Z_k) \sum_{\substack{DO^* \subseteq V: \\ |DO^*| = |Z \setminus C|}} (p^\exists p^D \langle h, \mathcal{N}_l \mathcal{N}_{k|k-1} \rangle)^{DO^*} (q^\exists + p^\exists q^D \langle h, \mathcal{N}_{k|k-1} \rangle)^{V \setminus DO^*}}{\sum_{C \subseteq Z} p(C|Z_k) \sum_{\substack{DO^* \subseteq V: \\ |DO^*| = |Z \setminus C|}} (p^\exists p^D \langle 1, \mathcal{N}_l \mathcal{N}_{k|k-1} \rangle)^{DO^*} (q^\exists + p^\exists q^D \langle 1, \mathcal{N}_{k|k-1} \rangle)^{V \setminus DO^*}}. \end{aligned} \quad (3.81)$$

Da der Nenner nicht mehr von der Testfunktion h abhängt wird er als Normalisierungskonstante NC abgekürzt:

$$G_{k|k}[h] = \frac{1}{NC} \sum_{C \subseteq Z} p(C|Z_k) \sum_{\substack{DO^* \subseteq V: \\ |DO^*| = |Z \setminus C|}} (p^\exists p^D \langle h, \mathcal{N}_l \mathcal{N}_{k|k-1} \rangle)^{DO^*} (q^\exists + p^\exists q^D \langle h, \mathcal{N}_{k|k-1} \rangle)^{V \setminus DO^*}. \quad (3.82)$$

Der Ausdruck $\langle 1, \mathcal{N}_l \mathcal{N}_{k|k-1} \rangle$ im Nenner ist identisch mit der Likelihood der Assoziation der Messung $\mathbf{tp}_j \in Z \setminus C$ zum Objekt $\mathbf{do}_j \in DO^*$ des Umfeldmodells (siehe Abschnitt 2.3.2, Seite 28, Gleichungen (2.85) und (2.86)). Diese Likelihood wird wie folgt abgekürzt geschrieben:

$$\langle 1, \mathcal{N}_l \mathcal{N}_{k|k-1} \rangle = \langle \mathcal{N}_l, \mathcal{N}_{k|k-1} \rangle \quad (3.83)$$

$$= \int \mathcal{N}(\mathbf{tp}_k^j, \mathbf{H}_k \mathbf{x}_k, \mathbf{R}_k^j) \mathcal{N}(\mathbf{x}_k, \hat{\mathbf{x}}_{k|k-1}^{\mathbf{do}_j}, \hat{\mathbf{P}}_{k|k-1}^{\mathbf{do}_j}) d\mathbf{x}_k. \quad (3.84)$$

Mit Lemma 7 (Anhang A, Seite 180) ergibt sich weiter:

$$\langle 1, \mathcal{N}_l \mathcal{N}_{k|k-1} \rangle = \mathcal{N}(\mathbf{tp}_k^j, \mathbf{H}_k \hat{\mathbf{x}}_{k|k-1}^{\mathbf{do}_j}, \mathbf{H}_k \hat{\mathbf{P}}_{k|k-1}^{\mathbf{do}_j} \mathbf{H}_k^T + \mathbf{R}_k^j) \quad (3.85)$$

$$= \Lambda(e = (\mathbf{tp}^j, \mathbf{do}^j)) = \Lambda. \quad (3.86)$$

Mit dem zweiten Kolmogorov-Axiom (2.4) und der daraus resultierenden Identität $\langle 1, \mathcal{N}_{k|k-1} \rangle = 1$ ergibt sich für die Normalisierungskonstante zu:

$$NC = \sum_{C \subseteq Z} p(C|Z_k) \sum_{\substack{DO^* \subseteq V: \\ |DO^*| = |Z \setminus C|}} (p^\exists p^D \Lambda)^{DO^*} (q^\exists + p^\exists q^D)^{V \setminus DO^*}. \quad (3.87)$$

Es ist offensichtlich, dass (3.82) nicht die Form eines MMBV-WGF (3.43) aufweist. Daher resultiert die Innovation einer MMBV-Wissensbasis nicht in einer a-posteriori Wissensbasis, die ebenfalls die MMBV-Form aufweist. Es wird hier darauf verzichtet, das nicht MMBV-förmige korrekte a-posteriori WGF in die zugehörige a-posteriori WDF zu überführen.

Bevor eine MMBV-förmige Approximation vorgestellt wird, muss zunächst noch das Falschalarmmodell $G_C[g]$ implementiert werden.

Das Falschalarmmodell

Die problemadäquate Modellierung des Falschalarmprozesses, d.h. die Bestimmung der Dichtefunktion $p(C|Z_k)$ ist für die Leistungsfähigkeit eines FISST-basierten Filters ausschlaggebend.

In der Literatur [62] wird für den Falschalarmprozess eine MMBV-Modellierung vorgeschlagen, bei der M verschiedene Falschalarmgeneratoren mit einheitlicher Generationswahrscheinlichkeit p^F Falschdetektionen nach der ebenfalls einheitlichen Dichtefunktion $f_c(\mathbf{z})$ erzeugen. Das zugehörige WGF lautet:

$$G_C[g] = (q^F + p^F \langle g, f_c \rangle)^M. \quad (3.88)$$

Für eine uniforme Falschalarmdichte im Messraum $f_c(\mathbf{z}) = |\mathbb{Z}|^{-1}$, eine sehr große Menge an Falschalarmgeneratoren $M \rightarrow \infty$ und eine sehr kleine Generationswahrscheinlichkeit $p^F \rightarrow 0$

konvergiert (3.88) gegen eine Poissonverteilung mit der Falschalarmrate λ pro Messraumhypervolumeneinheit (siehe [58], Seite 373):

$$G_C[g] = e^{\lambda|\mathbb{Z}|\langle g, f_c \rangle - \lambda|\mathbb{Z}|}. \quad (3.89)$$

Dieses Poisson-Falschalarmmodell wird durchgehend in der FISST-Literatur verwendet.

In der radarbasierten Luftraumüberwachung ist eine homogene und a-priori für jeden Sensor bekannte Falschalarmrate λ adäquat. In der Fahrzeugumfelderfassung ist es jedoch kaum möglich, eine konstante Ereignisrate für poissonverteilte Falschalarme in verschiedenen Situationen, wie zum Beispiel bei Tag und Nacht, bei Schlecht- und Schönwetter oder in innerstädtischen und außerstädtischen Szenarien anzugeben. Würde man spezielle Modellparameter für jede dieser Situationen identifizieren, müssten die Situationen aber selbst sensorisch erfasst werden, um das Modell entsprechend umzuschalten. Deshalb wird für die Fahrzeugumfelderfassung nicht das in der Literatur verwendete Poisson-Falschalarmmodell, sondern eine datengetriebene Alternative ohne a-priori bekannte Parameter vorgeschlagen. Zu diesem Zweck wurde in den vorherigen Abschnitten das WGF der Falschalarme $G_C[g|Z_k]$ in Abweichung zur Literatur auf die Menge der aktuellen Messungen Z_k bedingt.

Für die Existenzkomponente bzw. die Generationswahrscheinlichkeit der Falschalarme wird anstatt der a-priori bekannten Poisson-Ereignisrate λ jede einzelne Messung $\mathbf{z} \in Z_k$ vom Sensor mit einer individuellen Falschalarmwahrscheinlichkeit $p^F(\mathbf{z})$, also gewissermaßen mit einer inversen Existenzkonfidenz, versehen (siehe Abschnitt 4.5.4, Seiten 139 ff.). Damit ist jede Messung mit Wahrscheinlichkeit $p^F(\mathbf{z})$ ein Falschalarm und mit Wahrscheinlichkeit $q^F(\mathbf{z}) = 1 - p^F(\mathbf{z})$ die Vermessung eines realen Objektes. Um die Unsicherheit der Messgrößen für die Fusionsstufe zu quantifizieren, liefern die Sensoren zusätzlich zu den Messvektoren $\mathbf{z}$ die Messfehlerkovarianzmatrizen $\mathbf{R}$. In vollständiger Analogie erfolgt für jede einzelne Messung durch die geforderte Falschalarmwahrscheinlichkeit $p^F(\mathbf{z})$ eine statistische Quantifizierung des Falschdetektionsprozesses durch den Sensor.

Für die räumliche a-priori Falschalarmverteilung wird die Gleichverteilung im Messraum beibehalten. In diesem angepassten Falschalarmmodell könnte die MMBV-Form zunächst lauten:

$$G_C[g|Z_k] = (q^F + p^F \langle g, f_c \rangle)^{Z_k}. \quad (3.90)$$

Betrachtet man die FISST-Theorie als simultane Modellierung der Existenz- und Zustandsunsicherheiten, so wird bei diesem Falschalarmmodell lediglich ein ständig vom Sensor neu parametrisiertes Existenzmodell für Falschalarme verwendet. Durch die Nutzung der Gleichverteilung mit dem Informationsgehalt Null (siehe Abschnitt 2.1.2, Seiten 8 ff.), bringt das Modell aufgrund der mangelnden Identifizierbarkeit jedoch kein a-priori Wissen über das räumliche Auftreten von Falschalarmen in die Wissensbasis ein. Die nachfolgenden Betrachtungen werden jedoch mit der allgemeinen räumlichen Falschalarmdichtefunktion $f_c(\mathbf{z})$ durchgeführt.

Differenziert man (3.90) nach der Falschalarmmenge C (3.79), ergibt sich nach (Lemma 10, Anhang A, Seite 182) die Wahrscheinlichkeitsdichtefunktion:

$$p(C|Z_k) = \frac{\delta(q^F + p^F \langle g, f_c \rangle)^{Z_k}}{\delta C} = \sum_{1 \leq i_1 \leq \dots \leq i_n \leq |Z|} \prod_{j=1}^n p_{i_j}^F f_{c, i_j}(\mathbf{z}_j) \prod_{l \in \{1, \dots, |Z|\} \setminus \{i_1, \dots, i_n\}} q_l^F. \quad (3.91)$$

Die MMBV-PDF (3.91) summiert über alle Möglichkeiten, den hypothetischen Falschalarmen $C = \{\mathbf{c}_1, \dots, \mathbf{c}_n\}$ genau $n = |C|$ MMBV-Generatoren aus der aktuellen Messmenge Z_k unter Beachtung der Reihenfolge zuzuordnen. Durch diese Eigenschaft ist eine FISST-PDF in der Lage, die Assoziationsunsicherheit zu repräsentieren.

Im avisierten Szenario, in dem der Sensor die Messungen mit Falschalarmwahrscheinlichkeiten versieht, besteht allerdings diese Assoziationsunsicherheit nicht, da ja der Sensor bereits assoziierte Paare von Messungen, also Falschalarmhypothesen und Generatorparameter, also Falschalarmwahrscheinlichkeiten, liefert. In diesem Fall haben alle Summenterme von (3.91), in denen $i_j \neq j$ gilt, eine reale Eintrittswahrscheinlichkeit von Null. Die Wahrscheinlichkeitsdichte besteht somit lediglich aus dem einen Summand, bei dem $i_j = j$ gilt:

$$p(C|Z_k) = \prod_{j=1}^n p_j^F f_{c,j}(\mathbf{z}_j) \prod_{l \in \{1, \dots, |Z|\} \setminus \{i_1, \dots, i_n\}} q_l^F = (p^F f_c)^C (q^F)^{Z \setminus C}. \quad (3.92)$$

Diese um alle bis auf eine Assoziationshypothese reduzierte Wahrscheinlichkeitsdichte (3.92) ist keine gültige FISST-PDF, da schließlich Summenterme in (3.91) einfach ausgelassen wurden. Die reduzierte PDF würde sich demnach nicht über den gesamten FISST-Ereignishorizont, der aus Existenz, Assoziations- und Zustandsunsicherheit besteht, also bei der Berechnung von (3.8) für $S = \mathbb{Z}$, zu Eins integrieren. Auf einem auf die Existenz- und Zustandsunsicherheit reduzierten Ereignishorizont integriert sich (3.92) jedoch zu Eins und ist daher dort eine gültige Wahrscheinlichkeitsdichtefunktion.

Für die anschließenden Betrachtungen wird das Falschalarmmodell 3.92 verwendet. Nachfolgearbeiten könnten die Einbettung reduzierter Unsicherheitsdomänen in die FISST-Infinitesimalrechnung untersuchen, welche die FISST-Differentiationsregeln (3.15)-(3.19) und die FISST-Integrationsregel (3.8) je nach aktueller Unsicherheitsdomänenkombination verändern würde.

3.3.4 Die „Joint Integrated Probabilistic Data Association“ - Approximation

Um ein rekursives Schätzverfahren und damit eine effiziente Softwareimplementierung zu erhalten, ist es erforderlich, dass sowohl der Prädiktionsschritt als auch der Innovationsschritt den Verteilungstyp der Wissensbasis erhalten. Da dies bei der MMBV-Innovation, wie im vorherigen Abschnitt gezeigt, nicht der Fall ist, wird im Folgenden eine Approximationsstrategie vom korrekten nicht MMBV-förmigen WGF der a-posteriori Wissensbasis (3.82) auf die Form eines MMBV-WGF vorgestellt. Diese Approximation führt zu den „Joint Integrated Probabilistic Data Association“-Filtern (JIPDA, [64]) und den Morelande-Challa-Filtern [62].

Die a-posteriori PDF wird durch Differentiation aus dem a-posteriori WGF berechnet (3.13). Gemäß der Summenregel (3.17) bleibt der konstante Nenner NC bei dieser Differentiation erhalten. Die Normierungskonstante im Nenner der a-posteriori PDF und des a-posteriori WGF sind daher identisch.

Dieser Nenner gibt die a-posteriori Likelihood des sicheren Ereignisses an. Als a-posteriori Likelihood wird im Folgenden der Nenner in (2.23) bezeichnet, also das unnormierte Produkt der

a-priori Wahrscheinlichkeit mit der sensorischen Likelihood eines Ereignisses. Das sichere Ereignis entspricht der „Oder“-Verknüpfung des gesamten Ereignishorizontes. Der Ereignishorizont ist hybrid, denn er enthält gleichzeitig kontinuierliche und diskrete Alternativen. Die kontinuierlichen Alternativen repräsentieren die Zustandsunsicherheiten, die diskreten die Existenz-, Detektions- und Assoziationsunsicherheiten. Die a-posteriori Likelihood des sicheren Ereignisses wird im Nenner von (3.81) über alle kontinuierlichen Ereignisalternativen integriert, da mit $h = 1$ die Indikatorfunktion des gesamten Zustandsraumes gewählt wird, und über alle diskreten Ereignisalternativen aufsummiert.

Die a-posteriori BMF ist das Verhältnis der a-posteriori Likelihood einer Teilmenge des Zustandsraumes zur a-posteriori Likelihood des sicheren Ereignisses. Die a-posteriori PDF ist das Verhältnis der a-posteriori Likelihood einer endlichen zufälligen Punktmenge zur a-posteriori Likelihood des sicheren Ereignisses.

Das sichere Ereignis besteht nach Integration der kontinuierlichen Anteile (3.84) nur noch aus diskreten und disjunkten Alternativen. Jede dieser Alternativen ist ein Verbundereignis, das eine Verbundhypothese über alle Objekte hinsichtlich deren Existenz, Detektion und Messwertassoziation sowie über alle Messungen hinsichtlich deren Ursprungs von einem realen Objekt darstellt. Dieser Fakt kann durch die Umformung der Normalisierungskonstante (3.87) auf eine disjunktive Normalform gezeigt werden (Lemma 15, Anhang A, Seite 186):

$$NC = \sum_{C \subseteq Z} (p^F f_c)^C (q^F)^{Z \setminus C} \sum_{\substack{DO^* \subseteq V: \\ |DO^*| = |Z \setminus C|}} (p^\exists p^D \Lambda)^{DO^*} (q^\exists + p^\exists q^D)^{V \setminus DO^*} \quad (3.93)$$

$$= \sum_{C \subseteq Z} (p^F f_c)^C (q^F)^{Z \setminus C} \sum_{\substack{DO^* \subseteq V: \\ |DO^*| = |Z \setminus C|}} (p^\exists p^D \Lambda)^{DO^*} \sum_{FN \subseteq V \setminus DO^*} (p^\exists q^D)^{FN} (q^\exists)^{V \setminus (DO^* \uplus FN)} \quad (3.94)$$

$$\text{mit } TN = V \setminus (DO^* \uplus FN): \quad (3.95)$$

$$= \underbrace{\sum_{C \subseteq Z} \sum_{\substack{DO^* \subseteq V: \\ |DO^*| = |Z \setminus C|}}}_{\text{Disjunktionen}} \sum_{FN \subseteq V \setminus DO^*} \underbrace{(p^F f_c)^C (q^F)^{Z \setminus C} (p^\exists p^D \Lambda)^{DO^*} (p^\exists q^D)^{FN} (q^\exists)^{TN}}_{\text{Konjunktionen}}. \quad (3.96)$$

Die einzelnen Verbundereignisse, d.h. die Konjunktionen von Einzelereignissen, sind durch die Produktterme aus Einzelwahrscheinlichkeiten repräsentiert. Nur eine einzige dieser Konjunktion entspricht der Realität. Das exklusive und alternative Eintreten der Verbundereignisse, d.h. die Disjunktion der Konjunktionen, wird durch die Summation der Verbundwahrscheinlichkeiten ausgedrückt. Die Verbundwahrscheinlichkeit einer Konjunktion lässt sich in die Wahrscheinlichkeiten der vier Fälle einer Detektor-Konfusionsmatrix (FP: „false positive“, TP: „true positive“, FN: „false negative“ und TN: „true negative“) faktorisieren:

$$NC = \underbrace{\sum_{C \subseteq Z} \sum_{\substack{DO^* \subseteq V: \\ |DO^*| = |Z \setminus C|}}}_{\text{Disjunktionen}} \sum_{FN \subseteq V \setminus DO^*} \underbrace{(p^F f_c)^C}_{\text{FP}} \underbrace{(q^F)^{Z \setminus C} (p^\exists p^D \Lambda)^{DO^*}}_{\text{TP}} \underbrace{(p^\exists q^D)^{FN}}_{\text{FN}} \underbrace{(q^\exists)^{TN}}_{\text{TN}}. \quad (3.97)$$

In einem einfachen Beispiel mit zwei Objekten im Umfeldmodell ($|V|=2$) und einer aufzeichneten Messung ($|Z|=1$) lautet die disjunktive Normalform des sicheren Ereignisses als aussagenlogische Formel auszugsweise im Wortlaut:

*Sicheres Ereignis: "Entweder [Objekt 1 existiert nicht **und** Objekt 2 existiert **und** Objekt 2 wurde nicht detektiert **und** Messung 1 ist ein Falschalarm] **oder** [Objekt 1 existiert **und** Objekt 1 wurde detektiert **und** Messung 1 ist kein Falschalarm **und** Objekt 1 erzeugte Messung 1 **und** Objekt 2 existiert **und** Objekt 2 wurde nicht detektiert] **oder** [Objekt 1 existiert nicht **und** Objekt 2 existiert nicht **und** Messung 1 ist ein Falschalarm] **oder** [... "*

Die entsprechende a-posteriori Likelihood des sicheren Ereignisses berechnet sich auszugsweise zu:

$$NC = q_1^{\exists} p_2^{\exists} q_2^D p_1^F f_{c,1} + p_1^{\exists} p_1^D q_1^F \Lambda_1^1 p_2^{\exists} q_2^D + q_1^{\exists} q_2^{\exists} p_1^F f_{c,1} + \dots \quad (3.98)$$

Durch Marginalisierung, d.h. durch das Berechnen von Randverteilungen, können die Wahrscheinlichkeiten von Einzelereignissen berechnet werden, die im ursprünglichen WGF bzw. der ursprünglichen PDF nur in Verbundereignissen auftreten. In diesem Fall ist die a-posteriori Wahrscheinlichkeit eines Einzelereignisses nach dem Satz von Bayes die Summe der a-posteriori Likelihoods aller „günstigen“ Verbundereignisse, d.h. aller Verbundereignisse, die das interessierende Einzelereignis enthalten, geteilt durch die Summe der a-posteriori Likelihoods aller möglichen Verbundereignisse.

Die Parameter der approximativen a-posteriori MMBV, d.h. die Existenzwahrscheinlichkeiten $p_{k|k}^{\exists,v}$ der Objekte des Umfeldmodells und deren Aufenthaltswahrscheinlichkeitsdichtefunktionen $\mathcal{N}_{k|k}^v$ im Zustandsraum werden jetzt durch Anwendung der Marginalisierungstechnik aus der a-posteriori Likelihood des sicheren Ereignisses gewonnen. Für die a-posteriori Existenzwahrscheinlichkeit werden dazu die Likelihoods aller Konjunktionen, in denen das Objekt v existiert zur Likelihood aller möglichen Konjunktionen, also zur Normalisierungskonstante, ins Verhältnis gesetzt:

$$p_{k|k}^{\exists,v} = \frac{1}{NC} \sum_{C \subseteq Z} \sum_{\substack{DO^* \subseteq V: \\ |DO^*| = |Z \setminus C|}} \sum_{\substack{FN \subseteq V \setminus DO^*: \\ v \in (DO^* \cup FN)}} (p^F f_c)^C (q^F)^{Z \setminus C} (p^{\exists} p^D \Lambda)^{DO^*} (p^{\exists} q^D)^{FN} (q^{\exists})^{TN} \quad (3.99)$$

Die Angabe einer a-posteriori Aufenthaltswahrscheinlichkeitsdichtefunktion eines Objektes v im Zustandsraum ist nur für den Fall der a-posteriori Objektexistenz von v sinnvoll. Zu ihr tragen demnach nur die Konjunktionen bei, in denen dieses Objekt nach der Innovation noch existiert. Ferner entstehen bei der Realisierung der verschiedenen Konjunktionen verschiedene a-posteriori Dichtefunktionen in Abhängigkeit davon, ob das Objekt innerhalb der Konjunktion überhaupt detektiert wurde und zu welcher Messung es innerhalb der Konjunktion assoziiert wurde. Wenn ein Objekt innerhalb einer Konjunktion existiert, aber nicht detektiert wurde, entspricht die a-posteriori Dichtefunktion des Objektzustandes der prädierten Dichtefunktion. Im Gegensatz dazu entspricht die a-posteriori Dichte der bayesschen Innovation (2.23) mit der Messung $\mathbf{z}$, wenn das Objekt innerhalb einer Konjunktion existiert und zusätzlich zur Messung $\mathbf{z}$ assoziiert wurde.

Da unklar ist, welche der Konjunktionen die Realität widerspiegelt, entsteht durch die „Oder“-Verknüpfung der Konjunktionen auch eine „Oder“-Verknüpfung der Innovationen und somit

eine a-posteriori Mischverteilung für die Zustandsunsicherheit eines Objektes v :

$$p(\mathbf{x}_{k|k}^v) = \beta_{v0} \cdot \mathcal{N}(\mathbf{x}_{k|k}^v, \hat{\mathbf{x}}_{k|k-1}^v, \hat{\mathbf{P}}_{k|k-1}^v) + \sum_{j=1}^{|Z|} \beta_{vj} \cdot \mathcal{N}(\mathbf{x}_{k|k}^v, \hat{\mathbf{x}}_{k|k-1}^v + \mathbf{K}^{vj} \boldsymbol{\gamma}^{vj}, \hat{\mathbf{P}}_{k|k-1}^v - \hat{\mathbf{P}}_{k|k-1}^v \mathbf{H}^T (\mathbf{S}^{vj})^{-1} \mathbf{H} \hat{\mathbf{P}}_{k|k-1}^v). \quad (3.100)$$

Die verwendeten Matrizen (2.88) und (2.89) werden analog zur Standard-Datenassoziation (siehe Abschnitt 2.3.2, Seite 27) berechnet. Die Gewichte β_{vj} der einzelnen Komponenten dieser Mischverteilung entsprechen den auf die Objektexistenz bedingten Assoziationswahrscheinlichkeiten des Objektes zu den einzelnen Messungen und das Gewicht β_{v0} entspricht der Assoziationswahrscheinlichkeit zur Zustandsprädiktion des Objektes. Diese Gewichte lassen sich analog zur a-posteriori Existenzwahrscheinlichkeit aus der a-posteriori Likelihood des sicheren Ereignisses ausmarginalisieren. So entspricht die Assoziationswahrscheinlichkeit des Objektes v mit der Messung $\mathbf{z}$ der Summe der a-posteriori Likelihoods aller Konjunktionen, in denen v existiert und zu $\mathbf{z}$ assoziiert ist, geteilt durch die Summe der a-posteriori Likelihoods aller Konjunktionen, in denen v existiert:

$$\beta_{vj} = \frac{\sum_{\substack{C \subseteq Z: \\ \mathbf{z}^j \in Z \setminus C}} \sum_{\substack{DO^* \subseteq V: \\ |DO^*| = |Z \setminus C|, \\ \mathbf{do}^j = v}} \sum_{FN \subseteq V \setminus DO^*} (p^F f_c)^C (q^F)^{Z \setminus C} (p^\exists p^D \Lambda)^{DO^*} (p^\exists q^D)^{FN} (q^\exists)^{TN}}{\sum_{C \subseteq Z} \sum_{\substack{DO^* \subseteq V: \\ |DO^*| = |Z \setminus C|}} \sum_{v \in (DO^* \uplus FN)} (p^F f_c)^C (q^F)^{Z \setminus C} (p^\exists p^D \Lambda)^{DO^*} (p^\exists q^D)^{FN} (q^\exists)^{TN}}. \quad (3.101)$$

Die Assoziationswahrscheinlichkeit zur eigenen Zustandsprädiktion des Objektes v berechnet sich analog aus der Summe der a-posteriori Likelihoods aller Konjunktionen, in denen v existiert aber nicht detektiert wurde, geteilt durch die Summe der a-posteriori Likelihoods aller Konjunktionen, in denen v existiert:

$$\beta_{v0} = \frac{\sum_{C \subseteq Z} \sum_{\substack{DO^* \subseteq V: \\ |DO^*| = |Z \setminus C|}} \sum_{\substack{FN \subseteq V \setminus DO^*: \\ v \in FN}} (p^F f_c)^C (q^F)^{Z \setminus C} (p^\exists p^D \Lambda)^{DO^*} (p^\exists q^D)^{FN} (q^\exists)^{TN}}{\sum_{C \subseteq Z} \sum_{\substack{DO^* \subseteq V: \\ |DO^*| = |Z \setminus C|}} \sum_{v \in (DO^* \uplus FN)} (p^F f_c)^C (q^F)^{Z \setminus C} (p^\exists p^D \Lambda)^{DO^*} (p^\exists q^D)^{FN} (q^\exists)^{TN}}. \quad (3.102)$$

Weil die a-posteriori Mischverteilung (3.100) eine Konvexkombination der Einzelinnovationen darstellt, muss

$$\sum_{j=0}^{|Z|} \beta_{vj} = 1 \quad (3.103)$$

gelten. Dies ist jedoch sichergestellt, da die im Nenner der Assoziationsgewichte stehende Menge von Konjunktionen, in denen das Objekt v existiert, in die jeweils in den Zählern stehenden Mengen von Konjunktionen disjunkt zerfällt, in denen das jeweilige Assoziationsereignis enthalten ist.

Da für eine geschlossene Filterrekursion die MMBV-Form für das a-posteriori WGF gefordert wird, die eine einzige Normalverteilung pro Objekt für die Zustandsunsicherheiten vorsieht (3.43), lässt sich die a-posteriori Mischverteilung (3.100) nicht direkt weiterverwenden. Vielmehr muss diese Mischverteilung durch Berechnung ihrer ersten beiden statistischen Momente

gewissermaßen in Gestalt ihrer „umschließenden“ Normalverteilung approximiert werden ([65] und [4] - Seiten 164 ff. und 324 ff.):

$$\hat{\mathbf{x}}_{k|k}^v = \sum_{j=0}^{|Z|} \beta_{vj} (\hat{\mathbf{x}}_{k|k-1}^v + \mathbf{K}^{vj} \boldsymbol{\gamma}^{vj}) \quad (3.104)$$

$$\hat{\mathbf{P}}_{k|k}^v = \sum_{j=0}^{|Z|} \beta_{vj} \left[\hat{\mathbf{P}}_{k|k-1}^v - \mathbf{K}^{vj} \mathbf{S}^{vj} (\mathbf{K}^{vj})^T + (\hat{\mathbf{x}}_{k|k-1}^v + \mathbf{K}^{vj} \boldsymbol{\gamma}^{vj} - \hat{\mathbf{x}}_{k|k}^v) (\hat{\mathbf{x}}_{k|k-1}^v + \mathbf{K}^{vj} \boldsymbol{\gamma}^{vj} - \hat{\mathbf{x}}_{k|k}^v)^T \right] \quad (3.105)$$

In dieser kompakten Schreibweise gelten bei der Assoziation eines Objektes v zur eigenen Zustandsprädiktion, d.h. bei $j = 0$: $\mathbf{K}^{v0} = \mathbf{0}$ und $\boldsymbol{\gamma}^{v0} = \mathbf{0}$.

Innerhalb des Innovationsschrittes können mit (3.99), (3.104) und (3.105) alle Verteilungsparameter der a-posteriori MMBV für alle $v = 1..|V|$ Objekte der Wissensbasis neu berechnet werden. Die JIPDA-Filterrekursion ist damit abgeschlossen.

Eine qualitative Beschreibung des JIPDA-Approximationsfehlers

Die Inklusionswahrscheinlichkeit des gesamten Metazustandes in eine Zustandsraumteilmenge S wird bei der MMBV-Modellierung als Produkt der Einzelinklusionswahrscheinlichkeiten der Objekthypothesen berechnet (3.38). Da die Verbundwahrscheinlichkeit gegenseitig unabhängiger Elementarereignisse durch die Multiplikation der Einzelwahrscheinlichkeiten ermittelt wird

$$p(A \cap B) = p(A)p(B) \iff A \text{ und } B \text{ statistisch unabhängig} \quad (3.106)$$

impliziert das MMBV-Produkt eine Unabhängigkeitsannahme der Einzelobjekte sowohl in der Existenz- als auch in der Zustandsdomäne.

Da die FISST-Innovation einer MMBV (3.82) nicht wieder in einer MMBV-Produktform (3.43) resultiert, führt sie offenbar gegenseitige Abhängigkeiten zwischen den Objekthypothesen der Wissensbasis ein. Abbildung 3.4 veranschaulicht diesen Fakt am Beispiel zweier Objekte bei einer eintreffenden Messung. Wenn beide Objekte $\mathbf{x}^1$ und $\mathbf{x}^2$ mit hoher Wahrscheinlichkeit




Abbildung 3.4: Zwei Objekte des Umfeldmodells $\mathbf{x}^1$, $\mathbf{x}^2$ konkurrieren um eine einzige Messung $\mathbf{z}^1$.

existieren, wird gewissermaßen die „Existenzevidenzmasse“ der Messung $\mathbf{z}^1$ auf beide Objekte aufgeteilt. Wenn das Objekt $\mathbf{x}^2$ jedoch nicht existiert, d.h. $p^{\exists,2} = 0$, werden die a-posteriori Likelihoods der Konjunktionen verschwinden, die $\mathbf{z}^1$ mit $\mathbf{x}^2$ assoziieren. In diesem Fall kann $\mathbf{x}^1$ die gesamte „Existenzevidenzmasse“ von $\mathbf{z}^1$ in der Innovation aufnehmen. Durch die Konkurrenz um die Messung $\mathbf{z}^1$ wird damit die Existenzwahrscheinlichkeit des Objektes $\mathbf{x}^1$ an die

Existenz des Objektes $\mathbf{x}^2$ gekoppelt. Die gleiche Abhängigkeit kann bei den Zustandsinnovationen festgestellt werden, da die Assoziationsgewichte β_{vj} (3.101) ebenfalls aus den a-posteriori Likelihoods der Konjunktionen gewonnen werden. Je geringer die Existenzwahrscheinlichkeit von $\mathbf{x}^2$, desto stärker wird die Innovation des Objektes $\mathbf{x}^1$ in Richtung der Messung $\mathbf{z}^1$ ausfallen.

Nach der Innovation ist die Existenz eines Objektes und dessen Zustand nicht mehr unabhängig von der Existenz und den Zuständen der anderen Objekthypothesen. Die Wahrscheinlichkeiten der Metazustände oder Objektkonfigurationen lassen sich nicht mehr ohne Informationsverlust in unabhängige Einzelobjektbeschreibungen zerlegen.

In Analogie kann davon gesprochen werden, dass eine FISST-Innovation eine Verschränkung (=Nichtseparierbarkeit) der Einzelobjektzustände eines Umfeldmodells bewirkt. Durch die Ausmarginalisierung unabhängiger Existenz- und Zustandswahrscheinlichkeiten während der JIPDA-Approximation erfolgt in jedem Filterschritt eine explizite Dekorrelation der Einzelobjekthypothesen. Der JIPDA-Approximationsfehler ist der dabei auftretende Informationsverlust über die gegenseitigen Abhängigkeiten der Objekte, die durch die Konkurrenz um die eintreffenden Messungen induziert werden.

3.3.5 Eine graphentheoretische Interpretation und ein Implementierungsvorschlag für die JIPDA - Filtergleichungen

In diesem Abschnitt werden die JIPDA-Filtergleichungen anhand einer Graphendarstellung abgeleitet. Obwohl diese Ableitung in exakt denselben Filtergleichungen mündet, die in den vorherigen Abschnitten aus der FISST-Theorie entstanden sind, trägt sie ungleich mehr zum intuitiven Verständnis des Verfahrens bei. Außerdem wird mit Hilfe dieser Darstellung ein Implementierungsvorschlag vorgestellt.

Das Ablaufschema des JIPDA-Filters

Die Repräsentation der Existenz- und Zustandsunsicherheiten in der MMBV- bzw. JIPDA-Darstellung kann für jedes Objekt der Wissensbasis als Evolution zweier gekoppelter Markov-Ketten interpretiert werden (Abbildung 3.5). Die erste Markov-Kette, die die Zustandsunsicherheiten propagiert, wird durch das herkömmliche Kalman-Filter mit multiplen gewichteten Assoziationen implementiert. Die zweite Markov-Kette repräsentiert die Existenzunsicherheit des Objektes anhand einer einzigen Wahrscheinlichkeit $p^\exists$ für das Verbundereignis der Objektexistenz, der Objektrelevanz und der Objektbeobachtbarkeit. Mit dem Gegenereignis der Nichtexistenz, der Nichtrelevanz oder der Nichtbeobachtbarkeit, dessen Wahrscheinlichkeit durch $1 - p^\exists$ berechnet wird, ist der binäre Ereignishorizont dieser zweiten Markov-Kette vollständig.

Die Prädiktion der Zustandsunsicherheiten unter Einbeziehung eines Dynamikmodells erfolgt innerhalb der ersten Markov-Kette für jedes Objekt der Wissensbasis separat mit (3.62) und (3.63). In Abhängigkeit dieser prädizierten Zustände berechnet sich die Prädiktion der Existenzwahrscheinlichkeit (3.59) in der zweiten Markov-Kette unter Einbeziehung eines Objektpersistenzmodells $p^P(\hat{\mathbf{x}}_{k-1}^v, \hat{\mathbf{P}}_{k-1}^v)$, das zum Beispiel Verdeckungen, Sensorsichtbereiche oder




Abbildung 3.5: Für jedes Objekt der Wissensrepräsentation modellieren zwei gekoppelte Markov-Ketten jeweils die Existenz- und Zustandsevolution durch die Zeit.

sonstige a-priori bekannte Zustandsbeschränkungen enthält. Die Einbeziehung der Zustandsprediktionen in die Existenzprediktion ist der erste Kopplungspunkt der Markov-Ketten (Pfeile in Abbildung 3.5). Nach der Prädiktion beider Markov-Ketten erfolgt die Innovation.

Eine graphentheoretische Interpretation der JIPDA-Innovation

Zur Veranschaulichung der JIPDA-Innovation wird das grafische Assoziationsmodell in Form von bipartiten Graphen aus dem Abschnitt zur Standard-Datenassoziation (Abschnitt 2.3.2, Seite 27) erweitert. Wurden zu einem Umfeldmodell mit $m = |V|$ Objekten $n = |Z|$ Messungen aufgezeichnet, existieren mehrere mehr oder weniger wahrscheinliche Zuordnungshypothesen. Das JIPDA-Filter wählt keine dieser Hypothesen exklusiv aus, sondern berücksichtigt alle Hypothesen in gewichteter Form (engl. „Soft Decision“). Dazu wird das Zuordnungsproblem als bipartiter Graph mit der bipartiten Knotenmenge $K = (V, Z)$ und der Kantenmenge E modelliert. Die Knoten-Teilmenge $V = \{1, \dots, m, \textcircled{c}\}$ enthält die Indizes der Objekte des Umfeldmodells und ein Spezialelement $\textcircled{c}$, das den virtuellen Falschalarmgenerator symbolisiert (engl. „Clutter Source“). Die Knoten-Teilmenge $Z = \{1, \dots, n, \emptyset, \nexists\}$ enthält die m Indizes der Messungen und zwei Spezialelemente. Das Element $\emptyset$ repräsentiert eine Fehldetektion und das Element $\nexists$ symbolisiert die Nichtexistenz eines Objektes. In den Annahmen des Standard-Messmodells wurden Mehrfachdetektionen und Segmentzerfälle ausgeschlossen. In diesem Fall wird die Kantenmenge E , die die beiden Knotenteilmengen V und Z verbindet, als gültige Zuordnung bezeichnet, wenn sie folgende Eigenschaften besitzt:

- Alle Kanten e in E verbinden Knoten aus V und Z und keine Kante verläuft innerhalb von V oder Z , d.h. $e \in V \times Z$.




Abbildung 3.6: Drei verschiedene Beispiel-Zuordnungen. Diese Zuordnungen entsprechen den in Abschnitt 3.3.4, Seite 59, auszugsweise im Wortlaut wiedergegebenen Konjunktionen.

- Alle Indexknoten in V und Z haben den Knotengrad Eins, d.h. alle Indexknoten sind mit genau einer Kante verbunden.
- In E verläuft keine Kante zwischen zwei Spezialelementen $(\textcircled{c}, \emptyset, \neq)$.

Abbildung 3.6 zeigt drei gültige Zuordnungen für den Fall von $n = |V| = 2$ Objekten und $m = |Z| = 1$ Messungen. Die Knoten-Teilmenge V der Objekte ist in Form von Kreisen und die Knoten-Teilmenge Z der Messungen in Form von Quadraten dargestellt. Jede gültige Zuordnung E entspricht in der Terminologie der FISST-basierten Herleitung der JIPDA-Innovation (Abschnitt 3.3.4, Seiten 59 ff.) genau einer der Konjunktionen in (3.96).

Innerhalb einer gültigen Zuordnung sind nach den oben genannten Regeln nur vier Kantentypen zulässig. Diese vier Kantentypen korrespondieren direkt mit den vier Fällen einer Detektor-Konfusionsmatrix (Tabelle 3.1).

Tabelle 3.1: Kantentypen einer gültigen Zuordnung

	Messwertassoziation (engl. „True Positive“) Messung j stammt von Objekt v .
	Falschdetektion (engl. „False Positive“) Messung j repräsentiert kein real vorhandenes Objekt. ($\textcircled{c}$ ist die virtuelle Falschalarmquelle)
	Fehldetektion (engl. „False Negative“) Objekt v existiert, wurde aber nicht detektiert. ($\emptyset$ symbolisiert die leere Messmenge)
	Nichtexistenz (engl. „True Negative“) Objekt v wurde nicht detektiert, weil es nicht existiert. ($\neq$ symbolisiert die Nicht-Existenz des Objektes)

Da innerhalb einer Zuordnung die Einzelassoziationen der Objekte und Messungen gleichzeitig eintreten, also eine Zuordnung das Verbundereignis aller durch ihre Kanten repräsentierten Einzelereignisse darstellt, wird die Likelihood einer Zuordnung aus dem Produkt der Kanten-

Tabelle 3.2: Tabelle der Kanten-Likelihoods (LUT)

LUT	$\emptyset$	$\nexists$	$\mathbf{z}_1$
$\odot$	$\times$	$\times$	$l(\odot, 1)$
$\mathbf{x}_1$	$l(1, \emptyset)$	$l(1, \nexists)$	$l(1, 1)$
$\mathbf{x}_2$	$l(2, \emptyset)$	$l(2, \nexists)$	$l(2, 1)$

Likelihoods berechnet:

$$l(E) = \prod_{e_i \in E} l(e_i). \quad (3.107)$$

Die Berechnung der Kanten-Likelihoods $l(e_i)$ hängt vom Kantentyp (Tabelle 3.1) ab. Die Likelihood einer Messwertassoziations-Kante berechnet sich zu:

$$l(e = (v, j)) = \Lambda_v^j \cdot p_v^D \cdot p_v^\exists \cdot q_j^F. \quad (3.108)$$

Nach (3.108) hat die Assoziation zwischen dem Objekt v und der Messung $\mathbf{z}_j$ dann eine hohe Likelihood, wenn die prädizierte Existenzwahrscheinlichkeit des Objektes $p_v^\exists$ groß ist, die sensorische Detektionswahrscheinlichkeit groß ist, die sensorische Falschalarmwahrscheinlichkeit der Messung $p_j^F = 1 - q_j^F$ klein ist und wenn im Messraum die räumliche Nähe Λ_v^j (3.85) zwischen Messwertprädiktion und Messung bezogen auf die bisherigen Zustandsunsicherheiten und die Messunsicherheiten gegeben ist. Hier unterscheidet sich das JIPDA-Verfahren vom Standardansatz, denn es werden für die Assoziationsgewichte auch die Existenzwahrscheinlichkeiten der Messung und des Umfeldmodells einbezogen. Dadurch können die heuristischen Regeln der Objektverwaltung vermieden werden, die zum Beispiel aus zu großen Zustandsunsicherheiten auf die Nichtexistenz schließen, um zu verhindern, dass Falschobjekte real existierenden Objekten ihre Messungen entziehen (Regel 3 in Abschnitt 2.3.4, Seiten 30 ff.). Die Likelihood einer Falschalarm-Kante berechnet sich aus dem Produkt der sensorischen Falschalarmwahrscheinlichkeit und der räumlichen Auftretenswahrscheinlichkeit von Falschalarmen:

$$l(e = (\odot, j)) = p_j^F \cdot f_{c,j}. \quad (3.109)$$

Die Likelihood einer Fehldetektionskante lautet:

$$l(e = (v, \emptyset)) = q_v^D \cdot p_v^\exists. \quad (3.110)$$

Die Wahrscheinlichkeit q_v^D ist die sensorspezifische Fehldetektionswahrscheinlichkeit in der Region des Messraumes, die durch die Messwertprädiktion des Objektes v , also durch $h(\hat{\mathbf{x}}^v)$ und $\mathbf{J}_h^T \hat{\mathbf{P}}^v \mathbf{J}_h$ definiert ist. Hierbei bezeichnet h die Messfunktion und $\mathbf{J}_h$ deren Jacobi-Matrix am Arbeitspunkt der Zustandsprädiktion. Diese Größe wird mit der prädizierten Existenzwahrscheinlichkeit des Objektes $p_v^\exists$ multipliziert. Die Likelihood des Nichtexistenz-Kantentyps berechnet sich abschließend zu:

$$l(e = (v, \nexists)) = q_v^\exists = 1 - p_v^\exists. \quad (3.111)$$

Jetzt kann die Likelihood einer Zuordnung aus dem Produkt der Kanten-Likelihoods mit (3.107) berechnet werden. Die a-posteriori Existenzwahrscheinlichkeit des Objektes v ergibt

Tabelle 3.3: Tabelle der aufsummierten Zuordnungs-Likelihoods (SUM)

SUM	$\emptyset$	$\#$	$\mathbf{z}_1$
$\textcircled{c}$	$\times$	$\times$	$\sum_{E:(\textcircled{c},1) \in E} l(E)$
$\mathbf{x}_1$	$\sum_{E:(1,\emptyset) \in E} l(E)$	$\sum_{E:(1,\#) \in E} l(E)$	$\sum_{E:(1,1) \in E} l(E)$
$\mathbf{x}_2$	$\sum_{E:(2,\emptyset) \in E} l(E)$	$\sum_{E:(2,\#) \in E} l(E)$	$\sum_{E:(2,1) \in E} l(E)$

sich jetzt aus dem Verhältnis der Likelihoods aller Zuordnungen, in denen v nicht mit $\#$ verbunden ist zur Likelihood aller möglichen Zuordnungen:

$$p_{k|k}^{\exists,v} = \frac{\sum_{E:(v,\#) \notin E} l(E)}{\sum_E l(E)}. \quad (3.112)$$

Diese Existenzinnovation ist identisch mit der Innovationsregel der FISST-basierten Herleitung (3.99) und benötigt eine Aufzählung aller möglichen Zuordnungen (Konjunktionen). Zur effizienten Implementierung wird zunächst eine Nachschlagetabelle LUT (engl. „Lookup-Table“) mit den Likelihoods aller möglichen Kanten mit (3.108)-(3.111) berechnet, wie in Tabelle 3.2 für das Beispiel aus Abbildung 3.6 dargestellt. Danach wird eine zu LUT strukturell identische zweite Tabelle (SUM) mit Nullen initialisiert. In ihr soll später an jeder Tabellenposition

Algorithmus 1 EnumerateMatchings($V, Z, E, l(E)$)

```

1  if  $|V| = 1$  and  $|Z| = 2$  then
2      for all  $e \in E$  do
3          SUM( $e$ ) = SUM( $e$ ) +  $l(E)$ 
4      end for
5      return
6  end if
7   $v = \text{firstElementOf}(V \setminus \textcircled{c})$ 
8  if isempty( $v$ ) then
9       $v = \textcircled{c}$ 
10 end if
11  $V_n = \{V \setminus v\} \cup \textcircled{c}$ 
12 for all  $\mathbf{z} \in Z$  do
13     if  $v = \textcircled{c}$  and  $\mathbf{z} \in \{\emptyset, \#\}$  then
14         continue
15     end if
16      $Z_n = \{Z \setminus \mathbf{z}\} \cup \{\emptyset, \#\}$ 
17      $e = (v, \mathbf{z})$ 
18     EnumerateMatchings( $V_n, Z_n, E \cup e, l(E) \cdot \text{LUT}(e)$ )
19     if  $v = \textcircled{c}$  then
20         break
21     end if
22 end for
```




Abbildung 3.7: Vollständiger Hypothesengraph für $|V|=2$ Objekte und eine aufgezeichnete Messung $|Z|=1$. Die Pfade von der Wurzel zum vierten, siebten und fünften Blattknoten von oben entsprechen den Beispielzuordnungen aus Abbildung 3.6.

die Summe der Likelihoods der Zuordnungen gespeichert werden, die die Kante enthalten, die durch diese Tabellenposition repräsentiert ist (Tabelle 3.3). Die Aufzählung aller Zuordnungen wird mit dem rekursiven Algorithmus 1 (Seite 68) durchgeführt. Er wird initial mit den Parametern $V = \{1, \dots, n, \textcircled{c}\}$, $Z = \{1, \dots, m, \emptyset, \neq\}$, $E = \{\}$ und $l(E) = 1$ aufgerufen. Der Algorithmus 1 ist eine Tiefensuche im JIPDA-Assoziationsbaum (Abbildung 3.7). Jede gültige Zuordnung E , und damit jede mögliche Konjunktion von Elementarereignissen, ist im Assoziationsbaum durch einen Pfad von der Wurzel zu einem der Blattknoten repräsentiert. Jeder Knoten des Assoziationsbaumes entspricht einer Zuordnungskante. Nachdem Algorithmus 1 terminiert ist, ist die SUM-Tabelle (Tabelle 3.3) gefüllt. Mit Hilfe dieser Tabelle ist die Berechnung der a-posteriori Existenzwahrscheinlichkeit nach (3.112) und damit auch nach (3.99) sehr einfach. Für jedes Objekt ist die a-posteriori Existenzwahrscheinlichkeit gleich der Zeilensumme dieses Objektes in der Tabelle SUM ohne Beachtung der Nichtexistenz-Spalte geteilt durch die gesamte Zeilensumme des Objektes in SUM:

$$p_{k|k}^{\exists,v} = \frac{\sum_{k \in \{Z \setminus \neq\}} \text{SUM}(v, k)}{\sum_{k \in Z} \text{SUM}(v, k)}. \quad (3.113)$$

Da für diese Berechnung der Existenz-Innovation die Kanten-Likelihoods verwendet werden, und diese wiederum auf die prädierten Objektzustände zurückgreifen, liegt hier ein zweiter Kopplungspunkt der beiden Markov-Ketten vor.

In der Zustandsinnovation werden die Assoziationsgewichte β_{vj} (3.101) und β_{v0} (3.102) benötigt, die sich ebenfalls mit der Tabelle SUM berechnen lassen. Die Gewichte entsprechen

jeweils dem zur Assoziationskante korrespondierenden Tabellenelement in SUM, geteilt durch die Zeilensumme des beteiligten Objektes unter Ausschluss der Nichtexistenzspalte:

$$\beta_{vj} = \frac{\text{SUM}(v, j)}{\sum_{k \in \{Z \setminus \# \}} \text{SUM}(v, k)}. \quad (3.114)$$

Zur Berechnung der Assoziationsgewichte und damit zur Berechnung der Zustandsinnovation werden ebenfalls die Kanten-Likelihoods verwendet, die ihrerseits die prädizierten Existenzwahrscheinlichkeiten enthalten. Daher erfolgt eine weitere Kopplung der Markov-Ketten von der Existenzprädiktion zur Zustandsinnovation.

3.3.6 Komplexitätsbetrachtungen

Die Speicherplatzkomplexität der JIPDA-Filterung ist maßgeblich durch die Größe der Tabellen SUM und LUT bestimmt, also im Wesentlichen durch $2mn$. Für die folgenden Betrachtungen wird ein uniformes Zeit-Komplexitätsmaß verwendet. Dabei werden die Kosten der elementaren skalaren Operationen wie Addition und Multiplikation einheitlich mit dem Kostenwert Eins angesetzt.

Die Prädiktion der MMBV-Wissensbasis erfolgt für jedes Objekt separat. Daher liegt die MMBV-Prädiktion in der Komplexitätsklasse der linearen Funktionen in der Anzahl der Objekte $O(n)$.

Für die MMBV-Innovation müssen die JIPDA-Innovationsgleichungen (3.99), (3.104) und (3.105) für jedes Objekt berechnet werden. Daher hat auch die Innovationskomplexität einen linearen Anteil in der Anzahl der Objekte im Umfeldmodell. Zusätzlich wird jedoch für die Assoziationsgewichte (3.101), (3.102) und die a-posteriori Existenzwahrscheinlichkeit (3.99) eine Aufzählung aller Zuordnungen (Konjunktionen) benötigt. Hier kommt die kombinatorische Natur des Zuordnungsproblems zum Tragen. Die Anzahl der Zuordnungen entspricht der Anzahl der Blattknoten des vollständigen Assoziationsgraphen (Abbildung 3.7). Mit dieser Kenntnis kann zunächst eine obere Schranke für die Anzahl der zu berechnenden Zuordnungs-Likelihoods angegeben werden. Die Tiefe des Assoziationsbaumes ist durch die Anzahl der Objekte im Umfeldmodell $n = |V|$ zuzüglich eines Elementes für den Falschalarmgenerator gegeben. Der Verzweigungsgrad entspricht der Kardinalität der Messmenge $m = |Z|$ zuzüglich den zwei Spezialelementen für die Nichtexistenz und die Fehldetektion. Da aufgrund der Regeln für gültige Zuordnungen (Seite 65) nicht immer alle Verzweigungsmöglichkeiten realisiert werden können, ergibt sich aus der Anzahl der Blätter des vollständigen Baumes zunächst eine obere Schranke für die Zeitkomplexität $f_{jipda-inno}$ der JIPDA-Innovation (Standard Landau-Symbolik [79]):

$$f_{jipda-inno}(m, n) \in o((n+1)^{m+2}). \quad (3.115)$$

Eine präzisere Abschätzung lässt sich aus der Analyse der disjunktiven Normalform der Normierungskonstante des a-posteriori MMBV-WGF (3.96) ableiten. Die Anzahl der Konjunktionen ist durch die drei geschachtelten Summationen bestimmt. Die erste Summe addiert über alle Möglichkeiten, die Teilmenge der Falschalarme C aus der Messmenge Z zu bilden. Für den Fall, dass mehr Messungen m als Objekte n im Umfeldmodell vorliegen, müssen mindestens $m - n$ Messungen Falschalarme sein, da kein explizites Geburtsmodell hinterlegt wurde. Zur

Berechnung der Anzahl der Summanden N_C der ersten Summe aus (3.96) wird über alle zulässigen Kardinalitäten $c = |C|$ der Falschalarmmenge und über alle Möglichkeiten summiert, diese c Elemente ohne Beachtung der Reihenfolge aus Z auszuwählen (Kombinationen ohne Wiederholung):

$$N_C(m, n) = \sum_{c=\max(0, m-n)}^m \binom{m}{c}. \quad (3.116)$$

Durch die zweite Summe innerhalb von (3.96) werden alle Möglichkeiten aufsummiert, den $m - c$ verbliebenen „True-Positive“-Messungen, genau $m - c$ Elemente der Objekthypothesenmenge V mit $n = |V|$ unter Beachtung der Reihenfolge zuzuordnen (Datenassoziation). Diese Elemente bilden die Menge der detektierten und existierenden Objekte DO^* . Die Anzahl der Möglichkeiten N_{DO^*} ergibt sich zu (Variationen ohne Wiederholung):

$$N_{DO^*}(m, n, c) = \binom{n}{m-c} \cdot (m-c)! \quad (3.117)$$

Final muss in der dritten Summe von (3.96) über alle Möglichkeiten summiert werden, die Menge der nicht den Messungen zugeordneten Objekthypothesen $V \setminus DO^*$ in die Menge der existierenden aber nicht detektierten Objekte FN und die Menge der tatsächlich nicht existierenden Objekte $TN = V \setminus (FN \uplus DO^*)$ zu zerlegen. Als Fehlalarmmenge FN kommt die gesamte Potenzmenge der verbliebenen Objekte in Betracht. Mithin ist die Anzahl der Summanden der innersten Summe N_{FN} :

$$N_{FN}(m, n, c) = \sum_{l=0}^{n-m+c} \binom{n-m+c}{l} = 2^{n-m+c}. \quad (3.118)$$

Aufgrund der geschachtelten Summation in (3.96) ist die Anzahl der zulässigen Zuordnungen N_E in Abhängigkeit der Anzahl der Messungen und Objekte gleich dem Produkt der Anzahlen von Summanden der drei Summen in (3.96):

$$N_E(m, n) = \sum_{c=\max(0, m-n)}^m \binom{m}{c} \binom{n}{m-c} (m-c)! \cdot 2^{n-m+c}. \quad (3.119)$$

Damit gilt auch für die Zeitkomplexität:

$$f_{jipda-inno}(m, n) \in O \left(\sum_{c=\max(0, m-n)}^m \binom{m}{c} \binom{n}{m-c} (m-c)! \cdot 2^{n-m+c} \right). \quad (3.120)$$

Dass $N_E(m, n)$ bereits durch eine Exponentialfunktion in m für die „Worst-Case“-Komplexität leicht nach unten abgeschätzt werden kann, ist durch den Term $(m-c)!$ im Summand für $c = 0$ und die Stirling-Formel (2.95) ersichtlich. Die JIPDA-Innovation ist daher nicht effizient im Sinne der Komplexitätstheorie berechenbar, d.h. die Laufzeit ist nicht durch ein Polynom in der Eingabelänge, hier m und n , beschränkt. Eine Vorstellung von der kombinatorischen Explosion der Zuordnungsalternativen gibt Tabelle 3.4.

Für die obigen Untersuchungen wurde angenommen, dass der zeitliche Ressourcenverbrauch im Wesentlichen durch die Anzahl der Eintragungen in die Tabelle SUM (Zeile 3 in Algorithmus

Tabelle 3.4: Anzahl der gültigen Zuordnungen $N_E(m, n)$

n	m	2	10	15
3		44	1.388	4.178
8		5.888	49.079.936	1.385.397.376
12		188.416	49.775.865.856	10.730.032.423.936

1) verursacht wird. Legt man die Anzahl der Rekursionen im JIPDA-Baum (Abbildung 3.7) für die Zeitkomplexität des Algorithmus zu Grunde, muss die Gesamtzahl der Knoten anstatt der Anzahl der Blattknoten betrachtet werden.

Aufwandsreduzierung durch Hypothesenverwurf

Die vollständige Anzahl N_E der Hypothesen kann keinesfalls in einem fahrzeuggebundenen echtzeitfähigen Umgebungserfassungssystem durchmustert werden, da laut Tabelle 3.4 bereits bei 15 Messungen und 12 Objekten die gigantische Anzahl von 10 Billionen Zuordnungshypothesen aufzuzählen wäre. Allerdings ist diese Hypothesenanzahl nur eine Konsequenz aus der Tatsache, dass die Normalverteilung des Innovationsresiduums an keiner Stelle des Messraumes den Funktionswert Null aufweist. Dies ist gleichbedeutend mit einer nicht verschwindenden Restwahrscheinlichkeit, dass sehr weit voneinander entfernte Objekte und Messungen trotzdem korrespondieren.

Ein Großteil der Hypothesen stellt daher keine „echten“ Mehrdeutigkeiten dar, da deren Assoziationswahrscheinlichkeiten Λ (3.85) bereits nahezu Null sind. In der Praxis ist es ausreichend, sich auf die Auflösung realer Mehrdeutigkeiten zu beschränken, das heißt nur Zuordnungsalternativen zuzulassen, deren Elementarereignisse alle signifikant von Null verschiedene Likelihoods beitragen. Im Hypothesenbaum (Abbildung 3.7) entspricht die Likelihood einer Zuordnung $l(E)$ der Likelihood eines Pfades von der Wurzel zum Blattknoten. Diese Pfad-Likelihood ist nach (3.107) gleich dem Produkt der Knoten-Likelihoods $l(e)$ entlang dieses Pfades. Wenn daher ein Knoten im Assoziationsbaum die Likelihood Null aufweist, ist die Likelihood aller Pfade, die durch den Unterbaum hinter diesem Knoten repräsentiert sind, ebenfalls Null.

Eine Strategie zum Hypothesenverwurf besteht darin, die rekursive Tiefensuche zwischen Zeile 17 und 18 in Algorithmus 1 abubrechen, sobald die Assoziationsresiduen einer Detektionskante ein Konfidenzniveau von $\varrho\sigma$ überschreiten (engl. „Gating“). Diese Vorgehensweise entspricht der Verwendung sogenannter „gesockelter“ Normalverteilungen $\mathcal{N}_{\varrho\sigma}$ mit dem „Gating“-Parameter ϱ für die Assoziationswahrscheinlichkeit:

$$A_i^j = \mathcal{N}_{\varrho\sigma} = \begin{cases} \mathcal{N}(\gamma^{ij}, \mathbf{0}, \mathbf{S}^{ij}) \cdot \chi^2(\varrho^2, \dim(\mathbf{z}))^{-1} & \text{für } (\gamma^{ij})^T (\mathbf{S}^{ij})^{-1} \gamma^{ij} \leq \varrho^2 \\ 0 & \text{sonst.} \end{cases} \quad (3.121)$$

Die bei $\varrho\sigma$ abgeschnittene Normalverteilung (Abbildung 3.8) integriert sich zu $\chi^2(\varrho^2, \dim(\mathbf{z}))$ statt zu Eins. Zur Erfüllung des Kolmogorov-Axioms (2.4) wird die abgeschnittene Normalverteilung mit diesem Integral renormiert.




Abbildung 3.8: Nutzung „gesockelter“ Normalverteilungen $\mathcal{N}_{\rho\sigma}$ zur Approximation des Assoziationsproblems. Die ursprüngliche Normalverteilung $\mathcal{N}$ (gestrichelt, grau) wird bei $\rho\sigma$ abgeschnitten (im Bild: $\rho = 2$) und um das abgeschnittene Volumen erhöht (schwarz). Zusätzlich ist die Gleichverteilung $\mathcal{U}_{\rho\sigma}$ im Volumen des $\rho\sigma$ -Hyperellipsoids dargestellt.

Wird der Ereignishorizont der akzeptierten Residuen vom gesamten Zustandsraum wie beschrieben auf die $\rho\sigma$ -Hyperellipsoiden der Innovationskovarianzen beschränkt, muss diese Beschränkung auch für die räumlichen Falschalarmwahrscheinlichkeiten durchgeführt werden, indem die in (3.109) verwendete Gleichverteilung auf dem gesamten Messraum ebenfalls auf die $\rho\sigma$ -Hyperellipsoiden V_ρ^i beschränkt wird.

$$f_c(\mathbf{z}^j) = \mathcal{U}_{\rho\sigma} = \left| \bigcup_{i: (\boldsymbol{\gamma}^{ij})^T (\mathbf{S}^{ij})^{-1} \boldsymbol{\gamma}^{ij} \leq \rho^2} V_\rho^i : \mathbf{z} \in V_\rho^i \Leftrightarrow (\mathbf{z} - h(\hat{\mathbf{x}}^v))^T (\mathbf{S}^{ij})^{-1} (\mathbf{z} - h(\hat{\mathbf{x}}^v)) \leq \rho^2 \right|^{-1} \quad (3.122)$$

$$\approx \left(\pi^{\frac{1}{2} \dim(\mathbf{z})} \cdot \Gamma \left(1 + \frac{1}{2} \dim(\mathbf{z}) \right)^{-1} \rho^{\dim(\mathbf{z})} \sum_{i: (\boldsymbol{\gamma}^{ij})^T (\mathbf{S}^{ij})^{-1} \boldsymbol{\gamma}^{ij} \leq \rho^2} \sqrt{\det \mathbf{S}^{ij}} \right)^{-1}. \quad (3.123)$$

Die Approximation in (3.123) für das Volumen der Vereinigung aller $\rho\sigma$ -Hyperellipsoiden, in denen $\mathbf{z}^j$ enthalten ist, vernachlässigt mögliche Überlappungen durch einfache Summation der Einzelvolumina der Assoziationsstore:

$$|V_\rho^i| = \pi^{\frac{1}{2} \dim(\mathbf{z})} \cdot \Gamma \left(1 + \frac{1}{2} \dim(\mathbf{z}) \right)^{-1} \rho^{\dim(\mathbf{z})} \sqrt{\det \mathbf{S}^{ij}}. \quad (3.124)$$

Genauere aber aufwändigere Approximationen finden sich beispielsweise in [66].

Von der enormen theoretischen Hypothesenvielfalt bleibt durch Anwendung des beschriebenen Approximationsverfahrens bei realen Sensordaten eine signifikant geringere Anzahl wahrscheinlicher Zuordnungen bestehen. Eine Quantifizierung dieser Aussage erfolgt in Abschnitt 5.2, Seiten 158 ff.

3.3.7 Zustandsschätzer für eine Multiobjekt-Multi-Bernoulli-Wissensbasis

Wenn die Ergebnisse des JIPDA-Verfahrens an nachfolgende Module weitergeben werden sollen, bestehen zwei verschiedene Möglichkeiten. Wenn das Folgesystem in der Lage ist, die probabilistische Natur der Wissensbasis direkt weiter zu verarbeiten, müssen bezüglich der Objektexistenz und des Objektzustandes keine Schätzverfahren angewendet werden. Solche Nachfolgesysteme sind beispielsweise die Situationsanalyse oder die Darstellung der erkannten Objekte in einem Kamerabild. Im letzten Fall können die Existenzwahrscheinlichkeiten unmittelbar auf die Helligkeit bzw. umgekehrt auf die Transparenz der Objekthervorhebungen angewendet werden. Die Zustandsunsicherheiten können direkt die räumliche Schärfe der Objekthervorhebungen bestimmen. Diese Strategie ist zum Beispiel in [21] für Nachtsichtsysteme beschrieben.

Sind die Nachfolgesysteme wie beispielsweise ACC-Regler nicht in der Lage, Existenz- und/oder Zustandsunsicherheiten zu verarbeiten, so müssen für beide Unsicherheitskomponenten Schätzwerte berechnet werden. Für die Existenzwahrscheinlichkeit muss dazu eine Konfidenzschwelle ε angegeben werden, so dass Objekte im Umfeldmodell dann an das Folgesystem ausgegeben werden, wenn ihre Existenzwahrscheinlichkeit größer als $1 - \varepsilon$ ist.

Verlassen reale Objekte den Überwachungsbereich oder sind Objektrepräsentationen aufgrund von Falschalarmen im Umfeldmodell aufgesetzt worden, so müssen diese regelmäßig entfernt werden, damit der Speicherplatzbedarf des Umfeldmodells nicht kontinuierlich wächst. Das Verwerfen einer Objektrepräsentation kann beispielsweise erfolgen, wenn die Existenzwahrscheinlichkeit unter den Wert ε gesunken ist. Hier bleibt festzuhalten, dass der Eingriff in die Wissensbasis durch das Entfernen oder Hinzufügen von Objektrepräsentationen mit sehr geringen Existenzwahrscheinlichkeiten keine signifikante Änderung der Wissensbasis zur Folge hat, da diese gewissermaßen eine Mischverteilung mit den Existenzwahrscheinlichkeiten als Gewichtungsfaktoren ist (3.40).

3.3.8 Implikationen für eine generische Sensorfusionsarchitektur

Aus dem in den vorherigen Abschnitten vorgestellten Verfahren resultiert die in Abbildung 3.9 (Seite 76) vorgeschlagene Fusionsarchitektur. In dieser Architektur übernehmen die Automobilzulieferer die sensorische Hardwareentwicklung und implementieren die Rohsignalverarbeitung und die Objektbildung im Sensormodul. In der Objektbildung werden Messwerte $\mathbf{z}_j$ und deren Messunsicherheiten $\mathbf{R}_j$ zum Beispiel mit den Verfahren aus Abschnitt 2.3.1 aus den Rohdaten extrahiert.

Die Bestimmung der Messfehlerkovarianz

Neben einer physikalischen Modellierung der einzelnen Fehlerquellen im Messsystem und einer Fehlerpropagation auf den finalen Messwert kann auch eine empirische Abschätzung der Messunsicherheiten mit Hilfe von hochgenauen Referenzdaten für eine repräsentative Stichprobe erfolgen. Dazu wird die empirische Kovarianzmatrix der Messabweichung des Sensors zu den

$j = 1..m$ hochgenauen Referenzwerten $\mathbf{z}_{k,j}^R$ eines jeden Zeitschrittes k der Referenzdatenbank berechnet:

$$\mathbf{R}_{emp} = E\{(\mathbf{z} - \mathbf{z}^R)(\mathbf{z} - \mathbf{z}^R)^T\}. \quad (3.125)$$

Ist diese Messfehlerkovarianzmatrix nicht stationär, kann sie auch für jeweils eine Partition des Messraumes separat bestimmt werden. Die entsprechende Messunsicherheit wird dann in Abhängigkeit der Messung $\mathbf{z}$ ausgegeben. Ein derartiges Vorgehen ist zum Beispiel für Distanzsensoren mit erhöhter Winkelgenauigkeit im zentralen Erfassungsbereich im Vergleich zu den Randbereichen sinnvoll. Eventuell sind die Messunsicherheiten auch von Umgebungstemperaturen (z.B. Ferninfrarot-Sensorik), der Geschwindigkeit des Sensorfahrzeugs, der Tag- oder Nachtzeit und anderen Einflüssen abhängig. Die Angabe eines messwertindividuellen Fehlermaßes $\mathbf{R}$ auf der Objektdatenschnittstelle erlaubt eine Behandlung derartiger Abhängigkeiten.

Bedeutung und Bestimmung der sensorischen Falschalarmwahrscheinlichkeit

Neben dem Messwert und seiner Unsicherheit liegt für jede der $j = 1..m$ Messungen zusätzlich die messwertindividuelle Falschalarmwahrscheinlichkeit p_j^F auf der Objektdatenschnittstelle. Diese Größe ist streng frequentistisch zu interpretieren. Hat die Falschalarmwahrscheinlichkeit beispielsweise den Wert 0.3, so bedeutet dies, dass es sich in 30% der Fälle, in denen der Sensor exakt die aktuell für das Objekt gemessenen Merkmalswerte (Abschnitt 2.3.1) aufgezeichnet hat, in Realität um Falschalarme handelt. Umgekehrt handelt es sich bei Messungen mit diesen sensorischen Merkmalen in 70% der Fälle um real existierende, beobachtbare und relevante Objekte. Die Falschalarmwahrscheinlichkeit ist damit die auf die aktuell gemessenen Merkmalswerte bedingte Rückschlusswahrscheinlichkeit (2.17) des Falschalarmfalls.

Die Initialisierungskommunikation

Zusätzlich zur Objektbildung müssen die Sensormodule ihre extrinsischen Lageparameter zum Fahrzeug und ihre intrinsischen Parameter, wie zum Beispiel Brennweiten und Halbwertsbreiten, mindestens vorhalten, optimalerweise aber selbständig während der Fahrt gleitend neu bestimmen. Diese Parameter bestimmen im Wesentlichen die Messfunktion h (2.15). Letztlich muss der Sensor noch eine möglicherweise zustandsabhängige Detektionswahrscheinlichkeit $p^D(\mathbf{x})$ angeben. Diese Größe beschreibt frequentistisch den Fehldetektionsprozess, also wie häufig reale Objekte in Abhängigkeit von ihrem Zustand während der Objektbildung keine Messung $\mathbf{z}$ erzeugen. Dieser Parameter des Messmodells kann ebenfalls empirisch aus einer vorklassifizierten Stichprobe ermittelt werden.

Die Fehldetektionswahrscheinlichkeitsfunktion wird initial an das zentrale Fusionssteuergerät übertragen. Für die Messfunktion bestehen zwei Möglichkeiten. Entweder transformieren die Sensoren die Messwerte selbst anhand des Messmodells h in den Zustandsraum und verzichten auf dessen Kommunikation oder sie übertragen die Messwerte und das Messmodell an das Fusionssteuergerät, das dann seinerseits die Koordinatentransformationen zwischen Mess- und Zustandsraum vornimmt. Die praktikablere erste Methode ist zunächst nur dann möglich, wenn die Messfunktion h invertierbar ist. Dass diese Methode jedoch auch bei nicht invertierbaren Messfunktionen angewendet werden kann, wird in Nachfolgearbeiten gezeigt werden.




Abbildung 3.9: Aufgabenverteilung in einer generischen Sensorfusionsarchitektur. Neben der sensorischen Hardwareentwicklung liegt das „Know-How“ der Zulieferer bei der Signalverarbeitung und Objektextraktion sowie der intrinsischen und extrinsischen Sensorkalibrierung. Die Existenzunsicherheiten werden in Form von Falschalarmwahrscheinlichkeiten an das zentrale Fusions- und Funktionssteuergerät übermittelt, auf dem die Automobilhersteller die Sensordatenfusion, die Datenassoziation, die Objektverfolgung und die Funktionen implementieren.

Uhrensynchronisation

Neben dem Austausch der aktuellen Messdaten und der Initialisierungsdaten kommt dem Kommunikationsnetzwerk eine weitere wesentliche Aufgabe zu. Es ist dafür verantwortlich, die Uhren der einzelnen Sensoren und des zentralen Fusionssteuergerätes zu synchronisieren. Dadurch ist gewährleistet, dass jedes Sensormodul seine Daten zum Messzeitpunkt mit Zeitstempeln versehen kann, die relativ zur netzwerkglobalen Referenzzeit erzeugt wurden. Durch derartige globale Zeitstempel können Unsicherheiten über die Latenzen der sensorinternen Datenverarbeitung, der Datenübertragung und Unsicherheiten über die Streuung des Empfangszeitstempels im Fusionssteuergerät komplett eliminiert werden. Diese Uhrensynchronisation ermöglicht sogar die Synchronisierung der Aufnahmezeitpunkte mehrerer Sensoren ohne zusätzliche Triggerleitungen, wenn sich die Sensoren über die Kommunikationsschnittstelle auf ein gemeinsames Aufnahmezeitraaster bezüglich der globalen Referenzuhr einigen. Die „FlexRay“-Technologie bietet beispielsweise die technischen Voraussetzungen für diese Anforderung.

Aufmerksamkeitssteuerung

Optional kann das Fusionssteuergerät auch die Prädiktionen des Objektmodells an die Sensormodule kommunizieren [126]. Dadurch entfallen Direktverbindungen zwischen den Sensoren zur Aufmerksamkeitssteuerung. Anhand der Messdaten des aufmerksamkeitssteuernden Sensors werden vielmehr Objektrepräsentationen im Umfeldmodell aufgesetzt, aus denen dann Messwertprädiktionen für den aufmerksamkeitsgesteuerten Sensor berechnet werden. Dieser nutzt dann die Messwertprädiktionen als Suchbereiche.

Das zentrale Fusionssteuergerät

Auf dem zentralen Fusionssteuergerät implementieren die Automobilhersteller die Sensordatenfusion bestehend aus der JIPDA-Datenassoziation und Objektverfolgung sowie der Schätzwertbildung für die Objektzustände und deren Existenz. Auf diesen Daten basieren dann die Assistenzfunktionen, die im gleichen Steuergerät realisiert werden können.

Ein Vorteil des in den vorhergehenden Abschnitten vorgestellten JIPDA-Verfahrens ist die Auflösung der Existenzunsicherheiten ohne das in Abschnitt 2.3.4 vorgestellte Regelwerk. Die Verwendung von Existenzwahrscheinlichkeiten ermöglicht eine Objektverwaltung, für die die Art und Weise der Berechnung dieser Existenzwahrscheinlichkeiten und die dafür verwendeten Informationsquellen nicht mehr relevant sind. Diese Eigenschaft ermöglicht überhaupt erst eine sensorunabhängige Fusionsrecheneinheit, da die üblicherweise in klassischen Architekturen verwendeten Objektverwaltungsregeln des Typus: „*Das Objekt ist verifiziert, wenn es mindestens fünf mal von einem Radar gesehen wurde und keine zwei sukzessiven Radar-Messausfälle aufweist und mindestens drei mal von einer Kamera detektiert wurde und ...*“ nicht mehr benötigt werden.

3.3.9 Diskussion, Kritik und Erweiterungsvorschläge

Das JIPDA-Verfahren verschiebt alle Entscheidungen an das Ende der Signalverarbeitungskette, die in der klassischen Architektur an den Modulschnittstellen getroffen werden (Abbildung 2.1, Seite 24). Dadurch können diese zentralisiert ausschließlich im Fusions- und Funktionssteuergerät und eventuell sogar funktionsabhängig getroffen werden. Die Verlässlichkeit dieser Entscheidungen hängt vom Informationsgehalt der Wissensbasis ab, auf deren Grundlage sie getroffen werden. Dieser Informationsgehalt ist wiederum durch die Auswahl und Anordnung der beitragenden Sensoren und durch die Genauigkeit der verwendeten Prozessmodelle für Zustand und Existenz bestimmt. Hier bieten sich wettbewerbsdifferenzierende Gestaltungsmöglichkeiten für die Automobilhersteller.

Trotz der aufwändigen Herleitung des JIPDA-Verfahrens aus der FISST-Theorie ergeben sich kompakte und graphentheoretisch interpretierbare Filtergleichungen, die das herkömmliche Kalman-Filter um eine Existenzschätzung erweitern (Abbildung 3.5, Seite 65). Bestehende und getestete Kalman-Filter-Implementierungen können somit nachträglich zum JIPDA-Verfahren aufgewertet werden, ohne dabei die verwendeten Modelle und Parameter verwerfen zu müssen.

Das JIPDA-Verfahren degeneriert zu dem aus der Literatur bekannten JPDA-Verfahren, wenn für die Objekte keine explizite Existenzwahrscheinlichkeit modelliert wird, also $p_v^\exists = 1, \forall v$ gilt. Dadurch wird die Nichtexistenzkante (Tabelle 3.1, Seite 66) für Objekte im Umfeldmodell während der Assoziation nicht berücksichtigt. Das JPDA-Filter beinhaltet deshalb gewissermaßen eine implizite Unfehlbarkeitsannahme, da der Fall von fälschlicherweise durch Falschalarme initialisierten Objektrepräsentationen nicht modelliert ist.

Obwohl das JIPDA-Filter hier für den linearen gaußschen Fall abgeleitet wurde (JIPDA-KF), lässt sich die Markov-Kette der Zustandsunsicherheit durch jede Implementierung der bayesschen Zustandsschätzung (Abschnitt 2.2, Seite 15) realisieren. Speziell sind die Filtervarianten JIPDA-EKF, JIPDA-UKF, JIPDA-PF, JIPDA-GM-EKF, JIPDA-GM-UKF in vollständiger Analogie herleitbar.

Fragmentierte Messdaten und mangelnde Trennfähigkeit des Sensors

Innerhalb des standardisierten FISST-Messmodells (Seite 45) und dem daraus resultierenden Regelwerk für zulässige Zuordnungen der graphentheoretischen Interpretation (Seite 65) wurden „Eins-zu-Eins“ Assoziationen zwischen Objekten und Messungen vorausgesetzt.

Diese Voraussetzung ist immer dann verletzt, wenn die Sensoren fragmentierte Messdaten aufzeichnen. So zerfällt die Objektkontur eines Laserscanners oft in mehrere Zusammenhangskomponenten, die aber alle der gleichen Objektrepräsentation zuzuordnen sind. Ein Radarsensor liefert im Nahbereich analog mehrere Echos verschiedener Reflektionszentren auf der Objektkontour. Umgekehrt kann ein Radarsensor aber auch nur eine Messung für mehrere Objekte liefern, wenn aufgrund der Abmessungen der Auflösungszellen keine Trennfähigkeit mehr gegeben ist. In den ersteren Fällen müssen für eine gültige Zuordnung im Sinne von Abschnitt 3.3.5, Seite 64, Objektknoten mit einem Knotengrad größer Eins zugelassen werden. Im zweiten Fall der mangelnden Trennfähigkeit muss für die Indexknoten der Messungen ein Knotengrad größer Eins zulässig sein. Können beide Effekte gleichzeitig auftreten, dürfen alle Indexknoten

positive nicht verschwindende Knotengrade haben.

Die ohnehin enorme kombinatorische Komplexität des Zuordnungsproblems vergrößert sich in diesen Fällen nochmals signifikant. Deshalb werden Approximationsverfahren zur schnellen Durchmusterung des Assoziationsbaumes hier weiter an Bedeutung gewinnen. Zumindest Sensoren mit fragmentierten Sensordaten können aber auch an das „Eins-zu-Eins“-Assoziationsverfahren angebunden werden, wenn sie in der sensorinternen Signalverarbeitung eine Objektbildung, das heißt eine Gruppierung der Fragmente zu Objektmessungen vornehmen. Diese Gruppierung stellt allerdings eine frühe Zuordnungsentscheidung dar, die erst durch die oben beschriebenen erweiterten Assoziationsbäume eliminiert werden kann.

Statistische Abhängigkeiten der Messgrößen

Für das parallele oder sequenzielle Einbringen von Messdaten mehrerer Sensoren wird in der bayesschen Filtertheorie die statistische Unabhängigkeit der Messfehler gefordert (Abschnitt 2.1.4 „Sensorfusion“, Seite 13). Diese Unabhängigkeit des Messfehlers muss analog auch für die Markov-Kette zur Existenzschätzung gelten. Dies wiederum bedeutet, dass die Fehl- und Falschdetektionsprozesse zweier fusionierter Sensoren gegenseitig unkorreliert sein müssen. Eine derartige Annahme kann bei heterogener Sensorfusion mit stark verschiedenen Messprinzipien in verschiedenen Frequenzbereichen zumindest nicht sofort widerlegt werden. Für die redundante Sensorfusion mit identischer Messtechnik ist diese Annahme aber definitiv inadäquat. Hier muss das vorgestellte Verfahren in Zukunft so erweitert werden, dass die Abhängigkeit nicht nur berücksichtigt, sondern eventuell auch während des Betriebs automatisch bestimmt wird. Hier wäre beispielsweise die Ermittlung von (Existenz-)Messfehlerstatistiken der Sensoren in anhand simpler Primärmerkmale einfach zu entscheidenden Situationen denkbar. Die so z.B. in Form der gegenseitigen Information gemessenen statistischen Abhängigkeiten könnten dann auf die schwierigen Fälle verallgemeinert werden.

Statistische Abhängigkeiten der Objekte im Prozessmodell

Das zur Ableitung der JIPDA-Gleichungen verwendete standardisierte FISST-Prozessmodell (Seite 44) nimmt eine gegenseitig statistisch unabhängige Transition der Objekte im Zustandsraum und im existenzbezogenen Ereignishorizont an. Diese Annahme führt zur kompakten Produktschreibweise der MMBV (3.38), die die geschlossene Filterrekursion erst ermöglicht. Im realen Straßenverkehr sind die Bewegungen der Verkehrsteilnehmer aber im höchsten Maße voneinander abhängig, da ja die Zielvorstellung ein synchronisierter unfallfreier Verkehrsfluss ist. Jeder Fahrer wird daher versuchen, anderen Verkehrsteilnehmern auszuweichen. Die Unabhängigkeitsannahme würde eher der Situation entsprechen, dass alle Verkehrsteilnehmer mit verbundenen Augen und ohne Gehör fahren. Die Fragestellung, wie derartige Abhängigkeiten zwischen den Objekten in das Prozessmodell einfließen können, so dass weiterhin effizient lösbare Filtergleichungen entstehen, bleibt Gegenstand zukünftiger Verfahrenserweiterungen.

Explizite Objektklassifikation

Das binäre Existenzmodell des JIPDA-Verfahrens unterscheidet zwischen nicht existenten, nicht beobachtbaren oder nicht relevanten und beobachtbaren, relevanten und existierenden Objekten. Bei manchen Funktionen reicht das Wissen über die Existenz eines relevanten Objektes jedoch nicht aus, sondern es wird eine explizite Klassifikation des Verkehrsteilnehmers z.B. als PKW, LKW, Fußgänger oder Motorrad benötigt. Für derartige Anforderungen muss statt des binären Ereignishorizontes ein endlicher diskreter Ereignishorizont verwendet werden, der neben der Nichtexistenz alle relevanten Objektklassen enthält.

Das Erscheinen neuer Objekte

Letztlich enthält das vorgestellte Verfahren kein explizites Objektgeburtsmodell. Vielmehr muss sichergestellt werden, dass für jede Messung, die signifikant weit von bereits existierenden Objekthypothesen aufgezeichnet wurde, eine neue Objekthypothese mit sehr geringer Existenzwahrscheinlichkeit aufgesetzt wird. Diese Operation verändert die Wissensbasis nicht wesentlich, da man die MMBV-Repräsentation auch als Produkt von unendlich vielen Objekthypothesen schreiben kann:

$$G[h] = \prod_{v=1}^{|V|} 1 - p_v^\exists + p_v^\exists \langle h, \mathcal{N}_v \rangle = \prod_{v=1}^{\infty} 1 - p_v^\exists + p_v^\exists \langle h, \mathcal{N}_v \rangle \text{ mit } p_v^\exists = 0 \Leftrightarrow v > |V|. \quad (3.126)$$

Die MMBV hält also eigentlich unendlich viele Objekthypothesen vor, bei denen nur die $|V|$ explizit abgespeicherten Hypothesen von Null verschiedene Existenzwahrscheinlichkeiten aufweisen. Die nicht abgespeicherten Hypothesen tragen durch den Term $1 - p_v^\exists$ mit $p_v^\exists = 0$ jeweils mit dem Faktor Eins zum Produkt bei. Wenn daher eine Objektrepräsentation mit verschwindender Existenzwahrscheinlichkeit explizit in die Wissensbasis aufgenommen wird, verändert sich die Wissensbasis nicht. Um dieses manuelle Initialisieren von Objekthypothesen zu umgehen, wurde in der Literatur [58] eine explizite Modellierung der Objektentstehung im Prozessmodell vorgeschlagen (siehe Abbildung 3.1, Seite 44). Hier werden poissonverteilte neue Objekthypothesen in jedem Prädiktionsschritt in den Zustandsraum gestreut. Diese Hypothesen können dann während der Innovation Assoziationen zu Messungen erhalten. Der Nachteil dieser Vorgehensweise liegt in ihrer Ineffizienz, da man nahezu den gesamten Messraum mit neuen Hypothesen ausfüllen muss, damit die Messungen neu erschienener Objekte eine Korrespondenz im Umfeldmodell finden.

Es kommt daher für echtzeitfähige Systeme nur eine datengetriebene Initialisierung neuer Objekte in Frage. Eine Möglichkeit, die auf der graphentheoretischen Interpretation beruht, ist die Einführung eines weiteren Spezialelementes B (engl. „Birth“) in die Indexknotenmenge der Objektrepräsentationen [126]. Dadurch können in einer gültigen Zuordnung zusätzlich Kanten von B zu einer Messung erzeugt werden. Es wird im Anschluss eine neue Objekthypothese an der Stelle der Messung aufgesetzt, deren initiale Existenzwahrscheinlichkeit der über alle Konjunktionen ausmarginalisierten a-posteriori Wahrscheinlichkeit der Geburtskante entspricht. Die Ableitung dieser Vorgehensweise aus der FISST-Theorie bleibt Untersuchungsgegenstand für Folgearbeiten.

Die Zeitkomplexität der JIPDA-Innovation

Trotz der in Abschnitt 3.3.6 vorgestellten Aufwandsreduzierung bleibt die Laufzeit der JIPDA-Innovation exponentiell in der Anzahl der Messungen und Objekte. In der Literatur [69] wurden sequentielle Monte-Carlo Verfahren als nichtdeterministische Polynomialzeitapproximation des Problems vorgeschlagen. Als weitere polynomielle Approximationsmöglichkeit könnte die sogenannte „Cheap Joint Probabilistic Data Association“ [27, 35] auf das JIPDA-Filter übertragen werden.

Kapitel 4

Ein multisensorielles Prototypsystem zur Fahrzeugumfelderfassung für ACC-Funktionen

Abstandsregeltempomaten (engl. „Adaptive Cruise Control“, ACC) sind in der Lage, die im Tempomat eingestellte Geschwindigkeit zu drosseln, wenn das Sensorfahrzeug auf ein langsames Fahrzeug aufschließt, und einen ebenfalls einstellbaren Abstand zu diesem Fahrzeug zu halten, bis bei freier Fahrbahn wieder automatisch auf das ursprünglich eingestellte Tempo beschleunigt werden kann. Im Gegensatz zur ersten Generation sind neuere Systeme in der Lage, das Tempo bis zum vollständigen Stillstand zu reduzieren (engl. „Follow-to-Stop“) und dem zähflüssigen Verkehr mit teilweisem Stillstand (engl. „Stop-and-Go“) zu folgen. Zukünftige Generationen sollen ein situationsadaptives Verhalten zeigen, dass mit einer vorausschauenden Fahrweise des Menschen vergleichbar ist. Dazu gehört unter Anderem eine Intentionserkennung für die anderen Verkehrsteilnehmer, um eventuelle Spurwechselmanöver und Einschervorgänge vorherzusagen und damit unnötige Beschleunigungs- und Bremsvorgänge des Sensorfahrzeugs zu vermeiden. Aufgrund der seltener notwendigen Fahrerinteraktion im Vergleich zu aktuellen Systemen ist dadurch eine Steigerung der Kundenakzeptanz zu erwarten. Weiterhin konnte gezeigt werden, dass sich die Effizienz neuartiger Antriebsstrategien wie die Hybridisierung, die Brennstoffzelle und die kurzfristige Energiespeicherung in Kondensatoren dann steigern lässt, wenn sich während der Fahrt die zukünftigen dynamischen Belastungsanforderungen an das Antriebssystem vorhersagen lassen [15]. Mithin ist es durchaus denkbar, dass Umfelderfassungssysteme in Zukunft neben ihrer Komfort- und Sicherheitsfunktion auch einen Beitrag zur Reduzierung von Kraftstoffverbrauch und CO₂-Emissionen leisten.

Das unterlegte Umgebungserfassungssystem für die beschriebenen Funktionen muss in der Lage sein, mehrere Objekte gleichzeitig in Echtzeit zu verfolgen, mehrere Fahrspuren zu überwachen und präzise Zustandsschätzungen zu berechnen, um aussagekräftige Prädiktionen des Umfeldmodells in die Zukunft zu ermöglichen. Zudem muss es stehende und bewegte Fahrzeuge in großen Distanzen robust erkennen, um auch bei hohen Geschwindigkeiten frühzeitig reagieren zu können. Die dafür eingesetzte Sensorik wird im nächsten Abschnitt vorgestellt.

4.1 Versuchsaufbau und Spezifikation der Umfeldsensorik

Heute am Markt verfügbare Abstandsregeltempomaten sind entweder mit frequenzmodulierten Dauerstrichradaren (engl. „Frequency Modulated Continuous Wave“, FMCW) oder Impulsradaren ausgestattet und nur in der Oberklasse und der oberen Mittelklasse verfügbar. Während der Markteinführung dieser Assistenzsysteme wurde in der Forschung und der Zulieferindustrie an der alternativen Lidar-Technologie gearbeitet, deren Serieneinführung vor einigen Jahren ebenfalls erfolgt ist. Statische Lidar-Sensoren besitzen eine Anordnung von parallel abstrahlenden Laserdioden, deren Licht durch eine Linse in die verschiedenen Winkelrichtungen abgelenkt wird. Die eingehenden Reflektionen werden durch eine zweite Linse auf eine einzige Empfängerdiode gelenkt, die sich die Sendedioden im Zeitmultiplexverfahren teilen. Aus der Zeitdifferenz zwischen gesendetem und empfangenem Signal lässt sich analog zum Impulsradar die Distanz zum Hindernis über die Lichtgeschwindigkeit ermitteln (engl. „Time of Flight“, TOF). Ein derartiger Aufbau ohne bewegliche Teile ist die preiswerteste Realisierungsmöglichkeit. Aufwändigere Konstruktionen besitzen jeweils nur eine Sende- und Empfangsdiode. Ein mechanisch verstellbarer Spiegel lenkt die ein- und ausgehenden Lichtpulse in die verschiedenen Winkelrichtungen ab. Mit dieser Methode können größere Erfassungsbereiche und kleinere Winkelschritte im Vergleich zur statischen Variante realisiert werden. Im Folgenden werden die Vor- und Nachteile des Einsatzes von Radar- und Lidar-Technologie für die Fahrzeugumfelderfassung gegenübergestellt.

4.1.1 Ein qualitativer Vergleich zwischen Radar- und Lidarsensoren

Lokalisierungsgenauigkeit und Trennfähigkeit: Bedingt durch die Wellenlängen im Millimeterbereich lassen sich bei Radarsensoren die Messkeulen nicht stark räumlich fokussieren, da die Antennengrößen durch die Einbaubeschränkungen am Fahrzeug limitiert sind. Demnach durchdringen sich trotz hoher azimuthaler Auflösungen benachbarte Messkeulen stark, so dass Objekte, die eigentlich in ihrer Ausdehnung auf den Raumwinkel eines Messkanals beschränkt sind, auch Echosignale auf vielen benachbarten Messkanälen erzeugen. Als Folge verwischen die Echosignale in Azimuthalrichtung, so dass eine präzise Lokalisierung erschwert wird. Dieser Effekt ist deutlich in Abbildung 4.10 (Seite 103) am direkt vorausfahrenden Fahrzeug ersichtlich. Weiterhin sind Radarsensoren aus demselben Grund ab einem bestimmten Punkt nicht mehr in der Lage, mehrere verschiedene nahe beieinander stehende Objekte von einem großen ausgedehnten Objekt zu unterscheiden. Im Gegensatz dazu bieten Lidar-Sensoren eine höhere Ortsauflösung, die derzeit bis zu $0,1^\circ$ in Winkelrichtung und 0,01 m in der gemessenen Distanz reicht. Damit ist es unter Anderem möglich, die Konturen ausgedehnter Objekte exakt zu vermessen. Außerdem lassen sich die Messkeulen aufgrund der viel kleineren Wellenlänge im Infrarotband exakt fokussieren, so dass sich die Messkanäle nicht gegenseitig beeinflussen und eine Trennung und Lokalisierung der Objekte im Rahmen der genannten Genauigkeiten möglich ist.

Geschwindigkeitsmessung: Durch den Doppler-Effekt sind Radarsensoren in der Lage, die Objektgeschwindigkeiten direkt aus der Frequenzverschiebung zu messen, während die Ge-

schwindigkeiten bei Lidar-Sensorik über die Zeitableitung der Positionsmessungen errechnet werden müssen und demnach lediglich phasenverschoben vorliegen. Diese Einschränkung kann bei Lidarsensoren durch erhöhte Abtastraten reduziert werden.

Horizontaler Erfassungsbereich: Für scannende Lidarsensoren wurde die Möglichkeit der Rundumsicht, d.h. ein Erfassungsbereich von 360° demonstriert. Bei bildgebenden Radarsensoren konnten Öffnungswinkel von 160° und mehr erreicht werden [60]. Es ist aber nur mit Radar-Sensorik möglich, den Mehrwegeausbreitungseffekt zu nutzen, um Objekte zu Vermessen, die nicht im direkten Sichtbereich des Sensors liegen. So können beispielsweise mehrere Fahrzeuge vor dem Sensorfahrzeug erfasst werden, obwohl sie eigentlich in direkter Sichtlinie vom vorausfahrenden Fahrzeug verdeckt sind (Abbildung 4.10, Seite 103). Gerade für die Längsführung im stockenden Verkehr und bei Notbremssystemen ist diese Zusatzinformation äußerst nützlich.

Nick- und Wankwinkeltoleranz: Die mangelnde räumliche Fokussierbarkeit der Radarsensorik ist in Bezug auf den Fahrzeugnickwinkel ein positives Merkmal. Im Gegensatz dazu ist es mit Lidarsensoren offenbar aufgrund der Leistungsbeschränkung der Sendedioden zur Erhaltung der Augensicherheit nicht gelungen, genug Raumwinkel auszuleuchten, um mit Radarsensoren vergleichbare vertikale Öffnungswinkel zu erzeugen. Zurzeit werden Lidar-Sensoren mit vertikalen Öffnungswinkeln von 3° bis 4° angeboten. In dieser Hinsicht besteht bei stark hügeligen Fahrbahnen oder starken Beschleunigungs- und Bremsphasen mit Lidar-Sensorik immer die Möglichkeit, unter oder über die anderen Verkehrsteilnehmer hinweg zu messen. Es wird daher an Verfahren zur automatischen Nickwinkelkompensation für Lidar-Sensoren zum Beispiel mit Hilfe der Beschleunigungsmessung aus der Eigenbewegungsschätzung (Abschnitt 4.4, Seiten 112 ff.) gearbeitet.

Verschmutzungstoleranz: Im Gegensatz zu Radarsensoren muss Lidar-Sensorik mit einem automatischen Reinigungssystem kombiniert werden, da Verschmutzungen der Optik zum Totalausfall führen können. Dies wird entweder durch Integration in das Scheinwerfergehäuse und Mitnutzung der Scheinwerfer-Reinigungsanlage, durch Anbringung hinter der Windschutzscheibe oder durch eine separate Reinigungsdüse erreicht. Radarsensoren können problemlos leichte Schmutz-, Nässe- oder Schneebedeckungen tolerieren. Erst bei massiven Vereisungen treten ebenfalls signifikante Funktionseinschränkungen auf.

Herstellkosten: Optoelektronik ist im Vergleich zu Hochfrequenztechnik bei vergleichbaren Stückzahlen preiswerter am Markt verfügbar. Hinzu kommt, dass sich Lidar-Sensoren zumindest in der statischen Ausführung ohne individuelle intrinsische Kalibrierung fertigen lassen. Im Gegensatz dazu muss bei Radarsensorik für jeden Sensor ein Antennendiagramm ausgemessen und im Sensor hinterlegt werden, um eine genauere Objektlokalisierung durch Keulen-Interpolation zu ermöglichen.

Wettertoleranz: Die Toleranz gegenüber Wettereinflüssen wie Regen, Nebel und Schnee wird durch die atmosphärische Dämpfung des Messsignals bestimmt, die stark von der Wellenlänge abhängt. Die Dämpfung elektromagnetischer Wellen ist im Millimeterbereich (Radar, 77 GHz) und im Nanometerbereich (Lidar, 905 nm) bei Regen annähernd vergleichbar. Bei Nebel zeigt Tabelle 4.1 jedoch für Lidar-Sensoren eine Dämpfung, die auf der logarithmischen Dezibel-Skala um zwei Größenordnungen über der Dämpfung von Radar-Signalen liegt. Diese Tatsache führt bei Nebel zur Funktionsunfähigkeit bzw. zu drastischen Reduktionen der Erfas-

Tabelle 4.1: Atmosphärische Dämpfung bei verschiedenen Wettereinflüssen für Radar- und Lidar-Sensorik im Automobilbereich, Quelle: [45].

Sensor- Technologie	Nieselregen 0.25 mm/hr	sehr starker Regen 25 mm/hr	Nebel 0.1 g/m ³
Radar, 24 Ghz	0 dB/km	$7.9 \cdot 10^{-1}$ dB/km	$1.1 \cdot 10^{-2}$ dB/km
Radar, 77 Ghz	$1.4 \cdot 10^{-1}$ dB/km	$1.0 \cdot 10^1$ dB/km	$2.0 \cdot 10^{-1}$ dB/km
Lidar, 905 nm	$3.2 \cdot 10^{-1}$ dB/km	$7.9 \cdot 10^0$ dB/km	$1.6 \cdot 10^2$ dB/km

sungsreichweiten. Sicherheitsfunktionen, wie z.B. die Warnung vor Stauenden im Nebel, sind daher voraussichtlich nicht mit augensicherer Lidar-Technologie realisierbar.

Objektklassifikation: Die erste Generation der Umgebungserfassungssysteme verwendete die Objektgeschwindigkeit als exklusives Merkmal zur Auswahl von relevanten Regelzielen. Diese zunächst robuste Strategie verhindert allerdings den Einsatz für Funktionen zur Stau-Warnung und den Einsatz im stockenden und teilweise stehenden Verkehr (engl. „Stop-and-Go“). Um dennoch Verkehrsteilnehmer von Hintergrundobjekten auch ohne dynamische Merkmale unterscheiden zu können, wurden Ansätze zur Musterklassifikation auf die räumlichen Amplituden- und Dopplersignalverteilungen über den Objekten für Radar- und Lidarsensoren angewendet. Für hochauflösende scannende Lidarsensoren konnten vielversprechende Ergebnisse durch Merkmale wie Objektabmessungen und Objektformen erzielt werden [102]. Für Radar- und Lidarsensoren mit geringer Ortsauflösung ist die Objektklassifikationsleistung mangels diskriminierender Merkmale eher moderat. Heute am Markt verfügbare ACC-Systeme sind auf eine „Follow-to-Stop-and-Go“-Funktion beschränkt, weil die Objektgeschwindigkeit über Grund das einzige robuste Detektionsmerkmal ist und eine Spurzuordnung in großen Distanzen durch die moderate laterale Messgenauigkeit erschwert wird. Eine Regelung auf Objekte in großen Distanzen, die noch nie als bewegt beobachtet wurden, ist dagegen nicht möglich [67].

4.1.2 Heterogene Sensordatenfusion

Diese Gegenüberstellung zeigt, dass keine der beiden Sensortechnologien der anderen prinzipiell überlegen ist. Vielmehr würden sich durchaus Synergieeffekte aus einer Kombination ergeben, die aber erst bei einem Massenmarkt für Fahrerassistenzsysteme wirtschaftlich zu produzieren wäre. Stattdessen wird unter Hinnahme der eventuellen Funktionseinschränkungen bei schlechtem Wetter der Einsatz von Lidar-Technologie in der unteren Mittelklasse und bei Kleinwagen erwogen und in der Oberklasse weiterhin die Radar-Technologie verwendet.

Für die verbesserte Nachtsicht durch Infrarotbilder wurden Kamerasysteme in das Fahrzeug integriert. Danach folgten Funktionen wie die Spurverlassenswarnung und die Verkehrszeichen-erkennung. Möglicherweise wird die automatische Querführung in Zukunft ebenfalls mit Videosensorik realisiert. Die Videokamera entfaltet ihre Stärken in der Objektklassifikation durch Auswertung von Formen, Farben und Texturen und in der lateralen und vertikalen Objektlokalisation. Die longitudinale Positionsinformation ist dagegen aufgrund des Fahrzeugnickens und der variablen Größen der Objekte sehr gering.




Abbildung 4.1: Einbaupositionen und Sichtbereiche des Lidar-Sensors und der Videokamera.

Wie in vielen anderen Arbeiten (z.B. [38, 39, 86, 99, 102]) wird auch in dieser Arbeit ein Fusionssystem mit einer Videokamera und einem Abstandssensor verwendet, dass die genannten Vorteile beider Sensoren kombiniert. Da die laterale Positionsbestimmung von Fahrzeugen sehr genau durch die Kamera erfolgen kann, ist die Verwendung eines Distanzsensors mit eingeschränkter azimuthaler Winkelauflösung ausreichend. Es kommt ein statischer Lidar-Sensor mit den in Tabelle 4.2 angegebenen Spezifikationen zum Einsatz, weil zum einen die verbesserte Schlechtwetterfähigkeit eines Radarsensors für den Videosensor nicht gegeben ist und die oben aufgeführten Synergieeffekte aber nur bei kooperativer Sensorfusion nutzbar sind. Zum anderen bietet der Lidar-Sensor einen attraktiven Kostenvorteil für das Gesamtsystem.

Tabelle 4.2: Spezifikationen des Mehrkanal-Lidarsensors. Quelle: [2]

Erfassungsreichweite	200 m
horizontaler Öffnungswinkel	3°
vertikaler Öffnungswinkel	16°
Winkelauflösung	1°
Distanzauflösung	0,1 m
Temperaturbereich	−40°C... + 85°C
Gewicht	410 g

Der Lidar-Sensor ist in den Kühlergrill integriert und die VGA-Videokamera wurde oben mittig hinter der Windschutzscheibe angebracht (Abbildung 4.1). Die Kamera ist mit einem Telefokusobjektiv ausgestattet (18mm) und besitzt einen horizontalen Öffnungswinkel von circa 20°.

4.2 Sensorkalibrierung und Sensorsynchronisation

Die Sensoren innerhalb eines Fusionssystems müssen zeitlich und räumlich in Beziehung gesetzt werden, um ihre Daten gemeinsam verarbeiten zu können. Dazu ist es bei verschiedenen Messfrequenzen der Sensoren notwendig, die Zeitstempel relativ zur gleichen globalen Uhr zu erzeugen. Diese Methode hat aber den Nachteil, dass das Umfeldmodell für jeden Sensor auf den individuellen Messzeitpunkt prädiert werden muss, um die aktuellen Messdaten einzubringen. Im Gegensatz dazu genügt eine globale Prädiktion des Umfeldmodells für alle Sensoren, wenn diese in Hardware auf die gleiche Messfrequenz und die gleichen Messzeitpunkte synchronisiert




Abbildung 4.2: Definition der Koordinatensysteme am Sensorfahrzeug: KK - Kamerakoordinaten, FK - Fahrzeugkoordinaten, LK - Lidarkoordinaten.

sind [40]. Speziell bei Filterverfahren mit numerischen Approximationen, wie zum Beispiel das Partikel- und das Unscented-Kalman-Filter, und bei einer hohen Anzahl zu verfolgender Objekte, ist die Prädiktion des Umfeldmodells eine teure Operation. Das hier vorgestellte Fusionssystem synchronisiert daher die Sensoren in Hardware, indem die Messzeitpunkte des Lidar-Sensors die Aufnahme eines Videobildes über den externen Triggereingang der Kamera bestimmen. Das Auslösesignal wird zusätzlich von einem praktisch latenzfreien Echtzeitrechner zur Generierung der Zeitstempel verwendet, dessen interne Uhr mit einem angeschlossenen GPS-Empfänger auf die UTC-Zeit synchronisiert wurde. Die Messdaten der fahrzeugeigenen ESP-Sensorik erhalten auf gleiche Weise einen UTC-Zeitstempel. In Serienfahrzeugen können diese Voraussetzungen durch die Verwendung einer FlexRay-Vernetzung geschaffen werden.

Für die Ermittlung der räumlichen Lagebeziehungen zwischen Sensoren und Fahrzeug werden zunächst die verwendeten Koordinatensysteme definiert und es wird ein Kalibrierverfahren für die Kombination von Video- und Lidar-Sensor vorgestellt. Im Gegensatz zu dem in [106] vorgestellten Ansatz für Laserscanner in Robotikanwendungen, verwendet das vorgestellte Verfahren ausschließlich die Daten des Videosensors zur Kreuzkalibrierung. Dies schließt zum einen die Ungenauigkeiten aus Messfehlern des Abstandssensors aus und ermöglicht andererseits auch die Kalibrierung von Abstandssensoren mit geringer Ortsauflösung, die sehr große und damit unpraktikable Kalibrierobjekte benötigen würden. Aus diesem Grund kommt auch das für automotive Anforderungen entworfene Verfahren für Laserscanner und Videokameras in [39] für die hier betrachtete Sensorik nicht in Frage. Zudem ist die nachfolgende Kalibriermethode erstmals in der Lage, extrinsische und intrinsische Kalibrierparameter gleichzeitig zu bestimmen. In der Serienfertigung werden die Kalibrierverfahren nicht wie in der Forschung und Vorentwicklung zur eigentlichen Ermittlung von Kalibrierparametern eingesetzt werden, sondern vielmehr zur Prüfung und Sicherung von Toleranzen, die dem Sensor-Zulieferer spezifiziert wurden.

4.2.1 Koordinatendefinitionen

Die Lage der verschiedenen Koordinatensysteme am Fahrzeug zeigt Abbildung 4.2. Die Lagebeziehung zwischen zwei Koordinatensystemen wird durch die homogene Transformationsmatrix

$\mathbf{T} \in \mathbb{R}^{4 \times 4}$ angegeben.

$$\mathbf{T} = \begin{bmatrix} \mathbf{R} & \mathbf{t} \\ \mathbf{0} & 1 \end{bmatrix} \quad (4.1)$$

Dabei ist $\mathbf{R}$ die von den drei Verdrehungen um die Koordinatenachsen $(\alpha_x, \alpha_y, \alpha_z)$ abhängige Rotationsmatrix [100] und $\mathbf{t} = [t_x, t_y, t_z]^T$ der Translationsvektor zwischen den Koordinatenursprüngen. Die Richtung der Transformation wird im Folgenden durch das Pfeil-Symbol angegeben. Für die Transformation von kartesischen Lidarkoordinaten in Fahrzeugkoordinaten und ihre Umkehrung werden beispielsweise die Matrizen

$$\mathbf{T}^{\text{LK} \rightarrow \text{FK}} = (\mathbf{T}^{\text{FK} \rightarrow \text{LK}})^{-1} \quad (4.2)$$

verwendet. Abweichend davon sind lediglich die nichtlineare Transformationsvorschrift von polaren Lidarkoordinaten (LP) in kartesische Lidarkoordinaten (LK), die der Standarddefinition von Polarkoordinaten entspricht und die Transformation von Kamerakoordinaten in homogene Bildkoordinaten mit der Projektionsmatrix:

$$\mathbf{T}^{\text{KK} \rightarrow \text{BK}} = \begin{bmatrix} c_i & -f_i & 0 & 0 \\ c_j & 0 & -f_j & 0 \\ 1 & 0 & 0 & 0 \end{bmatrix}. \quad (4.3)$$

Der Ursprung des Bildkoordinatensystems liegt in der linken oberen Ecke. Von diesem Punkt verlaufen die i-Achse horizontal nach rechts und die j-Achse vertikal nach unten. Das optische Zentrum (auch Hauptpunkt, Abbildung 4.4) ist durch das Bildkoordinatenpaar $C = (c_i, c_j)$ bestimmt und die Brennweiten in Horizontal- und Vertikalrichtung (f_i, f_j) sind direkt in Pixel angegeben.

4.2.2 Aufbau und Verfahren zur Lage- und Orientierungsbestimmung der Sensoren am Fahrzeug

Die Aufgabe des Kalibrierverfahrens ist die automatische Bestimmung der Lagebeziehungen $\mathbf{T}^{\text{LK} \rightarrow \text{FK}}$ und $\mathbf{T}^{\text{KK} \rightarrow \text{FK}}$. Die Lagebeziehung zwischen den Sensoren lässt sich dann aus diesen Matrizen ableiten:

$$\mathbf{T}^{\text{LK} \rightarrow \text{KK}} = (\mathbf{T}^{\text{KK} \rightarrow \text{FK}})^{-1} \mathbf{T}^{\text{LK} \rightarrow \text{FK}}. \quad (4.4)$$

Neben der vollständigen Automatisierbarkeit sollte das Verfahren möglichst wenige und einfache Kalibrierobjekte verwenden, um einen Einsatz in der Serienproduktion am Band zu ermöglichen. Im Folgenden wird davon ausgegangen, dass beide Sensoren vorjustiert sind und lediglich die exakten Lageparameter bestimmt werden sollen. Das Kalibrierverfahren kann aber auch zur Ermittlung einer Ist-Anbaulage verwendet werden, die dann mit einer Soll-Einbaulage der Sensoren verglichen wird, um eventuelle Korrekturen vorzunehmen. In diesem Fall erzeugt der Kalibrierprozess ein Fehlermaß als Rückkopplung für den Justageprozess. Zusätzlich existiert auch die Variante, bei der die Kamera nicht am Fahrzeug, sondern an der Kalibriervorrichtung verbaut ist, um ausschließlich die Einbaulage des Distanzsensors zum Fahrzeug zu ermitteln oder zu überprüfen [131].



Abbildung 4.3: Eine Wand mit einem Schachbrettmuster dient als Kalibrierobjekt. Die Ecken des Schachbrettmusters lassen sich im Videobild automatisch extrahieren (links). Im Differenzbild zwischen zwei Aufnahmen mit ein- und ausgeschaltetem Lidar-Sensor treten die Belichtungsbereiche der Messkeulen hervor (rechts). Die schwarzen Kreise kennzeichnen die automatisch extrahierten Schwerpunkte der Belichtungsflecken.

Messdatenerfassung zur Kreuzkalibrierung der Video-Lidar Kombination

Als Kalibrierobjekt kommt eine einzige planare Fläche zum Einsatz, die zum Beispiel eine Wand (Abbildung 4.3/links) ist. Diese Wand ist im oberen Teil mit einem Schachbrettmuster ausgestattet und sie ist im unteren Teil so beschaffen, dass die Emissionen des Lidar-Sensors im Nahinfrarot-Band gut und möglichst diffus reflektiert werden. Weiterhin ist das Schachbrett so an der Kalibrierwand angebracht, dass die horizontalen Begrenzungslinien der Quadrate parallel zur Bodenebene verlaufen und die unterste Begrenzungslinie einen bekannten Abstand l^M zum Boden hat.

Treffen die Emissionen des Lidar auf die Kalibrierfläche, so lassen sich die Belichtungsbereiche der einzelnen Messkeulen mit der Videokamera erfassen, da Videosensoren in CCD und CMOS Technologie immer eine Restempfindlichkeit im Nahinfrarotband aufweisen (Abbildung 4.3/rechts). Ist diese Empfindlichkeit oder die Sendeleistung des Lidar sehr gering oder der Abstand zur Kalibrierfläche sehr hoch, kann die Erfassung der Reflektionsflecken durch die temporäre Anbringung eines NIR-Bandpassfilters an der Kamera verbessert werden. Eine zweite praktikablere Methode ist das Differenzbildverfahren bei ein- und ausgeschaltetem Lidar-Sensor zur Unterdrückung der Hintergrundausleuchtung. Weiterhin ist es vorteilhaft, die Reflektionsflecken über mehrere Bilder zu akkumulieren um ein eventuelles Bildrauschen bei niedrigen Intensitäten zu unterdrücken und um eine Abbildung jedes Messkanals bei scannenden Sensoren zu erhalten.

Die Kalibrierwand wird jetzt derart in den Sichtbereich der Kamera eingebracht, dass zumindest ein Großteil des Schachbrettmusters und ein Grossteil der Reflektionsflecken im Videobild sichtbar sind. Für diese Position des Kalibrierobjektes wird ein Videobild aufgezeichnet, in dem sowohl das Kalibriermuster als auch die Reflektionsflecken gut sichtbar sind. Ist dies aufgrund der Umstände nicht möglich, werden zwei Aufnahmen mit den jeweils nötigen Einstellungen für jede Komponente bei unveränderter Position des Kalibrierobjektes durchgeführt (Abbildung 4.3). Durch Korrelation aller Rotationsvarianten einer Eck-Schablone an allen Positionen im Videobild sind die Positionen der Schachbrett-Ecken $\mathbf{z}^{V,BK}$ automatisch extrahier-




Abbildung 4.4: Rückprojektion der Merkmalspunkte aus dem Bildkoordinatensystem in das dreidimensionale Kamerakoordinatensystem durch Schnitt des Projektionsstrahls mit der Ebene, die durch den Schachbrettmarker bestimmt ist.

bar ([47], Abbildung 4.3/links). Die Reflektionsflecken im Videobild lassen sich als Abbildung des Antennendiagramms entlang der Schnittebene zwischen Kalibrierwand und Emissionskeule des Sensors interpretieren. Wenn die einzelnen Flecken ausreichend separiert sind, lassen sich für jeden Messkanal Merkmale wie Mittelpunkt, horizontale und vertikale Halbwertsbreiten (-3 dB Grenzen) durch elementare Bildverarbeitungsoperationen ermitteln [124]. Sind die Reflektionsflecken nicht separierbar, wird ein Mischverteilungsmodell zum Beispiel mit dem EM-Algorithmus [19] in die Intensitätsverteilung eingepasst, um die Merkmale zu bestimmen. Bei Verwendung von gewichteten Normalverteilungen ergeben sich die Schwerpunkte dann aus den Mittelwerten der Komponenten und die Halbwertsbreiten lassen sich aus deren Kovarianzmatrizen ablesen [141]. Abbildung 4.3/rechts zeigt die extrahierten Schwerpunkte der Reflektionsflecken $\mathbf{z}^{L,BK}$ im Videobild.

Nach der Merkmalsextraktion wird die Lage und/oder Orientierung der Kalibrierwand zum Fahrzeug verändert. Dazu kann beispielsweise die Wand fest vor einem Produktionsband angebracht sein und die Bewegung des Fahrzeugs auf dem Band genutzt werden. Alternativ kann das Fahrzeug stehen und es wird die Wand verschoben. In der neuen Position wird der Datenaufnahmeprozess und die Merkmalsextraktion erneut durchgeführt. Die Datenerfassung ist nach $K \geq 2$ Wiederholungen dieses Prozesses mit verschiedenen Wandpositionen abgeschlossen.

Bestimmung der intrinsischen Kameraparameter

Das Kreuzkalibrierungsverfahren verwendet die intrinsische Kamerakalibrierung aus [11]. Dazu wird ein lokales Markerkoordinatensystem (MK) für das Schachbrettmuster definiert, dessen Ursprung in der linken oberen Schachbrettecke liegt (Abbildung 4.4). Die dreidimensionale Lage des Schachbretts zur Kamera ist durch die Transformationsmatrix

$$\mathbf{T}^{MK \rightarrow KK} = \mathbf{T}(t_x, t_y, t_z, \alpha_x, \alpha_y, \alpha_z) \quad (4.5)$$

gegeben. Weiterhin ist die Seitenlänge l der Quadrate im Kalibriermuster konstruktiv bekannt. Wenn das Kalibriermuster aus $M \times N$ Quadraten besteht, so ergeben sich die Markerkoordinaten der Eckpunkte zu:

$$\mathbf{x}_{m,n}^{\text{MK}} = [ml \quad nl \quad 0 \quad 1]^T, \quad m = 0..M, \quad n = 0..N. \quad (4.6)$$

Die intrinsischen Kameraparameter $\mathbf{p}^{\text{int}} = (c_i, c_j, f_i, f_j)$ und die extrinsischen Lageparameter $\mathbf{p}_k^{\text{ext}} = (t_x, t_y, t_z, \alpha_x, \alpha_y, \alpha_z)$ der K Aufnahmen des Schachbretts werden gleichzeitig durch eine Minimierung der summierten quadratischen Rückprojektionsfehler der Eckpunkte aller Aufnahmen in das Videobild bestimmt:

$$\begin{bmatrix} \mathbf{p}^{\text{int}} \\ \mathbf{p}_1^{\text{ext}} \\ \vdots \\ \mathbf{p}_K^{\text{ext}} \end{bmatrix}_{\text{opt}} = \underset{\mathbf{p}^{\text{int}}, \mathbf{p}_1^{\text{ext}} \dots \mathbf{p}_K^{\text{ext}}}{\text{argmin}} \sum_{k=1}^K \sum_{m=1}^M \sum_{n=1}^N \left| \mathbf{z}_{m,n,k}^{\text{V,BK}} - \hbar(\mathbf{T}^{\text{KK} \rightarrow \text{BK}} \mathbf{T}^{\text{MK} \rightarrow \text{KK}} \mathbf{x}_{m,n,k}^{\text{MK}}) \right|^2. \quad (4.7)$$

Der Operator $\hbar$ steht hier für die Renormierung der homogenen Bildkoordinaten:

$$\hbar([i \quad j \quad w]^T) = [i/w \quad j/w \quad 1]^T. \quad (4.8)$$

Bei einer für ACC-Funktionen verwendeten Telefokuslinse ist die Vernachlässigung der Linsenverzeichnungen zulässig. Die Verwendung des Kalibrierverfahrens für Objektive mit geringen Brennweiten erfordert zusätzlich noch eine Verzerrungskorrektur. Für das weitere Verfahren bleibt festzuhalten, dass sich die Lagen der Schachbrett-Marker in dreidimensionalen Kamerakoordinaten für jede Positionierung der Kalibrierwand mit Hilfe der intrinsischen Kamerakalibrierung rekonstruieren lassen. Dabei können die intrinsischen Parameter der Kamera entweder bekannt sein, oder sie können gleichzeitig mitbestimmt werden, wenn genügend Iterationen K durchgeführt werden.

Bestimmung der Lagebeziehung Kamera-Fahrzeug

Nach der Berechnung der Positionen der Schachbrett-Marker in dreidimensionalen Kamerakordinaten für alle Aufnahmen (Abbildung 4.5/a), wird eine Ebene in Eckpunkte in der untersten Reihe eines jeden Schachbretts eingepasst. Dies geschieht mit der Methode der kleinsten Fehlerquadrate unter Variation der Parameter der Ebenengleichung. Da die Anbringungshöhe des Schachbrett-Markers über dem Boden bekannt ist, wird die eingepasste Ebene um genau diesen Abstand in Normalenrichtung nach unten verschoben. Die resultierende Ebenengleichung beschreibt die Bodenebene in Kamerakordinaten (Abbildung 4.5/a). Durch die Kenntnis der Lage der Bodenebene im Kamerakordinatensystem sind die Einbauhöhe, der Nick- und der Wankwinkel der Kamera zum Fahrzeug bestimmt, wenn dieses auf der Bodenebene steht. Dies sind gerade die sensibelsten Parameter in der automatischen Bildverarbeitung. Die anderen beiden Translationsfreiheitsgrade werden vom vorgestellten Verfahren nicht bestimmt und müssen konstruktiv oder messtechnisch ermittelt werden.

Soll die beliebige Positionierbarkeit der Kalibrierwand erhalten bleiben, muss der Gierwinkel der Kamera zum Fahrzeug durch Justage festgelegt werden. Ist es allerdings möglich, zumindest zwei der Aufnahmen so vorzunehmen, dass das gleiche optische Merkmal in zwei verschiedenen Aufnahmen in dreidimensionalen Weltkoordinaten auf einer Geraden liegt, die parallel zur

x-Achse des Fahrzeugkoordinatensystems verläuft, dann lässt sich der Koordinateneinheitsvektor des Fahrzeugkoordinatensystems in x-Richtung aus den beiden 3D-Rekonstruktionen des Merkmals bestimmen. Dazu wird zunächst das Lot vom Ursprung des Kamerakoordinatensystems in die bestimmte Bodenebene gefällt. An den Durchstoßpunkt in der Bodenebene wird die Projektion des Differenzvektors der beiden korrespondierenden Merkmale als x-Achse des Fahrzeugkoordinatensystems angesetzt. Steht diese Möglichkeit nicht zur Verfügung, wird stattdessen die x-Achse des Kamerakoordinatensystems in die Bodenebene projiziert und um den durch Justage bestimmten Gierwinkel innerhalb der Bodenebene gedreht. Die z-Achse des FKS entspricht dem Normalenvektor der Bodenebene und die y-Achse ergibt sich durch das Kreuzprodukt von x- und z-Achse. Innerhalb der Bodenebene wird jetzt der Ursprung des FKS noch um die beiden extern ermittelten Translationsfreiheitsgrade in x- und y- Richtung des FKS verschoben. Das auf diese Weise ermittelte FKS ist in Abbildung 4.5/a dargestellt.

Die geforderte Konstellation zur automatischen Gierwinkelbestimmung zwischen Kamera und Fahrzeug kann am Band einfach dadurch sichergestellt werden, dass sich das Kalibrierobjekt fix an einer Position vor oder neben dem Band befindet. Wenn das Fahrzeug das Kalibrierobjekt dann geradlinig passiert, bewegt sich dieses automatisch parallel zur x-Achse des Fahrzeugkoordinatensystems.

Bestimmung der Lagebeziehung zwischen Lidar und Kamera


Die Lagebeziehungen zwischen den Sensoren müssen für eine frühe Messdatenfusion in hoher Genauigkeit zur Verfügung stehen. Deshalb ermittelt das vorgestellte Verfahren erstmalig alle sechs Freiheitsgrade dieser Lagebeziehung vollautomatisch. Dazu müssen zunächst die dreidimensionalen Positionen der in jeder der $k = 1..K$ Aufnahmen extrahierten Lidar-Merkmale für jede Messkeule $i = 1..N$, in diesem Fall die Schwerpunkte der Reflektionsflecken $\mathbf{z}_{i,k}^{\text{L,BK}}$, im Kamerakoordinatensystem ermittelt werden. Unter Annahme eines Lochkameramodells definiert jede Bildposition einen Projektionsstrahl vom Brennpunkt durch den Bildpunkt (Abbildung 4.4). Die Geradengleichung des Projektionsstrahls für den Bildpunkt (i, j) lautet in homogenen Kamerakoordinaten:

$$g : \mathbf{x}^g = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 1 \end{bmatrix} + \lambda_1 \begin{bmatrix} \frac{1}{2}(f_i + f_j) \\ c_i - i \\ c_j - j \\ 0 \end{bmatrix}. \quad (4.9)$$


Weiterhin ist die Ebenengleichung der Kalibrierwand in der k-ten Aufnahme ebenfalls in homogenen Kamerakoordinaten bekannt:

$$E : \mathbf{x}^E = \mathbf{T}_k^{\text{MK} \rightarrow \text{KK}} \left(\begin{bmatrix} 0 \\ 0 \\ 0 \\ 1 \end{bmatrix} + \lambda_2 \begin{bmatrix} 1 \\ 0 \\ 0 \\ 0 \end{bmatrix} + \lambda_3 \begin{bmatrix} 0 \\ 1 \\ 0 \\ 0 \end{bmatrix} \right). \quad (4.10)$$


Der durch Gleichsetzen $\mathbf{x}^g = \mathbf{x}^E$ ermittelte Schnittpunkt ist die dreidimensionale Rekonstruktion $\mathbf{z}_{i,k}^{\text{L,KK}}$ der Lidar-Merkmalposition im Bild $\mathbf{z}_{i,k}^{\text{L,BK}}$. Abbildung 4.5/b zeigt diese rekonstruierten 3D-Positionen als schwarze Kreise. In der Abbildung ist deutlich zu erkennen, wie sich



(a) Ermittlung der 3D-Schachbrettpositionen und Rekonstruktion der Bodenebene



(b) Rekonstruierte 3D-Positionen der Lidar-Merkmale und Lidar-Sensormodell vor der Optimierung



(c) Lagebeziehungen nach der Optimierung

Abbildung 4.5: Kreuzkalibrierung durch Einpassung des Lidar-Sensormodells in die gemessenen 3D-Positionen der Reflektionsflecken innerhalb der Sichtpyramide der Videokamera.

die Distanzen der Reflektionsflecken einer Aufnahme untereinander auf Grund des polaren Messprinzips mit zunehmendem Abstand von der Kamera vergrößern.

Der nächste Schritt ist die Aufstellung eines Sensormodells für den Lidar. Dazu wird der Ursprung des lokalen Lidarkoordinatensystems in den Linsenbrennpunkt des Sensors definiert. Im Folgenden ist weiterhin die Mittelachse einer Emissionskeule als diejenige Raumrichtung definiert, in der die größte Energiedichte innerhalb dieser Messkeule abgestrahlt wird. Die vollständigen intrinsischen Parameter des Abstandssensors beschreiben die Ausbreitungsrichtungen der N Mittelachsen (φ_i, ϑ_i) , $i = 1..N$ im Raum und deren horizontale und vertikale Halbwertsbreiten. Obwohl eine Bestimmung all dieser Parameter mit dem Verfahren möglich ist, wird das Modell in der beschriebenen Ausführungsvariante zusätzlich vereinfacht. Dabei wird angenommen, dass sich alle Keulenmittelachsen in der xy -Ebene des lokalen Sensorkoordinatensystems ausbreiten. Die Halbwertsbreiten werden nicht explizit kalibriert, sondern den Herstellerspezifikationen entnommen. Zusätzlich wird eine konstante Winkelschrittweite $\Delta\varphi$ zwischen allen Messkeulen modelliert. Damit ist $\Delta\varphi$ der einzige zu kalibrierende intrinsische Lidarparameter. Die extrinsischen Lidarparameter sind die drei Rotations- und die drei Translationsfreiheitsgrade, welche die Lagebeziehung des Lidarkoordinatensystems (Abbildung 4.2, Seite 88) zum Kamerakoordinatensystem beschreiben. Das Sensormodell besteht damit aus den $i = 1..N$ Keulenmittelachsen in homogenen Kamerakoordinaten, deren Geradengleichungen wie folgt lauten:

$$g_i : \mathbf{x} = \mathbf{T}^{\text{LK} \rightarrow \text{KK}} \left(\begin{bmatrix} 0 \\ 0 \\ 0 \\ 1 \end{bmatrix} + \lambda_4 \begin{bmatrix} \cos[\frac{1}{2}(-N-1) + i]\Delta\varphi \\ \sin[\frac{1}{2}(-N-1) + i]\Delta\varphi \\ 0 \\ 0 \end{bmatrix} \right). \quad (4.11)$$

Die extrinsischen und intrinsischen Parameter des Lidar-Sensors $(\mathbf{p}^{\text{L},\text{ext}}, \mathbf{p}^{\text{L},\text{int}})$, von denen das Sensormodell abhängt, werden durch eine Minimierung der summierten quadratischen perpendicularen Abstände $d(\cdot, \cdot)$ der Rückprojektionen der Lidar-Merkmale $\mathbf{z}_{i,k}^{\text{L},\text{KK}}$ zu den zugehörigen Keulenmittelachsen des Sensormodells bestimmt:

$$\begin{bmatrix} \mathbf{p}^{\text{L},\text{ext}} \\ \mathbf{p}^{\text{L},\text{int}} \end{bmatrix}_{\text{opt}} = \underset{\mathbf{p}^{\text{L},\text{ext}}, \mathbf{p}^{\text{L},\text{int}}}{\text{argmin}} \sum_{k=1}^K \sum_{i=1}^N d \left[\mathbf{z}_{i,k}^{\text{L},\text{KK}}, g_i(\mathbf{p}^{\text{L},\text{ext}}, \mathbf{p}^{\text{L},\text{int}}) \right]^2. \quad (4.12)$$

Die durch die trigonometrischen Funktionen innerhalb der Transformationsmatrix bedingte nichtlineare Optimierungsaufgabe wird durch iterative Methoden gelöst (z.B. Levenberg-Marquardt Algorithmus [49, 59]). Abbildung 4.5/b zeigt eine beliebige Initialisierung der extrinsischen und intrinsischen Lidarparameter und Abbildung 4.5/c visualisiert die kalibrierten Parameter. Für den verwendeten Sensor ist die Gültigkeit der Planaritätsannahme aller Emissionskeulen in der Seitenansicht (Abbildung 4.6/a) und die Gültigkeit der Annahme äquidistanter Winkelschritte zwischen den Messkeulen in der Draufsicht (Abbildung 4.6/b) auf die kalibrierten Lagebeziehungen ersichtlich.

4.2.3 Erweiterungen für Radarsensorik

Für die Kreuzkalibrierung von Video- und Lidar Sensoren konnte die direkte Erfassbarkeit des Antennendiagramms des Abstandssensors durch den Kamerasensor ausgenutzt werden. Da




Abbildung 4.6: Verschiedene Ansichten der kalibrierten Lagebeziehungen zwischen Videokamera und Lidar-Sensor.

diese Möglichkeit bei Radarsensoren nicht besteht, müssen die Messdaten des Radars selbst hinzugezogen werden. Als Kalibrierobjekt findet eine Platte mit einem Schachbrettmuster und einem Winkelreflektor Verwendung (Abbildung 4.7). Um das Antennendiagramm in Vertikalrichtung aufzunehmen, wird ein einzelnes Kalibrierobjekt mehrmals hintereinander oder werden mehrere Kalibrierobjekte gleichzeitig an verschiedenen Positionen vor dem Sensoraufbau vertikal durch das Sichtfeld der Kamera geführt, so dass immer ein Großteil des Schachbrettmusters im Kamerabild sichtbar ist. Dabei werden die Daten beider Sensoren aufgezeichnet. Da die Position des Reflektors am Kalibrierobjekt konstruktiv im Markerkoordinatensystem bekannt ist, können auch die 3D-Positionen des Reflektors im Kamerakoordinatensystem für jede Lage des Kalibrierobjektes über das Schachbrett rekonstruiert werden. Zusätzlich muss sichergestellt werden, dass das Echo des Kalibrierreflektors eindeutig in den Radardaten auffindbar ist. Aufgrund der beschriebenen moderaten Fokussierbarkeit der einzelnen Radar-Emissionskeulen, wird sich dieses Echo über mehrere Abstands- und Winkelzellen ausdehnen. Durch Einpassung einer gaußschen Glockenkurve in das ausgedehnte zum Reflektor korrespondierende Radar-Echo können der Azimutwinkel und die Amplitude des Maximums mit Subpixelgenauigkeit extrahiert werden. Damit werden für jede Position $n = 1..N$ des Kalibrierobjektes während der $m = 1..M$ vertikalen Durchläufe durch das Radar-Emissionsfeld die Kamerakoordinaten des




Abbildung 4.7: Das Kalibrierobjekt für die Radar-Video Kreuzkalibrierung ist eine ebene Platte mit einem Schachbrettmuster und einem Winkelreflektor.

Reflektors sowie dessen Radar-Azimuthwinkel und Radar-Amplitude messtechnisch ermittelt:

$$\mathbf{z}_{m,n}^V = [x^{\text{KK}} \ y^{\text{KK}} \ z^{\text{KK}} \ 1]^T, \quad \mathbf{z}_{m,n}^R = [A \ \varphi^{\text{RP}}]^T. \quad (4.13)$$

Eine Normierung der gemessenen Amplituden innerhalb jedes vertikalen Durchlaufs erspart eine explizite Modellierung der Dämpfung in Radialrichtung:

$$A_{m,n} = \frac{A_{m,n}}{A_{i,n}}, \quad i = \underset{j}{\operatorname{argmax}} A_{j,n}. \quad (4.14)$$

Als Optimierungskriterium für die Bestimmung der extrinsischen Lageparameter des Radarsensors zur Kamera wird jetzt gefordert, dass die gemessenen Azimuthwinkel der Reflektorechos mit denen des eingepassten Radarkoordinatensystems übereinstimmen und dass die gemessenen Amplituden eine symmetrische Verteilung in Elevationsrichtung des eingepassten lokalen Radarkoordinatensystems aufweisen. Dazu wird die Intensitätsverteilung des Radars in Elevationsrichtung unter Vernachlässigung von Nebenkeulen als normierte Glockenkurve

$$\mathcal{N}_n(\vartheta^{\text{RP}}, 0, \sigma_\vartheta^2) = \exp\left(-\frac{1}{2} \left[\frac{\vartheta^{\text{RP}}}{\sigma_\vartheta^2}\right]^2\right) \quad (4.15)$$

modelliert, so dass σ_ϑ der einzige kalibrierte intrinsische Radarparameter ist, aus dem sich die Halbwertsbreiten in Elevationsrichtung ableiten lassen. Die Parameterbestimmung für $\mathbf{p}^{\text{R},\text{ext}} = \mathbf{T}^{\text{KK} \rightarrow \text{RK}}$ und $\mathbf{p}^{\text{R},\text{int}} = \sigma_\vartheta$ lässt sich als Minimierung von Fehlerquadraten formulieren

$$\begin{bmatrix} \mathbf{p}^{\text{R},\text{ext}} \\ \mathbf{p}^{\text{R},\text{int}} \end{bmatrix}_{\text{opt}} = \underset{\mathbf{p}^{\text{R},\text{ext}}, \mathbf{p}^{\text{R},\text{int}}}{\operatorname{argmin}} \sum_{m=1}^M \sum_{n=1}^N \left| \mathbf{z}_{m,n}^R - \begin{bmatrix} \mathcal{N}_n(\vartheta^{\text{RP}}(\mathbf{p}^{\text{R},\text{ext}}, \mathbf{z}_{m,n}^V), 0, \sigma_\vartheta^2) \\ \varphi^{\text{RP}}(\mathbf{p}^{\text{R},\text{ext}}, \mathbf{z}_{m,n}^V) \end{bmatrix} \right|^2 \quad (4.16)$$

mit

$$\vartheta^{\text{RP}}(\mathbf{p}^{\text{R},\text{ext}}, \mathbf{z}_{m,n}^V) = \arctan \frac{z^{\text{RK}}}{\sqrt{(x^{\text{RK}})^2 + (y^{\text{RK}})^2}} \quad (4.17)$$

$$\varphi^{\text{RP}}(\mathbf{p}^{\text{R},\text{ext}}, \mathbf{z}_{m,n}^V) = \arctan \frac{y^{\text{RK}}}{x^{\text{RK}}} \quad (4.18)$$

$$[x^{\text{RK}} \ y^{\text{RK}} \ z^{\text{RK}} \ 1]^T = \mathbf{T}^{\text{KK} \rightarrow \text{RK}} \cdot \mathbf{z}_{m,n}^V. \quad (4.19)$$




Abbildung 4.8: Die Kreuzkalibrierung zwischen Video und Radar erfolgt durch Variation der extrinsischen Radarparameter bis eine symmetrische Verteilung der gemessenen Amplituden in Elevationsrichtung des polaren Radarkoordinatensystems erreicht ist. Die gemessenen (grau) und modellierten (schwarz) Amplituden sind vor (links) und nach (rechts) der Optimierung dargestellt.

Die Amplitudenkomponente des zur Kalibrierung verwendeten Abstandsmaßes ist in Abbildung 4.8 für eine beliebige Initialisierung der extrinsischen und intrinsischen Radarparameter und für die kalibrierten Parameter nach der Optimierung von (4.16) dargestellt. Dabei ist die Anwendbarkeit des Modells einer normierten Glockenkurve aus den Messwerten ersichtlich. Abbildung 4.9 visualisiert die kalibrierten Lagebeziehungen zwischen dem lokalen Kamerakoordinatensystem und dem Radarkoordinatensystem sowie die verwendeten Reflektormesspunkte und deren gemessene Amplituden.


4.2.4 Diskussion

Ein vollautomatisches bandtaugliches Kalibrier- und/oder Prüfverfahren für die extrinsischen Anbauparameter eines Lidar- oder Radar-Abstandssensors zu einer im Auto oder an der Kalibriervorrichtung verbauten Kamera wurde vorgestellt. Dabei stützt sich das Verfahren für den Lidar-Sensor ausschließlich auf die Kamerabilder. Zusammenfassend sind in Tabelle 4.3 die mit


Tabelle 4.3: Bestimmbare extrinsische Parameter

Lagebeziehung	t_x	t_y	t_z	α_x	α_y	α_z
Kamera-Fahrzeug	-	-	+	+	+	(+)
Kamera-Lidar	+	+	+	+	+	+
Kamera-Radar	+	+	+	+	+	+

dem gezeigten Verfahren bestimmbaren extrinsischen Parameter für die verschiedenen Sensor-kombinationen gezeigt. Dabei wird zwischen dem Funktionsnachweis mit dem tatsächlich implementierten Verfahren "+", der nicht implementierten aber offensichtlichen Bestimmbarkeit durch einfache Erweiterungen "(+)" und der eventuellen Bestimmbarkeit nur durch erhebliche



(a) Kalibrierte Lagebeziehungen Video-Radar



(b) Seitenansicht

Abbildung 4.9: Rekonstruktionen der Reflektor-Positionen mit Grauwertkodierung der Radar-Amplituden bei 8 vertikalen Durchläufen durch das Radar-Emissionsfeld sowie die aus der Kalibrierung resultierenden extrinsischen Lageparameter des Radarkoordinatensystems zur Kamera.

Veränderungen bzw. Weiterentwicklungen ”-” unterschieden. Tabelle 4.4 enthält die gleiche Auf-

Tabelle 4.4: Bestimmbare intrinsische Parameter der Abstandssensoren

Sensor	$\Delta\varphi/\varphi_{i,j}$	$\Delta\vartheta/\vartheta_{i,j}$	$w_{i,j}^\varphi$	$w_{i,j}^\vartheta$
Lidar	+	(+)	(+)	(+)
Radar	-	-	-	+

listung für die bestimmbaren intrinsischen Parameter der Abstandssensoren. Die Parameter $(\varphi_{i,j}, \vartheta_{i,j})$ stehen dabei für die individuellen Abstrahlrichtungen der einzelnen Keulenmittellachsen. Bei äquidistanter Modellierung werden diese durch die zwei Auflösungsparameter in

Azimuthal- und Elevationsrichtung $(\Delta\varphi, \Delta\vartheta)$ ersetzt. Die Werte $(w_{i,j}^\varphi, w_{i,j}^\vartheta)$ beschreiben die vertikalen und horizontalen Aufweitungen der einzelnen Emissionskeulen, zum Beispiel durch Angabe der Halbwertsbreiten.

Auch wenn die individuellen Aufweitungen und Abstrahlrichtungen der einzelnen Emissionskeulen nicht kalibriert werden, sondern statt dessen ein äquidistantes oder starres Emissionsmodell für den Abstandssensor verwendet wird, lassen sich die absoluten Werte der minimierten Fehlerfunktionen (4.12) und (4.16) zu Prüfzwecken als Maß für die Abweichung zum geforderten Modell verwenden, um fehlerhafte Sensoren mit ausgefallenen oder fehlgelenkten Emissionskeulen zu identifizieren.

Neben der Erweiterung für die bisher nicht bestimmbar Parameter stellt sich für Nachfolgearbeiten die Frage nach der Anwendbarkeit des Verfahrens für die nicht betrachteten Sensortechnologien wie Laserscanner und Impulsradare.

Da die Sensorkalibrierung nicht der Fokus dieser Arbeit ist, sondern diese nur eine Notwendigkeit für das Gesamtsystem darstellt, wird hier auf eine Genauigkeitsuntersuchung verzichtet. Zu deren Durchführung müssten zunächst die unsicheren Parameter im Kalibrierprozess identifiziert und quantifiziert werden. Mit der Fehlerfortpflanzungsrechnung würden im Anschluss die Auswirkungen auf die Kalibrierparameter bestimmt und für den ungünstigsten Fall summiert. Diese Vorgehensweise wurde in [39] für ein verwandtes Verfahren demonstriert.

Eine im Rahmen dieser Arbeit entwickelte weiter vereinfachte Variante des beschriebenen Verfahrens für die Video-Lidar-Kombination, die komplett ohne optische Marker, d.h. mit jeder beliebigen senkrechten Wand funktioniert, dafür aber weniger Freiheitsgrade bestimmen kann, ist in [124] publiziert. Die Grundideen der vorgestellten Verfahren wurden weiterhin in [131] patentiert.

Für die Kalibrierung von reinen Kamerasystemen existieren auch Verfahren, die gänzlich ohne Kalibrierobjekte oder Kalibriermuster funktionieren [18].

4.3 Datenvorverarbeitung der Umgebungssensoren

In diesem Abschnitt wird die Verarbeitungskette von den Rohdaten der Sensoren bis zur Objektlistenrepräsentation vorgestellt, die dann in das zentrale Fusions- und Zielverfolgungsmodul eingespeist wird.

4.3.1 Aufwandsreduktion durch Aufmerksamkeitssteuerung

Mit Hilfe der in Abschnitt 4.2 ermittelten Lagewinkel und Abstände der Sensoren untereinander und zum Fahrzeug können Transformationsvorschriften zwischen den lokalen Sensorkoordinatensystemen und dem Fahrzeugkoordinatensystem angegeben werden. Eine Aufmerksamkeitssteuerung wird dann durch Transformation der Messdaten eines Sensors in das lokale Sensorkoordinatensystem eines anderen Sensors erreicht. Die Sensordatenvorverarbeitung des zweiten Sensors kann von den Messdaten des ersten Sensors profitieren, indem zum Beispiel der Berechnungsaufwand reduziert oder der Informationsgehalt der vorverarbeiteten Daten erhöht

wird. Diese Assoziation von unverarbeiteten Sensordaten wird als Rohdatenfusion (engl. „Low-Level-Fusion“) bezeichnet. Die beteiligten Sensoren verschmelzen dabei zu einem Meta-Sensor, da die vorverarbeiteten Daten und ihre Positions- und Detektionsfehler nicht mehr statistisch unabhängig sind. Dies führt insbesondere dazu, dass die Messdaten der Sensoren nicht als unabhängige Messungen in ein Messdatenfilter eingebracht werden dürfen, sondern als Metamessung in einem kombinierten Messraum verarbeitet werden müssen (siehe Abschnitt 2.1.4, Seite 13). Gleichermaßen verschwindet das Datenassoziationsproblem zwischen den heterogenen Sensordaten und es muss lediglich das Assoziationsproblem zwischen den Metamessungen und den Objekten im Umfeldmodell gelöst werden.

Die Objekterkennung in monokularen Videobildern ist die Abtastung eines dreidimensionalen Suchraumes, der sich durch verschiedene Bildpositionen in horizontaler und vertikaler Richtung und den unterschiedlichen Abbildungsgrößen der Objekte bei verschiedenen Distanzen von der Kamera ergibt. Diese Suchoperation ist mit heutiger Rechentechnik nicht in Echtzeit lösbar, denn es müssen immer noch ca. 10^6 Bildposition für die in einer ACC Funktion relevanten Beobachtungsreichweiten abgesucht werden, wenn sogar zusätzlich die Restriktion verwendet wird, dass sich alle Suchobjekte auf einer Ebene befinden (engl. „Flat-World-Assumption“, FWA oder „Ground-Plane-Constraint“, GPC). Wenn weiterhin die gesuchten Objekte kein konstantes und bekanntes Seitenverhältnis von Breite und Höhe besitzen, würde sich der Suchraum noch um eine weitere Dimension vergrößern. Als Lösungsmöglichkeit für das Suchproblem existieren einerseits Techniken zur Aufwandsreduktion für die reine monokulare Bildverarbeitung (siehe Abschnitt 4.3.2), es bietet sich jedoch andererseits die heterogene Sensordatenfusion mit einem Abstandssensor an, mit welcher der Suchraum durch eine Aufmerksamkeitssteuerung drastisch reduziert werden kann.

Für die Rohdatenfusion eines Lidar-Sensors mit einer Videokamera zur Einschränkung des Suchbereichs muss für jedes Lidar-Echo $z^L = (r, \varphi, A)$ die Querschnittsfläche der entsprechenden Strahlungskeule in der gemessenen Echodistanz in das Videobild projiziert werden. Dazu werden die vier horizontalen und vertikalen Begrenzungspunkte p^l, p^r, p^o, p^u dieser Querschnittsfläche mit Hilfe der horizontalen und vertikalen Keulen-Öffnungswinkel $(\Delta\varphi, \Delta\vartheta)$ in homogenen kartesischen Lidarkoordinaten berechnet:

$$p^{l,LK} = \begin{bmatrix} r \cos(\varphi + \frac{1}{2}\Delta\varphi) & r \sin(\varphi + \frac{1}{2}\Delta\varphi) & 0 & 1 \end{bmatrix}^T \quad (4.20)$$

$$p^{r,LK} = \begin{bmatrix} r \cos(\varphi - \frac{1}{2}\Delta\varphi) & r \sin(\varphi - \frac{1}{2}\Delta\varphi) & 0 & 1 \end{bmatrix}^T \quad (4.21)$$

$$p^{o,LK} = \begin{bmatrix} r \cos(\varphi) & r \sin(\varphi) & r \sin(\frac{1}{2}\Delta\vartheta) & 1 \end{bmatrix}^T \quad (4.22)$$

$$p^{u,LK} = \begin{bmatrix} r \cos(\varphi) & r \sin(\varphi) & r \sin(-\frac{1}{2}\Delta\vartheta) & 1 \end{bmatrix}^T. \quad (4.23)$$

Die anschließende Transformation in das Bild besteht aus der Transformation von Lidarkoordinaten in Kamerakoordinaten und weiter in Bildkoordinaten. Sie erfolgt durch linksseitige Multiplikation der in Abschnitt 4.2.2, Seiten 89 ff., ermittelten Matrix $T^{LK \rightarrow BK}$ mit jedem dieser Punkte (4.24):

$$p^{*,BK} = T^{LK \rightarrow BK} p^{*,LK}, \quad T^{LK \rightarrow BK} = T^{KK \rightarrow BK} T^{LK \rightarrow KK}. \quad (4.24)$$

Prinzipiell lassen sich auch die Messdaten eines Radarsensors auf diese Weise mit den Videodaten assoziieren, wie Abbildung 4.10/b zeigt. Verbindet man für den Lidar-Sensor die in das Bild

transformierten Punkte durch Geraden, entstehen Rhomben als Approximationen der Echo-Querschnittsflächen (siehe Abbildung 4.10/a). Für die Bildverarbeitung entsteht daraus die Information, dass sich ein Objekt in einer bestimmten Distanz zur Kamera - und bei bekannter realer Objektgröße damit in einer bestimmten Skalierung - derart im Videobild befinden muss, dass sich die Bildregion der Abbildung dieses Objektes mit der projizierten Querschnittsfläche der Strahlungskeule überlappt. Diese überlappende Fläche kann dabei sehr klein in Bezug auf die Gesamtfläche des Objektes und des Echos sein, wenn das Objekt eine stark reflektierende Oberfläche, wie zum Beispiel Retroreflektoren, aufweist. Das Intervall der realen Objektanmessungen lässt sich aus den 3-Sigma Schranken der entsprechenden Statistiken approximieren, die z.B. in [85] für die Europäische Union veröffentlicht sind. Demnach finden sich 99% aller Fahrzeugbreiten im Intervall von $w^{\text{FK}} \in [1.5\text{m}..2.0\text{m}]$. Für jedes Echo des Abstandssensors werden die Intervallgrenzen der realen Objektanmessungen über das Lochkameramodell in das Videobild transformiert $w^{\text{BK}} \in [w_1^{\text{BK}}..w_2^{\text{BK}}]$. Bei einem festen Seitenverhältnis δ ist damit auch das Höhenintervall festgelegt. An den Grenzen dieses Skalierungsintervalls ergeben sich die vertikalen und horizontalen Positionsintervalle für den Mittelpunkt (i, j) des Suchfensters aus der Berührung der Echo-Projektion und der Objektprojektion als Grenzfall für die Überlappung (Abbildung 4.11):

$$\begin{aligned} i &\in [p_i^{l,\text{BK}} - \frac{w}{2} .. p_i^{r,\text{BK}} + \frac{w}{2}] \\ j &\in [p_j^{o,\text{BK}} - \frac{w}{2\delta} .. p_j^{u,\text{BK}} + \frac{w}{2\delta}]. \end{aligned} \quad (4.25)$$

Da somit die Größe der abzutastenden Fläche im Bild von der aktuellen Skalierung w abhängt, ergeben sich für jede Lidar-Messung Bild-Intervalle in Form eines Pyramidenstumpfes (Abbildung 4.12). Im Folgenden wird diese Intervallmenge als Echo-Intervallmenge bezeichnet. Abbildung 4.12/links zeigt die Ineffizienz der direkten Abtastung der Echo-Intervallmenge, da sich die Intervalle stark überlappen, wenn mehrere Echos von einem Objekt reflektiert wurden. In diesem Fall wird ein nicht zu vernachlässigender Teil des Suchraumes unnötigerweise zweifach oder öfter abgetastet. Da der hauptsächliche Laufzeitaufwand der Bildverarbeitung in der Musterklassifikation der Teilfenster besteht, lässt sich die Verarbeitungsgeschwindigkeit durch eine kollisionsarme bzw. -freie Neuapproximation der Echo-Intervallmenge steigern. Die Neuapproximationsaufgabe kann auf zweidimensionale Intervalle beschränkt werden, wenn vorher die Skalierungsdimension diskretisiert wird.

Als Parameter ist dazu zunächst die Schrittweite Δw metrisch in Fahrzeugkoordinaten gegeben. Sie wird in Abhängigkeit von der Echo-Distanz über das Lochkameramodell in das Videobild transformiert. Es ergibt sich ein Suchraster, das mit der Größe des Objektes im Bild skaliert. Im Anschluss werden für jede diskrete Objektskalierung alle 3D-Intervalle mit der Ebene geschnitten, die dieser Skalierung entspricht. Im Ergebnis erhält man eine Zuordnung von Mengen von möglicherweise überlappenden rechteckigen Positionsintervallen zu diskreten Objektskalierungen. Für jede Objektskalierung, deren Intervallmenge nicht leer ist, wird im Anschluss ein akkumulierendes Clusterverfahren auf die zugeordneten Intervalle angewendet. Bei einem einfachen Ansatz zur Neuapproximation werden zwei überlappende Intervalle dann durch ihr umschließendes Rechteck ersetzt, wenn der Flächeninhalt der Überlappung größer als der Flächeninhalt ist, der gleichzeitig innerhalb des umschließenden Rechtecks und außerhalb der Schnittmenge der beiden Intervalle liegt. Zwei Intervalle werden daher zusammengefasst,



(a) Rechts: Messdaten eines mehrkanaligen Lidar-Sensors (schwarze Punkte) mit 16 Messkanälen (Schattierung) in Vogelperspektive. Links: perspektivische Einblendung der Lidar-Messdaten in das Videobild (Rhomben) und Mittelachsen der Messkanäle (grau). Die Größe der Rhomben ist durch die Aufweitung des Lichtkegels bei der Zieldistanz bestimmt, die innerhalb der Rhomben in Metern angegeben ist.



(b) Rechts: Messdaten eines bildgebenden Radarsensors mit 17 Messkanälen in Vogelperspektive. Links: perspektivische Einblendung der Radar-Messdaten in das Videobild. Aufgrund des volumetrischen Charakters der Radar-Messdaten ist nur die mittlere Ebene durch die Emissionskeulen im Bild visualisiert.

Abbildung 4.10: Rohdatenassoziation mit Video und Lidar (a) oder Video und Radar (b).




Abbildung 4.11: Berechnung des Suchintervalls aus der Echo-Projektion für eine bestimmte Objektgröße mit dem Berührungskriterium (links) oder einer Mindestüberlappung (rechts).




Abbildung 4.12: Links: Der aus den Bildpositionen $[i, j]$ und Objektskalierungen w bestehende Suchraum im Videobild wird durch die Projektionen der Lidar-Daten (schwarze Rhomben, Abb. 4.10) eingeschränkt. Aufgrund der unsicherheitsbehafteten tatsächlichen Objektanmessungen entstehen dreidimensionale Suchintervalle. Rechts: Quantisierung der Skalierungsdimension und Neuapproximation der 2D-Schnittintervalle zur Effizienzsteigerung durch Eliminierung von Überlappungen.




Abbildung 4.13: Überlappungstest für die einfache Intervallneuapproximation. Die beiden Intervallboxen werden durch ihre umschließende Box ersetzt wenn der doppelt abzutastende innere Flächeninhalt A_i größer als der außen liegende Flächeninhalt A_a ist, d.h. in Summe die Suchfläche abnimmt.

wenn das abzutastende Volumen in Summe durch die Vereinigungsoperation abnimmt (Abbildung 4.13). Eine vollständig kollisionsfreie Neuapproximation kann immer durch Zerlegung zweier überlappender Rechtecke in drei neue Rechteck-Intervalle erreicht werden. Während bei der einfachen Variante die Anzahl der Intervalle sinkt, steigt bei der kollisionsfreien Variante die Anzahl der Intervalle und damit der Verarbeitungsaufwand an. Nach der Neuapproximation werden alle Intervalle mit Quantisierungsschrittweiten ($\Delta i, \Delta j$) auf der horizontalen und vertikalen Bildposition abgetastet, die ebenfalls mit der Objektgröße w nach dem Lochkammermodell skalieren. Die eigentliche Klassifikation eines einzelnen Bildausschnittes (i, j, w) wird in Abschnitt 4.3.2 besprochen.

Tabelle 4.5: Mittlere Anzahl der zu berechnenden Teilfenster-Klassifikationen pro Bild im Vergleich zwischen vollständiger Suche und Lidar-Aufmerksamkeitssteuerung mit und ohne Intervallneuapproximation, gemittelt über 25 Sequenzen mit 12495 Einzelmessungen. Die Intervallgrenzen wurden mit dem Berührungskriterium (4.25) berechnet.

Anzahl Klassifikationen	vollständige Suche	ohne Neuapproximation	einfache Neuapproximation	kollisionsfreie Neuapproximation
μ	$1.172 \cdot 10^6$	$2.229 \cdot 10^5$	$1.777 \cdot 10^5$	$1.767 \cdot 10^5$
$\mu + 3\sigma$	$1.172 \cdot 10^6$	$5.096 \cdot 10^5$	$3.970 \cdot 10^5$	$3.931 \cdot 10^5$
μ , normiert	100%	19.03%	15.16%	15.08%
$\mu + 3\sigma$, normiert	100%	43.50%	33.88%	33.55%
μ , normiert	525.50%	100%	79.69%	79.25%
$\mu + 3\sigma$, normiert	229.88%	100%	77.89%	77.13%

Tabelle 4.6: Mittlere Anzahl der zu berechnenden Teilfenster-Klassifikationen pro Bild im Vergleich zwischen vollständiger Suche und Lidar-Aufmerksamkeitssteuerung mit und ohne Intervallneuapproximation, gemittelt über 25 Sequenzen mit 12495 Einzelmessungen. Die Intervallgrenzen wurden für eine Mindestüberlappung von Echo-Projektion und Suchfenster von 30% der Suchfenstergröße berechnet.

Anzahl Klassifikationen	vollständige Suche	ohne Neuapproximation	einfache Neuapproximation	kollisionsfreie Neuapproximation
μ	$9.046 \cdot 10^5$	$9.286 \cdot 10^4$	$7.778 \cdot 10^4$	$7.703 \cdot 10^4$
$\mu + 3\sigma$	$9.046 \cdot 10^5$	$2.034 \cdot 10^5$	$1.697 \cdot 10^5$	$1.667 \cdot 10^5$
μ , normiert	100%	10.27%	8.60%	8.51%
$\mu + 3\sigma$, normiert	100%	22.49%	18.76%	18.43%
μ , normiert	974.14%	100%	83.75%	82.94%
$\mu + 3\sigma$, normiert	444.66%	100%	83.42%	81.96%

Tabelle 4.5 zeigt die mittlere Anzahl der Teilfensterklassifikationen pro Bild bei einer Quantisierungsschrittweite von $\Delta w = \Delta i = \Delta j = 0.08\text{m}$. Der Aufwand für die vollständige Bildsuche ohne Aufmerksamkeitssteuerung ist dabei nur in dem Raumwinkel ausgezählt, der von beiden Sensoren abgedeckt wird. Bei Verwendung einer Aufmerksamkeitssteuerung ergibt sich

bei naiver Abtastung aller Echo-Intervalle eine mittlere Aufwandsersparnis von 81% im Vergleich zur vollständigen Bildsuche. Im besten Fall, wenn keine Messungen des Lidar vorliegen, wird gar keine Teilfensterklassifikation benötigt. Im ungünstigsten Fall, d.h. bei sehr vielen Echos des Distanzsensors, können immer noch 56% der Klassifikationen eingespart werden. Bezogen auf den Suchaufwand dieser naiven Intervallabtastung erhöht sich die Verarbeitungsgeschwindigkeit durch das einfache Verfahren zur Intervallneuapproximation um weitere 20% im Mittel und 22% im ungünstigsten Fall. Die Leistungssteigerungen durch vollständig kollisionsfreie Neuapproximation liegen in der Größenordnung von einem Prozent. Der Grund hierfür ist die Tatsache, dass ein Großteil der überlappenden Such-Intervalle durch Echos auf dem gleichen Objekt erzeugt wird und damit annähernd gleiche Distanzmessungen aufweisen. Die resultierenden Bildprojektionen befinden sich daher ungefähr in gleicher Bildhöhe, so dass die zusätzlichen Suchbereiche der einfachen Vereinigungsoperation (Fläche A_a in Abbildung 4.13) minimal sind. Für das Gesamtsystem kommt aus diesem Grund das einfache Neuapproximationsverfahren zum Einsatz. Abbildung 4.12 zeigt die 3D-Echointervalle und ihre 2D-Neuapproximationen nach diesem Verfahren.

Tabelle 4.6 zeigt eine analoge Evaluierung bei der Verwendung verkleinerter 3D-Suchintervalle mit einer Mindestüberlappung zwischen Echo-Projektion und Suchfenster von 30% der Suchfenstergröße (Abbildung 4.11/rechts). Im Vergleich zu Tabelle 4.5 zeigt die absolute Anzahl der Klassifikationen, wie sensitiv die Rechenzeit in der Bildverarbeitung in Bezug auf die Lokalisierungsungenauigkeit des Distanzsensors ist, da der Suchaufwand bei den verkleinerten Intervallen noch einmal um 50% sinkt. So ist zu erwarten, dass der Aufwand einerseits durch eine genauere horizontale und vertikale Objektvorlokalisierung zum Beispiel mit Laserscannern [102, 39] deutlich reduzierbar ist und andererseits mit tendenziell schlechter räumlich aufgelösten Radarsensoren eher ansteigt. Gleichzeitig rechtfertigt sich damit die hochgenaue räumliche Kreuzkalibrierung zwischen den Sensoren, da Ausrichtungsunsicherheiten der Sensoren zu vergrößerten Suchbereichen und damit zu drastisch steigendem Rechenaufwand führen würden.

Es sei hier angemerkt, dass die obigen Aufwandsbetrachtungen nur für schlecht ortsaufgelöste Distanzsensoren gelten, mit denen allein aus den Distanzdaten keine Objektklassifikation möglich ist, ohne dynamische Merkmale zu verwenden, die aber wiederum für stehende Fahrzeuge inadäquat sind. Mit hochauflösender Distanzsensorik können aus den vermessenen Objektkonturen weitere Einschränkungen für die Bildverarbeitung, wie z.B. Objektklassen, Abmessungen oder Orientierungen gewonnen werden, die den Suchaufwand im Bild weiter drastisch reduzieren [102].

Wie oben beschrieben, führt die gemeinsame Rohdatenverarbeitung statistische Abhängigkeiten in die Messungen beider Sensoren ein. Bei der Messung von Zustandsvariablen wird meist über diese Tatsache hinweggesehen, da bei ausreichend großen Toleranzen für die Suchbereiche im Bild die Abhängigkeit der Positionsmessungen sicher minimal ist. Bei der Existenzschätzung sind die Folgen aber gravierender, wie an einem einfachen Beispiel ersichtlich ist. Wenn der Abstandssensor temporär kein Echo von einem Objekt vermessen kann, wird auch in der Bildverarbeitung mangels entsprechenden Suchbereichs kein Objekt detektiert. Eine Fusion der Daten auf Objektebene würde hier eine unabhängige Messung der Nicht-Existenz des Objektes von beiden Sensoren annehmen, obwohl es sich um genau dieselbe Information handelt.

Als Folge kann das zumindest für die Forschung und Vorentwicklung anvisierte Ziel, einzelne Sensorik in einem Fusionsmodul zu Vergleichszwecken eventuell sogar im laufenden Betrieb zu- und abschaltbar zu machen, mit dem gezeigten Ansatz nicht erreicht werden, da hier eine individuelle Sensordatenverarbeitung mit anschließender Fusion auf höherer Ebene nötig wäre, um nicht eine spezielle Datenvorverarbeitung für jede Sensorkombination hinterlegen zu müssen. Mit heutiger Rechentechnik kann das Videobild aber nicht vollständig in Echtzeit durchsucht werden, ohne die Annahme einer flachen Welt (engl. „Flat-World-Assumption“, „Ground-Plane-Constraint“) zu verwenden, die bei Erfassungsreichweiten bis zu 200 Metern sicher inadäquat ist.

Als Lösung kommt der bekannte Ansatz der „grob-zu-fein“-Suche in Betracht, der in heutigen monokularen Bildverarbeitungssystemen meist zusammen mit der Annahme einer flachen Welt für den Nahbereich verwendet wird [29, 118]. Hier wird das Suchraster dynamisch an den Bildinhalt angepasst. Dazu wird das Bild zunächst mit einem grobem Raster abgetastet. In den Regionen, in denen die Antwort des Bildklassifikators die Objektpräsenz zumindest nicht sicher verneint, wird dann das Suchraster verfeinert und erneut abgetastet. Dieser Prozess kann mehrere Male wiederholt werden. Derart hierarchische Suchstrategien funktionieren nur für Bildklassifikatoren, deren Antwortsignal mit der Positionsabweichung zum tatsächlichen Objekt monoton abfällt. Erste erfolgreiche rein monokulare Ansätze dieser Art wurden in der Fußgängererkennung bei Tag [28] und bei Nacht [3] demonstriert. Sollten diese Ansätze eines Tages die gleiche Aufwandsersparnis bei vergleichbarer Erkennungsleistung erbringen, würde sich die Aufmerksamkeitssteuerung als Rohdatenfusion erübrigen. In diesem Fall könnte man die unabhängig berechneten Bildinformationen auf einer höheren Fusionsebene mit den Daten eines Distanzsensors fusionieren und ein „Plug-and-Play“-System für heterogene Sensorik realisieren.

4.3.2 Objektdetektion

Die Klassifikation der durch die Aufmerksamkeitssteuerung erzeugten Suchfenstermenge erfolgt in dieser Arbeit mit einer Erweiterung des von Viola und Jones vorgestellten kaskadierten „Boosting“-Klassifikators [92] durch Lienhart et. al. [50, 51]. Dabei wird für jedes einzelne Suchfenster jeweils eine binäre Entscheidung getroffen, ob es sich bei dem Fensterinhalt um die gesuchte Objektklasse handelt oder nicht.

Dieses zuerst für die Gesichtserkennung entwickelte Verfahren wurde in der Fahrzeugumfeld-erfassung sehr erfolgreich für die Detektion von Fußgängern [93, 118, 63, 3, 102] und Fahrzeugen [99, 38, 74] eingesetzt. Die Kombination dieses Bildverarbeitungsverfahrens mit einem Abstandssensor in einem Sensorfusionssystem wurde nach derzeitigem Kenntnisstand erstmalig im Rahmen dieser Arbeit in [124] vorgestellt.

Neben der Objektdetektion durch Klassifikationsalgorithmen existieren auch monokulare Erkennungsverfahren, die auf dem optischen Fluss basieren [43]. Mit heute verfügbarer Videosensorik können damit Objekte zwar unabhängig vom Objekttyp, jedoch lediglich mit Reichweiten von bis zu 60 Metern [44] stabil erkannt werden. Daher sind diese Verfahren auch in einer Fusionsarchitektur eher im Nahbereich [34] und weniger für die hier fokussierte ACC-Anwendung mit Erkennungsreichweiten bis zu 200 Metern geeignet.

Aufgrund der großen Verbreitung des hier verwendeten Ansatzes werden im Folgenden lediglich dessen Grundkonzepte kompakt erläutert.

Äußere Struktur des Detektionsalgorithmus

Um das effiziente Prinzip der „grob-zu-fein“-Suche umzusetzen, werden mehrere binäre Einzelklassifikatoren mit zunächst unbekannter innerer Struktur aber mit steigender Komplexität, Rechenzeitanforderung und Diskriminierungsleistung hintereinander geschaltet. Die Intention dieser äußeren Struktur ist das schnelle Verwerfen möglichst vieler Negativmuster in den ersten schnellen Stufen, um nur noch wenige schwierige Muster mit viel Rechenaufwand in den hinteren Stufen entscheiden zu müssen. Dabei werden die einzelnen Klassifikatorknoten jeweils so trainiert, dass sie möglichst alle Positivmuster richtig als solche klassifizieren und dabei so viele Negativmuster wie möglich aus der zu klassifizierenden Mustermenge aussortieren. Da ein einzelner Klassifikatorknoten eventuell nicht in der Lage ist, die verbleibende Testmustermenge „richtig“ zu separieren, wurde die Kaskadenstruktur von Lienhard et. al. auf eine Baumstruktur erweitert. Hier kann ein Klassifikatorknoten mehrere Tochterknoten besitzen. Dadurch können sich die einzelnen Zweige des Klassifikatorbaumes durch entsprechende Merkmalswahl auf verschiedene Ausprägungen der gesuchten Objektklasse spezialisieren, während alle Klassifikatorknoten in der linearen Kaskadenstruktur immer für alle Ausprägungen der relevanten Objektklasse trainiert werden müssen und daher potenziell weniger diskriminante Merkmale verwenden können.

Der Algorithmus wurde mit einer Trainingsmenge von ca. 10000 manuell markierten Fahrzeugfronten und Fahrzeugrückfronten trainiert. Da der Trainingsalgorithmus automatisch nach jedem Knoten prüft, ob die verbliebene Mustermenge effizienter durch einen oder zwei Folgeknoten klassifizierbar ist, wurde die in Abbildung 4.14 gezeigte äußere Baumstruktur mit 36 Klassifikatorknoten und einer Baumtiefe von 18 Stufen vollautomatisch erzeugt. Neben dieser automatischen Verzweigung wurden in der Literatur auch Ansätze mit manueller Verzweigungswahl präsentiert [41]. Alle durch die Aufmerksamkeitssteuerung (Abschnitt 4.3.1) berechneten Suchfenster werden in den Knoten Null eingespeist und traversieren den Klassifikatorbaum in einer Tiefensuche. Erreicht ein Suchfenster einen Blattknoten und klassifiziert dieser es ebenfalls als positiv, wird das Suchfenster als Detektion ausgegeben.

Innere Struktur des Detektionsalgorithmus

Jeder Klassifikatorknoten entwickelt zunächst das zu klassifizierende Bildmuster nach einer Haar-Wavelet-Basis. Der Koeffizientenvektor dieser Entwicklung ist der Merkmalsvektor des Klassifikators. Jedes Element einer solchen Wavelet-Basis ist durch einen Funktionstyp, eine horizontale und vertikale Skalierung, eine zweidimensionale Positionierung des Wavelets im Suchfenster und einen Rotationswinkel von 0° oder 45° gegeben. Die verwendeten Grundtypen zeigt Abbildung 4.15. Von Stufe zu Stufe der äußeren Baumstruktur steigt die Anzahl der Basisfunktionen nach denen das Muster entwickelt wird. Der Koeffizient eines Testmusters $\mathbf{m}$ und einer Haar-Wavelet-Basisfunktion $\mathbf{b}$ ergibt sich durch ihr Skalarprodukt $\langle \mathbf{m}, \mathbf{b} \rangle$, also das Integral des Produktes beider Funktionen. Aufgrund der einfachen Struktur der Haar-Wavelet-Funktionen können die Koeffizienten durch wenige Zugriffe in das sogenannte Integralbild




Abbildung 4.14: Baumstruktur des trainierten Kaskadenklassifikators. Kreise: Klassifikatorknoten, Rechtecke: Baumtiefen.




Abbildung 4.15: Grundtypen der verwendeten Haar-Wavelet-Filtermasken. Die zweidimensionalen Funktionen haben außerhalb der Rechtecke den Funktionswert Null und sind innerhalb der schwarzen Bereiche gleich dem negativen Flächeninhalt der weißen Bereiche und innerhalb der weißen Bereiche gleich dem positiven Flächeninhalt der schwarzen Bereiche.

berechnet werden, dass an jedem Bildpunkt die Pixelsumme des Rechteckes vom Ursprung bis zu diesem Bildpunkt enthält. Ein solches Integralbild kann einmalig für jedes Videobild vorberechnet und dann für jedes Suchfenster und jeden Klassifikatorknoten wiederverwendet werden [92].

Für eine Suchfenstergröße von 24×20 Pixel ergeben sich so ca. 100000 verschiedene Haar-Wavelet-Basisfunktionen, unter denen der Trainingsalgorithmus pro Stufe der äußeren Baumstruktur einige wenige auswählt, die die gesuchte Objektklasse am stärksten diskriminieren. Die eigentliche binäre Entscheidungsfunktion eines Klassifikatorknotens auf dem Koeffizientenvektor ist hierarchisch aufgebaut (Abbildung 4.16). Zunächst werden Untergruppen von Koeffizienten in binären Entscheidungsbäumen verarbeitet (engl. „Classification and Regression Trees“ [12], CART, Rechtecke in Abbildung 4.16). Je nach dem, welchen Blattknoten des binären Klassifikationsbaumes ein Muster erreicht und welche Entscheidung dieser Blattknoten trifft, werden verschiedene feste, während des Trainings bestimmte, Aktivierungswerte α_{ij} aus dem CART an ein zentrales Perzeptron weitergereicht. Dieses Neuron summiert die Aktivierungen aller CARTs und vergleicht die Summe gegen einen Schwellwert, um die finale binäre Klassifikationsentscheidung des Klassifikatorknotens zu erzeugen.

Während des Trainings werden für jeden Klassifikatorknoten vollautomatisch und datengetrieben die Basisfunktionen ausgewählt, die Strukturen und Aktivierungen der CARTs sowie die Schwellwerte der Zentralneuronen bestimmt, so dass der Klassifikationsfehler minimal wird.




Abbildung 4.16: Innere Struktur des Knotens 7 der Klassifikatorkaskade aus Abbildung 4.14.




Abbildung 4.17: Zur Fahrzeugdetektion werden die Lidardaten (rechts) in das Videobild projiziert (Rhomben). Der Kaskadenklassifikator erzeugt in diesen Bildregionen mehrfache Detektionen (weiße Boxen). Ein Clusteralgorithmus führt die Mehrfachdetektionen zusammen. Die Clusterzentroide entsprechen den finalen Bildmessungen (schwarze Boxen).

Zusammenfassung von Mehrfachdetektionen

Pro realem Objekt passieren regelmäßig mehrere Hypothesenfenster erfolgreich den Klassifikatorbaum (Abbildung 4.17). Zur Zusammenfassung dieser Mehrfachdetektionen wird ein agglomeratives Clusterverfahren verwendet. Dabei bezeichnet ein Cluster eine Menge von zusammengehörigen Detektionsboxen. Initial wird ein Cluster pro positiv klassifiziertem Suchfenster erzeugt. Im Anschluss wird für jedes Cluster ein Distanzmaß zu jedem anderen Cluster berechnet. Unterschreitet die Distanz zwischen zwei Clustern einen Schwellwert, werden die beiden Cluster durch Vereinigung der Boxmengen zusammengefasst. Dieser Prozess wird so lange wiederholt, bis keine Zusammenfassung mehr möglich ist.

Die verwendete Abstandsmetrik muss die Positions- und die relativen Größenunterschiede zweier Cluster berücksichtigen und gleichzeitig unabhängig von der absoluten Skalierung sein, damit der Distanzschwellwert für alle Objektentfernungen gleich wirkt. Ein Abstandsmaß, das diese Anforderungen erfüllt, ist der Betrag des Differenzvektors der normierten und pro Cluster gemittelten Boxbreiten und Bildpositionen. Die Normierung erfolgt dabei auf die über beide Cluster gemittelte Detektionsboxbreite $\bar{B}$. Für zwei Detektionscluster

$$c_x = [(i_{x,1}, j_{x,1}, b_{x,1}), \dots, (i_{x,|c_x|}, j_{x,|c_x|}, b_{x,|c_x|})] \quad (4.26)$$

und

$$c_y = [(i_{y,1}, j_{y,1}, b_{y,1}), \dots, (i_{y,|c_y|}, j_{y,|c_y|}, b_{y,|c_y|})] \quad (4.27)$$

ergibt sich das Abstandsmaß

$$D(c_x, c_y) = \sqrt{\left| \frac{\bar{I}_x}{\bar{B}} - \frac{\bar{I}_y}{\bar{B}} \right|^2 + \left| \frac{\bar{J}_x}{\bar{B}} - \frac{\bar{J}_y}{\bar{B}} \right|^2 + \left| \frac{\bar{B}_x}{\bar{B}} - \frac{\bar{B}_y}{\bar{B}} \right|^2} \quad (4.28)$$

mit

$$\bar{B} = \frac{\sum_{k=1}^{|c_x|} b_{x,k} + \sum_{k=1}^{|c_y|} b_{y,k}}{|c_x| + |c_y|}, \quad \bar{I}_x = \frac{\sum_{k=1}^{|c_x|} i_{x,k}}{|c_x|}, \quad \bar{J}_x = \frac{\sum_{k=1}^{|c_x|} j_{x,k}}{|c_x|}, \quad \bar{B}_x = \frac{\sum_{k=1}^{|c_x|} b_{x,k}}{|c_x|}. \quad (4.29)$$

4.4 Eigenbewegungsschätzung für das Sensorfahrzeug

Mit der im Fahrzeug verbauten Umgebungserfassungssensorik ist man zunächst nur in der Lage, die dynamischen Zustandsgrößen anderer Verkehrsteilnehmer relativ zum Bezugssystem des eigenen Fahrzeugs zu vermessen oder zu schätzen. Für nachgeschaltete Systemmodule, wie zum Beispiel die Objektklassifikation, die drahtlose Übertragung des Umfeldmodells an andere Verkehrsteilnehmer und die automatische Situationsanalyse sind jedoch Objektbeschreibungen mit absoluten Geschwindigkeiten und Gierraten über Grund notwendig. Diese absoluten Größen können nur unter Kenntnis der Dynamik des Sensorfahrzeugs aus den relativen Sensordaten berechnet werden. Im Folgenden wird daher ein Beobachterkonzept für die Bestimmung der Fahrzeugeigendynamik aus den Sensordaten des ESP-Systems mit einem Extended-Kalman-Filter [42] beschrieben.

4.4.1 Prozessmodellierung

Für die fokussierte Adaptive-Cruise-Control Anwendung (ACC) werden im Folgenden Drift- und Radschlupfeffekte vernachlässigt. Für eine Eigenbewegungsschätzung bei extremen Fahrmanövern sei auf [101] verwiesen. Die Fahrzeugdynamik ist damit durch die Bahngeschwindigkeit v^e (auch: Tangentialgeschwindigkeit), die Gierrate um die Fahrzeughochachse sowie deren Zeitableitungen vollständig beschrieben (Abbildung 4.18). Ausgehend von einem Modell konstanter Geschwindigkeit in beiden Bewegungsrichtungen werden die höheren Ableitungen




Abbildung 4.18: Fahrdynamikmodell: Das fahrzeugfeste Koordinatensystem (FK) bewegt sich auf einer klothoidenartigen Trajektorie T mit Bahngeschwindigkeit $v^e(t)$ und dreht mit Gierrate $\dot{\varphi}^e(t)$ gegen ein globales Bezugssystem.

und insbesondere die Beschleunigungen durch das Prozessrauschen $\mathbf{v}^e$ modelliert. Die Identifikation der Modellparameter erfolgt für beide Bewegungskomponenten getrennt, weil ihre statistische Unabhängigkeit angenommen wird. Diese Annahme wird zunächst durch die Tatsache gestützt, dass der Fahrer beide Bewegungskomponenten unabhängig voneinander durch Lenkradeinschlag und Gas- bzw. Bremspedalstellung bestimmt. Weiterhin ist bei der Kurvenfahrt die Tangentialbeschleunigung mit der Gierbeschleunigung betragsmäßig stark korreliert, da in der Regel beim Einfahren in eine Kurve gleichzeitig gebremst und eingelenkt und beim Ausfahren gleichzeitig zurück gelenkt und beschleunigt wird. Im Vorzeichen sind die Beschleunigungen jedoch bei Linkskurven positiv korreliert und bei Rechtskurven antikorreliert, so dass bei gleicher Häufigkeit beider Kurvenrichtungen die Kreuzkorrelation verschwindet.

Identifikation des Prozessmodells

Zur Identifikation der Rauschparameter für die Gierbeschleunigung werden N Messwerte des ESP-Drehratensensors über einen sehr langen Zeitraum in verschiedenen repräsentativen Verkehrsumgebungen, wie Autobahnen, Landstraßen und Innenstädten, aufgezeichnet. Dieses Signal wird differenziert, so dass als Ergebnis $\ddot{\varphi}$ eine additive Überlagerung des tatsächlichen Gierbeschleunigungssignals $\ddot{\varphi}^e$ mit dem durch die Differentiation verstärkten Messrauschen des Sensors entsteht. Für dieses zusammengesetzte Signal wird die empirische Autokorrelationsfolge (AKF) in Abhängigkeit von der diskreten Zeitverschiebung κ berechnet:

$$\phi^{\ddot{\varphi}}(\kappa) = \frac{1}{N - \kappa} \sum_{k=1}^{N-\kappa} \ddot{\varphi}_k \ddot{\varphi}_{k+\kappa}. \quad (4.30)$$

Aus den Nulldurchgängen dieser Folge (Abbildung 4.19/oben) und der Tatsache, dass Autokorrelationsfunktion und -folgen die Periodizitäten des Ausgangssignals nicht verändern [78], lässt sich ablesen, dass das Einlenkmanöver im statistischen Mittel circa drei Sekunden und die gesamte Kurvendurchfahrt circa sechs Sekunden dauert. Da die Autokorrelationsfolge erwartungsgemäß keine Übereinstimmungen mit einem Dirac-Stoß aufweist, kann das Prozessrauschen der Gierbeschleunigung nicht als weißes Rauschen modelliert werden. Um dennoch ein Kalman-Filter für die Eigenbewegungsschätzung verwenden zu können, wird ein zeitdiskretes Formfilter zur Rauschmodellierung eingesetzt. Weiterhin wird angenommen, dass die schnell dekorrelierte Spitze um den Nullpunkt der empirischen AKF dem verstärkten Messrauschen und der langsamere schwingungsähnliche Anteil dem tatsächlichen Gierbeschleunigungssignal zuzuordnen ist. Im Abschnitt über die Messmodellierung wird später gezeigt, dass das Messrauschen des Gierratensensors tatsächlich eine sehr kurze Dekorrelationsdauer aufweist. Da der langsame Anteil die Form einer exponentiell gedämpften harmonischen Schwingung hat, wird ein Filterprototyp mit der zeitkontinuierlichen Impulsantwort

$$h(\tau) = \mathbb{1}^+(\tau) K e^{-\alpha|\tau|} \cos(\omega_0 \tau) \quad (4.31)$$

gewählt. Dabei bezeichnet $\mathbb{1}^+(\tau)$ die Heaviside-Funktion. Weiterhin werden die Symbole t für die kontinuierliche Zeit, k für den diskreten Zeitindex, T_S für die Abtastperiode, τ für die kontinuierliche und κ für die diskrete Zeitverschiebung verwendet. Es gelten daher bei




Abbildung 4.19: Autokorrelationsfolge (oben) und normiertes Leistungsdichtespektrum (unten) der Gierbeschleunigung (zeitdiskret, zweiseitig)

abgetasteten Systemen die Beziehungen:

$$t = k \cdot T_S \quad (4.32)$$

$$\tau = \kappa \cdot T_S. \quad (4.33)$$

Parameterbestimmung

Zur Bestimmung der Filterparameter in (4.31), bestehend aus der Verstärkung K , dem Dämpfungskoeffizient α und der Eigenfrequenz ω_0 , wird zunächst die zweiseitige diskrete Fourier-Transformation $\mathcal{F}$ auf die empirische Autokorrelationsfolge angewendet, um das in Abbildung 4.19/unten gezeigte empirische Leistungsdichtespektrum zu berechnen (Wiener-Khintchine-Relation, [48]):

$$S^{\ddot{\phi}}(e^{j\Omega}) = \mathcal{F}_{\kappa \rightarrow \Omega} \{ \phi^{\ddot{\phi}}(\kappa) \}, \quad \Omega = \frac{2\pi\kappa}{N}, \quad \kappa = -\lfloor N/2 \rfloor .. \lfloor N/2 \rfloor. \quad (4.34)$$

Setzt man

$$z = e^{j\omega T_S}, \quad \omega = \frac{2\pi\kappa}{T_S N}, \quad (4.35)$$

wird die normierte Kreisfrequenz Ω in Radiant pro Abtastwert durch eine multiplikative Eins (T_S/T_S) zur zeitbezogenen Kreisfrequenz ω in Radiant pro Sekunde umdefiniert. Die diskrete Fourier-Transformation wird dadurch zum Spezialfall der z-Transformation [70] mit

$$S^{\ddot{\varphi}}(e^{j\Omega}) = S^{\ddot{\varphi}}(e^{j\omega T_S}) = S^{\ddot{\varphi}}(z). \quad (4.36)$$

Für den Durchgang eines stochastischen Anregungssignals u mit dem Leistungsdichtespektrum $S^u(z)$ durch ein lineares zeitinvariantes System (LZI) mit dem Ausgangsleistungsdichtespektrum $S^{\ddot{\varphi}}(z)$ und der Leistungsübertragungsfunktion $L(z)$ gilt folgende Beziehung:

$$S^{\ddot{\varphi}}(z) = L(z) \cdot S^u(z). \quad (4.37)$$

Neben der Forderung des Kalman-Filters nach weißem normalverteiltem Rauschen wird zusätzlich noch o.E.d.A. die Standardnormalverteilung $u \sim \mathcal{N}(0, 1)$ für das Anregungssignal modelliert, so dass $S^u(z) = 1$ gilt [30], und (4.37) in

$$S^{\ddot{\varphi}}(z) = L(z) \quad (4.38)$$

übergeht. Für die daher direkt durch das empirische Leistungsdichtespektrum gemessene spektrale Leistungsübertragungsfunktion und die zeitdiskrete Impulsantwort des gesuchten Formfilters gilt folgende Faktorisierungsbeziehung [5]:

$$L(z) = |H(z)|^2 = H(z) \cdot H(z^{-1}) = \mathcal{Z}\{h(\kappa)\} \cdot \mathcal{Z}\{h(-\kappa)\}. \quad (4.39)$$

Beim zeitdiskreten Filterentwurf durch Impulsinvarianz wird die zeitdiskrete Impulsantwort durch eine skalierte Abtastung der zeitkontinuierlichen Impulsantwort gewonnen [70]:

$$h(\kappa) = T_S h(\tau), \quad \tau = \kappa T_S. \quad (4.40)$$

Die zeitdiskrete Übertragungsfunktion als z-Transformierte der Impulsantwort des gewählten Filterprototyps (4.31) ergibt sich zu [88]:

$$\mathcal{Z}\{h(\kappa)\} = H(z) = K T_S \frac{z^2 - e^{-\alpha T_S} z \cos(\omega_0 T_S)}{z^2 - 2e^{-\alpha T_S} z \cos(\omega_0 T_S) + e^{-2\alpha T_S}}. \quad (4.41)$$

Daraus lassen sich jetzt die Filterparameter im Bildbereich durch eine Minimierung der Fehlerquadrate berechnen:

$$[K, \alpha, \omega_0]_{opt} = \underset{K, \alpha, \omega_0}{\operatorname{argmin}} \sum_{\kappa=-\lfloor N/2 \rfloor}^{\lfloor N/2 \rfloor} [S^{\ddot{\varphi}}(z) - H(z)H(z^{-1})]^2. \quad (4.42)$$

Alternativ kann die Parameteroptimierung auch im Zeitbereich mit der Autokorrelationsfolge erfolgen:

$$[K, \alpha, \omega_0]_{opt} = \underset{K, \alpha, \omega_0}{\operatorname{argmin}} \sum_{\kappa=-\lfloor N/2 \rfloor}^{\lfloor N/2 \rfloor} [\phi^{\ddot{\varphi}}(\kappa) - \mathcal{Z}_{z \rightarrow \kappa}^{-1}\{H(z)H(z^{-1})\}]^2. \quad (4.43)$$

Abbildung 4.19 zeigt die gemessenen und die durch die bestimmten Filterparameter modellierten Autokorrelationsfolgen und Leistungsdichtespektren der Gierbeschleunigung. In Abbildung




Abbildung 4.20: Autokorrelationsfolge (oben) und normiertes Leistungsdichtespektrum (unten) der Tangentialbeschleunigung (zeitdiskret, zweiseitig)

4.20 sind die Autokorrelationsfolge und das Leistungsdichtespektrum des Formfilters für die Tangentialbeschleunigung dargestellt, für die der gleiche Filterprototyp und die gleiche Methode der Parameterbestimmung angewendet wurde. Aus der Lernsequenz wurden folgende Parameterwerte ermittelt:

$$K^{\ddot{\varphi}} = 0.012 \text{ rad} \cdot \text{s}^{-3} \quad \alpha^{\ddot{\varphi}} = 0.4586 \text{ s}^{-1} \quad \omega_0^{\ddot{\varphi}} = 0.8185 \text{ rad} \cdot \text{s}^{-1} \quad (4.44)$$

$$K^a = 0.1002 \text{ m} \cdot \text{s}^{-3} \quad \alpha^a = 0.2392 \text{ s}^{-1} \quad \omega_0^a = 0.1790 \text{ rad} \cdot \text{s}^{-1}. \quad (4.45)$$

Charakteristisch für die bestimmten Parameter ist die doppelte Dekorrelationsdauer und ein Viertel der Eigenfrequenz bei einem Vergleich zwischen Tangentialbeschleunigung und Gierbeschleunigung.

Realisierung des Formfilters

Nachdem die Parameter für (4.31) bestimmt worden sind, soll eine zeitdiskrete Zustandsraumdarstellung des Filters für zunächst eine Bewegungskomponente am Beispiel der Gierbeschleunigung gefunden werden, um eine rekursive Softwareimplementierung zu ermöglichen. Obwohl dies direkt mit Hilfe der zeitdiskreten Übertragungsfunktion für die Gierbeschleunigung (4.41) möglich ist, wird zunächst ein zeitkontinuierliches Modell verwendet, um die Kopplung mit der

Gierrate zu erreichen. Dazu wird die zeitkontinuierliche Übertragungsfunktion zu (4.31) durch Laplace-Transformation der Impulsantwort (4.31) ermittelt:

$$\mathcal{L}_{\tau \rightarrow s}\{h(\tau)\} = K \cdot \frac{s + \alpha}{s^2 + 2\alpha s + \alpha^2 + \omega_0^2}. \quad (4.46)$$

Aus den Polynomkoeffizienten lässt sich eine Systemgleichung für die Gierbeschleunigung in Beobachtungsnormalform [30] aufstellen. Hier wird die zusätzliche Zustandskomponente $\xi^\dot{\varphi}$ eingeführt, die als zweite Speichervariable neben der Gierbeschleunigung zur Modellierung des schwingfähigen Systems (4.31) benötigt wird. Wird der Zustandsvektor noch um die eigentlich interessierende Gierrate erweitert erhält man das Systemmodell

$$\dot{\mathbf{x}}^\dot{\varphi} = \mathbf{A}^\dot{\varphi} \mathbf{x}^\dot{\varphi} + \mathbf{B}^\dot{\varphi} u^\dot{\varphi} \quad (4.47)$$

mit

$$\mathbf{x}^\dot{\varphi} = \begin{bmatrix} \dot{\varphi} \\ \ddot{\varphi} \\ \xi^\dot{\varphi} \end{bmatrix}, \quad \mathbf{A}^\dot{\varphi} = \begin{bmatrix} 0 & 1 & 0 \\ 0 & -2\alpha & 1 \\ 0 & -\alpha^2 - \omega_0^2 & 0 \end{bmatrix}, \quad \mathbf{B}^\dot{\varphi} = \begin{bmatrix} 0 \\ K \\ K\alpha \end{bmatrix}, \quad u^\dot{\varphi} \sim \mathcal{N}(0, 1). \quad (4.48)$$

Die zeitdiskretisierte Lösung der Systemgleichung

$$\mathbf{x}_{t+\Delta t}^\dot{\varphi} = \mathbf{F}^\dot{\varphi}(\Delta t) \mathbf{x}_t^\dot{\varphi} + \mathbf{G}^\dot{\varphi}(\Delta t) u_{t+\Delta t}^\dot{\varphi} \quad (4.49)$$

kann mit

$$\mathbf{F}^\dot{\varphi}(\Delta t) = \mathcal{L}_{s \rightarrow \Delta t}^{-1} \{ (s\mathbf{I} - \mathbf{A}^\dot{\varphi})^{-1} \} \quad (4.50)$$

$$\mathbf{G}^\dot{\varphi}(\Delta t) = \int_0^{\Delta t} \mathbf{F}^\dot{\varphi}(\Delta t - \tau) \mathbf{B}^\dot{\varphi} d\tau \quad (4.51)$$

$$u_{t+\Delta t}^\dot{\varphi} \sim \mathcal{N}(0, 1) \quad (4.52)$$

berechnet werden [5]. Als Lösung erhält man

$$\mathbf{F}^\dot{\varphi}(\Delta t) = \frac{e^{-\alpha\Delta t}}{\omega_0} \begin{bmatrix} \omega_0 e^{\alpha\Delta t} & C_1 & (\omega_0 e^{\alpha\Delta t} - \omega_0 C_2 - \alpha C_1) C_3^{-1} \\ 0 & C_2 - \alpha C_1 & C_1 \\ 0 & C_1 C_3 & \omega_0 C_2 + \alpha C_1 \end{bmatrix} \quad (4.53)$$

$$\mathbf{G}^\dot{\varphi}(\Delta t) = \frac{K}{C_3} \begin{bmatrix} [e^{-\alpha\Delta t}(C_2(\alpha^2 - \omega_0^2) - 2\omega_0\alpha C_1) + \Delta t(\alpha^3 + \alpha\omega_0^2) - \alpha^2 + \omega_0^2] C_3^{-1} \\ e^{-\alpha\Delta t}(-\alpha C_2 - \omega_0 C_1) - \alpha \\ e^{-\alpha\Delta t}(C_2(\omega_0^2 - \alpha^2) + 2\omega_0\alpha C_1) + \alpha^2 - \omega_0^2 \end{bmatrix} \quad (4.54)$$

$$C_1 = \sin(\omega_0\Delta t), \quad C_2 = \cos(\omega_0\Delta t), \quad C_3 = \alpha^2 + \omega_0^2.$$

Trotz der Komplexität dieser Matrizen handelt es sich für ein Messsystem mit gleichbleibender Messperiode $\Delta t = T_S$ um Konstanten, die vorab berechnet werden können. Wenn das Messsystem einzelne Sensordatenpakete verwirft, um Echtzeitanforderungen zu genügen, oder anderweitige Messausfälle zu erwarten sind, müssen die Matrizen eventuell noch zusätzlich für einige ganzzahlige Vielfache von T_S vorberechnet werden. Für die Tangentialgeschwindigkeit

v^e wird das diskrete Filter für den Zustandsvektor $\mathbf{x}^v = (v \ a \ \xi^v)^T$ mit den entsprechenden Filterparametern analog realisiert.

Die Funktionsweise dieses Formfilters kann so interpretiert werden, dass sich beispielsweise während des Einlenkens in eine Linkskurve (positive Gierbeschleunigung) eine Feder spannt, deren potenzielle Energie in der Speichervariable ξ^φ akkumuliert wird, und die nach Ablauf der Zeit $1/2\omega_0^\varphi$ das Prozessmodell des Fahrzeugs zum Zurücklenken (negative Gierbeschleunigung) zwingt. Analog wird beim Beschleunigen und Bremsen potenzielle Energie aufgebaut die nach der Zeit $1/2\omega_0^a$ den gegenteiligen Vorgang einleitet. Dies entspricht exakt dem durch die Autokorrelationsfunktionen identifizierten mittleren Fahrverhalten.

Stabilität

Ein LZI-System ist dann stabil, wenn seine Polstellen auf der imaginären Achse oder in der linken komplexen Halbebene liegen, d.h. alle Eigenfunktionen entweder gedämpft sind oder eine konstante Amplitude für die gesamte Zeitachse aufweisen. Beobachter mit instabilen Systemmodellen divergieren spontan vom tatsächlichen Zustand. Für das beschriebene Prozessmodell existieren fünf Polstellen:

$$\text{Eig} \begin{bmatrix} \mathbf{A}^v & \mathbf{0} \\ \mathbf{0} & \mathbf{A}^\varphi \end{bmatrix} = [0, -\alpha^v + j\omega_0^v, -\alpha^v - j\omega_0^v, -\alpha^\varphi + j\omega_0^\varphi, -\alpha^\varphi - j\omega_0^\varphi]. \quad (4.55)$$

Als Stabilitätsbedingung gilt daher:

$$\alpha^v, \alpha^\varphi \geq 0. \quad (4.56)$$

Da für Autokorrelationsfolgen immer $\phi(0) > \phi(\kappa \neq 0)$ gilt [78], kann die exponentielle Hüllkurve von (4.31) nur gedämpft sein. Damit ist die Stabilitätsbedingung immer erfüllt.

4.4.2 Messmodellierung für das ESP-System

Das ESP-System enthält Sensorik für die vier Raddrehzahlen $R_{VL}, R_{VR}, R_{HL}, R_{HR}$ (VL=vorn links, HR=hinten rechts, u.s.w.) und die Fahrzeuggierrate $\dot{\varphi}$. Diese Größen bilden den Messvektor der Eigenbewegungsschätzung $\mathbf{z}^e$. Weiterhin werden die Querschleunigung $\ddot{y}$ und der Lenkradeinschlagwinkel δ gemessen. Die Gründe für die Auslassung dieser Größen im folgenden Messmodell liegen in der ungenügenden Messgüte des zur Verfügung stehenden Querschleunigungssensors, insbesondere bezogen auf dessen volatilen systematischen Messfehler, und der Tatsache, dass der Lenkradwinkel eine unbekannte, hersteller- und fahrzeugspezifische, nicht lineare und eventuell nicht stationäre Beziehung zum tatsächlichen Radeinschlagwinkel (Ackermann-Winkel) aufweist, deren Identifikation außerhalb des Fokus dieser Arbeit liegt.

$$\mathbf{z}^e = [R_{VL} \ R_{VR} \ R_{HL} \ R_{HR} \ \dot{\varphi}]^T \quad (4.57)$$

Aus den in Abbildung 4.21 dargestellten geometrischen Beziehungen bei einer Ackermann-Lenkung folgen für (4.57) die Messgleichungen $h^e(\mathbf{x}^e)$ (Lemma 18, Anhang A, Seiten 189 ff.):

$$R_{VL} = \frac{30}{U_R} \sqrt{4(v^e)^2 - 4v^e\dot{\varphi}^e l_S + l_S^2(\dot{\varphi}^e)^2 + 4l_R^2(\dot{\varphi}^e)^2}$$

$$R_{VR} = \frac{30}{U_R} \sqrt{4(v^e)^2 + 4v^e\dot{\varphi}^e l_S + l_S^2(\dot{\varphi}^e)^2 + 4l_R^2(\dot{\varphi}^e)^2}$$

heiten im Messmodell, Seite 122). Wenn umgekehrt hochgenaue Referenzsensoren direkt für die Raddrehzahlen am Fahrzeug angebracht werden, ist eine Unterschätzung des Messrauschens zu erwarten, weil nicht sensorisch bedingte Messfehler ebenfalls im Referenzsignal enthalten sind. Dies sind Messfehler, die aus Radschlupfeffekten und den durch unebene Fahrbahnbeläge verursachten Oberschwingungen in der Drehbewegung resultieren.




Abbildung 4.22: Binde Extraktion des Rauschsignals – Oben: Fensterung des Originalsignals um dessen Mittelwert und Approximation des Nutzsignals durch ideale Tiefpassfilterung im Frequenzbereich. Unten: Geschätzter Rauschsignalverlauf nach Subtraktion des niederfrequenten Signalanteils und Kompensation der Fensterfunktion.

Rauschmodellierung für die Raddrehzahlsensoren

Zur Ermittlung des Drehzahl-Messrauschens nach der zweiten Variante wird ein repräsentativer Satz von Messwert-Sequenzen auf unterschiedlichen Fahrbahnen und bei verschiedenen Fahr-situationen und Geschwindigkeiten aufgezeichnet. Im Anschluss erfolgt eine Selektion hinreichend großer Teilintervalle an verschiedenen Zeitpunkten derart, dass die intervallbegrenzenden Messwerte annähernd gleich groß sind. Auf diese Intervalle wird eine Hamming-Fensterfunktion angewendet, um die verbleibenden Unstetigkeiten bei der Periodisierung des Intervalls zu minimieren (Abbildung 4.22/oben). Nach der Fourier-Transformation kommt ein ideales Tiefpassfilter durch Eliminierung aller Frequenzen oberhalb einer Grenzfrequenz von $f_G \approx 1\text{Hz}$ zur

Anwendung. Das rücktransformierte Zeitsignal wird als Schätzung des Nutzsignals und damit als Referenz verwendet. Durch Subtraktion vom Originalsignal und Multiplikation mit der inversen Fensterfunktion entsteht das geschätzte Rauschsignal, mit dessen Hilfe die Modellparameter ermittelt werden (Abbildung 4.22/unten). Dieses Verfahren wurde mit Lernsequenzen aus einem Zeitraum von zwei Jahren an insgesamt 892 Arbeitspunkten durchgeführt. In die




Abbildung 4.23: Nicht-stationäres Messrauschmodell der Drehzahlsensoren. Oben: Stückweise lineare Approximation der Drehzahlabhängigkeit der Standardabweichung. Unten: Die Abklingkonstanten der empirischen Autokorrelationsfolgen des Drehzahlrauschens bei verschiedenen Arbeitspunkten liegen in den für eine ACC-Anwendung interessanten Geschwindigkeitsbereichen unterhalb der Abtastperiode.

empirischen Autokorrelationsfolgen der an den verschiedenen Arbeitspunkten resultierenden Rauschsequenzen wird ein exponentielles Modell mit (4.42) oder (4.43) eingepasst. In Abbildung 4.23/unten sind die ermittelten Abklingzeitkonstanten $1/\alpha^R$ an verschiedenen Arbeitspunkten der Fahrgeschwindigkeit dargestellt. In den für eine ACC-Applikation interessierenden Geschwindigkeitsbereichen sind diese gemessenen Werte vorwiegend kleiner als die Abtastperiode T_S . Daher kann das Messrauschen der Raddrehzahlen bei dieser Abtastfrequenz als weiß modelliert werden.

Die Rauschvarianz zeigt eine starke Abhängigkeit von der Fahrgeschwindigkeit (Abbildung

4.23/oben). Die Standardabweichung steigt tendenziell mit der Geschwindigkeit an, zeigt aber ein welliges Verhalten. Eine mögliche Ursache für das nicht-stationäre Verhalten ist die Frequenzabhängigkeit beider in Frage kommender Drehzahl-Messverfahren (Periodendauermessung und Frequenzmessung [48]). Des Weiteren können die mit der Fahrgeschwindigkeit steigende Intensität von Oberschwingungen in der Drehbewegung aufgrund der rauen Fahrbahnoberfläche und die damit verbundenen Resonanzeffekte zu den Varianzschwankungen führen. Für die Modellierung der Rauschintensität in Abhängigkeit von der Drehzahl wird eine stückweise lineare Hüllkurve $\sigma_R^2(R_{**})$ als Schätzung des Intensitätsverlaufs in die Messwerte gelegt (Abbildung 4.23/oben). Statt einer tatsächlichen Ausgleichskurve wird die Hüllkurve als pessimistischere Abschätzung verwendet, da das vorgestellte Verfahren zur Rauschsignalextraktion die Varianzen tendenziell unterschätzt. Dies liegt an der Tatsache, dass der Beitrag der niederfrequenten Signalanteile des realen weißen Rauschsignals in der Schätzung der Gesamtrauschleistung fehlt, da diese Anteile durch das ideale Tiefpassfilter fälschlicherweise dem Nutzsignal zugeordnet wurden.

Rauschmodellierung für den Gierratensensor

Zur Rauschmodellierung des Gierratensensors kann mit Bestätigung des gleichen Verfahrens, das für die Raddrehzahlen verwendet wurde, die Autokorrelation des Rauschsignals für die gegebene Abtastfrequenz vernachlässigt werden. Weiterhin kann keine systematische Abhängigkeit der Rauschintensität vom Arbeitspunkt festgestellt werden. Die durch das oben beschriebene Verfahren ermittelte mittlere Rauschintensität beträgt:

$$\sigma_{\dot{\varphi}}^2 = 0.1 \left[\begin{smallmatrix} \circ \\ - \\ s \end{smallmatrix} \right]^2. \quad (4.59)$$

Zusätzlich steht ein hochgenaues Referenzsignal $\dot{\varphi}^{REF}$ für die Fahrzeugdrehrate durch Verwendung eines RTK-GPS Empfängers zur Verfügung. Mit dessen Hilfe und der Annahme, dass das Referenzsignal keinen systematischen Fehler aufweist, lässt sich die Varianz des Gierraten-Rauschsignals durch Subtraktion des quadrierten systematischen Messfehlers des Fahrzeugsensors und der Messfehlervarianz des Referenzsignals von der Varianz des Differenzsignals von Referenz und Messung berechnen:

$$\sigma_{\dot{\varphi}}^2 = E\{(\dot{\varphi} - \dot{\varphi}^{REF})^2\} - (E\{\dot{\varphi}\})^2 - \sigma_{\dot{\varphi}^{REF}}^2. \quad (4.60)$$

Mit dieser Methode wurde ein Wert von

$$\sigma_{\dot{\varphi}}^2 = 0.085 \left[\begin{smallmatrix} \circ \\ - \\ s \end{smallmatrix} \right]^2 \quad (4.61)$$

ermittelt. Für die Filterauslegung wird die pessimistischere Abschätzung nach dem ersten Verfahren verwendet.

Parameterunsicherheiten im Messmodell

Die Messgleichungen (4.58) beinhalten die Parameter U_R , l_S und l_R , die zum einen nur messtechnisch fehlerbehaftet bestimmt werden können und zum anderen tatsächlichen zeitlichen




Abbildung 4.24: Sensitivität der Messwertprädiktion für die Raddrehzahl $\hat{R}_{V*}$ bei Veränderungen des Parameters Radstand l_R . Das Diagramm zeigt Iso-Gradientenlinien in Abhängigkeit vom Geschwindigkeits-Gieraten-Arbeitspunkt.




Abbildung 4.25: Sensitivität der Messwertprädiktion für die Raddrehzahl $\hat{R}_{V*}$ bei Veränderungen des Parameters Spurbreite l_S . Das Diagramm zeigt Iso-Gradientenlinien in Abhängigkeit vom Geschwindigkeits-Gieraten-Arbeitspunkt.

Veränderungen unterliegen. Die Spurbreite und der Radstand sind zwar aus den Konstruktionsdaten mit hoher Genauigkeit bekannt, beim Einfedern wird jedoch die Radaufhängung nach außen gedrückt, so dass sich die Spurbreite vergrößert. Gleichmaßen verändert sich der Radstand, wenn die Achsen unterschiedlich weit einfedern. Die maximale Vergrößerung des Radstandes ergibt sich dann aus dem Satz von Pythagoras bei maximaler Federkontraktion einer Achse und gleichzeitiger maximaler Federexpansion der anderen Achse. Der Radumfang - in der Literatur deshalb oft als dynamischer Radumfang bezeichnet - variiert durch Betrieb mit unterschiedlichem Reifenluftdruck, Außentemperaturschwankungen und verschiedenen Belastungs- und Beladungszuständen. Um eine Sensitivitätsanalyse der Messwertprädiktion auf Parametervariationen durchzuführen, wird die Jacobimatrix der Messfunktion (4.58) bei Differentiation nach den Parametern am Arbeitspunkt der aktuellen Zustandsschätzung $\hat{\mathbf{x}}^e$ untersucht. Da die Parameter nur in den Messgleichungen für die Raddrehzahlen vorkommen, wird die




Abbildung 4.26: Sensitivität der Messwertprädiktion für die Raddrehzahl $\hat{R}_{**}$ bei Veränderungen des Parameters Radumfang U_R . Das Diagramm zeigt den Gradient in Abhängigkeit vom Geschwindigkeits-Arbeitspunkt.

Messwertprädiktion der Gierrate nicht beeinflusst. Es sei hier bemerkt, dass die Parametervariationen dennoch einen Einfluss auf die Gierraten-Schätzung ausüben, da die Raddrehzahlen auch als Messung für die Gierrate eingebracht werden. Der Parameter für den Radstand beeinflusst nur die Prädiktion der vorderen Raddrehzahlen. Abbildung 4.24 zeigt den entsprechenden Gradienten in Abhängigkeit vom Fahrzustand. Es ist ersichtlich, dass dieser Parameter nur bei langsamen Fahrgeschwindigkeiten und gleichzeitig hoher Gierrate einen signifikanten Einfluss ausübt, d.h. genau für die typischen Fahrsituationen einer ACC-Anwendung unkritisch ist.

Abbildung 4.25 stellt die Abhängigkeit der Messwertprädiktion der Drehzahl für die vorderen Räder von der Spurbreite dar. Dominant ist hier der Einfluss der momentanen Gierrate im Gegensatz zur Geschwindigkeit, die bei den vorderen Drehzahlen nur im sehr niedrigen Bereich nennenswerten Einfluss ausübt. Bei den Hinterrädern entfallen die gekrümmten Flächen in diesen niedrigen Geschwindigkeitsbereichen, so dass die Messwertprädiktion hier vollständig geschwindigkeitsunabhängig wird. Bei der Sensitivität bezüglich des Radumfanges besteht lediglich eine Arbeitspunktabhängigkeit von der Momentangeschwindigkeit. Diese Abhängigkeit ist erwartungsgemäß umgekehrt proportional zum Radumfang (Abbildung 4.26). Bemerkenswert ist das Verhältnis der Parametersensitivitäten untereinander. Da sich die Abweichungen bzw. Unsicherheiten der drei Parameter alle in gleichen Größenordnungen von wenigen Zentimetern bewegen, dominiert die Sensitivität bezüglich des Radumfanges die anderen Parameter um mindestens eine Größenordnung. Bei der Propagierung von Unsicherheiten wirkt sich der Gradient sogar quadratisch aus. Daher ist leicht ersichtlich, dass eine Unsicherheit von nur wenigen Zentimetern auf dem Parameter Radumfang bereits das gesamte identifizierte Messrauschen der Drehzahlsensoren betragsmäßig weit übersteigt. Für die Parameterunsicherheiten wird jeweils die maximal mögliche Abweichung als 3σ -Schranke angesetzt.

4.4.3 Filterung durch das Extended-Kalman-Filter

Das komplette Prozessmodell für die Fahrzeugeigenbewegung entsteht durch Konkatenation der beiden Komponenten Gieren und Tangentialbewegung, in denen die Formfilter für das Prozessrauschen bereits enthalten sind, und eines brownischen Bewegungsmodells für den sys-

tematischen Messfehler des Gierratensensors:

$$\mathbf{x}_{t+\Delta t}^e = \mathbf{F}^e \mathbf{x}_t^e + \mathbf{v}_t^e \quad (4.62)$$

$$\mathbf{x}^e = [v \ a \ \xi^v \ \dot{\varphi} \ \ddot{\varphi} \ \xi^{\dot{\varphi}} \ o^{\dot{\varphi}}]^T. \quad (4.63)$$

Dabei ist eine Schätzung der Offset-Parameter der MEMS-Sensoren nur deshalb möglich, weil durch die vier Raddrehzahlen eine unabhängige und vollständige Beobachtbarkeit der Gierrate gegeben ist. Da das Messrauschen der Raddrehzahlen beim völligen Stillstand des Fahrzeugs modellgemäß am geringsten ist (Abbildung 4.23/oben) und die Messung daher in diesen Situationen am präzisesten ist, werden die Schätzungen der systematischen Fehler aufgrund der sich ergebenden maximalen Filterverstärkungen vorrangig in diesen Phasen angepasst. Es hat sich als Vorteilhaft erwiesen, den Gierratenoffset nicht permanent mit zu schätzen, sondern eine Modellierung als stationären Parameter vorzunehmen, d.h. eine Anfangsunsicherheit zu modellieren und die entsprechende Komponente des Prozessrauschens auf Null zu setzen. Lediglich bei Erkennung des vollständigen Anhaltens des Fahrzeugs wird die Schätzfehlerkovarianz dieses Parameters neu initialisiert, um den langsamen sicherlich temperaturabhängigen Drift zu kompensieren. Die blockweise kombinierten Systemmatrizen lauten:

$$\mathbf{F}^e = \begin{bmatrix} \mathbf{F}^v & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \mathbf{F}^{\dot{\varphi}} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & 1 \end{bmatrix}, \quad \mathbf{v}_t^e \sim \mathcal{N}(\mathbf{0}, \mathbf{Q}^e), \quad \mathbf{Q}^e = \begin{bmatrix} \mathbf{G}^v(\mathbf{G}^v)^T & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \mathbf{G}^{\dot{\varphi}}(\mathbf{G}^{\dot{\varphi}})^T & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & 0 \end{bmatrix}. \quad (4.64)$$

Die Messgleichung beinhaltet die Linearisierung der Messfunktion (4.58) um die aktuelle Zustandsschätzung und den Messrauschvektor:

$$\mathbf{z}_t^e = \mathbf{H}^e \mathbf{x}_t^e + \mathbf{w}_t^e \quad (4.65)$$

$$\mathbf{H}^e = \nabla_{\mathbf{x}^e} h^e(\mathbf{x}^e)|_{\hat{\mathbf{x}}^e}, \quad \mathbf{w}_t^e \sim \mathcal{N}(\mathbf{0}, \mathbf{R}^e) \quad (4.66)$$

$$\mathbf{R}^e = \begin{bmatrix} \sigma_R^2(R_{VL}) & 0 & 0 & 0 & 0 \\ 0 & \sigma_R^2(R_{VR}) & 0 & 0 & 0 \\ 0 & 0 & \sigma_R^2(R_{HL}) & 0 & 0 \\ 0 & 0 & 0 & \sigma_R^2(R_{HR}) & 0 \\ 0 & 0 & 0 & 0 & \sigma_{\dot{\varphi}}^2 \end{bmatrix}. \quad (4.67)$$

Die Kovarianzmatrizen des Messrauschens und des Prozessrauschens sind zeitvariant. Aus diesem Grund kann kein Filter mit konstanter Verstärkung (α, β, γ -Tracker, [5]) verwendet werden. Aufgrund der zusätzlichen Nichtlinearität des Messmodells wird ein Extended-Kalman-Filter [42, 5] auf (4.62) und (4.65) angewendet. Sollten für weitere Sensoren zeitliche Autokorrelationen des Messrauschens festgestellt werden, so können deren Messdaten mit dem Verfahren nach Bryson und Hendrikson [13] in das Filter eingebracht werden.

Die im vorherigen Abschnitt besprochenen Parameterunsicherheiten im Messmodell beeinflussen die Messwertprädiktion. Daraus folgt, dass bei falschen Parametern falsche Residuen und falsche Innovationen berechnet werden. Um diese Fehler zu berücksichtigen muss die Fehlerkovarianz der Messwertprädiktion und damit auch die Innovationskovarianz um die Parameterunsicherheiten vergrößert werden. Dies geschieht mit Hilfe der Jacobi-Matrix der Messfunktion bei Differentiation nach dem Parametervektor $\mathbf{p}_h = [U_R \ l_S \ l_R]^T$:

$$\mathbf{J}^p = \nabla_{\mathbf{p}_h} h^e(\mathbf{x}^e)|_{\hat{\mathbf{x}}^e}. \quad (4.68)$$

Obwohl nicht alle Parameter für die Fahrzustände der fokussierten ACC-Anwendung relevant sind, werden alle Parameterunsicherheiten eingebracht, um die Anwendung des Eigenbewegungsmoduls auch für andere Funktionen zu ermöglichen. Die Parameterunsicherheiten sind in der Parameterfehlerkovarianzmatrix $\mathbf{P}_p$ erfasst,

$$\mathbf{P}^p = \begin{bmatrix} \sigma_{U_R}^2 & 0 & 0 \\ 0 & \sigma_{l_S}^2 & 0 \\ 0 & 0 & \sigma_{l_R}^2 \end{bmatrix} \quad (4.69)$$

und die Kalman-Filter-Gleichung zur Berechnung der Innovationskovarianz (2.56) wird entsprechend ergänzt:

$$\mathbf{S}^e = \mathbf{H}^e \mathbf{P}^e (\mathbf{H}^e)^T + \mathbf{J}^p \mathbf{P}^p (\mathbf{J}^p)^T + \mathbf{R}^e. \quad (4.70)$$

Effektiv bedeutet diese Modifikation eine Vergrößerung des Messrauschens für die Raddrehzahlsensoren und damit eine Schwächung des Einflusses dieser Sensoren auf den geschätzten Zustand im Vergleich zum Gierratensensor und zum Prozessmodell. Bei bestimmten Arbeitspunkten wird auch das Gewicht der Messungen der Vorderräder im Vergleich zu den Hinterrädern verringert.

4.4.4 Optimierung und Evaluierung

Die in der Prozessmodellierung identifizierten Intensitäten des Prozessrauschens spiegeln die mittleren Gier- bzw. Tangentialbeschleunigungen für den gesamten Sequenzen-Satz in der Lernstichprobe wieder. Diese Werte liegen zwischen sehr niedrigen Beschleunigungen in geraden unbeschleunigten Fahrphasen und sehr hohen Werten bei kurvenreichen Abschnitten mit stark variierenden Geschwindigkeiten. Gerade in letzteren Situationen werden daher die über die Zeit gemittelten Beschleunigungswerte nicht ausreichen, damit das Prozessmodell der tatsächlichen Trajektorie folgen kann. Da aus diesem Grund eine so genannte Manöverreserve zur Prozessrauschintensität addiert werden muss, werden die Verstärkungsparameter der Formfilter des Prozessrauschens zu Optimierungsvariablen. Als Gütefunktion der Optimierung wird die Filterkonsistenz bei einer hochdynamischen Fahrphase verwendet.

Mit Filterkonsistenz im strengeren Sinne ist die Übereinstimmung der tatsächlichen Wahrscheinlichkeitsverteilung der Schätzfehler mit der vom Zustandsfilter berechneten Unsicherheit der Schätzung zu verstehen. In der ingenieurtechnischen Praxis – und in nahezu allen Publikationen zur Fahrzeugumfelderfassung – gelten Filter im weiteren Sinne als konsistent, wenn die Wahrscheinlichkeitsverteilungsfunktion der tatsächlichen Messfehler nach unten durch die vom Filter berechnete Verteilungsfunktion beschränkt ist, also der Fehler auf keinen Fall unterschätzt wird. Eine Überschätzung, d.h. die Berechnung zu großer Unsicherheitsbereiche, wird dagegen akzeptiert, weil die Aussage, dass der tatsächliche Wert einer Zustandsgröße innerhalb des berechneten Unsicherheitsbereiches liegt, weiterhin gültig ist.

Bei der Optimierung wird strenge Filterkonsistenz in einer sehr hochdynamischen Verkehrsszene durch entsprechende Parametrisierung erzeugt. Die Manöverreserve ergibt sich dann aus der Tatsache, dass reguläre Fahrsituationen weniger Dynamik aufweisen. Die Berechnung des tatsächlichen Schätzfehlers $\tilde{\mathbf{x}}^e$ erfolgt ausschließlich mit dem Referenz-Geschwindigkeits- und Gierratensignal eines RTK-GPS Empfängers mit integrierter hochgenauer Inertialsensorik

(IMU). Es werden also die weiteren Zustandsgrößen, wie zum Beispiel die Beschleunigungen, nicht berücksichtigt. Bei der Berechnung des normierten Schätzfehlerquadrates (NEES, ϵ) geht die Literatur von einem absolut präzisen Referenzsignal aus [5]. Da aber auch die Signale hochgenauer Referenzsensorik mit – zwar viel geringeren – Unsicherheiten behaftet sind, müssen diese bei der Berechnung des NEES berücksichtigt werden:

$$\epsilon_k = (\tilde{\mathbf{x}}_k^e)^T (\mathbf{P}_k^e + \mathbf{P}_k^{REF})^{-1} \tilde{\mathbf{x}}_k^e. \quad (4.71)$$

Moderne RTK-GPS-IMU-Referenzsysteme geben die zeitabhängige Messfehlerkovarianzmatrix $\mathbf{P}_k^{REF}$ zusammen mit den Messwerten aus, da die Unsicherheiten des Referenzsystems je nach aktueller GPS-Empfangssituation variieren. Damit das Konsistenzmaß noch eine Aussagekraft besitzt, muss immer eine um mindestens eine Größenordnung höhere Genauigkeit der Referenzsensorik im Vergleich zur Fahrzeugsensorik sichergestellt sein.

Wenn die Schätzfehler tatsächlich mit Kovarianz $\mathbf{P}_k^e$ normalverteilt sind, ist der NEES als Summe der quadrierten normierten Schätzfehler der einzelnen Zustandskomponenten χ^2 -verteilt mit $\dim(\tilde{\mathbf{x}}^e)$ Freiheitsgraden [5]. Der Konsistenztest ist damit ein Anpassungstest der empirischen relativen Häufigkeiten der NEES-Werte auf χ^2 -Verteilung und die Optimierungsaufgabe besteht in der Parametervariation bis diese Anpassung erreicht ist.

Bei der im Versuchsfahrzeug verbauten Drehzahlsensorik kann das Drehzahlintervall von 0 bis 25 Umdrehungen pro Sekunde nicht aufgelöst werden. Daher führen die Messwerte einen Sprung über dieses Intervall beim Anhalten und beim Anfahren durch. Das hinterlegte Modell des Eigenbewegungsfilters weist in (4.65) keine Durchgriffsmatrix $\mathbf{D}$ vom Systemeingang, dem Prozessrauschen, zum Systemausgang, den Messwertprädiktionen, auf. Dies bedeutet, dass das Systemmodell zweckmäßigerweise nicht sprungfähig ist (der Grad des Zählerpolynoms in (4.46) ist kleiner als der Grad des Nennerpolynoms). Wäre dies der Fall, könnten Sprünge in der Anregung, d.h. im Beschleunigungsrauschen direkt auf die Zustandsvariablen und dann auf die Messwertprädiktionen durchgreifen, wodurch die gewünschten Glättungseigenschaften des Filters verloren gehen würden. Für die Anwendung bedeutet dies, dass keine Möglichkeit existiert, mit der das Prozessmodell dem Messwertsprung folgen kann und gleichzeitig in allen anderen Fahrsituationen glättend wirkt, weil der Durchmesser des übersprungenen Intervalls das identifizierte Messrauschen weit übersteigt. Deshalb muss eine Filterinkonsistenz beim Anfahren und Anhalten toleriert werden (siehe Abbildung 4.27/erste und zweite von oben), und diese Phasen werden von der Filterparametrisierung ausgenommen. Hier stellt sich die Frage, inwieweit diese Sensorik für „Stop-and-Go“-Anwendungen verbessert werden muss. Wenn die NEES-Werte von N Zustandschätzungen χ^2 -verteilt mit n Freiheitsgraden sind, so ist die Summe der N NEES-Werte χ^2 -verteilt mit nN Freiheitsgraden. Als skalare Optimierungsgüte wird daher die quadratische Distanz dieser Summe zum 50%-Quantil der χ^2 -Verteilung mit nN Freiheitsgraden verwendet:

$$[K^a \ K^{\ddot{\varphi}}]_{opt} = \underset{K^a, K^{\ddot{\varphi}}}{\operatorname{argmin}} \left[Q_{\chi^2}(0.5, nN) - \sum_{k=1}^N \epsilon_k \right]^2. \quad (4.72)$$

Tabelle 4.7 zeigt die Lage der Summe der NEES-Werte nach der Optimierung im Konfidenzintervall der entsprechenden χ^2 -Verteilung mit einem Signifikanzniveau von 5%, aufgeschlüsselt für die Geschwindigkeit, die Gierrate und für die Kombination beider Zustandskomponenten.




Abbildung 4.27: Güteabschätzung des Eigenbewegungsfilters mit hochgenauer Referenz. Die Rad-drehzahlmessung zeigt eine Unstetigkeit im Intervall von $[0..25]$ Umdrehungen pro Minute, d.h. das Intervall von 0 bis 0.8 ms^{-1} wird bei der Geschwindigkeitsmessung (oben) übersprungen. Da das Prozessmodell für ein Glättungsfilter zweckmäßigerweise nicht sprungfähig ist, wird das Filter beim Anhalten und Anfahren unvermeidbar inkonsistent (zweite von oben). Das Filter muss deshalb auf Konsistenz außerhalb dieser Unstetigkeitsphasen ausgelegt werden, wie in den beiden unteren logarithmischen Schätzfehlerdiagrammen für Geschwindigkeit und Gierrate dargestellt. Die Inkonsistenzen müssen mit der vorhandenen Sensorik toleriert werden.

In Abbildung 4.27 sind die einzelnen NEES-Werte zusammen mit dem 99%-Quantil der entsprechenden χ^2 -Verteilung über der Zeit dargestellt. Die Abbildungen 4.28 und 4.29 zeigen




Abbildung 4.28: Empirische relative Häufigkeiten des normierten Schätzfehlerquadrats (NEES) in einer Teststichprobe (grau) sowie deren theoretische Verläufe (schwarz) für die Geschwindigkeit (links) und die Gierrate (rechts).




Abbildung 4.29: Empirische relative Häufigkeiten der Teststichprobe (grau) sowie theoretische Verläufe (schwarz) für den kombinierten NEES-Wert der geschätzten Geschwindigkeit und Gierrate.

Tabelle 4.7: Anpassungstest der empirischen NEES-Werte auf χ^2 -Verteilung mit $1.5 \cdot 10^4$ Stichproben.

Komponente	n -#Freiheitsgrade	$Q_{\chi^2}(0.05, nN)$	$\sum_{k=1}^N \epsilon_k$	$Q_{\chi^2}(0.95, nN)$
v^e	1	14496.361	14685.444	15061.913
$\dot{\varphi}^e$	1	14496.361	14753.709	15061.913
$v^e + \dot{\varphi}^e$	2	29157.228	29585.722	29957.046

die gute Übereinstimmung der empirischen relativen Häufigkeiten des Auftretens der NEES-Werte in diskreten Intervallen $[a..b]$ mit der theoretischen Zähl-dichtefunktion $f_{\chi^2}^d$, also der diskretisierten χ^2 -Verteilung mit n Freiheitsgraden:

$$f_{\chi^2}^d([a..b], n) = \int_a^b f_{\chi^2}(x, n) dx = \chi^2(b, n) - \chi^2(a, n). \quad (4.73)$$

Durch Integration der geschätzten Gier- und Tangentialgeschwindigkeiten kann die Trajektorie des Fahrzeugs unter Vernachlässigung der höheren Ableitungen aufgezeichnet werden.




Abbildung 4.30: Die durch Integration des geschätzten dynamischen Fahrzustandes aufgezeichnete Trajektorie einer 5 km langen Testfahrt im Vergleich zur digitalen Karte. Der Kreisverkehr wurde zweimal umrundet.

Abbildung 4.30 stellt eine derartige Trajektorie für eine Testfahrt dar, deren Start- und Endposition identisch waren (Ursprung des lokalen Koordinatensystems). Bei einer Gesamtlänge von fünf Kilometern unterscheiden sich die Endpunkte der gemessenen Trajektorie nur um wenige Meter. Für eine ACC-Applikation, bei der die Eigenbewegung nur zur Prädiktion der dynamischen Objektzustände anderer Verkehrsteilnehmer über den Zeitraum einer Messperiode $t \ll 1s$ dient, ist diese Genauigkeit ausreichend.

4.4.5 Diskussion

Ein Zustandsschätzer für die Eigenbewegung eines mit dem ESP-System ausgestatteten Sensorfahrzeugs wurde vorgestellt, dessen freie Parameter auf die Konsistenz der Schätzung in Bezug auf die Daten eines hochgenauen Referenzsystems optimiert wurden. Dabei konnte erstmalig die Autokorrelation der Gier- und Tangentialbeschleunigung im Prozessmodell berücksichtigt werden. Im konkreten Einzelfall wird das ermittelte Prozessmodell jedoch genau so wenig der

momentanen Realität entsprechen, wie ein Modell mit weißem Beschleunigungsrauschen. Im Mittel liegt das Modell aber näher an den tatsächlichen Beschleunigungsverläufen, weil es gerade deren statistische Eigenschaften wiedergibt.

Um eine bessere Anpassung des Bewegungsmodells an das momentane Manöver zu ermöglichen, wäre eine Modifikation des vorgestellten Systems denkbar, die getrennte Modelle mit unterschiedlichen Parametern für verschiedene Fahrumgebungen, wie zum Beispiel Autobahnen und Innenstädte, aufstellt und diese anhand einer Fahrzeugeigenlokalisierung auf einer Karte mit Straßentypinformationen dann entsprechend umschaltet. Ebenso ist der Betrieb eines „Interacting-Multiple-Model“-Filters (IMM, [8, 61]) denkbar, das nicht – wie in der Literatur beschrieben – Modelle unterschiedlicher Struktur mischt, sondern eine situationsadaptive Überlagerung mehrerer Prozessmodelle des vorgestellten Typs mit unterschiedlichen Verstärkungsfaktoren, Eigenfrequenzen und Abklingzeitkonstanten berechnet.

Weiterhin können die Autokorrelationsfolgen als Datenbasis der Prozessmodellierung während der Fahrt dauerhaft neu berechnet werden, so dass eine gleitende Anpassung der Modellparameter an den Fahrer und die Fahrumgebung möglich ist. Die dabei ermittelten Parameter sind auch potenziell geeignete Merkmale für die Situationsanalyse, um das Fahrerverhalten zu klassifizieren. Es ist dabei zu erwarten, dass sportlichere und weniger vorausschauende Fahrer höhere Verstärkungsfaktoren, kürzere Abklingzeitkonstanten und größere Eigenfrequenzen in den Beschleunigungsmodellen aufweisen.

Eine weitere lohnende Erweiterung ist die Verwendung der Daten eines GPS-Empfängers aus einem Navigationssystem, mit dessen Hilfe ebenfalls eine gleitende Neubestimmung des Parameters Radumfang durch die Kenntnis der zurückgelegten Wegstrecke möglich wird. Eine genauere Kenntnis dieses das Schätzergebnis stark beeinflussenden und von mehreren bereits beschriebenen Einflussfaktoren abhängigen Parameters kann die Unsicherheit der Schätzung weiter reduzieren, wie oben gezeigt wurde.

4.5 Prozess- und Messmodellierung

Im Gegensatz zur klassischen Mehrobjektverfolgung müssen für die Anwendung FISST-basierter Verfahren Prozess- und Messmodelle sowohl für die Zustandsgrößen als auch für die Existenzkomponente angegeben werden. In Summe werden daher im folgenden Abschnitt vier statt der klassischen zwei Modelle vorgestellt.

4.5.1 Das Prozessmodell der Zustandsgrößen

Die Wissensrepräsentation beschreibt die 3D-Positionen der anderen Fahrzeuge zu jedem Zeitpunkt im fahrzeugfesten Koordinatensystem des Sensorfahrzeuges mit dem Koordinatentripel $(x^{\text{FK}}, y^{\text{FK}}, z^{\text{FK}})$. Obwohl eine derartige Beschränkung auf Punktziele für ACC-Funktionen genügen würde, wird zusätzlich die Objektbreite w als Parameter mitgeschätzt, damit das Prozessmodell unter Verwendung anderer Sensorik auch für Nahbereichsprobleme wie die knappe Vorbeifahrt und für „PreCrash“-Algorithmen verwendet werden kann. Neben der Position und Abmessung interessiert noch der relative Orientierungswinkel φ der anderen Fahrzeuge zum

Sensorfahrzeug in der XY-Ebene. Die Dynamik eines beobachteten Objektes ist durch dessen Gierrate $\dot{\varphi}$ und Bahngeschwindigkeit v über Grund bestimmt. In der Literatur wurden Ansätze untersucht [5], in denen die Richtung des Geschwindigkeitsvektors nicht der Fahrzeugorientierung φ entspricht. Bei diesen sogenannten „freie Masse“-Modellen wird der Geschwindigkeitsvektor durch seine x- und y-Komponenten zusätzlich zur Fahrzeugorientierung φ geschätzt. Diese Modellierung führt einen weiteren Freiheitsgrad in die Systembeschreibung ein, der in der Realität nur in Extremsituationen mit signifikantem Radschlupf und signifikanten Schwimmwinkeln realisiert wird. In regulären Fahrsituationen ist eine derartige Beschreibung jedoch überbestimmt. In dieser Arbeit wird daher der Zustandsvektor

$$\mathbf{x} = [x^{\text{FK}}, y^{\text{FK}}, z^{\text{FK}}, v, \varphi^{\text{FK}}, \dot{\varphi}, w]^T \quad (4.74)$$

verwendet. Die Zustandsübergänge der Objekte des Umfeldmodells werden zwischen zwei Messzeitpunkten durch drei als unabhängig angenommene Prozesse beeinflusst. Zuerst bewegen sich die Objekte selbst entsprechend ihrer dynamischen Zustände. Zum anderen entstehen durch die Bewegungen des Sensorfahrzeuges in der Fahrbahnebene ebenfalls Zustandsänderungen der beobachteten Objekte im Sensorfahrzeugkoordinatensystem. Zu dieser horizontalen Eigenbewegung kommt die vertikale Eigenbewegung des Sensorfahrzeuges in Form von Nickbewegungen. Die Modelle für diese drei Teilprozesse werden im Folgenden besprochen.

Eigenbewegung des Sensorfahrzeuges in der Fahrbahnebene

Für die Eigenbewegung des Sensorfahrzeuges wird das Ergebnis der Eigenbewegungsschätzung aus Abschnitt 4.4 als unsicherheitsbehafteter Steuereingang in das Prozessmodell eingebracht. Dabei werden lediglich die Eigengeschwindigkeit und die Eigengierrate unter Vernachlässigung aller höheren Ableitungen aus (4.63) berücksichtigt:

$$\mathbf{u}^e = \begin{bmatrix} v^e \\ \dot{\varphi}^e \end{bmatrix}, \quad \mathbf{U}^e = \begin{bmatrix} p_{v^e v^e} & p_{v^e \dot{\varphi}^e} \\ p_{\dot{\varphi}^e v^e} & p_{\dot{\varphi}^e \dot{\varphi}^e} \end{bmatrix}. \quad (4.75)$$

Bei diesem Prädiktionsmodell konstanter Bahngeschwindigkeit und Gierrate verschiebt sich das Sensorfahrzeug zwischen den Zeitschritten t und $t + \Delta t$ in der Fahrbahnebene um den Vektor $[\Delta x^e \ \Delta y^e]^T$ relativ zum Fahrzeugkoordinatensystem des Zeitpunktes t . Gleichzeitig erfährt es aufgrund seiner Eigengierrate eine Orientierungsänderung $\Delta \varphi^e$. Mit den in Abbildung 4.31 illustrierten trigonometrischen Beziehungen und dem Kurvenradius $v^e \cdot (\dot{\varphi}^e)^{-1}$ ergeben sich die genannten Verschiebungsgrößen zu:

$$\Delta \varphi^e = \dot{\varphi}^e \Delta t \quad (4.76)$$

$$\Delta x^e = v^e (\dot{\varphi}^e)^{-1} \sin(\dot{\varphi}^e \Delta t) \quad (4.77)$$

$$\Delta y^e = v^e (\dot{\varphi}^e)^{-1} [1 - \cos(\dot{\varphi}^e \Delta t)]. \quad (4.78)$$

Mit den Verschiebungsgrößen lässt sich zunächst die Transformationsmatrix für die geschätzten XY-Positionen der erfassten Verkehrsteilnehmer vom Sensorfahrzeugkoordinatensystem des Zeitschrittes $t + \Delta t$ rückwärts in das Sensorkoordinatensystem zum Zeitpunkt t angeben:

$$\mathbf{T}^{\text{FK}_{t+\Delta t} \rightarrow \text{FK}_t} = \begin{bmatrix} \cos(\Delta \varphi^e) & -\sin(\Delta \varphi^e) & \Delta x^e \\ \sin(\Delta \varphi^e) & \cos(\Delta \varphi^e) & \Delta y^e \\ 0 & 0 & 1 \end{bmatrix}. \quad (4.79)$$




Abbildung 4.31: Modell der koordinierten Kurvenfahrt.

Die Positionen der verfolgten Fahrzeuge lassen sich im durch die Eigenbewegung verschobenen Fahrzeugkoordinatensystem zum Zeitpunkt $t + \Delta t$ aus den Zuständen im „alten“ Fahrzeugkoordinatensystem zum Zeitpunkt t wie folgt berechnen:

$$\begin{bmatrix} x \\ y \\ 1 \end{bmatrix}_{t+\Delta t}^{FK} = (\mathbf{T}^{FK_{t+\Delta t} \rightarrow FK_t})^{-1} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix}_t^{FK}. \quad (4.80)$$

Daraus ergibt sich das Eigenbewegungsprozessmodell $f_e(\mathbf{x})$ zu

$$\mathbf{x}_{t+\Delta t} = f_e(\mathbf{x}_t) = \begin{bmatrix} \cos(\dot{\varphi}^e \Delta t)x + \sin(\dot{\varphi}^e \Delta t)y - v^e(\dot{\varphi}^e)^{-1} \sin(\dot{\varphi}^e \Delta t) \\ -\sin(\dot{\varphi}^e \Delta t)x + \cos(\dot{\varphi}^e \Delta t)y - v^e(\dot{\varphi}^e)^{-1} [\cos(\dot{\varphi}^e \Delta t) - 1] \\ z \\ v \\ \varphi - \dot{\varphi}^e \Delta t \\ \dot{\varphi} \\ w \end{bmatrix}. \quad (4.81)$$

Für das Extended-Kalman-Filter werden die Zustandsunsicherheiten $\mathbf{P}_t$ der Objektbeobachtungen zum Zeitpunkt t zuzüglich der Eigenbewegungsunsicherheit $\mathbf{U}^e$ auf die Zustandsunsicherheiten zum Zeitpunkt $t + \Delta t$ propagiert:

$$\mathbf{P}_{t+\Delta t} = \mathbf{J}^e \begin{bmatrix} \mathbf{P}_t & \mathbf{0} \\ \mathbf{0} & \mathbf{U}^e \end{bmatrix} (\mathbf{J}^e)^T, \quad \text{mit } \mathbf{J}^e = \left. \frac{\partial f_e}{\partial (x, y, z, v, \varphi, \dot{\varphi}, w, v^e, \dot{\varphi}^e)} \right|_{\hat{\mathbf{x}}_t, \hat{v}^e, \hat{\dot{\varphi}}^e}. \quad (4.82)$$

Für den Fall, dass die Eigengierate verschwindet, d.h. für die Geradeausfahrt, sind die ersten beiden Terme in (4.81) nicht mehr bestimmt. Dieser Fall bedarf einer Sonderbehandlung, die




Abbildung 4.32: Nickbewegungsmodell.

anstatt des Eigenbewegungsmodells $f_e(\mathbf{x}_t)$ dessen Grenzwert $f_e^0(\mathbf{x}_t)$ für die verschwindende Eigengierrate und dessen Jacobimatrix verwendet:

$$\mathbf{x}_{t+\Delta t} = f_e^0(\mathbf{x}_t) = \lim_{\dot{\varphi}^e \rightarrow 0} f_e(\mathbf{x}_t) = [x - v^e \Delta t, y, z, v, \varphi, \dot{\varphi}, w]^T. \quad (4.83)$$

Nickbewegungen des Sensorfahrzeugs

Für die Nickbewegung des Sensorfahrzeugs, dass heißt seine Rotationen in der XZ-Ebene aufgrund von Bodenunebenheiten oder Beschleunigungen, wird vereinfachend eine Rotation um den Koordinatenursprung des Sensorkoordinatensystems in der Mitte der Hinterachse modelliert (Abbildung 4.32). Das Nickprozessmodell f_p (engl. „pitch“) lautet:

$$\mathbf{x}_{t+\Delta t} = f_p(\mathbf{x}_t) = \begin{bmatrix} \cos(\Delta\vartheta)x + \sin(\Delta\vartheta)z \\ y \\ -\sin(\Delta\vartheta)x + \cos(\Delta\vartheta)z \\ v \\ \varphi \\ \dot{\varphi} \\ w \end{bmatrix}. \quad (4.84)$$

Die Unsicherheitspropagation erfolgt für den Steuereingang $\Delta\vartheta$ analog zum horizontalen Eigenbewegungsmodell:

$$\mathbf{P}_{t+\Delta t} = \mathbf{J}^p \begin{bmatrix} \mathbf{P}_t & \mathbf{0} \\ \mathbf{0} & \sigma_{\Delta\vartheta\Delta\vartheta}^2 \end{bmatrix} (\mathbf{J}^p)^T, \quad \text{mit } \mathbf{J}^p = \left. \frac{\partial f_p}{\partial (x, y, z, v, \varphi, \dot{\varphi}, w, \Delta\vartheta)} \right|_{\hat{\mathbf{x}}_t, \Delta\vartheta}. \quad (4.85)$$

Fremdbewegte Objekte

Nach dem gleichen Kurvenfahrtsmodell, dass bei der horizontalen Eigenbewegung verwendet wurde, ergeben sich in Analogie zu (4.76)-(4.78) die durch Fremdbewegung verursachten Verschiebungen und Verdrehungen der sensorisch verfolgten Objekte:

$$\Delta\varphi = \dot{\varphi}\Delta t \quad (4.86)$$

$$\Delta x = v(\dot{\varphi})^{-1} \sin(\dot{\varphi}\Delta t) \quad (4.87)$$

$$\Delta y = v(\dot{\varphi})^{-1} [1 - \cos(\dot{\varphi}\Delta t)]. \quad (4.88)$$

Während die Orientierungsänderung $\Delta\varphi$ in allen Bezugssystemen identisch ist, liegt der mit (4.87) und (4.88) berechnete Verschiebungsvektor zwischen den Zeitpunkten t und Δt zunächst im lokalen Fahrzeugkoordinatensystem des beobachteten Objektes zum Zeitpunkt t vor. Damit die Verschiebung auf den Zustandsvektor addiert werden kann, muss sie zuerst in das Fahrzeugkoordinatensystem des beobachtenden Sensorfahrzeuges transformiert werden. Die Transformationsmatrix ist durch den Objektzustand zum Zeitpunkt t gegeben:

$$\mathbf{T}^{\text{OK}_t \rightarrow \text{FK}_t} = \begin{bmatrix} \cos(\varphi) & -\sin(\varphi) & x \\ \sin(\varphi) & \cos(\varphi) & y \\ 0 & 0 & 1 \end{bmatrix}. \quad (4.89)$$

Mit der veränderten Position der fremdbewegten Objekte

$$\begin{bmatrix} x \\ y \\ 1 \end{bmatrix}_{t+\Delta t}^{\text{FK}} = \begin{bmatrix} x \\ y \\ 1 \end{bmatrix}_t^{\text{FK}} + \mathbf{T}^{\text{OK}_t \rightarrow \text{FK}_t} \begin{bmatrix} \Delta x \\ \Delta y \\ 0 \end{bmatrix}_t^{\text{OK}} \quad (4.90)$$

lässt sich das Fremdbewegungsprozessmodell aufstellen:

$$\mathbf{x}_{t+\Delta t} = f_o(\mathbf{x}_t) = \begin{bmatrix} x + v\dot{\varphi}^{-1} [\sin(\dot{\varphi}\Delta t) \cos(\varphi) - \sin(\varphi) \cos(1 - \dot{\varphi}\Delta t)] \\ y + v\dot{\varphi}^{-1} [\sin(\dot{\varphi}\Delta t) \sin(\varphi) + \cos(\varphi) \cos(1 - \dot{\varphi}\Delta t)] \\ z \\ v \\ \varphi + \dot{\varphi}\Delta t \\ \dot{\varphi} \\ w \end{bmatrix}, \quad (4.91)$$

$$\mathbf{P}_{t+\Delta t} = \mathbf{J}^o \mathbf{P}_t (\mathbf{J}^o)^T + \mathbf{Q}, \quad \text{mit } \mathbf{J}^o = \left. \frac{\partial f_o}{\partial (x, y, z, v, \varphi, \dot{\varphi}, w)} \right|_{\mathbf{x}_t}. \quad (4.92)$$

Für den algorithmisch zu behandelnden Grenzfall verschwindender Objektgierraten resultiert daraus das vereinfachte Prozessmodell:

$$\mathbf{x}_{t+\Delta t} = f_o^0(\mathbf{x}_t) = [x + v\Delta t \cos(\varphi), y + v\Delta t \sin(\varphi), z, v, \varphi, \dot{\varphi}, w]^T. \quad (4.93)$$

Über die Prozessfehlerkovarianzmatrix $\mathbf{Q}$ werden die nicht explizit modellierten Tangentialbeschleunigungen, die Gierbeschleunigungen und die z.B. aus Straßenunebenheiten resultierenden Änderungen der z -Position berücksichtigt:

$$\mathbf{Q} = \Delta t^2 \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & \sigma_z^2 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & \sigma_v^2 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & \sigma_{\dot{\varphi}}^2 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}. \quad (4.94)$$

Die Jacobimatrix $\mathbf{J}^o$ propagiert das Prozessrauschen aus den in $\mathbf{Q}$ besetzten Einträgen auch auf die x - und y -Position und die Gierrate φ . Lediglich die Objektbreite w erhält kein Prozessrauschen, da es sich um einen zeitinvarianten Parameter handelt.

Die drei vorgestellten Teilprozessmodelle werden für den Zustandsprädiktionsschritt sukzessive auf die a-posteriori Zustandsschätzung des vorherigen Zeitschrittes angewendet.

die Positionskoordinaten aus dem gesamten Zustandsvektor $\mathbf{x}^{\text{FK}}$ und transformiert diese mit Hilfe der in Abschnitt 4.2.2 (Seiten 89 ff.) bestimmten Lagebeziehung $\mathbf{T}^{\text{FK} \rightarrow \text{LK}} = (\mathbf{T}^{\text{LK} \rightarrow \text{FK}})^{-1}$ in das lokale kartesische Lidarkoordinatensystem (LK). Im Anschluss erfolgt noch eine Umrechnung in polare Lidarkoordinaten (LP):

$$\begin{bmatrix} x^{\text{LK}} \\ y^{\text{LK}} \\ z^{\text{LK}} \\ 1 \end{bmatrix} = \mathbf{T}^{\text{FK} \rightarrow \text{LK}} \mathbf{X} \begin{bmatrix} \hat{\mathbf{x}}_{t+\Delta t|t}^{\text{FK}} \\ 1 \end{bmatrix} \quad (4.99)$$

$$\hat{\mathbf{z}}^{\text{LP}} = h_{\text{LIDAR}}(\mathbf{x}^{\text{FK}}) = \begin{bmatrix} r^{\text{LP}} \\ \varphi^{\text{LP}} \end{bmatrix} = \begin{bmatrix} |(x^{\text{LK}}, y^{\text{LK}})| \\ \arctan \frac{y^{\text{LK}}}{x^{\text{LK}}} \end{bmatrix}. \quad (4.100)$$

Aufgrund der Nichtlinearität der trigonometrischen Anteile wird die Jacobimatrix der Messfunktion für das Extended-Kalman-Filter verwendet:

$$\mathbf{J}^L = \left. \frac{\partial h_{\text{LIDAR}}}{\partial \mathbf{x}^{\text{FK}}} \right|_{\hat{\mathbf{x}}_{t+\Delta t|t}^{\text{FK}}}. \quad (4.101)$$

Der im Sensor verbaute Analog-zu-Digital-Wandler zur Aufzeichnung des reflektierten Laserlichtes arbeitet mit einer Abtastperiode, die einer Entfernungsauflösung von 90 cm entspricht. Durch Interpolation des abgetasteten Signals wird diese Genauigkeit weiter gesteigert. Deshalb wird für die Quantifizierung des Lidar-Messrauschens in Radialrichtung die vom Hersteller angegebene Messgenauigkeit von 10 cm als 1σ -Quantil für die Messfehlerwahrscheinlichkeit angesetzt. Daraus ergibt sich ein 6σ -Fehlerintervall von 60 cm. In Azimuthalrichtung wird lediglich vorausgesetzt, dass mindestens ein Messkanal, der mit dem zu vermessenden Objekt geometrisch überlappt, einen Messwert erzeugt. Die Winkelunsicherheit der Objektposition ergibt sich aus dem Winkelintervall, dass das Objekt aufgrund seiner prädizierten Breite $\hat{w}_{t+\Delta t}$ im polaren Lidarkoordinatensystem einnimmt, zuzüglich der Winkelauflösung des Sensors von einem Grad. Das resultierende Winkelintervall wird als 6σ -Fehlerintervall angesetzt (Abbildung 4.34):

$$\mathbf{R}^L = \begin{bmatrix} 0.01m^2 & 0 \\ 0 & \frac{1}{36} \left[\arctan \frac{\hat{w}_{t+\Delta t}}{r} + \frac{\pi}{180} \right]^2 \end{bmatrix}. \quad (4.102)$$




Abbildung 4.34: Die 6σ -Winkelunsicherheit der Lidarmessung ergibt sich aus dem Winkelintervall $\arctan(\hat{w}_{t+\Delta t}r^{-1})$, dass die Fahrzeugbreite $\hat{w}_{t+\Delta t}$ überstreicht zuzüglich der Winkelauflösung von einem Grad ($\pi/180$ rad).




Abbildung 4.35: Kameramessmodell für die Objektbreite. Senkrecht zur Orientierung des beobachteten Fahrzeuges (oben) werden von der Objektposition zwei Punkte im Abstand der halben Objektbreite generiert. Diese werden separat in das Kamerabild transformiert. Die Differenz der errechneten horizontalen Bildpositionen der zwei Punkte ist die Messwertprädiktion für die Objektbreite.

Zustandsmessung mit der monokularen Kamera

Der Bildsensor ist mit der in Abschnitt 4.3 vorgestellten Signalverarbeitung in der Lage, die Position (i, j) und die Breite b der Abbildungen von Fahrzeugen im Bild zu vermessen. Der Messvektor lautet daher:

$$\mathbf{z}^{BK} = h_{VIDEO}(\mathbf{x}^{FK}) = [i \ j \ b]^T. \quad (4.103)$$

Die Messfunktion für die Objektposition selektiert zunächst die Positionskoordinaten mit der Projektionsmatrix $\mathbf{X}$ (4.98) und transformiert sie anhand der in Abschnitt 4.2.2 (Seiten 92 ff.) ermittelten Transformation $\mathbf{T}^{FK \rightarrow KK}$ in das Kamerakoordinatensystem. Im Anschluss erfolgt die Bildprojektion mit den intrinsischen Kameraparametern durch $\mathbf{T}^{KK \rightarrow BK}$ (4.3) und eine Renormierung der homogenen Bildkoordinaten mit dem Operator $\tilde{h}(\cdot)$ (4.8):

$$\begin{bmatrix} i \\ j \\ 1 \end{bmatrix}^{BK} = \tilde{h} \left(\mathbf{T}^{KK \rightarrow BK} \mathbf{T}^{FK \rightarrow KK} \mathbf{X} \begin{bmatrix} \hat{\mathbf{x}}_{t+\Delta t}^{FK} \\ 1 \end{bmatrix} \right). \quad (4.104)$$

Für die Messfunktion der Objektbreite wird zunächst ein Offsetvektor $\mathbf{o}$ berechnet, mit dessen Hilfe zwei Punkte senkrecht zur Orientierung des beobachteten Fahrzeuges im Abstand der halben Objektbreite von der Objektposition generiert werden (Abbildung 4.35):

$$\mathbf{o} = \left[-\sin(\varphi) \frac{w}{2}, \cos(\varphi) \frac{w}{2}, 0, 0, 0, 0, 0, 0 \right]^T. \quad (4.105)$$

Durch separate Projektion dieser zwei Punkte in das Videobild und Differenzbildung zwischen den errechneten horizontalen Bildpositionen ergibt sich die Messwertprädiktion b für die Objektbreite:

$$b^{\text{BK}} = \left| \mathbf{Y} \hbar \left(\mathbf{T}^{\text{KK} \rightarrow \text{BK}} \mathbf{T}^{\text{FK} \rightarrow \text{KK}} \mathbf{X} \left(\begin{bmatrix} \hat{\mathbf{x}}_{t+\Delta t|t}^{\text{FK}} \\ 1 \end{bmatrix} + \mathbf{o} \right) \right) - \mathbf{Y} \hbar \left(\mathbf{T}^{\text{KK} \rightarrow \text{BK}} \mathbf{T}^{\text{FK} \rightarrow \text{KK}} \mathbf{X} \left(\begin{bmatrix} \hat{\mathbf{x}}_{t+\Delta t|t}^{\text{FK}} \\ 1 \end{bmatrix} - \mathbf{o} \right) \right) \right|. \quad (4.106)$$

Der Operator $\mathbf{Y}$ selektiert hier die horizontale Bildposition i aus den renormierten homogenen Bildkoordinaten:

$$\mathbf{Y} = \begin{bmatrix} 1 & 0 & 0 \end{bmatrix}. \quad (4.107)$$

Aufgrund der Nichtlinearitäten im Lochkameramodell wird auch für die Videoinnovation die Jacobimatrix der Messfunktion im Extended-Kalman-Filter verwendet:

$$\mathbf{J}^V = \frac{\partial h_{\text{VIDEO}}}{\partial \mathbf{x}^{\text{FK}}} \bigg|_{\hat{\mathbf{x}}_{t+\Delta t|t}^{\text{FK}}}. \quad (4.108)$$

Die Quantifizierung des Zustandsmessfehlers für die Bildverarbeitung erfolgt durch eine empirische Auswertung mit einer Referenzstichprobe. Dazu wird die empirische Kovarianz der Residuen zwischen den in der Stichprobe manuell markierten Soll-Bildpositionen $\mathbf{z}_{\text{REF}}^V$ und den von der Bildverarbeitung erzeugten Messungen $\mathbf{z}^V$ berechnet:

$$\mathbf{R}_{\text{emp}}^V = E\{(\mathbf{z}^V - \mathbf{z}_{\text{REF}}^V)(\mathbf{z}^V - \mathbf{z}_{\text{REF}}^V)^T\}. \quad (4.109)$$

Aufgrund der äquidistanten Abtastung des Suchraumes in dreidimensionalen Kamerakoordinaten (Abschnitt 4.3.1, Seiten 100 ff.) ergeben sich durch die perspektivische Projektion verschiedene Messfehlervarianzen in Abhängigkeit von der Objektskalierung im Bild und damit in Abhängigkeit von der Objektentfernung. Abbildung 4.36 zeigt die empirische Auswertung dieser Abhängigkeit. Für die Objektverfolgung wird die Messfehlerkovarianz der Bildverarbeitung durch die in Abbildung 4.36 dargestellten linearen Approximationen am Arbeitspunkt der prädizierten Objektbreite parametrisiert.

4.5.4 Messmodelle für die Existenzkomponente

Mit Hilfe der Existenzmessmodelle werden die messwertindividuellen Falschalarmwahrscheinlichkeiten $p^F(\mathbf{z})$ (3.90) anhand von Sensormerkmalen bestimmt. Zusätzlich muss die sensorspezifische Detektionswahrscheinlichkeit p^D (3.66), d.h. die Wahrscheinlichkeit, dass der Sensor überhaupt eine Messung für ein reales Objekt erzeugt, angegeben werden.

Existenzmessung mit dem Lidar-Sensor

Für den Lidarsensor wurden die relativen Häufigkeiten der Echoamplituden f_{amp} für Falschdetektionen $h_r^{\text{FP}}(f_{\text{amp}})$ und korrekte Detektionen $h_r^{\text{TP}}(f_{\text{amp}})$ anhand einer vorklassifizierten Referenzstichprobe ermittelt (Abbildung 4.37). Mit diesen relativen Häufigkeiten lassen sich die




Abbildung 4.36: Bestimmung der Fehlervarianzen des Fahrzeugrückfrontendetektors für die gemessenen Bildpositionen und Bildbreiten. Die Anhand einer Referenzdatenbank empirisch ermittelten Varianzverläufe über der Objektskalierung werden durch eine lineare Approximation derart angenähert, dass der Messfehler an keinem Arbeitspunkt unterschätzt wird.

Existenzrückschlusswahrscheinlichkeiten $p^\exists(\mathbf{z})$ und die Falschalarmwahrscheinlichkeiten $p^F(\mathbf{z})$ in Abhängigkeit von der Echoamplitude angeben (vgl. 2.17, Seite 10):

$$p^F(\mathbf{z}|f_{amp}) = \frac{h_r^{FP}(f_{amp})}{h_r^{TP}(f_{amp}) + h_r^{FP}(f_{amp})}, \quad (4.110)$$

$$p^\exists(\mathbf{z}|f_{amp}) = \frac{h_r^{TP}(f_{amp})}{h_r^{TP}(f_{amp}) + h_r^{FP}(f_{amp})}. \quad (4.111)$$

Abbildung 4.37 zeigt eine annähernde Gleichverteilung der Lidar-Falschalarmamplituden im Messwertebereich, während die Echoamplituden auf Fahrzeugen zu höheren Werten tendieren.




Abbildung 4.37: Existenzmessmodell für den Lidarsensor. Aus der gemessenen Echoamplitude wird eine Rückschlusswahrscheinlichkeit auf die Objektexistenz berechnet.




Abbildung 4.38: Existenzmessmodell für den Videosensor. Die Rückschlusswahrscheinlichkeit auf die Objektexistenz wird aus der Anzahl der Detektionsboxen pro Cluster berechnet.

Daraus ergibt sich eine mit steigender Amplitude fallende messwertindividuelle Falschalarmwahrscheinlichkeit.

Existenzmessung mit der Mono-Kamera

Für den Videosensor wurde das Kardinalitätsmerkmal f_{size} der in Abschnitt 4.3.2 (Seiten 111 ff.) erzeugten Detektionscluster für das Existenzmodell verwendet. Damit lassen sich die Rückschlusswahrscheinlichkeiten analog zu (4.110) und (4.111) berechnen. Abbildung 4.38 zeigt die relativen Merkmalshäufigkeiten und die Rückschlusswahrscheinlichkeiten für den Videosensor. Im Gegensatz zum Lidarsensor klingen die Merkmalshäufigkeiten für Falschalarme bei steigender Clustergröße schnell ab, während die Clustergrößen für korrekte Detektionen annähernd gleichverteilt sind. Daraus ergibt sich eine schnell mit der Clustergröße abfallende Falschalarmwahrscheinlichkeit. Aus den Abbildungen 4.37 und 4.38 geht weiterhin hervor, dass die

Clustergröße im Vergleich zur Echoamplitude das diskriminanzmerkmale Merkmal ist.

Die Unabhängigkeitsannahme der Existenzmessung

Die in den letzten beiden Abschnitten erzeugten Falschalarmwahrscheinlichkeiten können für die asynchrone Sensordatenfusion verwendet werden. Im hier beschriebenen Prototypsystem werden die Sensoren vollsynchron betrieben und aufgrund der Aufmerksamkeitssteuerung durch Konkatenation der Messvektoren als Metasensor abstrahiert (siehe Abschnitt 4.3.1, Seiten 100 ff.). Daher wird auch eine auf beide Sensormerkmale bedingte Falschalarmwahrscheinlichkeit verwendet, die unter der statistischen Unabhängigkeitsannahme mit uniformer a-priori Klassenwahrscheinlichkeit aus der Bayes-Formel gewonnen wird:

$$p^F(\mathbf{z}|f_{amp}, f_{size}) = \frac{h_r^{FP}(f_{size})h_r^{FP}(f_{amp})}{h_r^{TP}(f_{size})h_r^{TP}(f_{amp}) + h_r^{FP}(f_{size})h_r^{FP}(f_{amp})}. \quad (4.112)$$

Bestimmung der Detektionswahrscheinlichkeit

Die sensorische Detektionswahrscheinlichkeit kann aus einer ROC-Kurve (engl. „Receiver-Operating-Characteristics“) des verwendeten Detektionsalgorithmus gewonnen werden. Für den JIPDA-Algorithmus wird dazu zunächst ein Arbeitspunkt so gewählt, dass so viele Messungen wie möglich vom Detektor an das Verfolgungsmodul weitergegeben werden, auch wenn ein Großteil dieser Messungen große sensorische Falschalarmwahrscheinlichkeiten besitzt. Der ROC-Arbeitspunkt des Detektors liegt demnach für die Verwendung mit dem JIPDA-Algorithmus optimalerweise weit rechts auf dem horizontalen Schenkel der ROC-Kurve (Abbildung 4.39). Wie weit rechts der Arbeitspunkt liegen darf, ist im Wesentlichen durch die zur Ver-




Abbildung 4.39: Bestimmung der Detektionswahrscheinlichkeit p^D aus dem ROC-Arbeitspunkt (schwarzes Rechteck) des verwendeten Objektdetektionsalgorithmus.

fügung stehende Rechenleistung für das Verfolgungsmodul und damit durch die Anzahl der

berechenbaren JIPDA-Hypothesen begrenzt (siehe dazu Abschnitt 5.2, Seiten 158 ff.). Am gewählten Arbeitspunkt des Detektors auf einer repräsentativen vorklassifizierten Teststichprobe entspricht die empirische Detektionsrate der sensorischen Detektionswahrscheinlichkeit p^D .

4.5.5 Diskussion und Kritik

In diesem Abschnitt werden Limitierungen und mögliche Erweiterungsansätze für die vorgestellten Prozess- und Messmodelle diskutiert.

Der Nickprozess und der Beschleunigungsprozess in Fahrtrichtung wurden vereinfachend als statistisch unabhängig modelliert. In der Realität ist jedoch eine starke Korrelation beider Prozesse zu erwarten. Weiterhin wurde das Rotationszentrum des Nickprozesses in den Koordinatenursprung des Fahrzeugkoordinatensystems definiert. Das reale Rotationszentrum der Nickbewegung liegt eher in der Fahrzeugmitte und ist zusätzlich zeitvariant. Der resultierende Modellfehler wird durch die Intensität des Prozessrauschens abgedeckt.

Ein Vorteil des vorgestellten Zustandsprozessmodells ist der sequenzielle modulare Aufbau aus Nick-, tangentialer Eigen- und Fremdbewegung. Dadurch ist es beispielsweise einfach möglich, für die Verfolgung von Fußgängern das Modell der Kurvenfahrt gegen ein Brown'sches Bewegungsmodell auszutauschen und die Nick- und Eigenbewegungskomponenten beizubehalten. Ebenso kann das Nickbewegungsmodell ausgelassen werden, wenn die z-Position der beobachteten Objekte nicht mitgeschätzt werden soll. Zu beachten ist dabei, dass die Prädiktionsoperatoren der einzelnen Komponenten nicht kommutieren und eine Reihenfolgekonvention eingehalten werden muss.

Die Positionsmessfehler des Lidarsensors sind stark von der reflektierten Echopulsbreite und damit von der Reflektivität des vermessenen Objektes abhängig. Ein detaillierteres Messmodell könnte diese Abhängigkeit identifizieren und eine weitere messwertspezifische Messfehlervarianzanzpassung vornehmen.

Die zur Berechnung der sensorischen messwertindividuellen Falschalarmwahrscheinlichkeiten des Lidar-Video-Metasensors verwendete Unabhängigkeitsannahme der Merkmale lässt sich durch die Heterogenität der Sensordaten stützen. Spätestens bei einer Fusion gleichartiger Sensoren ist diese Annahme jedoch nicht mehr adäquat.

Für die Ableitung der sensorischen Falschalarmwahrscheinlichkeiten speziell aus den Detektionen eines Kaskadenklassifikators können noch spezifischere Merkmale verwendet werden, als die hier präsentierten Detektionsclustergrößen. In [80] wurden beispielsweise die Aktivierungen der Klassifikatorknoten vor der Schwellwertbildung (siehe Abbildung 4.16) mit den theoretischen Ergebnissen aus [26] zu sensorischen Existenz- bzw. Falschalarmwahrscheinlichkeiten verarbeitet.

4.6 Beispielszenen zum Einsatz des Prototypsystems

Die Abbildungen 4.40-4.45 illustrieren die Arbeitsweise und Leistungsfähigkeit des Prototypsystems. In der Mitte jeder Abbildung befindet sich eine Darstellung der Lidarrohdaten in der Vogelperspektive. Dabei sind der Messbereich und die Auflösung des Lidar als Fächer repräsentiert. Die eigentlichen Messwerte werden durch schwarze Punkte abgebildet. Im Videobild links sind die Messkanäle des Lidar zusätzlich perspektivisch als graue Geraden eingezeichnet. Die Rhomben auf diesen Geraden entsprechen den schwarzen Echomesswerten in der Vogelperspektive. Ihre horizontalen und vertikalen Abmessungen sind durch die Laserstrahlaufweitung in der Reflektordistanz bestimmt.

Die Ausgaben der bildgestützten Objekterkennung sind als schwarze Rechtecke analog zu Abbildung 4.17 (Seite 111) markiert. In der Vogelperspektive ganz rechts in jeder Abbildung sind die probabilistischen Umfeldmodelle, also die Ausgaben des JIPDA-Filters visualisiert. Hier entspricht das nicht ausgefüllte Rechteck dem Sensorfahrzeug mit dem Eigengeschwindigkeitsvektor, dessen Richtung mit der x-Achse des fahrzeuglokalen Koordinatensystems übereinstimmt. Die ausgefüllten Rechtecke repräsentieren die Objekte des JIPDA-Umfeldmodells. Die a-posteriori Existenzwahrscheinlichkeit der Objekte ist für das Intervall $[0..1]$ grauwertkodiert von leicht grau bis schwarz. Alle Objekte sind nach der geschätzten relativen Orientierung zum Sensorfahrzeug orientiert und mit Geschwindigkeitsvektoren über Grund versehen. Zusätzlich sind für jedes Objekt die Projektionen der a-posteriori Schätzfehlerkovarianzen in den Messraum der (i, j) -Bildpositionen als schwarze Ellipsen ganz links im Videobild eingezeichnet.




Abbildung 4.40: Typische Autobahnsituation mit drei verfolgten Fahrzeugen auf verschiedenen Spuren.




Abbildung 4.41: Die Sensorik und die Signalverarbeitung sind in der Lage, Objekte in großen Distanzen über 150 Metern stabil zu verfolgen.




Abbildung 4.42: Eine Einscherersituation kann anhand exakter Geschwindigkeitsvektoren erkannt werden. Ein sporadischer Falschalarm im Texturhintergrund erzeugt ein Objekt mit niedriger Existenzwahrscheinlichkeit.




Abbildung 4.43: Für die Verfolgung von Gegenverkehr mit großen Differenzgeschwindigkeiten werden exakte Prozessmodelle und Zustandsinitialisierungen für eine korrekte Datenassoziation benötigt.




Abbildung 4.44: Kreuzungssituation mit sechs gleichzeitig verfolgten Objekten. Das zweite Fahrzeug von links im Gegenverkehr wurde erst kürzlich initialisiert und hat daher noch eine geringe Existenzwahrscheinlichkeit. Das Fahrzeug ganz rechts zeigt zusätzlich zur eigentlichen Fahrzeugdetektion noch zwei Falschalarme innerhalb der Fahrzeugtextur. Derartige Konstellationen begünstigen in der klassischen Architektur den Effekt der Objektkoaleszenz (siehe Abschnitt 2.3.4, Seite 31). Die beiden Fahrzeuge in der Mitte haben sich noch nie bewegt und wurden trotzdem stabil erkannt.




Abbildung 4.45: Zwei systematische Falschalarme auf Verkehrsschildern erhalten trotz geringer sensorischer Falschalarmwahrscheinlichkeiten aufgrund ihrer räumlichen Positionsfluktuationen keine hohen Existenzwahrscheinlichkeiten. In jeder sonst funktionsfähigen Parametrisierung der regelbasierten klassischen Systemarchitektur (Abschnitt 2.3, Seiten 24 ff.) haben diese Fehldetektionen fälschlicherweise zu bestätigten Objektrepräsentationen geführt.

Kapitel 5

Experimente

5.1 Das Übertragungsverhalten des JIPDA-Filters

In das Schätzergebnis des JIPDA-Filters fließen verschiedene Eingangsgrößen ein (Abbildung 3.5, Seite 65). Dies sind zum einen die vom Sensor in jedem Zyklus bereitgestellten Daten, d.h. die Messvektoren, die Messfehlerkovarianzen und die sensorischen Falschalarmwahrscheinlichkeiten. Zum anderen geht Modellwissen in Form von Zustandstransitionswahrscheinlichkeiten, von Persistenzwahrscheinlichkeiten, von Detektionswahrscheinlichkeiten und von der räumlichen Messfehlerstatistik ein.

Bei der Auslegung eines JIPDA-Filters müssen für alle beteiligten Sensoren die Messmodellparameter und für die relevante Objektklasse die Prozessmodellparameter jeweils für Zustand und Existenz identifiziert werden. Die exakte JIPDA-Implementierung enthält somit keine „freien“ Designparameter. Die in Abschnitt 3.3.6 (Seiten 70 ff.) vorgestellte Approximation durch Hypothesenverwurf verwendet lediglich den wenig sensitiven Parameter ϱ für die $\varrho\sigma$ -Assoziationsstore (engl. „Gates“).

Obwohl die manuelle oder automatische Optimierung freier und sensorspezifischer Parameter entfällt, ist dennoch der Einfluss der Eingangsgrößen des JIPDA-Filters auf die Ausgangsgrößen von Interesse. Mit Kenntnis dieses Übertragungsverhaltens lassen sich Erweiterungs- oder Einsparpotenziale bei der Sensorauswahl oder der Sensorkombination ausmachen, wenn das JIPDA-Filterergebnis für die Zielfunktionen zu gute oder zu schlechte Ergebnisse liefert.

Für die rekursive Zustandsschätzung, zum Beispiel durch das Kalman-Filter, ist das Übertragungsverhalten bekannt und wird weitgehend durch das Intensitätsverhältnis zwischen Prozess- und Messrauschen bestimmt. Daher werden die folgenden Betrachtungen ausschließlich für den a-posteriori Existenzwahrscheinlichkeitsausgang des JIPDA-Filters durchgeführt.

Neben den eingangs genannten Einflussgrößen ist die Gesamtkonstellation aller Messungen und aller Objekte des Umfeldmodells für die Innovation der Zustände und Existenzwahrscheinlichkeiten jedes einzelnen Objektes maßgeblich (siehe Abschnitt 3.3.5, Seiten 64 ff.). Im Folgenden wird jedoch eine vereinfachte Konstellation mit einer Messung und einem Objekt im Umfeldmodell betrachtet. Für diese Situation ist der vollständige JIPDA-Hypothesenbaum in Ab-




Abbildung 5.1: JIPDA-Assoziationsbaum bei einer Messung und einem Objekt im Umfeldmodell.




Abbildung 5.2: Schematische Darstellung des JIPDA-Filters für maximal eine Messung und maximal ein Objekt im Umfeldmodell.

bildung 5.1 dargestellt. In der betrachteten Konstellation lässt sich das JIPDA-Filter wie in Abbildung 5.2 schematisch darstellen. Mit dieser Einschränkung degeneriert das JIPDA-Filter noch unter das IPDA-Filter (Abschnitt 3.2.4, Seite 45), da im Letzteren immer noch mehrere Messwertassoziationen pro Objekt zulässig wären.

Für die betrachtete Konstellation ergibt sich die Rekursionsvorschrift für die a-posteriori Existenzwahrscheinlichkeit aus Abbildung 5.1, der Existenzprädiktion (3.59) und der Existenzinnovation (3.99) zu:

$$\begin{aligned}
 p_{k|k}^{\Xi}(p^D, p^P, p^F, \Lambda, f_c, p_{k-1|k-1}^{\Xi}) &= \frac{q^D f_c p^F p^P p_{k-1|k-1}^{\Xi} + \Lambda q^F p^D p^P p_{k-1|k-1}^{\Xi}}{f_c p^F (1 - p^P p_{k-1|k-1}^{\Xi}) + q^D f_c p^F p^P p_{k-1|k-1}^{\Xi} + \Lambda q^F p^D p^P p_{k-1|k-1}^{\Xi}} \\
 &= \left[1 + \frac{f_c p^F}{q^D f_c p^F + \Lambda q^F p^D} \left(\frac{1}{p^P p_{k-1|k-1}^{\Xi}} - 1 \right) \right]^{-1}. \quad (5.1)
 \end{aligned}$$

Die räumliche Falschalarmwahrscheinlichkeitsdichte im Messraum f_c (3.123) ist eine Funktion des „Gating“-Parameters ϱ , der Innovationskovarianz $\mathbf{S}$ - und damit der Messfehlerkovarianz $\mathbf{R}$ und der Schätzfehlerkovarianz des Objektes $\mathbf{P}$ und der Dimension des Messraumes $\dim(\mathbf{z})$. Die Assoziationslikelihood Λ (3.121) hängt zusätzlich noch vom Innovationsresiduum γ ab.

Durch die spezielle Konstellation, in der f_c und Λ in der Rekursion (5.1) stehen, ist die a-posteriori Existenzwahrscheinlichkeit nur noch von ϱ , $\dim(\mathbf{z})$ und der Mahalanobisdistanz D_{MH} zwischen Objekt und Messung abhängig, jedoch nicht mehr explizit von γ oder $\mathbf{S}$. Es gilt

(Lemma 17, Anhang A, Seite 188):

$$p_{k|k}^{\exists}(p^D, p^P, p^F, \Lambda, f_c, p_{k-1|k-1}^{\exists}) = p_{k|k}^{\exists}(p^D, p^P, p^F, \varrho, \dim(\mathbf{z}), D_{MH}, p_{k-1|k-1}^{\exists}). \quad (5.2)$$

Die folgenden Abschnitte betrachten den Einfluss einzelner Eingangsgrößen auf die a-posteriori Existenzwahrscheinlichkeit. Zusätzlich werden ausgesuchte paarweise Abhängigkeiten mit anderen Eingangsgrößen untersucht. Der Einfluss der gerade nicht betrachteten Eingangsgrößen wird durch Belegung mit einem maximal indifferenten Wert eliminiert.

Die sensorische Falschalarmwahrscheinlichkeit p^F , die sensorische Detektionswahrscheinlichkeit p^D und die initiale Existenzwahrscheinlichkeit des Objektes $p_{0|0}^{\exists}$ sind bei einem Wert von 0.5 maximal indifferent. Das Existenzprozessmodell kann durch die Belegung $p^P = 1$ deaktiviert werden. Lediglich für den Parameter der Mahalanobisdistanz D_{MH} zwischen Objekt und Messung ist es aufwendiger, einen indifferenten Wert anzugeben. Dazu werden Messungen in einem Abstand zur Messwertprädiktion erzeugt, deren „gesockelte“ Assoziationslikelihoods (3.121) der Gleichverteilung im Volumen des $\varrho\sigma$ -Ellipsoids der Innovationskovarianz entsprechen. In dieser Assoziationsdistanz d_0 spricht die räumliche Lage der Messung gleichermaßen für die Hypothese einer korrekten Detektion, wie für die Falschalarmhypothese (Abbildung 3.8, Seite 73). Aus dem Ansatz

$$\mathcal{N}_{\varrho\sigma}(\gamma, \mathbf{0}, \mathbf{S}) = \mathcal{U}_{\varrho\sigma} \quad (5.3)$$

ergibt sich die Mahalanobis-Distanz d_0 mit identischer Hypothesenwahrscheinlichkeit in Abhängigkeit vom „Gating“-Parameter ϱ und von der Messraumdimension $\dim(\mathbf{z}) = \dim(\gamma)$ zu (Anhang A, Lemma 16, Seite 187):

$$d_0(\varrho, \dim(\mathbf{z})) = \sqrt{-2 \ln \left(\Gamma \left(1 + \frac{1}{2} \dim(\mathbf{z}) \right) \cdot \chi^2(\varrho^2, \dim(\mathbf{z})) \right) - \dim(\mathbf{z}) \ln \frac{2}{\varrho^2}}. \quad (5.4)$$

Für die Verwendung von 3σ -Assoziationsstoren ($\varrho = 3$) in einem vierdimensionalen Messraum ($\dim(\mathbf{z}) = 4$) sind demnach Messungen in einer Mahalanobis-Distanz von $d_0 = 2.181\sigma$ von ihrer räumlichen Lage her indifferent bezüglich der Detektions- oder Falschalarmhypothese.

5.1.1 Die Assoziationsdistanz

Die Mahalanobis-Distanz der eintreffenden Messung zur Messwertprädiktion eines Objektes im Umfeldmodell bestimmt deren Assoziationswahrscheinlichkeit Λ (3.85). Diese geht multiplikativ in die Likelihood der Detektionskanten ein (3.108), welche zur Berechnung der Zuordnungswahrscheinlichkeiten (3.107) im JIPDA-Algorithmus verwendet wird. Mit Hilfe der Zuordnungswahrscheinlichkeiten berechnen sich die Assoziationsgewichte (3.114) und die a-posteriori Existenzwahrscheinlichkeiten (3.112).

Zur Bestimmung des Übertragungsverhaltens wird eine Sprungantwort des JIPDA-Filters für den Fall aufgezeichnet, in dem in jedem Zyklus eine Messung bei exakt $k\sigma$ der Innovationskovarianz eintrifft. Die Falschalarmwahrscheinlichkeit der Messung, die Detektionswahrscheinlichkeit des Sensors sowie die initiale Existenzwahrscheinlichkeit des Objektes sind dabei maximal

indifferent mit dem Wert 0.5. Das Persistenzmodell wird durch eine Persistenzwahrscheinlichkeit von Eins deaktiviert. Abbildung 5.3/Mitte zeigt die Verläufe der a-posteriori Existenzwahrscheinlichkeiten unter den genannten Randbedingungen für verschiedene Werte von k im Zeitbereich. Es lassen sich folgende Beobachtungen feststellen:

- Mit steigender Mahalanobis-Distanz zwischen Messung und Messwertprädiktion sinkt die a-posteriori Existenzwahrscheinlichkeit.
- Wenn alle anderen Parameter fix sind, existiert eine Assoziationsdistanzschwelle, oberhalb der die Existenzwahrscheinlichkeit gegen Null und unterhalb der die Existenzwahrscheinlichkeit gegen Eins konvergiert.
- Wenn alle Filterparameter invariant sind, d.h. $p^F = 0.5$, $p^D = 0.5$, $p_{0|0}^{\exists} = 0.5$, $D_{MH} = d_0$ und $p^P = 1$, bleibt das Filter für alle Zeit invariant (siehe d_0 -Line in Abbildung 5.3/Mitte).

Für die selben Mahalanobisdistanzen wird jetzt zusätzlich die Falschalarmwahrscheinlichkeit der Messung von der Indifferenz leicht nach unten (Abbildung 5.3/oben-links) und leicht nach oben (Abbildung 5.3/unten-links) variiert. Dabei lassen sich folgende Punkte beobachten:

- Die Konvergenzschwelle der Assoziationsdistanz ist vom Wert der sensorischen Falschalarmwahrscheinlichkeit abhängig.
- Bei geringeren Assoziationsdistanzen akzeptiert das Filter größere Falschalarmwahrscheinlichkeiten für eine Konvergenz zur Objektexistenz und umgekehrt.

Variiert man statt der sensorischen Falschalarmwahrscheinlichkeit die sensorische Detektionswahrscheinlichkeit, ergeben sich für die verschiedenen Mahalanobisdistanzen die Verläufe in Abbildung 5.3/oben-rechts und 5.3/unten-rechts. Hier ist festzustellen:

- Die Konvergenzschwelle der Assoziationsdistanz ist vom Wert der sensorischen Detektionswahrscheinlichkeit am betrachteten Arbeitspunkt unabhängig.
- Stattdessen bestimmt die sensorische Detektionswahrscheinlichkeit die Konvergenzgeschwindigkeit. Bei gleichen Mahalanobisdistanzen der Messungen konvergiert das Filter bei großen Detektionswahrscheinlichkeiten schneller und bei kleinen Detektionswahrscheinlichkeiten langsamer gegen die Existenz bzw. Nichtexistenz.
- Die Sensitivität der mahalanobisdistanzabhängigen Verläufe der a-posteriori Existenzwahrscheinlichkeiten ist bezüglich der Falschalarmwahrscheinlichkeit p^F viel größer als bezüglich der Detektionswahrscheinlichkeit p^D . Für Letztere sind viel größere Variationen notwendig, um signifikante Änderungen im Ausgangssignal zu erzeugen.




Abbildung 5.3: Zeitverläufe der a-posteriori Existenzwahrscheinlichkeit $p^{\exists}$ für Messungen in verschiedenen Mahalanobis-Distanzen bei Variation der sensorischen Falschalarmwahrscheinlichkeit p^F (links) und der sensorischen Detektionswahrscheinlichkeit p^D (rechts).




Abbildung 5.4: Zeitverläufe der a-posteriori Existenzwahrscheinlichkeit $p_{k|k}^{\exists}$ bei verschiedenen sensorischen Falschalarmwahrscheinlichkeiten p^F (links) und verschiedenen Detektionswahrscheinlichkeiten p^D (rechts) sowie deren Abhängigkeiten von der jeweils anderen Größe (oben bis unten).

5.1.2 Die sensorische Falschalarmwahrscheinlichkeit der Messung

Der im vorherigen Abschnitt betrachtete Einfluss des Assoziationsabstandes auf die a-posteriori Existenzwahrscheinlichkeit wird für die folgenden Untersuchungen durch die Belegung $D_{MH} = d_0$ eliminiert.

Für die sensorische Falschalarmwahrscheinlichkeit lässt sich in Abbildung 5.4/links feststellen:

- Mit sinkender Falschalarmwahrscheinlichkeit der Messung steigt die a-posteriori Existenzwahrscheinlichkeit.
- Bei Variation der sensorischen Falschalarmwahrscheinlichkeit ergibt sich analog zur Assoziationsdistanz eine Konvergenzschwelle. Diese Konvergenzschwelle ist am untersuchten Arbeitspunkt unabhängig von der sensorischen Detektionswahrscheinlichkeit.
- Größere Detektionswahrscheinlichkeiten beschleunigen unabhängig von der Falschalarmwahrscheinlichkeit die Konvergenz gegen die Existenz bzw. Nichtexistenz.
- Bei Falschalarmwahrscheinlichkeit Null springt die Existenzwahrscheinlichkeit unabhängig von der Detektionswahrscheinlichkeit sofort innerhalb eines Zyklus auf Eins.
- Bei Falschalarmwahrscheinlichkeit Eins konvergiert die Existenzwahrscheinlichkeit über mehrere Zyklen gegen Null, da hier die Fehldetektionshypothese einbezogen wird, die jedoch über mehrere Zyklen immer unwahrscheinlicher wird. Die Konvergenzgeschwindigkeit wird durch die sensorische Fehldetektionswahrscheinlichkeit $1 - p^D$ bestimmt. Bei Falschalarmwahrscheinlichkeit Eins und Detektionswahrscheinlichkeit Eins würde die Existenzwahrscheinlichkeit innerhalb eines Zyklus unabhängig von den anderen Parametern sofort auf Null springen.

5.1.3 Die sensorische Detektionswahrscheinlichkeit

Für die sensorische Detektionswahrscheinlichkeit und die gegenseitige Abhängigkeit mit der sensorischen Falschalarmwahrscheinlichkeit ermöglicht Abbildung 5.4/rechts folgende Rückschlüsse:

- Bei sensorischen Falschalarmwahrscheinlichkeiten kleiner 0.5 und indifferenten sonstigen Eingangssignalen konvergiert die Existenzwahrscheinlichkeit unabhängig von der Detektionswahrscheinlichkeit immer gegen Eins. Bei sensorischen Falschalarmwahrscheinlichkeiten größer 0.5 und indifferenten sonstigen Eingangssignalen konvergiert die Existenzwahrscheinlichkeit unabhängig von der Detektionswahrscheinlichkeit immer gegen Null.
- Die Detektionswahrscheinlichkeit bestimmt lediglich die Konvergenzgeschwindigkeit.
- Wenn alle Eingangssignale indifferent sind, bleibt das Filter für verschiedene Werte der Detektionswahrscheinlichkeit immer indifferent.

Die bisherigen Betrachtungen sind davon ausgegangen, dass für ein im Umfeldmodell initialisiertes Objekt sukzessive Messungen eintreffen. Damit kann die Neuinitialisierung und die Lebensdauer eines Objektes analysiert werden. Im Folgenden wird ein auf an Sicherheit grenzende Existenzwahrscheinlichkeit eingeschwungenes Objekt verwendet ($p_{0|0}^{\exists} \rightarrow 1$) und es treffen keine weiteren Messungen mehr ein ($D_{MH} = \infty$). Damit wird die Reaktion des JIPDA-Filters auf das Verschwinden von eingeschwungenen Objekten aus dem Sensorüberwachungsbereich nachgebildet. Für diesen Fall zeigt Abbildung 5.5/rechts:

- Mit sinkender Detektionswahrscheinlichkeit verbleibt ein Objekt ohne eintreffende Messungen länger im Umfeldmodell, da die Existenzwahrscheinlichkeit langsamer gegen Null konvergiert.
- Bei Detektionswahrscheinlichkeit Eins erhält das Objekt bereits nach einem Zyklus ohne Messung unabhängig von allen anderen Parametern die Existenzwahrscheinlichkeit Null.

5.1.4 Die Persistenzwahrscheinlichkeit

Ist die Persistenzwahrscheinlichkeit kleiner Eins, wird sich für alle anderen Parameter die Konvergenzgeschwindigkeit gegen Eins im Vergleich zu den bisher gezeigten Kurven verlangsamen und die Konvergenzgeschwindigkeit gegen Null erhöhen. Dies liegt an der Tatsache, dass für $p^P < 1$ die a-priori Existenzwahrscheinlichkeit $p_{k|k-1}^{\exists}$ vor jedem Innovationsschritt verringert wird (3.59). Abbildung 5.5/links verdeutlicht folgende Zusammenhänge für die Persistenzwahrscheinlichkeit:

- Mit steigender Persistenzwahrscheinlichkeit bleibt ein Objekt länger im Umfeldmodell, wenn keine Messungen mehr eintreffen.
- Bei Persistenzwahrscheinlichkeit Null erhält die Existenzwahrscheinlichkeit eines Objektes unabhängig von allen anderen Parametern innerhalb eines Zyklus den Wert Null.
- Bei Persistenzwahrscheinlichkeit Eins und Existenzwahrscheinlichkeit Eins wird ein Objekt unabhängig von den anderen Parametern und den Messungen nie wieder gelöscht.

Für die gegenseitige Abhängigkeit der Detektions- und Persistenzwahrscheinlichkeit im Fall ausbleibender Messungen verdeutlichen die Abbildungen 5.5/links und rechts:

- Für eine gegebene Verweildauer initialisierter Objekte im Umfeldmodell bei ausbleibenden Messungen werden für größere Persistenzwahrscheinlichkeiten auch größere Detektionswahrscheinlichkeiten benötigt.




Abbildung 5.5: Zeitverläufe der a-posteriori Existenzwahrscheinlichkeit $p^{\exists}$ im Fall ausbleibender Messungen $D_{MH} = \infty$ bei Variation der Persistenzwahrscheinlichkeit p^P (links) und der Detektionswahrscheinlichkeit p^D (rechts).

5.2 Untersuchungen zur Effizienzsteigerung durch Hypothesenverwurf

Zur Bestimmung des Performanzgewinns, der durch das in Abschnitt 3.3.6 (Seiten 70 ff.) beschriebene Approximationsverfahren erreichbar ist, wurde der JIPDA-Algorithmus auf reale Sensordaten des in Kapitel 4 (Seiten 83 ff.) beschriebenen Prototypsystems angewandt. Dabei erfolgte in jedem Filterzyklus eine Aufzeichnung der Anzahl der Objekte des Umfeldmodells $|V|$, der Anzahl der von den Sensoren gelieferten Messungen $|Z|$ und der Anzahl der vom JIPDA-Algorithmus unter Verwendung der Aufwandsreduktionstechnik berechneten Zuordnungshypothesen $|E|$.

Um ein skalares Maß für die kombinatorische Komplexität eines zu berechnenden Szenarios anzugeben, die im Wesentlichen durch die Anzahl der Messungen und Objekte bestimmt ist, wird der Kardinalitätsindex ρ als deren arithmetisches Mittel eingeführt:

$$\rho = \frac{1}{2}(|Z| + |V|). \quad (5.5)$$

Abbildung 5.6 zeigt die mittlere Anzahl der vom JIPDA-Algorithmus bei Hypothesenverwurf aufgezählten Zuordnungshypothesen im Vergleich zur Anzahl aller möglichen JIPDA-Zuordnungen über dem Kardinalitätsindex. Dabei zeigt sich, dass für eine kleine Anzahl von zu verfolgenden Objekten ($\rho < 6$), etwa für Landstraßen- und Autobahnsszenarien, in der Praxis weniger als 10^3 Zuordnungshypothesen aufgezählt werden müssen. Die theoretische Anzahl der JIPDA-Zuordnungen liegt hier schon bei Werten bis zu $3 \cdot 10^4$.

In innerstädtischen Umgebungen ($\rho > 6$) wächst die Anzahl der aufzuzählenden Alternativen auch bei Verwendung der Aufwandsreduktion weiter exponentiell an. So enthält die vollständige Menge der JIPDA-Zuordnungen bei ca. 11 Objekten (und Messungen) unbeherrschbare 10^{10} Elemente. Bei der Eliminierung theoretischer Mehrdeutigkeiten mit nahezu verschwindenden Likelihoods müssen in diesem Fall lediglich $5 \cdot 10^5$ Zuordnungsmöglichkeiten berücksichtigt werden. Obwohl diese Hypothesenanzahl mit entsprechendem Hardwareaufwand und -optimierungen noch in Echtzeit beherrschbar ist, stößt das Verfahren bei diesen und größeren Objektanzahlen ohne weitere Approximation an seine Grenzen.

Abbildung 5.7 zeigt die prozentuale Aufwandsersparnis, die durch den Hypothesenverwurf erreicht wird. Zusätzlich sind die Streuungsintervalle in den realen Daten angegeben. Obwohl die Anzahl der aufzuzählenden Zuordnungsalternativen auch mit dem Approximationsverfahren für wachsende Kardinalitätsindizes rapide anwächst, steigert sich die Aufwandsersparnis mit wachsender Objektanzahl. So liegt die relative Aufwandsersparnis verglichen mit dem vollständigen Hypothesenbaum bei mehr als 8 Objekten bereits über 99%.




Abbildung 5.6: Empirischer Vergleich der mittleren Anzahl zu berechnender JIPDA-Zuordnungshypothesen mit und ohne Aufwandsreduktion über dem Mittel der Objekt- und Messwertanzahl (Kardinalitätsindex) für reale Messdaten.




Abbildung 5.7: Empirische relative Aufwandsreduktion durch Zuordnungshypothesenverwurf bezogen auf die vollständige Anzahl möglicher JIPDA-Hypothesen (3.119) für reale Messdaten.

5.3 Die Detektionsleistung des JIPDA-Filters

5.3.1 Versuchsumgebung

Um eine Aussage über die Objekterkennungsleistung vor und nach der JIPDA-Filterung zu treffen, wird eine ROC-Analyse (engl. „Receiver Operating Characteristics“) im Messraum der Videokamera durchgeführt. Dazu wurden alle sichtbaren Fahrzeuge in den Bilddaten einer Sequenzstichprobe durch Rechtecke markiert. Nach Anwendung des JIPDA-Filters auf diese Teststichprobe erfolgt nach jedem Filterzyklus eine Transformation der Objekte des a-posteriori Umfeldmodells in das aktuelle Videobild. Diese Transformation entspricht der in Abschnitt 4.5.3 (Seiten 138 ff.) vorgestellten Messwertprädiktion mit dem Unterschied, dass sie

vor statt nach dem JIPDA-Prädiktionsschritt erfolgt. Die Mittelwerte der rücktransformierten a-posteriori JIPDA-Objektrepräsentationen (4.103) werden nun mit den Referenzmarkierungen (engl. „Labels“) verglichen.

Um zu entscheiden, ob eine Objektrepräsentation mit einer Referenzmarkierung korrespondiert, benötigt man ein Deckungs- bzw. Abstandskriterium, mit dem dann durch Schwellwertbildung eine Zugehörigkeitsentscheidung getroffen werden kann. Da die Messwertprädiktionen für das Videobild lediglich Positions- und Breiteninformationen im Videobild aufweisen aber keine Höheninformationen, wird das in der Literatur gängige Flächenüberlappungskriterium (z.B. [118]) nicht verwendet. Statt dessen findet ein Deckungskriterium Verwendung, welches




Abbildung 5.8: Das Deckungskriterium zur Berechnung von ROC-Kurven.

die Positionsabweichung und den Breitenunterschied zur Breite der Referenzmarkierung ins Verhältnis setzt (Abbildung 5.8). Mit der Bildposition i_l, j_l und der Bildbreite b_l der Referenzmarkierung und der Bildposition i_o, j_o und der Bildbreite b_o des algorithmisch erkannten Objektes wird eine prozentuale Abweichung d_{lo} definiert:

$$\frac{d_{lo}}{[\%]} = \frac{100}{b_l} \cdot \max \left\{ \left| \begin{bmatrix} i_o \\ j_o \end{bmatrix} - \begin{bmatrix} i_l \\ j_l \end{bmatrix} \right|, |b_o - b_l| \right\}. \quad (5.6)$$

Die Teststichprobe besteht aus mehreren Sequenzen mit insgesamt 10^4 Messzyklen. Die Teststichprobe und die Lernstichproben für den Detektor und die Existenzmodelle sind disjunkt. Zwischen ihren Aufzeichnungen liegen zwei Jahre und es wurden für beide Aufzeichnungen verschiedene Kamertypen verwendet.

Für jeden Messzyklus werden die Referenzmarkierungen des Videobildes in zwei Klassen unterteilt. Die Klasse MH (engl. „Must Haves“) enthält alle Fahrzeugmarkierungen, die unverdeckt und vollständig sichtbar sind und die im Winkel- und Abstandssichtbereich der Kamera und des Lidars liegen. Die Klasse CH (engl. „Can Haves“) enthält alle restlichen Referenzmarkierungen, die mindestens eine der genannten Bedingungen verletzen.

Mit Hilfe des Deckungskriteriums und einem entsprechenden Schwellwert, der eine geforderte Lokalisierungsgenauigkeit repräsentiert, werden nun für jeden Messzyklus k drei Kenngrößen ausgezählt. Diese sind die Anzahl n_k^{MH} der Elemente von MH, die Anzahl n_k^{DMH} der Referenzmarken in MH, zu denen mindestens eine algorithmische Detektion unter dem Deckungskriterium korrespondiert und die Anzahl der algorithmischen Detektionen n_k^{FP} , zu denen weder eine Referenzmarke in MH noch in CH korrespondiert.

Über alle K Messzyklen lässt sich damit die globale Detektionsrate (engl. „detection rate“ oder „sensitivity“)

$$s = \frac{\sum_{k=1}^K n_k^{\text{DMH}}}{\sum_{k=1}^K n_k^{\text{MH}}} \quad (5.7)$$

und die globale Falschalarmrate pro Messzyklus

$$f = \frac{1}{K} \sum_{k=1}^K n_k^{\text{FP}} \quad (5.8)$$

berechnen.

Die Kenngrößen werden nun für verschiedene Wahrscheinlichkeitsschwellwerte $T_p = [0..1]$ sowohl für die JIPDA-Objekte und ihre a-posteriori Existenzwahrscheinlichkeit als auch für die Rohdetektionen und ihre sensorische Falschalarmwahrscheinlichkeit berechnet. Hinzu kommt eine Variation der Schwelle $T_d = [0\%..100\%]$ für das Deckungskriterium, so dass zweidimensionale ROC-Kurvenschaaren

$$ROC_{\text{JIPDA}}(T_p, T_d) = \begin{bmatrix} s_{\text{JIPDA}}(T_p, T_d) \\ f_{\text{JIPDA}}(T_p, T_d) \end{bmatrix} \quad (5.9)$$

und

$$ROC_{\text{RAWDET}}(T_p, T_d) = \begin{bmatrix} s_{\text{RAWDET}}(T_p, T_d) \\ f_{\text{RAWDET}}(T_p, T_d) \end{bmatrix} \quad (5.10)$$

entstehen.

5.3.2 Ergebnisse

Ob die Erkennungsperformanz des JIPDA-Filters die der Rohdetektionen übersteigen kann, ist zunächst unklar.

Für eine Steigerung der Erkennungsleistung spricht die Fähigkeit des JIPDA-Filters, Detektionsausfälle über die Fehldetektionshypothese für eine gewisse Zeit zu überbrücken. Ebenso kann das JIPDA-Filter Falschdetektionen unterdrücken, wenn diese entweder große sensorische Falschalarmwahrscheinlichkeiten aufweisen (Abschnitt 5.1.2, Seiten 155 ff.) oder wenn sie Trajektorien im Messraum ausbilden, die nicht dem Prozessmodell der gesuchten Objektklasse entsprechen (Abschnitt 5.1.1, Seiten 151 ff.).

Für eine Verschlechterung der Erkennungsleistung nach der JIPDA-Filterung spricht jedoch die Tatsache, dass das JIPDA-Filter wie alle synchron zur Datenaufzeichnung mitlaufenden Objektverfolgungsverfahren ein kausales Tiefpassfilter ist. Eine optimale Tiefpassfilterung zur Unterdrückung des Zustands- und Existenzmessrauschens müsste sowohl Messwerte aus der Vergangenheit als auch Messwerte aus der Zukunft verwenden und wäre somit akausal. Als Konsequenz der ausschließlichen Verwendung aktueller und zurückliegender Messwerte kann das Filter erst nach einigen Zyklen unterscheiden, ob es sich bei einer Auslenkung des Eingangssignals um Messrauschen oder um eine tatsächliche Objektdynamik handelt. Das gefilterte Ausgangssignal erfährt eine Phasenverschiebung, da das Filter der tatsächlichen Dynamik




Abbildung 5.9: Die Phasenverschiebung der Existenzschätzung führt zu Fehlerkennungen (FN) und Falscherkennungen (FP). Die Darstellung ist schematisch mit übertrieben großen Trägheiten.

mit einer gewissen Trägheit folgt (siehe Abschnitt 5.1 zum Übertragungsverhalten, Seiten 149 ff.).

Bezogen auf die Existenzschätzung illustriert Abbildung 5.9 schematisch die negativen Auswirkungen der Phasenverschiebung auf die Erkennungsleistung. Beim Erscheinen neuer Objekte benötigt das JIPDA-Filter einige Zeit um auf eine hohe Existenzwahrscheinlichkeit einzuschwingen. In dieser Zeit können Fehldetektionen entstehen. Beim Verschwinden von Objekten wird sich die Existenzwahrscheinlichkeit nicht sofort auf Null einstellen. In dieser Übergangszeit können Falschalarme entstehen.

Abbildung 5.10 zeigt die ROC-Kurven für die Deckungsschwellen $T_d = (30\%, 20\%, 17\%)$. Es können folgende Rückschlüsse festgehalten werden:

- Für alle Deckungsschwellen übersteigt die JIPDA-Erkennungsleistung auf realen Sensordaten die der Rohdetektionen. Damit überwiegen die positiven Effekte des JIPDA-Filters auf die Erkennungsleistung die negativen Effekte. Der Grund hierfür liegt darin, dass kurze Detektorausfälle und sporadische Falschalarme in realen Daten viel häufiger vorkommen als das Erscheinen und Verschwinden von Objekten. Zudem sind die Einschwingphasen bei der gewählten Parametrisierung nur wenige Filterzyklen lang.
- Bei niedrigen Existenzwahrscheinlichkeitsschwellen erzeugt das JIPDA-Filter viel mehr Falschalarme als der Detektor, da die horizontalen Schenkel der ROC-Kurven für das JIPDA-Filter viel weiter nach rechts reichen. Dies liegt tatsächlich an der Phasenverschiebung. Wenn sporadische Falschalarme Objektrepräsentationen initialisieren, werden diese noch einige Zyklen als Objekte mit sehr niedriger Existenzwahrscheinlichkeit gehalten.
- Mit steigender geforderter Lokalisierungsgenauigkeit bricht die Erkennungsleistung des JIPDA-Filters weniger stark ein, als die der ungefilterten Rohdetektionen. Dieser Fakt lässt sich mit der Glättung der geschätzten Objektpositionen durch das Filter erklären, die im Vergleich zu den Rohdetektionen im Mittel zu einem geringeren Abstand zur Referenz führen.




Abbildung 5.10: Vergleich zwischen der Erkennungsleistung auf Rohdetektionsebene und auf der JIPDA-Objektebene mittels ROC-Kurven (engl. „Receiver Operating Characteristics“) für verschiedene geforderte Lokalisierungsgenauigkeiten auf realen Sensordaten. Die rechte Spalte zeigt Vergrößerungen der relevanten Bereiche der ROC-Kurven links.

Als wichtigste Erkenntnis lässt sich festhalten, dass die Anwendung des JIPDA-Filters bei realen Sensordaten die Erkennungsleistung des verwendeten Detektors steigert.

5.4 Ein Konsistenztest ohne Referenzdaten für Filterverfahren mit gewichteten Innovationen

5.4.1 Stand der Technik

Aus der Literatur sind die Konsistenztests NEES (engl. „Normalized Estimation Error Squared“) und NIS (engl. „Normalized Innovation Squared“) bekannt [5]. Beim NEES-Test wird der auf die Schätzfehlerkovarianz $\hat{\mathbf{P}}_{k|k}$ normierte quadratische Schätzfehler auf χ^2 -Verteilung mit $\dim(\mathbf{x})$ Freiheitsgraden getestet (siehe auch Abschnitt 4.4.4, Seiten 126 ff.):

$$\tilde{\mathbf{x}}^T \hat{\mathbf{P}}_{k|k}^{-1} \tilde{\mathbf{x}} = (\mathbf{x}_k^{\text{REF}} - \hat{\mathbf{x}}_{k|k})^T \hat{\mathbf{P}}_{k|k}^{-1} (\mathbf{x}_k^{\text{REF}} - \hat{\mathbf{x}}_{k|k}) \stackrel{?}{\sim} \chi^2(\cdot, \dim(\mathbf{x})). \quad (5.11)$$

Mit dem NIS-Test wird überprüft, ob die auf die Innovationskovarianz $\mathbf{S}$ (2.56) normierten quadratischen Filterresiduen $\boldsymbol{\gamma}$ (2.58) einer χ^2 -Verteilung mit $\dim(\mathbf{z})$ Freiheitsgraden folgen:

$$\boldsymbol{\gamma}^T \mathbf{S}^{-1} \boldsymbol{\gamma} = (\mathbf{z} - \mathbf{H} \hat{\mathbf{x}}_{k|k-1})^T (\mathbf{H} \hat{\mathbf{P}}_{k|k-1} \mathbf{H}^T + \mathbf{R})^{-1} (\mathbf{z} - \mathbf{H} \hat{\mathbf{x}}_{k|k-1}) \stackrel{?}{\sim} \chi^2(\cdot, \dim(\mathbf{z})). \quad (5.12)$$

Für den NEES-Test werden hochgenaue Referenzdaten $\mathbf{x}_k^{\text{REF}}$ benötigt, während der NIS ohne Referenzdaten berechenbar ist. In der Literatur ist jedoch nach dem aktuellen Wissensstand des Autors kein einziger Konsistenztest ohne Referenzdaten für Filterverfahren mit gewichteten Innovationen bekannt, bei denen für jedes Objekt v simultan multiple Innovationsvektoren $\boldsymbol{\gamma}^{vj}$ verarbeitet werden. In der Literatur werden Mischverteilungsfiler im Prädiktionsschritt, wie das IMM-Filter und Mischverteilungsfiler im Innovationsschritt, wie das PDA- [6], IPDA- [65], JPDA- [6] und JIPDA-Filter [64] ausschließlich mit dem NEES-Test auf Konsistenz geprüft. Im Folgenden wird ein Konsistenztest ohne Referenzdaten analog zum NIS-Test für Filter mit gewichteten Innovationen vorgeschlagen.

5.4.2 Der NPCS-Test

Der hier beschriebene Test wird aus Anschauungsgründen mit einer auf Positions- und Geschwindigkeitsdaten reduzierten Version des Prototypsystems vorgenommen. Dazu wird die Breitenschätzung deaktiviert. Die Zustands- und Messvektoren des reduzierten Systems lauten:

$$\mathbf{x} = [x^{\text{FK}}, y^{\text{FK}}, z^{\text{FK}}, v, \varphi^{\text{FK}}, \dot{\varphi}]^T \quad (5.13)$$

$$\mathbf{z} = [i^{\text{BK}}, j^{\text{BK}}, r^{\text{LP}}, \varphi^{\text{LP}}]^T. \quad (5.14)$$

Zunächst wird die gewichtete Innovation des Zustandsvektors (3.104) umgeformt:

$$\hat{\mathbf{x}}_{k|k}^v = \sum_{j=0}^{|Z|} \beta_{vj} (\hat{\mathbf{x}}_{k|k-1}^v + \mathbf{K}^{vj} \boldsymbol{\gamma}^{vj}) \quad (5.15)$$

$$= \sum_{j=0}^{|Z|} (\beta_{vj} \hat{\mathbf{x}}_{k|k-1}^v + \beta_{vj} \mathbf{K}^{vj} \boldsymbol{\gamma}^{vj}) \quad (5.16)$$

$$= \sum_{j=0}^{|Z|} \beta_{vj} \hat{\mathbf{x}}_{k|k-1}^v + \sum_{j=0}^{|Z|} \beta_{vj} \mathbf{K}^{vj} \boldsymbol{\gamma}^{vj}, \quad \text{mit (3.103)} \quad (5.17)$$

$$= \hat{\mathbf{x}}_{k|k-1}^v + \underbrace{\sum_{j=0}^{|Z|} \beta_{vj} \mathbf{K}^{vj} \boldsymbol{\gamma}^{vj}}_{\text{summierter gewichteter Zustandskorrekturvektor}} \quad (5.18)$$

$$= \hat{\mathbf{x}}_{k|k-1}^v + \sum_{j=0}^{|Z|} \boldsymbol{\gamma}^{*,vj} \quad (5.19)$$

$$= \hat{\mathbf{x}}_{k|k-1}^v + \boldsymbol{\gamma}^*. \quad (5.20)$$

Gleichung (5.18) kann so interpretiert werden, dass zunächst jedes Residuum $\boldsymbol{\gamma}^{vj}$ mit dem linearen Operator $\beta_{vj} \mathbf{K}^{vj}$ in einen gewichteten Korrekturvektor im Zustandsraum $\boldsymbol{\gamma}^{*,vj}$ transformiert wird. Die transformierten gewichteten Korrekturvektoren werden dann im Zustandsraum summiert und ergeben einen Zustandskorrekturvektor $\boldsymbol{\gamma}^*$, der auf die a-priori Zustandsschätzung $\hat{\mathbf{x}}_{k|k-1}^v$ addiert wird. Da die Konvexkombination der Residuen im Zustandsraum und nicht im Messraum erfolgt, darf nicht einfach die Konvexkombination der NIS-Werte der Einzelinnovationen als Konsistenztest verwendet werden.

Stattdessen wird die Statistik des summierten gewichteten Zustandskorrekturvektors $\boldsymbol{\gamma}^*$ untersucht. Als Ausgangspunkt wird für die Statistik der Einzelresiduen NIS-Konsistenz gefordert:

$$\boldsymbol{\gamma}^{vj} \stackrel{!}{\sim} \mathcal{N}(\cdot, \mathbf{0}, \mathbf{S}^{vj}). \quad (5.21)$$

Nach der linearen Transformation der Residuen in den Zustandsraum durch den Operator $\beta_{vj} \mathbf{K}^{vj}$ ergibt sich für die gewichteten Korrekturvektoren $\boldsymbol{\gamma}^{*,vj}$ die Statistik:

$$\boldsymbol{\gamma}^{*,vj} = (\beta_{vj} \mathbf{K}^{vj}) \boldsymbol{\gamma}^{vj} \stackrel{!}{\sim} \mathcal{N}(\cdot, \mathbf{0}, (\beta_{vj} \mathbf{K}^{vj}) \mathbf{S}^{vj} (\beta_{vj} \mathbf{K}^{vj})^T) = \mathcal{N}(\cdot, \mathbf{0}, \mathbf{S}^{*,vj}) \quad \text{mit} \quad (5.22)$$

$$\mathbf{S}^{*,vj} = \beta_{vj}^2 \mathbf{K}^{vj} \mathbf{S}^{vj} (\mathbf{K}^{vj})^T. \quad (5.23)$$

Durch Summation der gewichteten Korrekturvektoren im Zustandsraum ergibt sich daraus die geforderte Statistik des summierten gewichteten Zustandskorrekturvektors $\boldsymbol{\gamma}^*$:

$$\boldsymbol{\gamma}^* = \sum_{j=0}^{|Z|} \boldsymbol{\gamma}^{*,vj} \stackrel{!}{\sim} \mathcal{N}(\cdot, \mathbf{0}, \sum_{j=0}^{|Z|} \mathbf{S}^{*,vj}) = \mathcal{N}(\cdot, \mathbf{0}, \mathbf{S}^*) \quad \text{mit} \quad (5.24)$$

$$\mathbf{S}^* = \sum_{j=0}^{|Z|} \beta_{vj}^2 \mathbf{K}^{vj} \mathbf{S}^{vj} (\mathbf{K}^{vj})^T. \quad (5.25)$$

Jetzt wäre es prinzipiell möglich, γ^* auf mittelwertfreie Normalverteilung mit Kovarianz $\mathbf{S}^*$ zu testen. Für den entsprechenden χ^2 -Anpassungstest müssten für eine Stichprobe die quadratischen Formen $(\gamma^*)^T (\mathbf{S}^*)^{-1} \gamma^*$ berechnet werden.

Da aber nicht immer alle Zustände aus einer Messung beobachtbar sind, ist $\mathbf{S}^*$ möglicherweise rangdefizitär und daher nicht invertierbar. Es gilt:

$$\text{rang}(\mathbf{S}^*) \leq \dim(\mathbf{z}), \quad \text{rang}(\mathbf{S}^*) \leq \dim(\mathbf{x}). \quad (5.26)$$

Der Rang der Matrix $\mathbf{S}^*$ gibt die Anzahl der unabhängigen Freiheitsgrade des Zustandsvektors an, die durch eine einzige Messung beobachtet werden können. Im Anwendungsbeispiel (5.13)-(5.14) ist der Rang von $\mathbf{S}^*$ gleich drei, obwohl der Messraum vierdimensional ist. Das mit der vierdimensionalen Messung (5.14) nur die drei Positionsfreiheitsgrade des Zustandsvektors (5.13) spezifiziert sind, kann man sich leicht dadurch verdeutlichen, dass die horizontale Bildkoordinate i^{BK} und der vom Lidar erfasste Objektwinkel φ^{LP} im Wesentlichen redundante Messungen der lateralen Objektposition sind. Anschaulich kollabiert der durch $\mathbf{S}^*$ beschriebene sechsdimensionale Hyperellipsoid in drei seiner Hauptachsenrichtungen auf eine Ausdehnung von Null. Diese drei kollabierenden Hauptachsen spannen den Nullraum (auch Kern) der Matrix auf. Das Komplement des Kerns, also die drei nicht kollabierenden Hauptachsen, spannt den Kokern (auch Bild) der Matrix $\mathbf{S}^*$ auf.

Eine Möglichkeit, das Problem der Invertierbarkeit zu beheben, bestünde darin, den summierten gewichteten Zustandskorrekturvektor γ^* und seine Kovarianz $\mathbf{S}^*$ wieder in den Messraum zurück zu transformieren und dort $\mathbf{H}\gamma^*$ auf mittelwertfreie Normalverteilung mit Kovarianz $\mathbf{H}\mathbf{S}^*\mathbf{H}^T$ zu prüfen. Im Fall des Extended-Kalman-Filters ist $\mathbf{H}$ aber die Linearisierung der Messfunktion. Daher führt jede Koordinatentransformation zwischen Zustands- und Messraum einen zusätzlichen Linearisierungsfehler ein und ist deshalb zu vermeiden.

Als Abhilfe wird stattdessen eine Unterraumprojektion von γ^* und $\mathbf{S}^*$ auf die Basis der $\text{rang}(\mathbf{S}^*)$ nicht verschwindenden Eigenvektoren, also auf den Kokern von $\mathbf{S}^*$ verwendet. Aus der Eigenwertzerlegung

$$\mathbf{S}^* = \mathbf{V}\mathbf{E}\mathbf{V}^T \quad (5.27)$$

ergibt sich die Diagonalmatrix $\mathbf{E}$ der Eigenvarianzen von $\mathbf{S}^*$, von denen lediglich $\text{rang}(\mathbf{S}^*)$ Hauptdiagonalwerte an den Positionen $\mathbf{E}(l_1, l_1) \dots \mathbf{E}(l_{\text{rang}(\mathbf{S}^*)}, l_{\text{rang}(\mathbf{S}^*)})$ ungleich Null sind.

Streicht man alle Zeilenvektoren aus $\mathbf{V}^T$ heraus, deren zugehörige Eigenwerte gleich Null sind, erhält man die Koordinatentransformationsmatrix $\mathbf{V}^*$ vom Zustandsraum auf den Kokern:

$$\mathbf{V}^* = \mathbf{V}^T([l_1, \dots, l_{\text{rang}(\mathbf{S}^*)}], 1 \dots \dim(\mathbf{x})). \quad (5.28)$$

Durch Eliminierung des Nullraumes in $\mathbf{E}$ erhält man die Kovarianzmatrix $\mathbf{E}^*$ des auf den Kokern von $\mathbf{S}^*$ projizierten summierten gewichteten Korrekturvektors:

$$\mathbf{E}^* = \mathbf{E}([l_1, \dots, l_{\text{rang}(\mathbf{S}^*)}], [l_1, \dots, l_{\text{rang}(\mathbf{S}^*)}]). \quad (5.29)$$

Die auf den Kokern projizierte Kovarianzmatrix $\mathbf{E}^*$ ist immer invertierbar.

Der finale gewichtete und auf den Kokern projizierte Korrekturvektor kann jetzt auf mittelwertfreie Normalverteilung mit Kovarianz $\mathbf{E}^*$ getestet werden:

$$\mathbf{V}^* \gamma^* \stackrel{?}{\sim} \mathcal{N}(\cdot, \mathbf{0}, \mathbf{E}^*). \quad (5.30)$$




Abbildung 5.11: Exemplarischer Verlauf der NPCS-Werte über der Zeit für ein verfolgtes Fahrzeug. Nur 5 von 800 Werten sind größer als das 99%-Quantil der zugehörigen χ^2 -Verteilung.

Dazu wird der gewichtete, projizierte, quadrierte und auf $\mathbf{E}^*$ normierte Korrekturvektor (engl. „Normalized Projected Correction Squared“, NPCS) auf χ^2 -Verteilung mit $\text{rang}(\mathbf{S}^*)$ Freiheitsgraden getestet:

$$NPCS = (\mathbf{V}^* \boldsymbol{\gamma}^*)^T (\mathbf{E}^*)^{-1} \mathbf{V}^* \boldsymbol{\gamma}^* \stackrel{?}{\sim} \chi^2(\cdot, \text{rang}(\mathbf{S}^*)). \quad (5.31)$$

5.4.3 Ergebnisse

Das JIPDA-Filter wird durch Variation der freien Parameter, d.h. der Intensität des Prozessrauschens, angepasst, bis die Summe aller NPCS-Werte einer Stichprobe mit N Elementen dem Median der χ^2 -Verteilung mit $N \cdot \text{rang}(\mathbf{S}^*)$ Freiheitsgraden entspricht. Tabelle 5.1 zeigt den Anpassungstest nach der Parameteroptimierung. Ein Ausschnitt der Teststichprobe wird

Tabelle 5.1: Anpassungstest der empirischen NPCS-Werte auf χ^2 -Verteilung mit $N \approx 5 \cdot 10^3$ Stichproben und einem Signifikanzniveau von 10%.

#Freiheitsgrade	$Q_{\chi^2}(0.05, N \cdot \text{rang}(\mathbf{S}^*))$	$\sum_{k=1}^N NPCS_k$	$Q_{\chi^2}(0.95, N \cdot \text{rang}(\mathbf{S}^*))$
3	14719.2	15009.8	15289.1

in Abbildung 5.11 über der Zeit dargestellt. Zusätzlich sind die 1%- und 99%-Quantile der χ^2 -Verteilung mit $\text{rang}(\mathbf{S}^*) = 3$ Freiheitsgraden eingetragen. In Abbildung 5.12 sind die empirischen relativen Häufigkeiten der NPCS-Stichproben im Vergleich zur theoretischen Zähldichtefunktion $f_{\chi^2}^d$ (4.73) der χ^2 -Verteilung mit $\text{rang}(\mathbf{S}^*) = 3$ Freiheitsgraden dargestellt. Die kumulativen Häufigkeiten und Zähldichten zeigt Abbildung 5.13.

Es ist ersichtlich, dass die empirischen Verteilungen zwar nach der Parameteroptimierung fehlerminimierend an die theoretischen Funktionen angepasst sind, sie jedoch in ihrer Form etwas von ihnen abweichen. So entstehen im mittleren Wertebereich der NPCS-Werte einige Stichproben zu wenig und in den Bereichen der kleinen und sehr großen NPCS-Werte einige Stichproben zu viel. Die Ursachen dieser leicht von der theoretischen χ^2 -Verteilung abweichenden Form können darin liegen, dass die realen Mess- und Prozessfehler möglicherweise nicht exakt normalverteilt sind, oder dass die Nichtlinearitäten im Mess- und Prozessmodell die Verteilung deformieren.

Ein Betrieb des Filters in dieser Konfiguration ist ohnehin riskant. In der Praxis wird nicht die Parametrisierung verwendet, die eine strenge Konsistenz (siehe Abschnitt 4.4.4, Seiten 126 ff.) auf einer Datenstichprobe erzeugt. Kommen im Betrieb auf der Straße dynamische Situationen vor, die in ihrer Intensität so nicht in der Teststichprobe repräsentiert sind, wird das Filter in so einem Fall möglicherweise inkonsistent. Eine mögliche Folge wären zum Beispiel Fehler bei der Berechnung der Datenassoziationsgewichte.

Stattdessen werden die auf die Teststichprobe optimierten Mess- und Prozessrauschmatrizen mit einer sogenannten Manöverreserve beaufschlagt, die zu einer systematischen Überschätzung der Schätzfehlerkovarianzen führen. In dieser Parametrisierung verschieben sich die empirischen relativen Häufigkeiten der NPCS-Stichproben von großen hin zu kleinen Werten.




Abbildung 5.12: Die theoretische Zähl-dichte der χ^2 -Verteilung im Vergleich zu den empirischen relativen Häufigkeiten der NPCS-Stichproben.




Abbildung 5.13: Die kumulative Zähl-dichte der χ^2 -Verteilung im Vergleich zu den empirischen kumulativen Häufigkeiten der NPCS-Stichproben.

Kapitel 6

Zusammenfassung und Ausblick

6.1 Weiterführende Arbeiten

Das in Abschnitt 3.3.8, Seiten 74 ff. beschriebene generische Sensorfusionssystem kann mit den in dieser Arbeit vorgestellten Verfahren noch nicht vollständig umgesetzt werden. So ist das in Kapitel 4 implementierte Prototypsystem zwar über die gesamte Verarbeitungskette schwellen- und heuristikfrei, realisiert aber noch kein „Plug-and-Play“-Sensorfusionssystem. Für weiterführende Untersuchungen bieten sich daher neben den in Abschnitt 3.3.9 (Seiten 78 ff.) genannten Aspekten, wie den fragmentierten- oder nicht aufgelösten Sensordaten und das explizite Objektgeburtsmodell, insbesondere die nachfolgend beschriebenen Themen an.

Verteilte Sensorfusionssysteme

Nach der in Abbildung 3.9 (Seite 76) vorgeschlagenen Systemarchitektur liegt die extrinsische und intrinsische Kalibrierung des Sensors im Zuständigkeitsbereich des Sensorzulieferers. Diese Kalibrierdaten parametrisieren das Messmodell, also die Abbildung vom Zustandsraum in den Messraum. Liefern die Sensoren ihre Messdaten in den Koordinaten des Messraumes an die zentrale Fusionseinheit, muss diese für jeden Sensor im Besitz des jeweiligen Messmodells und dessen Parametern sein, um die Filterinnovation zu berechnen. Dieses Kenntnis der sensorischen Abbildungseigenschaften und der Kalibrierparameter in der Fusionseinheit widerspricht jedoch dem Ziel einer sensorunabhängigen Fusion.

Alternativ können die Sensoren ihre Messdaten in Zustandsraumkoordinaten an die zentrale Fusionseinheit kommunizieren. Da nicht immer alle Zustandsgrößen aus den Messdaten eines Sensors beobachtbar sein müssen, ergeben sich bei der Transformation eventuell unendliche Unsicherheiten auf einigen Zustandsgrößen. Weil die numerische Behandlung des Symbols „unendlich“ auf den meisten Architekturen problematisch ist, kann hier eine Umstellung des JIPDA-Algorithmus auf eine Informationsfilter-Implementierung [5] sinnvoll sein. In diesem Fall hätten schlecht oder gar nicht beobachtbare Zustandsgrößen in der transformierten Messung kleine oder verschwindende Informationsbeiträge statt sehr großer oder unendlicher Unsicherheiten.

Die Kommunikation von Messvektoren und deren Unsicherheiten bzw. Informationen in Zustandsraumkoordinaten ist sensorunabhängig und ermöglicht daher den Betrieb verschiedenster Sensorkombinationen und -typen mit dem gleichen Kommunikationsprotokoll.

Unüberwachtes Lernen statistischer Abhängigkeiten

Sollten die Sensoren statistische Abhängigkeiten der Messfehler und Detektionsfehler aufweisen, genügt eine Identifikation und Berücksichtigung dieser Abhängigkeiten in der zentralen Fusionseinheit nicht, um eine generische Fusion zu realisieren, da hier für jede Sensorkombination separate Parameter hinterlegt sein müssten.

Vielmehr ist es notwendig, die statistischen Abhängigkeiten zwischen den Messungen für die aktuelle Sensorkonfiguration im laufenden Betrieb zu ermitteln. Die besondere Herausforderung besteht hier darin, dass in diesem Fall weder in der Zustandsdomäne noch in der Existenzdomäne Referenzdaten für die beobachtete Verkehrsszene vorhanden sind, aus denen die Mess- und Detektionsfehler und letztlich deren Statistiken berechenbar wären. Die Fusionseinheit muss daher die statistischen Abhängigkeiten aus eindeutig identifizierbaren Szenen erlernen und auf alle mehrdeutigen Szenarien verallgemeinern. Wie diese eindeutigen Szenen praktisch identifiziert werden, bleibt dabei dahingestellt. In der Existenzdomäne sind beispielsweise an Sicherheit grenzende Existenzwahrscheinlichkeiten denkbar.

Numerische Stabilität

Bei der Ermittlung der Zuordnungswahrscheinlichkeiten im JIPDA-Algorithmus wird das Pfadprodukt der Kantenwahrscheinlichkeiten im Hypothesenbaum berechnet. Da bereits die Kantenwahrscheinlichkeiten Produkte aus Einzelwahrscheinlichkeiten sind, werden die Zuordnungswahrscheinlichkeiten mit steigender Baumtiefe, also mit wachsender Objektanzahl, immer kleiner. Es ist absehbar, dass die Zuordnungswahrscheinlichkeiten ab einer gewissen Baumtiefe den in der verwendeten Architektur mit Fließkommazahlen abbildbaren Wertebereich verlassen.

Obwohl im praktischen Betrieb mit dem hier vorgestellten Prototypsystem keine Instabilitäten festgestellt werden konnten, wäre neben der theoretischen Analyse dieses Effektes und der Benennung einer Toleranzschwelle, bis zu der die hier vorgestellte Implementierung numerisch stabil bleibt, als Abhilfe die Abbildung der Verbundwahrscheinlichkeitsberechnungen in eine nicht multiplikative Repräsentation von Interesse.

Ein Varianzanalogen für die Existenzschätzung

Für den Grenzfall einer Messung mit unendlicher Messfehlerkovarianz verschwindet die Kalman-Verstärkung (2.59) bei einer endlichen Schätzfehlerkovarianz:

$$\mathbf{P} < \infty : \lim_{\mathbf{R} \rightarrow \infty} \mathbf{K} = \mathbf{0}. \quad (6.1)$$

Dadurch bleibt bei der Kalman-Innovation (2.60), (2.61) mit einer solchen Messung die a-priori Wissensbasis erhalten. Der nicht mehr als echte Funktion existierende Grenzwert der

Likelihood-Funktion:

$$\lim_{\mathbf{R} \rightarrow \infty} \mathcal{N}(\mathbf{z}, \mathbf{H}\mathbf{x}, \mathbf{R}) \stackrel{\text{Interpr.}}{=} \mathcal{U}(\mathbf{z}) \quad (6.2)$$

kann als Gleichverteilung auf dem gesamten $\mathbb{R}^{\dim(\mathbf{z})}$ interpretiert werden. Diese Pseudo-Gleichverteilung auf dem gesamten Messraum ist ein neutrales Element bezüglich der Kalman-Innovation. Auf einem endlichen diskreten Ereignishorizont erhält eine Bayes-Innovation (2.23) mit der hier tatsächlich existierenden Gleichverteilung $\mathcal{U}(z_k|x_k) = \mathcal{U}(z_k)$ ebenfalls die a-priori Wissensbasis:

$$p(x_k|Z_{1:k}) = \frac{\mathcal{U}(z_k)p(x_k|Z_{1:k-1})}{\sum_{x_k \in X} \mathcal{U}(z_k)p(x_k|Z_{1:k-1})} = \frac{\mathcal{U}(z_k)p(x_k|Z_{1:k-1})}{\mathcal{U}(z_k) \sum_{x_k \in X} p(x_k|Z_{1:k-1})} = p(x_k|Z_{1:k-1}). \quad (6.3)$$

Dieser Fakt lässt sich so interpretieren, dass die Gleichverteilung die maximale Unwissenheit des Sensors bezüglich der Zustandsgrößen repräsentiert. Umgekehrt wird durch eine Einheitsimpulsfunktion (bzw. Dirac-Distribution), also im Kontinuierlichen bei einem Messwert mit verschwindender Messfehlervarianz, die absolute Sicherheit ausgedrückt.

In der Existenzdomäne bedeutet eine Gleichverteilung auf dem binären Ereignishorizont jedoch kein neutrales Element bezüglich der Innovation der Existenzwahrscheinlichkeiten. So lässt sich einfach empirisch nachvollziehen, dass die Existenz-Innovation mit der Gleichverteilung, also einer gemessenen sensorischen Falschalarmwahrscheinlichkeit von $p^F = 0.5$, nicht die a-priori Existenzwahrscheinlichkeit erhält. Vielmehr wird sich eine a-priori Existenzwahrscheinlichkeit größer 0.5 durch diese Innovation verringern, da dieser Wert ein ganz konkretes - und zwar geringeres - Chancenverhältnis für die Objektexistenz bei den gemessenen Merkmalswerten und nicht die absolute Unwissenheit des Sensors repräsentiert.

Innerhalb der Existenzschätzung haben die Sensoren in der vorliegenden JIPDA-Formulierung mithin keine Möglichkeit die Sicherheit der Existenzaussage gegenüber der Fusionseinheit zu quantifizieren. Im Extremfall ist es für einen Sensor nicht möglich, analog zur Gleichverteilung in der Zustandsschätzung, die Existenzaussage komplett zu verweigern.

Abhilfe würde hier die Hinzunahme eines Unsicherheitsmaßes für die Existenzaussage schaffen. Es bietet sich zum Beispiel an, die Sensoren Wahrscheinlichkeitsintervalle statt einzelne Existenzwahrscheinlichkeiten liefern zu lassen. In diesem Fall würde die absolute Unsicherheit als Intervall $[0..1]$ repräsentiert und die absolute Sicherheit über die Existenzchancen als degeneriertes Intervall, also als einzelner Wahrscheinlichkeitswert.

Die Intervalle könnten aus den Streubreiten der Merkmalsstatistiken generiert werden. Letztlich läuft diese Erweiterung auf eine Umstellung des JIPDA-Algorithmus von der Grundlage der bayesschen Schätztheorie auf eine Dempster-Schäfer basierte Version hinaus.

Andere Kantenwahrscheinlichkeiten

Experimente mit anderen Kantenwahrscheinlichkeiten, insbesondere für die Assoziationskante und die Falschalarmkante, haben ebenfalls funktionsfähige Implementierungen erzeugt. Beispielsweise kann ein funktionierendes JIPDA-Derivat mit den Kantenwahrscheinlichkeiten

$$l(e = (v, j)) = e^{-\frac{1}{2}D_{MH}(v,j)^2} \cdot p_v^D \cdot p_v^\exists \cdot q_j^F, \quad (6.4)$$

$$l(e = (\odot, j)) = p_j^F \quad (6.5)$$

anstatt von (3.108) und (3.109) betrieben werden. Der Vorteil dieser Variante liegt im Verzicht auf die räumliche Falschalarmwahrscheinlichkeit $f_c(\mathbf{z})$. Nachfolgende Arbeiten könnten sich daher auch mit der Aufstellung alternativer FISST-Messmodelle und der Untersuchung geänderter JIPDA-Versionen beschäftigen.

6.2 Resümee

In dieser Arbeit wurde die klassische Verkopplung der Objektdetektion, der Datenassoziation und der Objektverfolgung zu einem Gesamtwahrnehmungssystem hinsichtlich der Verwendung von Schwellwerten, frühen Entscheidungen und Heuristiken analysiert. Dabei konnten innerhalb dieser herkömmlichen Verarbeitungskette mehrfach Fehleranfälligkeiten aufgrund ignorierte Unsicherheiten und Mehrdeutigkeiten identifiziert werden, die speziell in zukünftigen integrierten Fahrerassistenzsystemen mit sicherheitskritischen Aktorikeingriffen nicht tolerierbar sind.

Als Ursache wurde das Unvermögen des der bayesschen Zustandsschätzung zugrundeliegenden Zustandsraummodells identifiziert, alle in der Fahrzeugumfelderfassung evidenten Unsicherheiten, namentlich der Existenz-, Assoziations- und Zustandsgrößenunsicherheit, zu repräsentieren.

Es wurde erstmalig in einem automobilen Kontext eine parametrische Wissensrepräsentation ausgehend von der aus der Literatur bekannten Theorie der Statistik endlicher zufälliger Mengen (engl. „Finite Set Statistics“, FISST) gewählt, die in der Lage ist, die vollständige Natur des Wahrnehmungsproblems mit allen inhärenten Unsicherheiten abzubilden. Für diese Wissensrepräsentation, die Multiobjekt-Multi-Bernoulli-Verteilung, konnten Prozess- und Messmodelle für die Fahrzeugumfelderfassung mit heterogenen Sensordaten erstellt werden, die eine echtzeitfähige rekursive Softwareimplementierung ermöglichen. Im Rahmen der Arbeit wurde erstmalig gezeigt, dass die aus dieser Herleitung resultierenden Filtergleichungen denen des aus der Literatur bekannten JIPDA-Filters entsprechen.

Nach derzeitigem Wissensstand wurde unabhängig vom Anwendungskontext in dieser Arbeit erstmalig ein FISST-Messmodell verwendet, das Falschdetektion nicht parametrisch durch eine Ereignisrate pro Volumen und Zeit und einer räumlichen Falschalarmverteilung beschreibt, sondern bei dem eine vom Sensor für jede Messung individuell gelieferte Falschalarmwahrscheinlichkeit Verwendung findet. Dieses nicht-parametrische Falschalarmmodell ermöglicht zum einen eine sensorunabhängige Datenfusion und ist zum anderen durch die Berücksichtigung messwertindividueller sensorischer Existenzmerkmale viel spezifischer als die in der Literatur verwendete Poisson-Approximation.

Das vorgestellte Filter behandelt die Detektion, Assoziation und die zeitliche Verfolgung von Objekten in einem einzigen Algorithmus und ersetzt damit die klassische Modularchitektur. Insbesondere enthält das Verfahren keine frühen Entscheidungen, Heuristiken und Schwellwerte mehr. Dadurch konnte zum einen die Anzahl der freien Parameter und damit der Optimierungsaufwand signifikant gesenkt werden und zum anderen wurden Fehlerquellen in der Signalverarbeitungskette eliminiert.

Die komplexen Filtergleichungen wurden graphentheoretisch interpretiert und es wurde ein Implementierungsvorschlag abgeleitet. Zum intuitiven Verständnis der Funktionsweise und zur Erleichterung der Filterparametrisierung ermöglichten Simulationen die Analyse des Übertragungsverhaltens des JIPDA-Filters von den sensorischen Eingangsdaten und von den Modellparametern auf den Existenzwahrscheinlichkeitsausgang.

Der Funktionsnachweis mit realen Sensordaten konnte anhand eines Prototypsystems erbracht werden. Das Prototypsystem besteht aus einer Video-Lidar-Sensorkombination für Autobahn- und Landstraßenszenarien. Als wesentliche Algorithmenbestandteile des Prototypsystems wurden neben dem JIPDA-Filter eine automatische Sensorkreuzkalibrierung, eine Eigenbewegungsschätzung unter Berücksichtigung des autokorrelierten Beschleunigungs-Prozessrauschens und erstmalig eine von einem Abstandssensor aufmerksamkeitsgesteuerte Objektdetektion mit einem kaskadierten „Boosting“-basierten Videoklassifikator vorgestellt. Ohne detaillierte Ausführungen in dieser Niederschrift entstand außerdem eine Mikrocontrollerplattform zur ersatzweisen Echtzeit-Zeitstempelgenerierung bzw. zur Synchronisation der Messzeitpunkte in Abwesenheit einer „Flexray“-Vernetzung. Diese Zeitsynchronisation ist eine weitere Voraussetzung für eine konsistente Sensordatenfusion.

Darüber hinaus wurde eine Steigerung der Erkennungsleistung durch die Verwendung des JIPDA-Filters anhand der Sensordaten des Prototypsystems mittels ROC-Kurven belegt und eine Konsistenzanalyse anhand eines für gewichtete Innovationen neu entwickelten Konsistenztests durchgeführt. Das Prototypsystem ist in einem Versuchsfahrzeug implementiert, mittlerweile wahlweise mit Lidar- oder Radartechnologie betreibbar und es ist in der Lage, bewegte und auch permanent stehende Fahrzeuge in Echtzeit mit Reichweiten bis zu 200 Metern zu erkennen und zu verfolgen.

Anhang A

Herleitungen

Lemma 1. *Im Diskreten gilt die Identität:*

$$J[p] = D_{KL}[p||\mathcal{U}]. \quad (\text{A.1})$$

Beweis

$$D_{KL}[p||\mathcal{U}] = \sum_{i=1}^{|X|} p(x_i) \cdot \log_b \frac{p(x_i)}{\mathcal{U}(x_i)} \quad (\text{A.2})$$

$$= \sum_{i=1}^{|X|} p(x_i) \log_b (|X| \cdot p(x_i)) \quad (\text{A.3})$$

$$= \sum_{i=1}^{|X|} p(x_i) (\log_b |X| + \log_b p(x_i)) \quad (\text{A.4})$$

$$= \sum_{i=1}^{|X|} p(x_i) \log_b |X| + \sum_{i=1}^{|X|} \log_b p(x_i) \quad (\text{A.5})$$

$$= \log_b |X| + \sum_{i=1}^{|X|} \log_b p(x_i) = J[p] \quad \square \quad (\text{A.6})$$

Lemma 2. *Im Diskreten gilt die Identität:*

$$H[p] = E_i\{D_{KL}[\delta_{x_i}||p]\}. \quad (\text{A.7})$$

Beweis

$$E_p\{D_{KL}[\delta_i||p]\} = \sum_{i=1}^{|X|} p(x_i) D_{KL}[\delta_{x_i}||p] \quad (\text{A.8})$$

$$= \sum_{i=1}^{|X|} p(x_i) \sum_{j=1}^{|X|} \delta_{x_i}(x_j) \log_b \frac{\delta_{x_i}(x_j)}{p(x_j)} \quad (\text{A.9})$$

$$= \sum_{i=1}^{|X|} p(x_i) \log_b \frac{1}{p(x_i)} \quad (\text{A.10})$$

$$= - \sum_{i=1}^{|X|} p(x_i) \log_b p(x_i) = H[p] \quad \square \quad (\text{A.11})$$

Lemma 3. (*Matrix-Inversions-Lemma*)

Für die Kovarianzmatrizen $\mathbf{B}$ und $\mathbf{C}$ (symmetrisch, positiv definit) gilt

$$(\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1})^{-1} = \mathbf{C} - \mathbf{C} \mathbf{A}^T (\mathbf{A} \mathbf{C} \mathbf{A}^T + \mathbf{B})^{-1} \mathbf{A} \mathbf{C}. \quad (\text{A.12})$$

Beweis Siehe z.B. [5], Seite 13.

Lemma 4. Für die Kovarianzmatrizen $\mathbf{B}$ und $\mathbf{C}$ (symmetrisch, positiv definit) gilt

$$(\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1})^{-1} \mathbf{A}^T \mathbf{B}^{-1} = \mathbf{C} \mathbf{A}^T (\mathbf{A} \mathbf{C} \mathbf{A}^T + \mathbf{B})^{-1}. \quad (\text{A.13})$$

Beweis

$$\begin{aligned} & (\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1})^{-1} \mathbf{A}^T \mathbf{B}^{-1} \\ &= [\mathbf{C} - \mathbf{C} \mathbf{A}^T (\mathbf{A} \mathbf{C} \mathbf{A}^T + \mathbf{B})^{-1} \mathbf{A} \mathbf{C}] \mathbf{A}^T \mathbf{B}^{-1} \\ &= \mathbf{C} [\mathbf{A}^T - \mathbf{A}^T (\mathbf{A} \mathbf{C} \mathbf{A}^T + \mathbf{B})^{-1} \mathbf{A} \mathbf{C} \mathbf{A}^T] \mathbf{B}^{-1} \\ &= \mathbf{C} \mathbf{A}^T (\mathbf{A} \mathbf{C} \mathbf{A}^T + \mathbf{B})^{-1} [(\mathbf{A} \mathbf{C} \mathbf{A}^T + \mathbf{B}) - \mathbf{A} \mathbf{C} \mathbf{A}^T] \mathbf{B}^{-1} \\ &= \mathbf{C} \mathbf{A}^T (\mathbf{A} \mathbf{C} \mathbf{A}^T + \mathbf{B})^{-1} \quad \square \end{aligned} \quad (\text{A.14})$$

Lemma 5. Für die Kovarianzmatrizen $\mathbf{B}$ und $\mathbf{C}$ (symmetrisch, positiv definit) gilt

$$\begin{aligned} & (\mathbf{a} - \mathbf{A} \mathbf{x})^T \mathbf{B}^{-1} (\mathbf{a} - \mathbf{A} \mathbf{x}) + (\mathbf{b} - \mathbf{x})^T \mathbf{C}^{-1} (\mathbf{b} - \mathbf{x}) = \\ & (\mathbf{x} - \mathbf{y})^T \mathbf{D}^{-1} (\mathbf{x} - \mathbf{y}) + (\mathbf{a} - \mathbf{A} \mathbf{b})^T \mathbf{E}^{-1} (\mathbf{a} - \mathbf{A} \mathbf{b}) \end{aligned} \quad (\text{A.15})$$

mit

$$\mathbf{y} = \mathbf{b} + \mathbf{C} \mathbf{A}^T (\mathbf{A} \mathbf{C} \mathbf{A}^T + \mathbf{B})^{-1} (\mathbf{a} - \mathbf{A} \mathbf{b}) \quad (\text{A.16})$$

$$\mathbf{D} = \mathbf{C} - \mathbf{C} \mathbf{A}^T (\mathbf{A} \mathbf{C} \mathbf{A}^T + \mathbf{B})^{-1} \mathbf{A} \mathbf{C} \quad (\text{A.17})$$

$$\mathbf{E} = \mathbf{A} \mathbf{C} \mathbf{A}^T + \mathbf{B}. \quad (\text{A.18})$$

Beweis Ausführliche Variante basierend auf [77]. Additive Nullen sind durch geschweifte Klammern gekennzeichnet.

$$\begin{aligned}
& (\mathbf{a} - \mathbf{Ax})^T \mathbf{B}^{-1} (\mathbf{a} - \mathbf{Ax}) + (\mathbf{b} - \mathbf{x})^T \mathbf{C}^{-1} (\mathbf{b} - \mathbf{x}) \\
&= (\mathbf{a}^T - \mathbf{x}^T \mathbf{A}^T) \mathbf{B}^{-1} (\mathbf{a} - \mathbf{Ax}) + (\mathbf{b}^T - \mathbf{x}^T) \mathbf{C}^{-1} (\mathbf{b} - \mathbf{x}) \\
&= (\mathbf{a}^T \mathbf{B}^{-1} - \mathbf{x}^T \mathbf{A}^T \mathbf{B}^{-1}) (\mathbf{a} - \mathbf{Ax}) + (\mathbf{b}^T \mathbf{C}^{-1} - \mathbf{x}^T \mathbf{C}^{-1}) (\mathbf{b} - \mathbf{x}) \\
&= \mathbf{a}^T \mathbf{B}^{-1} \mathbf{a} - \mathbf{a}^T \mathbf{B}^{-1} \mathbf{Ax} - \mathbf{x}^T \mathbf{A}^T \mathbf{B}^{-1} \mathbf{a} + \mathbf{x}^T \mathbf{A}^T \mathbf{B}^{-1} \mathbf{Ax} \\
&\quad + \mathbf{b}^T \mathbf{C}^{-1} \mathbf{b} - \mathbf{b}^T \mathbf{C}^{-1} \mathbf{x} - \mathbf{x}^T \mathbf{C}^{-1} \mathbf{b} + \mathbf{x}^T \mathbf{C}^{-1} \mathbf{x} \\
&= -\mathbf{x}^T (\mathbf{A}^T \mathbf{B}^{-1} \mathbf{a} + \mathbf{C}^{-1} \mathbf{b}) - (\mathbf{a}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{b}^T \mathbf{C}^{-1}) \mathbf{x} \\
&\quad + \mathbf{x}^T (\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1}) \mathbf{x} + \mathbf{a}^T \mathbf{B}^{-1} \mathbf{a} + \mathbf{b}^T \mathbf{C}^{-1} \mathbf{b} \\
&= -\mathbf{x}^T (\mathbf{A}^T \mathbf{B}^{-1} \mathbf{a} + \mathbf{C}^{-1} \mathbf{b} + \{\mathbf{A}^T \mathbf{B}^{-1} \mathbf{Ab} - \mathbf{A}^T \mathbf{B}^{-1} \mathbf{Ab}\}) \\
&\quad - (\mathbf{a}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{b}^T \mathbf{C}^{-1} + \{\mathbf{b}^T \mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} - \mathbf{b}^T \mathbf{A}^T \mathbf{B}^{-1} \mathbf{A}\}) \mathbf{x} \\
&\quad + \mathbf{x}^T (\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1}) \mathbf{x} + \mathbf{a}^T \mathbf{B}^{-1} \mathbf{a} + \mathbf{b}^T \mathbf{C}^{-1} \mathbf{b} \tag{A.19} \\
&= -\mathbf{x}^T [\mathbf{A}^T \mathbf{B}^{-1} (\mathbf{a} - \mathbf{Ab}) + (\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1}) \mathbf{b}] \\
&\quad - [(\mathbf{a}^T - \mathbf{b}^T \mathbf{A}^T) \mathbf{B}^{-1} \mathbf{A} + \mathbf{b}^T (\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1})] \mathbf{x} \\
&\quad + \mathbf{x}^T (\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1}) \mathbf{x} + \mathbf{a}^T \mathbf{B}^{-1} \mathbf{a} + \mathbf{b}^T \mathbf{C}^{-1} \mathbf{b} \\
&= -\mathbf{x}^T (\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1}) [(\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1})^{-1} \mathbf{A}^T \mathbf{B}^{-1} (\mathbf{a} - \mathbf{Ab}) + \mathbf{b}] \\
&\quad - [(\mathbf{a} - \mathbf{Ab})^T \mathbf{B}^{-1} \mathbf{A} (\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1})^{-1} + \mathbf{b}^T] (\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1}) \mathbf{x} \\
&\quad + \mathbf{x}^T (\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1}) \mathbf{x} + \mathbf{a}^T \mathbf{B}^{-1} \mathbf{a} + \mathbf{b}^T \mathbf{C}^{-1} \mathbf{b} \\
&= -\mathbf{x}^T (\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1}) [(\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1})^{-1} \mathbf{A}^T \mathbf{B}^{-1} (\mathbf{a} - \mathbf{Ab}) + \mathbf{b}] \\
&\quad - [(\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1})^{-1} \mathbf{A}^T \mathbf{B}^{-1} (\mathbf{a} - \mathbf{Ab}) + \mathbf{b}]^T (\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1}) \mathbf{x} \\
&\quad + \mathbf{x}^T (\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1}) \mathbf{x} + \mathbf{a}^T \mathbf{B}^{-1} \mathbf{a} + \mathbf{b}^T \mathbf{C}^{-1} \mathbf{b}
\end{aligned}$$

Aus Lemma 4 folgt

$$\begin{aligned}
&= -\mathbf{x}^T (\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1}) [\mathbf{b} + \mathbf{CA}^T (\mathbf{ACA}^T + \mathbf{B})^{-1} (\mathbf{a} - \mathbf{Ab})] \\
&\quad - [\mathbf{b} + \mathbf{CA}^T (\mathbf{ACA}^T + \mathbf{B})^{-1} (\mathbf{a} - \mathbf{Ab})]^T (\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1}) \mathbf{x} \\
&\quad + \mathbf{x}^T (\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1}) \mathbf{x} + \mathbf{a}^T \mathbf{B}^{-1} \mathbf{a} + \mathbf{b}^T \mathbf{C}^{-1} \mathbf{b}. \tag{A.20}
\end{aligned}$$

Mit den Abkürzungen (A.16) und (A.17), sowie Lemma 3 ergibt sich:

$$\begin{aligned}
&= -\mathbf{x}^T \mathbf{D}^{-1} \mathbf{y} - \mathbf{y}^T \mathbf{D}^{-1} \mathbf{x} + \mathbf{x}^T \mathbf{D}^{-1} \mathbf{x} + \mathbf{a}^T \mathbf{B}^{-1} \mathbf{a} + \mathbf{b}^T \mathbf{C}^{-1} \mathbf{b} \\
&= -\mathbf{x}^T \mathbf{D}^{-1} \mathbf{y} - \mathbf{y}^T \mathbf{D}^{-1} \mathbf{x} + \mathbf{x}^T \mathbf{D}^{-1} \mathbf{x} + \mathbf{a}^T \mathbf{B}^{-1} \mathbf{a} + \mathbf{b}^T \mathbf{C}^{-1} \mathbf{b} \\
&\quad + \{\mathbf{y}^T \mathbf{D}^{-1} \mathbf{y} - \mathbf{y}^T \mathbf{D}^{-1} \mathbf{y}\} \\
&= (\mathbf{x}^T \mathbf{D}^{-1} - \mathbf{y}^T \mathbf{D}^{-1}) \mathbf{x} - (\mathbf{x}^T \mathbf{D}^{-1} - \mathbf{y}^T \mathbf{D}^{-1}) \mathbf{y} - \mathbf{y}^T \mathbf{D}^{-1} \mathbf{y} \\
&\quad + \mathbf{a}^T \mathbf{B}^{-1} \mathbf{a} + \mathbf{b}^T \mathbf{C}^{-1} \mathbf{b} \tag{A.21} \\
&= (\mathbf{x} - \mathbf{y})^T \mathbf{D}^{-1} (\mathbf{x} - \mathbf{y}) - \mathbf{y}^T \mathbf{D}^{-1} \mathbf{y} + \mathbf{a}^T \mathbf{B}^{-1} \mathbf{a} + \mathbf{b}^T \mathbf{C}^{-1} \mathbf{b} \\
&= (\mathbf{x} - \mathbf{y})^T \mathbf{D}^{-1} (\mathbf{x} - \mathbf{y}) + \mathbf{a}^T \mathbf{B}^{-1} \mathbf{a} + \mathbf{b}^T \mathbf{C}^{-1} \mathbf{b} \\
&\quad - [\mathbf{b}^T + (\mathbf{a} - \mathbf{AB})^T \mathbf{B}^{-1} \mathbf{AD}] \mathbf{D}^{-1} [\mathbf{DA}^T \mathbf{B}^{-1} (\mathbf{a} - \mathbf{Ab}) + \mathbf{b}]
\end{aligned}$$

$$\begin{aligned}
&= (\mathbf{x} - \mathbf{y})^T \mathbf{D}^{-1} (\mathbf{x} - \mathbf{y}) + \mathbf{a}^T \mathbf{B}^{-1} \mathbf{a} + \mathbf{b}^T \mathbf{C}^{-1} \mathbf{b} \\
&\quad + [-\mathbf{b}^T \mathbf{D}^{-1} - (\mathbf{a} - \mathbf{A}\mathbf{b})^T \mathbf{B}^{-1} \mathbf{A}] [\mathbf{D} \mathbf{A}^T \mathbf{B}^{-1} (\mathbf{a} - \mathbf{A}\mathbf{b}) + \mathbf{b}] \\
&= (\mathbf{x} - \mathbf{y})^T \mathbf{D}^{-1} (\mathbf{x} - \mathbf{y}) + \mathbf{a}^T \mathbf{B}^{-1} \mathbf{a} + \mathbf{b}^T \mathbf{C}^{-1} \mathbf{b} - (\mathbf{a}^T - \mathbf{b}^T \mathbf{A}^T) \mathbf{B}^{-1} \mathbf{A} \mathbf{b} \\
&\quad - \mathbf{b}^T \mathbf{A}^T \mathbf{B}^{-1} (\mathbf{a} - \mathbf{A}\mathbf{b}) - \mathbf{b}^T \mathbf{D}^{-1} \mathbf{b} - (\mathbf{a} - \mathbf{A}\mathbf{b})^T \mathbf{B}^{-1} \mathbf{A} \mathbf{D} \mathbf{A}^T \mathbf{B}^{-1} (\mathbf{a} - \mathbf{A}\mathbf{b}) \\
&= (\mathbf{x} - \mathbf{y})^T \mathbf{D}^{-1} (\mathbf{x} - \mathbf{y}) + \mathbf{a}^T \mathbf{B}^{-1} \mathbf{a} + \mathbf{b}^T \mathbf{C}^{-1} \mathbf{b} \\
&\quad - (\mathbf{a} - \mathbf{A}\mathbf{b})^T \mathbf{B}^{-1} \mathbf{A} \mathbf{D} \mathbf{A}^T \mathbf{B}^{-1} (\mathbf{a} - \mathbf{A}\mathbf{b}) - \mathbf{a}^T \mathbf{B}^{-1} \mathbf{A} \mathbf{b} + \mathbf{b}^T \mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} \mathbf{b} \\
&\quad - \mathbf{b}^T \mathbf{A}^T \mathbf{B}^{-1} \mathbf{a} + \mathbf{b}^T \mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} \mathbf{b} - \mathbf{b}^T (\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1}) \mathbf{b} \\
&= (\mathbf{x} - \mathbf{y})^T \mathbf{D}^{-1} (\mathbf{x} - \mathbf{y}) + \mathbf{a}^T \mathbf{B}^{-1} \mathbf{a} - \mathbf{b}^T \mathbf{A}^T \mathbf{B}^{-1} \mathbf{a} + \mathbf{b}^T \mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} \mathbf{b} \\
&\quad - (\mathbf{a} - \mathbf{A}\mathbf{b})^T \mathbf{B}^{-1} \mathbf{A} \mathbf{D} \mathbf{A}^T \mathbf{B}^{-1} (\mathbf{a} - \mathbf{A}\mathbf{b}) - \mathbf{a}^T \mathbf{B}^{-1} \mathbf{A} \mathbf{b} \tag{A.22} \\
&= (\mathbf{x} - \mathbf{y})^T \mathbf{D}^{-1} (\mathbf{x} - \mathbf{y}) - (\mathbf{a} - \mathbf{A}\mathbf{b})^T \mathbf{B}^{-1} \mathbf{A} \mathbf{D} \mathbf{A}^T \mathbf{B}^{-1} (\mathbf{a} - \mathbf{A}\mathbf{b}) \\
&\quad + (\mathbf{a}^T \mathbf{B}^{-1} - \mathbf{b}^T \mathbf{A}^T \mathbf{B}^{-1}) \mathbf{a} - (\mathbf{a}^T \mathbf{B}^{-1} - \mathbf{b}^T \mathbf{A}^T \mathbf{B}^{-1}) \mathbf{A} \mathbf{b} \\
&= (\mathbf{x} - \mathbf{y})^T \mathbf{D}^{-1} (\mathbf{x} - \mathbf{y}) - (\mathbf{a} - \mathbf{A}\mathbf{b})^T \mathbf{B}^{-1} \mathbf{A} \mathbf{D} \mathbf{A}^T \mathbf{B}^{-1} (\mathbf{a} - \mathbf{A}\mathbf{b}) \\
&\quad (\mathbf{a}^T - \mathbf{b}^T \mathbf{A}^T) \mathbf{B}^{-1} (\mathbf{a} - \mathbf{A}\mathbf{b}) \\
&= (\mathbf{x} - \mathbf{y})^T \mathbf{D}^{-1} (\mathbf{x} - \mathbf{y}) \\
&\quad + (\mathbf{a} - \mathbf{A}\mathbf{b})^T (\mathbf{B}^{-1} - \mathbf{B}^{-1} \mathbf{A} (\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1})^{-1} \mathbf{A}^T \mathbf{B}^{-1}) (\mathbf{a} - \mathbf{A}\mathbf{b}) \\
&= (\mathbf{x} - \mathbf{y})^T \mathbf{D}^{-1} (\mathbf{x} - \mathbf{y}) + (\mathbf{a} - \mathbf{A}\mathbf{b})^T (\mathbf{A} \mathbf{C} \mathbf{A}^T + \mathbf{B})^{-1} (\mathbf{a} - \mathbf{A}\mathbf{b}). \quad \square
\end{aligned}$$

Lemma 6. (*generalisiertes Matrix-Determinanten-Lemma*)

Für die regulären Matrizen $\mathbf{B}$ und $\mathbf{C}$ gilt:

$$|\mathbf{A} \mathbf{C} \mathbf{A}^T + \mathbf{B}| = |\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1}| |\mathbf{B}| |\mathbf{C}| \tag{A.23}$$

Beweis siehe [33].

Lemma 7. Für die Kovarianzmatrizen (symmetrisch, positiv definit) $\mathbf{B}$ und $\mathbf{C}$ gilt:

$$\int \mathcal{N}(\mathbf{a}, \mathbf{A}\mathbf{x}, \mathbf{B}) \mathcal{N}(\mathbf{x}, \mathbf{b}, \mathbf{C}) d\mathbf{x} = \mathcal{N}(\mathbf{a}, \mathbf{A}\mathbf{b}, \mathbf{A} \mathbf{C} \mathbf{A}^T + \mathbf{B}). \tag{A.24}$$

Beweis $m = \dim(\mathbf{a})$, $n = \dim(\mathbf{x})$

$$\begin{aligned}
&\int \mathcal{N}(\mathbf{a}, \mathbf{A}\mathbf{x}, \mathbf{B}) \mathcal{N}(\mathbf{x}, \mathbf{b}, \mathbf{C}) d\mathbf{x} \\
&= \int (2\pi)^{-\frac{m}{2}} |\mathbf{B}|^{-\frac{1}{2}} \exp \left[-\frac{1}{2} (\mathbf{a} - \mathbf{A}\mathbf{x})^T \mathbf{B}^{-1} (\mathbf{a} - \mathbf{A}\mathbf{x}) \right] \\
&\quad \cdot (2\pi)^{-\frac{n}{2}} |\mathbf{C}|^{-\frac{1}{2}} \exp \left[-\frac{1}{2} (\mathbf{x} - \mathbf{b})^T \mathbf{C}^{-1} (\mathbf{x} - \mathbf{b}) \right] d\mathbf{x} \\
&= (2\pi)^{-\frac{m+n}{2}} (|\mathbf{B}| |\mathbf{C}|)^{-\frac{1}{2}} \int \exp \left[-\frac{1}{2} ((\mathbf{a} - \mathbf{A}\mathbf{x})^T \mathbf{B}^{-1} (\mathbf{a} - \mathbf{A}\mathbf{x}) + (\mathbf{x} - \mathbf{b})^T \mathbf{C}^{-1} (\mathbf{x} - \mathbf{b})) \right] d\mathbf{x} \tag{A.25}
\end{aligned}$$

Aus Lemma 5 folgt:

$$\begin{aligned}
&= (2\pi)^{-\frac{m+n}{2}} (|\mathbf{B}||\mathbf{C}|)^{-\frac{1}{2}} \int \exp \left[-\frac{1}{2} ((\mathbf{x} - \mathbf{y})^T \mathbf{D}^{-1} (\mathbf{x} - \mathbf{y}) + (\mathbf{a} - \mathbf{Ab})^T \mathbf{E}^{-1} (\mathbf{a} - \mathbf{Ab})) \right] d\mathbf{x} \\
&= (2\pi)^{-\frac{m+n}{2}} (|\mathbf{B}||\mathbf{C}|)^{-\frac{1}{2}} \exp \left[-\frac{1}{2} (\mathbf{a} - \mathbf{Ab})^T \mathbf{E}^{-1} (\mathbf{a} - \mathbf{Ab}) \right] \int \exp \left[-\frac{1}{2} (\mathbf{x} - \mathbf{y})^T \mathbf{D}^{-1} (\mathbf{x} - \mathbf{y}) \right] d\mathbf{x}
\end{aligned} \tag{A.26}$$

Aus der Definitionsgleichung einer Wahrscheinlichkeitsdichtefunktion $1 = \int \mathcal{N}(\mathbf{x}, \mathbf{y}, \mathbf{D}) d\mathbf{x}$ folgt:

$$= (2\pi)^{-\frac{m+n}{2}} (|\mathbf{B}||\mathbf{C}|)^{-\frac{1}{2}} \exp \left[-\frac{1}{2} (\mathbf{a} - \mathbf{Ab})^T \mathbf{E}^{-1} (\mathbf{a} - \mathbf{Ab}) \right] (2\pi)^{\frac{n}{2}} |\mathbf{D}|^{\frac{1}{2}} \tag{A.27}$$

Mit Lemma 3 und Lemma 6 ergibt sich:

$$\begin{aligned}
&= (2\pi)^{-\frac{m}{2}} (|\mathbf{D}^{-1}||\mathbf{B}||\mathbf{C}|)^{-\frac{1}{2}} \exp \left[-\frac{1}{2} (\mathbf{a} - \mathbf{Ab})^T \mathbf{E}^{-1} (\mathbf{a} - \mathbf{Ab}) \right] \\
&= (2\pi)^{-\frac{m}{2}} (|\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1}||\mathbf{B}||\mathbf{C}|)^{-\frac{1}{2}} \exp \left[-\frac{1}{2} (\mathbf{a} - \mathbf{Ab})^T \mathbf{E}^{-1} (\mathbf{a} - \mathbf{Ab}) \right] \\
&= (2\pi)^{-\frac{m}{2}} |\mathbf{ACA}^T + \mathbf{B}|^{-\frac{1}{2}} \exp \left[-\frac{1}{2} (\mathbf{a} - \mathbf{Ab})^T (\mathbf{ACA}^T + \mathbf{B})^{-1} (\mathbf{a} - \mathbf{Ab}) \right] \\
&= \mathcal{N}(\mathbf{a}, \mathbf{Ab}, \mathbf{ACA}^T + \mathbf{B}) \quad \square
\end{aligned} \tag{A.28}$$

Lemma 8. Für die Kovarianzmatrizen (symmetrisch, positiv definit) $\mathbf{B}$ und $\mathbf{C}$ gilt

$$\frac{\mathcal{N}(\mathbf{a}, \mathbf{Ax}, \mathbf{B}) \mathcal{N}(\mathbf{x}, \mathbf{b}, \mathbf{C})}{\mathcal{N}(\mathbf{a}, \mathbf{Ab}, \mathbf{E})} = \mathcal{N}(\mathbf{x}, \mathbf{y}, \mathbf{D}) \tag{A.29}$$

mit den Abkürzungen (A.16)-(A.18) für $\mathbf{y}$, $\mathbf{D}$ und $\mathbf{E}$.

Beweis

$$\begin{aligned}
&\frac{\mathcal{N}(\mathbf{a}, \mathbf{Ax}, \mathbf{B}) \mathcal{N}(\mathbf{x}, \mathbf{b}, \mathbf{C})}{\mathcal{N}(\mathbf{a}, \mathbf{Ab}, \mathbf{ACA}^T + \mathbf{B})} \\
&= \frac{(2\pi)^{-\frac{m+n}{2}} (|\mathbf{B}||\mathbf{C}|)^{-\frac{1}{2}} \exp \left[-\frac{1}{2} (\mathbf{a} - \mathbf{Ax})^T \mathbf{B}^{-1} (\mathbf{a} - \mathbf{Ax}) \right] \exp \left[-\frac{1}{2} (\mathbf{x} - \mathbf{b})^T \mathbf{C}^{-1} (\mathbf{x} - \mathbf{b}) \right]}{(2\pi)^{-\frac{m}{2}} |\mathbf{ACA}^T + \mathbf{B}|^{-\frac{1}{2}} \exp \left[-\frac{1}{2} (\mathbf{a} - \mathbf{Ab})^T \mathbf{E}^{-1} (\mathbf{a} - \mathbf{Ab}) \right]} \\
&= (2\pi)^{-\frac{n}{2}} (|\mathbf{B}||\mathbf{C}|)^{-\frac{1}{2}} |\mathbf{ACA}^T + \mathbf{B}|^{\frac{1}{2}} \\
&\quad \cdot \frac{\exp \left[-\frac{1}{2} ((\mathbf{a} - \mathbf{Ax})^T \mathbf{B}^{-1} (\mathbf{a} - \mathbf{Ax}) + (\mathbf{x} - \mathbf{b})^T \mathbf{C}^{-1} (\mathbf{x} - \mathbf{b})) \right]}{\exp \left[-\frac{1}{2} (\mathbf{a} - \mathbf{Ab})^T \mathbf{E}^{-1} (\mathbf{a} - \mathbf{Ab}) \right]}
\end{aligned} \tag{A.30}$$

Mit Lemma 5 und Lemma 6 folgt:

$$\begin{aligned}
&= (2\pi)^{-\frac{n}{2}} (|\mathbf{B}||\mathbf{C}|)^{-\frac{1}{2}} (|\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1}||\mathbf{B}||\mathbf{C}|)^{\frac{1}{2}} \\
&\quad \cdot \frac{\exp \left[-\frac{1}{2} ((\mathbf{x} - \mathbf{y})^T \mathbf{D}^{-1} (\mathbf{x} - \mathbf{y}) + (\mathbf{a} - \mathbf{Ab})^T \mathbf{E}^{-1} (\mathbf{a} - \mathbf{Ab})) \right]}{\exp \left[-\frac{1}{2} (\mathbf{a} - \mathbf{Ab})^T \mathbf{E}^{-1} (\mathbf{a} - \mathbf{Ab}) \right]} \\
&= (2\pi)^{-\frac{n}{2}} |\mathbf{A}^T \mathbf{B}^{-1} \mathbf{A} + \mathbf{C}^{-1}|^{\frac{1}{2}} \\
&\quad \cdot \frac{\exp \left[-\frac{1}{2} (\mathbf{x} - \mathbf{y})^T \mathbf{D}^{-1} (\mathbf{x} - \mathbf{y}) \right] \exp \left[-\frac{1}{2} (\mathbf{a} - \mathbf{Ab})^T \mathbf{E}^{-1} (\mathbf{a} - \mathbf{Ab}) \right]}{\exp \left[-\frac{1}{2} (\mathbf{a} - \mathbf{Ab})^T \mathbf{E}^{-1} (\mathbf{a} - \mathbf{Ab}) \right]}
\end{aligned} \tag{A.31}$$

Aus Lemma 3 und Abkürzung (A.17) ergibt sich:

$$\begin{aligned}
&= (2\pi)^{-\frac{n}{2}} |\mathbf{C} - \mathbf{C}\mathbf{A}^T(\mathbf{A}\mathbf{C}\mathbf{A}^T + \mathbf{B})^{-1}\mathbf{A}\mathbf{C}|^{-\frac{1}{2}} \exp \left[-\frac{1}{2}(\mathbf{x} - \mathbf{y})^T \mathbf{D}^{-1}(\mathbf{x} - \mathbf{y}) \right] \\
&= (2\pi)^{-\frac{n}{2}} |\mathbf{D}|^{-\frac{1}{2}} \exp \left[-\frac{1}{2}(\mathbf{x} - \mathbf{y})^T \mathbf{D}^{-1}(\mathbf{x} - \mathbf{y}) \right] \\
&= \mathcal{N}(\mathbf{x}, \mathbf{y}, \mathbf{D}). \quad \square
\end{aligned} \tag{A.32}$$

Lemma 9. Für das Produkt der Normalverteilungen $\mathcal{N}(\mathbf{a}^j, \mathbf{A}\mathbf{b}^i, \mathbf{E}^{ij})$ gilt:

$$\begin{aligned}
&\prod_{i=1}^N \mathcal{N}(\mathbf{a}^j, \mathbf{A}\mathbf{b}^i, \mathbf{E}^{ij}) = \\
&(2\pi)^{-\frac{\dim(\mathbf{a}^j)N}{2}} \exp \left[-\frac{1}{2} \sum_{i=1}^N [(\mathbf{a}^j - \mathbf{A}\mathbf{b}^i)^T (\mathbf{E}^{ij})^{-1} (\mathbf{a}^j - \mathbf{A}\mathbf{b}^i) + \ln |\mathbf{E}^{ij}|] \right]. \tag{A.33}
\end{aligned}$$

Beweis

$$\begin{aligned}
&\prod_{i=1}^N \mathcal{N}(\mathbf{a}^j, \mathbf{A}\mathbf{b}^i, \mathbf{E}^{ij}) \\
&= \prod_{i=1}^N \left[(2\pi)^{-\frac{\dim(\mathbf{a}^j)}{2}} |\mathbf{E}^{ij}|^{-\frac{1}{2}} \exp \left[-\frac{1}{2}(\mathbf{a}^j - \mathbf{A}\mathbf{b}^i)^T (\mathbf{E}^{ij})^{-1} (\mathbf{a}^j - \mathbf{A}\mathbf{b}^i) \right] \right] \\
&= (2\pi)^{-\frac{\dim(\mathbf{a}^j)N}{2}} \prod_{i=1}^N \left[\exp \left[-\frac{1}{2} \ln |\mathbf{E}^{ij}| \right] \exp \left[-\frac{1}{2}(\mathbf{a}^j - \mathbf{A}\mathbf{b}^i)^T (\mathbf{E}^{ij})^{-1} (\mathbf{a}^j - \mathbf{A}\mathbf{b}^i) \right] \right] \tag{A.34} \\
&= (2\pi)^{-\frac{\dim(\mathbf{a}^j)N}{2}} \prod_{i=1}^N \exp \left[-\frac{1}{2} [(\mathbf{a}^j - \mathbf{A}\mathbf{b}^i)^T (\mathbf{E}^{ij})^{-1} (\mathbf{a}^j - \mathbf{A}\mathbf{b}^i) + \ln |\mathbf{E}^{ij}|] \right] \\
&= (2\pi)^{-\frac{\dim(\mathbf{a}^j)N}{2}} \exp \left[-\frac{1}{2} \sum_{i=1}^N [(\mathbf{a}^j - \mathbf{A}\mathbf{b}^i)^T (\mathbf{E}^{ij})^{-1} (\mathbf{a}^j - \mathbf{A}\mathbf{b}^i) + \ln |\mathbf{E}^{ij}|] \right] \quad \square
\end{aligned}$$

Lemma 10. Aus dem wahrscheinlichkeitsgenerierenden Funktional der Multiobjekt-Multi-Bernoulli-Verteilung (MMBV) mit der Generatormenge $v = 1..V$, den Generationswahrscheinlichkeiten p_v^G und den Generatordichtefunktionen $f_v^G(\mathbf{y})$

$$G[h] = (q^G + p^G \langle f^G, h \rangle)^V \tag{A.35}$$

ergibt sich mit $n = |Y|$ die Wahrscheinlichkeitsdichtefunktion:

$$p(Y) = \sum_{1 \leq i_1 \neq \dots \neq i_n \leq |V|} \prod_{j=1}^n p_{i_j}^G f_{i_j}^G(\mathbf{y}_j) \prod_{l \in \{1, \dots, |V|\} \setminus \{i_1, \dots, i_n\}} q_l^G. \tag{A.36}$$

Beweis Ausführliche Version basierend auf [58]. Die gesuchte Wahrscheinlichkeitsdichtefunktion entspricht der Ableitung des wahrscheinlichkeitsgenerierenden Funktionals an der Stelle Null, da die Indikatorfunktion (3.11) der leeren Menge die Nullfunktion ist:

$$p(Y) = \frac{d\beta_Y}{dY}(\emptyset) = \frac{dG}{dY}[0]. \quad (\text{A.37})$$

Über die allgemeine Produktregel (3.19) ergibt sich:

$$\frac{d \left[\prod_{v=1}^{|V|} q_v^G + p_v^G \langle f_v^G, h \rangle \right]}{dY} [0] = \sum_{W_1 \uplus \dots \uplus W_{|V|=Y}} \prod_{v=1}^{|V|} \frac{d [q_v^G + p_v^G \langle f_v^G, h \rangle]}{dW_v} [0]. \quad (\text{A.38})$$

Die Summation erfolgt über sämtliche Möglichkeiten, Y aus genau $|V|$ disjunkten Teilmengen $W_v \subseteq Y$ zu konstruieren. Dabei dürfen die einzelnen W_v Null bis n Elemente enthalten, solange die Vereinigung insgesamt wieder Y ergibt. Aus der Linearitätsregel (3.16) folgt jedoch, dass alle Ableitungen eines Funktionals von h nach mehrelementigen Mengen verschwinden. Daher entfallen alle Summanden in (A.38), die mehrelementige W_v enthalten und es kann alternativ lediglich über Zerlegungen von Y in maximal einelementige w_v summiert werden:

$$p(Y) = \sum_{w_1 \uplus \dots \uplus w_{|V|=Y}} \prod_{v=1}^{|V|} \frac{d [q_v^G + p_v^G \langle f_v^G, h \rangle]}{dw_v} [0]. \quad (\text{A.39})$$

Mit der Summationsregel (3.17) ergibt sich weiter:

$$p(Y) = \sum_{w_1 \uplus \dots \uplus w_{|V|=Y}} \prod_{v=1}^{|V|} \frac{dq_v^G}{dw_v} [0] + p_v^G \frac{d \langle f_v^G, h \rangle}{dw_v} [0]. \quad (\text{A.40})$$

Die Summe in (A.40) zählt alle Möglichkeiten auf, die n Elemente der Menge Y unter Beachtung der Reihenfolge auf die $|V|$ Komponenten zu verteilen. Dies ist identisch mit der Summation über alle Variationen, jedem Element einer geordneten Aufzählung $(\mathbf{y}_1, \dots, \mathbf{y}_n)$ der Elemente aus Y , eindeutig ein Element aus V zuzuweisen:

$$p(Y) = \sum_{1 \leq i_1 \neq \dots \neq i_n \leq |V|} \prod_{j=1}^n \frac{dq_{i_j}^G}{d\mathbf{y}_j} [0] + p_{i_j}^G \frac{d \langle f_{i_j}^G, h \rangle}{d\mathbf{y}_j} [0] \cdot \prod_{l \in \{1, \dots, |V|\} \setminus \{i_1, \dots, i_n\}} \frac{dq_l^G}{d\emptyset} [0] + q_l \frac{d \langle f_l^G, h \rangle}{d\emptyset} [0]. \quad (\text{A.41})$$

Das Produkt über die $|V|$ Komponenten in A.40 wurde zusätzlich in das Produkt der $n = |Y|$ Komponenten mit einelementigen w_v und das Produkt der $|V| - n$ Komponenten mit leeren w_v faktorisiert. Mit der Konstantenregel (3.15), der Linearitätsregel (3.16) und den Definitionen (3.9) und (3.13) ergibt sich weiter:

$$p(Y) = \sum_{1 \leq i_1 \neq \dots \neq i_n \leq |V|} \prod_{j=1}^n 0[0] + p_{i_j}^G f_{i_j}^G(\mathbf{y}_j)[0] \prod_{l \in \{1, \dots, |V|\} \setminus \{i_1, \dots, i_n\}} (q_l^G)[0] + q_l \langle f_l^G, h \rangle [0]. \quad (\text{A.42})$$

Durch Einsetzen der Nullfunktion ($h = 0$) erhält man die finale Form:

$$p(Y) = \sum_{1 \leq i_1 \neq \dots \neq i_n \leq |V|} \prod_{j=1}^n p_{i_j}^G f_{i_j}^G(\mathbf{y}_j) \prod_{l \in \{1, \dots, |V|\} \setminus \{i_1, \dots, i_n\}} q_l^G, \quad \text{mit } n = |Y|. \quad \square \quad (\text{A.43})$$

Lemma 11. *Unter linearen gaußschen Annahmen gilt die Identität:*

$$\begin{aligned} G_{k|k-1}[h] &= (q_{k-1|k-1}^{\exists} + p_{k-1|k-1}^{\exists} \langle \mathcal{N}_{k-1|k-1}, q^P + p^P \langle \mathcal{N}_t, h \rangle \rangle)^V \\ &= (1 - p^P p_{k-1|k-1}^{\exists} + p^P p_{k-1|k-1}^{\exists} \langle \mathcal{N}_{k|k-1}, h \rangle)^V. \end{aligned} \quad (\text{A.44})$$

Beweis Ausführliche Version basierend auf [58]. Aufgrund der Linearität von Skalarprodukten gilt:

$$G_{k|k-1}[h] = (q_{k-1|k-1}^{\exists} + p_{k-1|k-1}^{\exists} \langle \mathcal{N}_{k-1|k-1}, q^P \rangle + p_{k-1|k-1}^{\exists} \langle \mathcal{N}_{k-1|k-1}, p^P \langle \mathcal{N}_t, h \rangle \rangle)^V. \quad (\text{A.45})$$

Die Persistenzwahrscheinlichkeit $p^P(\mathbf{x}_{k-1})$ eines Objektes hängt von dessen exaktem Zustand $\mathbf{x}_{k-1}$ ab. Im Folgenden wird angenommen, dass diese Zustandsabhängigkeit auch durch die Parameter der Verteilung, deren Realisierung $\mathbf{x}_{k-1}$ ist, ausreichend gut beschrieben wird:

$$p^{P,v}(\mathbf{x}_{k-1}) \stackrel{!}{=} p^P(\hat{\mathbf{x}}_{k-1|k-1}^v, \hat{\mathbf{P}}_{k-1|k-1}^v), \text{ mit } \mathbf{x}_{k-1} \sim \mathcal{N}(\cdot, \hat{\mathbf{x}}_{k-1|k-1}^v, \hat{\mathbf{P}}_{k-1|k-1}^v). \quad (\text{A.46})$$

Dadurch lassen sich p^P und q^P aus den Integrationen über $\mathbf{x}_{k-1}$ in den Skalarprodukten ausklammern:

$$G_{k|k-1}[h] = (q_{k-1|k-1}^{\exists} + q^P p_{k-1|k-1}^{\exists} \langle \mathcal{N}_{k-1|k-1}, 1 \rangle + p^P p_{k-1|k-1}^{\exists} \langle \mathcal{N}_{k-1|k-1}, \langle \mathcal{N}_t, h \rangle \rangle)^V. \quad (\text{A.47})$$

Mit $\langle \mathcal{N}_{k-1|k-1}, 1 \rangle = \int \mathcal{N}(\mathbf{x}_{k-1}, \hat{\mathbf{x}}_{k-1|k-1}^v, \hat{\mathbf{P}}_{k-1|k-1}^v) d\mathbf{x}_{k-1} = 1$ (zweites Kolmogorov-Axiom, (2.4)) ergibt sich weiter:

$$\begin{aligned} G_{k|k-1}[h] &= (q_{k-1|k-1}^{\exists} + q^P p_{k-1|k-1}^{\exists} + p^P p_{k-1|k-1}^{\exists} \langle \mathcal{N}_{k-1|k-1}, \langle \mathcal{N}_t, h \rangle \rangle)^V \\ &= (1 - p_{k-1|k-1}^{\exists} + (1 - p^P) p_{k-1|k-1}^{\exists} + p^P p_{k-1|k-1}^{\exists} \langle \mathcal{N}_{k-1|k-1}, \langle \mathcal{N}_t, h \rangle \rangle)^V \\ &= (1 - p_{k-1|k-1}^{\exists} + p_{k-1|k-1}^{\exists} - p^P p_{k-1|k-1}^{\exists} + p^P p_{k-1|k-1}^{\exists} \langle \mathcal{N}_{k-1|k-1}, \langle \mathcal{N}_t, h \rangle \rangle)^V \\ &= (1 - p^P p_{k-1|k-1}^{\exists} + p^P p_{k-1|k-1}^{\exists} \langle \mathcal{N}_{k-1|k-1}, \langle \mathcal{N}_t, h \rangle \rangle)^V \\ &= \left(1 - p^P p_{k-1|k-1}^{\exists} + p^P p_{k-1|k-1}^{\exists} \int \mathcal{N}(\mathbf{x}_{k-1}, \hat{\mathbf{x}}_{k-1}^v, \hat{\mathbf{P}}_{k-1}^v) \left(\int \mathcal{N}(\mathbf{x}_k, \mathbf{F}\mathbf{x}_{k-1}, \mathbf{Q}) h(\mathbf{x}_k) d\mathbf{x}_k \right) d\mathbf{x}_{k-1} \right)^V \\ &= \left(1 - p^P p_{k-1|k-1}^{\exists} + p^P p_{k-1|k-1}^{\exists} \int h(\mathbf{x}_k) \int \mathcal{N}(\mathbf{x}_k, \mathbf{F}\mathbf{x}_{k-1}, \mathbf{Q}) \mathcal{N}(\mathbf{x}_{k-1}, \hat{\mathbf{x}}_{k-1}^v, \hat{\mathbf{P}}_{k-1}^v) d\mathbf{x}_{k-1} d\mathbf{x}_k \right)^V. \end{aligned} \quad (\text{A.48})$$

Hier wurden die Kurzschreibweisen $\hat{\mathbf{x}}_{k-1}^v \stackrel{abk.}{=} \hat{\mathbf{x}}_{k-1|k-1}^v$ und $\hat{\mathbf{P}}_{k-1}^v \stackrel{abk.}{=} \hat{\mathbf{P}}_{k-1|k-1}^v$ verwendet. Mit Lemma 7, Seite 180, und der Abkürzung der prädizierten Normalverteilung des Kalman-Filters $\mathcal{N}_{k|k-1}^v = \mathcal{N}(\mathbf{x}_k, \mathbf{F}\hat{\mathbf{x}}_{k-1|k-1}^v, \mathbf{F}\hat{\mathbf{P}}_{k-1|k-1}^v\mathbf{F}^T + \mathbf{Q})$ folgt:

$$\begin{aligned} G_{k|k-1}[h] &= \left(1 - p^P p_{k-1|k-1}^{\exists} + p^P p_{k-1|k-1}^{\exists} \int h(\mathbf{x}_k) \mathcal{N}(\mathbf{x}_k, \mathbf{F}\hat{\mathbf{x}}_{k-1|k-1}^v, \mathbf{F}\hat{\mathbf{P}}_{k-1|k-1}^v\mathbf{F}^T + \mathbf{Q}) d\mathbf{x}_k \right)^V \\ &= (1 - p^P p_{k-1|k-1}^{\exists} + p^P p_{k-1|k-1}^{\exists} \langle \mathcal{N}_{k|k-1}, h \rangle)^V. \quad \square \end{aligned} \quad (\text{A.49})$$

Lemma 12. *Das Funktional*

$$F[g, h] = G_C[g|Z_k] \cdot \left(q_{k|k-1}^\exists + p_{k|k-1}^\exists \langle \mathcal{N}_{k|k-1}, h(q^D + p^D \langle \mathcal{N}_l, g \rangle) \rangle \right)^V \quad (\text{A.50})$$

lässt sich zu

$$F[g, h] = G_C[g|Z_k] \cdot \left(q_{k|k-1}^\exists + p_{k|k-1}^\exists q^D \langle \mathcal{N}_{k|k-1}, h \rangle + p_{k|k-1}^\exists p^D \langle \mathcal{N}_{k|k-1}, h \langle \mathcal{N}_l, g \rangle \rangle \right)^V \quad (\text{A.51})$$

umformen.

Beweis

$$\frac{F[g, h]}{G_C[g|Z_k]} = \left(q_{k|k-1}^\exists + p_{k|k-1}^\exists \langle \mathcal{N}_{k|k-1}, h(q^D + p^D \langle \mathcal{N}_l, g \rangle) \rangle \right)^V \quad (\text{A.52})$$

$$= \left(q_{k|k-1}^\exists + p_{k|k-1}^\exists \langle \mathcal{N}_{k|k-1}, q^D h + p^D h \langle \mathcal{N}_l, g \rangle \rangle \right)^V \quad (\text{A.53})$$

$$= \left(q_{k|k-1}^\exists + p_{k|k-1}^\exists \langle \mathcal{N}_{k|k-1}, q^D h \rangle + p_{k|k-1}^\exists \langle \mathcal{N}_{k|k-1}, p^D h \langle \mathcal{N}_l, g \rangle \rangle \right)^V \quad (\text{A.54})$$

Die Integration des äußeren Funktionsskalarproduktes erfolgt über den Zustandsraum. Da die Detektionswahrscheinlichkeiten p^D gemäß Annahme nicht vom konkret realisierten Zustand $\mathbf{x}_k$, sondern nur von den Verteilungsparametern $\hat{\mathbf{x}}_{k|k-1}^v, \hat{\mathbf{P}}_{k|k-1}^v$ der v -ten MMBV-Komponente abhängen, können sie vor das Integral geschrieben werden:

$$\frac{F[g, h]}{G_C[g|Z_k]} = \left(q_{k|k-1}^\exists + p_{k|k-1}^\exists q^D \langle \mathcal{N}_{k|k-1}, h \rangle + p_{k|k-1}^\exists p^D \langle \mathcal{N}_{k|k-1}, h \langle \mathcal{N}_l, g \rangle \rangle \right)^V. \quad \square \quad (\text{A.55})$$

Lemma 13. *Es gilt die Identität:*

$$\langle h \langle g, l \rangle, \mathcal{N} \rangle = \langle g, \langle h, l \mathcal{N} \rangle \rangle \quad (\text{A.56})$$

Beweis

$$\langle h \langle g, l \rangle, \mathcal{N} \rangle = \int_{\mathbf{x}} h(\mathbf{x}) \int_{\mathbf{z}} g(\mathbf{z}) l(\mathbf{z}|\mathbf{x}) d\mathbf{z} \cdot \mathcal{N}(\mathbf{x}) d\mathbf{x} \quad (\text{A.57})$$

$$= \int_{\mathbf{x}} \int_{\mathbf{z}} h(\mathbf{x}) g(\mathbf{z}) l(\mathbf{z}|\mathbf{x}) \mathcal{N}(\mathbf{x}) d\mathbf{z} d\mathbf{x} \quad (\text{A.58})$$

$$= \int_{\mathbf{z}} g(\mathbf{z}) \left[\int_{\mathbf{x}} h(\mathbf{x}) l(\mathbf{z}|\mathbf{x}) \mathcal{N}(\mathbf{x}) d\mathbf{x} \right] d\mathbf{z} \quad (\text{A.59})$$

$$= \langle g, \langle h, l \mathcal{N} \rangle \rangle \quad \square \quad (\text{A.60})$$

Lemma 14. *Es gilt die Identität:*

$$\begin{aligned} & \frac{d \left[(q^\exists + p^\exists q^D \langle h, \mathcal{N}_{k|k-1} \rangle + p^\exists p^D \langle h \langle g, \mathcal{N}_l \rangle, \mathcal{N}_{k|k-1} \rangle)^V \right]}{d(Z \setminus C)} \Big|_{[0, h]} \\ &= \sum_{DO^* \subseteq V: |DO^*| = |TP|} (p^\exists p^D \langle h, \mathcal{N}_l \mathcal{N}_{k|k-1} \rangle)^{DO^*} \cdot (q^\exists + p^\exists q^D \langle h, \mathcal{N}_{k|k-1} \rangle)^{V \setminus DO^*}. \end{aligned} \quad (\text{A.61})$$

Beweis Es gilt $Z \setminus C = TP$ (Abschnitt 3.3.3, Seiten 54 ff.). Mit der Produktregel (3.19) folgt:

$$\frac{d \left[(q^\exists + p^\exists q^D \langle h, \mathcal{N}_{k|k-1} \rangle + p^\exists p^D \langle h \langle g, \mathcal{N}_l \rangle, \mathcal{N}_{k|k-1} \rangle)^V \right]}{dTP} [0, h] \quad (\text{A.62})$$

$$= \sum_{\mathbf{w}_1 \uplus \dots \uplus \mathbf{w}_{|V|} = TP} \prod_{v=1}^{|V|} \frac{d \left[(q^\exists + p^\exists q^D \langle h, \mathcal{N}_{k|k-1} \rangle + p^\exists p^D \langle h \langle g, \mathcal{N}_l \rangle, \mathcal{N}_{k|k-1} \rangle)^V \right]}{d\mathbf{w}_i} [0, h] \quad (\text{A.63})$$

$$= \sum_{\uplus_{v=1}^{|V|} \mathbf{w}_v = TP} \prod_{v=1}^{|V|} \frac{dq_v^\exists}{d\mathbf{w}_v} [0, h] + p_v^\exists q_v^D \frac{d \langle h, \mathcal{N}_{k|k-1}^v \rangle}{d\mathbf{w}_v} [0, h] + p_v^\exists p_v^D \frac{d \langle h \langle g, \mathcal{N}_l \rangle, \mathcal{N}_{k|k-1}^v \rangle}{d\mathbf{w}_v} [0, h]. \quad (\text{A.64})$$

Analog zu (A.41) gilt mit Lemma 13 und (3.16), (3.15):

$$= \sum_{1 \leq i_1 \neq \dots \neq i_{|TP|} \leq |V|} \prod_{j=1}^{|TP|} \frac{dq_{i_j}^\exists}{d\mathbf{tp}_j} [0, h] + p_{i_j}^\exists q_{i_j}^D \frac{d \langle h, \mathcal{N}_{k|k-1}^{i_j} \rangle}{d\mathbf{tp}_j} [0, h] + p_{i_j}^\exists p_{i_j}^D \frac{d \langle g, \langle h, \mathcal{N}_l \mathcal{N}_{k|k-1}^{i_j} \rangle \rangle}{d\mathbf{tp}_j} [0, h] \quad (\text{A.65})$$

$$\cdot \prod_{r \in \{1..|V|\} \setminus \{i_1 \dots i_{|TP|}\}} \frac{dq_r^\exists}{d\emptyset} [0, h] + p_r^\exists q_r^D \frac{d \langle h, \mathcal{N}_{k|k-1}^r \rangle}{d\emptyset} [0, h] + p_r^\exists p_r^D \frac{d \langle g, \langle h, \mathcal{N}_l \mathcal{N}_{k|k-1}^r \rangle \rangle}{d\emptyset} [0, h] \quad (\text{A.66})$$

$$= \sum_{1 \leq i_1 \neq \dots \neq i_{|TP|} \leq |V|} \prod_{j=1}^{|TP|} p_{i_j}^\exists p_{i_j}^D \langle h, \mathcal{N}_l^j \mathcal{N}_{k|k-1}^{i_j} \rangle \cdot \prod_{r \in \{1..|V|\} \setminus \{i_1 \dots i_{|TP|}\}} q_r^\exists + p_r^\exists q_r^D \langle h, \mathcal{N}_{k|k-1}^r \rangle. \quad (\text{A.67})$$

Dabei ist der Term $\langle h, \mathcal{N}_l^j \mathcal{N}_{k|k-1}^{i_j} \rangle$ eine Kurzschreibweise für:

$$\langle h, \mathcal{N}_l^j \mathcal{N}_{k|k-1}^{i_j} \rangle = \int h(\mathbf{x}_k) \mathcal{N}(\mathbf{tp}_j, \mathbf{H}_k \mathbf{x}_k, \mathbf{R}_k) \mathcal{N}(\mathbf{x}_k, \hat{\mathbf{x}}_{k|k-1}^{i_j}, \hat{\mathbf{P}}_{k|k-1}^{i_j}) d\mathbf{x}_k. \quad (\text{A.68})$$

Es wird über alle Variationen summiert, den objektgenerierten Messungen TP Objekthypothesen des Umfeldmodells V unter Beachtung der Reihenfolge zuzuordnen. Diese zugeordneten Objekthypothesen entsprechen der hypothetisierten geordneten Menge DO^* (Abschnitt 3.3.3, Seiten 54 ff.). Folglich ergibt sich:

$$= \sum_{DO^* \subseteq V: |DO^*| = |TP|} (p^\exists p^D \langle h, \mathcal{N}_l \mathcal{N}_{k|k-1} \rangle)^{DO^*} \cdot (q^\exists + p^\exists q^D \langle h, \mathcal{N}_{k|k-1} \rangle)^{V \setminus DO^*} \quad \square \quad (\text{A.69})$$

Lemma 15. *Binomische Formel für Mengen-Potenzen*

$$(a + b)^X = \sum_{T \subseteq X} a^T \cdot b^{X \setminus T} \quad (\text{A.70})$$

Beweis Für $X = \emptyset$ gilt:

$$(a + b)^\emptyset \stackrel{!}{=} 1. \quad (\text{A.71})$$

Für $X = \{\mathbf{x}\}$ gilt (Induktionsanfang):

$$(a + b)^{\mathbf{x}} = \sum_{T \subseteq \{\mathbf{x}\}} a^T \cdot b^{X \setminus T} \quad (\text{A.72})$$

$$= a^{\emptyset} b^{\mathbf{x}} + a^{\mathbf{x}} b^{\emptyset} \quad (\text{A.73})$$

$$= b^{\mathbf{x}} + a^{\mathbf{x}} \quad (\text{A.74})$$

$$= a(\mathbf{x}) + b(\mathbf{x}). \quad (\text{A.75})$$

Definition: Für jedes Element T der Potenzmenge $P(X)$ ist das zu T duale Element T' bezüglich X definiert durch:

$$T' = X \setminus T. \quad (\text{A.76})$$

Die zu beweisende binomische Formel lässt sich schreiben als:

$$\sum_{T \subseteq X} a^T \cdot b^{X \setminus T} = \sum_{T \subseteq X} a^T b^{T'}. \quad (\text{A.77})$$

Induktionsschritt:

$$(a + b)^{X \cup \mathbf{y}} = (a + b)^X (a + b)^{\mathbf{y}} \quad (\text{A.78})$$

$$= \sum_{T \subseteq X} a^T b^{T'} \cdot (a + b)^{\mathbf{y}} \quad (\text{A.79})$$

$$= \sum_{T \subseteq X} a^{T \cup \mathbf{y}} b^{T'} + a^T b^{T' \cup \mathbf{y}} \quad (\text{A.80})$$

Die Potenzmenge der Vereinigung von X und $\mathbf{y}$ wird konstruiert durch:

$$P(X \cup \mathbf{y}) = P(X) \cup \bigcup_{T \in P(X)} \{T \cup \mathbf{y}\} \quad (\text{A.81})$$

$$= \bigcup_{T \in P(X)} \{T\} \cup \bigcup_{T \in P(X)} \{T \cup \mathbf{y}\} \quad (\text{A.82})$$

$$= \bigcup_{T \in P(X)} \{T\} \cup \{T \cup \mathbf{y}\}. \quad (\text{A.83})$$

Im ersten Summand von (A.80) ist die Menge T' das bezüglich der Vereinigung $X \cup \mathbf{y}$ duale Element von $T \cup \mathbf{y}$. Analog ist im zweiten Summand die Menge $T' \cup \mathbf{y}$ das bezüglich $X \cup \mathbf{y}$ duale Element von T . Mit (A.83) ergibt sich daher:

$$\sum_{T \subseteq X} a^{T \cup \mathbf{y}} b^{T'} + a^T b^{T' \cup \mathbf{y}} = \sum_{T \subseteq (X \cup \mathbf{y})} a^T b^{T'}. \quad \square \quad (\text{A.84})$$

Lemma 16. Aus dem Ansatz

$$\mathcal{N}_{\varrho\sigma}(\boldsymbol{\gamma}, \mathbf{0}, \mathbf{S}) = \mathcal{U}_{\varrho\sigma} \quad (\text{A.85})$$

folgt die Mahalanobis-Distanz (siehe auch Abbildung 3.8, Seite 73)

$$d_0(\varrho) = \sqrt{-2 \ln \left(\Gamma \left(1 + \frac{1}{2} \dim(\mathbf{z}) \right) \cdot \chi^2(\varrho^2, \dim(\mathbf{z})) \right)} - \dim(\mathbf{z}) \ln \frac{2}{\varrho^2}. \quad (\text{A.86})$$

Beweis Mit den Definitionen (3.121) und (3.124) sowie $\dim(\gamma) = \dim(\mathbf{z})$ folgt:

$$\mathcal{N}_{\varrho\sigma}(\gamma, \mathbf{0}, \mathbf{S}) = \mathcal{U}_{\varrho\sigma} \quad (\text{A.87})$$

$$\frac{\mathcal{N}(\gamma, \mathbf{0}, \mathbf{S})}{\chi^2(\varrho^2, \dim(\mathbf{z}))} = \left(\pi^{\frac{1}{2} \dim(\mathbf{z})} \cdot \Gamma \left(1 + \frac{1}{2} \dim(\mathbf{z}) \right)^{-1} \varrho^{\dim(\mathbf{z})} \sqrt{|\mathbf{S}|} \right)^{-1} \quad (\text{A.88})$$

$$\frac{(2\pi)^{-\frac{1}{2} \dim(\mathbf{z})} |\mathbf{S}|^{-\frac{1}{2}} e^{-\frac{1}{2} d_0^2}}{\chi^2(\varrho^2, \dim(\mathbf{z}))} = \frac{\Gamma \left(1 + \frac{1}{2} \dim(\mathbf{z}) \right)}{\pi^{\frac{1}{2} \dim(\mathbf{z})} \varrho^{\dim(\mathbf{z})} \sqrt{|\mathbf{S}|}} \quad (\text{A.89})$$

$$e^{-\frac{1}{2} d_0^2} = \frac{(2\pi)^{\frac{1}{2} \dim(\mathbf{z})} |\mathbf{S}|^{\frac{1}{2}} \Gamma \left(1 + \frac{1}{2} \dim(\mathbf{z}) \right) \chi^2(\varrho^2, \dim(\mathbf{z}))}{\pi^{\frac{1}{2} \dim(\mathbf{z})} \varrho^{\dim(\mathbf{z})} |\mathbf{S}|^{\frac{1}{2}}} \quad (\text{A.90})$$

$$e^{-\frac{1}{2} d_0^2} = (2)^{\frac{1}{2} \dim(\mathbf{z})} \Gamma \left(1 + \frac{1}{2} \dim(\mathbf{z}) \right) \chi^2(\varrho^2, \dim(\mathbf{z})) \varrho^{-\dim(\mathbf{z})} \quad (\text{A.91})$$

$$-\frac{1}{2} d_0^2 \ln e = \ln \left(\Gamma \left(1 + \frac{1}{2} \dim(\mathbf{z}) \right) \chi^2(\varrho^2, \dim(\mathbf{z})) \right) \quad (\text{A.92})$$

$$+ \frac{1}{2} \dim(\mathbf{z}) \ln 2 - \dim(\mathbf{z}) \ln \varrho \quad (\text{A.93})$$

$$d_0^2 = -2 \ln \left(\Gamma \left(1 + \frac{1}{2} \dim(\mathbf{z}) \right) \chi^2(\varrho^2, \dim(\mathbf{z})) \right) \quad (\text{A.94})$$

$$+ 2 \dim(\mathbf{z}) \ln \varrho - \dim(\mathbf{z}) \ln 2 \quad (\text{A.95})$$

$$d_0^2 = -2 \ln \left(\Gamma \left(1 + \frac{1}{2} \dim(\mathbf{z}) \right) \chi^2(\varrho^2, \dim(\mathbf{z})) \right) \quad (\text{A.96})$$

$$- \dim(\mathbf{z}) (\ln 2 - \ln \varrho^2) \quad (\text{A.97})$$

$$d_0 = \sqrt{-2 \ln \left(\Gamma \left(1 + \frac{1}{2} \dim(\mathbf{z}) \right) \chi^2(\varrho^2, \dim(\mathbf{z})) \right) - \dim(\mathbf{z}) \ln \frac{2}{\varrho^2}}. \quad \square \quad (\text{A.98})$$

Lemma 17. *Es gilt:*

$$p_{k|k}^{\exists}(p^D, p^P, p^F, \Lambda, f_c, p_{k-1|k-1}^{\exists}) = p_{k|k}^{\exists}(p^D, p^P, p^F, \varrho, \dim(\mathbf{z}), D_{MH}, p_{k-1|k-1}^{\exists}). \quad (\text{A.99})$$

Beweis

$$p_{k|k}^{\exists}(p^D, p^P, p^F, \Lambda, f_c, p_{k-1|k-1}^{\exists}) = \left[1 + \frac{f_c p^F}{f_c q^D p^F + \Lambda q^F p^D} \left(\frac{1}{p^P p_{k-1|k-1}^{\exists}} - 1 \right) \right]^{-1} \quad (\text{A.100})$$

Für den Faktor

$$\frac{f_c p^F}{f_c q^D p^F + \Lambda q^F p^D} \quad (\text{A.101})$$

ergibt sich mit (3.123) und (3.121):

$$= \frac{\frac{\Gamma[1+\frac{1}{2} \dim(\mathbf{z})]}{\pi^{\frac{1}{2} \dim(\mathbf{z})} \varrho^{\dim(\mathbf{z})} \sqrt{\det \mathbf{S}}} p^F}{\frac{\Gamma[1+\frac{1}{2} \dim(\mathbf{z})]}{\pi^{\frac{1}{2} \dim(\mathbf{z})} \varrho^{\dim(\mathbf{z})} \sqrt{\det \mathbf{S}}} q^D p^F + \frac{\exp^{-\frac{1}{2} \gamma^T \mathbf{S}^{-1} \gamma}}{(2\pi)^{\frac{1}{2} \dim(\mathbf{z})} \chi^2(\varrho^2, \dim(\mathbf{z})) \sqrt{\det \mathbf{S}}} q^F p^D}. \quad (\text{A.102})$$

Durch Kürzen und Einsetzen von $D_{MH}^2 = \gamma^T \mathbf{S}^{-1} \gamma$ vereinfacht sich der Ausdruck weiter:

$$= \frac{\frac{\Gamma[1+\frac{1}{2}\dim(\mathbf{z})]}{\varrho^{\dim(\mathbf{z})}} p^F}{\frac{\Gamma[1+\frac{1}{2}\dim(\mathbf{z})]}{\varrho^{\dim(\mathbf{z})}} q^D p^F + \frac{\exp^{-\frac{1}{2}D_{MH}^2}}{\pi^{\frac{1}{2}\dim(\mathbf{z})} \chi^2(\varrho^2, \dim(\mathbf{z}))} q^F p^D}. \quad (\text{A.103})$$

Damit ergibt sich die zu beweisende Identität:

$$p_{k|k}^\Xi(p^D, p^P, p^F, \Lambda, f_c, p_{k-1|k-1}^\Xi) \quad (\text{A.104})$$

$$= \left[1 + \frac{\frac{\Gamma[1+\frac{1}{2}\dim(\mathbf{z})]}{\varrho^{\dim(\mathbf{z})}} p^F}{\frac{\Gamma[1+\frac{1}{2}\dim(\mathbf{z})]}{\varrho^{\dim(\mathbf{z})}} q^D p^F + \frac{\exp^{-\frac{1}{2}D_{MH}^2}}{\pi^{\frac{1}{2}\dim(\mathbf{z})} \chi^2(\varrho^2, \dim(\mathbf{z}))} q^F p^D} \left(\frac{1}{p^P p_{k-1|k-1}^\Xi} - 1 \right) \right]^{-1} \quad (\text{A.105})$$

$$= p_{k|k}^\Xi(p^D, p^P, p^F, \varrho, \dim(\mathbf{z}), D_{MH}, p_{k-1|k-1}^\Xi) \quad \square \quad (\text{A.106})$$

Lemma 18. Die Messgleichungen des Eigenbewegungsschätzers nach der Ackermann-Lenkgeometrie aus Abbildung 4.21, Seite 119, lauten:

$$R_{VR/VL} = \frac{30}{U_R} \sqrt{4(v^e)^2 \pm 4v^e \dot{\varphi}^e l_S + l_S^2 (\dot{\varphi}^e)^2 + 4l_R^2 (\dot{\varphi}^e)^2} \quad (\text{A.107})$$

$$R_{HR/HL} = \frac{30}{U_R} (2v^e \pm l_S \dot{\varphi}^e). \quad (\text{A.108})$$

Beweis Aus dem Zusammenhang zwischen Winkel- und Bahngeschwindigkeit folgt:

$$r_{HL/HR} = \frac{v_{HL/HR}}{\dot{\varphi}^e} \quad (\text{A.109})$$

$$\dot{\varphi}^e \left(r_{HL/HR} \pm \frac{1}{2} l_S \right) = v^e. \quad (\text{A.110})$$

Durch Einsetzen von (A.109) in (A.110) ergibt sich:

$$\dot{\varphi}^e \left(\frac{v_{HL/HR}}{\dot{\varphi}^e} \pm \frac{1}{2} l_S \right) = v^e \quad (\text{A.111})$$

$$v_{HR/HL} = v^e \pm \frac{1}{2} l_S \dot{\varphi}^e. \quad (\text{A.112})$$

Die Raddrehzahlen $R_{HR/HL}$ in Umdrehungen pro Minute stehen mit den Radgeschwindigkeiten $v_{HR/HL}$ in Metern pro Sekunde über den Radumfang U_R in Beziehung:

$$v_{HR/HL} = \frac{R_{HR/HL} U_R}{60}. \quad (\text{A.113})$$

(A.113) wird in (A.112) eingesetzt:

$$\frac{R_{HR/HL} U_R}{60} = v^e \pm \frac{1}{2} l_S \dot{\varphi}^e \quad (\text{A.114})$$

$$R_{HR/HL} = \frac{30}{U_R} (2v^e \pm l_S \dot{\varphi}^e). \quad \square \quad (\text{A.115})$$

Für die Vorderräder ergibt sich aus dem Zusammenhang zwischen Winkel- und Bahngeschwindigkeit:

$$\frac{v_{VR/VL}}{\dot{\varphi}^e} = r_{VR/VL}. \quad (\text{A.116})$$

Für die Kurvenradien der Vorder- und Hinterräder gilt der Satz von Pythagoras:

$$r_{VR/VL} = \sqrt{r_{HR/HL}^2 + l_R^2}. \quad (\text{A.117})$$

Mit Gleichung (A.110) ergibt sich:

$$r_{VR/VL} = \sqrt{\left(\frac{v^e}{\dot{\varphi}^e} \pm \frac{1}{2}l_S\right)^2 + l_R^2}. \quad (\text{A.118})$$

(A.118) wird in (A.116) eingesetzt:

$$\frac{v_{VR/VL}}{\dot{\varphi}^e} = \sqrt{\left(\frac{v^e}{\dot{\varphi}^e} \pm \frac{1}{2}l_S\right)^2 + l_R^2} \quad (\text{A.119})$$

$$\frac{v_{VR/VL}}{\dot{\varphi}^e} = \sqrt{\frac{(v^e)^2}{(\dot{\varphi}^e)^2} \pm \frac{v^e}{\dot{\varphi}^e}l_S + \frac{1}{4}l_S^2 + l_R^2} \quad (\text{A.120})$$

$$\frac{v_{VR/VL}}{\dot{\varphi}^e} = \frac{1}{\dot{\varphi}^e} \sqrt{(v^e)^2 \pm v^e \dot{\varphi}^e l_S + \frac{1}{4}l_S^2 (\dot{\varphi}^e)^2 + l_R^2 (\dot{\varphi}^e)^2} \quad (\text{A.121})$$

$$v_{VR/VL} = \sqrt{(v^e)^2 \pm v^e \dot{\varphi}^e l_S + \frac{1}{4}l_S^2 (\dot{\varphi}^e)^2 + l_R^2 (\dot{\varphi}^e)^2} \quad (\text{A.122})$$

In Analogie zu (A.113) gilt:

$$\frac{R_{VR/VL} U_R}{60} = \sqrt{(v^e)^2 \pm v^e \dot{\varphi}^e l_S + \frac{1}{4}l_S^2 (\dot{\varphi}^e)^2 + l_R^2 (\dot{\varphi}^e)^2} \quad (\text{A.123})$$

$$R_{VR/VL} = \frac{60}{U_R} \sqrt{\frac{1}{4} [4(v^e)^2 \pm 4v^e \dot{\varphi}^e l_S + l_S^2 (\dot{\varphi}^e)^2 + 4l_R^2 (\dot{\varphi}^e)^2]} \quad (\text{A.124})$$

$$R_{VR/VL} = \frac{30}{U_R} \sqrt{4(v^e)^2 \pm 4v^e \dot{\varphi}^e l_S + l_S^2 (\dot{\varphi}^e)^2 + 4l_R^2 (\dot{\varphi}^e)^2}. \quad \square \quad (\text{A.125})$$

Anhang B

Errata

In [122] und [125] wurde für die statistische Assoziationsdistanz 2.92 (Seite 29) zwischen einer Messung und einer Messwertprädiktion fälschlicherweise behauptet, dass es sich bei dem Term $\log |\mathbf{S}|$ um eine heuristische Erweiterung als Malus für große Zustandsunsicherheiten handelt. Statt dessen ergibt sich 2.92 inklusive dieses Terms als exakte Lösung in Lemma 9 (Seite 182).

In [125] wurde fälschlicherweise behauptet, dass die räumliche Falschalarmwahrscheinlichkeit der Falschdetektionskante auch weggelassen werden darf, was nicht der Fall ist.

In [122] und [125] wurde in der Definition der Likelihood der Messwertassoziationskante, Gleichung (3) in [122] und Gleichung (5) in [125], die Detektionswahrscheinlichkeit p^D fälschlicherweise ausgelassen. Die richtige Likelihood der Messwertassoziationskante (3.108) inklusive der Detektionswahrscheinlichkeit ergibt sich jedoch aus der FISST-basierten Herleitung (3.97).

Anhang C

Literaturverzeichnis

C.1 Verwendete Literatur

- [1] Gefahren erkennen, bevor sie gefährlich werden. - Mit den pro.pilot Sensoren / VDO Automotive AG. 2007. – Forschungsbericht [1]
- [2] Technische Informationen: Elektronik - Fahrerassistenzsysteme / Hella KGaA Hueck & Co. Lippstadt, Germany, 2007. – Forschungsbericht [87]
- [3] ARNDT, Richard; SCHWEIGER, Roland; RITTER, Werner; PAULUS, Dietrich; LOEHLEIN, Otto: Detection and Tacking of Multiple Pedestrians in Automotive Applications. In: *Proc. IEEE Intelligent Vehicles Symposium*, 2007, S. 13–18 [107]
- [4] BAR-SHALOM, Yaakov; FORTMANN, Thomas E.: *Mathematics in Science and Engineering*. Bd. 179: *Tracking and Data Association*. Academic Press Inc., 1988 [63]
- [5] BAR-SHALOM, Yaakov; LI, Xiao-Rong: *Estimation and Tracking - Principles, Techniques, and Software*. Artech House, Inc., 1993 (Artech House Radar Library). – ISBN 0-89006-643-4 [18, 115, 117, 125, 127, 132, 164, 171, 178]
- [6] BAR-SHALOM, Yaakov; LI, Xiao-Rong: *Multitarget-Multisensor Tracking: Principles and Techniques*. YBS, 1995 [164]
- [7] BEHRENDTS, Ehrhard: *Introduction to Markov Chains*. Vieweg, 2000. – ISBN 3-528-06986-4 [11]
- [8] BLOM, H.A.P.: An Efficient Filter for Abruptly Changing Systems. In: *Proc. 23rd IEEE Conf. Decision and Control*. Las Vegas, NV, Dezember 1984, S. 656–658 [23, 131]
- [9] BLOM, H.A.P.; BLOEM, E.A.: Joint Probabilistic Data Association Avoiding Track Coalescence. In: *IEEE Colloquium on Algorithms for Target Tracking*, 1995, S. 1–3 [32]

- [10] BLOM, H.A.P.; BLOEM, E.A.; MUSICKI, Darko: Joint Integrated PDA Avoiding Track Coalescence under Non-Homogeneous Clutter Density. In: *In Proc. International Conference on Information Fusion*, 2006 [32]
- [11] BOUGUET, Jean-Yves. *Camera Calibration Toolbox for Matlab*. 2007 [91]
- [12] BREIMAN, L; FRIEDMAN, J H.; OLSHEN, R A.; STONE, C J. *Classification and Regression Trees*. 1984 [109]
- [13] BRYSON, A. E.; HENRIKSON, L. J.: Estimation Using Sampled-Data Containing Sequentially Correlated Noise / Office of Naval Research - National Aeronautics and Space Administration (NASA). 1967 (533). – Forschungsbericht [125]
- [14] BURGESS, Christopher J.: A tutorial on support vector machines for pattern recognition. In: *Data Mining and Knowledge Discovery* 2 (1998), S. 121–167 [27]
- [15] CASSEBAUM, Oliver; SCHURICHT, P.; BÄKER, B.: Konzeptstudie für eine effiziente Betriebsführung von Hybridfahrzeugen durch Fahrzeugumfeldinformationen. In: *8. Internationales Stuttgarter Symposium* Bd. 2, Vieweg, März 2008 [83]
- [16] CHALLA, Subhash; VO, Ba-Ngu; WANG, Xuezhai: Bayesian approaches to track existence - IPDA and random sets. In: *Proceedings of the Fifth International Conference on Information Fusion* Bd. 2, 2002, S. 1228– 1235 [45]
- [17] CHEN, Zhe: Bayesian Filtering: From Kalman Filters to Particle Filters, and Beyond / McMaster University. Canada, 2007. – Forschungsbericht [11, 20]
- [18] DANG, Thao; HOFFMANN, Christian; STILLER, Christoph: Continuous stereo self-calibration by camera parameter tracking. In: *IEEE Transactions on Image Processing* 18 (2009), Juli, Nr. 7, S. 1536–1550 [100]
- [19] DEMPSTER, A.P.; LAIRD, N.M.; RUBIN, D.B.: Maximum-Likelihood from Incomplete Data via the EM Algorithm. In: *J. Royal Statist. Soc. Ser. B.* 39 (1977), S. 1–38 [26, 48, 91]
- [20] DEZERT, Jean; BAR-SHALOM, Yaakov: Joint Probabilistic Data Association for Autonomous Navigation. In: *IEEE Transactions on Aerospace and Electronic Systems* 29 (1993), Oktober, Nr. 4, S. 1275–1286 [36]
- [21] EGGERS ET. AL., Helmuth: Virtuelles Spotlight zur Kennzeichnung von interessierenden Objekten in Bilddaten. In: *DPMA Deutsches Patent und Markenamt* (2007), Nr. DE102006047777A1 [74]
- [22] ERDINC, Ozgur; WILLET, Peter; BAR-SHALOM, Yaakov: Probability hypothesis density filter for multitarget multisensor tracking. In: *8th International Conference on Information Fusion* Bd. 1, 2005 [47, 48]
- [23] ERDINC, Ozgur; WILLET, Peter; BAR-SHALOM, Yaakov: A physical-space approach for the probability hypothesis density and cardinalized probability hypothesis density filters. In: *Proc. of SPIE, Signal and Data Processing of Small Targets* Bd. 6236, 2006 [47]

- [24] FRANK, András: On Kuhn's Hungarian Method – A tribute from Hungary / Egervary Research Group on Combinatorial Optimization. Budapest, Hungary, Oktober 2004. – Forschungsbericht [30]
- [25] FREUND, Y.: Boosting a Weak Learning Algorithm by Majority. In: *COLT: Proceedings of the Workshop on Computational Learning Theory*, Morgan Kaufmann Publishers, 1990 [27]
- [26] FRIEDMAN, Jerome; HASTIE, Trevor; TIBSHIRANI, Robert: Additive Logistic Regression: a Statistical View of Boosting. In: *Annals of Statistics* 28 (1998), S. 2000 [143]
- [27] FRITZGERALD, Robert J.: Development of Practical PDA Logic For Multitarget Tracking By Microprocessor. In: *Proc. of the American Control Conference (ACC)*, 1986, S. 889–898 [81]
- [28] GAVRILA, Darius M.: A Bayesian, Exemplar-based Approach to Hierarchical Shape Matching. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 29 (2007), August, Nr. 8 [107]
- [29] GAVRILA, Darius M.; MUNDER, Stefan: Multi-Cue Pedestrian Detection and Tracking from a Moving Vehicle. In: *International Journal of Computer Vision* 73 (2007), Juni, Nr. 1, S. 41–59 [107]
- [30] GEERING, Hans P.: *Regelungstechnik - Mathematische Grundlagen, Entwurfsmethoden, Beispiele*. 5. Auflage. Berlin Heidelberg New York : Springer Verlag, 2001 (Springer-Lehrbuch). – ISBN 3-540-41264-6 [115, 117]
- [31] GELFAND, Israel: *Verallgemeinerte Funktionen (Distributionen)*. Bd. I-V. Berlin (Ost) : VEB Deutscher Verlag der Wissenschaften, 1962 [10]
- [32] GOODMAN, I.R.; MAHLER, R.P.S.; HUYEN, H.T.: *Series B: Mathematical and Statistical Methods*. Bd. 37: *Mathematics of Data Fusion*. Kluwer Academic Publishers, 1997. – ISBN 0-7923-4674-2 [39]
- [33] HARVILLE, David A.: *Matrix Algebra From a Statistician's Perspective*. Springer-Verlag, 1997. – ISBN 978-0-387-78356-7 [180]
- [34] HILLENBRAND, Jörg: *Fahrerassistenz zur Kollisionsvermeidung*, Universität Karlsruhe, Dissertation, Oktober 2007 [107]
- [35] HOFFMANN, Christian; DANG, Thao: Cheap Joint Probabilistic Data Association filters in an Interacting Multiple Model Design. In: *Robotics and Autonomous Systems* 57 (2009), Nr. 3, S. 268–278 [81]
- [36] ISO-TC22/SC3/WG16. *ISO 26262 - „Road Vehicles - Functional Safety“ (Committee Draft)*. August 2008 [2]
- [37] JULIER, S.; UHLMANN, J.: A new extension of the Kalman filter to nonlinear systems. In: *Int. Symp. Aerospace/Defense Sensing, Simul. and Controls, Orlando, FL*, 1997 [22]

- [38] KADOW, Ulrich; SCHNEIDER, Georg; VUKOTICH, Alejandro: Radar-Vision Based Vehicle Recognition with Evolutionary Optimized and Boosted Features. In: *Proc. IEEE Intelligent Vehicles Symposium*, 2007 [87, 107]
- [39] KAEMPCHEN, Nico: *Feature-Level Fusion of Laser Scanner and Video Data for Advanced Driver Assistance Systems*, Universität Ulm, Institut für Mess-, Regel- und Mikrotechnik, Dissertation, Juni 2007 [87, 88, 100, 106]
- [40] KAEMPCHEN, Nico; DIETMAYER, Klaus C. J.: Data synchronization strategies for multi-sensor fusion. In: *Proceedings of ITS 2003, 10th World Congress on Intelligent Transportation Systems*. Madrid, Spain, November 2003 [88]
- [41] KALLENBACH, Ingo; SCHWEIGER, Roland; PALM, Guenther; LOEHLEIN, Otto: Multi-class Object Detection in Vision Systems Using a Hierarchy of Cascaded Classifiers. In: *Proc. of IEEE Intelligent Vehicles Symposium*, 2006 [108]
- [42] KALMAN, Rudolph E.: A New Approach to Linear Filtering and Prediction Problems. In: *Transactions of the ASME—Journal of Basic Engineering* 82 (1960), Nr. D, S. 35–45 [16, 18, 112, 125]
- [43] KLAPPSTEIN, Jens: *Optical-Flow Based Detection of Moving Objects in Traffic Scenes*, Ruprecht-Karls-Universität Heidelberg, Naturwissenschaftlich-Mathematische Gesamtfakultät, Dissertation, Juli 2008 [5, 107]
- [44] KLAPPSTEIN, Jens; STEIN, Fridtjof; FRANKE, Uwe: Monocular Motion Detection using Spatial Constraints in a Unified Manner. In: *Proc. IEEE Intelligent Vehicles Symposium*, 2006 [107]
- [45] KLEIN, Lawrence A.: *Sensor and Data Fusion - A Tool for Information Assessment and Decision Making*. SPIE - The International Society for Optical Engineering, 2004 (Signal Processing - Digital Techniques). – ISBN 0–8194–5435–4 [86]
- [46] KONRAD, Marcus: *Rückkopplungsansätze für ein raum-zeitliches Stereo-Verfahren unter Verwendung eines Shape-Priors*, Technische Universität Ilmenau, Fakultät für Informatik und Automatisierung, Fachgebiet Neuroinformatik und Kognitive Robotik, Diplomarbeit, April 2008 [5]
- [47] KRÜGER, Lars: *Model Based Object Classification and Localisation in Multiocular Images*, Universität Bielefeld, Technische Fakultät, Dissertation, 2007 [91]
- [48] LERCH, Reinhard: *Elektrische Messtechnik - Analoge, digitale und computergestützte Verfahren*. 2. Auflage. Berlin Heidelberg New York : Springer-Verlag, 2005 (Springer-Lehrbuch). – ISBN 3–540–21870–X [114, 122]
- [49] LEVENBERG, K.: A Method for the Solution of Certain Problems in Least Squares. In: *Quarterly of Applied Mathematics* 2 (1944), S. 164–168 [95]
- [50] LIENHART, Rainer; KURANOV, Alexander; PISAREVSKY, Vadim: Empirical Analysis of Detection Cascades of Boosted Classifiers for Rapid Object Detection / Microprocessor Research Lab, Intel Labs, Santa Clara. 2002. – Forschungsbericht [107]

- [51] LIENHART, Rainer; MAYDT, Jochen: An Extended Set of Haar-like Features for Rapid Object Detection. In: *Proc. International Conference on Image Processing (ICIP)*, 2002, S. 900–903 [107]
- [52] MAHALANOBIS, P. C.: On the generalised distance in statistics. In: *Proceedings of the National Institute of Science of India* 12 (1936), S. 49–55 [xiv, 29]
- [53] MAHLER, Ronald P. S.: The Random-Set Approach to Data Fusion. In: *Proc. of SPIE, Automatic Object Recognition* Bd. IV, 1994, S. 287–295 [37]
- [54] MAHLER, Ronald P. S.: An Introduction to Multisource-Multitarget Statistics and its Applications / Lockheed Martin. 2000. – Forschungsbericht [37]
- [55] MAHLER, Ronald P. S.: Multitarget Bayes filtering via first-order multitarget moments. In: *IEEE Transactions on Aerospace and Electronic Systems* 39 (2003), Oktober, Nr. 4, S. 1152 – 1178 [47]
- [56] MAHLER, Ronald P. S.: PHD filters of second order in target number. In: *Proc. of SPIE, Signal and Data Processing of Small Targets* Bd. 6236, 62360P, 2006 [47]
- [57] MAHLER, Ronald P. S.: A theory of PHD Filters of Higher Order in Target Number. In: *Proc. SPIE Signal Processing, Sensor Fusion, and Target Recognition* Bd. 6235, 62350K, 2006 [47]
- [58] MAHLER, Ronald P. S.: *Statistical Multisource-Multitarget Information Fusion*. Artech House Publishers, 2007 (Information Warfare Library). – ISBN 978–59693–092–6 [10, 21, 37, 38, 40, 43, 46, 50, 51, 52, 54, 58, 80, 183, 184]
- [59] MARQUARDT, Donald W.: An Algorithm for Least-Squares Estimation of Nonlinear Parameters. In: *Journal of the Society for Industrial and Applied Mathematics* 11 (1963), Juni, Nr. 2, S. 431–441 [95]
- [60] MAYER, Winfried: *Abbildender Radarsensor mit sendeseitig geschalteter Gruppenantenne*, Universität Ulm, Dissertation, Februar 2008 [85]
- [61] MAZOR, A.; AVERBUCH, Amir; BAR-SHALOM, J.; DAYAN, J.: Interacting Multiple Models Methods in Multitarget-Multisensor Tracking: Survey. In: *IEEE Trans. on Aerospace and Electronic Systems* 34 (1998), Jan, Nr. 1, S. 103–123 [xiii, 131]
- [62] MORELANDE, Mark R.; CHALLA, Subhash: A Multitarget Tracking Algorithm Based on Random Sets. In: *In Proc. International Conference on Information Fusion*, 2003 [57, 59]
- [63] MUNDER, Stefan; GAVRILA, Dariu: An Experimental Study on Pedestrian Classification. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 28 (2006), Nr. 11, S. 1863–1868 [107]
- [64] MUŠICKI, Darko; EVANS, Robin: Joint Integrated Probabilistic Data Association: JIP-DA. In: *IEEE Transactions on Aerospace and Electronic Systems* 40 (2004), Juli, Nr. 3, S. 1093–1099 [59, 164]

- [65] MUŠICKI, Darko; EVANS, Robin; STANKOVIĆ, Srdjan: Integrated Probabilistic Data Association. In: *IEEE Transactions on Automatic Control* 39 (1994), Nr. 6, S. 1237–1241 [45, 63, 164]
- [66] MUŠICKI, Darko; MORELANDE, Mark R.: Gate Volume Estimation for Target Tracking. In: *Proc. of International Conference on Information Fusion*, 2004 [73]
- [67] NEUKUM, Alexandra; LÜBBEKE, Thomas; KRÜGER, Hans-Peter; MAYSER, Christoph; STEINLE, Joachim: ACC Stop&Go: Fahrerverhalten an funktionalen Systemgrenzen. In: *5. Workshop Fahrerassistenzsysteme*, 2008, S. 141–150 [86]
- [68] OBERLAENDER, Matthias: Hyperpermutation networks - a discrete approach to machine perception. In: *Third Weightless Neuronal Networks Workshop*. University of York, 1999 [27]
- [69] OH, Songhwai; SASTRY, Shankar: A Polynomial-Time Approximation Algorithm for Joint Probabilistic Data Association. In: *Proc. of the American Control Conference (ACC)*, 2005 [81]
- [70] OPPENHEIM, Alan V.; SCHAFER, Ronald W.: *Zeitdiskrete Signalverarbeitung*. München : R. Oldenbourg Verlag GmbH, 1992. – ISBN 3–486–21544–2 [115]
- [71] PALKKI, Ryan D.: Addressing Track Coalescence in Sequential K-Best Multiple Hypothesis Tracking / School of Electrical and Computer Engineering, Georgia Institute of Technology. 2006. – Masterarbeit [32]
- [72] PITT, M.; SHEPHARD, N.: Filtering via Simulation: Auxiliary Particle Filters. In: *Journal of the American Statistical Association* 94 (1999), Nr. 446, S. 590–599 [22]
- [73] PLUIM, Josien P. W.; MAINTZ, J. B. A.; VIERGEVER, Max A.: Mutual information based registration of medical images: a survey. In: *IEEE Transactions on Medical Imaging* (2003) [13]
- [74] PONSÁ, Daniel; LÓPEZ, Antonio: *Lecture Notes in Computer Science: Advanced Concepts for Intelligent Vision Systems*. Bd. 4678: *Cascade of Classifiers for Vehicle Detection*. Springer, 2007, S. 980–989. – ISBN 978–3–540–74606–5 [107]
- [75] PUNITHAKUMAR, K.; KIRUBARAJAN, T.; SINHA, A.: A sequential Monte Carlo probability hypothesis density algorithm for multitarget track-before-detect. In: *Proc. SPIE* Bd. 5913, 59131S, 2005 [47]
- [76] RISTIC, Branko; ARULAMPALAM, Sanjeev; GORDON, Neil: *Beyond the Kalman Filter - Particle Filters for Tracking Applications*. Artech House Publishers, 2004 (Signal Processing). – ISBN 1–58053–631–X [20, 22]
- [77] SALMOND, D. J.: Tracking in Uncertain Environments / Royal Aerospace Establishment. London, September 1989 (121). – Forschungsbericht [179]
- [78] SCHLITT, Herbert: *Systemtheorie für stochastische Prozesse*. Springer-Verlag, 1992. – ISBN 3–540–54288–4 [113, 118]

- [79] SCHÖNING, Uwe: *Algorithmen - kurz gefasst*. Spektrum Akademischer Verlag, 1997. – ISBN 3-8274-0232-8 [30, 70]
- [80] SCHWEIGER, Roland; HAMER, H.; LOEHLEIN, Otto: Determining Posterior Probabilities on the Basis of Cascaded Classifiers as used in Pedestrian Detection Systems. In: *Proc. IEEE Intelligent Vehicles Symposium*, 2007 [143]
- [81] SIDENBLADH, Hedvig: Multi-target particle filtering for the probability hypothesis density. In: *Proc. of International Conference on Information Fusion*, 2003, S. 800–806 [47]
- [82] SIDENBLADH, Hedvig; WIRKANDER, Sven lennart: Particle filtering for random sets. In: *Citeseer* (2003) [42]
- [83] SIDENBLADH, Hedvig; WIRKANDER, Sven lennart: Tracking random sets of vehicles in terrain. In: *IEEE Workshop on Multi-Object Tracking*, 2003 [42]
- [84] STIRLING, James: *Methodus Differentialis*. 1730 [29]
- [85] STRELLER, Daniel; SPARBERT, Jan; DIETMAYER, Klaus C. J.: Model Based Classification and Object Tracking in Traffic Scenes from Range-Images. In: *Proc. IEEE Intelligent Vehicles Symposium*. Tokio, Japan, Mai 2001 [102]
- [86] SZARVAS, Mate; SAKAI, Utsushi; OGATA, Jun: Real-time Pedestrian Detection Using LIDAR and Convolutional Neuronal Networks. In: *Proc. IEEE Intelligent Vehicles Symposium*, 2006 [87]
- [87] TAYLOR, Jill B.: *My Stroke of Insight: A Brain Scientist's Personal Journey*. Viking Penguin, 2006. – ISBN 978-0670020744 [4]
- [88] UNBEHAUEN, Heinz: *Automatisierungstechnik*. Bd. 8: *Regelungstechnik II - Zustandsregelungen, digitale und nichtlineare Regelsysteme*. Friedr. Vieweg & Sohn Verlagsgesellschaft mbH, 2000. – ISBN 3-528-73348-9 [115]
- [89] UNESCO. *Übereinkommen über den Strassenverkehr (Wiener Straßenverkehrskonvention)*. November 1968 [2]
- [90] VAN DER MERWE, Rudolph: *Sigma-Point Kalman Filters for Probabilistic Inference in Dynamic State-Space Models*, Oregon Health & Science University, Dissertation, April 2004 [11, 22]
- [91] VIHOLA, Matti: Rao-blackwellised particle filtering in random set multitarget tracking. In: *IEEE Transactions on Aerospace and Electronic Systems* 43 (2007), April, S. 689 – 705 [42]
- [92] VIOLA, Paul; JONES, Michael J.: Rapid Object Detection using a Boosted Cascade of Simple Features. In: *IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*, 2001, S. 511–518 [107, 109]

- [93] VIOLA, Paul; JONES, Michael J.; SNOW, Daniel: Detecting pedestrians using patterns of motion and appearance. In: *Proc. of International Conference on Computer Vision (ICCV)*, 2003, S. 734–741 [107]
- [94] VO, Ba-Ngu; MA, Wing-Kin: The Gaussian mixture Probability Hypothesis Density Filter. In: *IEEE Transactions on Signal Processing* 54 (2006), Nr. 11, S. 4091–4104 [47]
- [95] VO, Ba-Ngu; MA, Wing-Kin; SINGH, Sumeetpal: Localizing an unknown time-varying number of speakers: a Bayesian random finite set approach. In: *Proc. IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP)* Bd. 4, 2005 [42]
- [96] VO, Ba-Ngu; SINGH, Sumeetpal: On the Bayes filtering equations of finite set statistics. In: *Proc. of the 5th Asian Control Conference* Bd. 2, 2004, S. 1264– 1269 [39]
- [97] VO, Ba-Ngu; SINGH, Sumeetpal; DOUCET, Arnaud: Sequential Monte Carlo Methods for Multi-target Filtering with Random Finite Sets. In: *IEEE Transactions on Aerospace and Electronic Systems* 41 (2005), Nr. 4, S. 1224 – 1245 [47]
- [98] VO, Ba-Tuong; VO, Ba-Ngu; CANTONI, Antonio: Analytic implementations of the Cardinalized Probability Hypothesis Density Filter. In: *IEEE Transactions on Signal Processing* (2007) [47]
- [99] WALCHSHÄUSEL, Leonhard: *Maschinelle Erkennung von Verkehrsteilnehmern mittels heterogener Sensorik*, Technische Universität München, Dissertation, Mai 2008 [87, 107]
- [100] WATT, Alan: *3D-Computergrafik*. Pearson Studium, 2001 (Informatik). – ISBN 3827370140 [89]
- [101] WEISS, Thorsten; DIETMAYER, Klaus C. J.: Robust Host-Localisation in Skidding Situations Using Laser Scanners. In: *Proc. of 4th International Workshop on Intelligent Transportation*, 2007 [112]
- [102] WENDER, Stefan: *Multisensorsystem zur erweiterten Fahrzeugumfelderfassung*, Universität Ulm, Institut für Mess-, Regel- und Mikrotechnik, Dissertation, 2008 [33, 86, 87, 106, 107]
- [103] WINKLER, Gerhard: Stochastische Prozesse in der statistischen Modellierung / GSF - Forschungszentrum für Umwelt und Gesundheit GmbH. 2000. – Forschungsbericht [11]
- [104] WÖHLER, Christian: *Neuronale Zeitverzögerungsnetzwerke für die Bildsequenzanalyse und ihre Anwendung in fahrzeuggebundenen Bildverarbeitungssystemen*, Rheinische Friedrich-Wilhelms-Universität Bonn, Dissertation, Juli 2000 [27]
- [105] ZAJIC, Tim; MAHLER, Ronald P. S.: A particle-systems implementation of the PHD multitarget tracking filter. In: *Proc. SPIE Signal processing, sensor fusion, and target recognition* Bd. 5096, 2003, S. 291–299 [47]
- [106] ZHANG, Q.; PLESS, R.: Extrinsic calibration of a camera and laser range finder. In: *Proc. IEEE Intelligent Robots and Systems (IROS)*, 2004, S. 2301– 2306 [88]

C.2 Publikationen

- [107] DICKMANN, Jürgen; DIEWALD, Fabian; MÄHLISCH, Mirko; KLAPPSTEIN, Jens; ZUTHER, Sebastian; PIETZSCH, Sylvia; HAHN, Stefan; MUNZ, Michael: Environmental Perception for Future Integrated Safety Systems. In: *Proc. of Int. Technical Conference on the Enhanced Safety of Vehicles*, 2009
- [108] DICKMANN, Jürgen; MEKHAIEL, Moheb; APPENRODT, Nils; MÄHLISCH, Mirko; RITTER, Werner: Sensorfusion als Schlüssel zukünftiger Fahrerassistenzsysteme. In: *3. Fachtagung Optische Technologien in der Fahrzeugtechnik*, 2008
- [109] IDLER, Corvin; SCHWEIGER, Roland; PAULUS, Dietrich; MÄHLISCH, Mirko; RITTER, Werner: Realtime Multi-Target-Tracking with Particle Filters in Night View Automotive Applications. In: *Proc. of IEEE Intelligent Vehicles Symposium*. Tokio, Japan, Jun 13-15 2006
- [110] MÄHLISCH, Mirko: *Fußgängererkennung in Ferninfrarot-Bildern*, Technische Universität Chemnitz, DaimlerChrysler Research and Technology, Ulm, Diplomarbeit, April 2004
- [111] MÄHLISCH, Mirko: Detection and Tracking based on Finite-Set-Statistics Theory (FISST) for Multisensor ACC. In: *2nd PReVENT Fusion Forum Workshop*. Paris, France, 2007
- [112] MÄHLISCH, Mirko; BRUNETT, Guido: Erkennung von Fußgängern in Ferninfrarot-Bildern: Detektion, Berechnung und Auswertung von Bewegungsbahnen. In: *TU-SPEKTRUM - Das Magazin der Technischen Universität Chemnitz, Sonderausgabe Auto & Verkehr* (2004), S. 28
- [113] MÄHLISCH, Mirko; DIETMAYER, Klaus C.: Random Finite Set Theorie zur Multiobjektverfolgung mit unsicheren und mehrdeutigen Sensordaten. In: *41. Regelungstechnisches Kolloquium*. Boppard, Germany, Februar 2007
- [114] MÄHLISCH, Mirko; DIETMAYER, Klaus C.: Multisensor Multitarget Tracking based on Random Finite Set Statistics for Advanced Driver Assistance Systems. In: *Tagungsband 8. Internationales Stuttgarter Symposium*, 2008
- [115] MÄHLISCH, Mirko; HERING, Ruediger; RITTER, Werner; DIETMAYER, Klaus C.: Heterogeneous Fusion of Video, Lidar and ESP Data for Automotive ACC Vehicle Tracking. In: *Proc. of IEEE Conference on Multisensor Fusion and Integration*. Heidelberg, Germany, Sep 3-6 2006
- [116] MÄHLISCH, Mirko; KAUDERER, Tobias; RITTER, Werner; DIETMAYER, Klaus C.: Feature-Level Video and Multibeam Lidar Sensor Fusion for Full-Speed ACC State Estimation. In: *Proceedings of 4th International Workshop on Intelligent Transportation*. Hamburg, Germany, 2007, S. 173–178

- [117] MÄHLISCH, Mirko; LOEHLEIN, Otto; RITTER, Werner; DIETMAYER, Klaus C.: *Exploiting Latest Developments in Signal Processing and Tracking for "Smart" Multi-Sensor Multi-Target ACC*. Berlin, Germany : Springer Verlag, Mai 2007 (Advanced Microsystems for Automotive Applications (AMAA)), S. 75–89. – ISBN 978–3–540–71324–1
- [118] MÄHLISCH, Mirko; OBERLAENDER, Matthias; LOEHLEIN, Otto; GAVRILA, Darius; RITTER, Werner: A Multiple Detector Approach to Low-resolution FIR Pedestrian Recognition. In: *Proc. of IEEE Intelligent Vehicles Symposium*. Las Vegas, USA, Jun 06-08 2005 [107, 160]
- [119] MÄHLISCH, Mirko; RITTER, Werner; DIETMAYER, Klaus C.: ACC Vehicle Tracking with Joint Multisensor Multitarget Filtering of State and Existence. In: *PReVENT ProFusion e-Journal* 1 (2006), Sep, S. 37ff [47]
- [120] MÄHLISCH, Mirko; RITTER, Werner; DIETMAYER, Klaus C.: De-cluttering with Integrated Probabilistic Data Association for Multisensor Multitarget ACC Vehicle Tracking. In: *Proceedings of IEEE Intelligent Vehicles Symposium*. Istanbul, Turkey, 2007 [46]
- [121] MÄHLISCH, Mirko; RITTER, Werner; DIETMAYER, Klaus C.: Feature level video and lidar sensor fusion for ACC stop-and-go using Joint Integrated Probabilistic Data Association. In: *Proc. of 6th European Congress on ITS in Europe*. Aalborg, Denmark, 2007
- [122] MÄHLISCH, Mirko; RITTER, Werner; DIETMAYER, Klaus C.: Simultane Minimierung von Existenz- und Zustandsunsicherheiten in der Fahrzeugumfelderfassung. In: *FAS 2008 - 5. Workshop Fahrerassistenzsysteme*, fmrt - Freundeskreis Mess- und Regelungstechnik Karlsruhe e.V., April 2008. – ISBN 3–9809121–3–2, S. 12–19 [191]
- [123] MÄHLISCH, Mirko; SCHWEIGER, Roland; RITTER, Werner; DIETMAYER, Klaus C.: Multisensor Vehicle Tracking with the Probability Hypothesis Density Filter. In: *Proceedings of ISIF/IEEE 9th International Conference on Information Fusion*. Florence, Italy, Juli 2006 [47, 48]
- [124] MÄHLISCH, Mirko; SCHWEIGER, Roland; RITTER, Werner; DIETMAYER, Klaus C.: Sensorfusion Using Spatio-Temporal Aligned Video and Lidar for Improved Vehicle Detection. In: *Proc. of IEEE Intelligent Vehicles Symposium*. Tokio, Japan, Jun 13-15 2006 [91, 100, 107]
- [125] MÄHLISCH, Mirko; SZCZOT, Magdalena; LOEHLEIN, Otto; MUNZ, Michael; DIETMAYER, Klaus C.: Simultaneous Processing of Multitarget State Measurements and Object Individual Sensory Existence Evidence with the Joint Integrated Probabilistic Data Association Filter. In: *WIT 2008: 5th International Workshop on Intelligent Transportation*, 2008, S. 117–122 [191]
- [126] MUNZ, Michael; MÄHLISCH, Mirko; DIETMAYER, Klaus C. J.: A Probabilistic Sensor-Independent Fusion Framework for Automotive Driver Assistance Systems. In: *WIT 2009: 6th International Workshop on Intelligent Transportation*, 2009 [77, 80]


- [127] MUNZ, Michael; MÄHLISCH, Mirko; DIETMAYER, Klaus C. J.: Probabilistische Sensorfusion und integrierte Existenzschätzung für zukünftige Fahrerassistenzsysteme. In: *FAS 2009 - 6. Workshop Fahrerassistenzsysteme*, 2009
- [128] MUNZ, Michael; MÄHLISCH, Mirko; DIETMAYER, Klaus C. J.: A Sensor Independent Probabilistic Fusion System. In: *Proc. of IEEE Int. Conf. on Intelligent Transportation Systems*, 2009
- [129] SZCZOT, Magdalena; LOEHLEIN, Otto; MÄHLISCH, Mirko: Incorporating Contextual Information in Pedestrian Tracking. In: *WIT 2010: 7th International Workshop on Intelligent Transportation*, 2010

C.3 Patente und Patentanmeldungen

- [130] EBERLE, Walter; DICKMANN, Jürgen; MÄHLISCH, Mirko; BULLINGER, Wilfried; FRITZSCHE, Martin; HÜRLAND, Armin; MERZ, Uwe. *Verfahren zur Steuerung einer Rückhaltevorrichtung für Insassen eines Fahrzeuges*. (Patent angemeldet). Juni 2009
- [131] MÄHLISCH, Mirko; HAHN, Stefan; DIETMAYER, Klaus C. *Kalibrierverfahren für einen Sensor zur Abstandsmessung*. Deutsches Patent- und Markenamt, Nr. DE102005037094B3. Oktober 2006 [89, 100]
- [132] MÄHLISCH, Mirko; SCHMID, Matthias. *Verfahren und Vorrichtung zur Erfassung einer Umgebung eines Fahrzeuges*. (Patent angemeldet). Juni 2009
- [133] MÄHLISCH, Mirko; SCHWEIGER, Roland. *Fahrerassistenzsystem für ein Fahrzeug und Verfahren zur Erzeugung einer Abbildung einer Umgebung eines Fahrzeuges*. (Patent angemeldet). 2009

C.4 Betreute Studien- und Diplomarbeiten

- [134] BRANDSMEIER, Holger: *Datensynchronisation zur Sensordatenfusion am Beispiel der Eigenpositionsschätzung für die digitale Karte*, Universität Ulm/DaimlerChrysler AG, Bachelor-Arbeit, 2007
- [135] HERING, Rüdiger: *Multi Sensor Multi Object Tracking*, Universität Ulm, Diplomarbeit, 2006 [30]
- [136] KAIM, Philipp: *Monokulare Spurverfolgung mit Sequenziellen Monte-Carlo-Methoden zur Eigenbewegungsschätzung und Suchbereichseinschränkung*, Universität Ulm, Diplomarbeit, 2007
- [137] KAUDERER, Tobias: *Mess- und Prozessmodelle zur Mehrobjektverfolgung in fahrzeuggebundenen Umgebungserfassungssystemen*, Universität Ulm, Diplomarbeit, 2007
- [138] PROBOST, Ulrich: *Mikrocontrollergestützte Echtzeit-Messdatenerfassung für Fahrzeugsensorik*, Universität Ulm, Studienarbeit, 2005
- [139] REINHART, Stefan: *Optische Spurerkennung*, Universität Ulm/Fachhochschule Ulm, Diplomarbeit (FH), 2006
- [140] SCHWARZ, Michael: *Optimierung eines Fahrzeugdetektionssystems auf Basis von kaskadierten Adaboost-Klassifikatoren*, Universität Ulm, Diplomarbeit, 2008
- [141] WACHTEL, Andreas: *Automatische Bestimmung intrinsischer und extrinsischer Parameter eines heterogenen Sensorfusionssystems*, Universität Ulm, Studienarbeit, 2006 [91]



Herausgeber:

Prof. Dr.-Ing. Klaus Dietmayer

Institut für Mess-, Regel- und Mikrotechnik

Albert-Einstein-Allee 41

89081 Universität Ulm

ISBN 978-3-941543-03-4