


J. Beyerer / F. Puente León / K.-D. Sommer (Hrsg.)

# Informationsfusion in der Mess- und Sensortechnik






J. Beyerer, F. Puente León, K.-D. Sommer (Hrsg.)

**Informationsfusion in der Mess- und Sensortechnik**



# Informationsfusion in der Mess- und Sensortechnik

hrsg. von  
J. Beyerer  
F. Puente León  
K.-D. Sommer



---

universitätsverlag karlsruhe

## Impressum

Universitätsverlag Karlsruhe  
c/o Universitätsbibliothek  
Straße am Forum 2  
D-76131 Karlsruhe  
[www.uvka.de](http://www.uvka.de)



Dieses Werk ist unter folgender Creative Commons-Lizenz  
lizenziert: <http://creativecommons.org/licenses/by-nc-nd/2.0/de/>

Universitätsverlag Karlsruhe 2006  
Print on Demand

ISBN-13: 978-3-86644-053-1  
ISBN-10: 3-86644-053-7

# Vorwort

Die Entwicklung und Beherrschung der immer komplexer werdenden technischen Systeme führt in zunehmenden Maße zu Anforderungen an die Mess- und Sensortechnik, die mit dem Einsatz eines Einzelsensors, Messprinzips oder -verfahrens zur Erfassung einer, meist multivariaten Messgröße oft nicht mehr erfüllt werden können. Dies hat in den letzten Jahren zu einem starken Entwicklungsschub für Multisensorsysteme und die Grundlagenforschung zur Fusion von Messdaten und Information aus unterschiedlichen Quellen geführt. Typische Beispiele sind die Fahrerassistenzsysteme mit der Fusion von Entfernung- und Objektinformation, die Kombination taktiler und berührungsloser optischer Sensoren in der Fertigungsmesstechnik oder die Kombination mehrerer Sensoren auf einem Chip.

Dieses Buch greift diese Entwicklung sowohl hinsichtlich ihrer theoretischen Grundlagen als auch wichtiger Anwendungsfelder auf. Es richtet sich an Fachleute aus der Mess- und Sensortechnik sowie aus der Regelungs-, Steuerungstechnik und Robotik, die sich in der industriellen Entwicklung, in der Forschung oder der Lehre mit der Informationsfusion befassen. Im Einzelnen werden die folgenden Themenkreise behandelt:

- Theoretische Grundlagen der Informationsfusion,
- Methoden, Algorithmen und Systeme,
- Neuronale Netze,
- Anwendungen der Informationsfusion in der Fertigungsmesstechnik, Robotik, bei Flugsystemen und Fahrerassistenzsystemen sowie in anderen wichtigen Feldern.

Damit wird ein Bogen gespannt, der von den mathematischen Fusionsansätzen über die Methoden und verteilten Systeme bis zu den verschiedenen Implementierungen reicht.

Die Beiträge in diesem Buch beruhen auf den Vorträgen der Autoren auf dem von der VDI/VDE-Gesellschaft für Mess- und Automatisierungstechnik (GMA) veranstalteten Expertenforum „Informationsfusion in der Mess- und Sensortechnik 2006“, das am 21. und 22. Juni 2006 in Eisenach stattfand.

Ziel der Herausgeber ist es, die neuesten Entwicklungen auf dem Gebiet der Informationsfusion in der Mess- und Sensortechnik bekannt zu machen sowie insbesondere generelle Fusionsansätze herauszuarbeiten. Damit soll ein Beitrag zur Entwicklung dieses wichtigen und zukunftssträchtigen Gebietes am Wirtschafts- und Forschungsstandort Deutschland geleistet werden.

Juli 2006

J. Beyerer  
F. Puente León  
K.-D. Sommer





# Inhaltsverzeichnis

## Übersichtsaufsatz

- Methoden der Informationsfusion — Überblick und Taxonomie . . . . . 1  
*H. Ruser (Universität der Bundeswehr München),*  
*F. Puente León (Technische Universität München)*

## Theoretische Grundlagen der Informationsfusion

- Fusion heterogener Informationsquellen . . . . . 21  
*J. Beyerer (Fraunhofer IITB und Universität Karlsruhe),*  
*J. Sander (Universität Karlsruhe),*  
*S. Werling (Universität Karlsruhe)*
- Evidenztheorie: Ein Vergleich zwischen Bayes- und Dempster-Shafer-  
Methoden . . . . . 39  
*K. Dietmayer (Universität Ulm)*
- On estimation of structured covariance matrices . . . . . 51  
*W. Utschick (Technische Universität München),*  
*F. A. Dietrich (Technische Universität München)*

## Methoden, Algorithmen und Systeme

- Informationsfusion für verteilte Systeme . . . . . 63  
*D. Brunn (Universität Karlsruhe),*  
*F. Sawo (Universität Karlsruhe),*  
*U. D. Hanebeck (Universität Karlsruhe)*
- Bildfusion . . . . . 79  
*M. Heizmann (Fraunhofer IITB),*  
*F. Puente León (Technische Universität München)*

## Neuronale Netze zur Informationsfusion

- Neuronale Netze: Eine Übersicht . . . . . 93  
*O. Nelles (Universität Siegen)*
- Informationsfusion in Neuro-Fuzzy-Systemen . . . . . 113  
*F. Rügheimer (Universität Magdeburg),*  
*D. Nauck (BT, Research & Venturing, ISRC, Ipswich),*  
*R. Kruse (Universität Magdeburg)*

## Fertigungsmesstechnik

Ermittlung der Oberflächengeometrie aus Messpunktewolken in der optischen 3D-Messtechnik .....	127
<i>R. Tutsch (Technische Universität Braunschweig),</i>	
<i>M. Petz (Technische Universität Braunschweig)</i>	
Multiskalige Messstrategien für die Mikrosystemtechnik .....	137
<i>J. Regin (Universität Stuttgart),</i>	
<i>J. Pannekamp (Universität Stuttgart),</i>	
<i>J. Neher (Universität Stuttgart),</i>	
<i>E. Westkämper (Universität Stuttgart),</i>	
<i>T. Wiesendanger (Universität Stuttgart),</i>	
<i>W. Osten (Universität Stuttgart)</i>	

## Robotik und Flugsysteme

Cooperative exploration with multiple robots using low bandwidth communication .....	145
<i>D. Meier (Universität Freiburg),</i>	
<i>C. Stachniss (Universität Freiburg und ETH Zürich),</i>	
<i>W. Burgard (Universität Freiburg)</i>	
Multisensorielle Exploration von Roboterarbeitsräumen .....	159
<i>M. Suppa (Deutsches Zentrum für Luft- und Raumfahrt),</i>	
<i>G. Hirzinger (Deutsches Zentrum für Luft- und Raumfahrt)</i>	
Pilot assistance for approach and landing .....	171
<i>B. Korn (DLR)</i>	
Negative Sensorevidenz: Ausgewählte Beispiele aus militärischen Überwachungsanwendungen .....	185
<i>W. Koch (FGAN-FKIE)</i>	

## Fahrerassistenzsysteme

Fusion von Sensordaten zur Umfeldwahrnehmung für Fahrerassistenzsysteme — eine Übersicht .....	207
<i>J. Becker (Robert Bosch GmbH)</i>	
Akquisition, Repräsentation und Nutzung von Wissen in der Fahrerassistenz .....	223
<i>C. Duchow (Universität Karlsruhe),</i>	
<i>B. Hummel (Universität Karlsruhe),</i>	
<i>A. Bachmann (Universität Karlsruhe),</i>	
<i>Z. Yang (Universität Karlsruhe),</i>	
<i>C. Stiller (Universität Karlsruhe)</i>	

Fusion von Radar- und Thermopilesensoren zur Fußgängerdetektion . . . . .	239
<i>D. Linzmeier (DaimlerChrysler AG),</i>	
<i>T. Bär (DaimlerChrysler AG)</i>	

## **Spezielle Anwendungen**

Informationsfusion in Multisensorsystemen für die Sportmedizin . . . . .	251
<i>M. Schilling (TU Braunschweig),</i>	
<i>U. Tegtbur (Medizinische Hochschule Hannover)</i>	

Elektronische Nase und Signalgewinnung . . . . .	261
<i>F. Röck (Universität Tübingen),</i>	
<i>U. Weimar (Universität Tübingen)</i>	

Sensorik in der elektrischen Energietechnik . . . . .	279
<i>E. Gockenbach (Universität Hannover)</i>	

<b>Stichwortverzeichnis</b> . . . . .	295
---------------------------------------	-----



# Methoden der Informationsfusion — Überblick und Taxonomie

Heinrich Ruser<sup>1</sup> und Fernando Puente León<sup>2</sup>

<sup>1</sup> Universität der Bundeswehr München, Institut für Mess- und  
Automatisierungstechnik, Werner-Heisenberg-Weg 39, D-85577 Neubiberg

<sup>2</sup> Technische Universität München, Fachgebiet Verteilte Messsysteme,  
Theresienstr. 90/N5, D-80333 München

**Zusammenfassung.** Mit Informationsfusion wird der Prozess bezeichnet, Daten aus unterschiedlichen Sensoren oder Informationsquellen mit dem Ziel zu verknüpfen, neues oder präziseres Wissen über physikalische Größen, Ereignisse und Situationen zu gewinnen. Im Beitrag werden eine Systematisierung der verschiedenen Ansätze und Modelle der Informationsfusion vorgenommen und allgemeine Kriterien bei der Herangehensweise an die Fusionsaufgabe vorgestellt. Ausgehend von den Anforderungen an die Messaufgabe bestimmen die Art und das bekannte oder erlernbare Wissen über die Informationsquellen und die Messobjekte sowie der vertretbare mathematische Aufwand die Wahl der Fusionsalgorithmen. Hierzu wird ein Überblick über verschiedene methodische Ansätze gegeben, welche in vielen Anwendungen eine wichtige Rolle spielen.

## 1 Einleitung

Das Konzept der Daten- oder Informationsfusion<sup>3</sup> (Information im Sinne von „Bedeutung“ oder „Wissen“) ist einfach zu verstehen: Mit der Nutzung verschiedenartiger Informationsquellen wird neues oder präziseres Wissen über physikalische Größen, Ereignisse und Situationen gewonnen, dazu oft in kürzerer Zeit und zu geringeren Kosten. Informationen können dabei sowohl Rohsignale von Sensoren als auch verbal beschriebene Eigenschaften von Objekten sein. Auf Sensoren als Informationsquellen übertragen, soll also — bildlich gesprochen — durch Kombination zweier Sensoren  $S_1$  und  $S_2$  mit unterschiedlichen Wirkprinzipien die Leistungsfähigkeit  $L(S_1 \cup S_2)$  des Multisensorsystems so erhöht werden, dass  $L(S_1 \cup S_2) > L(S_1) + L(S_2)$  oder zumindest  $L(S_1 \cup S_2) > \max\{L(S_1), L(S_2)\}$  [1]. Dabei wird vielfach zwischen den Begriffen *Sensorintegration* und *Datenfusion* unterschieden: Integration bezeichnet die „synergetische Verwendung der Information mehrerer Sensoren zur Lösung einer Detektions-, Klassifikations- oder Identifikationsaufgabe“, während Fusion die eigentliche Kombination der Daten (Zeit- oder Ortssignale, Parameter, Aussagen) der beteiligten Sensoren beinhaltet [2, 3].

---

<sup>3</sup> In diesem Beitrag werden beide Begriffe synonym verwendet.

Eine oft zitierte Definition beschreibt die Daten- und Informationsfusion als „*a multilevel, multifaceted process dealing with the automatic detection, association, correlation, estimation, and combination of data and information from single and multiple sources to achieve refined position and identity estimates, and complete and timely assessments of situations and threats, and their significance*“ [4]. Eine neuere, allgemeinere Formulierung spricht von einem formalen Rahmen (*framework*) „*that expresses the means and tools for the alliance of data originating from different sources; it aims at obtaining information of greater quality, the exact definition of ‘greater quality’ will depend upon the application*“ [5]. Damit wird insbesondere der Schwerpunkt auf die allgemeine Qualität des Fusionsergebnisses als herausragendem Ziel des Fusionsprozesses gelegt, wobei darunter sowohl die technischen Parameter und Leistungsmerkmale (*performance*) als auch die Effektivität (*effectiveness*) und der Nutzen für den Anwender (*benefit*) gezählt werden.

Informationsfusion ist ein integraler Bestandteil der Wahrnehmung vieler technischer und biologischer Systeme [6,7]. Die Fusion gibt darüber hinaus auch eine wichtige Rückkopplung über die Qualität der Daten der einzelnen Sensoren. Ein Nachteil von Einzelsensoren ist nämlich die Unfähigkeit, die inhärente Unsicherheit bei der Interpretation des Sensorsignals (z. B. in Bezug auf eine beobachtete Größe) zu beheben. Diese Unsicherheit entsteht, wenn entscheidende Merkmale vom eingesetzten Sensor aufgrund seines Wirkprinzips nicht bestimmt werden können oder aus einem anderen Grund zum benötigten Zeitpunkt nicht zur Verfügung stehen, oder wenn mehrdeutige Situationen vorliegen — z. B. bei der Bewertung von Kamerabildern [8]. Mit der Integration von Informationen aus verschiedenen Datenquellen können die Wahrnehmungsfähigkeiten erweitert und die Glaubwürdigkeit der Sensoraussage erhöht werden.

Die Einsatzgebiete der Informationsfusion sind sehr vielseitig und betreffen u. a. Anwendungen in der Messtechnik [9–11], Militärtechnik [12], Robotik [13], Navigation [14], Fahrerassistenz [15–17], Medizintechnik [18], Fernerkundung und der Fertigungstechnik [19]. Eine wichtige Aufgabe ist die zuverlässige Auswertung von Bildinformationen [8]. Dabei stehen oftmals Aufgaben wie die Erkennung und Klassifikation von Objekten sowie ihre Zustandsschätzung (z. B. die Bestimmung ihres Abstandes und ihrer Geschwindigkeit) im Vordergrund. Ein Integrationsansatz zur Umfeldwahrnehmung ist beispielsweise die Messwertverknüpfung von Abstandssensoren mit abgestuften Entfernungsmessbereichen: Kraftsensoren für die direkte Manipulation, kapazitive und induktive Näherungsschalter, Ultraschallsensoren für den Sensornahbereich, Stereokameras für mittlere Entfernungen sowie Radarsensoren für den Fernbereich.

Eine zentrale Frage bei einem solchen Vorgehen betrifft die Art und Weise der Fusion der von den Einzelsensoren gelieferten Daten. In der Literatur existieren verschiedene Ansätze für den Entwurf solcher multisensorieller Systeme [20–24]. Der vorliegende Beitrag gibt zunächst einen Überblick über gebräuchliche Strukturen und Methoden zur Verknüpfung von Informationen und geht dann auf einige Beispiele und Entwicklungstendenzen ein.

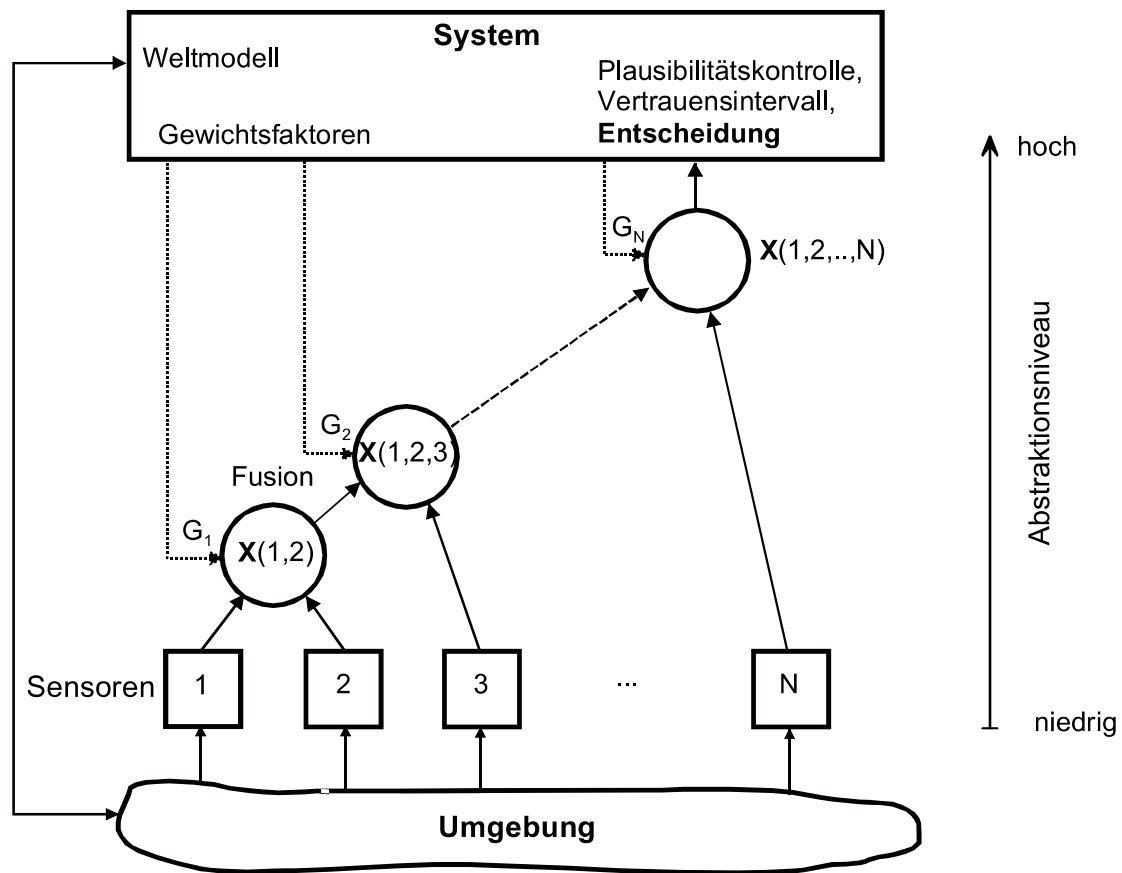


Abb. 1. Prinzipbild der Multisensorintegration und Datenfusion [2].

## 2 Fusionsmodelle

In Abbildung 1 ist der Aufbau eines allgemeinen Multisensorsystems schematisch gezeigt [2]. Alle bekannten Objekte im Erfassungsbereich und wichtige Merkmale (z. B. deren Lage, Trajektorie und Orientierung relativ zum Sensor) sind in einem *Weltmodell* zusammengefasst, welches zyklisch oder bedarfsorientiert aktualisiert wird, um beispielsweise Veränderungen der Position eines Objektes oder neu hinzukommende Objekte zu erfassen. Anhand von *Sensormodellen* und von Kenntnissen über den Zustand der Sensoren können Aussagen über statistische Eigenschaften der Sensoraussagen gemacht werden.

In vielen Übersichten [3, 24] wird auf das sog. JDL-Modell gemäß Abbildung 2 verwiesen [4], das insbesondere für Anwendungen in der Militärtechnik Grundlage vieler systematischer Einteilungen von Fusionsansätzen ist. Es besteht aus fünf Stufen der Informationsverdichtung. Neben der Vorverarbeitung der Einzelinformationen (*Level 0*) erfolgt die Einteilung der Fusionsaufgaben in folgende Ebenen:

- **Objekterkennung und Zustandsschätzung** (*Level 1*) durch iterative Fusion der Sensordaten. Hierzu gehören eine Registrierung der Daten, eine Objektdetektion, eine Zuordnung der Detektionsergebnisse unterschiedlicher

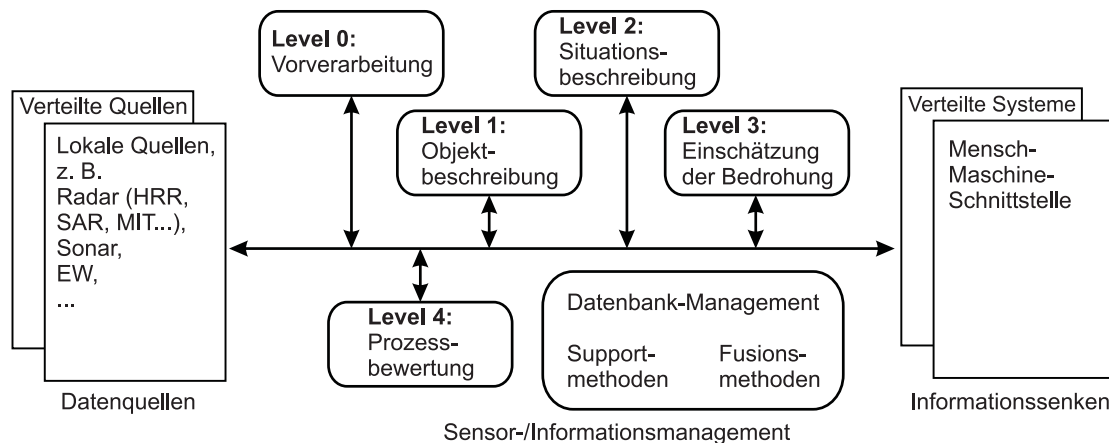


Abb. 2. JDL-Modell [3].

Sensoren, die Verfolgung der Objekttrajektorien und ggf. eine Objektklassifikation. Das Ergebnis dieser Schritte liefert das sogenannte *Situationsbild* und gestattet u. a. die Prädiktion des Objektverhaltens.

- **Situationsanalyse** (*Level 2*): Sie beinhaltet die Zuordnung der Objekte zu einem Szenario — in der Regel durch eine zeitliche Analyse ihrer Trajektorien — und ermöglicht eine Interpretation ihrer Bewegungsmuster.
- **Bedrohungsanalyse** (*Level 3*): Nachdem die „Intention“ der beobachteten Objekte identifiziert wurde, bewertet das Fusionssystem in dieser Ebene Handlungsoptionen im Sinne einer Risikominimierung.
- **Prozessoptimierung** (*Level 4*) durch laufende Bewertung des Gesamtprozesses und Interaktion mit den anderen Ebenen, z. B. zur aktiven Steuerung der Datenerfassung („Aktives Messen“).

Trotz seiner häufigen Erwähnung in der Literatur liefert das JDL-Modell keine Beschreibung der eigentlichen Datenfusion, sondern beschränkt sich auf eine hierarchische Einteilung der Informationsverarbeitung. Ferner fällt es — vor allem jenseits militärischer Szenarien — manchmal schwer, die Funktion der Ebenen 2 und 3 zu erkennen.

Demgegenüber wird im neueren Omnibus-Modell [25] Messen als Regelkreis („aktives Messen“) dargestellt; siehe Abbildung 3. Die vier Aufgaben

- Messen (Wahrnehmung, Signalverarbeitung),
- „Ausloten“ (Merkmalsextraktion, Mustererkennung),
- Entscheiden (Kontextverarbeitung, Entscheidung) und
- Handeln (Steuerung, Ressourceneinsatz)

durchlaufen einen Regelkreis, wobei die Übergänge zwischen diesen Funktionen mit verschiedenen Fusionsstufen korrespondieren (Sensordatenfusion, „*Soft decision*“-Fusion, „*Hard decision*“-Fusion und Sensor-Management.



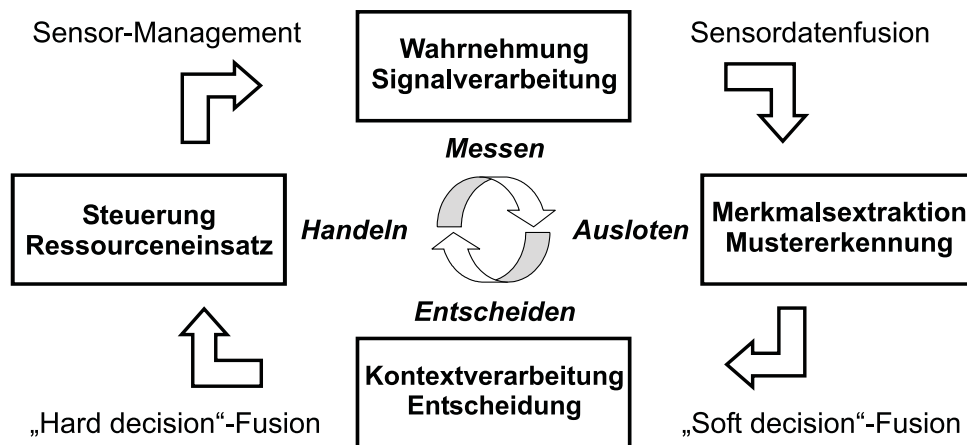


Abb. 3. Omnibus-Modell [25].

### 3 Konzepte zur Sensorintegration und Datenfusion

Der Aussagegewinn durch den Einsatz von Multisensorsystemen bei der Erfassung einer Größe beruht in der Regel auf der Verknüpfung *redundanter* oder *komplementärer* Informationen [1, 2]. Durch Redundanz kann die Unsicherheit (z. B. in Form der Varianz) der Sensorsignale verringert, das Signal-zu-Rausch-Verhältnis erhöht sowie die Plausibilität der Aussage überprüft und damit die Sensorzuverlässigkeit gesteigert werden. Durch heterogene Sensoren können komplementäre (sich ergänzende) Informationen aufgenommen werden. Ihre Auswertung führt zu einem gegenüber Einzelsensoren oder redundanten Sensoren erweiterten Ansprechbereich auf verschiedene Objektmerkmale und zur Eliminierung von Mehrdeutigkeiten durch Ergänzung unvollständiger Informationen der Einzelsensoren.

Konzepte zur Integration von Einzelsensoren in einem Multisensorsystem sind vom Einsatzort und der Art der Sensordaten abhängig. Entsprechend lassen sich verschiedene Konzepte der Sensorintegration definieren; siehe Abbildung 4:

- *Konkurrierende Integration*: Datenintegration gleichartiger Sensoren mit gleicher Nutzinformation mit dem Ziel, Unsicherheiten zu reduzieren — z. B. durch Mittelung. Ein Beispiel für eine konkurrierende Integration ist die Akkumulation von Bildern, die unter gleichen Aufnahmebedingungen erfasst wurden, zur Rauschunterdrückung.
- *Komplementäre Integration*: Datenintegration gleichartiger Sensoren mit unterschiedlicher Nutzinformation mit dem Ziel, Informationslücken zu vervollständigen. In diesem Fall würde sich eine Mittelung destruktiv auf die Messdaten auswirken. Ein Beispiel für eine komplementäre Integration ist die Verknüpfung von Sensoren mit unterschiedlichen Messbereichen.
- *Kooperative Integration*: In diesem Fall liegt die Nutzinformation verteilt vor, so dass sämtliche Messdaten ausgewertet werden müssen, um auf die Messgröße schließen zu können — z. B. weil ein Sensorsignal erst mit Hilfe von Signalen anderer Sensoren interpretiert werden kann. Ein Beispiel für

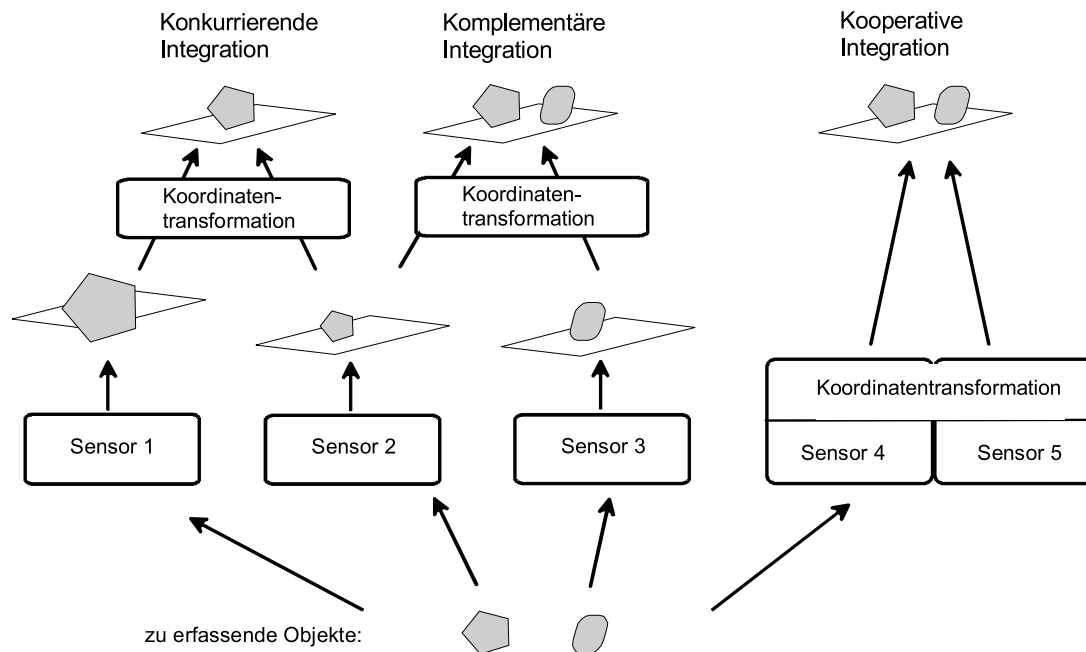


Abb. 4. Einteilung von Konzepten zur Sensorintegration.

eine kooperative Integration ist die Berechnung einer Tiefenkarte aus einem Stereo-Bildpaar [8].

Die Lösungsansätze für die Fusionsaufgabe lassen sich in drei Grundmuster einteilen [3, 23, 26]:

- (1)  $M$ -aus- $N$ -Entscheidung für  $M$  der  $N$  vorliegenden Informationsquellen;
- (2) Verrechnung aller entsprechend der Zuverlässigkeit oder des Informationsgehaltes gewichteten Datenquellen;
- (3) Planung des Sensoreinsatzes, etwa durch Auswahl des für eine Messaufgabe am besten geeigneten Sensors (1-aus- $N$ -Entscheidung, beispielsweise für eine Hinderniserkennung in zwei Stufen: die Objektumgebung wird zunächst mit der Kamera qualitativ bestimmt und dann die Entfernung zum erkannten Hindernis mit dem Ultraschall-Laufzeitverfahren vermessen).

**Abstraktionsebenen** Für die Ausführung der Datenfusion werden — abhängig vom Abstraktionsniveau — drei Möglichkeiten unterschieden: Fusion auf *Signalebene*, *Merkmalsebene* und *Symbolebene*. Dabei ist die Fusion auf einer höheren Abstraktionsebene meist effizienter, nicht jedoch notwendigerweise effektiver, da sie mit Datenreduktion und einem Informationsverlust einhergeht.

- Auf der *Signalebene* werden die Signale von Einzelsensoren direkt kombiniert. Voraussetzung sind die Vergleichbarkeit der Messsignale sowie deren Registrierung und Synchronisation.

**Tabelle 1.** Gegenüberstellung von Fusionsebenen.

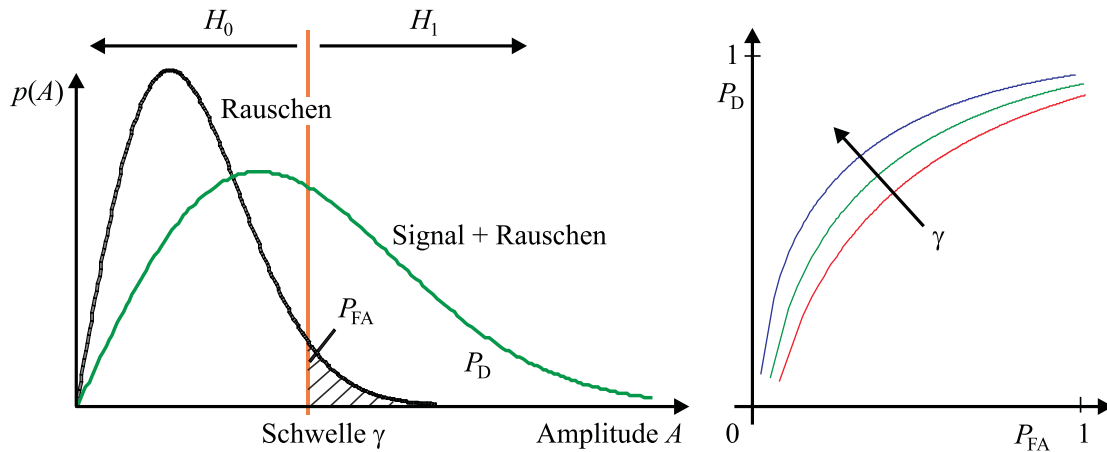
Fusionsebene	Signalebene	Merkmalsebene	Symbolebene
<b>Art der zu fusionierenden Daten</b>	Signale, Messdaten	Signaldeskriptoren	Symbole, Objekte, Entscheidungen, Äquivalenzklassen
<b>Zielsetzung</b>	Signalschätzung, Parameterschätzung	Merkmalsschätzung, Parameterschätzung	Klassifikation, Mustererkennung
<b>Abstraktionsgrad</b>	niedrig	mittel	hoch
<b>Geeignete Datenmodelle</b>	Zufallsprozesse, Zufallsvariablen	Zufallsvektoren	Wahrscheinlichkeitsverteilungen
<b>Voraussetzungen für die Fusion (räumlich/zeitlich)</b>	Registrierung/ Synchronisation ( <i>alignment</i> )	Zuordnung der Merkmale ( <i>association</i> )	Zuordnung der Symbole ( <i>association</i> )
<b>Typische Komplexität</b>	hoch	mittel	gering

- Auf der *Merkmalsebene* werden Signaldeskriptoren fusioniert, um verbesserte numerische Schätzwerte bestimmter Signaleigenschaften zu erhalten. Dies ist insbesondere dann sinnvoll, wenn auf der Signalebene keine zeitliche oder räumliche Kohärenz der Daten der Einzelsensoren hergestellt werden kann oder muss.
- Auf der *Ebene symbolischer Beschreibungen* werden symbolische Signaldeskriptoren — wie z. B. Detektions- oder Klassifikationsergebnisse — kombiniert, um etwa anhand jeweils zugeordneter Wahrscheinlichkeiten Entscheidungen zu treffen.

Im Falle der Merkmalsfusion als auch der Symbolfusion können Ergebnisse aus darunterliegenden Abstraktionsebenen berücksichtigt werden [27]. In der Tabelle 1 sind die unterschiedlichen Fusionsebenen gegenübergestellt.

**Fusionsarchitekturen** Hinsichtlich der Architektur der Datenfusion wird zwischen *zentraler Datenfusion* mit *einem* Entscheidungszentrum und *verteilter Datenfusion* mit lokalen Entscheidungszentren sowie Mischformen von beiden Varianten unterschieden [3, 21]. Bei der zentralen Fusion bleiben bis zur Verknüpfung sämtliche Informationen erhalten, es fallen jedoch unter Umständen (z. B. bei Sensorarrays) hohe Datenmengen an. Aufgrund begrenzter Bandbreite und geforderter Echtzeitfähigkeit sowie der Komplexität zentraler Fusionsmethoden werden daher häufig trotz des damit verbundenen Informationsverlustes die Sensorinformationen vor Ort von lokalen Entscheidungszentren ausgewertet und nur die Ergebnisse an ein zentrales Entscheidungszentrum weitergegeben.

**Objektdetektion** Viele Anwendungen von Multisensorsystemen betreffen eine verbesserte Detektion von Objekten. Hierbei wird die Amplitude der gemessenen Signale — je nach Sensorart ggf. nach Hüllkurvendetektion, Signalaufbereitung,




**Abb. 5.** (a) Amplitudenverteilung mit Detektionswahrscheinlichkeit  $P_D$  und Falschalarmwahrscheinlichkeit  $P_{FA}$  bei Schwellenauswertung; (b) Empfängercharakteristiken (ROC-Kurven).

Matched-Filterung o. ä. — meist mit einer Schwelle  $\gamma$  verglichen. Zur Bewertung der Leistungsfähigkeit des Detektors wird, ausgehend von geeigneten Signal- und Rauschmodellen, die Wahrscheinlichkeit  $P_D$  bestimmt, dass der Detektor ein vorhandenes Objekt erkennt (Detektionswahrscheinlichkeit). Wesentlich sind darüber hinaus vor allem die Fehlalarmwahrscheinlichkeit  $P_{FM} = 1 - P_D$  (ein vorhandenes Objekt wird nicht erkannt) und die Falschalarmwahrscheinlichkeit  $P_{FA}$  (ein nicht vorhandenes Objekt wird als erkannt angegeben) [28]. Signale, welche die Schwelle  $\gamma$  überschreiten, werden als Nutzsignale angesehen (Hypothese  $H_1$ ), die anderen als Rauschen interpretiert (Hypothese  $H_0$ ); siehe Abbildung 5(a). Der Zusammenhang zwischen der Detektionswahrscheinlichkeit  $P_D$  und der Falschalarmwahrscheinlichkeit  $P_{FA}$  ist eine Funktion der Detektionsschwelle  $\gamma$  und lässt sich durch sog. Empfängercharakteristiken (ROC-Kurven, engl. *Receiver Operating Characteristic*) darstellen; siehe Abbildung 5(b). Für bekannte Verteilungsdichtefunktionen von Signal und Rauschen kann  $\gamma$  tabellierten ROC-Kurven entnommen werden. Zur Detektion wird vielfach das *Neyman-Pearson*-Kriterium angewendet: Die Detektorschwelle wird so bestimmt, dass  $P_D$  für eine fest vorgegebene Falschalarmwahrscheinlichkeit  $P_{FA}$  maximiert wird. Damit wird der Tatsache Rechnung getragen, dass speziell für Ortungs- und Überwachungsaufgaben die Glaubwürdigkeit der Aussage durch Falschalarme sinkt und die Kosten steigen. Es sind zudem keine A-priori-Kenntnisse über die Übergangswahrscheinlichkeiten erforderlich.

## 4 Fusionsmethoden

Die Sensorsignale werden typischerweise sensornah, d. h. vor der Fusion, vorverarbeitet (Verstärkung, Rauschunterdrückung). Anschließend ist unter Umständen eine räumliche Koordinatenanpassung (Registrierung) oder eine Synchronisation der Signale der Einzelsensoren erforderlich. Die Verknüpfung der Daten



**Abb. 6.** Verarbeitungsschritte für eine Datenfusion (Beispiel).

der unterschiedlichen Sensoren erfolgt somit meist im mehreren Schritten. Ein einfaches Beispiel hierzu ist in Abbildung 6 dargestellt.

Eine grundlegende Einteilung erfolgt — in Abhängigkeit von der Art der Zielgröße — in *gitterbasierte* (geometrische) und *parameterbasierte* (numerische) Ansätze [1, 3].


**Gitterbasierte Ansätze** Datenfusionsverfahren basierend auf gitterbasierten Ansätzen werden seit langem zur Fahrwegplanung und Navigation von Robotern angewendet [29–32]. Dabei werden aus der Kombination sequentieller und zeitgleicher Abstandsmessungen homogener oder heterogener Sensoren (Ultraschall, Infrarot, Laser) Belegungswahrscheinlichkeiten einer Rasterstruktur (*occupancy grid*) bestimmt, um daraus ein Abbild der Objektszene zu gewinnen. Im Verlauf der sog. Kartographierung wird dann die Belegungswahrscheinlichkeit unbesetzter und besetzter Bereiche kumuliert und anhand einer Schwellenentscheidung ausgewertet. Durch sequentielle Messungen während der Roboterbewegung wird das Belegungsgitter aktualisiert. Liefern Messungen von verschiedenen Ortspunkten und aufeinanderfolgenden Zeitpunkten fortlaufend hohe Belegungswerte für eine bestimmte Zelle, so vergrößert sich die Wahrscheinlichkeit, dass sich dort ein Objekt befindet. Gegensätzliche Sensoraussagen schwächen sich dagegen ab.

**Parametrische Fusionsmethoden** Für die Verschmelzung der Messergebnisse von Einzelsensoren eines Multisensorsystems wurde eine Vielzahl sog. parametrischer Fusionsmethoden entwickelt [1, 3]. Eine übliche Einteilung erfolgt in

- merkmalsbasierte Ansätze,
- probabilistische Ansätze,
- fuzzy-basierte Methoden sowie
- neuronale Ansätze.

Zu den Erstgenannten zählen der gewichtete Mittelwert und das Kalman-Filter. Häufig anzutreffende probabilistische Ansätze sind die Methoden der Klassischen und der Bayesschen Statistik [35] sowie ihre Verallgemeinerung zur sog. Dempster-Shafer-Evidenztheorie [36]. Zur ihrer Betrachtung sei zunächst das Fusionsproblem anhand des in Bild 7 gezeigten Parameterschätzmodells formuliert.

Von einer Quelle wird ein Parameter  $\theta$  emittiert, der eine Realisierung der Zufallsgröße  $\Theta$  darstellt. Bei der Zielgröße  $\theta$  kann es sich um eine Messgröße handeln, aber auch um latente Konstrukte, die keinen Anspruch auf physikalische



**Abb. 7.** Informationsfusion als Parameterschätzproblem.

Realität haben müssen. Im letzteren Fall kann die Größe  $\theta$  als eine Idealisierung der Sensordaten  $\mathbf{m}_i$  verstanden werden, bei der gewünschte oder bekannte Eigenschaften der Zielgröße selbst berücksichtigt werden. Mit Hilfe mehrerer Sensoren werden die Daten  $\mathbf{m}_i$  erfasst, welche ebenfalls als Realisierungen eines Zufallsprozesses  $\mathbf{M}$  aufzufassen sind. Die Messung entspricht einer Abbildung  $\Theta \mapsto \mathbf{M}$ , die sich mathematisch mittels der bedingten Wahrscheinlichkeitsverteilung (WV) von  $\mathbf{M}|\Theta$  beschreiben lässt. Im Folgenden sei angenommen, dass es sich bei  $\theta$  und  $\mathbf{m}$  um kontinuierliche Größen handelt, so dass die WV anhand einer Wahrscheinlichkeitsdichtefunktion (WDF) beschrieben wird.

Eine besonders für zeitkritische Anwendungen elementare Methode der konkurrierenden Datenfusion ist die Bildung des **gewichteten Mittelwertes** der Sensorausgangssignale  $\mathbf{m}_i$  ( $i = 1, \dots, N$ )  $N$  redundanter Sensoren:

$$\hat{\theta} = \frac{1}{N} \sum_{i=1}^N w_i \mathbf{m}_i. \quad (1)$$

Durch die Wichtungsfaktoren  $w_i$  mit  $\sum_{i=1}^N w_i = 1$  wird der Einfluss unsicherer Werte gegenüber sicheren Werten vermindert. Der gefundene Schätzwert  $\hat{\theta}$  enthält aber keine Aussage über die Qualität des Fusionsergebnisses.

**Kalman-Filter** sind ein häufig eingesetztes Mittel, um redundante Daten dynamischer Systeme auf einer niedrigen Ebene der Signalverarbeitung zu fusionieren [33]. Das rekursive Schätzverfahren bestimmt aus verrauschten Daten unbekannte Zustände eines dynamischen Prozesses mit minimaler Fehlervarianz. Voraussetzung sind kinematische Sensor- und Umgebungsmodelle sowie Informationen über die Anfangszustände. Aus dem gesamten A-priori-Wissen wird eine Schätzung der gewünschten Variablen mit minimalem quadratischen Fehler erzeugt. In jedem neuen Fusionsschritt werden nur die bisherige Gesamtunsicherheit und die Unsicherheit des neuen Messwertes berücksichtigt. Dadurch ist eine exakte Unsicherheitsabschätzung des Endergebnisses möglich. Werte mit größerer Unsicherheit beeinflussen die aktuelle Schätzung weniger als genaue Werte. Problematisch ist unter Umständen die Bestimmung geeigneter Anfangswerte.

Der **Klassischen Statistik** liegt eine empirische, frequentistische Interpretation von Wahrscheinlichkeiten zugrunde, bei der zwar die Sensordaten  $\mathbf{m}_i$  als Zufallsgrößen angesehen werden, nicht jedoch die Messgröße  $\theta$  selbst [34]. Die Schätzung von  $\theta$  anhand der Sensordaten  $\mathbf{m}_i$  stützt sich auf die sogenannte Likelihoodfunktion  $p_{\mathbf{M}|\Theta}(\mathbf{m}|\theta)$ , die dafür als Funktion von  $\theta$  aufgefasst und maximiert wird:

$$\hat{\theta}_{\text{ML}} = \arg \max_{\theta} \{p_{\mathbf{M}|\Theta}(\mathbf{m}|\theta)\}. \quad (2)$$

Der zugehörige Wert  $\hat{\theta}_{\text{ML}}$  heißt Maximum-Likelihood- oder ML-Schätzwert.

In der **Bayesschen Statistik** wird auch die Messgröße  $\theta$  als Realisierung einer Zufallsgröße  $\Theta$  aufgefasst, weshalb die A-priori-WDF  $p_{\Theta}(\theta)$  zur Bestimmung der A-posteriori-WDF  $p_{\Theta|\mathbf{M}}(\theta|\mathbf{m})$  herangezogen wird:

$$p_{\Theta|\mathbf{M}}(\theta|\mathbf{m}) = \frac{p_{\mathbf{M}|\Theta}(\mathbf{m}|\theta) p_{\Theta}(\theta)}{p_{\mathbf{M}}(\mathbf{m})}. \quad (3)$$

Durch Maximierung dieser Gleichung erhält man die Maximum-a-posteriori-Lösung (MAP-Lösung) für den zu schätzenden Parameter  $\theta$ :

$$\hat{\theta}_{\text{MAP}} = \arg \max_{\theta} \{p_{\Theta|\mathbf{M}}(\theta|\mathbf{m})\}. \quad (4)$$

Diese Vorgehensweise hat den wesentlichen Vorteil, dass sie die Angabe der WV für den zu schätzenden Parameter  $\theta$  bei gegebenen Messdaten  $\mathbf{m}_i$  zulässt, wohingegen die Klassische Vorgehensweise lediglich die Angabe der WV für die Sensordaten  $\mathbf{m}_i$  bei gegebenem Parameterwert  $\theta$  erlaubt [38]. Eine nähere Betrachtung des Bayesschen Fusionsansatzes kann in [35] nachgelesen werden.

Die **Dempster-Shafer-Evidenztheorie** wird oftmals als eine Erweiterung der Wahrscheinlichkeitstheorie oder als eine Verallgemeinerung der Bayesschen Statistik betrachtet. Sie basiert auf zwei nichtadditiven Maßen — dem Grad des Dafürhaltens (englisch: *degree of belief*) und der Plausibilität — und bietet die Möglichkeit, Ungewissheit detaillierter auszudrücken [36, 37]. In praktischen Aufgabenstellungen ist es jedoch nicht immer möglich, das verfügbare Wissen über die relevanten Größen derart differenziert darzustellen und somit die theoretischen Möglichkeiten dieses Ansatzes voll auszuschöpfen.

Methoden der **Fuzzy-Logik** basieren auf der Verallgemeinerung des Mengenbegriffes mit dem Ziel, eine unscharfe Wissensrepräsentation zu erlangen. Dies erfolgt anhand einer sogenannten Zugehörigkeitsfunktion, die jedem Element einen Grad der Zugehörigkeit zu einer Menge zuordnet [37]. Aufgrund der Willkür bei der Wahl dieser Funktion stellt die Fuzzy-Mengentheorie eine sehr subjektive Methode dar, die sich daher besonders zur Repräsentation von menschlichem Wissen eignet. In der Informationsfusion werden Fuzzy-Methoden eingesetzt, um Ungewissheit und Vagheit im Zusammenhang mit den Sensordaten zu handhaben [38]. Beispiele hierzu sind die Realisierung situationsbedingter Ablaufsteuerungen (z. B. zur Unterdrückung von Mehrfachechos und zeitlichen Fluktuationen) sowie Klassifikationsaufgaben zur Bewertung der Übereinstimmung der Messung mit eingelernten Situationen [39].

Ein weiteres Paradigma zur Fusion von Sensordaten sind die künstlichen **Neuronalen Netze** (NN). Diese basieren meist auf softwaresimulierten Verarbeitungseinheiten, welche zu einem Netzwerk verschaltet werden, um bestimmte Aufgaben zu lösen. Ihr Einsatz ist besonders vorteilhaft, wenn es schwer oder nicht möglich ist, einen Algorithmus zur Kombination der Sensordaten zu spezifizieren. In solchen Fällen wird dem NN in einer Trainingsphase mittels Testdaten das gewünschte Verhalten beigebracht. Nachteilig an NN sind die mangelnden Möglichkeiten zur Einbindung von A-priori-Wissen über die an der Fusion beteiligten Größen.

## 5 Beispiele

**Doppelte Evidenz** Am Beispiel eines Einbruchsicherungssystems soll gezeigt werden, wie die Glaubwürdigkeit eines Ereignisses (Ursache) durch mehrere Beobachtungen ihrer Wirkung gesteigert werden kann [40]. Ein Einbruch sei die Ursache und werde durch die a priori bekannte Auftrittswahrscheinlichkeit  $P(U)$  charakterisiert, beispielsweise aus Erfahrungswerten der Polizei für die betreffende Wohngegend. Die Wirkung sei die Auslösung eines Alarms, ihre Wahrscheinlichkeit  $P(W)$ .  $P(W|U)$  bezeichnet die Wahrscheinlichkeit, dass bei einem Einbruch ein Alarm gemeldet wird (Detektionswahrscheinlichkeit). Ferner bezeichnet  $P(W|\bar{U})$  die Falschalarmwahrscheinlichkeit, dass ein Alarm aus einem anderen Grund als  $U$  ausgelöst wird. Die A-posteriori-Wahrscheinlichkeit  $P(U|W)$  beschreibt die Wahrscheinlichkeit, dass tatsächlich ein Einbruch stattgefunden hat, wenn Alarm ausgelöst wurde. Nach der Bayes-Regel beträgt sie:

$$P(U|W) = \frac{P(W|U) P(U)}{P(W)} = \frac{P(W|U) P(U)}{P(W|U) P(U) + P(W|\bar{U}) P(\bar{U})}. \quad (5)$$

Mit Hilfe des Likelihoodverhältnisses

$$L(W|U) = \frac{P(W|U)}{P(W|\bar{U})} \quad (6)$$

lässt sich Gl. (5) wie folgt schreiben:

$$P(U|W) = \frac{L(W|U) P(U)}{L(W|U) P(U) + P(\bar{U})}. \quad (7)$$

Das Likelihoodverhältnis besagt, um wieviel wahrscheinlicher es ist, dass ein Alarm durch einen Einbruch als durch irgendeinen anderen Grund ausgelöst wird.

Wird  $P(U) = 10^{-4}$  angenommen (d. h. zu einer beliebigen Zeit wird in eine aus 10.000 Wohnungen einer Wohngegend ein Einbruchversuch unternommen) und dann mit einer Wahrscheinlichkeit von 95% einen Alarm ausgelöst ( $P(W|U) = 0,95$ ), wobei ein Alarm zu 1% auch durch andere Einflüsse ausgelöst werden kann ( $P(W|\bar{U}) = 0,01$ ), so beträgt das Likelihoodverhältnis  $L(W|U) = 95$ . Für die A-posteriori-Wahrscheinlichkeit eines Einbruches im Falle eines Alarms folgt mit Gl. (7):

$$P(U|W) = \frac{95 \cdot 10^{-4}}{95 \cdot 10^{-4} + (1 - 0,01)} = 0,0094. \quad (8)$$

Wenn zwei unabhängige Wirkungen  $W_1$  und  $W_2$  auf eine gemeinsame Ursache  $U$  ansprechen, beträgt die A-posteriori-Wahrscheinlichkeit eines Einbruches:

$$\begin{aligned} P(U|W_1 \cap W_2) &= \frac{L(W_1 \cap W_2|U) P(U)}{L(W_1 \cap W_2|U) P(U) + P(\bar{U})} \\ &= \frac{L(W_1|U) L(W_2|U) P(U)}{L(W_1|U) L(W_2|U) P(U) + P(\bar{U})}. \end{aligned} \quad (9)$$



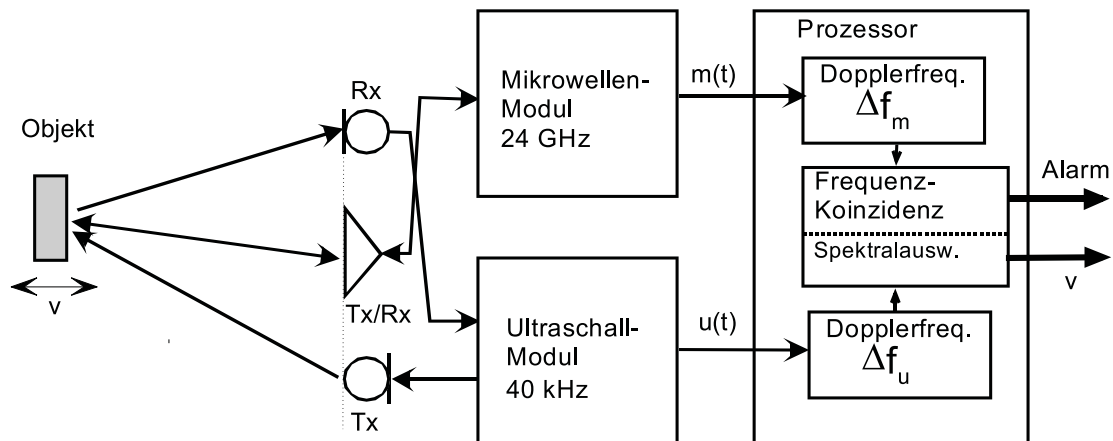


Abb. 8. Ultraschall-Mikrowellen-Dualsensor [41].

Wird für beide Alarmsysteme die gleiche Charakteristik  $L(W_i|U) = 95$  wie beim vorherigen Beispiel angenommen, so erhält man für die Fusion von  $W_1$  und  $W_2$ :

$$P(U|W_1 \cap W_2) = 0,47. \tag{10}$$

Der Vergleich der Ergebnisse aus Gln. (8) und (10) zeigt, wie wesentlich sich durch doppelte Evidenz die Wahrscheinlichkeit erhöht hat, dass die beobachtete Wirkung (Alarm) auf die gesuchte Ursache (Einbruch) zurückzuführen ist.  $\diamond$

**Dopplerfrequenzkoinzidenz** Als zweites Beispiel wird ein Multisensoransatz vorgestellt, welcher auf der direkten Vergleichbarkeit der Nutzsignale beruht, während Störsignale durch die unterschiedlichen Funktionsprinzipien der Einzelsensoren statistisch unkorreliert sind: Zur Messung von Geschwindigkeit und Entfernung von Objekten wird die Phasenkoinzidenz zwischen Ultraschall- und Mikrowellen-Echosignalen ausgewertet, wobei die von Objekten reflektierten Ultraschall- und Mikrowellensignale mit kohärenten Echofrequenzen empfangen werden, während Störsignale unterschiedlich auf beide Wellen einwirken. Mit der Fusion der diversitär-redundanten Ultraschall- und Mikrowellen-Dopplersignale kann die Falschalarmquote ohne Verlust an Nachweisempfindlichkeit um Größenordnungen gesenkt werden [41].

In Abbildung 8 ist das Prinzipbild des Ultraschall-Mikrowellen-Multisensors dargestellt. Der Mikrowellensensor und der Ultraschallsensor sind ortsnahe zueinander angeordnet und stehen damit unter annähernd gleichem Einblickwinkel zu den interessierenden Nutzobjekten. Die Trägerfrequenzen betragen 40 kHz für Ultraschall (Wellenlänge  $\lambda_U = 8$  mm) und 24 GHz für Mikrowellen (Wellenlänge  $\lambda_M = 12$  mm, K-Band). Die Datenfusion und Signalauswertung erfolgen auf einer digitalen Auswertepattform.

Die Proportionalität zwischen der gemessenen Dopplerfrequenz  $f_d$  im Empfangssignal und der Geschwindigkeitskomponente  $v_r$  in Wellenausbreitungsrichtung ist nur durch die Wellenlänge des Ortungssignals im Ausbreitungsmedium

gegeben, nicht jedoch durch die Wellennatur. Die in beiden Systemen registrierten Dopplerfrequenzen  $f_{d_U}$  und  $f_{d_M}$  von nichtruhenden Objekten stehen also im reziproken Verhältnis zu den Wellenlängen  $\lambda_U$  und  $\lambda_M$  der ausgesandten Wellen:

$$\frac{f_{d_M}}{f_{d_U}} = \frac{\lambda_U}{\lambda_M}. \quad (11)$$

Eine Überprüfung der Bedingung Gl. (11) ergibt also, ob die registrierten Dopplersignale von Nutzobjekten herrühren oder Störsignale sind.

Für die automatische Auswertung der Dopplerfrequenzkoinzidenz wird die Amplitude der Kreuzkorrelationsfunktion  $r(\tau)$  aus den (harmonischen) Ultraschall- und Mikrowellen-Empfangssignalen  $u(t)$  und  $m(t)$  ausgewertet, welche ein Maß für die Ähnlichkeit der beiden Empfangssignale liefert:

$$r(\tau) = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T u(t - \tau) m(t) dt. \quad (12)$$

Die Berechnung erfolgt im Spektralbereich. Aus den komplexen Spektren  $U(f)$  und  $M'(f)$  der Ultraschall- und der entsprechend dem Wellenlängenverhältnis  $\lambda_U/\lambda_M$  normierten Mikrowellensignale wird die Kreuzleistungsdichte  $R(f)$  berechnet:

$$R(f) = \frac{1}{T} (U(f) \cdot M'^*(f)) \quad (13)$$

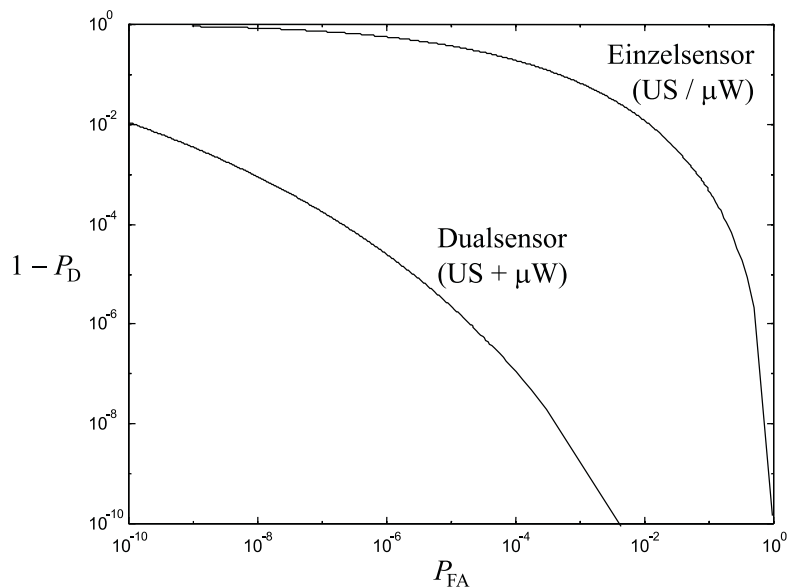
mit  $M'^*(f)$  konjugiert komplex zu  $M'(f)$ . Stimmen die Perioden in  $u(t)$  und  $m'(t)$  überein, so weist der Betrag von  $R(f)$  ein scharfes Maximum für diese Frequenz auf.

Mit Hilfe einer Maximum-Likelihood-Abschätzung wird für komplementäre Hypothesen das Ereignis gesucht, dessen Auftreten am Wahrscheinlichsten ist [33]. Für den vorliegenden Fall lässt sich nachweisen [42], dass das entsprechende Likelihoodverhältnis  $\Lambda$  die folgende Form hat:

$$\Lambda = \frac{2}{\sigma_U^2 \sigma_M^2} |U(f_d) M'^*(f_d)| \quad (14)$$

(mit  $\sigma_U^2$ ,  $\sigma_M^2$ : Rauschvarianzen des Ultraschall- und des Mikrowellensignals) und damit die Berechnung der Kreuzleistungsdichte der Empfangssignale der Einzelsensoren ein *statistisch* optimales Fusionsverfahren darstellt.

Zur Veranschaulichung des Detektionsvermögens des Empfängers werden Empfängercharakteristiken (ROC-Kurven) aufgestellt. Für ein gegebenes Signal-zu-Rausch-Verhältnis ( $\text{SNR} = 6 \text{ dB}$ ) wurden die ROC-Kurven für die Bewegungsdetektion mit einem Sensor und mit zwei gleichzeitig betriebenen, diversitär-redundanten Sensoren berechnet. Dargestellt ist die für ein Alarmsystem aussagekräftigere Wahrscheinlichkeit  $P_{FM} = 1 - P_D$  eines Übersehens einer Alarmsituation (Fehlalarm) über der Wahrscheinlichkeit  $P_{FA}$  eines falschen Alarms im Vergleich zum Detektionsvermögen eines Einzelsensors; siehe Bild 9.  $\diamond$




**Abb. 9.** ROC-Kurven des Dualsensors im Vergleich zu Einzelsensoren.

**Fusion von Belichtungsserien** Schließlich soll am Beispiel einer Belichtungsserie gezeigt werden, wie eine Bildserie unter Variation eines Parameters — der Verschlusszeit — zu einem Resultatbild höherer Güte fusioniert wird. Herkömmliche Bildsensoren haben einen relativ schmalen nutzbaren Dynamikbereich. Natürliche und technische Szenen können jedoch eine wesentlich höhere Dynamik aufweisen. Das bedingt, dass sehr helle Szenenbereiche zu einer Übersteuerung des Sensors führen und in dunklen Bereichen die Szeneninformation mit nur sehr geringem SNR erfasst wird oder gar im Rauschen verschwindet. Im Folgenden soll daher eine Bildserie derart gewonnen werden, dass alle Szenenbereiche in mindestens einem Bild der Serie mit adäquatem SNR enthalten sind. Bei der anschließenden Fusion werden dann die Regionen mit bestem SNR zu einem Resultatbild verschmolzen, das überall ein hohes SNR aufweist [43].

In Abbildung 10 sind links vier Bilder einer Belichtungsserie einer hell leuchtenden LED vor einem davon nicht direkt angeleuchteten Hintergrund zu sehen. Das obere rechte Bild zeigt das logarithmierte Fusionsergebnis, welches eine erweiterte Dynamik und ein im Mittel deutlich höheres SNR aufweist. Zur visuellen Bewertung des Ergebnisses zeigt das untere rechte Bild das Fusionsresultat nach Durchführung einer Homogenisierung des lokalen mittleren Grauwertes und des lokalen Kontrastes [44]. Man beachte insbesondere, dass in diesem Bild sowohl sehr hell ausgeleuchtete als auch dunkle Bereiche der Szene deutlich erkannt werden können.  $\diamond$

## 6 Zusammenfassung und Ausblick

In vielen technischen Systemen werden zur Funktionsüberwachung und Ausfallsicherung mehrere baugleiche Systemgruppen parallel betrieben (sog. *strukturelle*



**Abb. 10.** Beispiel zur Fusion von Belichtungsserien zur Gewinnung eines Bildes mit gleichmäßigem SNR auf hohem Niveau: Belichtungsserie (links); Fusionsergebnis (rechts).

*Redundanz*). Demgegenüber werden die hier behandelten „echten“ Multisensorsysteme mit dem Ziel eingesetzt, die Aussagequalität einer Messaufgabe verglichen mit Ergebnissen, die mit Einzelsensoren erzielt wurden, zu verbessern — oder eine solche Aussage erst möglich zu machen.

Begünstigt durch neue Anforderungen in vielen Bereichen des modernen Lebens (u. a. Automobiltechnik, Medizin, Robotik, Umweltbeobachtung, *Ambient Intelligence*, Sicherheit) und bedeutende Fortschritte auf den Gebieten der Miniaturisierung und Autonomisierung intelligenter Sensoren als allgegenwärtigen Datenquellen hat die Informationsfusion in der jüngsten Vergangenheit vermehrte Aufmerksamkeit erfahren. Auf drei Aspekte, deren zunehmende Bedeutung in [45] prognostiziert wird, soll abschließend kurz eingegangen werden.

**Modellbasierte Signalauswertung** Grundlegend für die Multisensor- und Informationsfusion sind die Modellierung des Sensorverhaltens der Einzelsensoren und die Ableitung geeigneter Merkmale als Träger der gewünschten Information aus dem aufgenommenen Signalverlauf. Dabei spielen Beurteilungskriterien von Wissen (Plausibilität, Unsicherheit) eine große Rolle, die in einem Multisensorsystem z. B. erlernbar sein können. Mit dieser Lernfähigkeit und dem Zuwachs an Wissen geht auch eine Vervollständigung („Überbrückung“) unvollständiger Daten einher. Durch kontinuierliche Beobachtung der Modellparameter können

der Sensorzustand während des Betriebs überwacht und Driften oder Alterungseffekte erkannt und korrigiert werden [46].

**Fusion ohne Vorwissen über Sensorverhalten** Insbesondere bei Einsätzen von Multisensorsystemen in unbekanntem Umgebungen (z. B. zur Steuerung von autonomen Fahrzeugen) ist es sinnvoll, situationsbedingt eine Auswahl der zu fusionierenden Sensoren zu treffen, beispielsweise anhand eines kontinuierlichen Rankings nach bestimmten allgemeinen Leistungsparametern wie dem SNR oder der Auflösung oder durch Formulierung der Sensorkombinationen nach Fuzzy-Regeln. Diese Art dynamische Fusion mit situationspezifischer Wichtung ist oftmals robuster gegenüber ungewissen, bisher nicht erfassten Einflussgrößen als die Verknüpfung aller Quellen [47, 48].

**Sensornetzwerke** Sensornetzwerke oder Sensornetze bestehend aus einer Vielzahl von einfachen Elementarsensoren (Knoten) können als preiswerte Alternative zu klassischen (Mehr-)Sensoranordnungen zur Überwachung größerer geographischer Gebiete oder komplexer physikalischer Systeme dienen. Sensornetze zeichnen sich durch ein dynamisches Verhalten aus: so können bei Bedarf zusätzliche Knoten eine Netzregion verstärken oder einzelne Knotenausfälle durch andere Nachbarknoten kompensiert werden [49]. Die Knoten werden oft als logische Sensoren behandelt, wobei nur der Ausgang bewertet und weitergegeben wird.

## Literatur

1. M. A. Abidi und R. C. Gonzalez (Hrsg.). *Data Fusion in Robotics and Machine Intelligence*. Academic Press, San Diego, 1992.
2. R. C. Luo und M. G. Kay. Multisensor integration and fusion in intelligent systems. *IEEE Transactions on Systems, Man, and Cybernetics*, 19(5):901–931, 1989.
3. D. Hall. *Mathematical Techniques in Multisensor Data Fusion*. Artech House, Boston, London, 1992.
4. F. E. White. *Data Fusion Lexicon*. Data Fusion Subpanel of the Joint Directors of Laboratories (JDL), Technical Panel for C<sup>3</sup>, Naval Ocean Sciences Center, San Diego, 1991.
5. L. Wald. Some terms of reference in data fusion. *IEEE Transactions on Geoscience and Remote Sensing*, 37(3):1190–1193, 1999.
6. J. Beyerer, F. Puente León und K.-D. Sommer (Hrsg.), *Informationsfusion in der Mess- und Sensortechnik*, Universitätsverlag Karlsruhe, Karlsruhe, 2006.
7. M. O. Ernst und H. H. Bühlhoff. Merging the senses into a robust percept. *Trends in Cognitive Sciences*, 8(4):162–169, 2004.
8. M. Heizmann und F. Puente León. Bildfusion. In: *Informationsfusion in der Mess- und Sensortechnik*, J. Beyerer, F. Puente León und K.-D. Sommer (Hrsg.), S. 79–92, Universitätsverlag Karlsruhe, Karlsruhe, 2006.
9. J. Regin, J. Pannekamp, J. Neher, E. Westkämper, T. Wiesendanger und W. Osten. Multiskalige Messstrategien für die Mikrosystemtechnik. In: *Informationsfusion in der Mess- und Sensortechnik*, J. Beyerer, F. Puente León und K.-D. Sommer (Hrsg.), S. 137–143, Universitätsverlag Karlsruhe, Karlsruhe, 2006.

10. F. Röck und U. Weimar. Elektronische Nase und Signalgewinnung. In: *Informationsfusion in der Mess- und Sensortechnik*, J. Beyerer, F. Puente León und K.-D. Sommer (Hrsg.), S. 261–278, Universitätsverlag Karlsruhe, Karlsruhe, 2006.
11. E. Gockenbach. Sensorik in der elektrischen Energietechnik. In: *Informationsfusion in der Mess- und Sensortechnik*, J. Beyerer, F. Puente León und K.-D. Sommer (Hrsg.), S. 279–294, Universitätsverlag Karlsruhe, Karlsruhe, 2006.
12. W. Koch. Negative Sensorevidenz: Ausgewählte Beispiele aus militärischen Überwachungsanwendungen. In: *Informationsfusion in der Mess- und Sensortechnik*, J. Beyerer, F. Puente León und K.-D. Sommer (Hrsg.), S. 185–205, Universitätsverlag Karlsruhe, Karlsruhe, 2006.
13. M. Suppa und G. Hirzinger. Multisensorielle Exploration von Roboterarbeitsräumen. In: *Informationsfusion in der Mess- und Sensortechnik*, J. Beyerer, F. Puente León und K.-D. Sommer (Hrsg.), S. 159–169, Universitätsverlag Karlsruhe, Karlsruhe, 2006.
14. B. Korn. Pilot assistance for approach and landing. In: *Informationsfusion in der Mess- und Sensortechnik*, J. Beyerer, F. Puente León und K.-D. Sommer (Hrsg.), S. 171–183, Universitätsverlag Karlsruhe, Karlsruhe, 2006.
15. J. Becker. Fusion von Sensordaten zur Umfeldwahrnehmung für Fahrerassistenzsysteme — eine Übersicht. In: *Informationsfusion in der Mess- und Sensortechnik*, J. Beyerer, F. Puente León und K.-D. Sommer (Hrsg.), S. 207–221, Universitätsverlag Karlsruhe, Karlsruhe, 2006.
16. C. Duchow, B. Hummel, A. Bachmann, Z. Yang und C. Stiller. Akquisition, Repräsentation und Nutzung von Wissen in der Fahrerassistenz. In: *Informationsfusion in der Mess- und Sensortechnik*, J. Beyerer, F. Puente León und K.-D. Sommer (Hrsg.), S. 223–237, Universitätsverlag Karlsruhe, Karlsruhe, 2006.
17. D. Linzmeier und T. Bär. Fusion von Radar und Thermopilesensoren zur Fußgängerdetektion. In: *Informationsfusion in der Mess- und Sensortechnik*, J. Beyerer, F. Puente León und K.-D. Sommer (Hrsg.), S. 239–250, Universitätsverlag Karlsruhe, Karlsruhe, 2006.
18. N. Schilling und U. Tegtbur. Informationsfusion in Multisensorsystemen für die Sportmedizin. In: *Informationsfusion in der Mess- und Sensortechnik*, J. Beyerer, F. Puente León und K.-D. Sommer (Hrsg.), S. 251–260, Universitätsverlag Karlsruhe, Karlsruhe, 2006.
19. R. Tutsch und M. Petz. Ermittlung der Oberflächengeometrie aus Messpunktewolken in der optischen 3D-Messtechnik. In: *Informationsfusion in der Mess- und Sensortechnik*, J. Beyerer, F. Puente León und K.-D. Sommer (Hrsg.), S. 127–135, Universitätsverlag Karlsruhe, Karlsruhe, 2006.
20. S. C. Thomopoulos. Sensor integration and data fusion. *Journal of Robotic Systems*, 7:337–372, 1990.
21. M. Kokar und K. Kim. Review of multisensor data fusion architectures and techniques. In: *Int. Symp. on Intelligent Control*, Chicago, 1993.
22. R. R. Murphy. Biological and cognitive foundations of intelligent sensor fusion. *IEEE Transactions on Systems, Man, and Cybernetics – part A*, 26(1):42–51, 1996.
23. B. V. Dasarthy. Sensor fusion potential exploitation – innovative architectures and illustrative applications. *Proceedings of the IEEE*, 85(1):24–38, 1997.
24. L. A. Klein. *Sensor and Data Fusion: A Tool for Information Assessment and Decision Making*. SPIE Press, Bellingham, 2004.
25. M. Bedworth und J. O’Brien. The Omnibus model: A new model of data fusion?. *IEEE AES Systems Magazine*, 30–36, April 2000.
26. E. Schrüfer. *Zuverlässigkeit von Meß- und Automatisierungseinrichtungen*. Hanser, München Wien, 1984.

27. F. Puente León. Komplementäre Bildfusion zur Inspektion technischer Oberflächen. *Technisches Messen*, 69(4):161–168, 2002.
28. M. I. Skolnik. *Radar Handbook*. McGraw-Hill, 1990.
29. A. Elfes. Sonar based real-world mapping and navigation. *IEEE Transactions on Robotics and Automation*, 3(3):249–265, 1987.
30. J. J. Leonard und H. F. Durrant-Whyte. *Directed Sonar Sensing for Mobile Robot Navigation*. Kluwer, Boston, 1992.
31. J. Borenstein, H. R. Everett, L. Feng und D. Wehe. Mobile robot positioning: sensors and techniques. *J. Robotic Systems*, 14(4):231–249, 1997.
32. D. Meier, C. Stachniss und W. Burgard. Cooperative exploration with multiple robots using low bandwidth communication. In: *Informationsfusion in der Mess- und Sensortechnik*, J. Beyerer, F. Puente León und K.-D. Sommer (Hrsg.), S. 145–157, Universitätsverlag Karlsruhe, Karlsruhe, 2006.
33. K. Kroschel. *Statistische Informationstechnik*. Springer, Heidelberg Berlin, 2004.
34. J. Beyerer. *Verfahren zur quantitativen statistischen Bewertung von Zusatzwissen in der Meßtechnik*. VDI Verlag, Düsseldorf, 1999.
35. J. Beyerer, J. Sander und S. Werling. Fusion heterogener Informationsquellen. In: *Informationsfusion in der Mess- und Sensortechnik*, J. Beyerer, F. Puente León und K.-D. Sommer (Hrsg.), S. 21–37, Universitätsverlag Karlsruhe, Karlsruhe, 2006.
36. K. Dietmayer. Evidenztheorie: Ein Vergleich zwischen Bayes- und Dempster-Shafer-Methoden. In: *Informationsfusion in der Mess- und Sensortechnik*, J. Beyerer, F. Puente León und K.-D. Sommer (Hrsg.), S. 39–49, Universitätsverlag Karlsruhe, Karlsruhe, 2006.
37. G. J. Klir und B. Yuan. *Fuzzy sets and fuzzy logic: theory and applications*. Prentice-Hall, Upper Saddle River, NJ, 1995.
38. X. E. Gros. *NDT Data Fusion*. Arnold, London, 1997.
39. F. Rügheimer, D. Nauck und R. Kruse. Informationsfusion in Neuro-Fuzzy-Systemen. In: *Informationsfusion in der Mess- und Sensortechnik*, J. Beyerer, F. Puente León und K.-D. Sommer (Hrsg.), S. 113–125, Universitätsverlag Karlsruhe, Karlsruhe, 2006.
40. J. Pearl. *Probabilistic Reasoning in Intelligent Systems*. Morgan Kaufmann, San Francisco, 1988.
41. H. Ruser. Ultraschall-Mikrowellen-Sensorsystem mit diversitär-redundanter Auswertung der Phasensignale. *Technisches Messen*, 71(3):184–191, 2004.
42. H. Ruser. *Ultraschall-Mikrowellen-Sensorsystem zur Geschwindigkeits- und Abstandsmessung mit diversitär-redundanter Auswertung der Phasensignale*. Dissertation, Universität der Bundeswehr, München, 2003.
43. J. Beyerer und F. Puente León. Bildoptimierung durch kontrolliertes Aktives Sehen und Bildfusion. *Automatisierungstechnik*, 53(10):493–502, 2005.
44. J. Beyerer und F. Puente León. Suppression of inhomogeneities in images of textured surfaces. *Optical Engineering*, 36(1):85–93, 1997.
45. R. C. Luo, C.-C. Yih und K. L. Su. Multisensor fusion and integration: approaches, applications and future research directions. *IEEE Sensors Journal*, 2(2), 2002.
46. H. Ruser. Mehrfachauswertung von Sensorsignalen am Beispiel eines Gefahrenmelders für automatische Fenster. In: *13. ITG/GMA Fachtagung „Sensorik und Messsysteme“*, Freiburg, 2006.
47. F. Cremer, K. Schutte, J. G. M. Schavemaker und E. den Breejen. A comparison of decision-level sensor-fusion methods for anti-personnel landmine detection. *Information Fusion*, 2(3):187–208, 2001.
48. G. Shayer, O. Cohen, E. Korach und Y. Edan. Ranking sensors using an adaptive fuzzy logic algorithm. *IEEE Sensors Journal*, 5(1):59–67, 2005.

49. D. Brunn, F. Sawo und U. D. Hanebeck. Informationsfusion für verteilte Systeme. In: *Informationsfusion in der Mess- und Sensortechnik*, J. Beyerer, F. Puente León und K.-D. Sommer (Hrsg.), S. 63–78, Universitätsverlag Karlsruhe, Karlsruhe, 2006.



# Fusion heterogener Informationsquellen

Jürgen Beyerer<sup>1,2</sup>, Jennifer Sander<sup>2</sup> und Stefan Werling<sup>2</sup>

<sup>1</sup> Fraunhofer IITB Institut Informations- und Datenverarbeitung,  
Fraunhoferstraße 1, D-76131 Karlsruhe

<sup>2</sup> Universität Karlsruhe (TH), Lehrstuhl für Interaktive Echtzeitsysteme,  
Adenauerring 4, D-76131 Karlsruhe

**Zusammenfassung.** Bei der Fusion heterogener Informationsquellen (Signale, Daten, Vorwissen...) muss deren unterschiedlicher Abstraktionsgrad und deren unterschiedliche Natur (Formalisierung) überwunden werden. Essentielle Forderungen an eine Fusionsmethodik sind die Fähigkeiten zur Transformation, Fusion und Fokussierung. Transformation bezeichnet die verlustarme Überführung auf eine einheitliche mathematische Beschreibungsebene. Dort bedarf es Mechanismen, die transformierte Information zusammenzuführen (Fusion) und sich anschließend auf speziell Interessierendes konzentrieren zu können (Fokussierung). Die Bayessche Wahrscheinlichkeitstheorie in einer *Degree-of-Belief*-Deutung erfüllt jede dieser Forderungen. Transformation gelingt über das Maximum-Entropie-Prinzip, wobei die ursprüngliche Information als Nebenbedingung bei der Optimierung aufgefasst wird. Die Fusion leistet das Bayessche Theorem, und die Fokussierung entspricht der Marginalisierung. Ein Nachteil der Bayesschen Methodik ist ihr hoher Rechenaufwand. Um diesen entscheidend zu verringern, wird ein lokaler Bayesscher Fusionsansatz vorgestellt, der in Anlehnung an kriminalistische Ermittlungen mit einer agentenbasierten Fusionsarchitektur umgesetzt werden kann. An Beispielen wird auch gezeigt, wie die Bayessche Methodik problemlos mit qualitativen Attributen und quantitativen Größen gemischt umgehen kann.

## 1 Einleitung

Unter Informationsfusion versteht man das Zusammenführen, Überlagern und Nutzen der Informationsbeiträge mehrerer Informationsquellen im Hinblick auf eine gegebene Aufgabenstellung. Der Begriff *Information* steht dabei für alles, das potentiell zur Verminderung der vorhandenen Ungewißheit beitragen kann. Information kann in unterschiedlichen Formalisierungen und Abstraktionsniveaus vorliegen. Repräsentationsformen von Information sind u. a. Vorwissen, Daten, Signale, Merkmale, Entscheidungen oder die Aussagen menschlicher Beobachter. Ein Maß für Information ist die durch ihr Hinzukommen beseitigte Ungewißheit. Für die Informationsfusion nützliche Information ist vollständig spezifiziert durch Angabe von Fakten, der zugehörigen Unsicherheiten sowie einer Beschreibung der Abhängigkeiten zwischen den Informationsbeiträgen der einzelnen Quellen.

Ziel der Informationsfusion ist die förderliche Kombination der für sich allein nicht ausreichend informativen Beiträge der einzelnen Quellen, um so sicheres oder neues Wissen zu erhalten. So kann z. B. die Fusion der Beobachtungen der Sensoren eines Sensornetzwerkes zur Verringerung der Messunsicherheit, zur Erhöhung des Detektionsbereiches oder zur Verminderung des Ausfallrisikos dienen. Durch Fusion der Aussagen mehrerer menschlicher Beobachter können Fakten ergänzt und die durch bewusste oder unbewusste Falschaussagen resultierende Gefahr eines falschen Ergebnisses gemindert werden.

Ein besonderes Potential liegt in der Fusion heterogener Informationsquellen, da diese oft unterschiedliche Stärken und Schwächen haben und sich dadurch gegenseitig ergänzen. Zusätzlich setzt die Lösung der meisten anwendungsbezogenen Aufgaben in unterschiedlichen wissenschaftlichen Disziplinen die effiziente Ausnutzung und Kombination einer großen Menge heterogener Informationsquellen voraus. Als Beispiel seien hier die militärische oder zivile Aufklärung, die automatische Sichtprüfung sowie die kognitive Robotik erwähnt.

## 2 Anforderungen an eine Fusionsmethodik

Basisanforderungen an eine Fusionsmethodik, die technische Systeme in die Lage versetzt, heterogene Informationen zu fusionieren, sind ihre Fähigkeiten zur


- Transformation,
- Fusion und
- Fokussierung.

Die Fähigkeit zur Transformation bedeutet, dass die Fusionsmethodik unterschiedlich stark abstrahierte und formalisierte Informationsbeiträge möglichst unverfälscht in eine einheitliche mathematische Beschreibung umsetzen kann. Dazu muss ein gegebener Informationsbeitrag, je nach seinem Abstraktionsgrad relativ zur angestrebten mathematischen Beschreibung,

- artefaktarm spezialisiert,
- fehlerarm gewandelt (bei konstantem Abstraktionsniveau) oder
- verlustarm abstrahiert werden; siehe Abbildung 1.

Dabei kann es technisch vorteilhaft sein, Gruppen strukturell ähnlicher Informationsbeiträge zunächst auf geeigneten Zwischenniveaus zusammenzuführen und so die Transformation auf die final verwendete mathematische Beschreibung zur Fusion und Fokussierung schrittweise durchzuführen. In Abbildung 1 werden z. B. zunächst die Bilddaten (IMINT) auf niedrigem Abstraktionsniveau zu höherwertigen Bildern fusioniert, um dann weiter zu abstrahieren als Vorbereitung zur Fusion mit Informationsbeiträgen aus Quellen anderer Natur, z. B. mit Funksignalen (SIGINT). Wünschenswert ist des Weiteren eine möglichst zwanglose simultane Handhabung unterschiedlich skaliertes Größen<sup>3</sup>. Die Transformation

<sup>3</sup> Man unterscheidet vier hierarchisch aufeinander aufbauende Skalenniveaus: Nominalskalierte „Größen“ weisen keine natürliche Reihenfolge auf. Ordinalskalierte Grö-



**Abb. 1.** Das Zusammenwirken von Transformation und Fusion am Beispiel militärischer Aufklärung. IMINT: *Image Intelligence* (Bilddaten), SIGINT: *Signal Intelligence* (z. B. Information aus Funksignalen), ACINT: *Acoustic Intelligence* (akustische Information), HUMINT: *Human Intelligence* (Information von Menschen).

der Informationsbeiträge heterogener Quellen homogenisiert diese in einer Weise, dass sie nachher mathematisch kompatibel, weil einheitlich beschrieben sind.

Nun müssen Methoden verfügbar sein, durch die die transformierten Informationsbeiträge der verschiedenen Quellen verschmolzen werden. Dies ist die Fähigkeit zur Fusion.

Die daraus resultierende umfassende Informationsverkörperung der Gesamtaufgabe muss fokussierbar sein, d. h. sie muss auf spezielle Einzelfragestellungen konzentriert werden können.

Diese drei essentiellen Forderungen an eine Fusionsmethodik sind nötig für ein qualitativ hochwertiges, differenziertes und aufgabenspezifisches Fusionsresultat mit minimaler Restunsicherheit. Weitere wünschenswerte Eigenschaften einer praktikablen Fusionsmethodik sind: Durchschaubarkeit, modulare Erweiterbarkeit sowie die Möglichkeit, sie den verfügbaren Ressourcen optimal anzupassen.

Als methodische Ansätze kommen insbesondere die Bayessche Wahrscheinlichkeitstheorie, die Fuzzy-Theorie sowie die Evidenztheorie von Dempster-Shafer in Betracht. Grundsätzlich sollte die Entscheidung für eine bestimmte Methodik von den Erfordernissen einer gegebenen Aufgabenstellung abhängig gemacht werden. Verzichtet man aber auf eine Differenzierung von Unsicherheiten hinsichtlich ihrer Ursachen und Natur (Messunsicherheit, Unbestimmtheit, Un-

---

ßen haben eine Rangordnung. Die Intervallskala bietet zusätzlich noch die Möglichkeit, die Abstände zwischen den einzelnen Ausprägungen zu quantifizieren. Bei der Verhältnisskala gibt es außerdem noch einen absoluten Nullpunkt, so dass Quotienten (Verhältnisse) gebildet werden können.

gewissheit...), was für die meisten realen Aufgabenstellungen einen sinnvollen pragmatischen Standpunkt darstellt, so ist die Bayessche Wahrscheinlichkeitstheorie eine hinreichend mächtige Plattform für die mathematische Beschreibung und Durchführung der Fusion. Vorteile dieser Theorie sind ihr schlankes und elegantes Kalkül, ihr hoher Reifegrad und ihre Verbreitung, ihre Anschaulichkeit, aber auch die Intuition, die der Nutzer für Wahrscheinlichkeitsbegriffe, auch wenn diese nicht immer im klassischen Sinne zu deuten sind, i. d. R. mitbringt.

### 3 Die Bayessche Fusionsmethodik

#### 3.1 Formulierung der Fusionsaufgabe

Der erste Schritt vor der Durchführung der eigentlichen Fusionsaufgabe besteht in der Festlegung des Fensters des Interesses  $z$ , das den Bezugsrahmen in zeitlicher, räumlicher und thematischer Hinsicht schafft: Durch den Vektor

$$z := (z_1, \dots, z_N) \in Z := Z_1 \times \dots \times Z_N$$

werden jene Parameter des nicht direkt beobachtbaren „*state of the nature*“ festgelegt, die abhängig von der gegebenen Aufgabenstellung auszuwerten sind. In praktischen Anwendungen werden die Komponenten von  $z$  unterschiedliche Skalierungen aufweisen, so dass nur zulässige informationserhaltende Transformationen angewandt werden dürfen.

Bezeichnet weiter  $d_s$  den von der Quelle Nummer  $s$  gelieferten Informationsbeitrag, so lässt sich durch den Vektor

$$d := (d_1, \dots, d_s) \quad \text{mit} \quad D := D_1 \times \dots \times D_S$$

die gesamte von den Quellen gelieferte Information zusammenfassen.

In der Bayesschen Methodik findet die in der klassischen Statistik übliche Unterscheidung zwischen deterministischen und zufallsbehafteten Größen nicht statt. Alle relevanten Größen werden formal als Zufallsvariablen aufgefasst und mit einer gemeinsamen Wahrscheinlichkeitsverteilung (WV)  $P(z, d)$  beschrieben, was den Bayesschen Kalkül im Vergleich zur klassischen Interpretation symmetriert. Für eine sinnvolle Fusion ist es natürlich notwendig, dass alle zu nutzenden Quellen sich auf dasselbe Geschehen beziehen, also derselbe „*state of the nature*“ zugrundeliegt und mithin die Verteilung  $P(z, d)$  existiert.

Zur Charakterisierung von WV werden im diskreten<sup>4</sup> Fall Wahrscheinlichkeitsfunktionen und Wahrscheinlichkeitsdichtefunktionen im kontinuierlichen Fall gewählt.

---

<sup>4</sup> Eine intervall- oder verhältnisskalierte Variable heißt diskret, wenn sie höchstens abzählbar unendlich viele Werte annehmen kann. Ansonsten heißt sie kontinuierlich. Nominal- und ordinalskalierte „Größen“ sind i. d. R. diskret.

### 3.2 *Degree-of-Belief-Interpretation von Wahrscheinlichkeiten*

Grundlage der Wahrscheinlichkeitstheorie sind die drei Kolmogorovschen Axiome. Diese definieren Wahrscheinlichkeit nur formal, legen gewissermaßen die Syntax fest. Sie deuten Wahrscheinlichkeiten nicht und lassen den semantischen Aspekt offen. Mit dem Kolmogorovschen Axiomensystem sind unterschiedliche Interpretationen (Deutungen) verträglich. Die beiden wichtigsten sind die u. a. in der klassischen Statistik übliche frequentistische Interpretation, bei der Wahrscheinlichkeiten als Grenzwerte relativer Häufigkeiten aufgefasst werden, sowie die allgemeinere *Degree-of-Belief-Deutung* (DoB), die in der Bayesschen Theorie verwendet wird.

Bei letzterer repräsentiert die Wahrscheinlichkeit eines Ereignisses den Grad an Gewissheit bezüglich dessen Eintreten unter Berücksichtigung der gegebenen Fakten und Annahmen. Wahrscheinlichkeit hat in der DoB-Deutung stets bedingten Charakter, sie ist abhängig vom aktuellen Informationsstand. Als Konsequenz wird sich eine Zunahme an Information in einer Konzentration der korrespondierenden DoB-Verteilung widerspiegeln.

Im Allgemeinen hängt der DoB von der definierenden Person ab, da das subjektive Vertrauen verschiedener Individuen in das Eintreten ein und desselben Ereignisses auch bei Vorliegen gleicher Information unterschiedlich stark sein wird. Wahrscheinlichkeit wird so zum subjektiven Ausdruck für den Grad des Dafürhaltens.

DoB-Verteilungen lassen sich aber auch anhand objektiver Mechanismen aus gegebenen Fakten ableiten. Ein Beispiel ist das Prinzip der Maximalen Entropie (ME); siehe Abschnitt 3.3. Mit solchen Prinzipien kommen dann auch unterschiedliche Individuen bei gleichen Fakten zu gleichen DoB-Verteilungen.

Im Folgenden wird Wahrscheinlichkeit grundsätzlich als DoB aufgefasst, der soweit wie möglich mit objektiven Verfahren eruiert wird.

### 3.3 Transformation

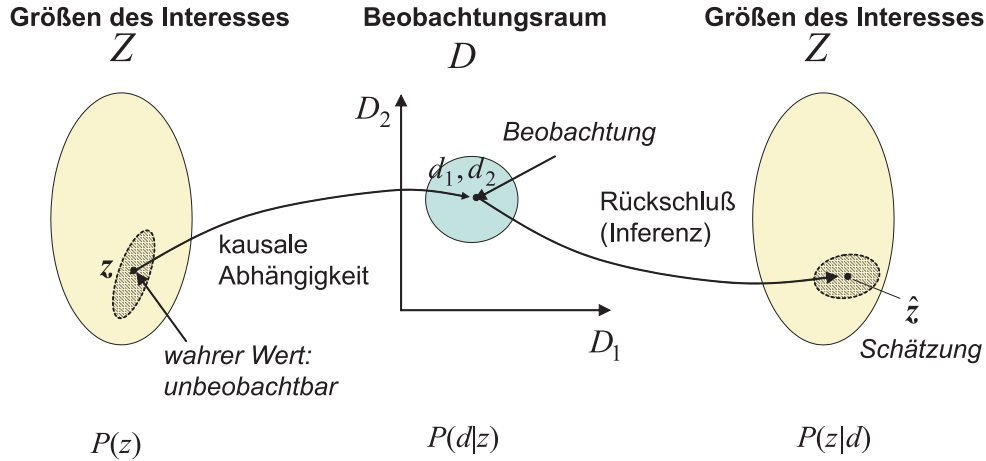
Ein zentrales Element der Bayesschen Fusionsmethodik ist die Transformation gegebener Fakten in eine DoB-Verteilung, die dieses Wissen — oder komplementär dazu das damit verbundene Nichtwissen — in objektiver Weise repräsentiert.

Ein einfacher aber theoretisch gut begründeter Mechanismus zur artefaktarmen Transformation ist das ME-Prinzip [9, 10]. Dabei wird die DoB-Verteilung mit maximaler Shannonscher Entropie — unter Betrachtung der gegebenen Fakten als Nebenbedingung — berechnet:

$$P_{\text{ME}}(x) = \arg \max_{P(x) \in \Pi} \{ \mathbf{E}\{-\log P(x)\} \} ,$$

$$\Pi := \{ P(x) \mid (P(x) \text{ ist eine WV}) \wedge (P(x) \text{ ist mit den Fakten verträglich}) \} .$$

Die Entropie ist ein Maß für die Unsicherheit bezüglich der Zufallsvariablen  $x$ . Somit verringern nur die gegebenen Fakten die Unsicherheit bezüglich  $x$  und mit hin werden diese ohne ungewollte implizite Einbeziehung artefaktischer Fakten in



**Abb. 2.** Fusion der Informationsbeiträge zweier Quellen und des durch  $P(z)$  verkörperten A-priori-Wissens durch Schätzung der zugrundeliegenden Ursache  $z$ .

eine DoB-Verteilung transformiert. Die Transformation mittels des ME-Prinzips entspricht einer Spezialisierung.

Wird als Faktum z. B. ein beschränkter Wertebereich für  $x$  vorgegeben, was äquivalent zu einem beschränkten Träger  $X = \text{supp}\{P(x)\}$  ist, resultiert als ME-Verteilung eine Gleichverteilung auf  $X$ . Sind die Fakten z. B. ein quantitativer Wert  $\xi$  und eine zugehörige Unsicherheit  $\sigma_\xi$ , die als Erwartungswert und Standardabweichung interpretiert werden können, ist die ME-Verteilung eine Normalverteilung  $N(\xi, \sigma_\xi^2)$ .

Für den wichtigen Fall von Fakten in Form von Erwartungswerten

$$\mathbf{E}\{k_l(x)\} = \kappa_l, \quad l = 1, \dots, L, \quad (1)$$

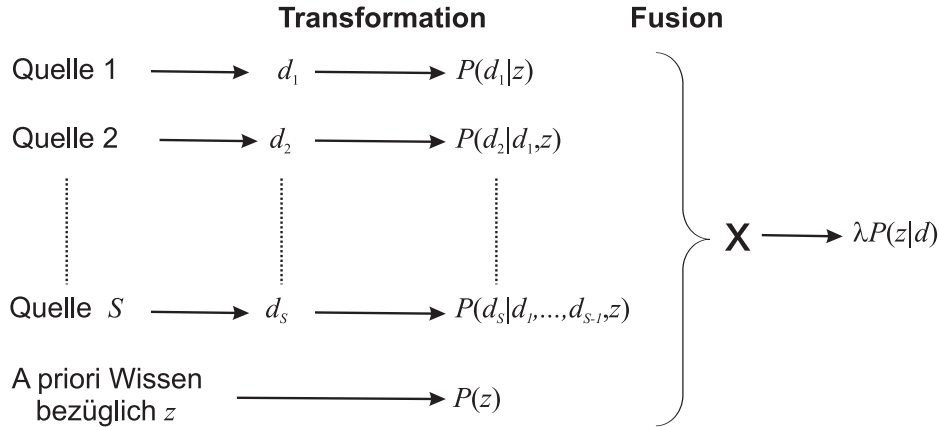
erhält man die geschlossene Lösung

$$P_{\text{ME}}(x) = \lambda_0 \exp \left\{ \sum_{l=1}^L \lambda_l k_l(x) \right\},$$

wobei die Konstanten  $\lambda_l$  anhand der Nebenbedingungen Gl. (1) zu bestimmen sind.

### 3.4 Fusion

Sind die Informationsbeiträge aller Quellen in DoB-Verteilungen transformiert, muss die eigentliche Fusion folgen. Das leistet die Bayessche Formel. Seien der Einfachheit halber zwei Informationsquellen gegeben. Die erste liefert die Beobachtung  $d_1$ , die zweite  $d_2$ . Gegeben dem „state of the nature“  $z$  seien diese durch die DoB-Verteilungen  $P(d_1|z)$  bzw.  $P(d_2|z)$  beschrieben. Eine verlustfreie — im Sinne von: kein Shannonscher Informationsverlust — Inferenz bezüglich



**Abb. 3.** Fusion im Bayesschen Kontext.

$z$  liefert als Endergebnis die A-posteriori-DoB-Verteilung  $P(z|d_1, d_2)$  [15]; siehe Abbildung 2.

Hierfür gilt:

$$\begin{aligned}
 P(z|d_1, d_2) &\propto P(d_1, d_2|z)P(z) = P(d_1|d_2, z)P(d_2|z)P(z) \\
 &\stackrel{(A)}{=} P(d_1|z)P(d_2|z)P(z), \tag{2}
 \end{aligned}$$


wobei die Gleichheit (A) dann gilt, wenn  $d_1$  von  $d_2$  unabhängig ist, falls die gemeinsame Ursache  $z$  festgehalten wird. Das ist praktisch oft der Fall, wenn  $d_1$  und  $d_2$  z. B. von unterschiedlichen Sensorprinzipien geliefert werden und die den beiden Kanälen überlagerten Störungen unabhängig sind.

Laut Gl. (2) geschieht die Fusion im Bayesschen Kontext also im Wesentlichen durch die Multiplikation der beiden Likelihoodfunktionen mit der A-priori-Verteilung  $P(z)$ . Genaugenommen werden in diesem Beispiel sogar drei Quellen fusioniert, sieht man das A-priori-Wissen ebenfalls als solche an.

### 3.5 Fokussierung durch Marginalisierung

In der A-posteriori-DoB-Verteilung  $P(z|d)$  sind die Informationsbeiträge aller Quellen zusammengeführt und liefern vereint den DoB bezüglich der Größen des Interesses  $z_1, \dots, z_N$ . Für die Beantwortung spezieller Fragen einer Aufgabenstellung muss die gesamthafte Aussage der DoB-Verteilung i. d. R. weiter verdichtet werden, was aber im Shannonschen Sinne mit einem Informationsverlust einhergeht.

Beschreiben beispielsweise in einer konkreten Problemstellung  $z_1, z_2$  und  $z_3$  den Ort,  $z_4$  die Zeit,  $z_5, z_6$  und  $z_7$  die Orientierung und  $z_8$  den Typ eines Fahrzeuges, und geht es darum, Fahrzeuge zu detektieren und vornehmlich Aufenthaltsort und -zeit zu bestimmen, ist eine Fokussierung auf  $z_1, z_2, z_3$  und  $z_4$  sinnvoll. Orientierung  $z_5, z_6, z_7$  und Typ  $z_8$  spielen dann die Rollen sogenannter



**Abb. 4.** Beispiel für eine A-posteriori-Verteilung mit einer diskreten und einer stetigen Komponente, wobei  $z_1$  metrisch und  $z_2$  nominal skaliert ist. Die Marginalverteilungen ergeben sich durch Projektion auf die Koordinatenachsen.

„*Nuisance*“-Parameter, die aus der A-posteriori-DoB-Verteilung herausintegriert bzw. -summiert werden:

$$P(z_1, \dots, z_4 | d) = \int_{z_5 \in Z_5} \int_{z_6 \in Z_6} \int_{z_7 \in Z_7} \sum_{z_8 \in Z_8} P(z_1, \dots, z_8 | d) dz_5 dz_6 dz_7.$$

Diese Marginalisierung führt zu einer Reduzierung der Dimensionalität des Problems und erlaubt die gewünschte Fokussierung im Rahmen der Bayesschen Methodik.

Einen zweiten Mechanismus zur Fokussierung ist die Bildung von A-posteriori-Erwartungswerten einer problemspezifischen Funktion  $f(z)$  auf  $Z$

$$\mathbf{E}\{f(z)\} = \int \sum f(z) P(z | d) dz, \quad (3)$$

wobei über die diskreten Komponenten von  $z$  summiert und über die kontinuierlichen integriert wird. Hängt  $f(z)$  nicht von allen Komponenten von  $z$  ab, impliziert Gl. (3) auch eine Marginalisierung.

Damit ist gezeigt, dass die Bayessche Methodik für jede der drei Forderungen nach Transformation, Fusion und Fokussierung geeignete Mechanismen zur Verfügung stellt. Abbildung (4) illustriert nebenbei, dass der Bayessche Formalismus simultan auch ganz zwanglos mit kontinuierlichen und diskreten Größen und unterschiedlichen Skalenniveaus umgehen kann.

## 4 Ein lokaler Ansatz zur Bayesschen Fusion

### 4.1 Die wesentliche Herausforderung

Bei praktisch relevanten Aufgaben kann die Dimension  $N$  des Raumes  $Z$  der interessierenden Größen recht groß sein. Trotz aller sonstigen Vorteile des Bayesschen Formalismus wächst seine Komplexität aber leider exponentiell mit  $N$ . So



wäre in Gl. (3) z. B. eine  $N$ -dimensionale Summation/Integration durchzuführen mit einem Aufwand  $O(\prod_{i=1}^N |Z_i|)$ , der auch bei moderatem  $N$  i. d. R. nicht tragbar ist. Problematisch ist dabei insbesondere, dass die bisher angestrebten Überlegungen sich auf den ganzen Raum  $Z$  beziehen, also globalen Charakter haben.

Ein in [1] vorgestellter Ansatz löst dieses Problem durch Einnahme eines lokalen Standpunktes, mit dem Ziel, Bayessche Inferenz und Fusion nur dort lokal in  $Z$  vorzunehmen, wo sich auch tatsächlich Aufgabenrelevantes abspielt. Dabei wird eine Analogie zur kriminalistischen Ermittlung hergestellt, also zu einem ausgereiften, funktionierenden Prozess der realen Welt. Charakteristisch an diesem Prozess sind die heterogenen Informationsquellen und die lokale Sichtweise einzelner Ermittler. Das inspirierte zu einer agentenbasierten Fusionsarchitektur, in der sogenannte Fusionsagenten (*Fuselets*) Spuren und Hypothesen lokal verfolgen und weiterentwickeln.

## 4.2 Ein Blick über den Tellerrand: Kriminalistische Ermittlungen

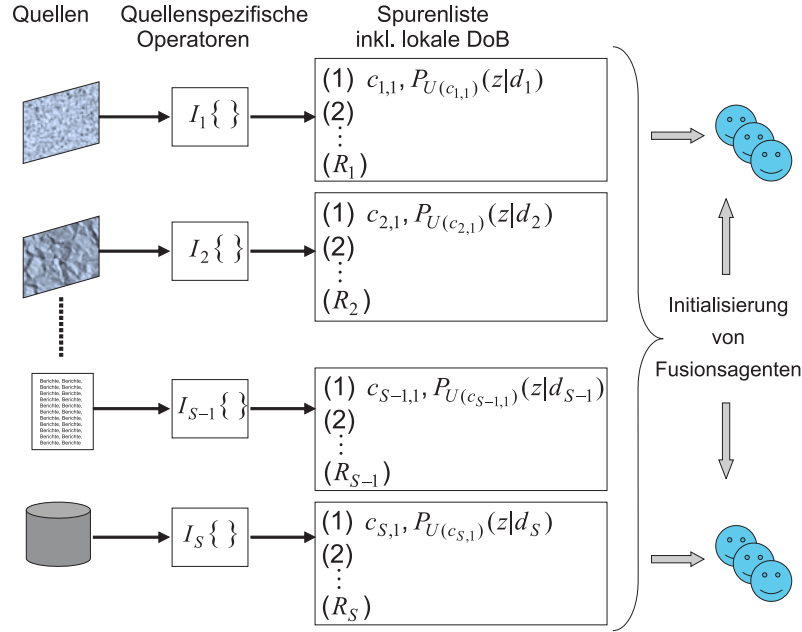
In einem kleinen Exkurs soll ein vereinfachter Blick auf kriminalistische Ermittlungen geworfen und die für die Fusion relevanten Vorgehensweisen aufgezeigt werden.

Am Anfang steht ein Sachverhalt, dessen Ursachen aufzuklären sind. Vorhandene Spuren — Indizien, Hinweise usw. — werden Ermittlern übertragen, die diese verfolgen, daraus Hypothesen generieren und diese Hypothesen anhand der weiteren Ermittlungen zu erhärten oder zu verwerfen versuchen. Im Erfolgsfall wird der Grad des Dafürhaltens einzelner Hypothesen so groß, dass man sie als bewiesen betrachtet. Entlang der Untersuchung wird ein Ermittler mit heterogenen Informationen konfrontiert: Zeugenaussagen, Fingerabdrücke, Reifenspuren, DNA-Spuren usw., die er in einen Zusammenhang bringen, also gewissermaßen fusionieren muss. Für viele dieser Evidenzen ist der Ermittler kein Experte, so dass er Sachverständige konsultiert, die ihm konkrete Spuren auswerten und ihm ein für ihn verständliches Resultat zurückliefern, das dann seinen DoB beeinflusst. Ermittler kommunizieren miteinander, um ihre Wissensstände abzugleichen und ihre beschränkten Sichten zu einem Ganzen zu verschmelzen. Am Ende des Ermittlungsprozesses sollten dann finale Hypothesen stehen sowie eine Bewertung ( $\hat{=}$  DoB), wie sicher man sich dabei ist.

Charakteristisch ist die lokale Sicht der einzelnen Ermittler. Sie haben keinen „*God's view*“ auf den ganzen Raum des Interesses, sondern sehen zunächst nur die Spuren und den sie lokal einbettenden Kontext.

## 4.3 Agentenbasierte Architektur zur Fusion heterogener Informationsquellen

In Analogie zu kriminalistischen Ermittlungen sollen Softwareagenten — sogenannte Fusionsagenten (FA) — für die Fusion heterogener Quellen eingesetzt werden.



**Abb. 5.** Initialisierungsphase. Quellenspezifische Operatoren liefern Spuren, die Fusionsagenten zugewiesen werden.

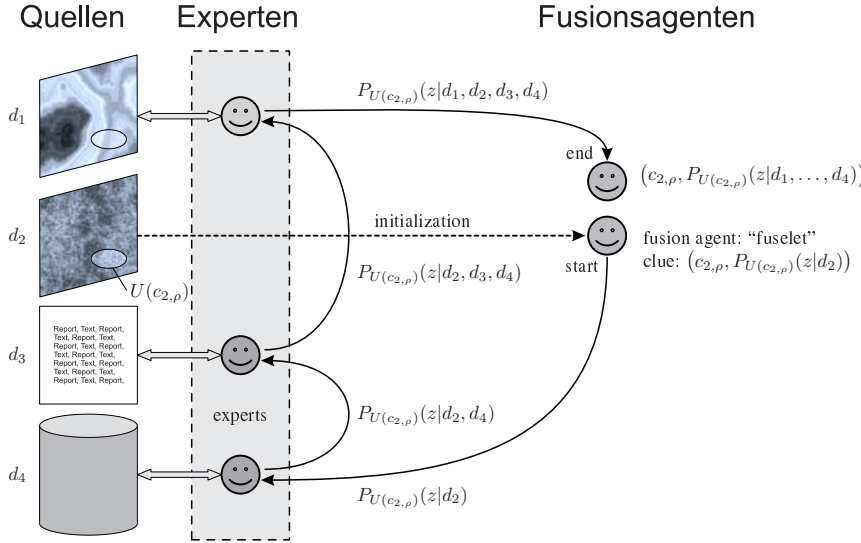
Für die verfügbaren Quellen, die alle einen Bezug zum gleichen zugrundeliegenden Sachverhalt haben, werden in einer Initialisierung Spuren (englisch: *clues*) gewonnen, die dann als zu prüfende Hypothesen FA übergeben werden. Die FA suchen dann sequentiell die verbleibenden Quellen auf und trachten danach, den DoB ihrer Spuren dort zu erhärten oder zu entkräften. Nach dem Besuch aller Quellen kann über die Annahme der Hypothesen anhand ihrer finalen DoB entschieden werden

Wesentlich dabei ist, dass jede Spur  $c \in Z$  lokal nur in einer kleinen Umgebung  $U(c) \in Z$ ,  $|U| \ll |Z|$  im Fenster des Interesses betrachtet wird und die Fusion nur lokal in  $U(c)$  stattfindet. Das senkt den Aufwand von  $O(|Z|)$  auf  $O(C|U|)$ , wobei  $C$  die Zahl der Spuren ist.

**Initialisierung** Im Hinblick auf eine gegebene Aufgabenstellung und unter Berücksichtigung von  $Z$  und  $P(z)$  wird auf jede der Quellen ein quellenspezifischer Operator  $I_s\{\}$ ,  $s = 1, \dots, S$  zur Erzeugung lokaler Auffälligkeiten in  $Z$  angewandt.  $I_s\{\}$  soll dabei optimal auf die Quelle  $s$  abgestimmt sein, so dass er bei isolierter Betrachtung von  $d_s$  das bestmögliche Detektionsergebnis für lokale Auffälligkeiten hervorbringt. Er verkörpert somit die vorhandene Expertise zur Auswertung der Quelle  $s$  alleine.

Besteht die Fusionsaufgabe beispielsweise darin, Fahrzeuge zu finden und zu klassifizieren, und ist  $d_s$  ein Luftbild, so sollte der Operator  $I_s\{\}$  ein Resultat  $i(z|d_s) = I_s\{d_s\}$  über

$$Z^s = [x_{\min}, x_{\max}] \times [y_{\min}, y_{\max}] \times \{\text{relevante Fahrzeugtypen}\} \subseteq Z$$



**Abb. 6.** Jede Spur wird von einem FA verfolgt. Dargestellt ist hier der für die Spur  $c_{2,\rho}$  zuständige FA. Die Ellipsen in  $d_1$  und  $d_2$  illustrieren die Umgebung  $U$  der Spur  $c_{2,\rho}$  in Bezug auf zwei Komponenten von  $z$ ; in diesem Beispiel sind es zwei Ortskoordinaten.

liefern, das lokale Maxima für vorhandene Fahrzeuge haben soll. Ausgeprägte lokale Maxima und deren Argumente  $z = c_{s,r} \in Z^s$

$$\{c_{s,r}\} := \arg_{z \in Z^s} \{\text{signifikante lokale Maxima von } i(z|d_s)\}$$

werden in einer Spurenliste gesammelt und nach Signifikanz geordnet. Formal wird jede Spur durch das Paar

$$(c_{s,r}, P_{U(c_{s,r})}(z|d_s))$$

repräsentiert, wobei  $P_{U(c_{s,r})}(z|d_s)$ : lokale DoB-Verteilung; berechnet durch lokale Normierung von  $i(z|d_s)$ ,

$$r \in \{1, \dots, R_s\}, \quad s \in \{1, \dots, S\},$$

$R_s$  : Zahl signifikanter Spuren in  $d_s$ ,

$$C = \sum_{s=1}^S R_s : \text{Gesamtzahl der Spuren aller Quellen.}$$

Für jede Spur wird ein FA instantiiert; siehe Abbildung 5.

**Lokale DoB-Verteilungen** Die entscheidende Idee zur Minderung der Komplexität der Bayesschen Fusion ist, jedes  $c_{s,r} \in Z$ , das im Hinblick auf die gestellte Aufgabe hinreichend auffällig ist, lokal innerhalb einer Umgebung  $U(c_{s,r}) \subset Z$  zu beschreiben, die ausreichend groß sein muss, um darin Bayessche Fusion<sup>5</sup> betreiben zu können.

<sup>5</sup> Letztendlich ist jede praktisch implementierte Bayessche Inferenz in gewissem Sinne lokal, da das zugrundegelegte  $Z$  als echte Teilmenge einer umfassenderen Menge

$U(c_{s,r})$  dient als Träger für die DoB-Verteilung  $P_{U(c_{s,r})}(z|d_s)$ . Für intervall- und verhältnisskalierte Größen kann  $U(c)$  z. B. einfach durch eine  $\epsilon$ -Umgebung in Bezug auf eine Norm  $\|\cdot\|$  definiert werden:

$$U(c) := \{z \mid \|z - c\| < \epsilon\}.$$

Bei qualitativen „Größen“ ergibt ein solches Konzept von Nachbarschaft allenfalls für ordinal skalierte Größen einen gewissen Sinn. Für nominal skalierte „Größen“ kann Lokalität jedoch nicht auf einem Abstandsbegriff begründet werden.

Lokalität bedarf im nominalen Fall einer speziell angepassten Definition, die am Beispiel einer einkomponentigen Eigenschaft  $z$  erläutert wird.

Sei  $Z^* \subset Z$  die Teilmenge von Elementen aus  $Z$ , deren DoB einen bestimmten Mindestwert überschreiten. Eine Art Lokalität kann nun eingeführt werden, indem man nur für die  $z \in Z^*$  detaillierte DoB ausweist und einen pauschalen DoB für  $Z \setminus Z^*$ :

$$P_{U(c)}(z|d) := \begin{cases} P(z|d), & z \in Z^* \\ P(Z \setminus Z^*|d) = 1 - \sum_{\zeta \in Z^*} P(\zeta|d), & z \notin Z^* \end{cases} \quad (4)$$

Ein Beispiel soll diese Idee illustrieren: Sei die Aufgabe, Automobile in einem Luftbild  $= d_s$  zu klassifizieren. Ein „lokales“ Ergebnis könnte dann z. B. so aussehen:

$$\begin{aligned} P(z = \text{VW\_Golf}|d_s) &= 0,8, \\ P(z = \text{Ford\_Focus}|d_s) &= 0,15, \\ P(z = \text{anderer\_Typ}|d_s) &= 0,05. \end{aligned}$$

Anstatt für sicherlich mehrere tausend Fahrzeugtypen eine detaillierte Verteilung anzugeben, werden nur drei Werte zur Beschreibung des DoB für die nominale Eigenschaft „Typ“ kommuniziert. Lokalität meint hier, nur für eine grobe Partition von  $Z$  eine DoB-Verteilung zu spezifizieren.

Das Konzept lokaler DoB-Verteilungen bietet neben der unmittelbaren Komplexitätsminderung der Bayesschen Inferenz von  $O(|Z|)$  auf  $O(C|U)$  einen weiteren Vorteil. Während bei globaler Betrachtung die A-posteriori-DoB-Verteilung auf  $Z$  i. d. R. eine komplizierte multimodale Gestalt haben wird, ist die Struktur lokaler DoB-Verteilungen um einzelne Auffälligkeiten herum einfacher und kann mit simpleren Verteilungsmodellen beschrieben werden.

**Lokale Fusion** Nachdem jeder Spur ein FA zugewiesen wurde, besuchen die FA in Bezug auf ihre Spuren bisher nicht berücksichtigte Quellen, um ihre lokalen DoB-Verteilungen weiterzuentwickeln; siehe Abbildung 6. Falls ein FA nicht

---

$\hat{Z} \supset Z$  so konstruiert werden kann, dass beim Übergang von  $\hat{Z}$  auf  $Z$  ein lokaler Standpunkt eingenommen wird. Auf die Spitze getrieben führt das auf die Frage, welche Mindestgröße Umgebungen  $U(c) \subset Z$  haben müssen, um darin noch nutzbringend im Bayesschen Sinne fusionieren zu können.

selbst fähig ist, auf eine Quelle  $s$  zuzugreifen bzw. deren Daten auszuwerten, konsultiert er einen Experten-Agenten ( $\hat{=}$  Sachverständigen), dem er die bis dahin entwickelte Spur übergibt.

Der Experte fasst die ihm überlassene lokale DoB-Verteilung als A-priori-Verteilung auf, die er anhand der ihm vorliegenden Daten  $d_s$  mittels der Bayes'schen Formel in eine lokale A-posteriori-DoB-Verteilung überführt und so lokale Fusion vollzieht. Danach gibt der Experte die Spur an den FA zurück, der dann die nächste Quelle aufsucht.

Zu den Aufgaben der FA gehört die Verwaltung seiner Spur, das Aufsuchen der verfügbaren Quellen aber auch gelegentlich mit anderen FA zu kommunizieren, um herauszufinden, ob Spuren anderer FA nicht das gleiche reale Objekt oder Ereignis zugrundeliegt, so dass schließlich überflüssige FA eliminiert werden können. Dieser Fall tritt ein, wenn für reale Objekte oder Ereignisse mehrere Quellen initial signifikante Spuren liefern. Andererseits muss bei der Initialisierung zunächst für jede signifikante Spur ein FA instantiiert werden, um Objekte und Ereignisse nicht zu verpassen, für die nur eine Quelle initial signifikante Spuren liefert.

Sobald ein FA alle Quellen besucht hat, liefert er seine nunmehr elaborierte Spur einer „Jury“ ab, die dann in der Zusammenschau aller Spuren und der damit einhergehenden Hypothesen über deren globale Signifikanz entscheiden kann.

**Diskussion** Das Konzept der FA hat eine intrinsische Skalierbarkeit. Anhand zur Verfügung stehender Ressourcen kann über die Zahl  $A \leq C$  der zu instanziierten FA entschieden werden, so dass zumindest die wichtigsten Spuren (heiße Spuren) verfolgt werden können.

Ein Vorteil des Ansatzes ist auch die Möglichkeit, die Experten teilweise technisch auszuführen und teilweise durch Menschen zu besetzen. Insbesondere wenn für einen Teil der Quellen bisher keine ausreichend leistungsfähigen Auswerteautomatismen existieren und man auf den Verstand und die kognitiven Fähigkeiten des Menschen angewiesen ist, sind solche Mensch-Maschine-Teams sinnvoll. Mit fortschreitender Entwicklung können dann solche Teams durch Hinzufügen neuer softwarebasierter Experten erweitert und durch Substitution der menschlichen Experten weiter automatisiert werden.

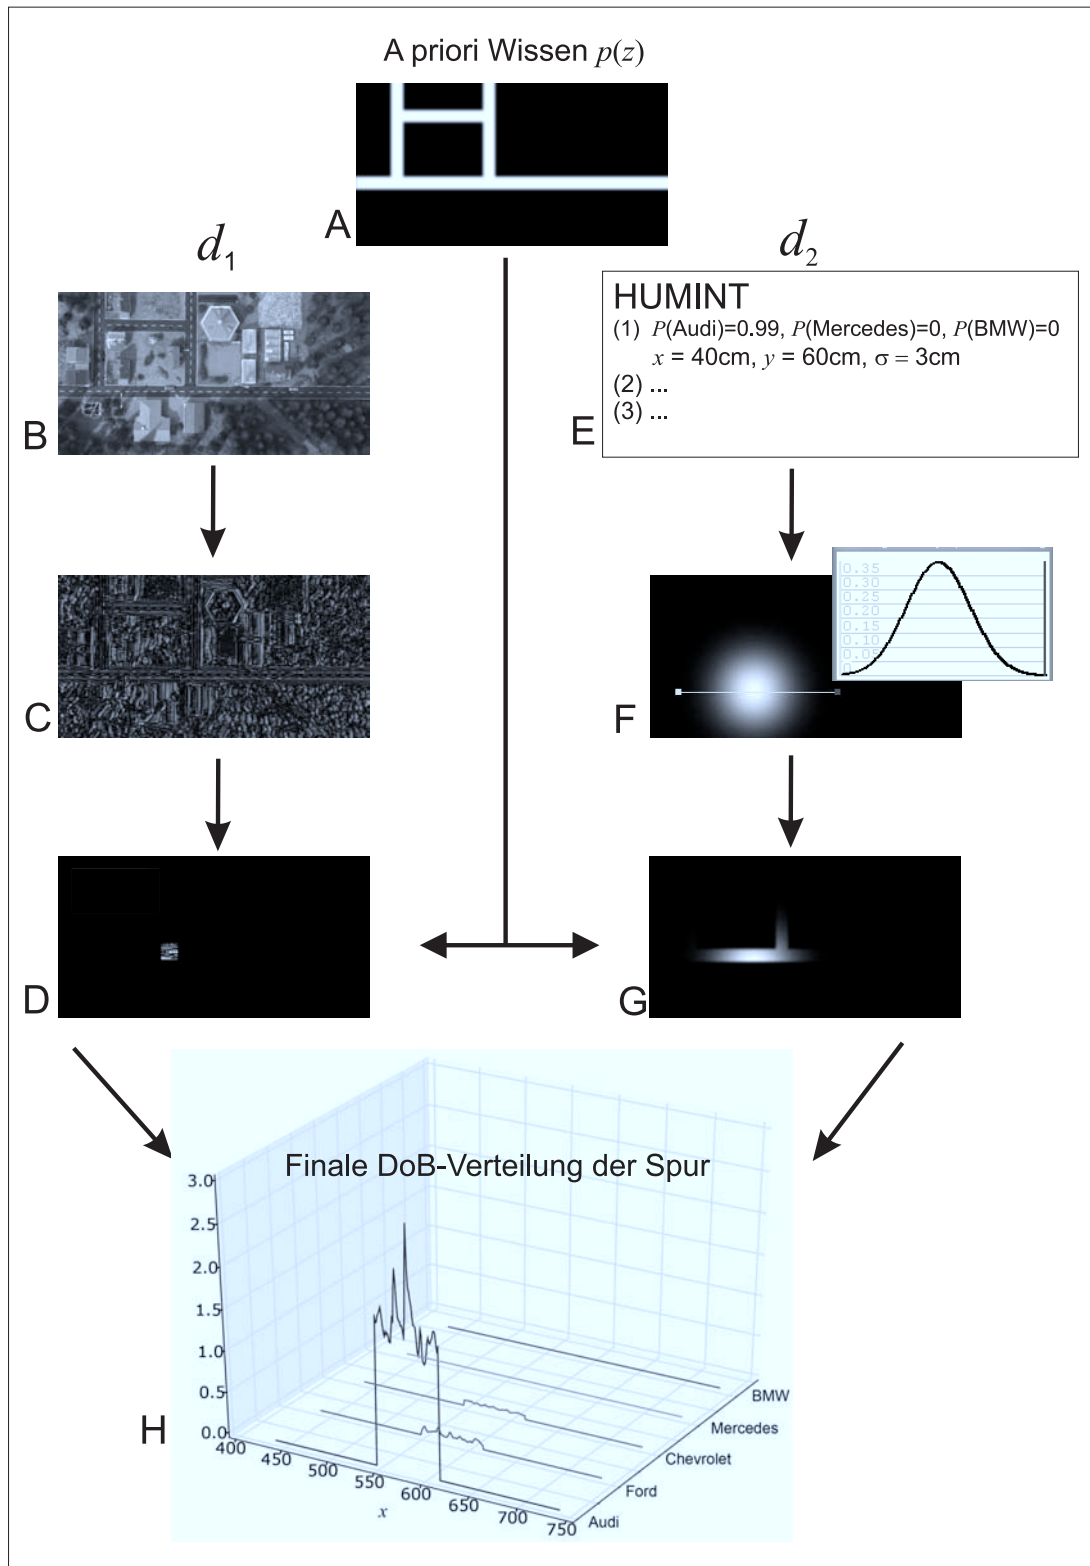
Unmittelbar leuchtet auch ein, dass das gezeigte Konzept für Fusionsaufgaben in großen Netzwerken mit verteilten Informationsquellen prädestiniert ist.

#### 4.4 Beispiel

Durch die Fusion von A-priori-Wissen, HUMINT- und IMINT-Information sollen aus einer vorgegebenen Szene Position und Typ der dort vorhandenen Fahrzeuge bestimmt werden; siehe Abbildung 7.

Der Raum des Interesses ist gegeben durch

$$Z = [x_{\min} = 0\text{cm}, x_{\max} = 94\text{cm}] \times [y_{\min} = 0\text{cm}, y_{\max} = 50,3\text{cm}] \\ \times \{\text{Fahrzeugtypen}\}.$$



**Abb. 7.** Das hier gezeigte illustrative Beispiel verwendet eine IMINT- und eine HUMINT-Quelle sowie eine Karte als A-priori-Wissen. Bei dem Beispiel handelt es sich um ein Landschaftsmodell im Maßstab 1:160. Der nominale Peak befindet sich bei “Audi”, was auch den Tatsachen entspricht. Das für “BMW” und “Mercedes” die DoB-Verteilung Null ist, liegt an der Einschätzung des menschlichen Beobachters, der die beiden Typen vollständig ausschloss.

Die Menge der möglichen Fahrzeugtypen wurde dabei der Übersichtlichkeit halber auf die fünf Typen: Ford, Audi, Chevrolet, BMW und Mercedes eingeschränkt.

Die Kenntnis einer a priori vorliegenden Straßenkarte der Szene ist in der vorliegenden Aufgabenstellung äquivalent zur Kenntnis der Menge

$$S = \{(x, y) | ((x, y) \text{ ist Punkt der Szene}) \wedge ((x, y) \text{ ist Punkt einer Straße})\},$$

durch die die Punkte der Szene, die auf einer der Straßen liegen und demzufolge die einzig möglichen Fahrzeugpositionen darstellen, spezifiziert werden. Die ME A-priori-DoB-Verteilung  $P_{\text{ME}(S)}$  ist die Gleichverteilung  $P_{\text{GV}(S)}$  auf  $S$ . Geht man nun außerdem von einer Messunsicherheit der Größe  $\sigma_\xi$  für jeden Punkt  $(x, y)$  in der Straßenkarte aus, so ist die ME A-priori-Verteilung  $P_{\text{ME}(S, \sigma_\xi)}$ , die zusätzlich noch dieses Faktum berücksichtigt, näherungsweise die Faltung der Gleichverteilung auf  $S$  mit der zweidimensionalen Normalverteilung  $N(0, I\sigma_\xi^2)$ . Dies kann man sich für jeden Punkt  $x$  wie folgt veranschaulichen (vgl. Abschnitt 3.3):

$$\begin{aligned} P_{\text{ME}(S, \sigma_\xi)}(x, y) &= P_{\text{ME}(S, \sigma_\xi)}((x - \xi) + \xi, (y - \eta) + \eta) \\ &\approx P_{\text{ME}(\sigma_\xi)}(x - \xi, y - \eta) * P_{\text{ME}(S)}(\xi, \eta) \\ &= N(0, I\sigma_\xi^2) * P_{\text{GV}(S)}(\xi, \eta) \\ &= \int \int_{(\xi, \eta) \in S} N((x - \xi, y - \eta), I\sigma_\xi^2) d\xi d\eta. \end{aligned}$$

Abbildung 7(A) zeigt die so resultierende ME A-priori-Verteilung für  $\sigma_\xi = 0,5 \text{ cm}$ .

Quelle  $s = 1$  liefert ein Grauwertbild  $d_1$ ; siehe Abbildung 7(B). Die von Quelle  $s = 2$  gelieferte Information ist die verbale Beschreibung der Szene (HUMINT) im Hinblick auf die Detektion und Klassifikation von Fahrzeugen.

Zur Erzeugung von  $i(z|d_1)$  wird eine an die gesuchten Fahrzeugtypen angepasste Matched-Filter-Bank verwendet. Die HUMINT-Information wird als Fakten und Messunsicherheiten in Bezug auf den Ort und mit einer Verteilung gemäß Gl. (4) im Bezug auf den Typ festgelegt. Für die beiden Ortskoordinaten resultiert als ME-Verteilung eine Gaußverteilung.

Das Ergebnis Abbildung 7(H) zeigt die bezüglich  $y$  marginalisierte DoB-Verteilung als Fusionsresultat für die in Abbildung 7(D) gezeigte Spur. Das Ergebnis zeigt, dass die lokale Bayessche Fusion brauchbare Ergebnisse bei erheblich verringertem Rechenaufwand liefert. Nebenbei erkennt man hier, dass die beiden Quellen sich ergänzende Informationen liefern. So bestimmt  $d_1$  im Wesentlichen den Ort des Fahrzeugs,  $d_2$  dominiert die Schätzung des Typs.

## 5 Zusammenfassung und Ausblick

An eine Methodik für die Fusion heterogener Informationsquellen wurden die drei Basisanforderungen nach Transformation, Fusion und Fokussierung gestellt.

Die Bayessche Wahrscheinlichkeitstheorie mit einer *Degree-of-Belief*-Deutung des Wahrscheinlichkeitsbegriffes erfüllt diese alle. Allerdings wächst der Rechenaufwand der Bayesschen Methodik exponentiell mit der Zahl der interessierenden Größen und Eigenschaften.

Zur Bewältigung dieses Problems wird ein lokales Bayessches Fusionsverfahren eingeführt, das sich an kriminalistische Ermittlungen anlehnt, wo zu verfolgende Spuren zunächst auch nur in einem lokalen Kontext im Raum der interessierenden Größen eingebettet betrachtet werden können. Aufgrund seiner Struktur lässt sich der Ansatz mit einer agentenorientierten Architektur zwanglos umsetzen, bei der die Fusionsagenten signifikante Spuren zugewiesen bekommen und der Fusionsprozess lokal durch Besuch der verfügbaren Quellen sequentiell erfolgt.

Zukünftige Forschungsaktivitäten werden sich der minimalen Größe von Umgebungen widmen, so dass eine lokale Bayessche Fusion noch sinnvolle Ergebnisse liefert. Wichtig ist auch die Frage nach dem Umgang mit unterschiedlichen Quellen, deren statistische Abhängigkeit a priori nicht bekannt ist. Für die Beschreibung der lokalen DoB-Verteilungen soll untersucht werden, inwieweit das Konzept der konjugierten A-priori-Verteilungen umgesetzt werden kann; im Erfolgsfalle könnte die lokale Fusion dann vereinfacht anhand algebraischer Verknüpfungen von Verteilungsparametern durchgeführt werden.

Während in diesem Aufsatz von a priori bekannten Quellen ausgegangen wurde, liegt eine explorative Verallgemeinerung nahe, die Fusionsagenten auch nach unbekanntem, für die Fusion relevanten Quellen suchen zu lassen, den Fusionsagenten also auch Recherche- und Data-Mining-Aufgaben zu übertragen.

## Literatur

1. J. Beyerer, M. Heizmann und J. Sander. Fuselets – An agent based architecture for fusion of information of heterogeneous information and data. In: *Multisensor, Multisource Information Fusion: Architectures, Algorithms, and Applications 2006*, Belur V. Dasarathy (Hrsg.), Proceedings of SPIE 6242, 2006.
2. J. O. Berger. *Statistical Decision Theory and Bayesian Analysis*. Springer, 1985.
3. J. M. Bernardo. Bayesian Statistics. In: *Encyclopedia of Life Support Systems, Probability and Statistics*. [www.uv.es/~bernardo/teaching.html](http://www.uv.es/~bernardo/teaching.html), UNESCO, Oxford, 2003.
4. J. M. Bernardo und A. Smith. *Bayesian Theory*. Wiley, New York, 1994.
5. M. Berthold und D. J. Hand. *Intelligent Data Analysis*. Springer, 2003.
6. P. Billingsley. *Probability and Measure*, 3. edition. Wiley, New York, 1995.
7. Bley Müller, Gehlert und Gülicher. *Statistik für Wirtschaftswissenschaftler*. Verlag Franz Vahlen, München, 1988.
8. J. D. Hey. *Data in Doubt – An Introduction to Bayesian Statistical Inference for Economists*. Oxford, Martin Robertson, 1983.
9. E. T. Jaynes. Information Theory and Statistical Mechanics. *Phys. Rev., Part I*, 106:620–630, *Part II*, 108:171–191, 1957.
10. E. T. Jaynes. Prior Probabilities. *IEEE Transactions on Systems, Science, and Cybernetics*, 4(3):227–241, 1968.



11. J. N. Kapur. *Maximum Entropy Models in Science and Engineering*. John Wiley and Sons, New York, 1993.
12. C. P. Robert. *The Bayesian Choice*. Springer, 1994.
13. S. J. Russell und P. Norvig. *Artificial Intelligence: A Modern Approach*. Prentice Hall, 2003.
14. P. N. Tan, M. Steinbach und V. Kumar. *Introduction to Data Mining*. Addison-Wesley, 2006.
15. G. Winkler. *Stochastische Systeme – Analyse und Synthese*. Wiesbaden, Akademische Verlagsgesellschaft, 1977.



# Evidenztheorie: Ein Vergleich zwischen Bayes- und Dempster-Shafer-Methoden

Klaus Dietmayer

Universität Ulm, Abteilung Mess-, Regel- und Mikrotechnik,  
Albert-Einstein-Allee 41, D-89081 Ulm

**Zusammenfassung.** Zur Klassifikation beobachtbarer Systemeigenschaften aufgrund fehlerbehafteter Einzelmessungen werden aufgrund der fundierten theoretischen Grundlage gerne probabilistische Methoden eingesetzt. Bei der Theorie von Bayes ist die Existenz von Einzelhypothesen vorausgesetzt, denen jeweils eine Alternativhypothese gegenübergestellt wird. Aufgrund der Messungen erfolgt mit gewisser Wahrscheinlichkeit eine Entscheidung für oder gegen die Hypothese. Die Dempster-Shafer-Theorie erweitert diese Sichtweise, indem sie auch Unwissenheit über die Entscheidung zulässt. Sie unterscheidet somit zwischen der Sensorinformation selbst und deren Glaubwürdigkeit. Hierdurch wird es möglich, auch einfache wenig diskriminierende Sensoren einzusetzen, die nicht zwischen Einzelhypothesen sondern nur Kombinationen hiervon differenzieren können. Diese Eigenschaft ist insbesondere bei komplexen Klassifikationsproblemen von Vorteil, wenn zusätzlich kostengünstige Sensoren eingesetzt werden sollen.

## 1 Einleitung

In vielen Messaufgaben müssen aufgrund fehlerbehafteter und unsicherer Messungen Entscheidungen über die Eigenschaft oder den Zustand des beobachteten Systems getroffen werden. Ein Beispiel hierfür ist die Fahrzeugumfelderfassung für neuartige aktive Sicherheitssysteme im Fahrzeug, bei der basierend auf bordautonomer Sensorik andere Verkehrsteilnehmer erkannt und dynamisch modelliert werden sollen. Aufgrund der Komplexität der Aufgabe sind hierzu in der Regel mehrere verschiedenartige Sensoren erforderlich, die komplementäre, redundante aber auch konträre Informationen liefern. Es müssen somit unterschiedliche Merkmale aus verschiedenen Sensorquellen mit in der Regel auch unterschiedlicher Zuverlässigkeit fusioniert werden. Gesucht ist letztendlich die Wahrscheinlichkeit der Zugehörigkeit der vermessenen Objekte zu den in Betracht gezogenen Klassen von möglichen Verkehrsteilnehmern wie Fußgänger, Radfahrer, Pkw oder Lkw. Aber auch die Wahrscheinlichkeit der Nichtzugehörigkeit zu einer Klasse und die Unsicherheit der Aussagen selbst sind wesentliche Ergebnisse. Man spricht in diesem Zusammenhang auch von Evidenz für das Klassifikationsergebnis.

Da alle Messsysteme unzuverlässige Ergebnisse liefern, ist unter der Voraussetzung der Dominanz aleatorischer Fehlerursachen die Anwendung von Metho-

den der Wahrscheinlichkeitstheorie zur Datenfusion naheliegend. In der klassischen Wahrscheinlichkeitsrechnung nach Bayes wird das Vorliegen einer Wahrscheinlichkeit von  $x\%$  für eine Klasse gleichzeitig mit der Wahrscheinlichkeit  $100\% - x\%$  gegen diese Klasse bewertet. Dies ist bei Mehrklassenproblemen im allgemeinen Fall nicht mehr logisch. Zudem muss auch der Praxis Rechnung getragen werden, dass unterschiedliche Sensorquellen Ergebnisse unterschiedlicher Zuverlässigkeit und Glaubwürdigkeit liefern. Auch vage Kenntnisse sollten in den Fusionsprozess einfach einfließen können.

Die Evidenztheorie von Dempster und Shafer [1, 2] erweitert daher die Theorie von Bayes in der Art, dass sie auch einen Unsicherheitsbereich modelliert, in dem keine Aussage für oder gegen eine Klassenzugehörigkeit möglich ist. Es wird somit im Gegensatz zu Bayes Unwissenheit explizit modelliert. Man spricht daher strenggenommen nicht mehr von Wahrscheinlichkeiten sondern von Evidenzen. Eine Evidenz kann somit als eine Erweiterung der klassischen Wahrscheinlichkeit betrachtet werden, wobei statt einem eindimensionalen ein zweidimensionales Maß verwendet wird, welches sich zusammensetzt aus dem Grad des Vertrauens darin, dass die Aussage einer Sensorquelle zutrifft und der Plausibilität der Aussage. Der Schwerpunkt dieses Beitrages liegt in der Vorstellung dieser Dempster-Shafer-Theorie für Datenfusionsaufgaben, die als Erweiterung der Bayes-Theorie angesehen werden kann. Ein konkretes Anwendungsszenario ist in [3] in diesem Band enthalten. Die Darstellung erfolgt daher hier anhand einfacher akademischer Beispiele.

## 2 Einführendes Beispiel

Das folgende einfache Beispiel der Auswertung von Wettervorhersagen soll zunächst die grundsätzlich unterschiedliche Denkweise der beiden Ansätze anschaulich aufzeigen. Die formelle Darstellung der Dempster-Shafer-Theorie findet sich im daran anschließenden Abschnitt.

In diesem einführenden Beispiel sei angenommen, dass der offizielle Wetterbericht für morgen schönes Wetter voraussagt. Diese Aussage basiert schon auf der Verdichtung und Auswertung zahlreicher Einzelmessungen, die hier aber nicht weiter betrachtet werden soll. Der Wetterbericht weise erfahrungsgemäß eine Zuverlässigkeit von  $80\%$  auf. Folglich kann man mit einer Wahrscheinlichkeit von  $80\%$  annehmen, dass morgen tatsächlich schönes Wetter sein wird. Unter Verwendung der klassischen Wahrscheinlichkeitsrechnung würde man nun weiter folgern, dass mit einer Wahrscheinlichkeit von  $20\%$  das Wetter morgen nicht schön sein wird. Dies ist aber nicht logisch, denn für die restlichen  $20\%$  ist alles offen. Das Wetter kann sowohl schön als auch schlecht sein. Es gibt keinen Hinweis darauf, dass das Wetter morgen schlecht sein wird.

In diesem Punkt unterscheidet sich die Theorie von Dempster-Shafer von der klassischen Wahrscheinlichkeitslehre: Da in  $80\%$  der Fälle die Prognose des Wetterberichts mit Sicherheit zutreffend ist, ist sie es in  $20\%$  nicht mit Sicherheit. Das heißt aber, dass die Aussage des Wetterberichts in  $20\%$  aller Fälle entweder falsch oder richtig sein kann. Die  $20\%$  werden deshalb bei Dempster-Shafer

**Tabelle 1.** Berechnung der Evidenzen bei redundanter Information der zwei Quellen.

	Wetterbericht zuverlässig (80%)	Wetterbericht unzuverlässig (20%)
Frosch zuverlässig (60%)	Wetter schön: $80\% \cdot 60\% = 48\%$	Wetter schön: $20\% \cdot 60\% = 12\%$
Frosch unzuverlässig (40%)	Wetter schön: $80\% \cdot 40\% = 32\%$	Wetter unbestimmt: $40\% \cdot 20\% = 8\%$

**Tabelle 2.** Berechnung der Evidenzen bei konträren Informationen der zwei Quellen.

	Wetterbericht zuverlässig (80%)	Wetterbericht unzuverlässig (20%)
Frosch zuverlässig (60%)	Unmöglich: $80\% \cdot 60\% = 48\%$	Wetter nicht schön: $20\% \cdot 60\% = 12\%$
Frosch unzuverlässig (40%)	Wetter schön: $80\% \cdot 40\% = 32\%$	Wetter unbestimmt: $40\% \cdot 20\% = 8\%$

nicht dem Komplement der Hypothese (schönes Wetter) sondern der Menge aller möglichen Hypothesen zugesprochen. Anhand des Wetterberichts liegt somit die Wahrscheinlichkeit für schönes Wetter gemäß Dempster-Shafer-Theorie tatsächlich im Bereich zwischen 80% bis 100% (Plausibilitätsbereich). Aufgrund des Wetterberichtes ist zu 80% schönes Wetter sicher (Vertrauensbereich) und zu 20% ist das Wetter unbestimmt (Unsicherheitsbereich). Das Vertrauen für schlechtes Wetter liegt bei 0%, da hierfür keine unterstützende Information vorliegt.

## 2.1 Kombination von Evidenzen

Bei realen Aufgaben hat man es in der Regel mit mehreren Sensorquellen zu tun. Das einführende Beispiel sei daher in der Form erweitert, dass zusätzlich zum Wetterbericht eine weitere Sensorquelle, nämlich ein Wetterfrosch, existiere. Dieser Wetterfrosch sei allerdings nur zu 60% zuverlässig. Zunächst wird der Fall betrachtet, dass beide Quellen schönes Wetter voraussagen. Tabelle 1 zeigt, wie diese Quellen miteinander verrechnet werden und welche Evidenzen sich kombiniert ergeben.

Bei drei der vier resultierenden Kombinationen wird die Hypothese „schönes Wetter“ bestätigt. Das Vertrauen darin, dass tatsächlich schönes Wetter ist, berechnet sich als Summe der drei unterstützenden Kombinationen zu 92%. Die Aussage ist somit durch die zweite Quelle sicherer geworden. Mit 8% kann keine Aussage über die Hypothese erfolgen. Es ist sowohl plausibel, dass zu 8% schlechtes oder schönes Wetter ist. Das Vertrauen für schlechtes Wetter liegt weiter bei 0%, da hierfür keine unterstützende Evidenz vorhanden ist.

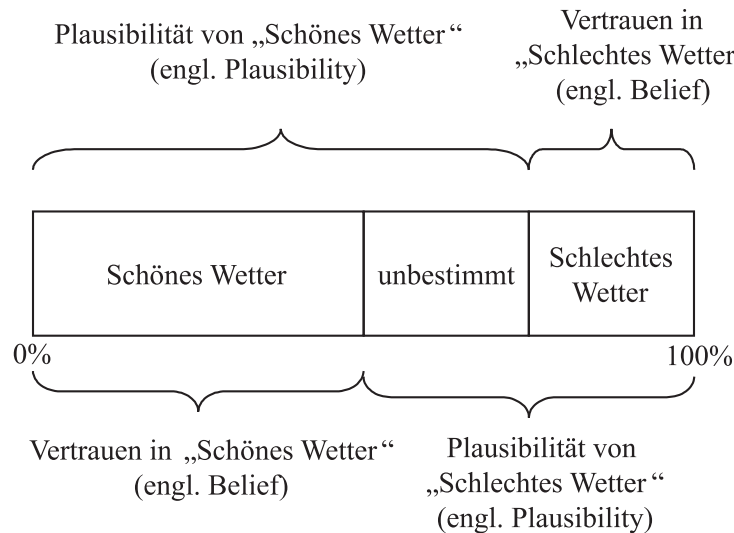
Sagt der Wetterfrosch aber im Gegensatz zum Wetterbericht schlechtes Wetter vorher, so ergibt sich die in Tabelle 2 dargestellte Situation.

**Tabelle 3.** Reskalierung der möglichen Fälle bei konträren Informationen.

	Wetterbericht zuverlässig (80%)	Wetterbericht unzuverlässig (20%)
Frosch zuverlässig (60%)		Wetter nicht schön: ca. 23%
Frosch unzuverlässig (40%)	Wetter schön: ca. 62%	Wetter unbestimmt: ca. 15%

Die Variante, dass beide Quellen Recht haben, ist jetzt natürlich unmöglich. Um mit konträren Aussagen umzugehen, werden nach der Dempster-Shafer-Theorie alle möglichen Fälle so reskaliert, dass die Summe der Wahrscheinlichkeiten aller möglichen Fälle wieder 1 ergibt. Mit anderen Worten, die Summe der Werte für eine mögliche Hypothese bzw. Klasse werden durch die Summe aller möglichen Hypothesen bzw. Klassen dividiert. Für das betrachtete Beispiel ergibt sich Tabelle 3.

Als Ergebnis kann man somit zu 62% darauf vertrauen, dass das Wetter morgen schön ist. Mit einem Vertrauen von 23% muss man mit schlechtem Wetter rechnen. Zu 15% ist das Wetter unbestimmt. Abbildung 1 verdeutlicht die Zusammenhänge.



**Abb. 1.** Aufteilung des Wahrscheinlichkeitsraums in Vertrauens- und Plausibilitätsbereich bei konträren Informationen. Die Begriffe „Plausibilität“ und „Vertrauen“ werden in Abschnitt 3 definiert.

Wie dieses einfache Beispiel aufzeigen sollte, liegt der wesentliche Unterschied in der Denkweise darin, dass bei Dempster-Shafer die Glaubwürdigkeit der Informationen entkoppelt von den Messergebnissen betrachtet wird, während sie bei

der Bayes-Theorie implizit verkoppelt ist. Hierdurch wird es möglich, auch vages Wissen unterschiedlicher Glaubwürdigkeit, beispielsweise aufgrund preiswerter und damit nicht so exakter und zuverlässiger Sensoren, einzusetzen.

### 3 Dempster-Shafer-Theorie

Im folgenden Abschnitt sollen nun die Dempster-Shafer-Theorie für den allgemeinen Fall mehrerer konkurrierender Hypothesen bzw. Klassen dargestellt und die zugehörigen Begriffe eingeführt werden.

#### 3.1 Wahrnehmungsrahmen

Der so genannte Wahrnehmungsrahmen  $\Theta$ , in der Dempster-Shafer-Theorie als *frame of discernment* bezeichnet, ist die Menge aller sich gegenseitig ausschließender Hypothesen bzw. Klassen, für die man sich aufgrund der Messungen entscheiden kann. Gl. (1) zeigt einen Wahrnehmungsrahmen mit drei Elementen

$$\Theta = \{A, B, C\}. \quad (1)$$

Diese Menge muss bezüglich der Sensorik vollständig sein, d. h. alle möglichen Hypothesen oder Klassen, die auftreten können, müssen auch enthalten sein. Nimmt man das Beispiel der Wetterbeobachtung wieder auf, so könnte  $A$  Sonnenschein,  $B$  bedeckter Himmel und  $C$  Niederschlag bedeuten.

Die Potenzmenge des Wahrnehmungsrahmens stellt hierarchisch angeordnete Aussageklassen dar, wobei eine grobe Aussageklasse eine Menge von disjunktiv verknüpften feineren Aussagen zusammenfasst. Sie lautet für das Beispiel aus Gl. (1):

$$2^\Theta = \{\emptyset, \{A\}, \{B\}, \{C\}, \{A, B\}, \{A, C\}, \{B, C\}, \Theta\}. \quad (2)$$

Die grobe Klasse  $\{A, B\}$  fasst beispielsweise die beiden feineren Aussagen  $A$  oder  $B$  zusammen. Sie bedeutet, dass aufgrund der Messungen sowohl  $A$  als auch  $B$  zutreffen kann, also in der Nomenklatur unseres Beispiels es entweder sonnig oder bedeckt sein kann.

#### 3.2 Massefunktion

Eine Funktion  $m$

$$m : 2^\Theta \rightarrow [0, 1] \quad (3)$$

heißt Massefunktion (*mass function*), wenn gilt:

$$\begin{aligned} m(\emptyset) &= 0, \\ \sum_{X \in 2^\Theta} m(X) &= 1. \end{aligned} \quad (4)$$

Die Massefunktion gibt damit die Unterstützung für eine Hypothese bzw. Klasse  $X$  aufgrund der Sensorquellen an. Wenn alle unterstützenden Wahrscheinlichkeiten auf die Einzelemente verteilt wurden, erhält  $\Theta$  die übrig gebliebene Wahrscheinlichkeit, das heißt die Differenz der verteilten Wahrscheinlichkeiten zu 1. Diese Restwahrscheinlichkeit repräsentiert damit das Unwissen, da  $\Theta$  gleichbedeutend mit der Aussage ist, jede der Hypothesen bzw. Klassen ist aufgrund der Sensorinformation möglich. Falls ein Sensor somit nicht in der Lage ist, plausible Messergebnisse zu liefern, kann dies durch die Zuweisung  $m(\Theta) = 1$  im Datenfusionsprozess einfach modelliert werden. Diese Belegung bedeutet vollständige Unsicherheit.

Eine Wahrscheinlichkeit gegen eine Aussage wird im Gegensatz zur klassischen Wahrscheinlichkeitsrechnung in der Dempster-Shafer-Theorie nicht als Negativwahrscheinlichkeit sondern als Wahrscheinlichkeit für das Komplement der Aussage aufgefasst. Das Komplement der Aussage  $\{A\}$  ist im Beispiel gemäß Gl. (2) die Menge  $\{B, C\}$ . Jede Sensorquelle erzeugt damit eine individuelle Belegung der Massefunktion, je nach seinen individuellen Messergebnissen und Messmöglichkeiten.

Nimmt man zur Veranschaulichung an, es existieren zwei Wetterberichte. Der eine sagt für den kommenden Tag zu 60% Regen und zu 30% wechselnd bewölkten Himmel mit Aufheiterungen voraus. Dieser Wetterbericht sei zu 90% zuverlässig. Ferner haben wir noch unseren alten Wetterbericht aus dem obigen einführenden Beispiel, der Sonnenschein bei 80% Zuverlässigkeit voraussagt. Für dieses Szenario ergibt sich folgende Belegung der beiden Massefunktionen:

$$\begin{aligned} m_1(\{C\}) &= 0,6, & m_1(\{A, B\}) &= 0,3, & m_1(\{\Theta\}) &= 0,1, \\ m_2(\{A\}) &= 0,8, & m_2(\{\Theta\}) &= 0,2. \end{aligned} \quad (5)$$

### 3.3 Dempsters Kombinationsregel

Zwei Massefunktionen  $m$  lassen sich gemäß der Dempster-Shafer-Kombinationsregel wie folgt zu einer neuen Massefunktion kombinieren:

$$m_1(X) \otimes m_2(X) = \begin{cases} \frac{\sum_{A_i \cap B_j = X} m_1(A_i) \cdot m_2(B_j)}{1 - \sum_{A_i \cap B_j = \emptyset} m_1(A_i) \cdot m_2(B_j)} & \text{für } X \neq \emptyset, A_i \in 2^\Theta, B_j \in 2^\Theta \\ 0 & \text{für } X = \emptyset. \end{cases} \quad (6)$$

Gl. (6) bestimmt damit den Anteil der die Hypothese bzw. die Klasse  $X$  unterstützenden Evidenz, normiert mit der gesamten möglichen Evidenz. Der Nenner in Gl. (6) ist daher ein Normalisierungsfaktor  $1 - k$ , wobei gilt:

$$k = \sum_{A_i \cap B_j = \emptyset} m_1(A_i) \cdot m_2(B_j). \quad (7)$$

Die Variable  $k$  ist damit ein Maß für die Widersprüchlichkeit der betrachteten Quellen und repräsentiert den Anteil der Wahrscheinlichkeit, die dem leeren Set zugeordnet würde. Ist dieser Widerspruch sehr hoch, d. h.  $k \rightarrow 1$ , ergibt diese



**Tabelle 4.** Zusammenstellung der Kombinationen des Beispiels aus Gl. (5) zur Berechnung des Zählers der Kombinationsregel.

	$m_1(\{C\}) = 0,6$	$m_1(\{A, B\}) = 0,3$	$m_1(\{\Theta\}) = 0,1$
$m_2(\{A\}) = 0,8$	$l(\{\emptyset\}) = 0,48$	$l(\{A\}) = 0,24$	$l(\{A\}) = 0,08$
$m_2(\{\Theta\}) = 0,2$	$l(\{C\}) = 0,12$	$l(\{A, B\}) = 0,06$	$l(\{\Theta\}) = 0,02$

Kombinationsregel keine intuitiv sinnvollen Ergebnisse. Für  $k = 1$  ist sie nicht definiert. Dies ist ein deutlicher Nachteil dieses nicht aus Axiomen folgenden Kombinationsansatzes, weshalb er auch nicht unumstritten ist. Der Fall sehr widersprüchlicher Quellen, d. h. eine widersprüchliche Aussage bei gleichzeitig hoher Zuverlässigkeit, muss daher in der Praxis vermieden werden. Er tritt bei zweckmäßiger Wahl des Wahrnehmungsrahmens und geeigneter Sensorik nicht auf.

Der Zähler in Gl. (6),

$$l = \sum_{A_i \cap B_j = X} m_1(A_i) \cdot m_2(B_j), \tag{8}$$

ist ein Maß für die die Hypothese bzw. Klasse  $X$  unterstützenden Evidenzen, in dem alle Elemente der Potenzmenge des Wahrnehmungsrahmens, von denen  $X$  eine Untermenge ist, berücksichtigt und aufsummiert werden. Für das in Gl. (5) dargestellte Beispiel ergeben sich die in Tabelle 4 aufgeführten Resultate.

Hieraus ergibt sich als Normalisierungsfaktor

$$1 - k = 1 - l(\{\emptyset\}) = 0,52. \tag{9}$$

Das normalisierte Endergebnis ist dann wie folgt:

$$\begin{aligned} m(\{\emptyset\}) &= 0 \quad \text{gemäß Definition,} & m(\{A\}) &= \frac{0,24 + 0,08}{0,52} \approx 0,62, \\ m(\{C\}) &= \frac{0,12}{0,52} \approx 0,23, & m(\{A, B\}) &= \frac{0,06}{0,52} \approx 0,11, \\ m(\{\Theta\}) &= \frac{0,02}{0,52} \approx 0,04. \end{aligned} \tag{10}$$

Sollen mehr als zwei Quellen miteinander kombiniert werden, so erfolgt die Berechnung der ersten beiden Quellen gemäß Gl. (6). Die dritte Quelle wird dann analog mit dem Ergebnis der ersten Kombination verrechnet und so fort.

### 3.4 Vertrauensfunktion

Es sei  $m$  eine Massefunktion. Eine Funktion

$$Bel : 2^\Theta \rightarrow [0, 1] \tag{11}$$

**Tabelle 5.** Berechnung der Vertrauens- und Plausibilitätsfunktion des Beispiels aus Gl. (10).

	$Bel$	$Pl$	$Pl - Bel$
$\emptyset$	0	0	0
$\{A\}$	0,62	$0,62 + 0,11 + 0,04 = 0,77$	0,15
$\{B\}$	0	$0,11 + 0,04 = 0,15$	0,15
$\{C\}$	0,23	$0,23 + 0,04 = 0,27$	0,04
$\{A, B\}$	$0,62 + 0,11 = 0,73$	$0,62 + 0,11 + 0,04 = 0,77$	0,04
$\{A, C\}$	$0,62 + 0,23 = 0,85$	$0,62 + 0,11 + 0,23 + 0,04 = 1$	0,15
$\{B, C\}$	0,23	$0,11 + 0,23 + 0,04 = 0,38$	0,15
$\Theta$	$0,62 + 0,23 + 0,11 + 0,04 = 1$	$0,62 + 0,11 + 0,23 + 0,04 = 1$	0

heißt dann Vertrauensfunktion (*belief function*), wenn gilt:

$$Bel(X) = \sum_{A \subseteq X} m(A). \quad (12)$$

Diese Funktion misst damit die gesamte Unterstützung bzw. das Vertrauen in  $X$  durch Addition der  $m$ -Werte aller Teilmengen von  $X$ . Tabelle 5 zeigt die Ergebnisse für das Beispiel aus Gl. (10).

### 3.5 Plausibilitätsfunktion

Es sei  $m$  eine Massefunktion. Eine Funktion

$$Pl : 2^\Theta \rightarrow [0, 1] \quad (13)$$

heißt dann Plausibilitätsfunktion (*plausibility function*), wenn gilt:

$$Pl(X) = \sum_{A \cap X \neq \emptyset} m(A). \quad (14)$$

Die Plausibilitätsfunktion misst damit die gesamte mögliche Unterstützung für  $X$  durch Addition der  $m$ -Werte all derjenigen  $A$ , deren Schnittmenge mit  $X$  nicht leer ist. Tabelle 5 zeigt die Ergebnisse des Beispiels aus Gl. (10).

### 3.6 Interpretation der Zusammenhänge

Mit den angegebenen Definitionen kann bei gegebener Belegung der Massefunktion das Intervall  $[Bel, Pl]$  für jedes  $X$  individuell berechnet werden. Die Intervallbreite ( $Pl - Bel$ ) repräsentiert damit das jeweilige Unwissen (vgl. Tabelle 5). Je breiter dieses Intervall ist, desto weniger vertrauenswürdig ist die Aussage. Das Intervall  $[0, 1]$  steht somit für vollständige Unwissenheit. Je schmaler hingegen das Intervall ist, desto mehr Sicherheit bietet die Aussage. Im Extremfall degeneriert das Intervall zu einem Punkt.

## 4 Wahrscheinlichkeitstheorie nach Bayes

Die Wahrscheinlichkeitstheorie sowie das Bayes-Theorem werden als hinlänglich bekannt vorausgesetzt und sollen hier nur im Kontext der Kombination verschiedener Sensorinformationen kurz diskutiert werden. Detaillierte Ausführungen sind in diversen Textbüchern enthalten (z. B. [6]).

Es sei angenommen, dass ein vollständiger Satz  $n$  sich gegenseitig ausschließender Hypothesen bzw. Klassen  $H_i$  existiert. Jedes Element dieses Satzes kann Ergebnis einer Messung eines Sensors  $E$  sein. Nach dem Bayes-Theorem gilt dann für die Wahrscheinlichkeit einer Hypothese bzw. Klasse  $H_i$  unter Berücksichtigung der Messung:

$$P(H_i|E) = \frac{P(E|H_i) \cdot P(H_i)}{\sum_{k=1}^n P(E|H_k) \cdot P(H_k)}, \quad \text{wobei} \quad \sum_{k=1}^n P(H_k) = 1 \quad (15)$$

mit

$P(H_i|W)$  : A-posteriori-Wahrscheinlichkeit für  $H_i$  bei Eintreffen von  $E$ ,

$P(H_i)$  : A-priori-Wahrscheinlichkeit, dass  $H_i$  wahr ist,

$P(E|H_i)$  : Wahrscheinlichkeit für die Messung  $E$ , wenn  $H_i$  wahr ist.

Für mehrere Sensoren kann Gl. (15) erweitert werden, indem man die unterschiedliche Zuverlässigkeit der Sensoren  $E_i$  mit  $P(E_j|H_i)$  modelliert. Unter dieser Annahme lässt sich Gl. (15) wie folgt generalisieren:

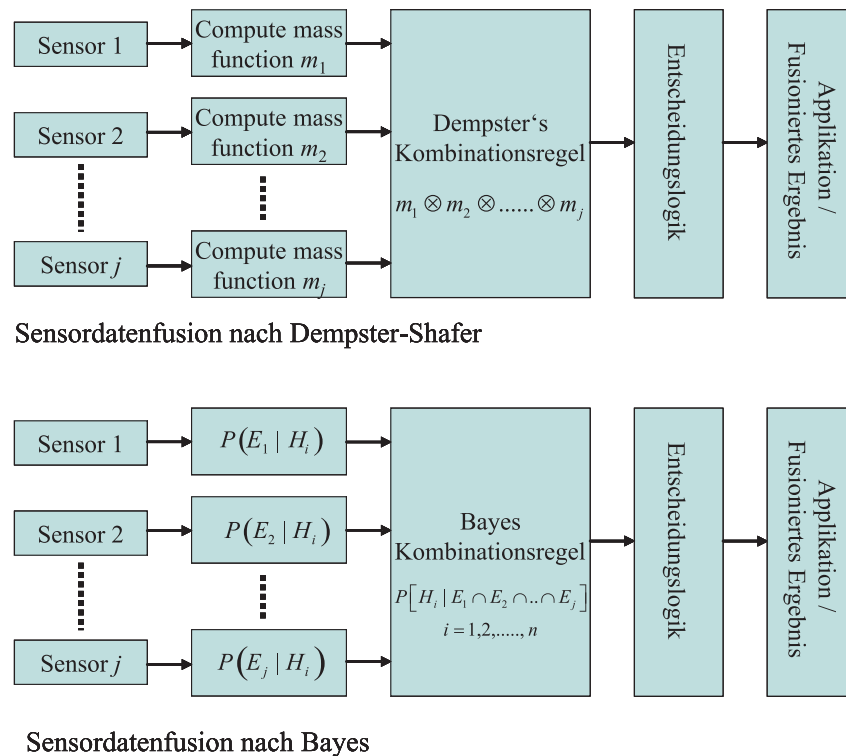
$$P(H_i|E_1 \cap E_2 \cap \dots \cap E_j) = \frac{P(E_1 \cap E_2 \cap \dots \cap E_j|H_i) \cdot P(H_i)}{\sum_{k=1}^n P(E_1 \cap E_2 \cap \dots \cap E_j|H_k) \cdot P(H_k)}. \quad (16)$$

Gl. (16) beschreibt damit eine Verbundwahrscheinlichkeit für die Hypothese bzw. Klasse  $H_i$  unter der Bedingung der Messungen  $E_i$  der beteiligten Sensoren. Gl. (16) lässt sich durch die Annahme statistisch unabhängiger Messungen entsprechend vereinfachen. Zu beachten ist jedoch, dass weiterhin eine A-priori-Wahrscheinlichkeit für die Hypothese bzw. Klasse benötigt wird. Diese kann häufig nur heuristisch gewonnen werden, weshalb die ansonsten sehr fundierte Bayes-Theorie an dieser Stelle für praktische Anwendungen aufgeweicht werden muss.

## 5 Vergleich der Datenfusion mit Dempster-Shafer und Bayes

Im Folgenden sind die wesentlichen Unterschiede der beiden Methoden kurz aufgezeigt. Eine ausführliche Gegenüberstellung findet sich in [7, 8]. Voraussetzung für die Anwendung des Bayes-Theorems ist die Existenz eines Satzes vollständiger und sich gegenseitig ausschließender Einzelhypothesen. Insbesondere müssen wechselseitig Alternativhypothesen zu jeder Einzelhypothese existieren. Setzt

man dies voraus, so führen die Dempster-Shafer-Theorie und das Bayes-Theorem auf dasselbe Ergebnis [5, 7]. In allen anderen Fällen ist das Bayes-Theorem nicht definiert. Diese Lücke wird durch die Dempster-Shafer-Theorie als Erweiterung des Bayes-Theorems geschlossen, indem auch vage Informationen, beispielsweise die Bestätigung mehrerer Basishypothesen durch einen einzigen Sensor, sinnvoll eingebracht werden kann. Wechselseitige eindeutige Alternativhypothesen müssen nicht existieren.



**Abb. 2.** Struktur der Sensordatenfusion nach Bayes und nach Dempster-Shafer.

Ein weiterer Nachteil der Bayes-Theorie ist die Notwendigkeit von A-priori-Wissen über die Hypothesen bzw. Klassen hinsichtlich ihres Eintreffens. Derartige Informationen lassen sich in der Regel nur sehr grob aus statistischen Untersuchungen gewinnen und werden daher häufig heuristisch festgelegt. Die Dempster-Shafer-Theorie benötigt dieses explizite A-priori-Wissen prinzipbedingt nicht. Bei ihr wird klar zwischen den Messergebnissen und der Vertrauenswürdigkeit unterschieden. Die Unterschiede hinsichtlich der Datenfusion zeigt Abbildung 2.

Als Nachteil der Dempster-Shafer-Theorie sind der vergleichsweise hohe Rechenaufwand sowie die undefinierte Kombinationsregel bei völlig gegensätzlichen Aussagen zu nennen.

## 6 Zusammenfassung

Mit der Dempster-Shafer-Theorie liegt eine Methodik zur Kombination von beliebigen Sensorquellen unterschiedlicher Zuverlässigkeit vor. Ein sinnvoller Einsatz der Methodik liegt bei Klassifikationsaufgaben unter Nutzung einfacher und damit sehr kostengünstiger Sensorik, die keine hohe Zuverlässigkeit erreicht. Ein Beispiel hierfür ist in [3] enthalten.

## Literatur

1. A. Dempster. A Generalization of Bayesian Interference. *Journal of Royal Statistical Society*, 30:205–247, 1968.
2. G. Shafer. *A Mathematical Theory of Evidence*. Princeton University Press, 1976.
3. D. Linzmeier und T. Bär. Fusion von Radar und Thermopilesensoren zur Fußgängerdetektion. In: *Informationsfusion in der Mess- und Sensortechnik*, J. Beyerer, F. Puente León und K.-D. Sommer (Hrsg.), Universitätsverlag Karlsruhe, Karlsruhe, 2006.
4. H. Barnett. Computational methods for a mathematical theory of evidence. *Proceedings of the 7th International Joint Conference on Artificial Intelligence*, Vancouver, S. 868–875, 1981.
5. D. Vogt. *A Data Fusion System for Pedestrian Protection*. Diplomarbeit, Universität Ulm, 2005.
6. J. Berger. *Statistical Decision Theory*. Springer Verlag, New York, 1980.
7. E. Walz, J. Linas. *Multisensor Data Fusion*. Artech House, London, 1990.
8. D. L. Hall. *Mathematical Techniques in Multisensor Data Fusion*. Artech House, London, 1992.



# On estimation of structured covariance matrices

Wolfgang Utschick und Frank A. Dietrich

Technische Universität München, Associate Institute for Signal Processing,  
Arcisstr. 21, D-80290 München

**Zusammenfassung.** We give an overview over different approaches to estimate the correlations between several system parameters, which can be modeled as random variables. The system parameters are observed at multiple sensors, but these measurements are distorted by random noise or interference. Based on the maximum likelihood principle we show how the structure of the covariance matrix of the measurements can be exploited to estimate parameter and noise correlations with high accuracy.

## 1 Introduction

For a linear system with parameters, which can be modeled as correlated random variables, we would like to estimate their statistical correlations based on measurements from multiple sensors. But the system's parameters cannot be observed directly and reliably, as the measurements are distorted by noise or interference with unknown statistic. Thus, to obtain an accurate estimate of the parameter correlations estimation of the noise correlations is necessary.

The algorithms for estimation of these correlations presented in the sequel are an important prerequisite, whenever a further processing and interpretation of the sensor data or optimization of the system's design exploits the parameter and noise correlations. Some examples of applications, which require accurate knowledge of the correlations, are:

- Multiple-input-multiple-output (MIMO) system identification, e.g., based on the Bayesian principle (MMSE estimation)
- Channel sounding for modeling of wireless communication channels with multiple antennas (sensors)
- Mobile positioning and satellite navigation
- Signal processing for antenna arrays (smart antennas, beamforming)
- Stochastic modeling of band-limited signals
- Sensor fusion based on a stochastic parameter and system model

Below we show that the estimation of the correlations can be formulated as the estimation of a structured covariance matrix. Anderson [1] discusses the estimation of covariance matrices with linear structure, whereas Burg *et al.* [2] give a more detailed treatment of the problem including an iterative algorithm.

Previously proposed estimators for the parameter and noise correlations are either heuristic and do not compensate for the noise in the measurements [6]

or do not provide positive semidefinite estimates of the parameters' correlation or covariance matrix [4]. If the estimates are indefinite, i.e., they have negative eigenvalues, performance of the application relying on these estimates can suffer significantly. Moreover, in some cases the measurement noise (interference) among the sensors is correlated. Thus, to obtain accurate estimates of the parameters' correlations, it is important to remove or reduce the influence of the noise correlations.

In Sec. 2 we introduce the stochastic signal model for the measurement data and describe the problem of estimating a structured covariance matrix. The maximum likelihood (ML) formulation of this problem is introduced in Sec. 3.1. We present a novel solution based on a generalization of the expectation-maximization (EM) algorithm [11] (Sec. 3.2), which is known as space-alternating generalized expectation-maximization (SAGE) algorithm [7]. The least-squares (LS) approach in Sec. 4 can be shown to be closely related to the ML problem, but yields an algorithm with considerably smaller numerical complexity. Here, we give a summary of our results in [5]. The performance of the ML and LS estimators is evaluated in the context of system identification based on the minimum mean square error (MMSE) (Sec. 5). As an example we consider estimation of the parameters in a linear (dispersive) transmission system based on transmitted training sequences.

*Notation:* Random vectors and matrices are denoted by lower and upper case sans serif bold letters (e.g.  $\mathbf{b}$ ,  $\mathbf{B}$ ), whereas the realizations or deterministic variables are, e.g.,  $\mathbf{b}$ ,  $\mathbf{B}$ . The operators  $\mathbb{E}[\bullet]$ ,  $(\bullet)^T$ ,  $(\bullet)^H$ , and  $\text{tr}(\bullet)$  stand for expectation, transpose, Hermitian transpose, and trace of a matrix, respectively.  $\mathbb{E}_{\mathbf{a}}[\bullet]$  and  $\mathbb{E}_{\mathbf{a}}[\bullet|\mathbf{b}]$  denote the (unconditioned) expectation w.r.t. the random vector  $\mathbf{a}$  and the conditional expectation w.r.t.  $\mathbf{a}$  given the realization  $\mathbf{b}$ .  $\mathbb{E}_{\mathbf{a}}[\bullet|\mathbf{b}; \mathbf{x}]$  additionally indicates, that the conditional probability distribution of  $\mathbf{a}$  is parameterized with  $\mathbf{x}$ .  $\otimes$  and  $\delta_{k,k'}$  denote the Kronecker product and function,  $\text{vec}[\mathbf{B}]$  stacks the columns of  $\mathbf{B}$  in a vector.  $\mathbf{e}_i$  is the  $i$ th column of an  $N \times N$  identity matrix  $\mathbf{I}_N$  and  $\mathbb{S}_{+,0}^M$  denotes the set of positive semidefinite  $M \times M$  matrices. The squared Frobenius norm of a matrix  $\mathbf{A}$  is  $\|\mathbf{A}\|_{\text{F}}^2 = \text{tr}[\mathbf{A}^H \mathbf{A}]$ .

## 2 Signal Model and Problem Statement

In a linear system with  $M$  sensors we collect  $N$  measurements per sensor. The observations at sensor  $m$  in time frame  $q$  are summarized in<sup>1</sup>

$$\mathbf{y}_m[q] = [y_m[q, 1], y_m[q, 2], \dots, y_m[q, N]]^T \in \mathbb{C}^N \quad (1)$$

and modeled as

$$\mathbf{y}_m[q] = \mathbf{x}_m[q] + \mathbf{n}_m[q] \in \mathbb{C}^N, \quad (2)$$

where  $\mathbf{n}_m[q]$  and  $\mathbf{x}_m[q]$  are measurement noise and the random system parameters of interest, respectively. We assume that the system parameters can be described

<sup>1</sup> We consider the general case of complex-valued signals.



by the basis expansion  $\mathbf{x}_m[q] = \bar{\mathbf{S}}\mathbf{h}_m[q]$ . The columns of  $\bar{\mathbf{S}} \in \mathbb{C}^{N \times K}$  contain the  $K < N$  relevant basis vectors to model the parameters and  $\mathbf{h}_m[q] \in \mathbb{C}^K$  the corresponding coefficients. Such a model of reduced rank  $K$  is adequate, for example, if  $\mathbf{x}_m[q]$  contains samples of a band-limited signal<sup>2</sup> or in a linear transmission system with training sequences for parameter identification [5].

The measurements  $\mathbf{y}_m[q]$  from all  $M$  sensors are written as the rows of

$$\mathbf{Y}[q] = [\mathbf{y}_1[q], \dots, \mathbf{y}_M[q]]^T = \mathbf{H}[q]\bar{\mathbf{S}}^T + \mathbf{N}[q] \in \mathbb{C}^{M \times N}, \quad (3)$$

with  $\mathbf{H}[q] = [\mathbf{h}_1[q], \dots, \mathbf{h}_M[q]]^T \in \mathbb{C}^{M \times K}$ . Applying the relation  $\text{vec}[\mathbf{ABC}] = (\mathbf{C}^T \otimes \mathbf{A})\text{vec}[B]$  and defining  $\mathbf{y}[q] = \text{vec}[\mathbf{Y}[q]]$  and  $\mathbf{S} = \bar{\mathbf{S}} \otimes \mathbf{I}_M$  we get the linear model

$$\boxed{\mathbf{y}[q] = \mathbf{S}\mathbf{h}[q] + \mathbf{n}[q] \in \mathbb{C}^{MN}.} \quad (4)$$

The stationary and zero-mean system parameters and noise with covariance matrices  $\mathbf{C}_h = \text{E}[\mathbf{h}[q]\mathbf{h}[q]^H]$  and  $\mathbf{C}_n = \text{E}[\mathbf{n}[q]\mathbf{n}[q]^H]$  are mutually uncorrelated. Generally the noise (interference) is correlated between sensors, i.e.,  $\mathbf{C}_n = \mathbf{I}_N \otimes \mathbf{C}_{n,S}$  with  $\mathbf{C}_{n,S} = \text{E}[\mathbf{n}[q,n]\mathbf{n}[q,n]^H]$  and  $\mathbf{n}[q,n]$  is the  $n$ th column of  $\mathbf{N}[q]$ . As a special case we define  $\mathbf{C}_n = c_n\mathbf{I}_{MN}$ .

This yields the covariance matrix of the measured signal  $\mathbf{y}[q]$

$$\boxed{\mathbf{C}_y = \text{E}[\mathbf{y}[q]\mathbf{y}[q]^H] = \mathbf{S}\mathbf{C}_h\mathbf{S}^H + \mathbf{I}_N \otimes \mathbf{C}_{n,S},} \quad (5)$$

which depends on the parameter covariance matrix  $\mathbf{C}_h$  and noise variance  $\mathbf{C}_{n,S}$  to be estimated. Thus, the problem of estimating  $\mathbf{C}_h$  and  $\mathbf{C}_{n,S}$  can be formulated as estimation of  $\mathbf{C}_y$  taking into account its linear structure.

**General Problem Statement:** Estimate the covariance matrices  $\mathbf{C}_h$  and  $\mathbf{C}_{n,S}$  (or  $c_n$ ) of the parameters  $\mathbf{h}[q]$  and noise  $\mathbf{n}[q]$  based on  $B$  observations  $\{\mathbf{y}[q]\}_{q=1}^B$ , which are assumed to be statistically independent for simplicity.

### 3 Maximum Likelihood Approach

#### 3.1 Maximum Likelihood Problem

We formulate the general problem as a ML problem for estimating the structured covariance matrix  $\mathbf{C}_y$  (5), which is linear in  $\mathbf{C}_h$  and  $\mathbf{C}_{n,S}$ . The measurements  $\mathbf{y}[q] \in \mathbb{C}^{MN}$  are assumed to be jointly Gaussian distributed with statistically independent real and imaginary part (“complex Gaussian”).

The ML problem reads as

$$\mathbf{C}_h \in \mathbb{S}_{+,0}^{MK}, \mathbf{C}_{n,S} \in \mathbb{S}_{+,0}^M \prod_{q=1}^B p_y(\mathbf{y}[q]; \mathbf{C}_h, \mathbf{C}_{n,S}) \quad (6)$$

<sup>2</sup> In this case the basis vectors are Discrete Prolate Spheroidal Sequences [13].

with  $\mathbf{C}_n = \mathbf{I}_N \otimes \mathbf{C}_{n,S}$  and probability density ( $\mathbf{C}_y$  is given by (5))

$$p_y(\mathbf{y}[q]; \mathbf{C}_h, \mathbf{C}_{n,S}) = \frac{1}{\pi^{MN} \det \mathbf{C}_y} \exp(-\mathbf{y}[q]^H \mathbf{C}_y^{-1} \mathbf{y}[q]). \quad (7)$$

Thus, the structured estimate of  $\mathbf{C}_y$  gives us the desired covariance matrices  $\mathbf{C}_h$  and  $\mathbf{C}_{n,S}$ . Generally, this problem is not concave and an explicit solution seems to be difficult, if not impossible, to obtain [1, 2].

### 3.2 Solution Based on the EM Algorithm

To derive the EM algorithm [11] for this problem we start with the following *Gedankenexperiment*: If  $\mathbf{h}[q]$  and  $\mathbf{n}[q]$  were observable for  $q = 1, \dots, B$ , then the corresponding ML problem would be

$$\max_{\mathbf{C}_h \in \mathbb{S}_{+,0}^{MK}} \prod_{q=1}^B p_h(\mathbf{h}[q]; \mathbf{C}_h) \quad (8)$$

and for statistically independent (in  $n$  and  $q$ ) samples  $\mathbf{n}[q, n]$

$$\max_{\mathbf{C}_{n,S} \in \mathbb{S}_{+,0}^M} \prod_{q=1}^B \prod_{n=1}^N p_{\mathbf{n}[q,n]}(\mathbf{n}[q, n]; \mathbf{C}_{n,S}). \quad (9)$$

The solution to both problems is simple and given by the sample covariance matrices of the corresponding (hypothetical) observations

$$\tilde{\mathbf{C}}_h = \frac{1}{B} \sum_{q=1}^B \mathbf{h}[q] \mathbf{h}[q]^H \quad \text{and} \quad \tilde{\mathbf{C}}_{n,S} = \frac{1}{BN} \sum_{q=1}^B \sum_{n=1}^N \mathbf{n}[q, n] \mathbf{n}[q, n]^H \quad (10)$$

(or  $\tilde{c}_n = \frac{1}{BNM} \sum_{b=1}^B \sum_{n=1}^N \|\mathbf{n}[q, n]\|_2^2$  for spatially uncorrelated noise).

The EM algorithm for our problem (6) relies on this idea: As direct observations of  $\mathbf{h}[q]$  and  $\mathbf{n}[q]$  would yield a ML problem with simple structure, they may be defined as the *complete data* space. Consequently, the observed signal  $\{\mathbf{y}[q]\}_{q=1}^B$  is called the “*incomplete data*”, as the corresponding ML problem (6) is difficult to solve. The incomplete and complete data are related via the many-to-one mapping in (4).

**Estimation of  $\mathbf{C}_{n,S}$ :** As  $K < N$  part of the noise is observable in  $\mathbf{y}[q]$  projecting the measurements on the noise subspace orthogonal to the column space of  $\mathbf{S}$ . Therefore, we do not estimate  $\mathbf{C}_{n,S}$  based on the EM principle with the definition of the complete data space from above. This also reduces the algorithmic complexity. Moreover, it turned out to be difficult to find a good initialization to yield an improved estimate, when extending the EM algorithm to include also a complete data space for  $\mathbf{C}_{n,S}$ .

The *projection* of the observed signal  $\{\mathbf{y}[q]\}_{q=1}^B$  on the noise subspace is denoted  $\{\mathbf{n}^\perp[q]\}_{q=1}^B$  with  $\mathbf{n}^\perp[q] = \mathbf{U}^\perp, \text{H} \mathbf{y}[q]$ .  $\mathbf{U}^\perp = \bar{\mathbf{U}}^\perp \otimes \mathbf{I}_M \in \mathbb{C}^{MN \times M(N-K)}$  (same structure as  $\mathbf{S}$ ) with  $\bar{\mathbf{U}}^\perp, \text{H} \bar{\mathbf{U}}^\perp = \mathbf{I}_{N-K}$  is an orthonormal basis of the noise subspace, i.e.,  $\bar{\mathbf{U}}^\perp, \text{H} \bar{\mathbf{S}} = \mathbf{0}$ .  $\bar{\mathbf{U}}^\perp \in \mathbb{C}^{N \times (N-K)}$  can be obtained from a QR-decomposition of  $\bar{\mathbf{S}}$ .

The log-likelihood function of  $\{\mathbf{n}^\perp[q]\}_{q=1}^B$  is

$$\begin{aligned} \sum_{q=1}^B \ln [\text{p}_{\mathbf{n}^\perp}(\mathbf{n}^\perp[q]; \mathbf{C}_{\mathbf{n}, \text{S}})] &= -BM(N-K) \ln \pi - B(N-K) \ln [\det \mathbf{C}_{\mathbf{n}, \text{S}}] - \\ &\quad - B \text{tr} \left[ \frac{1}{B} \sum_{q=1}^B (\mathbf{n}^\perp[q] \mathbf{n}^\perp[q]^\text{H}) (\mathbf{I}_{N-K} \otimes \mathbf{C}_{\mathbf{n}, \text{S}}) \right] \end{aligned} \quad (11)$$

as  $\mathbf{U}^\perp = \bar{\mathbf{U}}^\perp \otimes \mathbf{I}_M$ , which gives  $\mathbf{C}_{\mathbf{n}^\perp} = \text{E} [\mathbf{n}^\perp[q] \mathbf{n}^\perp[q]^\text{H}] = \mathbf{I}_{N-K} \otimes \mathbf{C}_{\mathbf{n}, \text{S}}$  and  $\det (\mathbf{I}_{N-K} \otimes \mathbf{C}_{\mathbf{n}, \text{S}}) = (\det \mathbf{C}_{\mathbf{n}, \text{S}})^{N-K}$ .

Maximization of the log-likelihood of  $\{\mathbf{n}^\perp[q]\}_{q=1}^B$  (11) w.r.t.  $\mathbf{C}_{\mathbf{n}, \text{S}}$  yields

$$\hat{\mathbf{C}}_{\mathbf{n}, \text{S}} = \frac{1}{B(N-K)} \sum_{q=1}^B \sum_{i=1}^{N-K} \mathbf{n}^\perp[q, i] \mathbf{n}^\perp[q, i]^\text{H}, \quad (12)$$

where  $[\mathbf{n}^\perp[q, 1], \mathbf{n}^\perp[q, 2], \dots, \mathbf{n}^\perp[q, N-K]] = \mathbf{Y}[q] \bar{\mathbf{U}}^{\perp*}$  with  $\bar{\mathbf{U}}^{\perp, \text{H}} \bar{\mathbf{S}} = \mathbf{0}$ .

**E-Step for  $\mathbf{C}_\mathbf{h}$ :** Having defined the complete data space for  $\mathbf{C}_\mathbf{h}$  as  $\{\mathbf{h}[q]\}_{q=1}^B$ , the EM algorithm proceeds iteratively with an expectation step (E-Step) followed by a maximization step (M-Step).<sup>3</sup>

In the E-Step a conditional mean (CM) estimate of the log-likelihood function of the complete data space given the observations  $\{\mathbf{y}[q]\}_{q=1}^B$  and estimates  $\hat{\mathbf{C}}_{\mathbf{n}, \text{S}}$  and  $\hat{\mathbf{C}}_\mathbf{h}^{(n)}$  from the previous iteration  $n$  is formed: For the log-likelihood function (compare with Eq. 7) of  $\{\mathbf{h}[q]\}_{q=1}^B$  it is

$$\text{E}_\mathbf{h} \left[ \sum_{q=1}^B \ln [\text{p}_\mathbf{h}(\mathbf{h}[q]; \mathbf{C}_\mathbf{h})] \middle| \{\mathbf{y}[q]\}_{q=1}^B; \hat{\mathbf{C}}_\mathbf{h}^{(n)}, \hat{\mathbf{C}}_{\mathbf{n}, \text{S}} \right]. \quad (13)$$

In the experiment above the likelihood function in (8) depends on the sample mean covariance matrix  $\tilde{\mathbf{C}}_\mathbf{h}$  (10) of the observations of the complete data space  $\{\mathbf{h}[q]\}_{q=1}^B$ , which were assumed to be available. In the E-Step (13) of the EM-Algorithm this sample covariance matrix is replaced by its CM estimate

$$\text{E}_\mathbf{h} \left[ \tilde{\mathbf{C}}_\mathbf{h} | \{\mathbf{y}[q]\}_{q=1}^B; \hat{\mathbf{C}}_\mathbf{h}^{(n)}, \hat{\mathbf{C}}_{\mathbf{n}, \text{S}} \right]. \quad (14)$$

<sup>3</sup> To be precise: Note that the mapping between complete and incomplete data is stochastic, which is covered in the extension to EM algorithm described in [7].

**M-Step for  $\mathbf{C}_h$ :** Now the CM estimate of the log-likelihood function of the complete data is maximized w.r.t.  $\mathbf{C}_h$ . The maximum is given for the CM estimate of the sample covariance matrix in (14). Its explicit expression [10] in terms of the CM estimates of the parameters  $\hat{\mathbf{h}}[q] = \mathbf{W}^{(n)}\mathbf{y}[q]$  (first order moment) with MMSE estimator  $\mathbf{W}^{(n)} = \hat{\mathbf{C}}_h^{(n)}\mathbf{S}^H\hat{\mathbf{C}}_y^{(n),-1}$  based on the correlations from the previous iterations,  $\hat{\mathbf{C}}_y^{(n)} = \mathbf{S}\hat{\mathbf{C}}_h^{(n)}\mathbf{S} + \hat{\mathbf{C}}_n$ , and the sample covariance matrix of the observations  $\tilde{\mathbf{C}}_y = \frac{1}{B}\sum_{q=1}^B\mathbf{y}[q]\mathbf{y}[q]^H$  is

$$\hat{\mathbf{C}}_h^{(n+1)} = \mathbf{W}^{(n)}\tilde{\mathbf{C}}_y\mathbf{W}^{(n),H} + \hat{\mathbf{C}}_{h|\mathbf{y}[q]}^{(n)}. \quad (15)$$

The second term is the error covariance matrix (conditional covariance matrix) [10]

$$\hat{\mathbf{C}}_{h|\mathbf{y}[q]}^{(n)} = \hat{\mathbf{C}}_h^{(n)} - \mathbf{W}^{(n)}\mathbf{S}\hat{\mathbf{C}}_h^{(n)} \quad (16)$$

of the MMSE estimate  $\hat{\mathbf{h}}[q]$  with  $\mathbf{W}^{(n)}$  given the correlations from iteration  $n$ .

**Summary of Algorithm and Complexity:** After initialization compute (15) in every iteration (E- and M-Step are included in Eq. 15) and (12) only in the first iteration. Initializing the EM algorithm with  $\hat{\mathbf{C}}_n = \mathbf{0}$  yields the heuristic estimator (see discussion Sec. 4.3) in the first iteration and does not require any choice for  $\hat{\mathbf{C}}_h^{(0)}$  as the first iteration is independent of  $\hat{\mathbf{C}}_h^{(0)}$  in this case. An improved initialization uses the positive-definite LS estimates in Section 4.2, which we also use in the simulations (Sec. 5).

The numerical complexity per iteration is dominated by the system of linear equations for  $\mathbf{W}^{(n)}$  (Sec. 3.2) with number of operations of the order  $M^3K^3$  (after applying the matrix inversion lemma [10]). Roughly, it is comparable to computing one MMSE parameter estimator per iteration. Certainly, the complexity can be reduced using appropriate numerical algorithms and approximations, which is not our focus here.

**Extensions:** In some scenarios we have additional a-priori knowledge about the structure of  $\mathbf{C}_h$ . It is rather straight forward to include the following assumptions in our algorithm:  $\mathbf{C}_h$  is block-diagonal, diagonal, or has a Kronecker or Toeplitz structure. Moreover, extension to parameters with non-zero mean is obvious.

## 4 Least-Squares Approaches

In this Section we aim at a structured least squares approximation of the sufficient<sup>4</sup> statistic  $\tilde{\mathbf{C}}_y = \frac{1}{B}\sum_{q=1}^B\mathbf{y}[q]\mathbf{y}[q]^H$  w.r.t.  $\mathbf{C}_h$  and  $c_n$ .

<sup>4</sup> In case of complex Gaussian distributed observations (Sec. 3.1).

#### 4.1 Unbiased Least Squares Estimator

As indicated in [9] the structured least squares (LS) approximation of  $\tilde{\mathbf{C}}_{\mathbf{y}}$

$$\min_{\mathbf{C}_{\mathbf{h}}, c_n} \|\tilde{\mathbf{C}}_{\mathbf{y}} - \mathbf{S}\mathbf{C}_{\mathbf{h}}\mathbf{S}^{\text{H}} - c_n\mathbf{I}_{MN}\|_{\text{F}}^2 \quad (17)$$

performs close to the maximum likelihood approach as  $B \rightarrow \infty$ , which is referred to as “extended invariance principle” in [14].<sup>5</sup> The solution is obtained using the gradient of the cost function [4] (see also [12]) and reads

$$\hat{c}_n^{\text{LS}} = \frac{1}{M(N-K)} \text{trace} \left[ \mathbf{P}^{\perp} \tilde{\mathbf{C}}_{\mathbf{y}} \mathbf{P}^{\perp} \right] \quad (18)$$

$$\hat{\mathbf{C}}_{\mathbf{h}}^{\text{LS}} = \mathbf{S}^{\dagger} \tilde{\mathbf{C}}_{\mathbf{y}} \mathbf{S}^{\dagger, \text{H}} - (\mathbf{S}^{\text{H}} \mathbf{S})^{-1} \hat{c}_n^{\text{LS}} \quad (19)$$

with projector  $\mathbf{P} = \mathbf{S}\mathbf{S}^{\dagger}$  on the column space of  $\mathbf{S}$  and orthogonal projector  $\mathbf{P}^{\perp} = (\mathbf{I}_{MN} - \mathbf{S}\mathbf{S}^{\dagger})$ . As shown in Fig. 1 this leads to an indefinite estimate for moderate to low  $B$ , as it is only an asymptotically optimum approach.

The estimate of the noise variance is obtained projecting the observations  $\mathbf{y}[q]$  on the noise subspace, which does not contain the signal of interest. The estimate of the parameter covariance matrix is unbiased, as the second term in (19) compensates for the bias in the first term, which is identical to the heuristic estimator in Sec. 4.3 [4].

#### 4.2 Positive Semidefinite Least Squares Estimator

In (17) the optimization problem was solved for all quadratic matrices  $\mathbf{C}_{\mathbf{h}} \in \mathbb{C}^{MK \times MK}$ . We propose to include constraints on  $\mathbf{C}_{\mathbf{h}}$  and  $c_n$  to be positive semidefinite (psd) into the optimization:

$$\min_{\mathbf{C}_{\mathbf{h}}, c_n} \|\tilde{\mathbf{C}}_{\mathbf{y}} - \mathbf{S}\mathbf{C}_{\mathbf{h}}\mathbf{S}^{\text{H}} - c_n\mathbf{I}_{MN}\|_{\text{F}}^2 \text{ s.t. } \mathbf{C}_{\mathbf{h}} \succeq 0, c_n \geq 0. \quad (20)$$

This can be solved analytically using Karush-Kuhn-Tucker conditions [3] and the parameterization of  $\mathbf{C}_{\mathbf{h}}$  via its EVD  $\mathbf{C}_{\mathbf{h}} = \mathbf{U}\mathbf{\Lambda}\mathbf{U}^{\text{H}}$  and corresponding constraints on the eigenvectors  $\mathbf{U}^{\text{H}}\mathbf{U} = \mathbf{I}_{MK}$  and eigenvalues  $\lambda_i \geq 0$ .

A computationally efficient algorithm to solve optimization problem (20) is given in [5]. The resulting estimates, to which we refer as  $\hat{c}_n^{\text{psd}}$  and  $\hat{\mathbf{C}}_{\mathbf{h}}^{\text{psd}}$ , are biased as long as the probability for  $\sigma_i - \hat{c}_n^{\text{LS}} < 0$  for any  $i$  is non-zero, which is more likely for small  $B$ , large noise variance  $c_n$ , and higher correlations in  $\mathbf{C}_{\mathbf{h}}$ .

As  $\hat{c}_n^{\text{psd}}$  underestimates the noise variance  $c_n$ , the following approach achieves better results, when applied to MMSE parameter estimation. Consider the joint likelihood of the ML estimates of  $\mathbf{h}[q]$ , which are denoted as  $\{\hat{\mathbf{h}}^{\text{ML}}[q]\}_{q=1}^B$  with  $\hat{\mathbf{h}}^{\text{ML}}[q] = \mathbf{S}^{\dagger} \mathbf{y}[q]$ , and the noise  $\{\mathbf{n}^{\perp}[q]\}_{q=1}^B$ . The likelihood equation of interest follows from the necessary condition for a maximum, which is the gradient of the log-likelihood w.r.t.  $\mathbf{C}_{\hat{\mathbf{h}}} = \text{E}[\hat{\mathbf{h}}^{\text{ML}}[q]\hat{\mathbf{h}}^{\text{ML}}[q]^{\text{H}}]$  and  $c_n$ . The following approach aims at a positive semidefinite LS solution of this likelihood equation.

<sup>5</sup> If a weighted Frobenius norm is used ML performance is achieved asymptotically.

1. Estimate  $c_n$  using  $\hat{c}_n^{\text{LS}}$  (18), which is unbiased and based on the true noise subspace.
2. Solve the optimization problem

$$\min_{\mathbf{C}_h} \|\tilde{\mathbf{C}}_{\hat{\mathbf{h}}} - \mathbf{C}_h - \hat{c}_n^{\text{LS}} \mathbf{I}_{MK}\|_{\text{F}}^2 \text{ s.t. } \mathbf{C}_h \succeq 0 \quad (21)$$

with  $\tilde{\mathbf{C}}_{\hat{\mathbf{h}}} = \frac{1}{B} \sum_{q=1}^B \hat{\mathbf{h}}^{\text{ML}}[q] \hat{\mathbf{h}}^{\text{ML}}[q]^{\text{H}} = \mathbf{S}^{\dagger} \tilde{\mathbf{C}}_{\mathbf{y}} \mathbf{S}^{\dagger, \text{H}}$ .

The solution reads

$$\hat{\mathbf{C}}_h^{\text{psd2}} = (\mathbf{S}^{\text{H}} \mathbf{S})^{-1/2} \mathbf{V} \mathbf{D}^+ \mathbf{V}^{\text{H}} (\mathbf{S}^{\text{H}} \mathbf{S})^{-1/2}, \quad (22)$$

where  $\mathbf{D}^+$  performs  $\max(0, d_i)$  for all elements in  $\mathbf{D}$  from the EVD of

$$(\mathbf{S}^{\text{H}} \mathbf{S})^{1/2} \hat{\mathbf{C}}_h^{\text{LS}} (\mathbf{S}^{\text{H}} \mathbf{S})^{1/2} = \mathbf{V} \mathbf{D} \mathbf{V}^{\text{H}}. \quad (23)$$

For  $\mathbf{S}^{\text{H}} \mathbf{S} \propto \mathbf{I}_{MK}$  this is equivalent to discarding the negative definite part of the estimate  $\hat{\mathbf{C}}_h^{\text{LS}}$  (19) similar to [8].

The additional complexity for computing the positive definite solution compared to (18) and (19) results from the eigenvalue decomposition (23) and computation of  $(\mathbf{S}^{\text{H}} \mathbf{S})^{1/2}$  and  $(\mathbf{S}^{\text{H}} \mathbf{S})^{-1/2}$ .

### 4.3 Heuristic Estimator

The heuristic estimator proposed by [6] minimizes

$$\min_{\mathbf{C}_h} \|\tilde{\mathbf{C}}_{\mathbf{y}} - \mathbf{S} \mathbf{C}_h \mathbf{S}^{\text{H}}\|_{\text{F}}^2. \quad (24)$$

Implicitly the noise variance is assumed small and is neglected. Its solution is the sample-mean of the ML parameter estimates  $\hat{\mathbf{h}}^{\text{ML}}[q] = \mathbf{S}^{\dagger} \mathbf{y}[q]$

$$\hat{\mathbf{C}}_h^{\text{Heur}} = \mathbf{S}^{\dagger} \tilde{\mathbf{C}}_{\mathbf{y}} \mathbf{S}^{\dagger, \text{H}} = \frac{1}{B} \sum_{q=1}^B \hat{\mathbf{h}}^{\text{ML}}[q] \hat{\mathbf{h}}^{\text{ML}}[q]^{\text{H}}. \quad (25)$$

and is positive semidefinite and biased.

### 4.4 Extensions

The algorithms presented in the previous section can be easily extended to correlated noise, which also apply in Sec. 5. Details are given in [5].

## 5 Application: Bayesian System Identification

### 5.1 MMSE System Identification

The MMSE parameter estimator of  $\mathbf{h}[q]$  based on the observation  $\mathbf{y}[q]$  is given by

$$\underset{\mathbf{W}}{\operatorname{argmin}} \mathbb{E}_{\mathbf{h}, \mathbf{y}} [\|\mathbf{h}[q] - \mathbf{W}\mathbf{y}[q]\|_2^2] = \mathbf{C}_h \mathbf{S}^H (\mathbf{S} \mathbf{C}_h \mathbf{S}^H + \mathbf{I}_N \otimes \mathbf{C}_{n,S})^{-1} \quad (26)$$

With the eigenvalue decomposition (EVD) of  $\mathbf{C}_h = \mathbf{U}\mathbf{\Lambda}\mathbf{U}^H$ , where  $\mathbf{\Lambda}$  is diagonal with  $\lambda_i$  ( $\lambda_i \geq \lambda_{i+1}$ ) on the diagonal, and assuming  $\mathbf{S}^H \mathbf{S} = N\mathbf{I}_{MK}$  and  $\mathbf{C}_{n,S} = c_n \mathbf{I}_M$  Eq. (26) can be written as

$$\mathbf{W}_{\text{MMSE}} = \mathbf{U}\mathbf{\Lambda}(\mathbf{\Lambda}N + c_n \mathbf{I}_{MK})^{-1} \mathbf{U}^H \mathbf{S}^H. \quad (27)$$

If  $\lambda_i < 0$  and  $\lambda_i N + c_n \approx 0$  for some  $i$  due to an indefinite estimate of  $\mathbf{C}_h$ , the system of equations is highly ill-conditioned, which leads to numerical problems in implementation. Thus, for indefinite estimates of  $\mathbf{C}_h$  numerical stability is not guaranteed in this application.

### 5.2 Performance Evaluation

Performance measure is the MSE (normalized by  $\operatorname{tr}[\mathbf{C}_h]$ ) of MMSE parameter estimation  $\hat{\mathbf{h}}[q] = \mathbf{W}\mathbf{y}[q]$  (26).  $\mathbf{W}_{\text{MMSE}}$  (27) is based on the estimates of  $\mathbf{C}_h$  and  $\mathbf{C}_n$  from the *EM algorithm* (Eqs. 15 and 12), the *heuristic* LS estimator (Eq. 24 and 12), the *unbiased* LS estimator (19) and the *positive semidefinite* LS approach.<sup>6</sup> As a reference we also include the MSE of the ML parameter estimator  $\mathbf{W}_{\text{ML}} = \mathbf{S}^\dagger$ , which does not exploit parameter correlations, and of  $\mathbf{W}_{\text{MMSE}}$  with perfect knowledge of  $\mathbf{C}_h$  and  $\mathbf{C}_n$ . We choose  $\mathbf{S}^H \mathbf{S} = N\mathbf{I}_{MN}$ ,  $N = 16$ ,  $M = 8$ ,  $B$  statistically independent  $\mathbf{h}[q] \sim \mathcal{N}_c(\mathbf{0}, \mathbf{C}_h)$ , and normalize  $\mathbf{C}_h$  such that  $\operatorname{tr}[\mathbf{C}_h] = M$ . The EM algorithm performs 10 iterations with initialization by the positive semidefinite LS estimate (22).

*Scenario 1:* We select  $K = 8$ ,  $\mathbf{C}_{n,S} = c_n \mathbf{I}_M$ , and  $\mathbf{C}_h = \mathbf{C} \otimes \mathbf{C}$  with elements  $[\mathbf{C}]_{i,j} = \rho^{|i-j|}$  and  $\rho = 0.9$  to model correlations of the parameters.

For spatially white noise the MMSE estimation significantly outperforms ML parameter estimation for high parameter correlation and low SNR (cf. Fig. 2 and [6]). The performance of MMSE estimators based on estimates of  $\mathbf{C}_h$  and  $c_n$  from the EM algorithm (Sec. 3.2) and positive definite LS (Sec. 4.2) is almost identical, i.e., the EM algorithm cannot improve the quality of the positive semidefinite LS estimates in this scenario. (The graphs in the figures cannot be distinguished.) We conclude that the quality of these LS estimates are very high and are (at least) very close to a local maximum of the log-likelihood function (6).

Already for  $B = 5$  the MMSE estimator with estimated covariance matrices outperforms ML parameter estimation. For small  $B$  the EM algorithm/positive semidefinite LS and the heuristic LS perform identically (Fig. 3). For high  $B$  the

<sup>6</sup> In case of correlated noise the generalizations for the LS approaches in [5] are used.

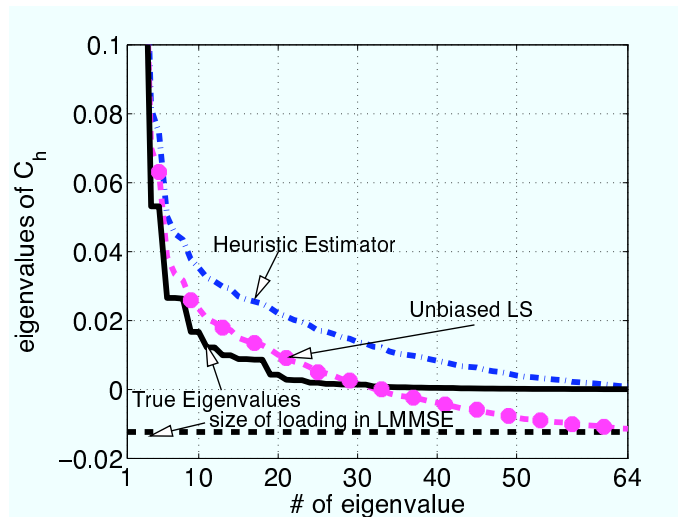
EM algorithm (positive semidefinite LS) is superior due to its reduced bias. For the unbiased LS algorithm the MMSE estimator performs always worse than the ML parameter estimator in Fig. 2 and for small  $B$  the system of equations is numerically very ill-conditioned, which is due to the indefinite estimate of  $\mathbf{C}_h$  (Fig. 3).

*Scenario 2:* The bias of the heuristic estimator (24) leads to a larger performance degradation for spatially correlated noise: For  $K = 1$  the bias is  $E_{h,n}[\hat{\mathbf{C}}_h^{\text{heur}}] - \mathbf{C}_h = \frac{1}{N}\mathbf{C}_{n,S}$ . For  $K = 1$  the noise correlations are modeled as  $\mathbf{C}_{n,S} = \mathbf{C}_i + c_n\mathbf{I}_M$  with thermal noise variance  $c_n = 0.01$ , interference covariance matrix  $\mathbf{C}_i$  with eigenvalues

$$[4.1, 3.1, 7.2 \cdot 10^{-1}, 4.410^{-2}, 8.9 \cdot 10^{-4}, 1.2 \cdot 10^{-5}, 8.9 \cdot 10^{-8}, 2.4 \cdot 10^{-10}],$$

and  $\text{tr}[\mathbf{C}_i] = M$  (signal to interference power ratio is 0 dB)

With spatially *correlated* noise the EM algorithm (positive semidefinite LS) yields a significant performance gain over the heuristic approach for  $B > 50$  (Fig. 4).

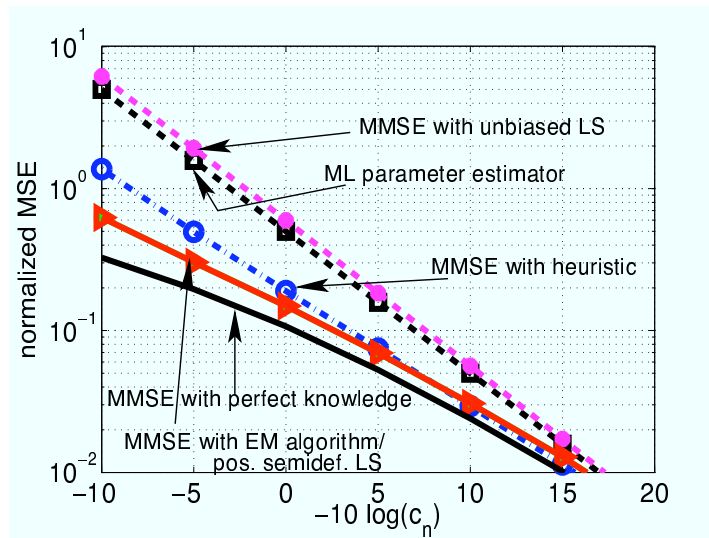


**Abb. 1.** Eigenvalues  $\lambda_i/\lambda_1$  of true parameter covariance matrix  $\mathbf{C}_h$  and different estimates  $\hat{\mathbf{C}}_h$  ( $B = 100$ ,  $c_n = 1$ ). Solid horizontal line shows negative value of loading, i.e.,  $-\hat{c}_n^{\text{LS}}/(N\lambda_1)$  (cf. Eq. 27), in the MMSE estimator to illustrate problem of ill-conditioned inverse in (26).

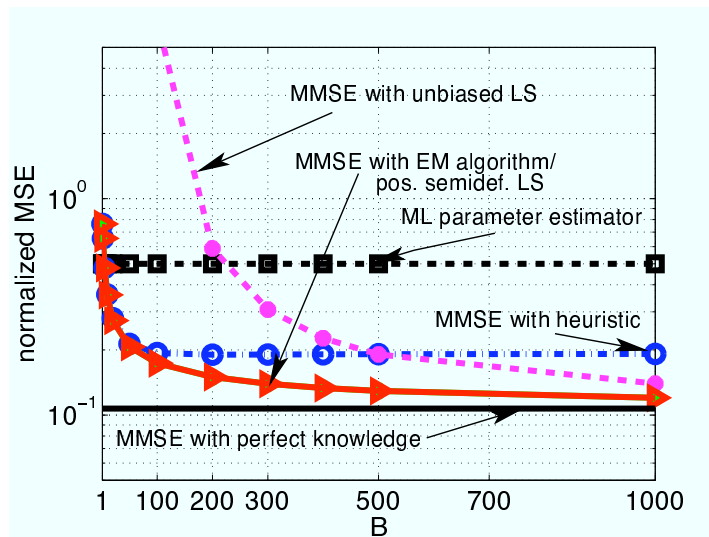
## 6 Conclusions

Knowledge of the second order moments of the system parameters and noise is important for a wide class of signal processing algorithms. We presented estimators for these moments based on the ML principle and least-squares approximation of the sample covariance matrix of the observed signal, which exploit the linear structure of this covariance matrix. The most promising solutions ensure that all estimates are positive semidefinite.





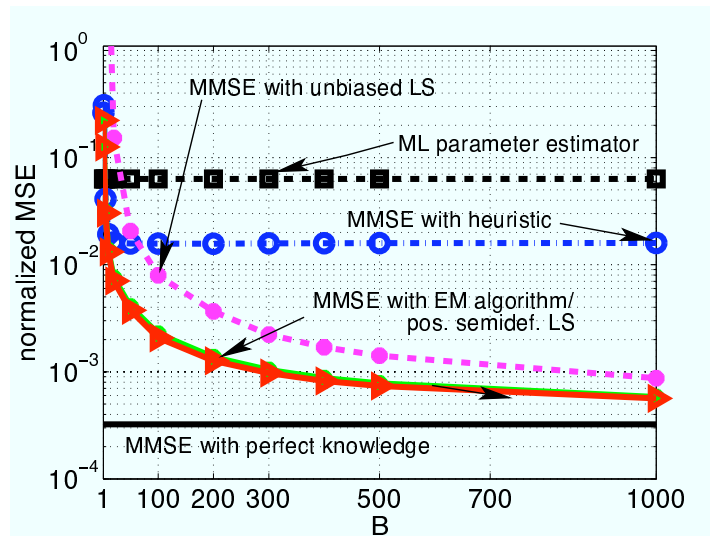
**Abb. 2.** Normalized MSE of  $\hat{\mathbf{h}}[q]$  vs.  $\text{SNR} = -10 \log_{10} c_n$  for  $B = 200$  and scenario 1.



**Abb. 3.** Normalized MSE of  $\hat{\mathbf{h}}[q]$  vs.  $B$  for  $c_n = 1$  and scenario 1.

## Literatur

1. T. W. Anderson. Statistical inference for covariance matrices with linear structure. In *Proc. of the Second International Symposium on Multivariate Analysis*, volume 2, pages 55–66, 1968.
2. J. P. Burg, D. G. Luenberger, and D. L. Wenger. Estimation of structured covariance matrices. *Proc. IEEE*, 70(9):500–514, Sept. 1982.
3. S. Boyd and L. Vandenberghe. *Convex Optimization*. Cambridge University Press, 2004.
4. N. Czink, G. Matz, D. Seethaler, and F. Hlawatsch. Improved MMSE Estimation of Correlated MIMO Channels using a Structured Correlation Estimator. In *Proceedings of SPAWC*, New York City, U.S.A., June 2005.



**Abb. 4.** Normalized MSE of  $\hat{h}[q]$  vs.  $B$  for  $c_n = 1$  and scenario 2.

5. F. A. Dietrich, T. Ivanov, and W. Utschick. Estimation of Channel and Noise Correlations for MIMO Channel Estimation. In *Proc. of the Workshop on Smart Antennas*, Germany, 2006.
6. F. A. Dietrich and W. Utschick. Pilot-Assisted Channel Estimation Based on Second-Order Statistics. *IEEE Trans. Signal Processing*, 53(3):1178–1193, March 2005.
7. J. A. Fessler and A. O. Hero. Space-alternating generalized expectation-maximization algorithm. *IEEE Trans. Signal Processing*, 42(10):2664–2677, Oct. 1994.
8. N. J. Higham. *Applications of Matrix Theory*, chapter Matrix Nearness Problems and Applications, pages 1–27. Oxford University Press, 1989.
9. T. Ivanov and F. Dietrich. Estimation of Second Order Channel and Noise Statistics in Wireless Communications. Technical report, Munich University of Technology, April 2005.
10. Steven M. Kay. *Fundamentals of Statistical Signal Processing - Estimation Theory*. PTR Prentice Hall, 1st edition, 1993.
11. G. McLachlan and T. Krishnan. *The EM algorithm and extensions. Wiley series in probability and statistics*. John Wiley & Sons, 1997.
12. Louis L. Scharf. *Statistical Signal Processing: Detection, Estimation, and Time Series Analysis*. Addison-Wesley, 1991.
13. D. Slepian. Prolate Spheroidal Wave Functions, Fourier Analysis, and Uncertainty—V: The Discrete Case. *The Bell System Technical Journal*, 57(5):1371–1430, May-June 1978.
14. P. Stoica and T. Söderström. On reparametrization of loss functions used in estimation and the invariance principle. *Signal Processing*, 17(4):383–387, Aug. 1989.

# Informationsfusion für verteilte Systeme

Dietrich Brunn, Felix Sawo und Uwe D. Hanebeck


Lehrstuhl für Intelligente Sensor-Aktor-Systeme (ISAS),  
Institut für Technische Informatik, Universität Karlsruhe (TH)

**Zusammenfassung.** Dieser Beitrag befasst sich mit modellbasierten Methoden zur Vermessung verteilter physikalischer Phänomene. Diese Methoden zeichnen sich durch eine systematische Behandlung stochastischer Unsicherheiten aus, so dass neben der Rekonstruktion der vollständigen Wahrscheinlichkeitsdichte der relevanten Größen aus einer geringen Anzahl von zeit-, orts- und wertdiskreten Messungen auch die Generierung optimaler Messsequenzen möglich ist. Es wird dargestellt, wie eine Beschreibung für ein verteilt-parametrisches System in Form einer partiellen Differentialgleichung, welche einen unendlich-dimensionalen Zustandsraum beschreibt, in eine konzentriert-parametrische Form konvertiert wird. Diese kann als Grundlage für den Entwurf klassischer Schätzer, wie z. B. des Kalman-Filters, dienen. Ferner wird eine Methode zur Sensoreinsatzplanung vorgestellt, mit der eine optimale Sequenz von Messparametern bestimmt werden kann, um mit einem minimalen Messaufwand die Unsicherheit auf ein gewünschtes Maß zu reduzieren. Die Anwendung dieser Methoden wird an zwei Beispielen, einer Temperaturverteilung und der Verformung einer Führungsschiene, demonstriert. Zusätzlich werden die Herausforderungen bei der Behandlung nichtlinearer Systeme und die Probleme bei der dezentralen Verarbeitung, wie sie typischerweise beim Einsatz von Sensornetzwerken auftreten, diskutiert.

## 1 Einleitung

Räumlich verteilte Systeme zeichnen sich dadurch aus, dass die betrachteten Größen sich mit der Zeit und mit dem Ort ändern. Typische Beispiele sind Temperaturverteilungen in Räumen und Festkörpern, Verteilungen von Schadstoffkonzentrationen in Gewässern oder Verformungen von Maschinenteilen.

Die Beobachtung, Überwachung und Vermessung von räumlich konzentrierten Größen, wie z. B. elektrische Spannungen oder Fahrzeuggeschwindigkeiten, sind die klassischen Kernaufgaben der Zustandsschätzung. Dabei wird aus Messungen gewonnene Information mit bereits vorhandener Information fusioniert. Für diese Fusion gibt es eine Vielzahl von Verfahren [15], wie das Kalman-Filter [8] und seine Derivate, Partikelfilter [4] und analytische Filter, z. B. Filter auf Basis von Gaußmischverteilungen [1, 7]. Eine Voraussetzung für die Anwendung solcher Verfahren ist eine konzentriert-parametrische endlich-dimensionale Systembeschreibung. Für verteilte Systeme ist diese Annahme allerdings in der Regel nicht erfüllt.



**Abb. 1.** Mögliches Anwendungsszenario zur Beobachtung und Vermessung eines verteilten Phänomens mit Hilfe von zeit-, orts- und wertdiskreten Messungen.

In diesem Beitrag werden deshalb neuartige Verfahren zur modellbasierten Rekonstruktion von physikalischen verteilten Systemen, auch verteilte Phänomene genannt, vorgestellt. Dabei soll aus zeit-, orts- und wertdiskreten Messungen das gesamte Phänomen, welches durch sogenannte Systemzustände charakterisiert wird, effizient rekonstruiert werden. Anhand von zwei anschaulichen Beispielanwendungen, nämlich einer Temperaturverteilung und der Verformung einer Führungsschiene, werden die neu entwickelten Ansätze zur Rekonstruktion verteilter Phänomene dargestellt und diskutiert.

Eine Anwendung für die Informationsfusion von verteilten Systemen sind Sensornetzwerke. Abbildung 1 zeigt schematisch ein Einsatzszenario für ein Sensornetzwerk: Einzelne Sensorknoten, welche die Schadstoffkonzentrationsmessungen durchführen können, werden im Meer ausgebracht. Mit Hilfe dieser Messungen soll eine Schadstoffverteilung im gesamten zu überwachenden Gebiet bestimmt werden. Aus wirtschaftlichen Gründen sollte die Anzahl der Sensorknoten, sowie die Anzahl der Messungen, so gering wie möglich gehalten werden. Allgemein gilt, je geringer dabei die Messrate ist, desto länger ist die Lebensdauer eines einzelnen autonomen Knotens. Es muss also ein Kompromiss zwischen Genauigkeit und Realisierungsaufwand gefunden werden.

Es werden Methoden vorgestellt, die es ermöglichen, durch Einbeziehung von (physikalischem) Hintergrundwissen in Form eines physikalischen Modells gute Ergebnisse bei vertretbarem Messaufwand zu erreichen. Durch diese Rekonstruktion ist es möglich, die charakterischen Größen zu bestimmen, welche das verteilte Phänomen an *jedem Ort* und zu *jedem Zeitpunkt* vollständig beschreiben. Somit können also auch Aussagen über das Phänomen an Nichtmesspunkten getroffen werden und außerdem das zukünftige Verhalten prädiziert werden.

Weiterhin zeichnen sich diese Methoden durch eine systematische Behandlung stochastischer Unsicherheiten aus, die natürlicherweise in den Messungen, aber auch bedingt durch die Art der Modellierung, auftreten. Durch diese Betrachtungsweise ist es möglich, neben der Rekonstruktion der vollständigen Wahrscheinlichkeitsdichte der relevanten Größen aus einer geringen Anzahl von zeit-, orts- und wertdiskreten Messungen auch optimale Messsequenzen in Bezug auf die Messorte und die Messzeitpunkte zu generieren. Die prinzipielle Struktur der modellbasierten Rekonstruktion verteilter Phänomene wird anhand eines möglichen Anwendungsszenario in Abbildung 1 dargestellt.

Der Beitrag ist wie folgt gegliedert: Im folgenden Abschnitt wird auf die Beschreibung von räumlich verteilten physikalischen Phänomenen durch partielle Differentialgleichungen (PDE<sup>1</sup>) eingegangen. Danach werden in Abschnitt 3 Methoden vorgestellt, welche verteilt-parametrische Systeme in konzentriert-parametrische Systeme konvertieren. Die Methoden zeichnen sich durch eine vernünftige Approximation des auftretenden unendlich-dimensionalen Zustandes durch einen endlich-dimensionalen Zustandsvektor aus. Dadurch können die klassischen Schätzverfahren angewendet werden, wie Abschnitt 4 aufzeigt. Die Methode zur Bestimmung von geeigneten Messparametern wird in Abschnitt 5 vorgestellt. Abschnitt 6 diskutiert Herausforderungen, die bei nichtlinearen Systemen und bei dezentraler Verarbeitung entstehen. Der Beitrag schließt mit einer Zusammenfassung und einem Ausblick in Abschnitt 7.

## 2 Beschreibung räumlich verteilter physikalischer Phänomene

Es gibt eine Vielzahl von Methoden, um physikalische Phänomene mathematisch zu beschreiben. In diesem Artikel werden physikalische Phänomene als entweder statische oder dynamische Systeme und als entweder konzentriert-parametrische oder verteilt-parametrische Systeme klassifiziert. Ein statisches System verändert sich über die Zeit nicht, aber im Fall eines verteilt-parametrischen Systems sehr wohl über seine Ortsvariablen, währenddessen sich der Zustand eines dynamischen Systems zusätzlich mit der Zeit ändert.

Konzentriert-parametrische Systeme zeichnen sich dadurch aus, dass ihre Parameter in einzelnen Raumpunkten *konzentriert* sind, d. h. die Parameter hängen nur von der Zeit, nicht aber vom Ort ab. Solche physikalischen Systeme lassen sich durch ein System gewöhnlicher Differentialgleichungen (DGL)

$$\mathbb{L}\left(t, \underline{x}, \underline{\dot{x}}, \dots, \underline{x}^{(i)}\right) = \underline{s}(t)$$

beschreiben.  $\underline{x}$  ist der Zustandsvektor,  $\underline{x}^{(i)}$  dessen  $i$ -te zeitliche Ableitung,  $\underline{s}(t)$  der Eingangsvektor und  $\mathbb{L}(\cdot)$  eine lineare Funktion. Ein Beispiel für ein konzentriert-parametrisches System ist das Flugverhalten eines Vogelschwarms. Position und Geschwindigkeit der einzelnen Vögel beschreiben den Zustand dieses Phänomens in erster Näherung vollständig.

<sup>1</sup> engl.: *partial differential equation*

Verteilt-parametrische Systeme haben die Eigenschaft, dass ihre Parameter nicht nur alleine von der Zeit abhängen. Vielmehr sind diese zusätzlich räumlich verschmiert, d. h. vom Ort abhängig. Zur Beschreibung eines räumlich verteilten Phänomens  $p(z, t)$ , wobei  $z$  den Ort angibt, werden Systeme von partiellen Differentialgleichungen (PDEs)

$$\mathbb{L}\left(p(z, t), \frac{\partial p(z, t)}{\partial t}, \dots, \frac{\partial^i p(z, t)}{\partial t^i}, \frac{\partial p(z, t)}{\partial z}, \dots, \frac{\partial^j p(z, t)}{\partial z^j}\right) = s(z, t) \quad (1)$$

verwendet. Diese beschreiben die Wechselwirkung zweier zeitlich und räumlich benachbarter Punkte in Abhängigkeit von einer Eingangsfunktion  $s(z, t)$ .

Ein typisches Beispiel für ein verteilt-parametrisches System ist eine Schadstoffwolke. Im Gegensatz zum Vogelschwarm gibt es an jedem kontinuierlichen Raumpunkt eine Schadstoffkonzentration. Die Auswirkungen von Konzentrationsunterschieden wird durch die Diffusions-PDE beschrieben.

Die allgemeine Lösung  $p(z, t, \underline{x}^\infty)$  von Gl. (1) in Abhängigkeit vom Parameter- oder Zustandsvektor  $\underline{x}^\infty$  ist im Allgemeinen unendlich-dimensional. Abschnitt 3 stellt Verfahren vor, wie  $\underline{x}^\infty$  durch einen endlich-dimensionalen Vektor approximiert werden kann.

### 3 Modellkonversion

Wie im vorherigen Abschnitt erläutert, führt die Modellierung eines verteilten Phänomens im Allgemeinen auf eine verteilt-parametrische Systembeschreibung. Da allerdings eine direkte Verwendung dieser Systembeschreibung für Rekonstruktionszwecke sehr komplex ist, ist typischerweise eine Konversion in ein endlich-dimensionales Zustandsraummodell zweckmäßig. In diesem Abschnitt wird nun detailliert auf die Konversion eines unendlich-dimensionalen Systems in ein endlich-dimensionales System eingegangen. Für die spätere Rekonstruktion stellt dies ein essentiellen Schritt dar, da sich ein verteilt-parametrisches System im Allgemeinen nicht mit einer endlichen Anzahl von Parametern darstellen lässt.


Die Kernidee des hier vorgestellten Ansatzes basiert darauf, das verteilte Phänomen  $p(z, t)$  durch eine Reihe

$$p(z, t) = \sum_{i=0}^{\infty} \Psi_i(z) x_i(t) \quad (2)$$

von orstabhängigen Basisfunktionen  $\Psi_i(z)$  und ihren zugehörigen zeitveränderlichen Gewichtsfunktion  $x_i(t)$  darzustellen. Dies ermöglicht eine effiziente Rekonstruktion von  $p(z, t)$ . Um ein endlich-dimensionales System zu erhalten, wird die Reihe bei  $N_{\text{dof}}$  abgebrochen, so dass nur noch der konzentriert-parametrische Zustandsvektor

$$\underline{x}(t) = [x_0(t), \dots, x_{\text{dof}}(t)]^T$$

bestimmt werden muss. Dafür existieren in der klassischen Schätztheorie eine Vielzahl von Verfahren.



**Abb. 2.** Führungsschiene mit Höenschlag, welche an diskreten Punkten befestigt ist.

Die Bestimmung des Approximationsfehlers für gegebenes  $N_{\text{dof}}$  ist ein noch ungelöstes Problem. Lediglich für den Spezialfall, dass die Randbedingungen das verteilte Phänomen  $p(z, t)$  so einschränken, dass die Reihe Gl. (2) an sich endlich ist, können Aussagen über den Approximationsfehler getroffen werden.

Im nächsten Abschnitt wird zunächst der Spezialfall von statischen verteilt-parametrischen Systemen betrachtet. Abschnitt 3.2 widmet sich dann dynamischen verteilt-parametrischen Systemen.

### 3.1 Statische verteilt-parametrische Systeme

Statische verteilt-parametrische Systeme sind bei Kalibrieraufgaben von Werkzeugmaschinen von besonderer Bedeutung. Ein typisches Beispiel für solche Anwendungen ist die effiziente Vermessung einer verformten Führungsschiene in Werkzeugmaschinen, siehe Abbildung 2. Für den hier betrachteten statischen Fall verschwinden die zeitlichen Ableitungen und somit vereinfacht sich die PDE Gl. (1) zu

$$\mathbb{L}\left(p(z), \frac{\partial p(z)}{\partial z}, \dots, \frac{\partial^j p(z)}{\partial z^j}\right) = s(z),$$

und die Funktionsreihe Gl. (2) wird zu

$$\tilde{p}(z) = \sum_{i=0}^{N_{\text{dof}}-1} \Psi_i(z) x_i . \quad (3)$$

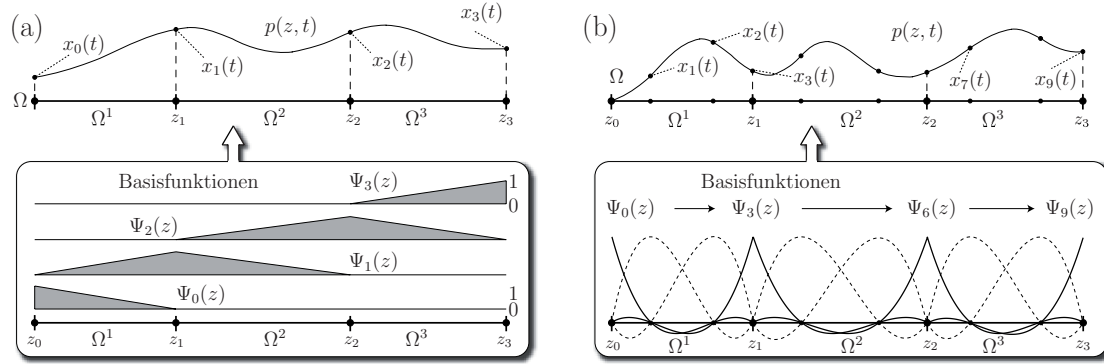
Betrachtet man das Beispiel der verformten Führungsschiene mit diskreten Befestigungspunkten näher, erhält man für kleine Durchbiegungen  $\partial p(z)/\partial z \ll 1$  die eindimensionale PDE

$$EI_0 \frac{\partial^4 p(z)}{\partial z^4} = s(z) , \quad (4)$$

wobei  $E$  das Elastizitätsmodul und  $I_0$  das axiale Flächenmoment 2. Grades ist [5]. Es lässt sich zeigen, dass zwischen zwei Befestigungspunkten  $l$  und  $(l+1)$  die Lösung von Gl. (4)

$$p(z) = a_l + b_l(z - z_0) + c_l(z - z_0)^2 + d_l(z - z_0)^3 \quad (5)$$

ein kubisches Spline ist. In [3] wird gezeigt, dass sich das kubische Spline Gl. (5) in die Form der Funktionsreihe Gl. (3) überführen lässt.



**Abb. 3.** Zerlegung des Lösungsraums  $\Omega$  in Teilräume  $\Omega^i$  und mögliche Basisfunktionen zur Lösungsapproximation: (a) Lineare Funktionen; (b) Legendre-Polynome.

### 3.2 Dynamische verteilt-parametrische Systeme

Wie schon erwähnt, kann ein zeitlich veränderliches und räumlich verteiltes physikalisches Phänomen typischerweise durch partielle Differentialgleichungen (PDE) beschrieben werden, die *sowohl räumliche Abhängigkeiten als auch zeitliche* Veränderungen berücksichtigen. Zum besseren Verständnis wird in diesem Beitrag exemplarisch eine eindimensionale lineare PDE

$$\mathbb{L} \left( p(z, t), \frac{\partial p(z, t)}{\partial t}, \dots, \frac{\partial^i p(z, t)}{\partial t^i}, \frac{\partial p(z, t)}{\partial z}, \dots, \frac{\partial^j p(z, t)}{\partial z^j} \right) = s(z, t) \quad (6)$$

betrachtet, wobei  $s(z, t)$  die äußere Anregungsfunktion (Wärmequellen, Wärmesenken, äußere Kräfte und Momente) beschreibt. Unter Einbeziehung von Randbedingungen, wie z. B. festen Randtemperaturen  $p(z, t), z \in \partial\Omega$ , und Anfangsbedingungen  $p(z, t = 0)$  kann dann für eine Vielzahl von relevanten Problemen eine Lösung  $p(z, t)$  der PDE gefunden werden, die das Phänomen abhängig vom Ort  $z$  und Zeit  $t$  beschreibt.

Für die Konversion des *dynamischen* verteilt-parametrischen Systems in ein konzentriert-parametrisches System stehen eine Vielzahl von Methoden zur Verfügung: die Methode der finiten Differenzen (FDM) [2], die Methode der finiten Elemente (FEM) und die *Spectral-Element-Methode* (SEM) [9]. Bei diesen Verfahren werden als Basisfunktionen  $\Psi_i(z)$  in der Regel Fourierreihen (Modalanalyse) [16], orthogonale Polynome, Hermite-Polynome oder Tschebyscheff-Polynome verwendet. Diese sind aber nicht über das gesamte Berechnungsgebiet  $\Omega$  definiert, sondern nur über ein oder mehrere nicht überlappende Teilgebiete  $\Omega_i$ ; siehe Abbildung 3. Dadurch wird die Modellierung von komplexen Geometrien von  $\Omega$  und komplexen Randbedingungen  $\partial\Omega$  erleichtert. Ferner ermöglicht dies die Modellierung nichtlinearer PDEs. Damit erhält man die orts- und zeitabhängige Funktionenreihe Gl. (2), mit der die PDE Gl. (6) in ein gewöhnliches Differentialgleichungssystem erster Ordnung

$$\dot{\underline{x}}(t) = \mathbb{L}(t, \underline{x}(t), \underline{u}(t)) \quad (7)$$



konvertiert werden kann.

Das entstandene konzentriert-parametrische System Gl. (7) kann nun zur Simulation des unterlagerten verteilten Systems verwendet werden, indem die Entwicklung des endlich-dimensionalen Zustands  $\underline{x}(t)$  über der Zeit berechnet wird. Zu diesem Zweck wird ein geeigneter Löser für die kontinuierliche Systemgleichung Gl. (7) verwendet. Die gesuchten ortskontinuierlichen Werte  $p(z, t)$  des unterlagerten verteilten Systems werden dann über die Ausgangsgleichung aus dem Zustandsvektor  $\underline{x}(t)$  berechnet.

Unser Ziel ist nun aber nicht die Simulation des verteilten Systems, sondern die Rekonstruktion des gesamten ortskontinuierlichen Phänomens aus indirekt gegebenen zeit-, orts- und wertdiskreten verrauschten Messungen. Dabei werden im Allgemeinen geeignet parametrisierte Wahrscheinlichkeitsdichten zur Beschreibung der Unsicherheit in den geschätzten Zuständen verwendet.

Selbstverständlich kann zur zeitlichen Fortschreibung dieses erweiterten Zustandsvektors die kontinuierliche Systemgleichung Gl. (7) verwendet werden. Aus Komplexitätsgründen bietet es sich aber an, zunächst eine Zeitdiskretisierung der Systemgleichung Gl. (7) in einer geeigneten Form vorzunehmen und das resultierende Differenzgleichungssystem erster Ordnung schließlich zur Fortschreibung dieses erweiterten Zustandsvektors über diskrete Zeitpunkte zu verwenden. Durch eine Zeitdiskretisierung erhält man also eine klassische zeitdiskrete lineare Zustandsgleichung

$$\underline{x}_{k+1} = \mathbf{A}_k \underline{x}_k + \mathbf{B}_k \underline{u}_k + \underline{w}_k \quad , \quad (8)$$


wobei  $\mathbf{A}_k$  die quadratische Systemmatrix,  $\mathbf{B}_k$  die Eingangsmatrix und  $\underline{u}_k$  der Eingangsvektor ist. Der Rauschterm  $\underline{w}_k$  wurde hinzugefügt, um den Modellierungsungenauigkeiten Rechnung zu tragen.

Genau diese Berechnung der Unsicherheitsterme stellt eine der Hauptschwierigkeiten bei der Konversion in ein endlich-dimensionales System dar. Dies betrifft sowohl die exogenen Störungen, also die Umrechnung von verteilten Störungen in konzentrierte Störquellen, als auch die endogenen Störquellen, d. h. die Berücksichtigung von Modellierungs- und Approximationsfehlern. Im ersten Fall handelt es sich meistens um stochastische Größen, wobei im zweiten Fall typischerweise eine mengenbasierte Beschreibung angebracht ist.

Im nächsten Abschnitt wird ein Wärmestab als Beispiel für ein dynamisches verteilt-parametrisches System diskutiert. Eine ausführliche Beschreibung zur Konvertierung des dynamischen verteilt-parametrischen Systems in eine zeitdiskrete Zustandsgleichung findet sich in [14].

## 4 Modellbasierte Rekonstruktion verteilter Systeme

Für eine modellbasierte Rekonstruktion eines verteilten Phänomens benötigt man neben der Systemgleichung noch eine Messgleichung, welche die Wirkung des Phänomens auf konkrete Messungen beschreibt (siehe Abbildung 4). Mit der im vorherigen Abschnitt aufgezeigten Beschreibung verteilter Phänomene ist es nun möglich, aus zeit-, orts- und wertdiskreten Messungen auf das gesamte Phänomen zu schließen.



**Abb. 4.** Schema und Bestandteile der modellbasierten Rekonstruktion verteilter Phänomene: (a) Systemmodell; (b) Messmodell.

Dazu benötigt man zunächst eine Abbildung, welche den Zusammenhang einer Messung  $\hat{\underline{y}}_k \in \mathbb{R}^n$  und des verteilten Phänomens  $p(z, t_k)$  beschreibt. Die so genannte Messgleichung

$$\hat{\underline{y}}_k = \underline{h}_k(p(\underline{z}, t_k)) + \underline{v}_k \quad (9)$$

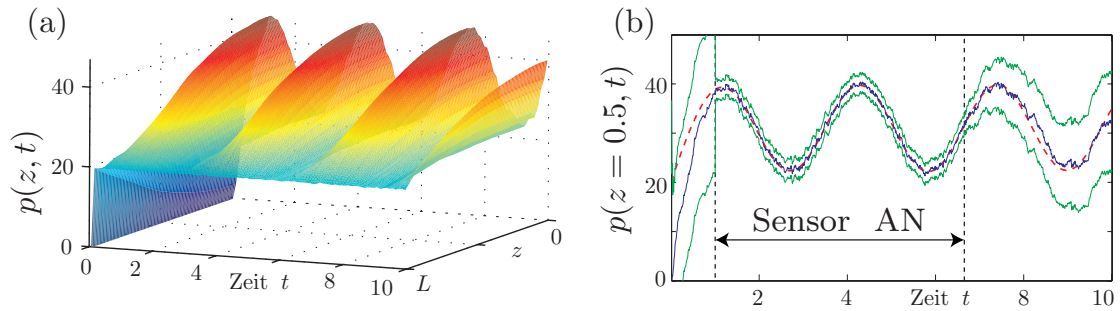
bildet mit der Funktion  $\underline{h}_k(\cdot)$  das verteilte Phänomen  $p(z, t_k)$  auf die Messung  $\hat{\underline{y}}_k$  ab.  $\underline{v}_k$  ist das Messrauschen, welches die Ungenauigkeiten, die bei einer realen Messung entstehen, subsummiert. Selbst für recht einfache in der Praxis vorkommende Messprinzipien ist die Abbildungsfunktion  $\underline{h}_k(\cdot)$  nichtlinear, was folglich die Anwendung von nichtlinearen Schätzverfahren erforderlich macht.

Neben der Messgleichung Gl. (9) benötigt man im Rahmen einer Vorwärtsmodellierung noch eine Ausgangsgleichung, welche die punktuell gemessenen Werte des verteilten Phänomens  $p(\underline{z}, t_k)$  direkt auf den endlich-dimensionalen Zustandsvektor  $\underline{x}_k$  der PDE abbildet:

$$p(\underline{z}, t_k) = \mathbf{C}_k \underline{x}_k + \underline{v}_k^* \quad (10)$$

wobei  $\underline{v}_k^*$  die Unsicherheiten durch die Messung und durch die Approximation beinhaltet.

Wird die Ausgangsgleichung Gl. (10) in die Messgleichung Gl. (9) eingesetzt, erhält man das vollständige Messmodell, welches es ermöglicht, mit zeit-, orts-



**Abb. 5.** Ergebnis der modellbasierten Rekonstruktion einer eindimensionalen Wärme­gleichung.

und wertdiskreten Messwerten unter Zuhilfenahme klassischer Schätzverfahren eine verbesserte Schätzung des Zustandsvektors  $\underline{x}_k$  zu ermitteln. Für lineare Gleichungen liefert das wohlbekannte Kalman-Filter [8] exakte Lösungen. Wohingegen für nichtlineare Gleichungen approximative Schätzverfahren, wie Extended Kalman-Filter [11] und Partikelfilter, eingesetzt werden müssen. Aufgrund der Eigenschaft eines universellen Approximators, eignen sich Gaussmischverteilungen besonders gut zur Approximation [7].

Am Beispiel des eindimensionalen Wärmeleiters mit der Länge  $L = 1$  wird nun ein verteiltes Phänomen mit Hilfe des geschätzten Zustands eines fortschreitenden Systemmodells rekonstruiert und prädiziert, wobei die äußere Anregung die Form  $s(z, t) = 30 \sin(2t) + 30$  hat. Der geschätzte Zustand des Systemmodells wird mittels aktueller Messungen von Zeit zu Zeit an das wahre System angepasst. Dabei wird angenommen, dass das Sensornetzwerk lediglich aus zwei Sensoren an den Positionen  $z_{s1} = 0,25$  und  $z_{s2} = 0,75$  besteht.

Der auf der Basis der physikalischen Modellierung und der Messungen rekonstruierte Lösungsverlauf  $p(z, t)$  der eindimensionalen Wärme­gleichung ist in Abbildung 5(a) dargestellt. In Abbildung 5(b) ist der rekonstruierte Lösungsverlauf für einen Nicht-Messpunkt ( $z = 0,5$ ) dargestellt. Dabei ist der rote Funktionsverlauf die analytische Lösung des Wärmeleiters, der blaue Funktionsverlauf der vom Kalman-Filter geschätzte Wert und der grüne Funktionsverlauf stellt das  $3\sigma$ -Konfidenzintervall dar. Es ist deutlich, dass durch einen modellbasierten Ansatz bei der Rekonstruktion die Genauigkeit des Schätzergebnisses drastisch verbessert werden kann, insbesondere an Nicht-Messpunkten.

## 5 Sensoreinsatzplanung

Ziel der Sensoreinsatzplanung ist es, bestmögliche Messparameter für zukünftige Messungen zu bestimmen. Bestmöglich heißt hier, maximaler Informationsgewinn unter Nebenbedingungen, wie z. B. begrenzter Energieverbrauch. Messparameter können z. B. der zu verwendende Sensorknoten in einem Sensornetz sein oder die Position eines Messkopfes.

Das Prinzip der Sensoreinsatzplanung soll am Beispiel der Vermessung einer verformten Führungsschiene (Abbildung 2, Abschnitt 3.1) aus [3] erklärt werden.

Es wird der zweidimensionale Fall  $\underline{p}(z, \underline{x}) = [p_x(z, \underline{x}) \ p_y(z, \underline{x})]^T$  für Höhen- und Seitenschlag mit gaußverteilten Unsicherheiten betrachtet. Die Schiene ist an sechs Stellen punktuell befestigt. Somit ist  $\underline{x}$  sechsdimensional und ebenfalls gaußverteilt. Die Verformung der Schiene lässt sich durch den Erwartungswert  $\hat{\underline{x}}$  und die Kovarianzmatrix  $\mathbf{C}$  von  $\underline{x}$  vollständig beschreiben.

Ferner sind Punktmessungen an beliebigen Positionen  $z_M$  mit additivem Gaußrauschen möglich. Abbildung 6 zeigt eine initiale Schätzung  $\underline{p}(z, \underline{x}_0)$  für das zweidimensionale Spline mit zugehörigem Unsicherheitsschlauch. Die initiale Schätzung ist hier eine Gerade, welche blau gekennzeichnet ist. Der Unsicherheitsschlauch ist die Verallgemeinerung des  $1\sigma$ -Konfidenzintervalls der eindimensionalen Gaußdichte. Der Schnitt entlang eines Punkts  $z_0$ , welcher immer eine Ellipse ist, ist die minimale Fläche, in welcher der wahre Wert mit einer Wahrscheinlichkeit von 39,5% liegt.

Hier ist das Ziel der Sensoreinsatzplanung, mit einer möglichst geringen Anzahl an Messungen die Schiene mit einer möglichst hohen Genauigkeit zu vermessen. Dazu wird für die  $k$ -te Messung ein Gütemaß

$$J_k = \int_{\Omega} \text{Var}\{p_x(z, \underline{x}_k)\} + \text{Var}\{p_y(z, \underline{x}_k)\} dz$$

definiert, welches die ortskontinuierliche Varianz von  $p_x$  und  $p_y$  über das Spline aufintegriert. Je kleiner das Gütemaß  $J_k$  ist, desto besser ist die Qualität der Schätzung und desto schmaler der Unsicherheitsschlauch.

Das Vorgehen bei der Sensoreinsatzplanung beginnt damit, dass aus der aktuellen Schätzung  $(\hat{\underline{x}}_k, \mathbf{C}_k)$  das Gütemaß  $J_{k+1}(z_M, \hat{\underline{x}}_k, \mathbf{C}_k)$  in Abhängigkeit von der Messposition  $z_M$  prädiziert wird. Abbildung 6 zeigt das prädizierte Gütemaß  $J_1(z_M, \hat{\underline{x}}_0, \mathbf{C}_0)$  für ein zweidimensionales Spline.

Dann wird die beste Messposition

$$z_{M,\text{opt}} = \arg \min_{z_M} \{J_{k+1}(z_M, \hat{\underline{x}}_k, \mathbf{C}_k)\}$$

bestimmt, welches dann als Messparameter für die  $k + 1$  Messung verwendet wird. Danach wird die Messung durchgeführt und  $J_{k+2}$  bestimmt. Es können natürlich auch  $l$  zukünftige  $z_{M,\text{opt}}$  berechnet werden und dann  $l$  mal gemessen werden.

Abbildung 6 zeigt das Minimum bei  $z_{M,\text{opt}} = 1,5$  und Abbildung 7 die Schätzung nach der entsprechenden Messung. Man sieht deutlich, dass sich an der Position  $z_M$  und deren Umgebung die Form der Splineapproximation sowie der Schlauchdurchmesser geändert haben. Außerdem ist in der Abbildung 7 das Ergebnis nach sechs Messungen abgebildet.

Im linearen Fall mit Gaußverteilungen ist die Berechnung recht einfach möglich, da das Kalman-Filter die Vorabberechnung der Kovarianzmatrix  $\mathbf{C}_k$  ohne Kenntnis des konkreten Messwerts  $y_k$  erlaubt. Für den Fall kubischer Splines lässt sich zeigen, dass  $J_{k+1}(z_M, \hat{\underline{x}}_k, \mathbf{C}_k)$  ein stückweise definiertes Polynom zwölfter Ordnung ist [3].

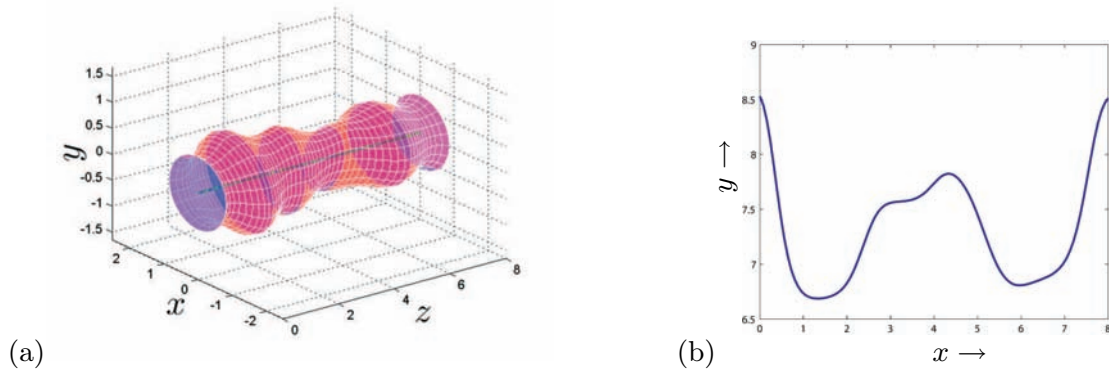


Abb. 6. (a) Initiale Schätzung; (b) zugehöriges Gütemaß.

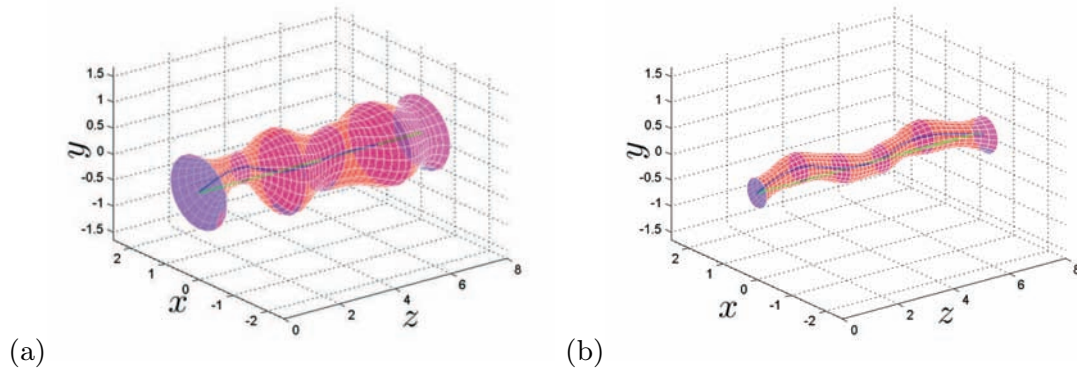
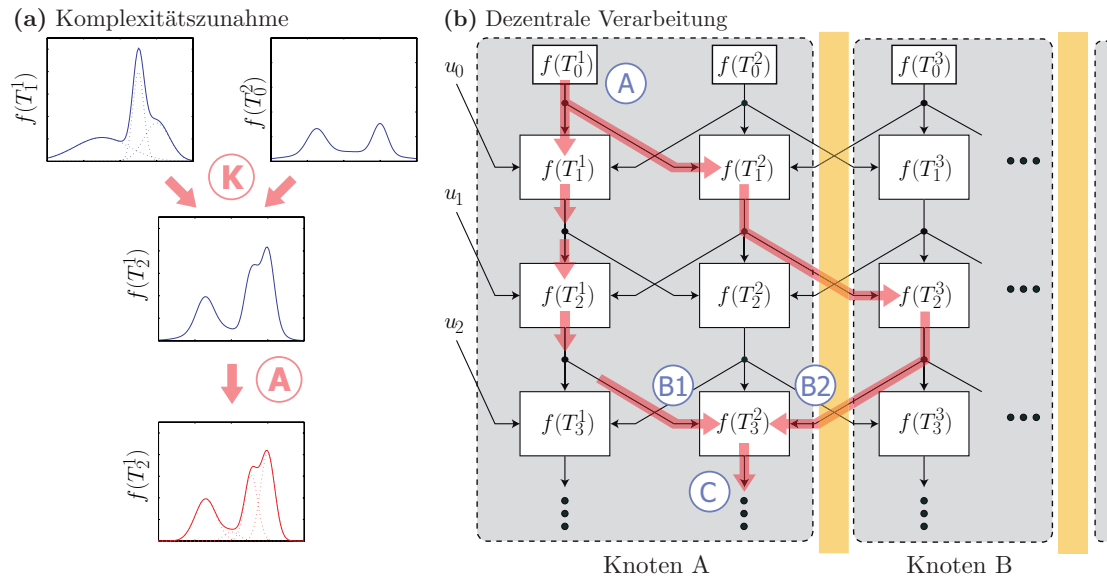


Abb. 7. (a) Schätzung nach einer Messung; (b) Schätzung nach sechs Messungen.

## 6 Dezentrale Verarbeitung und Komplexitätszunahme

Neben der Ausgangsgleichung benötigt man, wie im Abschnitt 4 gezeigt, im Rahmen einer Vorwärtsmodellierung noch eine Messgleichung, welche die Wirkung des Phänomens auf konkrete Messungen beschreibt, wobei diese im Allgemeinen nichtlinear mit dem Phänomen verknüpft sind. Damit ergibt sich bei einer rekursiven Verwendung von Messungen zum Zweck der Rekonstruktion selbst für den Fall einer linearen Systemgleichung und einer linearen Ausgangsgleichung bei einer exakten Berechnung ein Anwachsen der Komplexität der Wahrscheinlichkeitsdichten mit einer wachsender Anzahl an Messungen, siehe Abbildung 8(a). Im Allgemeinen ändert sich zudem der Typ der Dichtebeschreibung. Zur Durchführung einer effizienten rekursiven Verarbeitung ist eine Approximation der entstehenden Wahrscheinlichkeitsdichten also unumgänglich (Punkt A in Abbildung 8(a)). Das Ziel ist dabei eine Approximation mit einem generischen parametrischen Dichtetyp für alle Zeitschritte und Positionen, wobei die Anzahl der Parameter in Abhängigkeit von der zur Verfügung stehenden Rechenleistung nach oben begrenzt sein sollte.

Da bekannte parametrische Dichtedarstellungen typischerweise nicht abgeschlossen unter den im Netzwerk auftretenden Operationen sind, bestehen zwei



**Abb. 8.** Herausforderungen der Informationsfusion für verteilte Systeme: (a) Komplexitätszunahme; (b) dezentrale Verarbeitung.

Möglichkeiten zur Approximation. Einerseits könnte man die auftretenden Systeme approximieren, wobei beispielsweise eine Linearisierung in Frage käme. Dann könnten einfache Schätzverfahren, wie beispielsweise das erweiterte Kalman-Filter, zum Einsatz kommen, was aber bei stark nichtlinearen Systemen nicht zum gewünschten Ergebnis führt. Es ist daher meist besser, das Ergebnis des exakten Verarbeitungsschrittes für das Originalsystem in jedem Schritt zu approximieren. Zu diesem Zweck existiert eine Vielzahl von Schätzverfahren, wie beispielsweise das Partikelfilter [4].

Eine systematische Minimierung eines vorgegebenen Abstandsmaßes zwischen der wahren Dichte und einer generischen Dichteapproximation wird in [7] vorgeschlagen, wobei gleichzeitig die Anzahl der Parameter begrenzt wird. Die Berechnung der optimalen Dichteparameter ist ein kompliziertes Optimierungsproblem mit vielen lokalen Minima, so dass Standardoptimierungsverfahren in der Regel nicht zu befriedigenden Ergebnissen führen. Zur Lösung dieses Problems wurde in [7] deshalb ein progressives Schätzverfahren eingeführt, welches die notwendigen Verarbeitungsschritte progressiv durchführt. Am Beispiel der Auffrischung eines gegebenen Schätzwertes mit Hilfe einer Messung bedeutet dies konkret, dass die entsprechenden Informationen graduell mit Hilfe einer Homotopie eingebracht werden. Auf der Basis dieser Progression kann dann ein System gewöhnlicher Differentialgleichungen angegeben werden, welches die Variation der gesuchten Parameter beschreibt. Diese Differentialgleichungen werden nun an Stelle des originalen Optimierungsproblem über einem endlichen Intervall gelöst, woraus sich der gesuchte Parametervektor ergibt.

In einem Sensornetzwerk wird nun aus verschiedenen Gründen eine dezentrale Verarbeitung der Informationen in den einzelnen Knoten einer Verarbeitung in einem Zentralrechner vorgezogen. Aus Gründen einer beschränkten Kommu-

nikationskapazität und begrenzten Speicherressourcen können dabei die Abhängigkeiten zwischen den auf unterschiedlichen Knoten gespeicherten Teilschätzungen nicht aufrechterhalten werden und gehen verloren. Als Beispiel betrachten wir wieder das in Abbildung 8(b) dargestellte Netzwerk, in dem zwei Pfade vom Punkt  $A$  zum Punkt  $C$  dargestellt sind. Kombiniert man nun die an den Punkten  $B1$  und  $B2$  vorliegenden Informationen, so ist dazu deren Abhängigkeitsstruktur, also im Allgemeinen die Verbundwahrscheinlichkeitsdichte, erforderlich. Da einer der Pfade aber über den Knoten  $B$  verläuft, sind diese Abhängigkeiten verloren gegangen.

Typischerweise wird nun in diesem Fall eine konkrete Abhängigkeit der beiden Größen angenommen. Für eine Beschreibung mit den ersten beiden Momenten wird dabei ein konkreter Wert für den Korrelationskoeffizienten zwischen den beiden Größen verwendet, wobei meist von Unkorreliertheit ausgegangen wird. Diese Annahme ergibt aber eine ungerechtfertigt starke Verringerung der Unsicherheit, was beim Propagieren der Informationen durch das Netzwerk zu stark optimistischen Ergebnissen führt.

Für eine korrekte Kombination von mehreren unsicheren Informationen ist es also notwendig, alle möglichen Abhängigkeiten zu berücksichtigen. Für den Fall linearer Systeme mit Gaußschen Unsicherheiten ist dieses Problem weitestgehend gelöst [6].

Werden die vorliegenden Informationen durch beliebige Wahrscheinlichkeitsdichten beschrieben, so entspricht die Berücksichtigung aller möglichen Abhängigkeiten der Berechnung aller Verbunddichten, die diese Wahrscheinlichkeitsdichten als Marginaldichten besitzen. Da eine Verarbeitung aller möglichen Verbunddichten nicht möglich ist, wurde in [12, 13] vorgeschlagen, untere und obere Dichten zu verwenden, welche die Menge aller möglichen Dichten einschließen. Mit einer entsprechenden Modifikation des Verarbeitungsschritts [10] kann dann die Menge aller Ergebnisdichten berechnet werden, die wieder durch untere und obere Dichten dargestellt wird.

## 7 Schlussfolgerung und Ausblick

Dieser Beitrag befasst sich mit der Rekonstruktion von verteilten Phänomenen auf der Basis von gegebenen verteilt-parametrischen Modellen und zeit-, orts- und wertdiskreten Messungen. Neben einem tutoriellen Teil zur Einführung in die Problemstellung werden auch neue Ansätze und Verfahren dargestellt sowie einige Beispielanwendungen diskutiert.

Die Modellierung eines verteilten Phänomens führt im Allgemeinen auf eine verteilt-parametrische Systembeschreibung, welche typischerweise nicht direkt für Rekonstruktionszwecke geeignet ist. Deshalb ist eine Konversion in ein endlich-dimensionales Zustandsraummodell notwendig.

Im Fall eines *statischen* verteilt-parametrischen Systems ergibt sich dadurch ein statisches konzentriert-parametrisches System, welches den endlich-dimensionalen Zustandsvektor auf das ortskontinuierliche Phänomen abbildet. Im Fall der Konversion eines *dynamischen* verteilt-parametrischen Systems ergibt sich

zusätzlich zu dieser statischen Abbildung ein konzentriert-parametrisches dynamisches System, welches die zeitliche Entwicklung des unterlagerten verteilt-parametrischen Systems (approximativ) beschreibt. Dieses wird typischerweise in Form eines gewöhnlichen Differentialgleichungssystems erster Ordnung dargestellt. Für den praktisch relevanten Fall zeitdiskreter Messungen ergibt sich bei einem dynamischen verteilt-parametrischen System insgesamt also eine gemischt diskret-kontinuierliche konzentriert-parametrische Systembeschreibung bestehend aus einer zeitdiskreten Ausgangsgleichung und einer zeitkontinuierlichen Systemgleichung.

Aus der zeitlichen Entwicklung des entstandenen konzentriert-parametrischen Systems, welches durch einen endlich-dimensionalen Zustand charakterisiert wird, kann mit Hilfe der Ausgangsgleichung das gesamte unterlagerte verteilte Phänomen berechnet werden. Um nun aus den gegebenen zeit-, orts- und wertdiskreten verrauschten Messungen das Phänomen zu rekonstruieren, werden im Allgemeinen Wahrscheinlichkeitsdichten zur Beschreibung der Unsicherheit in den geschätzten Zuständen verwendet. Zur zeitlichen Fortschreibung dieser Wahrscheinlichkeitsdichten könnte prinzipiell direkt das kontinuierliche Differentialgleichungssystem verwendet werden, wobei dieses zur besseren Handhabbarkeit durch eine Zeitdiskretisierung in ein Differenzgleichungssystem erster Ordnung umgewandelt wird.

Bei der Konversion in ein endlich-dimensionales System ist eine Hauptschwierigkeit die Behandlung der verteilt auf das System einwirkenden Unsicherheiten. Hier steht eine durchgängige systematische Lösung insbesondere der Modellierungs- und Approximationsfehler noch aus und ist Gegenstand aktueller Forschung.

Neben der Ausgangsgleichung benötigt man im Rahmen einer Vorwärtsmodellierung noch eine Messgleichung, welche die Wirkung des Phänomens auf konkrete Messungen beschreibt, die im Allgemeinen nichtlinear mit dem Phänomen verknüpft sind. Damit ergibt sich bei einer rekursiven Verwendung von Messungen zum Zweck der Rekonstruktion selbst für den Fall einer linearen Systemgleichung und einer linearen Ausgangsgleichung bei einer exakten Berechnung ein Anwachsen der Komplexität der Wahrscheinlichkeitsdichten mit einer wachsender Anzahl an Messungen. Eine Approximation der entstehenden Wahrscheinlichkeitsdichten ist damit unumgänglich, wobei für diesen Zweck in [7] ein effizientes allgemeines Verfahren angegeben ist.

Im Fall der dezentralen Verarbeitung der Informationen in einem Sensornetzwerk können aus Gründen einer beschränkten Kommunikationskapazität und begrenzten Speicherressourcen die Korrelationen und Abhängigkeiten zwischen den einzelnen Zuständen nicht gespeichert werden. Da für eine korrekte Kombination von unsicheren Informationen aber Wissen über deren Abhängigkeitsstruktur beispielsweise in Form einer Verbundwahrscheinlichkeitsdichte unabdingbar ist, wurden Verfahren entwickelt, die eine konsistente Kombination mit unbekanntem Verbundwahrscheinlichkeitsdichten ermöglichen. Dies ist für den Fall linearer Systeme mit Gaußschen Unsicherheiten weitestgehend gelöst [6], erfordert nach



ersten vielversprechenden Ergebnissen für komplexere Wahrscheinlichkeitsdichten aber noch weitergehende Untersuchungen [12, 13].

Die in diesem Beitrag vorgestellten Verfahren zur Informationsfusion in verteilten Systemen basieren allesamt auf der approximativen Konversion des verteilten Systems in ein konzentriertes System, dessen Zustand dann mit Hilfe von Schätzverfahren für endlich-dimensionale Systeme rekonstruiert wird. Zukünftige Arbeiten werden sich mit der Entwicklung von Schätzverfahren für unendlich-dimensionale Systeme befassen, welche eine direkte Rekonstruktion des verteilten Systems ermöglichen.

## Literatur

1. D. L. Alspach und H. W. Sorenson. Nonlinear Bayesian estimation using Gaussian sum approximations. *IEEE Transactions on Automatic Control*, 17(4):439–448, 1972.
2. A. J. Baker. *Finite Element Computational Fluid Mechanics*. Taylor and Francis, 1983.
3. D. Brunn und U. D. Hanebeck. A model-based framework for optimal measurements in machine tool calibration. *IEEE International Conference on Robotics and Automation (ICRA '05)*, 2005.
4. A. Doucet, N. de Freitas und N. Gordon (Hrsg.). Sequential Monte Carlo methods in practice. In: *Statistics for Engineering and Information Science*. Springer-Verlag, 2001.
5. H. Dubbel. *Taschenbuch für den Maschinenbau*. Springer-Verlag Berlin, 20. edition, 2001.
6. U. D. Hanebeck und K. Briechle. New results for stochastic prediction and filtering with unknown correlations. In: *Proceedings of the IEEE Conference on Multisensor Fusion and Integration for Intelligent Systems (MFI'2001)*, 2001.
7. U. D. Hanebeck, K. Briechle und A. Rauh. Progressive Bayes: A new framework for nonlinear state estimation. In: *Proceedings of SPIE*, volume 5099. AeroSense Symposium, 2003.
8. R. E. Kalman. A new approach to linear filtering and prediction problems. *Transactions of the ASME Journal of Basic Engineering*, 1960.
9. G. Karniadakis und S. J. Sherwin. *Spectral/hp Element Methods for Computational Fluid Dynamics*. Oxford University Press, 2005.
10. V. Klumpp, D. Brunn und U. D. Hanebeck. Approximate nonlinear Bayesian estimation based on lower and upper densities. In: *9th International Conference on Information (Fusion 2006)*, 2006.
11. A. Papoulis. *Probability, Random Variables and Stochastic Processes*. McGraw-Hill, 1991.
12. F. Sawo, D. Brunn und U. D. Hanebeck. Parameterized joint densities with Gaussian and Gaussian mixture marginals. In: *9th International Conference on Information (Fusion 2006)*, 2006.
13. F. Sawo, D. Brunn und U. D. Hanebeck. Parameterized joint densities with Gaussian mixture marginals and their potential use in nonlinear robust estimation. In: *IEEE International Conference on Control Applications (CCA 2006)*, 2006.
14. F. Sawo, K. Roberts und U. D. Hanebeck. Bayesian estimation of distributed phenomena using discretized representations of partial differential equations. In:

*3rd International Conference on Informatics in Control, Automation and Robotics (ICINCO'06)*, 2006.

15. H. Tanizki. *Handbook of Statistics 21: Stochastic Processes and Simulation*, Kap. Nonlinear and Non-Gaussian State-Space Modeling with Monte Carlo Techniques: A Survey and Comparative Study. North-Holland, 2003.
16. H. Tao und T. S. Huang. Connected vibrations: A modal approach for non-rigid motion tracking. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, S. 735, 1998.

# Bildfusion

Michael Heizmann<sup>1</sup> und Fernando Puente León<sup>2</sup>

<sup>1</sup> Fraunhofer IITB Institut für Informations- und Datenverarbeitung,  
Fraunhoferstr. 1, D-76131 Karlsruhe

<sup>2</sup> Technische Universität München, Fachgebiet Verteilte Messsysteme,  
Theresienstr. 90/N5, D-80333 München

**Zusammenfassung.** Für viele Aufgaben der industriellen Sichtprüfung und der Umfeldwahrnehmung sind Aufnahme und Auswertung von Einzelbildern nicht ausreichend, da die interessierende Information gar nicht oder nur unzureichend mit einer Einzelaufnahme erfasst werden kann. In solchen Fällen kann die gewünschte Information oft dadurch erhalten werden, dass eine Serie von Bildern mit dem Ziel verknüpft wird, eine neue oder verbesserte Repräsentation von Bildinhalten oder -charakteristika zu gewinnen. Dieser Beitrag stellt wesentliche Aspekte der Fusion von Bilddaten dar. Zunächst werden Bildsensoren hinsichtlich ihrer fusionsrelevanten Eigenschaften charakterisiert. Danach werden mögliche Abstraktionsebenen, auf denen die Verknüpfung der Bilder stattfinden kann, sowie eine allgemeine Methodik zur Durchführung der Bildfusion dargestellt. Schließlich werden Beispiele erläutert, welche das Potential der vorgestellten Fusionsmethodik aufzeigen.

## 1 Einführung

Bildfusion ist die Verknüpfung von Bildsignalen mit dem Ziel, eine neue oder verbesserte Repräsentation der in Bildern oder Bildeigenschaften enthaltenen Information zu gewinnen. Information bezeichnet in diesem Zusammenhang alles, was für einen beliebigen Betrachter innerhalb eines bestimmten Kontextes relevant ist.

Bildsignale sind Funktionen oder Wertefolgen, die Information tragen. Die Belichtung des Bildsensors in einer Kamera entspricht zunächst einem analogen Bildsignal, das zur rechnergestützten Verarbeitung digitalisiert wird und die Grundlage für eine Bildfusion bilden kann.

Bei der Beobachtung der Szene durch einen Sensor findet eine Informationsverminderung statt, die dazu führt, dass die Abbildung der Szene auf Bilder nicht bezüglich aller physikalischen Szeneigenschaften invertierbar ist. In Bezug auf Bildsensoren umfasst die Verminderung im Wesentlichen folgende Aspekte:

- Bilder haben einen endlichen Definitionsbereich, d. h. sie weisen eine Ortsbegrenzung auf.
- Die Bildaufnahme ist eine Projektion in mehrfacher Hinsicht: Geometrisch wird die 3-dimensionale Szene auf eine 2-dimensionale  $x$ - $y$ -Bildebene projiziert. Bezüglich spektraler Emissions- und Reflexionseigenschaften findet

eine Projektion des unendlichen Raums der Wellenlängen des elektromagnetischen Spektrums auf meist eine Dimension — bei Grauwert- und Infrarotbildern — oder drei Dimensionen — bei RGB-Bildern — statt. Auch die Belichtung des Sensors über eine endliche Belichtungszeit entspricht letztlich einer Projektion der Zeitdimension. Die Bildaufnahme ist daher nicht injektiv.

- Durch die sensorinhärente zeitliche und örtliche Integration und Abtastung sowie die Quantisierung der vom Bildsensor empfangenen Bestrahlungsstärke  $E(x, y, t)$  wird ein digitales Bildsignal erhalten. Systemtheoretisch betrachtet wird die orts- und zeitabhängige Bestrahlungsstärke mit der Aperturfunktion der einzelnen Pixel gefaltet und im Pixelraster abgetastet. Genauso entspricht die Belichtung einer Faltung der Bestrahlungsstärke mit einer Belichtungsfunktion und einer Abtastung mit der Bildwiederholfrequenz.

## 2 Charakteristika von Bildsensoren

Bildsensoren, die eine Szene durch optische Projektion der von der Szene emittierten Strahlung auf eine Bildebene erfassen, liefern grundsätzlich *kommensurable* Daten, da Bilder als zweidimensionale Datenobjekte stets die gleiche Dimension aufweisen.

Bildserien, welche die Szene unter Variation von Beleuchtungs- oder Beobachtungsparametern oder zu unterschiedlichen Zeitpunkten zeigen, lassen sich als mehrdimensionale Datenobjekte interpretieren, wobei jeder der variierten Parameter eine eigene Dimension darstellt [5]. Die Parameter der Bilderfassung umfassen auf der Seite der Beleuchtung u. a. Position und Ausrichtung, Spektrum, Polarisationszustand sowie räumliche Verteilung der Bestrahlungsstärke (bei Beleuchtungsmustern) der Lichtquelle. Beobachtungsparameter sind u. a. Position und Orientierung der Kamera, spektrale Empfindlichkeit, Empfindlichkeit bezüglich des Polarisationszustands, Blende und Fokuseinstellung der Abbildungsoptik sowie einige<sup>3</sup> der intrinsischen Kameraparameter [16].

Bei Aufgaben der automatischen Sichtprüfung hat man es häufig mit Bildern zu tun, die mit demselben Sensor, aber mindestens einem unterschiedlichen Erfassungsparameter aufgenommen worden sind. Bei Farbsensoren unterscheiden sich die Bilder der Serie etwa mindestens in der spektralen Empfindlichkeit, bei Grauwertsensoren variiert mindestens der Zeitpunkt der Bilderfassung. Da die Daten dann in Wirklichkeit von einem einzigen Sensor erfasst worden sind, werden die Sensoren der einzelnen Aufnahmen auch als *virtuelle* Sensoren bezeichnet.

---

<sup>3</sup> Falls für die Erfassung der Bildserie eine einzige Kamera verwendet wird, ist der einzige variable intrinsische Parameter die Brennweite. Im Fall mehrerer Kameras sind alle intrinsischen Kameraparameter unterschiedlich, jedoch bis auf die Brennweite nicht einstellbar.

## 2.1 Homogene Sensoren

Erfassen die Sensoren gleiche oder vergleichbare physikalische Messgrößen der Szene, liegen *homogene* Sensoren vor. Beispiele sind Bildserien, die mit gleichartigen Kameras, aber unterschiedlichen Beobachtungsparametern erfasst worden sind. Die Bildfusion ist dann meist ohne aufwendige Vorverarbeitung möglich. Solche Bildserien werden häufig erfasst, um die Messzeit zu reduzieren, die Zuverlässigkeit der Datenerfassung zu erhöhen oder die Rauscheigenschaften des Sensorsystems zu verbessern. Darüber hinaus lassen sich mittels homogener Sensoren aber auch zusätzliche Informationen über die Szene gewinnen, indem etwa das Erscheinungsbild bei unterschiedlichen Beleuchtungen ausgewertet wird [3, 13].

*Inhomogene* Sensoren liegen etwa bei 3D- und Grauwertbildern vor, da die Einzelsensoren unterschiedliche physikalische Eigenschaften der Szene erfassen. In der Regel ist eine aufwendigere Vorverarbeitung und Registrierung erforderlich, damit die Daten vergleichbar, verknüpfbar oder ineinander überführbar werden.

## 2.2 Kollokierte Sensoren

Falls die Bildserie mit homogenen Sensoren bei konstanter relativer Sensorposition und -ausrichtung zur Szene und konstantem Abbildungsmaßstab erfasst wird, handelt es sich um *kollokierte* Sensoren. Die Bilder zeigen dann identische Ausschnitte der Szene. Stimmen die relative Kameraposition, -ausrichtung oder der Abbildungsmaßstab nicht überein, sind Methoden der Bildregistrierung erforderlich. Dazu werden Bildmerkmale (z. B. lokale Grauwertstrukturen, Ecken, Kanten) in jedem Bild identifiziert und durch geometrische Transformationen aneinander ausgerichtet [2, 10].

## 2.3 Informationsgehalt der Daten

Wie in Abschnitt 1 dargestellt, können die Einzelsensoren sowohl in den örtlichen Dimensionen als auch bezüglich aller anderen wahrnehmbaren Szeneigenschaften nur jeweils einen Ausschnitt der gesamten über die Szene verfügbaren Information gewinnen. Bei der Fusion der Daten ist daher zu unterscheiden, welcher Zusammenhang zwischen der in den einzelnen Bildern der Serie enthaltenen Nutzinformation besteht:

- *Redundante Information:* Wenn die zu fusionierende Nutzinformation von homogenen Sensoren denselben Aspekt der Szene erfasst, kann eine konkurrierende Fusion sinnvoll sein, wobei alle Bilder der Serie in gleicher Weise zum Fusionsergebnis beitragen.

Ein Beispiel ist die Akkumulation mehrerer Bilder von homogenen, kollokierten Sensoren, d. h. für jeden Bildpunkt die Mittelwertbildung über die Bilder der Serie, um das thermische Rauschen des Bildsensors zu reduzieren.

- *Komplementäre Information*: Liegt die Nutzinformation von homogenen Sensoren für einen bestimmten Ort auf ein oder wenige Bilder konzentriert vor, ist eine komplementäre Fusion angebracht.

Beispielsweise kann ein Bild mit synthetisch erweiterter Schärfentiefe aus einer Bildserie mit variiertem Beobachtungsabstand gewonnen werden, indem für jeden Ort genau dasjenige Bild in das Fusionsergebnis übernommen wird, das die lokale Umgebung des Ortes mit hohem Kontrast zeigt [13]. In ähnlicher Weise lassen sich kontrastreiche Bilder aus Bildserien mit variiertem Beleuchtungsrichtung erzeugen [6, 13]. Ein weiteres Beispiel für eine komplementäre Fusion ist die Erzeugung von Bildteppichen aus einer Bildserie mit bewegter Kamera, indem die Bilder der Serie registriert und in einer Art Puzzle aneinander gelegt werden [9].

- *Verteilte Information*: In manchen Fällen liegt die Nutzinformation derart verteilt über die Serie vor, dass grundsätzlich erst die Auswertung mehrerer oder sämtlicher Bilder eine Aussage über die Zielgröße der Fusion erlaubt. Im Gegensatz zur einfacheren konkurrierenden Fusion werden hier aus den Daten zunächst Merkmale extrahiert, so dass die Fusion auf einer höheren Abstraktionsebene stattfindet.

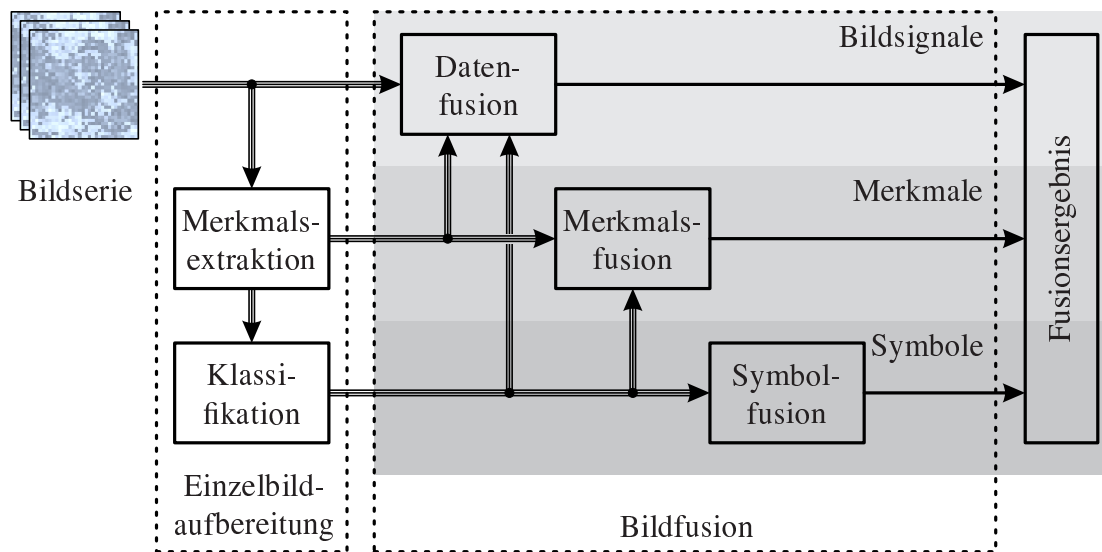
Zu dieser Kategorie gehört etwa die Gewinnung von Tiefeninformation mittels unterschiedlicher Verfahren:

- die Fusion von Stereobildern zu Tiefenkarten, wobei als Grundlage für die Fusion die scheinbare Verschiebung von Merkmalen (Kanten, Ecken etc.) zwischen mehreren Bildern mit unterschiedlicher Beobachtungsposition (auch durch Eigenbewegung der Kamera — *depth from motion*) dient [2], sowie
- Verfahren des Photometrischen Stereo (*shape from shading*), bei denen die Variation der von der Szene reflektierten Strahldichte in Abhängigkeit von der Beleuchtungsrichtung ausgewertet werden [7].

Ein weiteres Beispiel ist die Oberflächeninspektion auf Eigenschaften, die in Einzelbildern nicht erkennbar sind und bei denen die Datengrundlage für aussagekräftige Merkmale über die Serie verteilt vorliegt [4, 12, 17].

- *Orthogonale Information*: Die Eigenschaft der Orthogonalität liegt vor, wenn die zu fusionierenden Daten Informationen über disjunkte Eigenschaften der Szene enthalten, beispielsweise über verschiedene physikalische Größen.

Eine typische Aufgabe zur Fusion orthogonaler Daten besteht etwa darin, Grauwertbilder, die mit diffuser Beleuchtung erfasst worden sind, und Tiefenkarten, die mittels Laserscannern oder Triangulationssensoren gewonnen worden sind, zu verknüpfen. Während die Grauwertbilder überwiegend die Reflektanzeigenschaften der Szene bewerten, enthalten die Tiefenkarten Aussagen über die 3D-Gestalt der Szene. Eine Verknüpfung solcher Daten ist — nach einer Registrierung — nur auf einem Abstraktionsniveau möglich, das Objekte mit ihren Reflektanz- und geometrischen Eigenschaften berücksichtigen kann [8].




**Abb. 1.** Abstraktionsebenen der Bildfusion [13]. Bildserien sind durch Mehrfachstriche, Einzelbilder durch einfache Striche gekennzeichnet.

### 3 Abstraktionsebenen

Die Fusion der Bilddaten kann auf unterschiedlichen Abstraktionsebenen stattfinden; siehe Abbildung 1. Entscheidend für die Festlegung der Abstraktionsebene ist der Verarbeitungsgrad der Bildserie, der vor der Verknüpfung der Bilder erreicht worden ist:

- Bei der *Datenfusion* (*pixel-level fusion*) findet die Verknüpfung auf der Ebene der Bilddaten — der Bildintensitäten als Grau- oder RGB-Werte — statt. Voraussetzung dafür ist, dass die Bilder von homogenen Sensoren erfasst worden sind, so dass die Bilder gleiche oder gleichartige physikalische Eigenschaften der Szene wiedergeben. Das Ziel einer Datenfusion ist oft, ein Fusionsergebnis mit höherer Qualität oder erweitertem Definitionsbereich zu erhalten. Dazu zählen etwa einfache Verfahren, die redundante Information mittels konkurrierender Fusion — z. B. zur Rauschunterdrückung — verknüpfen sowie Verfahren der komplementären Fusion, die für jeden Ort dasjenige Bild auswählen und in das Ergebnis übernehmen, in dem die Nutzinformation am besten enthalten ist. Das Beispiel der komplementären Fusion setzt die Definition eines geeigneten Qualitätsmerkmals voraus. Allgemein können bei einer Fusion auf Daten- oder Merkmalsebene Informationen aus höheren Abstraktionsebenen (z. B. Merkmalsausprägungen oder Segmentierungsergebnisse) erforderlich oder nützlich sein.
- Die *Merkmalsfusion* (*feature-level fusion*) führt eine Verknüpfung auf der Grundlage von Merkmalen durch, die aus der Bildserie extrahiert worden sind. Die Merkmale können dabei getrennt aus jedem Bild der Serie bestimmt werden — wie das z. B. bei lokalen Texturmerkmalen der Fall ist



**Abb. 2.** Allgemeines Schema der Bildfusion.

— oder durch gleichzeitige Auswertung sämtlicher Bilder der Serie erhalten werden — ein Beispiel hierfür ist die Berechnung der mittleren Intensität eines Ortes aus einer Beleuchtungsserie. Während im zweiten Fall homogene Sensoren zu bevorzugen sind, genügen im ersten Fall Sensoren, die vergleichbare Merkmale erzeugen.

Ziel einer Merkmalsfusion ist es oft, die Bestimmung von Bildmerkmalen zu verbessern oder einen Zugang zu Merkmalen zu erhalten, die über die Serie verteilt vorliegen.

- Die Fusion auf einer *symbolischen Ebene* oder *Objektebene* (*Symbolfusion*, *Entscheidungsfusion*, *decision-level fusion*) verknüpft symbolische Informationen — z. B. aus den Einzelbildern erhaltene Klassifikationsergebnisse — zu einem Fusionsresultat. Dabei können durchaus Informationen von inhomogenen Sensoren zum Einsatz kommen, deren Ergebnisse auf symbolischer Ebene vergleichbar sind.

Ziel einer Entscheidungsfusion ist meist, die Zuverlässigkeit einer Klassifikation zu verbessern, etwa zur Fehlerdetektion oder Objekterkennung.

Die Fusion von Information ist algorithmisch oft umso leichter, je höher die Abstraktionsebene gewählt wird, da zur Merkmalsgewinnung und Auswertung von Einzelbildern meist Standardverfahren der Bildverarbeitung zur Verfügung stehen. Allerdings ist die Qualität des Fusionsergebnisses in der Regel höher, wenn die Fusion auf einer möglichst niedrigen Abstraktionsebene stattfindet. Der Grund dafür liegt in der Informationsveränderung und potenziellen Informationsreduktion bei der Verarbeitung und Auswertung der Einzelbilder [14].

## 4 Allgemeine Struktur der Bildfusion

Abbildung 2 zeigt ein allgemeines Schema, nach dem sich eine Vielzahl von Aufgabenstellungen der Bildfusion lösen lässt. Im ersten Schritt erfolgt eine Transformation der Bildserie in einen für die Erfassung ihres Informationsgehaltes geeigneten Darstellungsbereich auf der erforderlichen Abstraktionsebene. Beispiele für diese Transformation sind die Berechnung von lokalen Merkmalen oder von Fourierkoeffizienten. Danach erfolgt eine Optimierung, in die neben den Merkmalen sowohl Vorwissen bezüglich der Bildserie und des Fusionsresultates als auch zusätzliche Nebenbedingungen eingehen können. Durch die Lösung der Optimierungsaufgabe wird sichergestellt, dass sämtliche Nebenbedingungen bei



der Fusion berücksichtigt werden. Das Ergebnis der Optimierung stellt eine Art „Bauanleitung“ zur Konstruktion des Fusionsresultates auf der Grundlage der Bildserie und des Zusatzwissens dar. Schließlich erfolgt eine weitere Transformation, welche bei Bedarf die aus der Optimierung resultierende „Fusionskarte“ in die gewünschte Abstraktionsebene überführt. Die Fusionskarte kann beispielsweise Informationen darüber enthalten, welche Bereiche von welchen Bildern der Serie für die Berechnung des Fusionsresultates herangezogen werden sollen. Im einfachsten Fall jedoch wird die Fusionskarte unmittelbar in das Ergebnisbild mittels einer wohldefinierten Funktion abgebildet. Im Folgenden sollen diese Struktur näher erläutert und Beispiele für die Realisierung der unterschiedlichen Schritte vorgestellt werden.

#### 4.1 Transformation der Bildserie

Der Transformation der zu fusionierenden Bildserie kommt eine entscheidende Bedeutung bei der Verschmelzung zu. Ihre Aufgabe ist die Erzeugung von Deskriptoren des Informationsgehaltes der Bildserie in einem geeigneten Darstellungsbereich — darauf wird sich die Verknüpfung der Information schließlich stützen. Abhängig von der Art der gewählten Transformation<sup>4</sup> kann im folgenden Optimierungsschritt die Selektion der bei der Fusion herangezogenen Nutzinformation in unterschiedlichen Domänen erfolgen: Ortsbereich, Ortsfrequenzbereich, Parameterbereich, Parameterfrequenzbereich, Orts-Ortsfrequenzbereich, Skalenraum usw.

Die Tabelle 1 gibt einen Überblick über gängige Transformationen der Bildserie sowie ihre möglichen Einsatzgebiete im Kontext der Bildfusion. Es sei ausdrücklich angemerkt, dass die in dieser Tabelle aufgeführten Transformationen sich allgemein nicht auf zwei-, sondern auf höherdimensionale Signale beziehen. Insofern sind lokale und globale Operatoren nicht auf die örtlichen Dimensionen beschränkt, unter Frequenzen und Skalen nicht ausschließlich die ortsbezogenen gemeint.

#### 4.2 Optimierung

Der zweite Schritt der Bildfusion dient dem Zweck, die Nutzinformation aus den transformierten Signalen oder Merkmalen durch Optimierung eines Fusionskriteriums bei gleichzeitiger Einbeziehung von Vorwissen und Nebenbedingungen bzgl. der Bildserie und des Fusionsresultates zu selektieren. Die Wahl geeigneter Methoden hierfür hängt sowohl von der konkreten Aufgabenstellung und von der Transformationsdomäne als auch vom Bildinhalt sehr stark ab und kann hier nur andeutungsweise behandelt werden. Eine Auswahl häufig eingesetzter Verfahren ist in Tabelle 2 zusammengestellt.

Gemeinsam mit der Transformation der Bildserie stellt dieser Schritt üblicherweise die höchsten Anforderungen bezüglich der Rechenzeit der gesamten Bildfusion.

<sup>4</sup> Selbstverständlich kann statt einer einzigen Transformation auch eine Folge von Transformationen zum Einsatz kommen.

**Tabelle 1.** Methoden zur Transformation der Bildserie und ihre Einsatzgebiete.

<b>Transformation</b>	<b>Typische Einsatzgebiete</b>
Geometrische Transformation	Ausrichtung der Bilder bei nicht kollokierten Sensoren, Korrektur geometrischer Verzerrungen infolge der optischen Abbildung
Intensitätstransformationen	Kennlinienanpassung, Beleuchtungsausgleich, Homogenisierung, Abstraktion von der physikalischen Einheit
Hauptachsentransformation	Dekorrelation, Kompression
Kreuzkorrelation	Aufdeckung von Ähnlichkeiten, Analyse auf Redundanz oder Komplementarität der Daten
Lokale Operatoren	Berechnung lokaler Bilddeskriptoren (z. B. Mittelwert, Kontrast, Kanten, Strukturtenor, Texturmerkmale)
Fouriertransformation	Harmonische Analyse, globale Ortsfrequenzselektion bei stationären Prozessen
Wavelettransformation, Pyramidentransformation	Ortsaufgelöste Spektralanalyse bei nichtstationären Prozessen
Morphologische Hat-Transformationen, Skalenraumdarstellung	Ortsaufgelöste Analyse von Strukturen im Skalenraum

### 4.3 Finale Transformation

Das Ergebnis der Optimierung ist eine Fusionskarte in der gewählten Transformationsdomäne, die als „Bauanleitung“ zur Konstruktion des gesuchten Fusionsresultates verstanden werden kann. Um das Fusionsergebnis zu erhalten, muss schließlich die Fusionskarte mittels einer weiteren Transformation in die gewünschte Abstraktionsebene überführt werden.

Als triviales Beispiel hierfür sei die identische Abbildung erwähnt, bei der die Fusionskarte direkt als Fusionsergebnis übernommen wird — was bei der Berechnung von Tiefenkarten aus Fokus- oder Stereoserien geschieht. Im Falle der künstlichen Erweiterung der Schärfentiefe mittels Fokuserien indizieren die Einträge der Fusionskarte diejenigen Bilder der Serie, aus denen die Intensitäten für das Fusionsresultat zu übernehmen sind. Bei der Wahl des Ortsfrequenzbereiches als Fusionsdomäne muss hingegen als finale Transformation eine inverse Fouriertransformation erfolgen, um zu einer Darstellung im Ortsbereich zu gelangen.

## 5 Beispiele

### 5.1 Bilddatenfusion zur Erzeugung hochwertiger Bilder

In vielen Aufgaben der Sichtprüfung ist man auf hochwertige Bilddaten angewiesen. Ein Beispiel hierzu ist die Goldschmiedekunst, bei der anhand von Prägemarken eine Zuordnung der Werke zum jeweiligen Meister erfolgt [15]. Um eine zuverlässige Erkennung und Dokumentation der Meisterzeichen zu erzielen, müssen qualitativ hochwertige Bilder unter reproduzierbaren Aufnahmebedingungen

**Tabelle 2.** Auswahl der zur Formulierung und Durchführung der Optimierung eingesetzten Methoden.


Methoden	Einsatzgebiete
Lineare Operatoren	(Ggf. gewichtete) Mittelung zur konkurrierenden Fusion von Daten oder Merkmalen
Nichtlineare Operatoren	Maximierung/Minimierung von Merkmalsausprägungen oder Gütemaßen, Rangordnungsoperatoren zur robusten Merkmalsselektion
Energieminimierung	Verknüpfung mehrerer Optimierungsziele zu einem Funktional (z.B. zur Maximierung eines Gütekriteriums, Einhaltung von Glattheits- oder Formbedingungen, Erfüllung von Gleichungen/Ungleichungen, Invarianzeigenschaften usw.)
Regularisierung	Verbesserung der Lösbarkeit inverser Probleme
Bayessche Statistik	Darstellung und Berechnung des Grads des Dafürhaltens ( <i>degree of belief</i> ) von Messwerten, Vorwissen und Fusionsergebnissen
Neuronale Netze	Klassifikation ohne explizite Formulierung der Regeln
Support-Vector-Maschinen	Klassifikation in hochdimensionalen Merkmalsräumen
Kalman-Filter und Derivate	Zustandsschätzung dynamischer Systeme

erfasst werden. In vielen Fällen zeigt sich, dass die simultane Erfüllung dieser Anforderungen mit einer einzigen Aufnahme aufgrund der Beschränkungen optischer Systeme nicht möglich ist [1]. Dennoch können diese Limitationen oftmals dadurch kompensiert werden, dass Bildserien unter Variation der Aufnahmeparameter erfasst und zu einem verbesserten Ergebnisbild fusioniert werden.

Exemplarisch sind in Abbildung 3(a) drei Bilder einer Serie zu sehen, die unter Variation der Beleuchtungsrichtung aufgenommen wurden. Da ein einziger, ortsfest angeordneter Sensor verwendet wurde, sind die „virtuellen“ Sensoren homogen und kolloziert. Die in diesem Fall angewandte Transformation der Serie basiert auf einer Berechnung des lokalen Kontrastes. Die anschließende Optimierung hat zum Ziel, den lokalen Kontrast als Qualitätsmaß global zu maximieren. Im mittleren Bild ist die errechnete Fusionskarte zu sehen, welche die Bilder der Serie mit dem höchsten lokalen Kontrast mit Hilfe von Intensitäten codiert. In Abbildung 3(c) ist das Ergebnis der Fusion dargestellt. Verglichen mit den Einzelbildern der Serie weist dieses Bild wesentlich mehr Details und eine höhere Homogenität auf.

## 5.2 Merkmalsfusion zur Inspektion von Schleiftexturen mit stochastischer Riefenrichtung

Bei der Inspektion instationärer Schleiftexturen mit stochastischer Riefenrichtung tritt das Problem auf, dass das Erscheinungsbild der Riefen und somit ihre Sichtbarkeit stark von der Beleuchtungsrichtung abhängen, siehe Abbildun-



**Abb. 3.** Bilddatenfusion zur Erzeugung hochwertiger Bilder: (a) Bilder mit variierter Beleuchtungsrichtung; (b) Codierung der Bilder der Serie mit dem höchsten lokalen Kontrast; (c) Fusionsresultat.

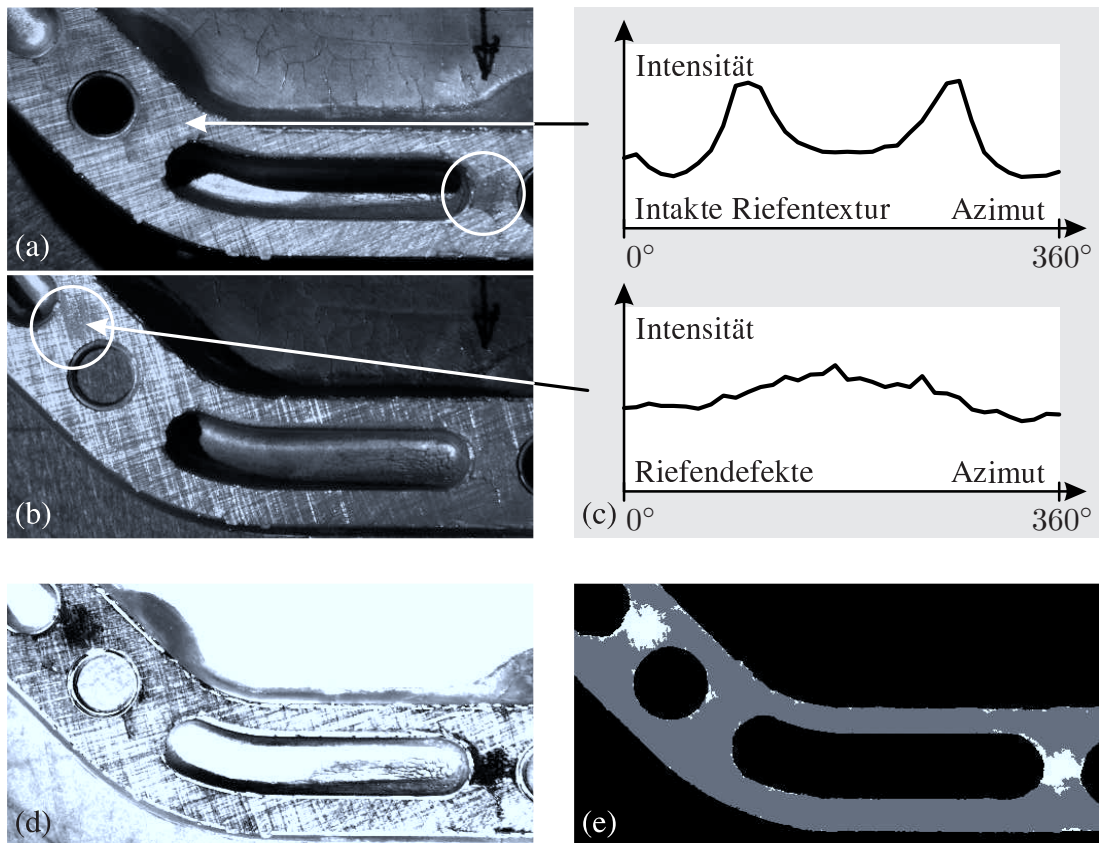
gen 4(a) und (b). Eine zuverlässige Inspektion auf Grundlage nur eines Bildes scheidet somit aus.

Zur visuellen Inspektion wird vielmehr eine Bildserie herangezogen, bei der die Richtung einer gerichteten Beleuchtung bei konstantem Elevationswinkel azimuthal variiert wird [17]. Die virtuellen Bildsensoren der Serie sind somit kommensurabel, homogen und kollokiert.

Während an Orten, an denen eine intakte Riefentextur vorliegt, aufgrund der metallischen Spiegelung an den Riefenflanken zwei markante Helligkeitsmaxima bei einem azimuthalen Umlauf der Lichtquelle auftreten, weisen Riefendefekte höchstens ein Maximum schwächerer Ausprägung auf; siehe Abbildung 4(c). Die Nutzinformation ist somit über die Bilder der Serie verteilt, so dass eine Fusion auf Merkmalsebene erforderlich ist. Im Transformationsschritt kommen Operatoren zum Einsatz, die Merkmale in den Domänen des Parameter- bzw. Parameterfrequenzbereichs bestimmen. Geeignete Methoden sind etwa die Analyse der parameterbezogenen Varianz — Abbildung 4(d) — oder der Periodizität der gemessenen Intensitäten sowie eine harmonische Analyse im Parameterfrequenzbereich. Die Optimierung wird durch Festlegung geeigneter Schwellwerte für die Transformationsergebnisse erzielt, die eine Klassifizierung in intakte und defekte Merkmalsausprägungen ermöglichen. Das Ergebnis der Klassifikation ist gleichzeitig das Fusionsresultat; siehe Abbildung 4(e).

### 5.3 Fusion von Stereobildern zur Erzeugung von Tiefenkarten

Zur Gewinnung von Tiefen- oder Entfernungskarten werden oftmals sogenannte Stereo-Kameraanordnungen eingesetzt, bei denen zwei Kameras eine Szene aus zwei verschiedenen Blickwinkeln beobachten. Sind beide Kameras parallel zueinander ausgerichtet und kalibriert, so lässt sich die Entfernung eines Objektpunktes aufgrund der Parallaxe ermitteln. Voraussetzung zur Anwendung dieses



**Abb. 4.** Merkmalsfusion zur Inspektion von Schleiftexturen mit stochastischer Riefenrichtung: (a), (b) Bilder der azimuthalen Beleuchtungsserie; (c) Charakteristische Intensitätsverläufe für die intakte Riefentextur und Defektbereiche; (d) Transformationsergebnis: Parameterbezogene Varianz, Defektbereiche erscheinen dunkel; (e) Fusionsresultat (grau: Intakte Riefentextur, weiß: Riefendefekte, schwarz: Hintergrund).

Verfahrens ist allerdings, dass sich der Punkt in beiden Bildern eindeutig identifizieren lässt, weshalb zur zuverlässigen Erfassung von dichten Punktwolken das abgebildete Objekt eine ausgeprägte Struktur aufweisen muss. Es leuchtet ein, dass bei dieser Anwendung homogene, nicht kollokierte Bildsensoren gewählt werden müssen.

Praktisch erfolgt die Zuordnung von Punkten in beiden Bildern durch Vergleich lokaler Bildbereiche, z. B. auf der Grundlage von Korrelationsverfahren. Zur Transformation der Bildserie werden daher verschiedene Bereiche des ersten Bildes mit dem zweiten Bild örtlich korreliert. Die im folgenden Schritt durchzuführende Optimierung bewirkt eine Maximierung der Korrelationsfunktion unter gleichzeitiger Berücksichtigung von Nebenbedingungen — etwa der Forderung nach einer glatten Tiefenkarte. Da die ermittelte Parallaxe umgekehrt proportional zur Entfernung der Punkte ist, muss in der anschließenden Transformation im Wesentlichen der Kehrwert der Fusionskarte gebildet werden.

Abbildung 5(a) zeigt exemplarisch ein mit einer Stereokamera aufgenommenes, rektifiziertes Bildpaar. In Abbildung 5(b) ist die daraus entstandene Tie-



**Abb. 5.** Fusion von Stereobildern zur Erzeugung von Tiefenkarten: (a) Rektifiziertes Stereo-Bildpaar; (b) Fusionierte Tiefenkarte (nahe Objekte sind heller dargestellt).


fenkarte gezeigt, bei der kleinere Objektentfernungen durch hellere Intensitäten codiert wurden. Bereiche, in denen mangels Struktur keine Entfernungen ermittelt werden konnten, sind schwarz dargestellt.

#### 5.4 Photometrisches Stereo

Eine klassische Aufgabe der automatischen Sichtprüfung ist die Rekonstruktion der 3D-Gestalt einer Oberfläche. Dabei besteht eine Möglichkeit darin, die von der Kamera gemessene Strahldichte bei Variation der Beleuchtung auszuwerten [7]. Die Bildserie wird daher mittels virtueller, kommensurabler, homogener und kollozierter Sensoren erfasst. Die Strahldichte — die „Helligkeit“, mit der ein Objekt erscheint — ist proportional zur Bestrahlungsstärke der Beleuchtung und der Bidirektionalen Reflektanzverteilungsfunktion (BRDF) [11]. Die BRDF beschreibt als Funktion der geometrischen Anordnung von Beleuchtung und Beobachtung relativ zur Oberflächennormalen, wie hell die Oberfläche bei einer bestimmten Bestrahlungsstärke erscheint. Bei gegebener Beleuchtungskonstellation und bekannter BRDF lassen sich somit Informationen über die Oberflächengestalt gewinnen.

Mit angenommener ideal diffuser Reflexion (Lambertscher Reflexion) ist die gemessene Bildhelligkeit  $g(x, y)$  proportional zur Reflektanz der Oberfläche  $r(x, y)$  und zum Kosinus des Winkels zwischen dem Normalenvektor der Beleuchtungsrichtung  $\mathbf{b}$  und der Oberflächennormalen  $\mathbf{n}(x, y)$ , d. h.  $g(x, y) \propto r(x, y) \cdot \mathbf{b}^T \mathbf{n}(x, y)$ . In diesem einfachen Fall reichen drei Beleuchtungsrichtungen aus, um für jeden Ort die Reflektanz — bis auf eine multiplikative Konstante — und den Normalenvektor zu bestimmen. Dazu wird die gemessene Bildhelligkeit als Vektor formuliert:  $\mathbf{g}(x, y) \propto r(x, y) \cdot \mathbf{B}^T \mathbf{n}(x, y)$ , wobei  $\mathbf{B} = (\mathbf{b}_1, \mathbf{b}_2, \mathbf{b}_3)$  die Beleuchtungsvektoren der drei Beleuchtungskonstellationen zusammenfasst. Dieser Zusammenhang lässt sich bis auf eine multiplikative Konstante nach  $r(x, y)$  und dem Einheitsvektor  $\mathbf{n}(x, y)$  auflösen. Stehen mehr als drei Beleuchtungskonstellationen zur Verfügung, ist eine robuste Schätzung der Größen möglich.

Bei dieser Merkmalsfusion ist die Transformation eine Identität. In der Optimierung wird das Vorwissen über die Reflexion verwendet, das Fusionsresultat ergibt sich direkt als Reflektanz und Normalenvektor. Abbildung 6 zeigt als



**Abb. 6.** Photometrisches Stereo: (a) Bilder mit variiertem Beleuchtungsrichtung; (b) Fusionsresultat: Reflektanz; (c) Fusionsresultat: Oberflächennormale (vorne:  $y$ -Komponente, hinten:  $x$ -Komponente).

Beispiel eine bedruckte Folie, von der eine Bildserie mit variiertem Beleuchtungsrichtung aufgenommen wurde. Das Fusionsresultat zeigt eine gute Trennung von Reflektanz — Abbildung 6(b) — und Oberflächennormale — Abbildung 6(c) —, so dass beide Oberflächenkenngrößen fast vollständig getrennt zur Verfügung stehen.

## 6 Zusammenfassung

Im Beitrag wurde ein allgemeiner Überblick über Methoden der Bildfusion vermittelt. Diese haben zum Ziel, mehrdimensionale Datenobjekte — sogenannte Bildserien — dahingehend auszuwerten, dass Ergebnisse generiert werden, welche die Welt „besser“ beschreiben als irgendein Einzelbild. Dafür werden gezielt Eingangsbilder erfasst, die redundante, komplementäre, verteilte oder orthogonale Informationen enthalten können. Abhängig vom Abstraktionsgrad, auf dem die Bildinformationen verknüpft werden, erfolgt eine Einteilung in Datenfusion, Merkmalsfusion und Symbolfusion. Schließlich wurde gezeigt, dass sich zahlreiche Methoden zur Bildfusion auf eine gemeinsame Struktur zurückführen lassen: eine Transformation der Bildserie, gefolgt von einer Optimierung und einer finalen Transformation.

## Literatur

1. J. Beyerer und F. Puente León. Datenfusion zur Gewinnung hochwertiger Bilder in der automatischen Sichtprüfung. *Automatisierungstechnik*, 45(10):480–489, 1997.
2. R. Hartley und A. Zisserman. *Multiple view Geometry in Computer Vision*. Cambridge University Press, Cambridge, 2003.
3. M. Heizmann. *Auswertung von forensischen Riefenspuren mittels automatischer Sichtprüfung*. Universitätsverlag Karlsruhe, Karlsruhe, 2004.

4. M. Heizmann. Techniques for the Segmentation of Striation Patterns. *IEEE Transactions on Image Processing*, 15(3):624–631, 2006.
5. M. Heizmann und J. Beyerer. Sampling the Parameter Domain of Image Series. In: E. R. Dougherty, J. T. Astola und K. O. Egiazarian (Hrsg.), *Image Processing: Algorithms and Systems IV*, Bd. 5672, S. 23–33. SPIE, 2005.
6. M. Heizmann und F. Puente León. Imaging and analysis of forensic striation marks. *Optical Engineering*, 42(12):3423–3432, 2003.
7. B. K. P. Horn und M. J. Brooks (Hrsg.). *Shape from Shading*. MIT Press, Cambridge, 1989.
8. L. A. Klein. *Sensor and Data Fusion — A Tool for Information Assessment and Decision Making*. SPIE Society of Photo-Optical Instrumentation Engineers, Bellingham (WA), 2004.
9. M. Müller, W. Krüger und G. Saur. Robust image registration for fusion. *Information Fusion*, 2006.
10. J. Modersitzki. *Numerical Methods for Image Registration*. Oxford University Press, Oxford, 2004.
11. F. E. Nicodemus, J. C. Richmond, J. J. Hsia, I. W. Ginsberg und T. Limperis. Geometrical Considerations and Nomenclature for Reflectance. NBS Monograph 160, National Bureau of Standards, U.S. Department of Commerce, Washington (DC), 1977.
12. A. Pérez Grassi, G. Monti und F. Puente León. Matched-Filter im Beleuchtungsraum zur Detektion kraterförmiger Defekte auf lackierten Holzoberflächen. In: *Sensoren und Meßsysteme 2006*, S. 349–352, VDE-Verlag, Berlin, 2006.
13. F. Puente León. Komplementäre Bildfusion zur Inspektion technischer Oberflächen. *Technisches Messen*, 69(4):161–168, 2002.
14. F. Puente León und S. Kammel. Inspection of specular and painted surfaces with centralized fusion techniques. *Measurement*, 39(6):536–546, 2006.
15. H. Seling. *Die Kunst der Augsburger Goldschmiede 1529–1868*. Verlag C. H. Beck, München, 1980.
16. L. G. Shapiro und G. C. Stockman. *Computer Vision*. Prentice Hall, Upper Saddle River (NJ), 2001.
17. B. Xin, M. Heizmann, S. Kammel und C. Stiller. Bildfolgenauswertung zur Inspektion geschliffener Oberflächen. *Technisches Messen*, 71(4):218–226, 2004.



# Neuronale Netze: Eine Übersicht

Oliver Nelles

Universität Siegen, Lehrstuhl für Mess- und Regelungstechnik – Mechatronik,  
Fachbereich Maschinenbau, Paul-Bonatz-Str. 9–11, D-57068 Siegen

**Zusammenfassung.** Neuronale Netze haben sich in den letzten Jahrzehnten zu einem wichtigen Werkzeug der Signalverarbeitung entwickelt. Sie sind heute aus der Welt der Mess-, Regelungs- und Automatisierungstechnik nicht mehr wegzudenken. Dieser Beitrag stellt in einer Übersicht die gängigsten neuronalen Netztypen zur datenbasierten Modellierung nichtlinearer Systeme vor. Auf andere Aufgaben wie die Informationsvorverarbeitung (Clustering, Transformationen, Dimensionsreduktion, etc.) und die Klassifikation wird hier nicht eingegangen. Die Vor- und Nachteile der betrachteten Netztypen werden anhand ihrer jeweiligen charakteristischen Eigenschaften erklärt. Dabei spielen auch die verwendeten Trainings- oder Lernverfahren eine wichtige Rolle. Abschließend werden die notwendigen Erweiterungen und Besonderheiten für die Modellierung dynamischer Systeme diskutiert.


## 1 Einleitung

Nichtlineare Zusammenhänge werden klassischerweise meist über Kennfelder (bzw. Kennlinien im eindimensionalen Fall) oder Polynome in Software umgesetzt. Diese Ansätze bieten sich wegen ihrer folgenden vorteilhaften Eigenschaften zunächst auch an:

- Leichtes Verständnis.
- Einfache Implementierbarkeit.
- Geringer Rechenaufwand.

Bei Kennfeldern kommt noch der weitere Vorteil hinzu, dass sie sich sofort mittels rasterförmig vermessener Daten parametrieren lassen, indem jede Stützstelle des Kennfeldes genau einem Messdatum entspricht. Bei Polynomen ist eine Optimierung notwendig, um aus den Messdaten die Koeffizienten zu schätzen. Dies ist bei Kennfeldern ebenfalls erforderlich, wenn die Daten nicht rasterförmig verteilt sind bzw. die Lagen der Stützstellen nicht mit denen der Messdaten überein stimmen. Ein solche Optimierung ist allerdings sehr einfach z.B. mittels der Methode der kleinsten Quadrate möglich, da sowohl die Polynomkoeffizienten als auch die Stützstellenhöhen eines Kennfeldes den Ausgang des Modells linear beeinflussen.

Leider stoßen Kennfelder und Polynome wegen folgender Nachteile recht schnell an ihre Grenzen:



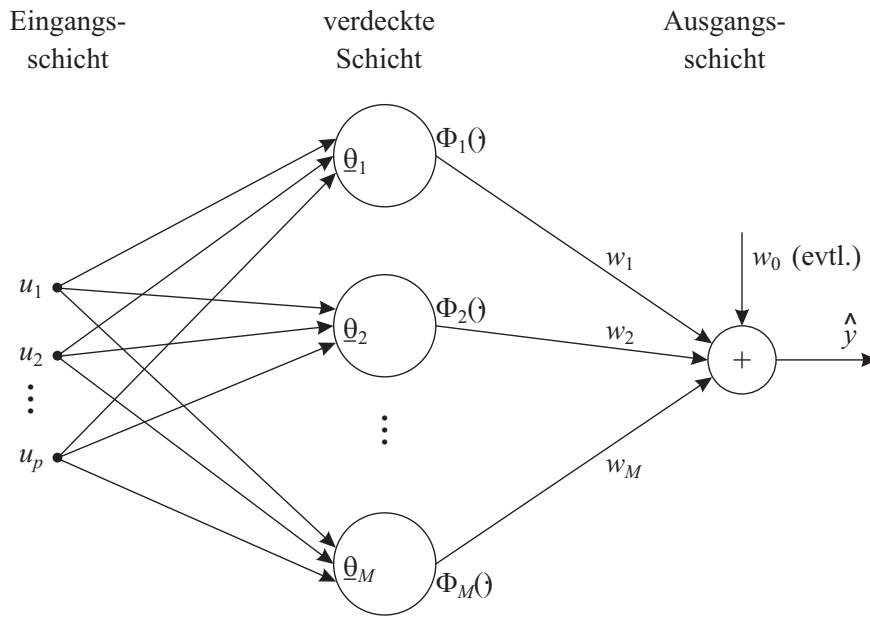
**Abb. 1.** Approximation mit einem Polynom fünften Grades.

- Nicht für hochdimensionale Probleme geeignet.
- Oft ungewünschtes Interpolationsverhalten.

Bei Kennfeldern wächst wegen der rasterförmigen Verteilung der Stützstellen deren Anzahl exponentiell mit der Dimension des Eingangsraums an. Dieses Phänomen nennt man auch den „Fluch der Dimensionalität“ (engl. *curse of dimensionality*) [1]. Daher werden Kennlinien/Kennfelder üblicherweise nur für Modelle mit einer oder zwei Eingangsgrößen verwendet. Durch den exponentiellen Komplexitätsanstieg sind Modelle mit mehr als drei oder vier Eingangsgrößen praktisch nicht realisierbar. Bei Polynomen steigt die Zahl der Koeffizienten nicht ganz so krass an, aber auch hier ist wegen der schnell wachsenden Zahl der Kreuzterme die handhabbare Eingangsraumdimensionalität stark begrenzt.

Bezüglich des Interpolationsverhaltens neigen Kennfelder zur Überanpassung (engl. *overfitting*), d.h. wegen ihrer enorm hohen Flexibilität (sehr großen Anzahl an Stützstellen) findet in der Regel keine oder nur eine geringe Glättung der Messdaten statt. Deshalb dürfen nur gering gestörte Messdaten verwendet werden, weil sonst das Rauschen mitmodelliert würde. Bei Polynomen stört mit zunehmender Flexibilität ihre starke Tendenz zum Schwingen und ihr für die meisten Anwendungen unrealistisches Extrapolationsverhalten, welches schnell gegen  $+\infty$  oder  $-\infty$  tendiert, siehe Abbildung 1.

Mit neuronalen Netzen möchte man diese Nachteile vermeiden oder zumindest abschwächen. Dieser Beitrag stellt die gängigsten Netztypen mit ihren spezifischen Eigenschaften vor. Zunächst wird in Abschnitt 2 ein allgemeiner Basisfunktionenansatz eingeführt, mit dessen Hilfe sich die meisten neuronalen Netze (und auch andere Modelltypen) beschreiben lassen. Danach werden drei grundlegende Konstruktionsprinzipien erklärt, wie sich eine eindimensionale Beschreibung auf höherdimensionale Fälle erweitern lässt. In den Abschnitten 4–6 werden die bekanntesten neuronalen Netztypen für diese drei Konstruktionsprinzipien vorgestellt. Abschnitt 7 behandelt eine sehr erfolgreiche und immer populärer werdende Erweiterung des üblichen Basisfunktionenansatzes basierend auf lokalen Modellen. Ein Ausblick auf die Besonderheiten bei der Modellierung dyna-



**Abb. 2.** Ein Netz besteht aus überlagerten Basisfunktionen.

mischer Systeme rundet diesen Beitrag ab. Für eine ausführlichere Behandlung des Themas sei auf [4] verwiesen.

## 2 Basisfunktionen

Sehr viele Modelltypen und dazu gehören auch die meisten neuronalen Netze lassen sich als gewichtete Überlagerung von Basisfunktionen darstellen, siehe Abbildung 2:

$$\hat{y}(\underline{u}) = w_0 + \sum_{i=1}^M w_i \Phi_i(\underline{u}, \underline{\theta}_i) . \tag{1}$$

Hiermit werden  $p$  Eingangsgrößen, die im Vektor  $\underline{u} = [u_1 \ u_2 \ \dots \ u_p]^T$  zusammengefasst sind, auf den Modellausgang  $\hat{y}$  abgebildet. Möchte man Systeme mit mehreren Ausgangsgrößen beschreiben, bieten sich zwei Alternativen: (i) für jeden Ausgang wird ein eigenes Modell nach (1) aufgestellt oder (ii) das Modell wird erweitert, indem  $w_i$  durch  $w_{ij}$  ersetzt wird, um damit  $q$  Ausgangsgrößen  $\hat{y}_j$ ,  $j = 1, \dots, q$ , zu beschreiben. Die erste Alternative bietet eine größere Flexibilität, da für jeden Ausgang unterschiedliche und unterschiedlich viele Basisfunktionen  $\Phi_i(\cdot)$  gewählt werden können. Die zweite Alternative ist wesentlich kompakter, da nur ein gemeinsames Modell statt  $q$  verschiedener Modelle benötigt wird.

Die Basisfunktionsdarstellung in (1) lässt sich wie folgt interpretieren. Der Modellausgang  $\hat{y}$  berechnet sich aus einem Gleichwert  $w_0$  (der evtl. entfallen kann) plus der gewichteten Summe von  $M$  Basisfunktionen  $\Phi_i(\cdot)$ . Jede Basisfunktion wird in Abbildung 2 durch ein Neuron in der sog. verdeckten bzw. mittleren Schicht repräsentiert. Die Eingangsschicht verteilt lediglich die Eingangsgrößen auf die Neuronen, die Ausgangsschicht berechnet die gewichtete Summe

der Neuronenausgänge. Es ist das Kennzeichen eines neuronalen Netzes, dass alle Neuronen bzw. Basisfunktionen von der selben Art sind und sich ausschließlich durch die Werte ihrer Parameter unterscheiden. Beispielsweise könnte man ein Polynom zwar in der Form von Abbildung 2 darstellen, die Basisfunktionen wären aber alle unterschiedlicher Art:  $\Phi_1 = u_1, \Phi_2 = u_2, \dots, \Phi_p = u_p, \Phi_{p+1} = u_1^2, \Phi_{p+2} = u_2^2, \dots, \Phi_{2p} = u_p^2, \Phi_{2p+1} = u_1 u_2, \dots$ . Daher zählt ein Polynom nicht zur Klasse der neuronalen Netze.

Die Gewichte  $w_i, i = 0, 1, \dots, M$ , entscheiden darüber, wie stark welches Neuron zum Gesamtmodellausgang beiträgt. Diese Gewichte gehen linear in  $\hat{y}$  ein und können daher effizient mit der Methode der kleinsten Quadrate aus Messdaten geschätzt werden, vorausgesetzt die Basisfunktionen sind vollständig bekannt. Bei  $N$  Messdaten  $\{\underline{u}(1), y(1)\}, \{\underline{u}(2), y(2)\}, \dots, \{\underline{u}(N), y(N)\}$  setzt sich die Regressionsmatrix wie folgt zusammen

$$\underline{\Phi} = \begin{pmatrix} 1 & \Phi_1(\underline{u}(1)) & \Phi_2(\underline{u}(1)) & \cdots & \Phi_M(\underline{u}(1)) \\ 1 & \Phi_1(\underline{u}(2)) & \Phi_2(\underline{u}(2)) & \cdots & \Phi_M(\underline{u}(2)) \\ \vdots & \vdots & \vdots & & \vdots \\ 1 & \Phi_1(\underline{u}(N)) & \Phi_2(\underline{u}(N)) & \cdots & \Phi_M(\underline{u}(N)) \end{pmatrix} \quad (2)$$

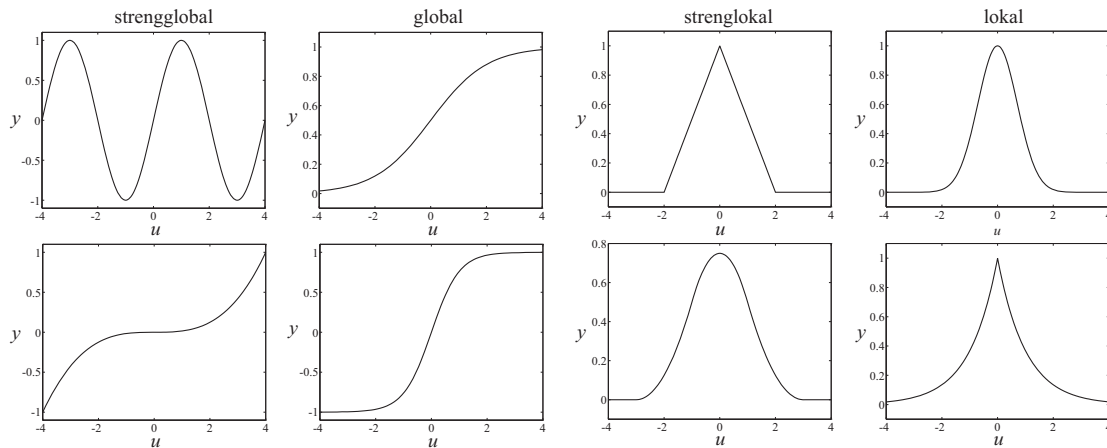
und mit dem Ausgangsdatenvektor  $\underline{y} = [y(1) \ y(2) \ \cdots \ y(N)]^T$  berechnet sich der optimale Gewichtsvektor  $\underline{\hat{w}} = [\hat{w}_0 \ \hat{w}_1 \ \cdots \ \hat{w}_M]^T$  aus

$$\underline{\hat{w}} = (\underline{\Phi}^T \underline{\Phi})^{-1} \underline{\Phi}^T \underline{y}. \quad (3)$$

Hier sollte noch angemerkt werden, dass diese effiziente Möglichkeit zur Optimierung der  $w_i$  oft nicht ausgenutzt wird, weil die lineare Abhängigkeit zwischen  $w_i$  und  $\hat{y}$  in der Standardliteratur aus den Anfängen der neuronalen Netz-Ära noch nicht realisiert worden ist und weil manchmal am Ausgangsneuron des Netzes eine Nichtlinearität wie in der verdeckten Schicht verwendet wird, die diesen linearen Zusammenhang zerstört.

Der entscheidende Unterschied zwischen den verschiedenen neuronalen Netztypen liegt in der Wahl ihrer Basisfunktionen und deren Parametrierung, d.h. in der Funktionsweise der Neuronen der verdeckten Schicht. Allen Netzen gemein ist aber, dass die Basisfunktionen  $\Phi_i(\cdot)$  in nichtlinearer Weise von ihren Parametern abhängen, die im Vektor  $\underline{\theta}_i$  zusammengefasst sind. Somit entsteht für die Bestimmung dieser Parameter  $\underline{\theta}_i, i = 1, \dots, M$  aus den Messdaten, ein nicht-lineares Optimierungsproblem. Dieses muss entweder relativ aufwändig iterativ gelöst werden, wobei dabei stets die Gefahr besteht, in schlechten lokalen Optima stecken zu bleiben, oder auf eine Optimierung muss zugunsten einer suboptimalen Heuristik verzichtet werden. Die sich ergebenden sinnvollen Möglichkeiten zur Bestimmung der  $\underline{\theta}_i$  prägen viele Eigenschaften des jeweiligen Netztyps. Daher muss für einen sinnvollen Vergleich immer die Kombination aus Netztyp und eingesetztem Optimierungsverfahren bzw. Heuristik bewertet werden.

Für die verschiedenen neuronalen Netztypen sind unterschiedliche Basisfunktionstypen üblich. Da es nicht auf den exakten Funktionsverlauf sondern mehr auf dessen Charakter ankommt, wird insbesondere zwischen globalen und lokalen



**Abb. 3.** Beispiele für globale und lokale Basisfunktionen.

Basisfunktionen unterschieden, siehe Abbildung 3. Streng globale Basisfunktionen, die nirgendwo in eine Sättigung laufen, kommen bei neuronalen Netzen üblicherweise nicht zum Einsatz. Globale Basisfunktionen werden normalerweise im Multilayer-Perzeptron eingesetzt, siehe Abschnitt 4. Lokale Basisfunktionen finden typischerweise in Netzen mit radialen Basisfunktionen, Neuro-Fuzzy-Netzen und lokalen Modellansätzen Verwendung, siehe Abschnitte 5–7, wobei der streng lokale Typ exakt und nicht nur asymptotisch auf Null abklingt.

Ein noch wichtigeres Merkmal als die Form der Basisfunktionen der verschiedenen Netztypen ist allerdings die Art und Weise, wie vom eindimensionalen Fall auf den höherdimensionalen Fall verallgemeinert wird. Diese Konstruktionsprinzipien werden im nächsten Abschnitt vorgestellt.

### 3 Konstruktionsprinzipien

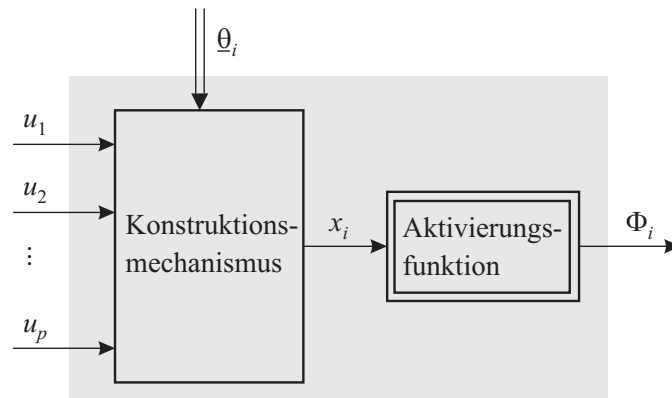
Ein Neuron  $i$  der verdeckten Schicht (siehe Abbildung 4) bildet einen  $p$ -dimensionalen Eingangsvektor  $\underline{u} = [u_1 \ u_2 \ \dots \ u_p]^T$  mit Hilfe der Parameter, die im Vektor  $\underline{\theta}_i$  zusammengefasst sind, auf eine skalare Größe ab, die sog. Aktivierung  $x_i$ , welche dann mittels der sog. Aktivierungsfunktion auf den Neuronenausgangswert nichtlinear transformiert wird. Diese Abbildung erfolgt bei neuronalen Netzen i.A. nach einem der in den folgenden drei Unterabschnitten beschriebenen Konstruktionsprinzipien.

#### 3.1 Skalarprodukt-Konstruktion

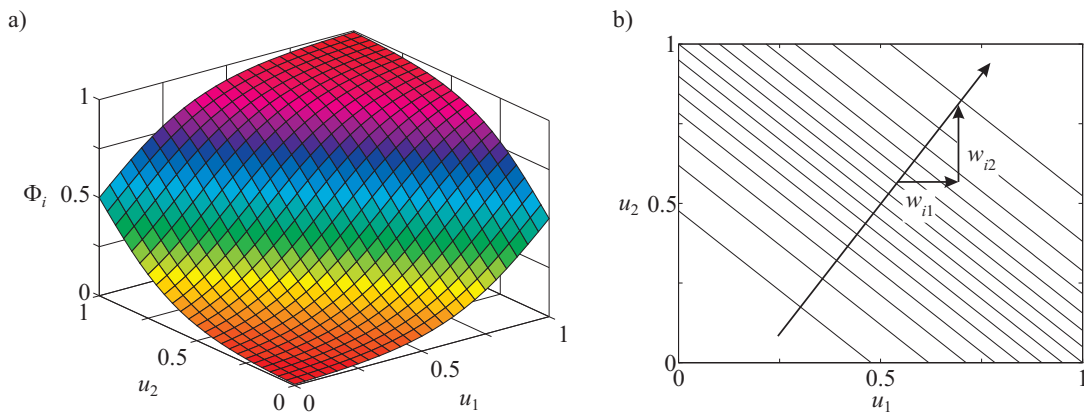
Die Skalarprodukt-Konstruktion (engl. *ridge construction*) projiziert den Eingangsvektor  $\underline{u}$  auf den Parametervektor  $\underline{\theta}_i = [w_{i0} \ w_{i1} \ w_{i2} \ \dots \ w_{ip}]^T$ :

$$x_i = w_{i0} + w_{i1}u_1 + w_{i2}u_2 + \dots + w_{ip}u_p. \quad (4)$$

Dies bedeutet, wie in Abbildung 5 illustriert, dass sich die durch dieses Neuron realisierte Basisfunktion entlang der Richtung des Parametervektors  $\underline{\theta}_i$  nichtlinear verändert, aber in allen  $p - 1$  dazu senkrechten Richtungen konstant verhält.



**Abb. 4.** Der Konstruktionsmechanismus bildet den hochdimensionalen Eingangsvektor auf eine skalare Größe ab.



**Abb. 5.** Skalarprodukt-Konstruktion: a) Basisfunktion mit ihren Höhenlinien (b).


Mit der Optimierung der Parameter in  $\underline{\theta}_i$  werden also die wichtigsten Richtungen nichtlinearen Verhaltens im Eingangsraum gefunden. Daher sind neuronale Netze, die auf diesem Konstruktionsmechanismus basieren, relativ unempfindlich gegenüber redundanten Eingängen und auch für sehr hochdimensionale Probleme ausgezeichnet geeignet. Es werden pro Neuron der verdeckten Schicht  $p + 1$  Parameter benötigt.

### 3.2 Radiale Konstruktion

Bei der radialen Konstruktion hängt die Aktivität  $x_i$  vom Abstand des Eingangsvektors zu einem neuronenspezifischen Zentrumsvektor  $\underline{c}_i = [c_{i1} \ c_{i2} \ \dots \ c_{ip}]^T$  ab. Im einfachsten Fall ist dies der euklidische Abstand:

$$\begin{aligned} x_i &= \|\underline{u} - \underline{c}_i\| = \sqrt{(\underline{u} - \underline{c}_i)^T (\underline{u} - \underline{c}_i)} \\ &= \sqrt{(u_1 - c_{i1})^2 + (u_2 - c_{i2})^2 + \dots + (u_p - c_{ip})^2}. \end{aligned} \quad (5)$$

Abbildung 6a zeigt Linien (Kreise) gleichen Abstands vom Zentrumsvektor  $\underline{c}_i$ . Wird die Abstandsnorm in (6) auf den Mahalanobis-Abstand erweitert, so



**Abb. 6.** Höhenlinien für eine radiale Konstruktion mit a) identisch skalierten Achsen ( $\underline{\Sigma}^{-1} = \underline{I}$ ), b) unterschiedlich skalierten Achsen ( $\underline{\Sigma}^{-1} = \text{diagonal}$ ), c) unterschiedlich skalierten und gedrehten Achsen ( $\underline{\Sigma}^{-1} = \text{symmetrisch}$ ).

ergibt sich allgemein

$$x_i = \|\underline{u} - \underline{c}_i\|_{\underline{\Sigma}^{-1}} = \sqrt{(\underline{u} - \underline{c}_i)^T \underline{\Sigma}_i^{-1} (\underline{u} - \underline{c}_i)} \quad (6)$$

mit den Kovarianzmatrizen  $\underline{\Sigma}_i$ , welche die Achsenskalierungen und -rotationen der Ellipsen in Abbildung 6 charakterisieren. In der Praxis beschränkt man sich oft auf den in Abbildung 6b dargestellten Fall

$$\underline{\Sigma}_i^{-1} = \begin{pmatrix} 1/\sigma_{i1}^2 & 0 & \cdots & 0 \\ 0 & 1/\sigma_{i2}^2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 1/\sigma_{ip}^2 \end{pmatrix}, \quad (7)$$

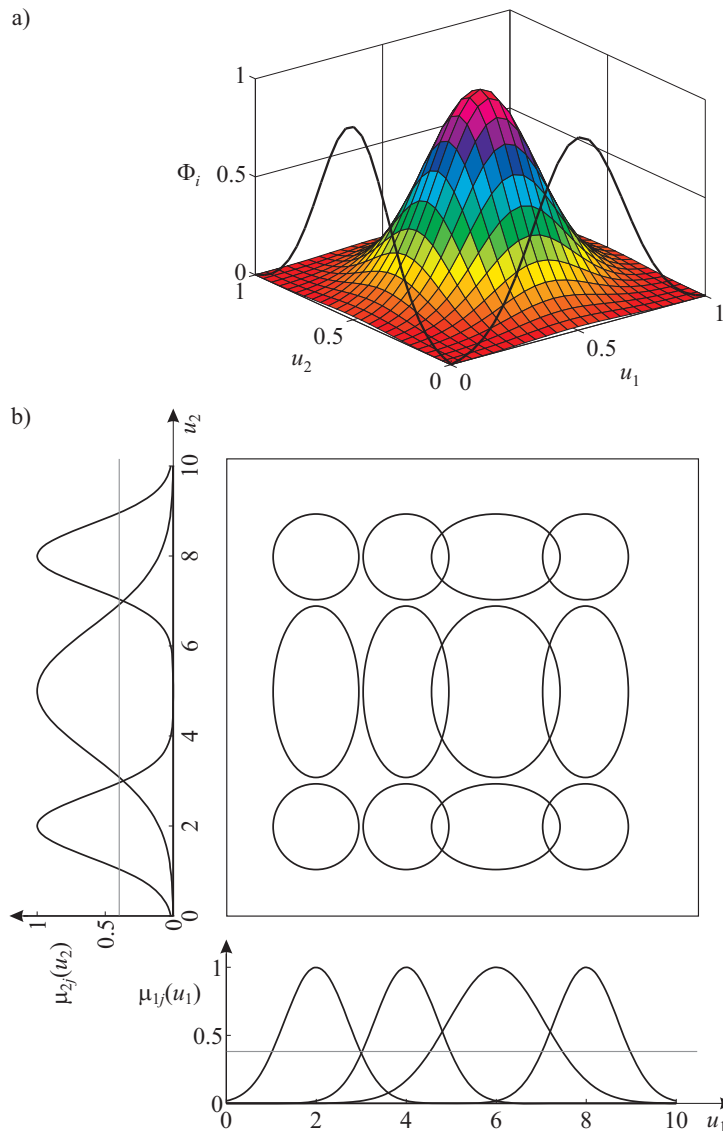
weil der in Abbildung 6c gezeigte allgemeine Fall, insbesondere für hochdimensionale Probleme (großes  $p$ ), extrem viele Parameter benötigt ( $\propto p^2$ ). Für den Fall einer Abstandsnorm mit Kovarianzmatrix nach (7) ergeben sich für die radiale Konstruktion  $2p$  Parameter  $\underline{\theta}_i = [c_{i1} \cdots c_{ip} \ \sigma_{i1} \cdots \sigma_{ip}]^T$  pro Neuron der verdeckten Schicht.

### 3.3 Tensorprodukt-Konstruktion

Die Tensorprodukt-Konstruktion wird auch außerhalb der Welt der neuronalen Netze häufig verwendet. Dies ist genau der Mechanismus, der bei Rasterkennfeldern und Splines zum Einsatz kommt. Die mehrdimensionalen Basisfunktionen  $\Phi(\underline{u})$  werden durch Multiplikation eindimensionaler Zugehörigkeitsfunktionen  $\mu_{ij}(u_i)$  erzeugt, wobei der Index  $j$  über die Anzahl der Zugehörigkeitsfunktionen pro Eingangsgröße läuft, siehe Abbildung 7:

$$x_i = \mu_{1j_1}(u_1) \cdot \mu_{2j_2}(u_2) \cdot \dots \cdot \mu_{pj_p}(u_p). \quad (8)$$

Da alle Zugehörigkeitsfunktionen der verschiedenen Eingänge miteinander kombiniert werden können, steigt die Anzahl der Basisfunktionen (und damit



**Abb. 7.** Tensorprodukt-Konstruktion: a) Basisfunktionen entstehen als Produkt der eindimensionalen Zugehörigkeitsfunktionen und b) erzeugen damit eine Gitterstruktur.

der Neuronen der verdeckten Schicht) exponentiell mit der Dimension des Eingangsraums  $p$  an. Wird jede eindimensionale Zugehörigkeitsfunktion durch zwei Parameter charakterisiert, z.B. Mittelwert und Standardabweichung einer Gaußglocke, dann ergeben sich für die Tensorprodukt-Konstruktion  $2p$  Parameter pro Neuron der verdeckten Schicht  $\underline{\theta}_i = [c_{1j_1} \ c_{2j_2} \ \cdots \ c_{pj_p} \ \sigma_{1j_1} \ \sigma_{2j_2} \ \cdots \ \sigma_{pj_p}]^T$  und

$$M = \prod_{i=1}^p M_i \quad (9)$$

Neuronen bei  $M_i$  Zugehörigkeitsfunktionen pro Eingang  $u_i$ . Modelle mit Tensorprodukt-Konstruktion unterliegen also in voller Schärfe dem Fluch der Dimensionalität.




## 4 Multilayer-Perzeptron

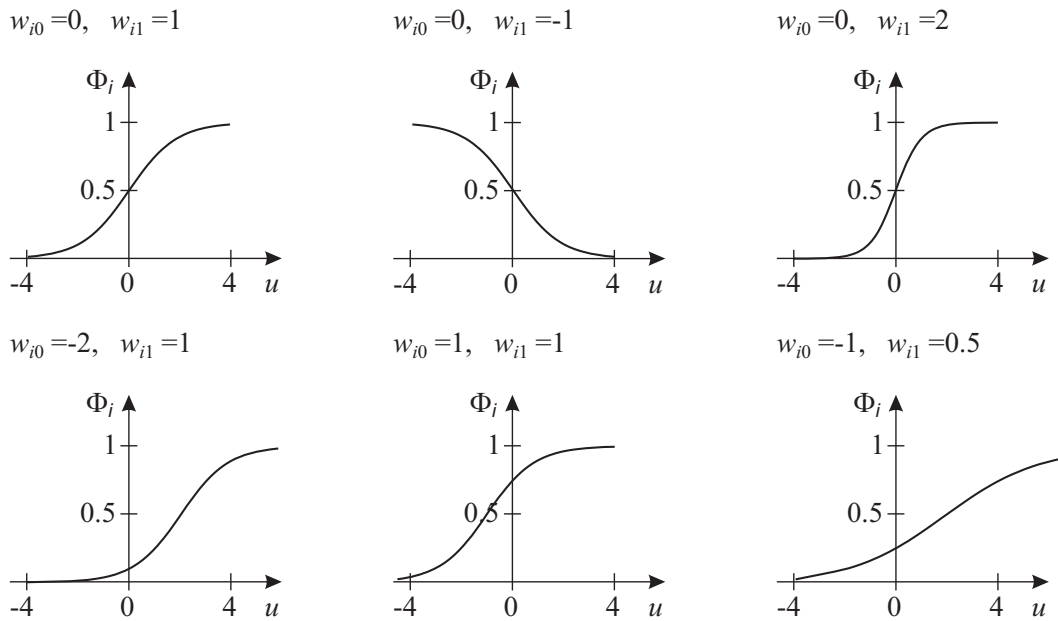
Der populärste neuronale Netztyp ist das Multilayer-Perzeptron (MLP), manchmal auch fälschlicherweise als „Backpropagation-Netz“ bezeichnet. Die häufig anzutreffende falsche Bezeichnung rührt von einer Verquickung des Trainingsverfahrens mit dem Netztyp her und wird weiter unten noch näher erläutert. Typisch für das MLP ist die Verwendung der Skalarprodukt-Konstruktion und einer sigmoiden Aktivierungsfunktion wie in der 2. Spalte von Abbildung 3 gezeigt. Ein einzelnes solches Neuron der verdeckten Schicht wird in Abbildung 8 dargestellt und wurde als Perzeptron bekannt, wodurch sich der Name MLP erklärt. Im Neuron der Ausgangsschicht wird entweder auch eine sigmoide oder eine lineare Aktivierungsfunktion gewählt. Letzteres führt dann exakt auf die Basisfunktionendarstellung nach (1) und Abbildung 2. Manchmal sind auch MLPs mit mehreren hintereinander geschalteten verdeckten Schichten anzutreffen. Eine solche erweiterte Netzarchitektur ist aber nur bei sehr komplexen Problemen sinnvoll, weil durch die Verschaltung mehrere verdeckter Schichten sehr viele Parameter entstehen. So hat ein MLP mit  $p$  Eingängen, einem Ausgang und einer verdeckten Schicht bestehend aus  $M$  Neuronen entsprechend Abbildung 2  $M(p + 1) + M + 1$  Parameter. Ein MLP mit zwei verdeckten Schichten bestehend aus  $M_1$  bzw.  $M_2$  Neuronen weist schon  $M_1(p + 1) + M_2(M_1 + 1) + M_2 + 1$  Parameter auf. D.h. die Anzahl der Parameter wächst quadratisch mit der Neuronenanzahl ( $\propto M_1 M_2$ ). Daher wird in den weitaus meisten Anwendungen auf MLPs mit einer verdeckten Schicht gesetzt.

Die sigmoiden Aktivierungsfunktionen jedes Neurons  $i$  des MLPs lassen sich mit Hilfe der Parameter in  $\underline{\theta}_i$ , wie in Abbildung 9 gezeigt, im Eingangsraum verschieben, in ihrer Steilheit verändern und spiegeln. Im höherdimensionalen Fall wird auch die Richtung der Nichtlinearität im Eingangsraum durch diese Parameter festgelegt, vergleiche Abbildung 5. Des Weiteren erlauben die Gewichte der Ausgangsschicht eine Verschiebung und Skalierung in  $y$ -Richtung.

Der Ausgangswert des MLPs ergibt sich aus einer gewichteten Überlagerung dieser sigmoiden Funktionen. Mittels Optimierung seiner Parameter kann das Netz die wesentlichen Richtungen, in denen die Nichtlinearität wirkt, „erkennen“ und durch entsprechendes Ausrichten der Parametervektoren  $\underline{\theta}_i$  modellieren. Wegen dieser Eigenschaft ist das MLP und alle anderen auf der Skalarprodukt-Konstruktion basierenden Ansätze besonders gut für hochdimensionale Probleme geeignet. Der Preis, der hierfür zu zahlen ist, besteht in der Notwendigkeit, die



**Abb. 8.** Perzeptron: Ein Neuron der verdeckten Schicht eines MLPs.



**Abb. 9.** Einfluss der Parameter eines Neurons der verdeckten Schicht auf die Form der Basisfunktion.

Parameter der verdeckten Schicht zu optimieren. Da diese Parameter den Netzausgang nichtlinear beeinflussen, ist dies eine zeitaufwendige Aufgabe, welche auch die Gefahr der Konvergenz in ein schlechtes lokales Optimum birgt.

Typischerweise werden alle Parameter eines MLPs gleichzeitig mit einem Trainingsverfahren optimiert. Traditionell kommt dabei ein einfaches Gradientenverfahren zum Einsatz. Die dafür notwendige symbolische Berechnung der Gradienten kann mit einem Trick vereinfacht werden. Diese Gradientenberechnung wird „Backpropagation“ genannt und galt in den 1980er Jahren als Durchbruch, weil sie erstmals das Training der Parameter der verdeckten Schicht erlaubte [6]. Das Backpropagation-Verfahren wurde gedanklich so eng mit dem MLP verbunden, dass es zunehmend synonym zum Netztyp gebraucht wurde. Aus der modernen Sicht der Dinge, stellt das Training der Netzparameter ein ganz normales nichtlineares Optimierungsproblem dar, das auch mit den Standardverfahren der numerischen Mathematik viel effizienter gelöst werden kann. Heute werden für das Training von MLPs vorwiegend die nichtlineare Least-Squares-Methode nach Levenberg-Marquardt oder für besonders große Netze ein konjugiertes Gradientenverfahren eingesetzt. Beide bauen mehr oder weniger Information über die zweite Ableitung (Krümmung) der Gütefunktion auf und konvergieren damit deutlich schneller als das Standard-Gradientenverfahren.

## 5 Netze mit radialen Basisfunktionen

Der wahrscheinlich zweitbeliebteste Netztyp verwendet radiale Basisfunktionen (RBF). Normalerweise werden lokale oder streng lokale Basisfunktionen eingesetzt, so dass man bestimmten Bereichen im Eingangsraum die RBFs zuordnen

kann, deren Zentren dort platziert sind. Ein RBF-Neuron der verdeckten Schicht ist in Abbildung 10 dargestellt. In vielen Anwendungen wird die Kovarianzmatrix  $\underline{\Sigma}$  auf Diagonalform eingeschränkt, was zu achsenorthogonalen Basisfunktionen und einer erheblich reduzierten Parameteranzahl führt.

Obwohl es wie beim MLP- auch beim RBF-Netz möglich ist, alle Parameter gleichzeitig mittels eines nichtlinearen Optimierungsverfahrens zu trainieren, wird dies gewöhnlich vermieden. Statt dessen versucht man die im Gegensatz zum MLP vorhandene bessere Interpretierbarkeit der Parameter, z.B. als Zentren und Standardabweichungen gaußförmiger RBFs, auszunutzen. Die Parameter der Neuronen der verdeckten Schicht  $c_{ij}$  und  $\sigma_{ij}$  werden dabei durch eine suboptimale Heuristik festgelegt, und anschließend werden die Gewichte  $w_i$  der Ausgangsschicht mittels der Methode der kleinsten Quadrate nach (3) geschätzt. Mit einer solchen Vorgehensweise werden im Vergleich zum MLP zwar wesentlich mehr Neuronen benötigt, der Rechenaufwand ist aber dennoch wegen der Vermeidung einer iterativen nichtlinearen Optimierung um Größenordnungen geringer. Außerdem erlaubt eine solche zweistufige Methode eine nachträgliche Adaption der Ausgangsgewichte. Dies kann auch online mittels einer rekursiven Least-Squares (RLS) Methode zuverlässig und numerisch robust erfolgen. So etwas wird man bei den nichtlinearen Parameterabhängigkeiten des MLP i.a. nicht wagen.

Für die oben erwähnte Heuristik zur Bestimmung der Zentren kommen u.a. die im Folgenden beschriebenen Ansätze in Betracht. Die Standardabweichungen können danach z.B. anhand des mittleren Abstands zu den nächsten Nachbarzentren ermittelt werden (engl: *nearest neighbor*).

- *Gitter*: Der Vorteil einer gitterförmigen Verteilung der RBFs liegt in deren identischem Abstand. Daher lassen sich die Standardabweichungen leicht wählen und das weiter unten beschriebene Problem der evtl. auftretenden „Dellen“ im Funktionsverlauf wegen zu geringer Überlappung der Basisfunktionen wird vermieden. Der wesentliche Nachteil einer jeden Gitterstrategie ist das exponentielle Anwachsen der RBF-Anzahl mit der Eingangsraumdimension genau wie beim Rasterkennfeld. Dieser Nachteil lässt sich zwar durch Erweiterungen und Verbesserungen etwas reduzieren, bleibt im Prinzip aber bestehen. Mögliche Verbesserungen sind die Kombination mehrerer Gitter unterschiedlicher Auflösung je nach Bedarf und ein reduziertes Gitter,




Abb. 10. RBF-Neuron der verdeckten Schicht.

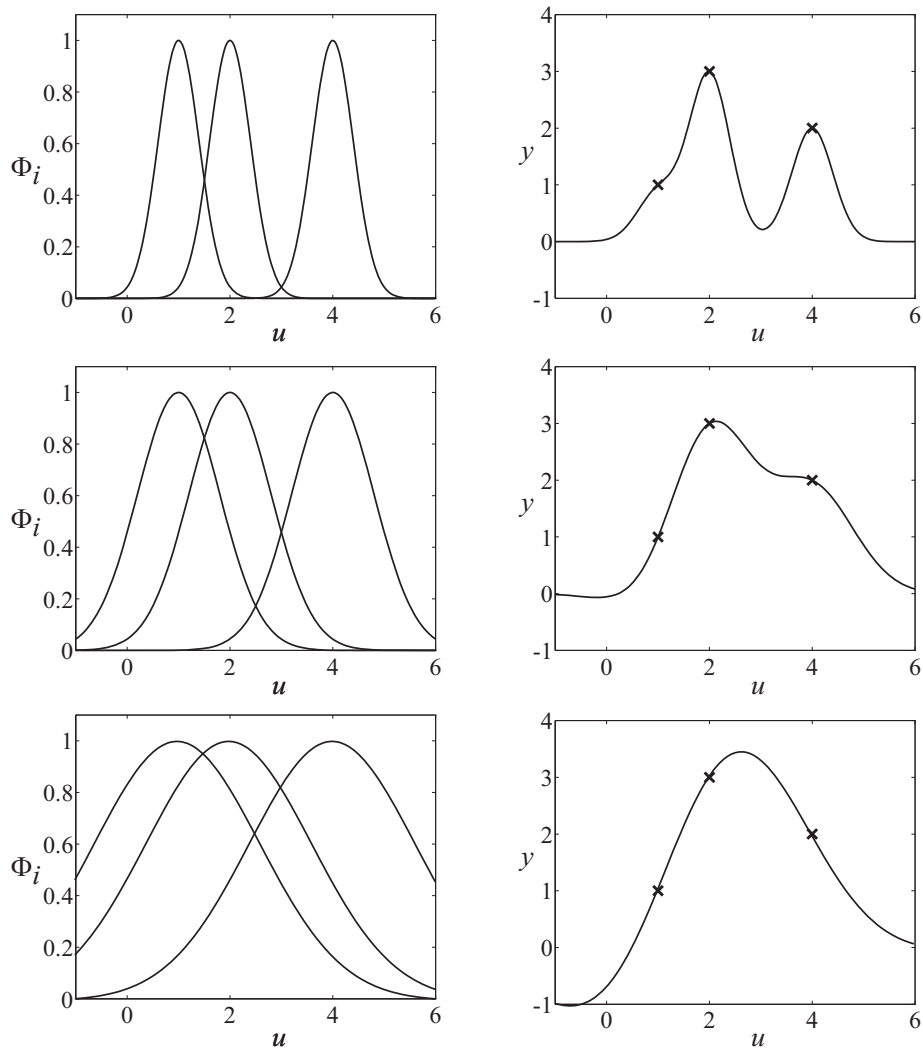
bei dem nur dort RBFs platziert werden, wo auch Datenpunkte in der Nähe liegen.

- *Datenpunkte:* Das Platzieren der RBFs auf den Koordinaten der Datenpunkte im Eingangsraum  $\underline{c}_i = [u_1(i) \ u_2(i) \ \cdots \ u_p(i)]^T$ ,  $i = 1, 2, \dots, N$ , hat den Vorteil, die Basisfunktionen nur dort zu erzeugen, wo auch Daten zur Schätzung ihrer Parameter vorhanden sind. Im Normalfall gibt es deutlich mehr Datenpunkte  $N$  als gewünschte Basisfunktionen  $M$  und es muss eine Auswahl getroffen werden. Neben der primitiven Vorgehensweise einer zufälligen Selektion gibt es auch inkrementelle Verfahren, die jeweils an dem Datenpunkt, der den größten Approximationsfehler aufweist, eine neue Basisfunktion erzeugen. Solche Ansätze sind allerdings sehr anfällig bezüglich Rauschen und Ausreißern. Eine weitere Methode, welche die Selektion der RBFs optimiert, wird weiter unten beschrieben.
- *Clustering:* Als Verallgemeinerung der datenpunkt-basierten RBF-Platzierung kann das Clustering aufgefasst werden. Die Vorgehensweise ist im Prinzip identisch, nur dass zuvor die sehr große Anzahl an Datenpunkten  $N$  auf eine viel kleinere Anzahl an Clusterpunkten  $N_C$  reduziert wurde. Der Sonderfall  $M = N_C$  ist besonders einfach: Dann wird jedem Cluster genau ein RBF zugeordnet [3].

Die oben beschriebenen Verfahren haben den Nachteil, dass sie ihren Fokus auf die Datenverteilung im Eingangsraum legen und dabei die Komplexität der zu approximierenden Funktion aus dem Auge verlieren.

Eine durch [2] populär gewordene leistungsfähige Alternative zu den oben aufgeführten Ansätzen geht von einer großen Zahl potentieller Basisfunktionen aus, z.B. wird eine potentielle Basisfunktion auf jeden Messdatenpunkt im Eingangsraum gelegt und die Standardabweichung plausibel festgelegt. Aus dieser großen Anzahl potentieller Basisfunktionen werden die statistisch wichtigsten ausgewählt. Dies kann effizient mittels eines orthogonalen Least-Squares-Verfahrens (OLS) geschehen, bei dem in jedem Schritt die Basisfunktion selektiert wird, welche die größte Verbesserung bringt. Damit wird zwar nicht notwendigerweise die global beste Kombination aus Basisfunktionen gefunden (das ist ein kombinatorisches Optimierungsproblem!), aber die Ergebnisse sind in der Praxis sehr gut. Problematischer ist hingegen die Festlegung der Standardabweichungen im Vorhinein, da anfangs noch nicht feststeht, welche Basisfunktionen selektiert werden werden und damit die nächste Nachbarn-Methode nicht angewandt werden kann. Ein zu kleine Festlegung der Standardabweichungen kann zu „Dellen“ im Funktionsverlauf führen, siehe Abbildung 11 (oben).

Die Empfindlichkeit bezüglich einer guten Wahl der Standardabweichungen ist eine der Hauptschwächen der RBF-Netze. Durch eine Normierung der Basisfunktionen kann dieser Schwachpunkt aufgehoben und für die meisten Anwendungen ein günstigeres Interpolations- und Extrapolationsverhalten erzielt werden. Diese normierten RBF-Netze (NRBF) werden ebenfalls durch einen Basisfunktionen-Ansatz wie in (1) beschrieben; allerdings kann der Gleichwert



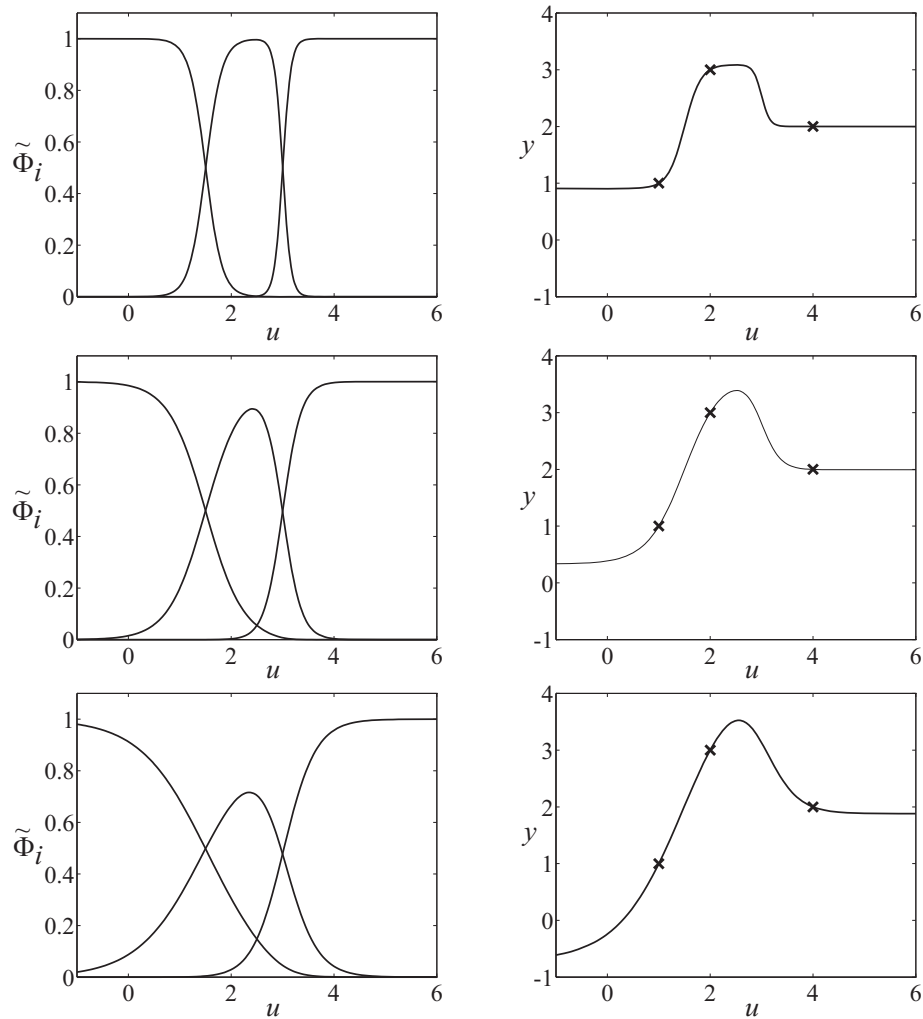
**Abb. 11.** Interpolations- und Extrapolationsverhalten eines RBF-Netzes mit kleinen, mittleren und großen Standardabweichungen für drei Datenpunkte markiert mit „x“.

$w_0$  entfallen, da die normierten Basisfunktionen diesen mit modellieren

$$\hat{y}(u) = \sum_{i=1}^M w_i \tilde{\Phi}_i(u, \theta_i) \quad \text{mit} \quad \tilde{\Phi}_i(u, \theta_i) = \frac{\Phi_i(u, \theta_i)}{\sum_{j=1}^M \Phi_j(u, \theta_j)}. \quad (10)$$

Daher kann ein NRBF-Netz auch als RBF-Netz mit den speziellen Basisfunktionen  $\tilde{\Phi}_i$  aufgefasst werden. Wichtig für das Verständnis ist, dass diese Basisfunktionen durch den gemeinsamen Normierungsnenner miteinander stark gekoppelt sind, also z.B. nicht unabhängig voneinander selektiert werden können.

Wie im Vergleich zwischen Abbildung 11 und Abbildung 12 zu sehen ist, verändert sich die Form der Basisfunktionen durch die Normierung erheblich. Das Extrapolationsverhalten ist nun konstant statt gehen Null abzufallen und das Interpolationsverhalten weist auch bei kleinen Standardabweichungen keine



**Abb. 12.** Interpolations- und Extrapolationsverhalten eines normierten RBF-Netzes mit kleinen, mittleren und großen Standardabweichungen für drei Datenpunkte markiert mit „x“.

„Dellen“ mehr auf. Diesen Vorteilen stehen einige Schwierigkeiten gegenüber, die bei der Normierung auftauchen können, siehe [4] und [7] für Details.

## 6 Neuro-Fuzzy-Netze

Mit Fuzzy-Systemen [10] kann ein nichtlinearer Zusammenhang zwischen den Eingangsgrößen und dem Ausgang in Form von Regeln beschrieben werden. Falls diese Regeln nicht von einem Experten formuliert werden sondern aus Messdaten gelernt werden sollen, spricht man wegen historischer Analogien bei der Entwicklung der Trainingsverfahren von Neuro-Fuzzy-Netzen. Dafür kommen meist die einfachen Singleton- bzw. Takagi-Sugeno-Fuzzy-Systeme zum Einsatz, bei denen die Regelkonklusionen mittels (scharfen) Gleichungen und nicht Fuzzy-Mengen beschrieben werden. Fuzzy-Systeme mit Singletons setzen sich aus  $i = 1, \dots, M$

Regeln der folgenden Form zusammen:

$R_i$  : Wenn  $u_1 = \text{klein}$  UND  $u_2 = \text{hoch}$  UND ... UND  $u_n = \text{mittel}$  Dann  $y = s_i$

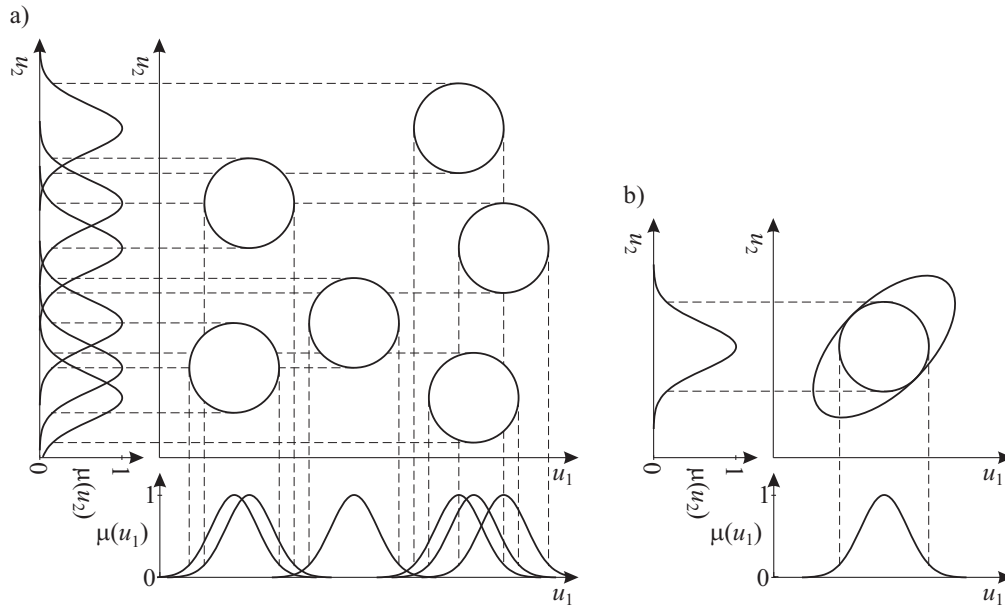
Die Singletons  $s_i$  können als gewünschter Ausgangswert für einen bestimmten Bereich des Eingangsraums interpretiert werden. Dieser Bereich wird durch die Konjunktion (Verundung) der Fuzzy-Terme in der Regelprämisse erzeugt und entspricht einer Basisfunktion  $\Phi_i(\underline{u}, \underline{\theta}_i)$ . Der Wert dieser Basisfunktion kann als Aktivierungsgrad der Regel  $R_i$  interpretiert werden. Der Ausgang eines solchen Neuro-Fuzzy-Systems ergibt sich aus einer gewichteten Mittelung der Singletons. Jeder Singleton wird mit seinem (normierten) Beitrag, nämlich dem Aktivierungsgrad der Regel, gewichtet. Bei  $M$  Regeln ergibt sich:

$$\hat{y}(\underline{u}) = \frac{\sum_{i=1}^M s_i \Phi_i(\underline{u}, \underline{\theta}_i)}{\sum_{j=1}^M \Phi_j(\underline{u}, \underline{\theta}_j)}. \quad (11)$$

Durch die Normierung im Nenner wird sichergestellt, dass sich die Aktivierungsgrade aller Regeln genau zu 100% aufsummieren. Ein Vergleich zwischen (11) und (10) zeigt, dass ein Singleton-Fuzzy-System identisch mit einem NRBF-Netz ist, wobei die Singletons den Ausgangsgewichten entsprechen  $s_i = w_i$ . Allerdings ist die Interpretation der gewichteten Summe genau entgegengesetzt. Im Fuzzy-Fall werden die  $s_i$  mit den normierten Basisfunktion (= Regelaktivierungen) gewichtet; im NRBF-Fall werden die  $\tilde{\Phi}_i$  mit den Gewichten  $w_i$  gewichtet.

Eine wesentliche Eigenschaft der Fuzzy-Systeme ist, dass die Basisfunktionen aus eindimensionalen Zugehörigkeitsfunktion durch Konjunktion (oder andere logische Operatoren) erzeugt werden. Dies entspricht genau der in Abschnitt 3.3 beschriebenen Tensorprodukt-Konstruktion. Da es Menschen schwer fällt, in hochdimensionalen Zusammenhängen zu denken, ermöglichen die Fuzzy-Regeln eine anschauliche Interpretation. Damit die Anschaulichkeit nicht nur auf dem Papier sondern auch in der Realität existiert, darf die Anzahl der Zugehörigkeitsfunktionen pro Eingangsgröße nicht zu groß werden. Durch diese Forderung und die Eigenschaften der Tensorprodukt-Konstruktion ergeben sich für die praktische Anwendung starke Einschränkungen in Bezug auf die Flexibilität eines solchen Neuro-Fuzzy-Systems im Vergleich zum formal äquivalenten NRBF-Netz, siehe Abbildung 13.

Die Parameter der Basisfunktionen  $\underline{\theta}_i$  setzen sich aus den Parametern von jeweils  $p$  Zugehörigkeitsfunktionen zusammen (einer pro Eingangsgröße), z.B. deren Zentren und Standardabweichungen. Durch die rasterförmige Anordnung ist die Anzahl der Freiheitsgrade aber erheblich geringer als bei NRBF-Netzen, nämlich nur  $2mp$  unabhängige Parameter, wenn  $m$  die Anzahl der Zugehörigkeitsfunktionen pro Eingangsgröße ist, also  $M = m^p$  gilt. Für das Training solcher Neuro-Fuzzy-Netze gibt es viele verschiedene Ansätze. Meist werden die Parameter der Zugehörigkeitsfunktionen mittels Vorwissen festgelegt oder zumindest sinnvoll vorinitialisiert und anschließend die Singletons mit der Methode



**Abb. 13.** Einschränkungen bei Neuro-Fuzzy-Systemen: a) Die  $M$  Basisfunktionen müssen auf einem Gitter liegen, damit die eindimensionalen Zugehörigkeitsfunktionen mehrfach genutzt werden sollen. Ist dies nicht der Fall ergeben sich pro Eingang  $M$  Zugehörigkeitsfunktionen. b) Die Basisfunktionen müssen achsenorthogonal sein (d.h. diagonale  $\underline{\Sigma}$  aufweisen), sonst lassen sie sich nicht aus eindimensionalen Zugehörigkeitsfunktionen konstruieren, was die Interpretationsvorteile des Fuzzy-Systems zerstört.

der kleinsten Quadrate optimiert. Generell besteht die Stärke der Neuro-Fuzzy-Ansätze in der Ausnutzung von Vorwissen zur Reduktion der Anzahl der freien Parameter und in der nachträglichen Interpretation von datenbasierten Schätzergebnissen.

## 7 Netze mit lokalen Modellen

Bei den im letzten Abschnitt beschriebenen Neuro-Fuzzy-Netzen wird jeder Regel  $R_i$  und damit jedem durch eine Basisfunktion  $\Phi_i$  beschriebenen Eingangsbereich ein Singleton  $s_i$  zugeordnet. Eine naheliegende Erweiterung dieser Idee ist die Verallgemeinerung von einem Singleton, also einer Konstanten, auf eine nichtlineare Funktion  $f_i(\underline{u})$ . Die Regeln heißen dann: Wenn ... Dann  $y = f_i(\underline{u})$  und der Ausgang berechnet sich nach:

$$\hat{y}(\underline{u}) = \frac{\sum_{i=1}^M f_i(\underline{u})\Phi_i(\underline{u}, \theta_i)}{\sum_{j=1}^M \Phi_j(\underline{u}, \theta_j)}. \quad (12)$$

Ein solches erweitertes Neuro-Fuzzy-Netz wird nach dessen Erfindern Takagi-Sugeno-Fuzzy-System genannt [9]. Die nichtlinearen Funktionen  $f_i(\underline{u})$  werden



sinnvollerweise linear parametrisiert gewählt, um deren Parameter, wie die Singletons, mit der Methode der kleinsten Quadrate schätzen zu können. Eine typische Wahl fällt auf Polynome und in den allermeisten Fällen beschränkt man sich auf lineare Funktionen, also

$$f_i(\underline{u}) = w_{i0} + w_{i1}u_1 + w_{i2}u_2 + \dots + w_{ip}u_p. \quad (13)$$

Je komplexer und flexibler die Funktionen  $f_i(\underline{u})$  gewählt werden, umso weniger Basisfunktionen wird man benötigen, um eine vorgegebene Modellgüte zu erreichen. In einem Extremfall könnte man ein Polynom hohen Grades wählen, und nur noch  $M = 1$  Basisfunktionen verwenden. Wegen der Normierung wäre diese dann überall  $\Phi_1(\underline{u}) = 1$ , und (12) reduzierte sich auf ein reines Polynom. Im anderen Extremfall könnte man ein Polynom nullten Grades wählen. Dies ergäbe ein Singleton-Neuro-Fuzzy-System mit  $s_i = w_{i0}$ .

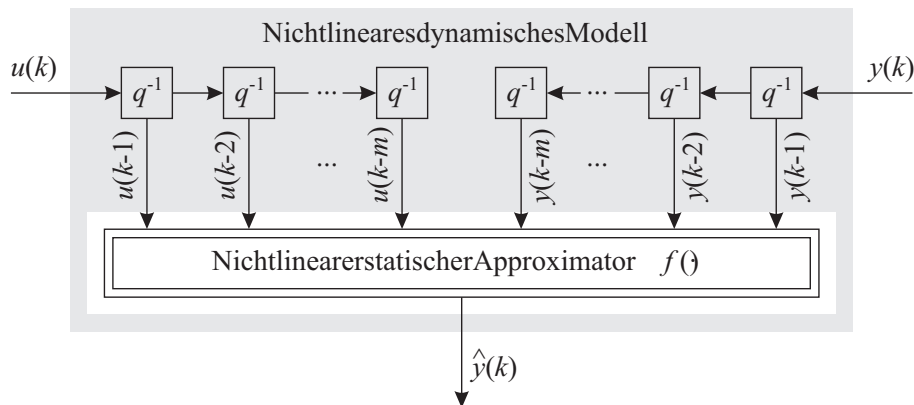
Lineare (genauer: affine)  $f_i(\underline{u})$  nach (13) haben sich in vielerlei Hinsicht als sehr guter Kompromiss zwischen diesen Extremen erwiesen. Denn für die sich daraus ergebenden lokal linearen Modelle lassen sich viele Ergebnisse aus der linearen Theorie (teilweise) übertragen.

Für solche Netze mit lokal linearen Modellen gibt es eine Vielzahl sehr erfolgreicher Trainingsverfahren die in [4] beschrieben und in [5] methodisch verglichen worden sind. Die gegenwärtig am meisten verwendeten Trainingsstrategien basieren entweder auf Clusteringverfahren im Produktraum, d.h. im Raum, der gemeinsam von den Eingangsachsen und der Ausgangsachse aufgespannt wird, oder sie setzen heuristische Baumkonstruktionsmethoden ein, bei denen der Eingangsraum schrittweise unterteilt und damit das Modell inkrementell verfeinert wird. Bei den Clusteringverfahren werden meist beliebige Kovarianzmatrizen  $\underline{\Sigma}_i$  für die Basisfunktionen erlaubt, um den Fluch der Dimensionalität abzuschwächen. Wie Abbildung 13 zeigt, gibt man damit aber einen Großteil der Interpretierbarkeit der Fuzzy-Regeln auf. Die Baumkonstruktionsmethoden basieren meist auf achsenorthogonalen Unterteilungen des Eingangsraums, die eine Projektion auf eindimensionale Zugehörigkeitsfunktionen weiterhin zulassen, aber für hochdimensionale Probleme sehr ineffektiv werden können. Generell scheint hier ein Abwägen zwischen Interpretierbarkeit und Performance notwendig.

Besonders gut geeignet sind solche lokal linearen Modellansätze zur Behandlung dynamischer Systeme, weil jedes lokale Modell dann eine lineare Differenzgleichung beschreibt. Netze mit lokal linearen Modellen sind daher äquivalent zur Klasse der sog. linear parametervarianten (LPV) Systeme.

## 8 Behandlung dynamischer Systeme

Dynamische Eigenschaften können entweder direkt in ein neuronales Netz eingebaut werden, indem man beispielsweise Zeitverzögerungsglieder oder ganze Filter in die Neuronen aufnimmt oder das Netz kann als solches statisch bleiben und mit verzögerten Ein- und Ausgängen beschaltet werden. Erstere Alternative entspricht dem Ansatz mit interner Dynamik, die zweite Möglichkeit dem Ansatz mit externer Dynamik, der weitaus häufiger anzutreffen ist, siehe Abbildung 14.



**Abb. 14.** Ein neuronales Netz realisiert mit der statischen Abbildung  $f(\cdot)$  einen Einschritt-Prädiktor ( $q^{-1}$  ist der Zeitverschiebeoperator).

Die einfachste Variante des externen Dynamikansatzes ist die sog. NARX-Struktur. Diese entspricht einer nichtlinearen ARX-Struktur (AutoRegressiv mit eXogenem Eingang), d.h. der Modellausgang wird als nichtlineare Funktion vergangener Prozessein- und ausgänge beschrieben [8], [4]:

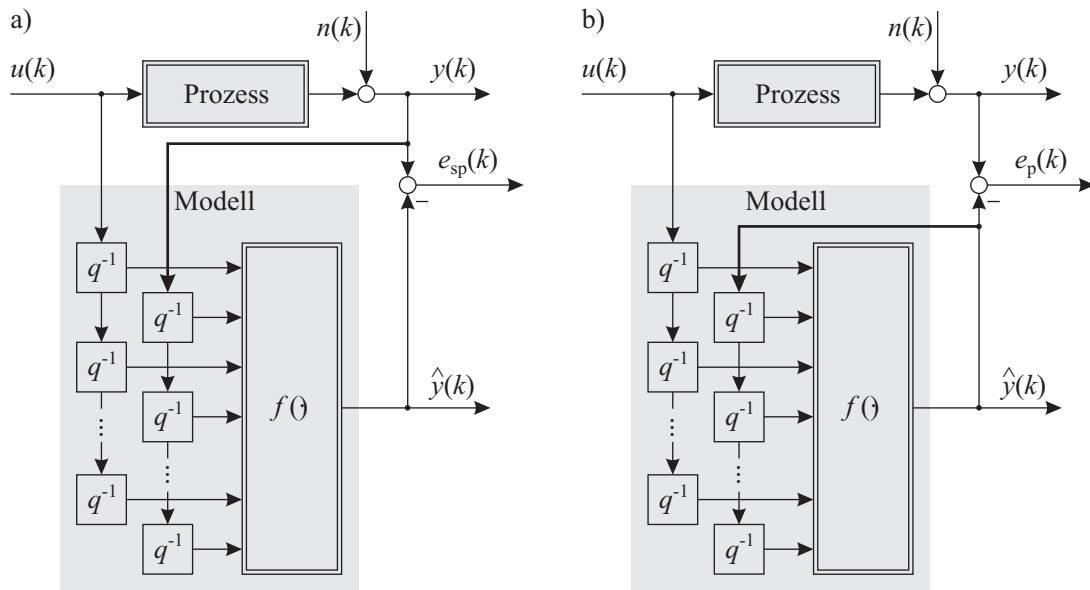
$$\hat{y}(k) = f(u(k-1), \dots, u(k-n), y(k-1), \dots, y(k-n)). \quad (14)$$

Die Dynamikordnung  $n$  entspricht der Ordnung der nichtlinearen Differentialgleichung, welcher der Prozess folgt, und muss in der Praxis durch Vorwissen und Ausprobieren festgelegt werden. Aus (14) wird offensichtlich, dass selbst für Prozesse mit nur einem physikalischen Eingang und moderater Dynamikordnung schon recht hochdimensionale Zusammenhänge modelliert werden müssen.

Mittels (14) bzw. Abbildung 14 wird eine *Einschritt-Prädiktion* durchgeführt. Dafür wird auf die vergangenen *Prozessausgänge* zurückgegriffen. Eine wesentlich anspruchsvollere Aufgabe ist die *Simulation*, bei der nur der Verlauf der Eingangsgröße vorliegt und das neuronale Netze mittels rückgekoppelter vergangener *Modellausgänge* betrieben wird. Abbildung 15 vergleicht diese beiden Anwendungsfälle. Bei der Simulation können sich durch die Rückkopplung kleine Fehler bis hin zu Stabilitätsproblemen „aufschaukeln“, so dass eine sehr hohe Modellgüte und ein „vernünftiges“ Extrapolationsverhalten essentiell sind. In diesem Zusammenhang bieten lokal lineare Modellansätze große Vorteile, weil sie im Extrapolationsfall vorhersagbares dynamisches Verhalten aufweisen.

## 9 Zusammenfassung

In diesem Beitrag wurden die wichtigsten Typen neuronaler Netze mit ihren wesentlichen Eigenschaften vorgestellt. Der Fokus lag dabei auf der Behandlung von höherdimensionalen Approximationsproblemen, bei denen klassische Ansätze wie Polynome oder Rasterkennfelder starke Nachteile aufweisen. Für sehr hochdimensionale Abbildungen sind Multilayer-Perzeptron-Netze und ähnliche



**Abb. 15.** a) Einschritt-Prädiktion: Seriell-paralleles oder Gleichungsfehler-Modell. b) Simulation: Paralleles oder Ausgangsfehler-Modell.

auf der Skalarprodukt-Konstruktion basierende Ansätze besonders gut geeignet, da sie die Richtungen suchen, in denen nichtlineares Verhalten vorliegt. Dies erfordert aber zwingend eine nichtlineare Parameteroptimierung, die viele Nachteile mit sich bringt. Oftmals ist daher der Einsatz radialer Basisfunktionen-Netze oder Neuro-Fuzzy-Netze effizienter. Insbesondere die erweiterten Ansätze basierend auf lokal linearen Modellen scheinen sehr vielversprechend, da hierfür sehr leistungsfähige Trainingsverfahren existieren.

## Literatur

1. R. E. Bellman. *Adaptive Control Processes*. Princeton University Press, New Jersey, 1961.
2. S. Chen, C. F. N. Cowan und P. M. Grant. Orthogonal least-squares learning algorithm for radial basis function networks. *IEEE Transactions on Neural Networks*, 2(2), 1991.
3. J. Moody und C. J. Darken. Fast learning in networks of locally-tuned processing units. *Neural Computation*, 1(2):281–294, 1989.
4. O. Nelles. *Nonlinear System Identification*. Springer, Berlin, 2001.
5. O. Nelles. Axes-oblique partitioning strategies for local model networks. In *IEEE International Symposium on Intelligent Control*, Munich, 2006.
6. D. E. Rumelhart, G. E. Hinton und R. J. Williams. Learning internal representations by error propagation. In: *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, volume 1, D. E. Rumelhart und J. L. McClelland (Hrsg.). MIT Press, Cambridge, 1986.
7. R. Shorten und R. Murray-Smith. Side-effects of normalising basis functions in local model networks. In: *Multiple Model Approaches to Modelling and Control*,

- R. Murray-Smith und T.A. Johansen (Hrsg.), S. 211–229. Taylor & Francis, London, 1997.
8. J. Sjöberg, Q. Zhang, L. Ljung, A. Benveniste, B. Delyon, P.-Y. Glorennec, H. Hjalmarsson und A. Juditsky. Nonlinear black-box modeling in system identification: A unified overview. *Automatica*, 31(12):1691–1724, 1995.
  9. T. Takagi und M. Sugeno. Fuzzy identification of systems and its application to modeling and control. *IEEE Transactions on Systems, Man, and Cybernetics*, 15(1):116–132, 1985.
  10. L. A. Zadeh. Fuzzy sets. *Information and Control*, 8:338–353, 1965.

# Informationsfusion in Neuro-Fuzzy-Systemen

Frank Rügheimer<sup>1</sup>, Detlef Nauck<sup>2</sup> und Rudolf Kruse<sup>1</sup>

<sup>1</sup> Otto-von-Guericke-Universität Magdeburg

<sup>2</sup> BT, Research & Venturing, Intelligent Systems Research Centre, Ipswich, UK

**Zusammenfassung.** In diesem Beitrag diskutieren wir Informationsfusion bei Neuro-Fuzzy-Systemen im Rahmen Intelligenter Datenanalyse. Als Datenquellen fungieren dabei einerseits menschliche Experten, die ihr Wissen in Form von Wenn-dann-Regeln formulieren, andererseits Datenbanken mit Beispielen. Wir behandeln die Zusammenführung dieser unterschiedlichen Formulierungen von Wissen unter Verwendung von Neuro-Fuzzy-Methoden und erläutern diese anhand von Beispielen. Dabei zeigen wir, wie Regelmengen aus Daten gewonnen und bestehende Regelbasen zusammengeführt oder anhand von Trainingsdaten revidiert werden können.

## 1 Einleitung

Anwendungen der Intelligenzen Datenanalyse bedienen sich der Konstruktion von Modellen, um Vorhersagen zu ermöglichen oder in den Daten versteckte Zusammenhänge aufzudecken. Im Gegensatz zu Data-Mining [1] erfordert Intelligente Datenanalyse explizit die Nutzung von Vorwissen über die Daten und die Einbeziehung bekannter Restriktionen im Hinblick auf potentielle Lösungen [2]. Für den Einsatz vorhandenes Vorwissens in Analyseprozessen bedarf es jedoch zunächst geeigneter Verfahren zur Kombination unterschiedlicher Informationsquellen, sowohl miteinander, als auch mit aus Daten gewonnenem Wissen. Dieser Prozess ist gemeinhin als Informationsfusion bekannt.

Der Begriff *Informationsfusion* bezeichnet die Erfassung, Verarbeitung und Zusammenführung von aus unterschiedlichen Quellen stammenden Informationen mit dem Ziel, tiefere Einsichten in und ein Verständnis für betrachtete Phänomene zu erlangen. Hierbei bieten sich mehrere Ansatzpunkte. Informationsfusion kann auf der Ebene, der Datenerfassung, -vorverarbeitung, Daten- und Wissensrepräsentation, oder auch auf der Modellierung- bzw. Entscheidungsfindungsebene stattfinden. Auf den unteren Ebenen, also dort, wo Rohdaten bearbeitet werden, wird der Begriff (*Sensor-*)*Datenfusion* bevorzugt. Einige Aspekte der Informationsfusion lassen sich mit Hilfe von Neuro-Fuzzy-Ansätzen zum Erlernen von Fuzzy-Klassifikatoren aus Daten realisieren. Von Experten formulierte unscharfe Regeln lassen sich mit solchen, die aus Lernprozessen gewonnen wurden verschmelzen. Für eine konzeptbezogene und vergleichende Untersuchung von Kombinationsstrategien in verschiedenen Unsicherheitskalkülen sei an dieser Stelle auf [3] verwiesen.

Im vorliegenden Beitrag erläutern wir, auf welche Weise Fuzzy-Systeme im Rahmen Intelligenter Datenanalyse zur Informationsfusion beitragen können. Fuzzy-Systeme werden heute häufig für die Bearbeitung von Problemen aus den Bereichen der Datenanalyse, Klassifikation, Funktionsapproximation oder Zeitreihenvorhersage eingesetzt, denn sie liefern einfache, gut interpretierbare und effizient nutzbare Ergebnisse. Der Hauptvorteil der Fuzzy-Systeme besteht dabei darin, dass diese intuitive Modelle für Interpretationen und Vorhersagen zu liefern vermögen. Vorwissen kann dabei leicht in Form von Fuzzy-Regeln eingearbeitet werden. Für die Verwendung von Fuzzy-Methoden zur Analyse präziser Daten ist die Bezeichnung Fuzzy-Datenanalyse geläufig.

Voraussetzung für den Einsatz von Fuzzy-Systemen in der Datenanalyse ist die Möglichkeit aus Beispielen zu Lernen. In Fuzzy-Systemen erfolgt Lernen sehr häufig anhand von Algorithmen, die sich von Trainingsalgorithmen Neuronaler Netze ableiten. Der Begriff Neuro-Fuzzy-Systeme (sowie Neuro-Fuzzy-Methoden und -Modelle) bezieht sich auf die Kombinationen von Neuronalen Netzen mit Fuzzy-Systemen, wobei hierunter jedoch üblicherweise nicht zu verstehen, dass ein Neuronales Netz und ein Fuzzy-System in irgend einer Weise zusammen genutzt werden. Stattdessen handelt es sich vielmehr um Fuzzy-Systeme, die sich zur Parameteroptimierung eines den Neuronalen Netzen entlehnten heuristischen Trainingsverfahrens bedienen.

Für das Lernen von Fuzzy-Systemen ist einerseits das Strukturlernen, d. h. die Erzeugung einer Regelbasis, andererseits das Parameterlernen, also die Optimierung der verwendeten Fuzzy-Mengen, zu betrachten. Parameterlernen ist häufig mithilfe durch Neuronale Netze inspirierter Algorithmen realisiert. Dies gilt jedoch nicht für das Strukturlernen, denn gewöhnlich ist die Struktur eines neuronalen Netzes bekannt und lediglich dessen Parameter (die Verbindungsgewichte) werden durch Training angepasst. Der Begriff Neuro-Fuzzy wird jedoch inzwischen auf nahezu alle Ansätze für Lernen in Fuzzy-Systemen verwendet, so dass diese Bezeichnung inzwischen auch das Lernen von Fuzzy-Regeln [4, 5] einschließt.

Unterscheidungen werden nur dann getroffen, wenn Fuzzy-Regeln mit anderen Verfahren, etwa über die Induktion von Fuzzy-Entscheidungsbäumen [6] oder mittels genetischer Algorithmen [7, 8] erzeugt werden. Für niedrigdimensionale Probleme existieren zudem Ansätze, die Kombinationen von Variablen explorieren [9]. In diesem Paper beschreiben wir einen Neuro-Fuzzy-Ansatz für Intelligente Datenanalyse. Für die Erzeugung eines Fuzzy-Modells in einem derartigen Szenario ist die Verfügbarkeit eines Algorithmus zur Unterstützung des explorativen Charakters der Datenanalyse bedeutsam. Dabei ist jedoch zu beachten, dass die Hauptvorteile der Fuzzy-Systeme — ihre Einfachheit und ihre gute Interpretierbarkeit — nicht verloren gehen.

Da Intelligente Datenanalyse die Einbeziehung von Vorwissen erfordert, können wir uns nicht allein mit der Erzeugung von Fuzzy-Systemen durch Lernen aus Daten befassen. Zusätzlich sollte das vorhandene Expertenwissen in Form von Wenn-dann-Regeln berücksichtigt werden.

In den nachfolgenden zwei Abschnitten werden wir erst unsere Interpretation von Intelligenter Datenanalyse und Informationsfusion vorstellen. Danach folgen zwei Abschnitte, die sich mit dem NEFCLASS benannten Neuro-Fuzzy Ansatz und den dazugehörigen Lernalgorithmen befassen. Zwei weitere Abschnitte diskutieren die Informationsfusion mit NEFCLASS, ergänzt durch ein auf realen Daten basierendes Beispiel.

## 2 Intelligente Datenanalyse

Datenanalyse lässt sich als die Berechnung von Zusammenfassungen und abgeleiteten Beschreibungen aus Daten oder genereller – als der Prozess der Konvertierung von Daten in Wissen beschreiben. Unter Daten verstehen wir dabei eine Sammlung von aufgezeichneten Werten, numerisch oder auch nicht, die untersuchte Objekte beschreiben. Die Begriffe Wissen bzw. aus den Daten gewonnene Information werden dabei in einer sehr allgemeinen Bedeutung verwendet. Dabei kann es sich beispielsweise um einen erlernten Satz von Schlußregeln, eine linguistische Beschreibung zur Vereinfachung oder Charakterisierung der Natur eines Datenbestands, oder ein mehr oder weniger komplexes Modell zur akuraten Beschreibung eines den beobachteten Daten zugrunde liegenden Prozesses handeln. Wissen ist die notwendige Voraussetzung für das Entscheidungsprozesse. Wir gehen davon aus, dass Daten auf einer deutlich niedrigeren Abstraktionsebene als das abgeleitete Wissen angesiedelt sind und daher keiner direkten Verwendung zugeführt werden können. Zum Beispiel können Datenbestände sehr umfangreich, hochdimensional, verrauscht, unvollständig, vage oder mit Unsicherheit behaftet sein. Daher sind Rohdaten selbst, sofern keine geeignete Verarbeitung und Analyse erfolgt, für Entscheidungsfindung nicht sonderlich hilfreich.

In diesem Paper diskutieren wir die Eignung von Neuro-Fuzzy-Systemen für die Wissensentdeckung im Rahmen der Intelligenten Datenanalyse (IDA). Berthold und Hand [2] beschreiben Intelligente Datenanalyse als einen Prozess kritischer Beurteilung, Exploration und Auswertung. Sie erfordert die Anwendung von Wissen und Expertise über die Daten und ist grundsätzlich interdisziplinär.

Wir betrachten Neuro-Fuzzy-Systeme als wertvolle Werkzeuge der IDA, da sie sich als besonders nützlich erweisen, wenn einfache, interpretierbare Modelle gefragt sind. [10] und [5] beschreiben Algorithmen, mit denen zügig Modelle erstellt und somit der explorative Charakter der IDA gestützt werden können. Neuro-Fuzzy-Ansätze können als Verfahren zur Erzeugung von Modellen, die einen Übergang zwischen der erklärenden und prognostizierenden Funktion realisieren, angesehen werden. Neuro-Fuzzy-Methoden erzeugen also Modelle aus Daten, die einerseits Vorhersagen ermöglichen, andererseits aber auf intuitive linguistische Weise interpretiert werden können und somit die zugrunde liegenden Daten beschreiben.

Allerdings geht die Rolle der Neuro-Fuzzy-Systeme über das reine Erzeugen von Modellen, einem Begriff der in der Datenanalyse häufig, jedoch nicht immer mit einheitlicher Bedeutung verwendet wird [2] hinaus. Beispielsweise kann zwischen empirischen und mechanischen oder auch zwischen Modellen, die der

Prognose, und solchen, die dem Verständnis dienen, unterschieden werden. Weiterhin ist zwischen Modellen und ggf. in den Daten zu entdeckenden Mustern (hier im Sinne lokaler Struktur zu verstehen) zu unterscheiden. Data-Mining beschäftigt sich häufig mit dem Auffinden derartiger Muster in Daten. Ein Modell dagegen beschreibt die globale Struktur und fasst Einzelfälle zusammen. Der Schwerpunkt der Datenanalyse liegt jedoch nicht beim Modellieren, sondern vielmehr bei der Beantwortung von Fragen. Bezogen auf Neuro-Fuzzy-Systeme in der Datenanalyse zieht dies die Forderung einer hohen Verständlichkeit der resultierenden Fuzzy-Regeln nach sich.

Bei der Wissensentdeckung in Datenbanken (KDD) besteht das Ziel darin, korrekte, nützliche, sinnvolle, zuvor unbekannte und unerwartete Beziehungen in großen Datenbeständen aufzudecken [1]. Diese Definition der KDD zeigt deutlich auf, dass es sich um einen explorativen Prozess handelt, bei dem das Ziel der Suche zunächst nicht notwendigerweise festgelegt sein muss. Es werden demnach Verfahren zur Erkennung von Mustern, also lokalen Strukturen, Anomalien oder Abhängigkeiten benötigt. Wie IDA liegt auch für KDD der Schwerpunkt auf der Beantwortung von Fragestellungen, jedoch geht diese gewissermaßen einen Schritt weiter, da auch zunächst noch nicht explizit formulierte Fragestellungen einbezogen werden. Im Kontext von KDD läßt sich Data-Mining also durchaus mit Intelligenter Datenanalyse vergleichen. Die zu beantwortenden Fragen stellen sich dabei erst im Verlaufe des Data-Mining-Prozesses selbst. Explorationsstrategien, wie graphische Visualisierung werden im Data Mining somit zu wichtigen Werkzeugen, die Einblicke in die Daten ermöglichen und die weitere Analyse leiten. Da häufig die Resultate einer Untersuchung die Formulierung weiterer Fragestellungen nach sich ziehen, betrachten wir Data-Mining als einen sich wiederholenden Prozeß Intelligenter Datenanalyse.

Die in diesem Paper behandelten Neuro-Fuzzy-Methoden können im Data Mining hauptsächlich zur Klassifikation und Vorhersage eingesetzt werden. Für hinreichend einfache Zusammenhänge liefern Neuro-Fuzzy-Methoden auch gute Beschreibungen und in einigen Fällen lassen sich einfache Abhängigkeitsanalysen durchführen. Allerdings müssen in den beiden letztgenannten Fällen gewöhnlich komplexere Abhängigkeiten beschrieben werden und Graphische Modelle [12], z. B. Bayessche Netze [13] oder Markow-Netze [14], erweisen sich hier als nützlicher.

### 3 Informationsfusion

Die Idee der Informationsfusion ist es, Intelligen Systemen den Zugriff auf mehrere Datenquellen zu ermöglichen. In diesem Paper betrachten wir zwei mögliche Quellen: Regelmengen und Beispiele. Wir verwenden folgende Symbole und Operatoren:



- R: von Experten spezifizierte Regelmenge
- D: Trainingsdatenbestand
- $\text{fuse}(R_1, R_2)$ : Zusammenführung zweier Regelmengen
- $\text{revise}(R, D)$ : Modifikation einer Regelmenge durch Lernen aus Daten
- $\text{induce}(D)$ : Ableiten einer Regelmenge aus Trainingsdaten

Mithilfe dieser Festlegungen können wir nun unterschiedliche Strategien beschreiben:

- $\text{fuse}(\text{fuse}(R_1, \dots, R_n), \text{induce}D)$  : Nach Verschmelzen aller von Experten gelieferten Regelmenge, wird aus den Daten eine neue Regelmenge generiert. Diese wird anschließend mit den kombinierten Expertenregeln verschmolzen.
- $\text{revise}(\text{fuse}(\text{fuse}(R_1, \dots, R_n), \text{induce}D), D)$  : Alle Expertenregeln verschmelzen, dann aus den Daten generiertes Regelsystem einarbeiten und schließlich Verträglichkeit mit den beobachteten Daten sicherstellen.
- $\text{revise}(\text{fuse}(R_1, \dots, R_n), D)$  : Zerschmelzen der Expertenregelmengen, dann Revision anhand der Trainingsdaten.
- $\text{fuse}(\text{revise}(R_1, D), \dots, \text{revise}(R_n, D))$  : Revidieren sämtlicher durch Experten vorgegebener Regelmengen, dann Fusion zu einer Gesamtlösung.

Die Auswahl der Strategie ist hier von mehreren Faktoren, wie der Wichtigkeit, die wir Daten und einzelnen Regelmengen zubilligen, und der Verfügbarkeit geeigneter Lern- und Revisionsoperatoren, abhängig. Falls alle Regelmengen als gleichwertig betrachtet werden, sollte man sich für eine der zwei erstgenannten Strategien entscheiden, je nach Verfügbarkeit eines geeigneten Revisionsoperators. Wenn dagegen den Expertenregeln gegenüber den Daten Vorrang eingeräumt werden soll, ist eine der beiden letzten Strategien vorzuziehen. Bei vorheriger Fusion der Regelmengen vereinfacht sich der Revisionsprozess, während die Revision aller Regelmengen noch vor der Zusammenführung den Einfluß einer einzelnen Regelmenge im Fusionsprozess erhöhen kann, sofern diese Regelmenge dadurch deutlich verbessert wird. Die eigentliche Implementierung der Operatoren  $\text{fuse}()$ ,  $\text{induce}()$  und  $\text{revise}()$  hängt dabei vom zur Wissensrepräsentation und zum Lernen gewählten Modell ab. In Neuro-Fuzzy-Systemen bedeutet Induktion, Regel- oder Strukturlernen. Unter Revision versteht man das Lernen von Fuzzy-Mengen bzw. die Optimierung von Parametern, während Fusion die Auflösung von Widersprüchen und Inkonsistenzen sowie die Auswahl der endgültigen Regelbasis aus einem Vorrat von Regeln umfasst.

Der im nächsten Abschnitt vorgestellte NEFCLASS-Ansatz stellt Methoden zum Strukturlernen, Parameterlernen, und Stützen bereit. NEFCLASS führt keine Wichtung von Informationsquellen ein und vermeidet folglich auch Regelgewichtungen, die in Fuzzy-Systemen zu semantischen Schwierigkeiten führen können (siehe [11]). Stattdessen betrachtet NEFCLASS Expertenregeln als Vorwissen. Ihnen wird kein Vorrang gegenüber dem aus Daten gewonnenen Informationen eingeräumt. Von den vier oben aufgeführten Strategien kann die zweite mit NEFCLASS realisiert werden.

## 4 Das Neuro-Fuzzy-Modell NEFCLASS

Bei NEFCLASS handelt es sich um einen Neuro-Fuzzy-Ansatz zum Lernen von Klassifikatoren aus Daten. Verwendet werden Regeln der Form

$$R_r : \text{Wenn } x_1 \mu_R^{(1)} \text{ ist und } \dots x_n \mu_r^{(n)} \text{ ist Dann ist Klasse } c_r - \text{ bzw. kurz}$$

$$R_r : (\mu_R^{(1)}, \dots, \mu_r^{(n)}) \rightarrow c_r,$$

wobei  $\mu_r^{(i)} : X_i \rightarrow [0, 1]$  eine Fuzzy-Menge ist, die einen linguistischen Wert der Eigenschaft  $x_i \in X_i$  beschreibt. Wir gehen davon aus, dass ein Muster  $\mathbf{p} = (p_1 \dots p_n)$  zu genau einer Klasse  $c_j$ ,  $c \in (1, \dots, m)$  gehört, es jedoch eventuell nicht möglich ist, diese exakt festzustellen.

NEFCLASS kann aus Trainingsdaten  $\tilde{\mathcal{L}}$  mit Paaren  $(\mathbf{p}, \mathbf{t})$  Klassifikatoren erzeugen, wobei  $p \in X_1 \times \dots \times X_n$  Eingabemuster und die  $\mathbf{t} \in [0, 1]^m$  Zielmuster, die eine (Fuzzy-)Klassifikation darstellen, sind. Falls  $c_j$  als exakte Klassifikation zu  $\mathbf{p}$  bekannt ist, gilt dabei  $t_j = 1$  und  $t_k = 0$  für alle  $k \neq j$ .


Der in NEFCLASS verwendete Lernalgorithmus läuft dabei in drei Phasen ab: Strukturlernen, Parameterlernen und Pruning. Für das Regellernen (Strukturlernen) wird dabei eine Variante des Wang-Mendel-Ansatzes [15] genutzt. Für jedes Eingabemerkmale wird eine gegebene Anzahl von Fuzzy-Mengen festgelegt. Somit wird der Eingaberaum in Bereiche aufgeteilt, und die Bedingungsregeln für mögliche Regeln lassen sich einfach durch Ermitteln derjenigen dieser Regionen, die Daten enthalten, gewinnen. Dies kann in einem einzigen Durchlauf durch die Daten erfolgen. Eine Evaluierungsprozedur erzeugt dann die Regeln, durch Zuweisung geeigneter Klassenlabel, und wählt daraus eine Anzahl von Regeln mit guter Performanz aus [16].

Beim Parameterlernen werden die Fuzzy-Mengen durch eine backpropagationartige Methode justiert. Der verwendete Algorithmus nutzt nicht das Gradientenabstiegsverfahren, da der Erfüllungsgrad einer Fuzzy-Regel über das Minimum berechnet wird und nichtstetige Zugehörigkeitsfunktionen zugelassen werden. Stattdessen wird eine Heuristik zur Verschiebung der Fuzzy-Mengen und zur Vergrößerung oder Verkleinerung ihrer Basen eingesetzt.

Die in der Implementierung NEFCLASS-J verwendete Pruning-Strategie basiert auf einem gierigen Algorithmus, für den die Berechnung eines Testwertes entfällt. Die grundlegende Idee besteht dabei in der Erzeugung lesbarer Klassifikatoren, indem durch Einführung von Restriktionen sichergestellt wird, dass Fuzzy-Mengen während des Lernens nicht beliebig modifiziert werden können, und diese auch nach dem Training noch ihren linguistischen Labels entsprechen. Zusätzlich werden Pruningstrategien angewendet, um die Zahl der Regeln und Variablen zu reduzieren [17].

## 5 Lernen in NEFCLASS

In diesem Abschnitt diskutieren wir einige Eigenschaften des in NEFCLASS verwendeten Lernalgorithmus. Dieser erstellt eine Fuzzy-Regelbasis aus einem




**Abb. 1.** Lernen von Fuzzy-Regeln durch Auswahl von Hyperboxen.

Datenbestand, der numerische und symbolische Attribute enthält, wobei einzelne Werte fehlen können. Eine vollständige Wiedergabe dieses Algorithmus ist an dieser Stelle leider nicht möglich, findet sich aber u. a. in [10].

Das Regellernen beginnt mit der Erzeugung initialer Bedingungs Mengen, die lediglich metrische Attribute berücksichtigen und mittels des Wang-Mendel-Algorithmus [15] bestimmt werden. Dies entspricht einer Auswahl von Hyperboxen im strukturierten Datenraum (vgl. Abbildung 1). Im Falle fehlender Werte könnte jede der Fuzzy-Mengen für die entsprechende Variable in die Bedingungs Menge aufgenommen werden. Daher werden alle Kombinationen von Fuzzy-Mengen, die mit dem betrachteten Trainingsmuster vereinbar sind erzeugt.

Im Falle eines nicht angegebenen Wertes soll keine Annahme über den tatsächlichen Wert eingeführt, sondern vielmehr sämtliche möglichen Werte berücksichtigt werden. Dadurch wird die Anwendbarkeit von Fuzzy Regeln auf Trainingsmuster mit fehlenden Werten nicht eingeschränkt. Fehlende Werte sollen also keinesfalls einen Einfluß auf den Erfüllungsgrad der in einer Fuzzy-Regel verwendeten Bedingungs Menge haben. Dies läßt sich erreichen, indem bei fehlenden Attributen jeder Fuzzy-Menge ein Zugehörigkeitsgrad von 1.0 zugewiesen wird, ein fehlender Wert also als jeder Fuzzy-Menge vollständig zugehörig gewertet wird. Ein Muster in dem jeder Wert als fehlend vermerkt ist, würde somit jede in der Regelbasis enthaltenen Fuzzy-Regel mit dem Grad 1.0 erfüllen, womit ein derartiges Muster jeder auftretenden Klasse zugeordnet werden könnte.

Wir gehen im Weiteren von  $k$  möglichen Bedingungs teilen aus. Falls zusätzlich symbolische Attribute vorhanden sind, erzeugen wir für jedes Antezedens  $m$  Regeln — eine für jedes Klassenlabel — und vervollständigen den Bedingungs teil durch Fuzzy-Mengen für die symbolischen Attribute. Hierzu werden die relativen Häufigkeiten der Attributwerte bestimmt [18]. Daraus ergibt sich eine initiale Regelbasis der Mächtigkeit  $m \cdot k$ , die jedoch gewöhnlich noch kon-



**Abb. 2.** Anpassung der Zugehörigkeitsfunktionen.

kurrierende Regeln enthält. Nach Beseitigung dieser Inkonsistenz durch Auswahl der jeweils performatesten Regel unter denen mit identischem Bedingungsteil, kann die endgültige Regelbasis erstellt werden.

Sollten dagegen keine symbolischen Attribute vorhanden sein, wählen wir für jedes Antezedens, dasjenige Konsequenz, das zu einem minimalen Fehler führt, wobei folgendes Maß genutzt wird:

$$P_R = \frac{1}{s} \sum_{(\mathbf{p}, \mathbf{t}) \in \tilde{\mathcal{L}}} (-1)^c R(\mathbf{p}), \text{ wobei } c = \begin{cases} 0, & \text{falls } \text{class}(\mathbf{p}) = \text{con}(R) \\ 1 & \text{sonst.} \end{cases}$$

Dabei bezeichnet  $\text{con}(R)$  das im Regelkonsequenz verwendete Klassenlabel, und  $\text{class}(\mathbf{p})$ , die Klasse, zu der  $p$  gehört.  $R(\mathbf{p})$  ist der Erfüllungsgrad der Regel  $R$ . Das resultierende Maß  $P \in [0, 1]$  beschreibt die Eindeutigkeit einer Regel, und nimmt den Wert  $P = 1$  für allgemeingültige Regeln, während  $P = -1$  auf eine Regel, die jedes Beispiel falsch klassifiziert hinweist. Bei  $P = 0$  halten sich entweder korrekte und falsche Zuordnungen die Waage, oder es wird kein Muster abgedeckt, lediglich Regeln mit  $P > 0$  können also als geeignet betrachtet werden. Die Größe der Regelmenge kann abschließend mittels integrierter Regelevaluierungsverfahren reduziert werden [19], wobei entweder eine feste Größe vom Nutzer vorgegeben wird, oder aber solange Regeln ergänzt werden, bis sämtliche Trainingsmuster abgedeckt wurden.

Nach der Regelerstellung erfolgt zur Verbesserung der Klassifikationsleistung das Training der Fuzzy-Mengen [5, 10, 18]. Die Algorithmen beruhen auf der Idee von Backpropagation. Für die lokale Anpassung der Fuzzy-Mengen zur Änderung der Zugehörigkeitsgrade (Verschieben, Verbreitern/Verkleinern der Basis) in Abhängigkeit vom momentanen Ausgabefehler werden einfache Heuristiken genutzt (siehe Abb. 2).

Für das Stutzen der Regelbasis werden im Anschluß die folgenden Heuristiken gewählt:

- Nach Korrelation: Löschen der Variablen mit dem geringsten Einfluss auf das Klassifizierungsergebnis. Diese kann anhand statistischer (Korrelation,

$\chi^2$ -Test) oder informationstheoretischer Maße (z. B. Informationsgewinn) bestimmt werden.

- Nach Klassifikationshäufigkeit: Regel, die jeweils in der geringsten Zahl von Fällen die dominierende Ausgabe liefert wird entfernt.
- Nach Redundanz: Entfernen jeweils desjenigen linguistischen Terms, der für die Regelaktivierung am seltensten beschränkend wirkt.
- Nach Präzision: Identifizieren der Fuzzy-Menge mit der größten Basis und Entfernung des zugehörigen Terms aus dem Bedingungsteil aller Regeln.

Nach jedem Stutzen werden die Fuzzy-Mengen erneut durch Training modifiziert. Jede dieser Strategien wird angewendet, bis einer der Schritte versagt<sup>3</sup>, woraufhin zur nächsten Strategie übergegangen wird. Sollten durch das Stutzen Inkonsistenzen eingeführt werden (möglich in den Schritten 1, 3 und 4), werden diese durch Löschen mit anderen Regeln widersprechender oder diese spezialisierender/verallgemeinernder Regeln automatisch beseitigt, wobei nach die Auswahl der zu löschenden Regeln anhand ihrer Performanzbewertung erfolgt.

## 6 Informationsfusion in NEFCLASS

Zur Erzeugung eines Fuzzy-Klassifikators für ein überwachtes Lernproblem, wird üblicherweise ein Datenbestand bereitgestellt, in dem jedem Muster nur ein Label zugeordnet ist — idealerweise das der korrekten Klasse. Mitunter ist eine exakte Einschätzung aber gar nicht möglich; man könnte dann statt eines einzelnen Labels einen Vektor mit Zugehörigkeitsgraden verwenden. Dies erfordert jedoch eine vage Klassifikation der Trainingsdaten, z.B. anhand einander teilweise widersprechender Expertenaussagen. Betrachten wir eine Gruppe von  $n$  Experten, die (einander möglicherweise widersprechende) Zuordnungen der Trainingsmuster vornehmen, so können wir deren Aussagen in einer Fuzzy-Klassifikation zusammenfassen. Im Sinne des Kontext-Modells, können wir mit jedem Experten einen eigenen Beobachtungskontext assoziieren [20].

Wenn den Experten eine Verlässlichkeit zugeordnet werden kann, oder Präferenzen ausgedrückt werden sollen, können den Experten Gewichte  $p_k$ ,  $\sum_{k=1,n} p_k = 1$  zugeordnet werden, anderenfalls kann  $p_k = \frac{1}{n}$  gewählt werden. Für jedes Muster wird dann der Vektor  $\mathbf{t}$  mit  $t_j = \sum_{k=1}^n c_j^{(k)} p_k$  bestimmt, wobei  $c_j^{(k)}$  der vom  $k$ -ten Experten angegebene Zugehörigkeitsgrad des Musters zur Klasse  $c_j^k$  ist. NEFCLASS unterstützt zwar nicht diesen speziellen Zusammenführungsprozess, kann aber derartige Trainingsmuster zur Erstellung von Klassifikatoren verarbeiten.

Wie bei jedem Fuzzy-Klassifikator ist die von NEFCLASS gelieferte Ausgabe ein Vektor von Zugehörigkeitsgraden — ganz wie die Zielvektoren der Trainingsbeispiele. Eine derartige Ausgabe bietet mehr Informationen, als eine harte

<sup>3</sup> Das Stutzen entfernt dabei niemals die letzte Regel für eine Klasse, es versagt, wenn nach dem Trainieren der Zugehörigkeitsfunktionen der Fehler zugenommen hat, oder die Regelbasis nicht mehr in einen konsistenten Zustand überführt werden kann. In diesem Fall wird der vorherige Zustand wiederhergestellt.

Klassifikation und wird daher direkt an den Nutzer weitergegeben. Eine niedrige Zugehörigkeit zu jeglicher Klasse oder hohe Zugehörigkeitsgrade für mehrere Klassen, können einen Nutzer zum Beispiel veranlassen, eine Klassifikation abzulehnen und die durch das entsprechende Eingabemuster beschriebenen Fälle mit anderen Methoden eingehender zu untersuchen. Sollte eine präzise Entscheidung gefordert sein, wird die Klasse mit dem höchsten Zugehörigkeitsgrad ausgewählt.

Ein von NEFCLASS direkt unterstützter Aspekt der Informationsfusion besteht in der Vereinigung von Expertenwissen in Form von Fuzzy-Regeln und Beobachtungsdaten, im Trainings- und Stutzungsprozess aus Abschnitt 5. Diese können vor dem Lernprozess der Regelbasis hinzugefügt werden. Bei der Konfliktbehandlung kann anschließend den Expertenregeln oder auch den gelernten Regeln Priorität eingeräumt werden. Üblicherweise jedoch würde hier anhand der Performanz entschieden werden.

Da NEFCLASS über Konfliktauflösungsmechanismen verfügt, können Modelle unterschiedlicher Experten auch auf Regelebene zusammengeführt werden. Werden von unterschiedlichen Experten stammende Regelbasen als Vorwissen zugeführt, löst NEFCLASS evt. vorhanden Konflikte auf, wobei wiederum die Regelperformanz als Kriterium eingesetzt wird um die jeweils schlechtere zweier unverträglicher Regeln zu entfernen. Wenn eine Beschränkung für die Mächtigkeit der Regelmenge gewünscht wird, muss bei der Festlegung der auszugebenden Regeln eine Entscheidung getroffen werden, ob die von Experten gelieferten Regeln in jedem Fall bewahrt oder eine rein performanzbasierte Auswahl von Regeln zurückgeliefert werden soll. Diese Entscheidung hängt gewöhnlich vom Vertrauen in die Expertenmeinung bzw. die Daten ab, gemischte Lösungen, bei denen etwa die besten Expertenregeln übernommen und die dann mit erlernten Regeln aufgefüllt wird, sind aber ebenfalls möglich. Ähnliche Entscheidungen sind bezüglich des Regelstutzens zu treffen.

## 7 Fusion von Expertenregeln und Informationen aus Daten

Zur Erläuterung der im vorherigen Kapitel beschriebenen Betrachtungen, nutzen wir die „Wisconsin Breast Cancer“ Daten [21]. Der Datenbestand weist 9 Attribute  $x_1 \dots x_9$  mit  $x_i \in 1, \dots, 10$  auf. Insgesamt sind 699 Fälle beschrieben, 16 davon unvollständig. Jeder Fall ist entweder als *benign* ( $b$ ) (456 Fälle) oder *malign* ( $m$ ) (241 Fälle) klassifiziert. Der Daten wurde von uns nach dem Zufallsprinzip in einen Trainings- und einen Testdatenbestand gleicher Größe aufgeteilt. Zur Partitionierung der Domäne jeder Variable wählten wir jeweils Fuzzy-Mengen *small* und *large*, die über halbtapezoiden Zugehörigkeitsfunktionen mit den Parametern  $a, b, c \in \mathbb{R}$ :

$$\mu_{\text{small}}(x) = \begin{cases} 1 & \text{falls } a \leq x \leq b \\ \frac{x-b}{c-b} & \text{falls } b \leq x \leq c \\ 0 & \text{sonst,} \end{cases} \quad \mu_{\text{large}}(x) = \begin{cases} \frac{b-x}{b-a} & \text{falls } a \leq x \leq b \\ 1 & \text{falls } b \leq x \leq c \\ 0 & \text{sonst,} \end{cases}$$

beschreibbar sind..

Zur Initialisierung wählten wir  $a = 1$ ,  $b = 5$ ,  $c = 7$  für *small* ( $s$ ) und  $a = 4$ ,  $b = 7$  und  $c = 10$  für *large* ( $l$ ). Zur Demonstration der Fusion-Komponente führten wir die Regel

$$R_0 : (s, s, s, s, s, s, s, s, s, s) \rightarrow b \quad (1)$$

ein. Diese Regel klassifiziert bereits einen Großteil der gutartigen Tumore korrekt und erreicht einen Performanzwert von 0,55. Um eine Fusion mit der in den Trainingsdaten enthaltenen Information zu erreichen, ließen wir NEFCLASS-J Regeln lernen, bis jedes Trainingsmuster abgedeckt wurde – insgesamt 56. Aufgrund der hohen Performanz verblieb  $R_0$  (1) in dieser Regelbasis. Alle weiteren Regeln wiesen einen Performanzwert um 0.01 auf. Anschließend starteten wir die Optimierung der Fuzzy-Mengen und den automatischen Pruningprozess. Die resultierende Regelmenge enthält lediglich 5 Elemente, erfasst alle 699 Fälle und liefert insgesamt 31 Fehlklassifikationen ( , ‘zeigt an, dass die entsprechende Variable nicht betrachtet wird):

$$\begin{aligned} R_0 : (\cdot, \cdot, s, s, \cdot, \cdot, s, s, \cdot, \cdot) &\rightarrow b \quad (0,55) & R_3 : (\cdot, \cdot, l, l, \cdot, \cdot, l, l, \cdot, \cdot) &\rightarrow m \quad (0,20) \\ R_1 : (\cdot, \cdot, l, l, \cdot, \cdot, l, s, \cdot, \cdot) &\rightarrow b \quad (0,11) & R_4 : (\cdot, \cdot, s, s, \cdot, \cdot, l, l, \cdot, \cdot) &\rightarrow m \quad (0,06) \\ R_2 : (\cdot, \cdot, l, l, \cdot, \cdot, s, l, \cdot, \cdot) &\rightarrow b \quad (0,04) \end{aligned}$$

Für ein zweites Experiment beschränkten wir die Größe der Regelbasis auf 4, wobei wiederum  $R_0$  (1) vorgegeben, und die Trainingsdaten wie zuvor verarbeitet wurden. Nach dem Stutzen verblieben lediglich zwei Regeln:

$$R_0 : (\cdot, \cdot, s, \cdot, \cdot, \cdot, \cdot, s, \cdot, \cdot) \rightarrow b \quad (0,58) \quad R_1 : (\cdot, \cdot, \cdot, l, \cdot, \cdot, l, \cdot, \cdot, \cdot) \rightarrow m \quad (0,25)$$

Wiederum ist darunter eine aus  $R_0$  (1) hervorgegangene Regel. Die im Resultat enthaltenen Regeln liefern für 45 Fälle keine korrekte Zuordnung – worin 8 nicht von den Regeln abgedeckte Fälle eingeschlossen sind.

Schließlich wiederholten wir das zweite Experiment, verwendeten als Vorwissen jedoch diesmal die ungünstige Regel:

$$R'_0 : (s, s, s, s, s, s, s, s, s, s) \rightarrow m$$

Da diese Regel durch die Trainingsdaten nicht gestützt wird, ersetzt NEFCLASS-J sie während der Regelerzeugung durch  $R_1$  (1). im Folgenden ergibt sich dann das vom zweiten Experiment bekannte Ergebnis.

Diese Experimente demonstrieren die von NEFCLASS-J geleistete Zusammenführung von Expertenregeln und den aus Daten erzeugten Regeln. Falls die vorgegebenen Regeln durch die Daten gestützt werden verbleiben diese in der Regelbasis. Während des Trainings der Zugehörigkeitsfunktionen werden die Regeln revidiert, um eine Steigerung der Performanz zu erzielen. Auch dies kann als Informationsfusionsprozess der Daten mit den in den ursprünglichen Zugehörigkeitsfunktionen enthaltenen Informationen gesehen werden. Beim Stutzen optimiert NEFCLASS schließlich die Regeln durch Löschen von Variablen aus den Bedingungen einer Regel. Von den Daten nicht hinreichend gestützte Regeln, werden entweder aus der Regelbasis entfernt, oder abgeändert. Regeln,

welche die Trainingsdaten in nicht ausreichendem Maße abdecken werden beim Stutzen oder der Zusammenstellung der entgültigen Regelbasis entfernt, ungeeignete Klassenzuweisungen in gut abdeckenden Regeln werden gegebenenfalls durch geeignetere ersetzt.

## 8 Ausblick

In dieser Veröffentlichung wurde gezeigt, wie der NEFCLASS-Ansatz Aspekte der Informationsfusion umsetzt. Im Lernprozess verbindet das System Expertenregeln mit aus solchen, die aus Daten generiert wurden. Gegenwärtig erfolgt dies durch Löschen schlecht gestützter Regeln und ggf. Modifikation der verbleibenden durch Stutzen bzw. Training der Zugehörigkeitsfunktionen.

Weitere Verbesserungen erwarten wir uns durch das gleichzeitige Betrachten mehrerer Regelbasen und Kombination der Ergebnisse in Abhängigkeit von den Resultaten auf Trainingsdaten. Auf diese Art können die erzielten Ergebnisse zusammengeführt werden, ohne die Regelbasen selbst zu verschmelzen.

## Literatur

1. U. M. Fayyad, G. Piateski-Shapiro, P. Smyth und R. Uthurusamy (Hrsg.). *Advances in Knowledge Discovery and Data Mining*. MIT Press, Menlo Park, 1996.
2. M. Berthold und D. J. Hand (Hrsg.). *Intelligent Data Analysis: An Introduction*. Springer-Verlag, Berlin, 1999.
3. J. Gebhardt und R. Kruse. Parallel combination of information sources. In: *Belief Change, volume 3 of Handbook of Defeasible Reasoning and Uncertainty Management Systems*, D. Gabbay und P. Smets (Hrsg.), Kluwer, Dordrecht, 1998.
4. J.-S. Jang, C. Sun und E. Mizutani. *Neuro Fuzzy and Soft Computing*. Prentice Hall, Upper Saddle River, NJ, 1997.
5. D. Nauck, F. Klawonn und R. Kruse. *Foundations of Neuro-Fuzzy Systems*. Wiley, Chichester, 1997.
6. C. Z. Janikow. Fuzzy decision trees: Issues and method. *IEEE Trans. Systems, Man & Cybernetics, Part B: Cybernetics*, 28(1):1–14, 1988.
7. J. Hopf und F. Klawonn. Learning the rule base of a fuzzy controller by a genetic algorithm. In: *Fuzzy Systems in Computer Science*, R. Kruse, J. Gebhardt und R. Palm (Hrsg.), Vieweg, Braunschweig, 1994.
8. M. Lee und H. Takagi. Integrating design stages of fuzzy systems using genetic algorithms. In: *Proc. IEEE Int. Conf. on Fuzzy Systems*, S. 612–617, 1993.
9. A. Krone und H. Kiendl. Rule-based decision analysis with fuzzy-ROSA method. In: *Proc. First European Workshop on Fuzzy Decision Analysis and Neural Networks for Management, Planning, and Optimization (EFDAN)*, S. 109–114, 1996.
10. D. Nauck. Data Analysis with Neuro-Fuzzy Methods. Habilitation thesis, Otto-von-Guericke University of Magdeburg, <http://fuzzy.cs.uni-magdeburg.de/~nauck>, 2000.
11. D. Nauck. Adaptive rule weights in neuro-fuzzy systems. *Neural Computing & Applications* 9(1):60–70, 2000.
12. C. Borgelt und R. Kruse. *em Graphical Models—Methods for Data Analysis and Mining*. J. Wiley & Sons, Chichester, 2002.



13. J. Pearl. *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*. Morgan Kaufman, San Mateo, USA, 1988.
14. J. Gebhardt, A. Klose, H. Detmer, F. Rügheimer und R. Kruse. Graphical models for industrial planning on complex domains. In: *Decision Theory and Multi-Agent Planning*, G. Della Riccia, D. Dubois, R. Kruse und H.-J. Lenz (Hrsg.), Springer, 2006.
15. L.-X. Wang und J. M. Mendel. Generating fuzzy rules by learning from examples. *IEEE Trans. Syst., Man, Cybern.*, 22(6):1414–1427, 1992
16. D. Nauck, U. Nauck und R. Kruse. Generating classification rules with the neuro-fuzzy system NEFCLASS. In: *Proc. Biennial Conference of the North American Fuzzy Information Processing Society NAFIPS*, S. 466–470, 1996.
17. D. Nauck und R. Kruse. New Learning Strategies for NEFCLASS. In: *Proc. 7th. Int. Fuzzy Systems Association World Congress IFSA, vol. IV*, M. Mares, R. Mesiar, V. Novak, V. Ramik und A. Stupnanova (Hrsg.), S. 50–55, Academia, Prague, 1997.
18. D. Nauck. Using symbolic data in neuro-fuzzy classification. In: *Proc. 18th International Conf. of the North American Fuzzy Information Processing Society (NAFIPS)*, S. 472–476, IEEE, New York, 1999.
19. D. Nauck und R. Kruse. Neuro-fuzzy methods in fuzzy rule generation. In: *Fuzzy Sets in Approximate Reasoning and Information Systems, The Handbook of Fuzzy Sets*, J. C. Bezdek, D. Dubois und H. Prade (Hrsg.), Kluwer, Boston, 1999.
20. J. Gebhardt, R. Kruse und D. Nauck. Information compression in the context model. In: *Proc. Workshop of the North American Fuzzy Information Processing Society (NAFIPS)*, S. 296–303, 1992.
21. W. Wolberg und O. Mangasarian. Multisurface method of pattern separation for medical diagnosis applied to breast cytology. In: *Proc. National Academy of Sciences 87*, S. 9193–9196, 1990.



# Ermittlung der Oberflächengeometrie aus Messpunktewolken in der optischen 3D-Messtechnik

Rainer Tutsch und Marcus Petz

Technische Universität Braunschweig, Institut für Produktionsmesstechnik,  
Schleinitzstr. 20, D-38106 Braunschweig

**Zusammenfassung.** Die berührungslose optische 3D-Messtechnik zeichnet sich im Vergleich zu taktilen Verfahren durch eine sehr hohe Datenrate aus. Innerhalb weniger Sekunden können  $10^5$  bis  $10^6$  Messpunkte gewonnen werden. Den verschiedenen optischen Verfahren gemeinsam ist die Notwendigkeit, die Messung aus unterschiedlichen Richtungen zu wiederholen, um eine vollständige Oberflächentopographie zu erhalten. Beim Zusammenführen der Messpunkte der Einzelmessungen und bei der Ableitung von Geometrieelementen sind die Unsicherheiten der Koordinaten der Einzelpunkte zu berücksichtigen. Diese wiederum sind i. Allg. anisotrop und z. B. durch Unsicherheitsellipsoide beschreibbar.

## 1 Einleitung

Die optischen Verfahren der dreidimensionalen geometrischen Messtechnik haben sich neben der taktilen Messtechnik (klassische Koordinatenmesstechnik) einen festen Platz in der Fertigungsmesstechnik erobert [1, 2]. Sie zeichnen sich insbesondere durch

- eine hohe Messdatenrate,
- die berührungslose und rückwirkungsfreie Arbeitsweise und
- die Skalierbarkeit von Mikro- bis Makrogeometrien

aus. Gemeinsam ist diesen Verfahren, dass das Ergebnis einer Messung eine i. Allg. große Zahl (Größenordnung  $10^4$  bis  $>10^6$ ) von Messpunkten im Raum, eine sogenannte Messpunktewolke, ist. In diesem Beitrag soll die optische 3D-Messtechnik unter den folgenden beiden Aspekten diskutiert werden:

1. Die gesuchte Messgröße ist i. Allg. eine Regelgeometrie oder eine Freiformfläche, die jeweils durch einen Parametersatz beschrieben werden. Bei der Bestimmung dieser Geometrieparameter und ihrer Unsicherheit sind die Unsicherheiten der Messpunkte zu berücksichtigen.
2. Häufig ist eine Messpunktewolke alleine nicht ausreichend, um die interessierende Oberfläche des Messobjektes vollständig zu erfassen. Dann müssen mehrere Messungen aus unterschiedlichen Positionen durchgeführt und die Punktewolken zusammengefügt werden.

Beide angesprochenen Fälle sind formal als Fusion der in den Messdaten mehrerer Sensoren enthaltenen Information zu behandeln.

**Tabelle 1.** Klassifikation der bildgebenden optischen 3D-Messverfahren.

	Strahlenoptisches Wirkprinzip	Wellenoptisches Wirkprinzip
Diffus reflektierende Oberflächen	Aktive Triangulation (Strukturierte Beleuchtung) Passive Triangulation (Nahbereichsphotogrammetrie)	Weißlichtinterferometrie Digitale Holographie
Spiegelnd reflektierende Oberflächen	Rasterreflexions-Photogrammetrie Shack-Hartmann-Sensoren Moiré-Deflektometrie	Interferometrische Formprüfung


## 2 Unsicherheit der Einzelpunkte in einer Messpunktewolke

Aus der Fülle der optischen Messverfahren betrachten wir in diesem Beitrag die optischen 3D-Messverfahren unter Verwendung von flächigen Bildsensoren. Diese können nach verschiedenen Kriterien geordnet werden, z. B. nach der Anwendbarkeit auf spiegelnden bzw. diffus reflektierenden Oberflächen und nach dem physikalisch-optischen Wirkprinzip; siehe Tabelle 1.

Alle diese Verfahren liefern jeweils eine große Zahl von Messpunkten, d. h. Koordinatentripeln  $(x_i, y_i, z_i)$ , die in einem geeigneten Koordinatensystem Oberflächenpunkte des Messobjekts beschreiben. Der Messvorgang lässt sich als simultane Antastung der Oberfläche mit einer entsprechend großen Anzahl von Einzelsensoren modellieren, die jeweils einen einzelnen Messpunkt liefern. Ziel einer Oberflächenmessung ist in der Regel entweder der direkte (punktweise) Vergleich mit einer Sollgeometrie oder die Bestimmung einer Regelgeometrie oder einer Freiformfläche. I. Allg. liegt ein parametrisiertes mathematisches Modell zugrunde (bei Freiformflächen z. B. kubische Splines), dessen Parameter durch eine Ausgleichsrechnung zu ermitteln sind.

Bei dieser Fusion der Information der einzelnen Elemente der Messpunktewolke ist die Messunsicherheit des jeweiligen Koordinatentripels  $(x_i, y_i, z_i)$  zu beachten. Diese ist i. Allg. vom Ort auf der Oberfläche abhängig, was vor allem auf zwei Ursachen zurückzuführen ist:

1. Die von der Oberfläche zur Kamera gestreute Lichtintensität hängt lokal von verschiedenen Parametern ab: spektrale Eigenschaft des Materials (transparent, absorbierend, reflektierend), makroskopische Flächenneigung, Mikrostruktur der Oberfläche; siehe Bild 1. Inhomogene Werkstückoberflächen können stark unterschiedliche lokale Ausleuchtung des Kamerabildes zur Folge haben [3]. Da die Dynamik von Kamera und Signalverarbeitungskette (A/D-Umsetzer!) begrenzt ist, führt dies zu einem unterschiedlichen Signal/Rausch-Verhältnis, im Extremfall (Überbelichtung) auch zu Nichtlinearität und Übersprechen zwischen benachbarten Informationskanälen (Pixeln).
2. Unterschiedliche geometrische Bedingungen führen ebenfalls zu einer ortsabhängigen Unsicherheit. Für die Triangulationsverfahren beispielsweise er-



**Abb. 1.** Rückstreuintdikatrix bei der Streuung von Licht an einer Oberfläche.

gibt eine Diskussion der Fehlerfortpflanzung der Unsicherheit der Winkelmessung, dass die Unsicherheit der Position eines Messpunkts durch das sogenannte Konfidenzellipsoid beschrieben werden kann, dessen Halbachsen durch die Eigenvektoren der Varianz-Kovarianzmatrix aufgespannt und deren Längen durch den Betrag der Eigenwerte bestimmt werden; siehe Bild 2 [4]. Der günstigste Fall (Ellipsoid entartet zur Kugel) tritt dann bei einem Winkel von  $90^\circ$  zwischen den beiden optischen Achsen auf, der in der Praxis aber selten so einstellbar ist.

### 3 Bestimmung der Einzelpunktunsicherheit

Anhand der oben beschriebenen Abhängigkeit der Messunsicherheit von der geometrischen Anordnung der optischen Achsen in Kombination mit einem Modell der verwendeten Kamera (Abbildungseigenschaften, Bildsensor) ist eine Abschätzung der zu erwartenden lokalen Messunsicherheit möglich.

Ein anderer Ansatz leitet diese Information aus den Messdaten selbst ab. So ist beispielsweise in vielen Fällen, wie der Anwendung einer Phasenschiebeauswertung oder eines Heterodynverfahrens der lokale Modulationskontrast ein direktes Maß für die erreichbare Messunsicherheit bei der Bildauswertung. Die gängigen Auswertelgorithmen liefern neben dem Ergebnis auch einen aus dem Modulationskontrast abgeleiteten Qualitätskoeffizienten [5]. Der Carré-Algorithmus zur Auswertung phasencodierter Oberflächenprofile beispielsweise erfordert die Aufnahme von vier Bildern, zwischen denen die Phase der Trägerfrequenz des Musters jeweils um den Betrag  $\frac{\pi}{2}$  verschoben wird. Für jeden Messpunkt erhält man vier Intensitätswerte  $I_1, \dots, I_4$ , aus denen die lokale Phase  $\Phi$  (aus der sich die lokale Profilhöhe ergibt) und der lokale Modulationskontrast  $\gamma$  berechnen

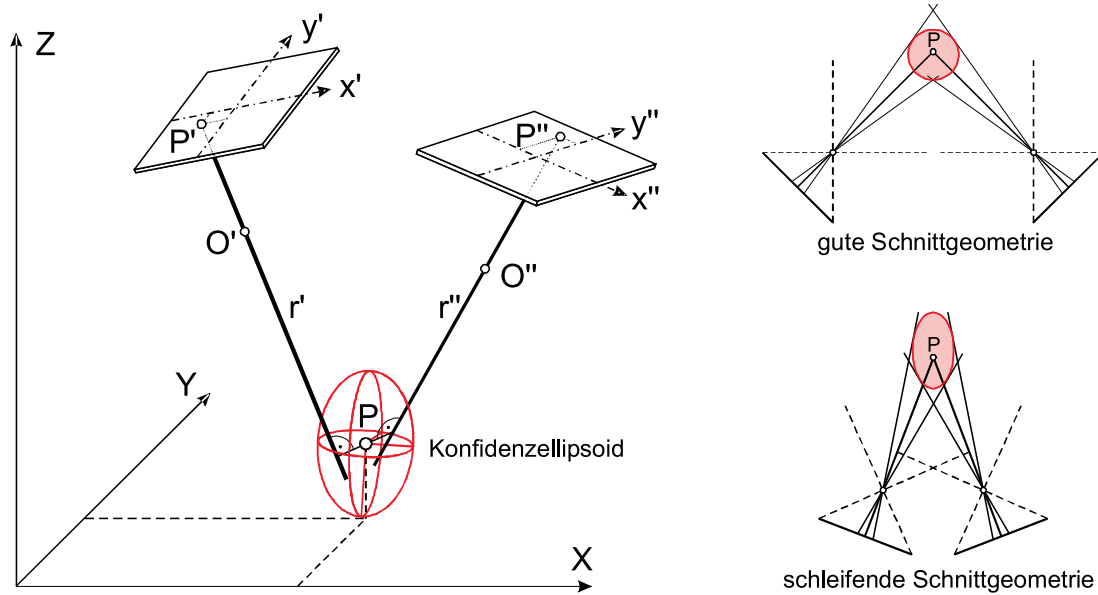


Abb. 2. Konfidenzintervall für die Stereophotogrammetrie.

lassen:


$$\left. \begin{aligned} I_1 &= I_0(1 + \gamma \cos \Phi) \\ I_2 &= I_0(1 + \gamma \cos(\Phi + \frac{\pi}{2})) \\ I_3 &= I_0(1 + \gamma \cos(\Phi + \pi)) \\ I_4 &= I_0(1 + \gamma \cos(\Phi + \frac{3\pi}{2})) \end{aligned} \right\} \Rightarrow \begin{aligned} \tan \Phi &= \frac{I_4 - I_2}{I_1 - I_3} \\ \gamma &= \frac{2\sqrt{(I_4 - I_2)^2 + (I_1 - I_3)^2}}{I_1 + I_2 + I_3 + I_4} \end{aligned} \quad (1)$$

Auch das in der Photogrammetrie bekannte Verfahren der Mehrbildtriangulation liefert Qualitätskoeffizienten [4]. Durch Verwendung von mindestens drei Kameraaufnahmen wird für eine Redundanz gesorgt, die es ermöglicht, nicht nur die Positionen von Objektpunkten, sondern auch die Posen (Position und Orientierung) der Kameras sowie die Kalibrierkoeffizienten für die Abbildungsfehler aus den Bilddaten zu berechnen; siehe Bild 3. Das System ist somit bis auf einen Skalierungsfaktor, der z. B. durch einen bekannten Maßstab im Messraum bestimmt wird, selbstkalibrierend. Der Unsicherheitskoeffizient ergibt sich hier aus der Abschätzung der Stabilität der zur Koordinatenberechnung zu lösenden Gleichungssysteme.

Bei Messverfahren, die keine direkte Information über die Unsicherheit bieten, empfiehlt sich eine statistische Auswertung von Wiederholmessungen zur Abschätzung der Messunsicherheit.

## 4 Datenfusion unter Berücksichtigung der Unsicherheit

In der Praxis arbeitet man bei der Flächenanpassung durchweg mit *Least-square-fit*-Verfahren, die normalverteilte Eingangsdaten mit einheitlicher Standardab-




**Abb. 3.** Bündelblockausgleich.

weichung voraussetzen. Bei (groben) Abweichungen von dieser Bedingung ist mit fehlerhaften Ergebnissen zu rechnen.

Als Gegenmaßnahme hat sich folgender Ansatz bereits praktisch bewährt: Die Messung wird mehrfach wiederholt, wobei unterschiedliche Parametereinstellungen (z. B. Belichtungszeit, Farbe/Polarisation der Lichtquelle, Ort der Lichtquelle) gewählt werden. Betrachtet man z. B. ein schwarzes und ein weißes Flächenelement auf dem Werkstück, so kann bei einer kurzen Belichtungszeit das Bild des weißen Flächenelements gut ausgesteuert sein, während das Bild des schwarzen Flächenelements nur einen sehr schwachen Signalpegel aufweist und damit verbunden ein schlechtes Signal/Rausch-Verhältnis, einen geringen Modulationskontrast und eine schlechte Nutzung der Dynamik des A/D-Umsetzers; siehe Bild 4. Eine zweite Messung mit erheblich längerer Belichtungszeit kann das Bild des schwarzen Flächenelements optimieren, während gleichzeitig das Bild des weißen Flächenelements aufgrund der Überbelichtung unbrauchbar wird.

Für jede der Messungen und jeden Objektpunkt wird die zugehörige Unsicherheit ermittelt. Damit stehen für jeden Messpunkt mehrere Messwerte mit jeweils zugeordneter Unsicherheit zur Verfügung. Durch die Auswahl des Messwertes mit der jeweils geringsten Unsicherheit lässt sich ein synthetischer Messdatensatz konstruieren, der eine weitgehend einheitliche Unsicherheit aufweist und „besser“ ist als jeder der realen Messdatensätze.

Stehen nicht genügend Ressourcen für die mehrfache Wiederholung der Messung zur Verfügung, so ist eine Verbesserung des Ergebnisses auch durch die Anwendung geeigneter statistischer Ausgleichsverfahren unter Berücksichtigung der unterschiedlichen Unsicherheit der Eingangsgrößen (Bayesscher Ansatz) möglich.



**Abb. 4.** Synthese eines Messdatensatzes aus zwei Teilmessungen bei kontrastreichem Objekt.

## 5 Zusammenfügen von Messpunktewolken

Die optischen 3D-Messverfahren messen genau genommen nur  $2\frac{1}{2}$ -D, da es aufgrund der geradlinigen Ausbreitung des Lichts nicht möglich ist, „um die Ecke“ zu messen. Die Objektrückseite oder hinterschnittene Oberflächenbereiche können nur durch die Wiederholung der Messung aus einer anderen Kameraposition erfasst werden. Für eine vollständige 3D-Messung müssen daher Messungen aus unterschiedlichen Richtungen kombiniert werden (engl.: *stitching*).

Prüfling und Messeinrichtung werden relativ zueinander bewegt. Man erhält mehrere Messpunktewolken, die relativ zueinander in sechs Freiheitsgraden justiert werden müssen. Die Anpassung der Teilmessungen erfolgt durch:

**Daten des Positioniersystems:** Das ist dann sinnvoll, wenn ein sehr genaues Positioniersystem zur Verfügung steht, z. B. beim Einsatz optischer Sensorik auf einem Koordinatenmessgerät; siehe Bild 5.



## KMG mit optischen 3D Sensor




Abb. 5. Optisches 3D-Messsystem an einem Koordinatenmessgerät.


**Korrelationsrechnung im Überlappbereich:** Dieser Ansatz setzt strukturierte Teilflächen voraus, die z. B. Kanten, Bohrungen oder ähnliche Geometrielemente enthalten; siehe Bild 6. Der Versuch, z. B. eine glatte Kugeloberfläche mit Korrelationsrechnung aus Segmenten zusammenzufügen, würde scheitern.

**Mitgemessene Referenzmarken:** Für diesen Ansatz werden Marken in der Weise am Messobjekt befestigt, dass jede Marke in mindestens zwei Messungen erfasst wird und jedes Messfeld mindestens drei Marken enthält; siehe Bild 7. Die Marken können zweidimensional (z. B. codierte Kreismarken) oder dreidimensional (z. B. Kugeln) sein. Die Positionen der Marken müssen nicht bekannt sein. Beim Anfügen der Messpunktewolken werden die jeweils sechs Freiheitsgrade der Posen der Messpunktewolken so berechnet, dass die mittlere quadratische Abweichung der Markenpositionen minimiert wird.

Es sind auch Kombinationen der beschriebenen Ansätze anwendbar. Dazu kann z. B. durch die Anwendung eines Kalman-Filters das Ergebnis der Anpassung mittels Referenzmarken durch die zusätzliche, in der Regel mit größerer Unsicherheit behaftete Information aus einer Korrelationsrechnung verbessert wird.

## 6 Zusammenfassung

Die Erfassung einer Messpunktewolke in der optischen 3D-Messtechnik ist als gleichzeitige Antastung der Objektoberfläche mit einer großen Zahl von Einzelpunktsensoren mit i. Allg. unterschiedlicher Messunsicherheit modellierbar. Es werden Ansätze zur Bestimmung dieser lokalen Messunsicherheit beschrieben und Methoden zur Fusion der in den Punktmessungen enthaltenen Information zu einer Beschreibung von Oberflächen angegeben. Es werden Strategien für




**Abb. 6.** Zusammenfügen zweier Punktwolken anhand der Korrelation im Überlappungsbereich.

das Zusammenfügen mehrerer Messpunktwolken erläutert, die eine vollständige Erfassung dreidimensionaler Objektflächen ermöglichen.

## Literatur

1. T. Pfeifer. *Fertigungsmesstechnik*. Oldenbourg Verlag, München, 1998.
2. R. Tutsch. Fertigungsmesstechnik. In: *Handbuch der Meß- und Automatisierungstechnik in der Produktion*, 2. Auflage, H.-J. Gevatter und U. Grünhaupt (Hrsg.). Springer Verlag, 2006.
3. M. Born und E. Wolf. *Principles of Optics*, 6th edition Pergamon Press, 1980
4. T. Luhmann. *Nahbereichsphotogrammetrie*. Wichmann Verlag, 2000.
5. J. E. Greivenkamp und J. H. Bruning. Phase Shifting Interferometry. In: *Optical Shop Testing*, 2nd edition, D. Malacara (Hrsg.). John Wiley, 1992.



**Abb. 7.** Beispiel für einen anhand von Referenzmarken aus Teilmessungen zusammengefügtens Datensatz.



# Multiskalige Messstrategien für die Mikrosystemtechnik

Johan Regin<sup>1</sup>, Joachim Neher<sup>1</sup>, Jens Pannekamp<sup>1</sup>, Engelbert Westkämper<sup>1</sup>,  
Tobias Wiesendanger<sup>2</sup> und Wolfgang Osten<sup>2</sup>

<sup>1</sup> Universität Stuttgart, Institut für Industrielle Fertigung und Fabrikbetrieb,  
Allmandring 35, 70569 Stuttgart

<sup>2</sup> Universität Stuttgart, Institut für Technische Optik, Pfaffenwaldring 9, 70569  
Stuttgart

**Zusammenfassung.** Eine multiskalige Mess- und Prüfstrategie wird für mikrosystemtechnische Mess- und Prüfaufgaben entwickelt. Die Strategie kombiniert Messverfahren unterschiedlicher Auflösungsstufe für die Erfassung, Charakterisierung und Prüfung von geometrischen und nicht-geometrischen funktionsrelevanten Kenngrößen. Der Mess- und Prüfablauf wird dynamisch gesteuert, so dass aufwendige Messverfahren lediglich auf kritischen Bereichen angewendet werden. Der Übergang von grob- zu feinskaligen Messverfahren wird durch Indikatorfunktionen unterstützt, die Hinweise auf mögliche Fehlstellen liefern. Ein Versuchsaufbau wurde erstellt, um die Strategie anhand des Anwendungsbeispiels Kontaminationskontrolle umzusetzen.

## 1 Problemstellung

Um die Oberfläche von mikro- und nanotechnischen Bauteilen zu erfassen, steht eine Vielzahl von Messverfahren bereit [1], die von taktilen Messverfahren [2] über optische Messverfahren [3–5] bis hin zu Sondenmessverfahren [6] reichen. Sollen auch von außen nicht zugängliche Bereiche wie Kavitäten vermessen werden, bietet sich der Einsatz von Mikro-Computertomographie (Mikro-CT) [7] an. Jedes der genannten Verfahren zeichnet sich durch spezifische Eigenschaften hinsichtlich des Messbereichs, der Messunsicherheit, der Messgeschwindigkeit und der Anwendbarkeit auf unterschiedliche technische Messobjekte aus. Um eine vollständige Charakterisierung eines Bauteils zu erhalten, ist ein einzelnes Messverfahren in der Regel nicht ausreichend. Werden Sensoren unterschiedlicher Auflösungsstufe durch intelligente Messstrategien zusammengeführt, lassen sich die Vorteile der jeweiligen Sensorkonzepte geschickt verbinden. Derartige multiskalige Messstrategien werden für mikrosystemtechnische Mess- und Prüfaufgaben entwickelt, die in der Praxis ungelöst oder nur ansatzweise gelöst sind. Beispiele solcher Mess- und Prüfaufgaben sind unter anderem:

- Die Prüfung von Mikrolinsenarrays mit mehreren tausend Einzellinsen ist sehr zeitaufwendig und wird deswegen nur stichprobenweise durchgeführt.

- 3D-Vermessung von mikromechanischen Komponenten wie Mikrozahnradern für miniaturisierte Getriebe oder Uhrwerke.
- Topografie Vermessung von substratbasierten Elementen wie Mikrofluidikelementen, mikrostrukturierten Schaltungen oder Membransensoren.
- Kontaminationskontrolle, insbesondere die Analyse von partikulären Verunreinigungen.

In einem multiskaligen Ansatz zur parallelen 100%-Prüfung von Mikrolinsenarrays wurden das konfokale Messprinzip in Kombination mit Weißlichtinterferometrie eingesetzt [8]. Als Indikator zur Steuerung des Messvorgangs diente die lateral aufgelöste fraktale Dimension. Im folgenden wird die multiskalige Strategie am Beispiel der Kontaminationskontrolle vorgestellt.

## 2 Allgemeiner Ansatz

Zielsetzung der hier vorgestellten Strategie ist die multiskalige Erfassung, Charakterisierung und Prüfung von geometrischen und nichtgeometrischen funktionsrelevanten Kenngrößen im Mikro- und Nanobereich. Im Abschnitt 2.1 wird ein hierarchischer Messablauf beschrieben, der eine sukzessive, bedarfsgesteuerte Detaillierung der Objektbeschreibung liefert. Der folgende Abschnitt 2.2 behandelt das Datenmodell, welches die Messobjekte über mehrere Skalen hinweg beschreibt und Abhängigkeiten zwischen den Skalen erfasst. Die Prüfentscheidung wird dynamisch in den fusionierten Datensätzen getroffen, sobald ein hinreichender Detaillierungsgrad vorliegt. Der Übergang von der grob- zur feinskaligen Objekterfassung wird von Indikatorfunktionen, die im Abschnitt 2.3 näher erläutert werden, gesteuert.

### 2.1 Messablauf

Abbildung 1 stellt den Ablauf des Messvorgangs schematisch dar. Im Zentrum des Ablaufs steht ein Messzyklus, in dem Messungen unter Verwendung von verschiedenen Sensorkonfigurationen und -positionen wiederholt ausgeführt werden. Vor dem Eintritt in den Zyklus wird die Mess-/Prüfaufgabe definiert und das Messsystem initialisiert.

Die Mess-/Prüfaufgabe setzt sich aus dem Vorwissen über das Messobjekt, den zur Verfügung stehenden Messverfahren, den zu erfassenden Messgrößen und deren Toleranzen zusammen. Im ersten Zyklusschritt wird geprüft, ob genügend Messdaten vorliegen, um die Mess-/Prüfaufgabe zu erfüllen. Das Ergebnis dieser Prüfung steuert den weiteren Ablauf des Messvorgangs. Wenn genügend Daten vorliegen, und die Mess-/Prüfaufgabe erfüllt ist, wird der Messzyklus abgebrochen und das Ergebnis der Messungen dargestellt. Liegen nicht genügend Daten vor, werden weitere Messungen benötigt und der Messzyklus wird mit der Konfiguration der nächsten Messung fortgeführt.

Bei der Konfiguration werden die vorhandenen Messdaten analysiert, um den Sensor für die nächste Messung auszuwählen, einzustellen und zu positionieren.

Ziel der Konfiguration ist, mit jeder Messung möglichst viel Information über das Objekt zu sammeln, so dass die Gesamtzahl der Messungen minimiert wird. Zu diesem Zweck werden drei Verfahren angewandt:

1. Unerforschte Bereiche des Messraumes werden grobskalig aufgenommen, sofern sie für die Prüfaufgabe relevant sind.
2. Die Messunsicherheit der vorhandenen Daten wird geschätzt und falls erforderlich durch wiederholte Messungen auf einer feineren Skala reduziert.
3. Indikatorfunktionen werden eingesetzt, um aus den grobskaligen Messdaten Hinweise auf mögliche Fehlstellen zu erhalten, die ebenfalls mittels feinskaliger Messungen überprüft werden.

Nach der Konfiguration wird der ausgewählte Sensor positioniert und eine Messung durchgeführt. Aufgrund von Unsicherheiten in der Sensorpositionierung müssen die neu aufgenommenen Messdaten zu den bereits vorhandenen registriert und korrigiert werden.

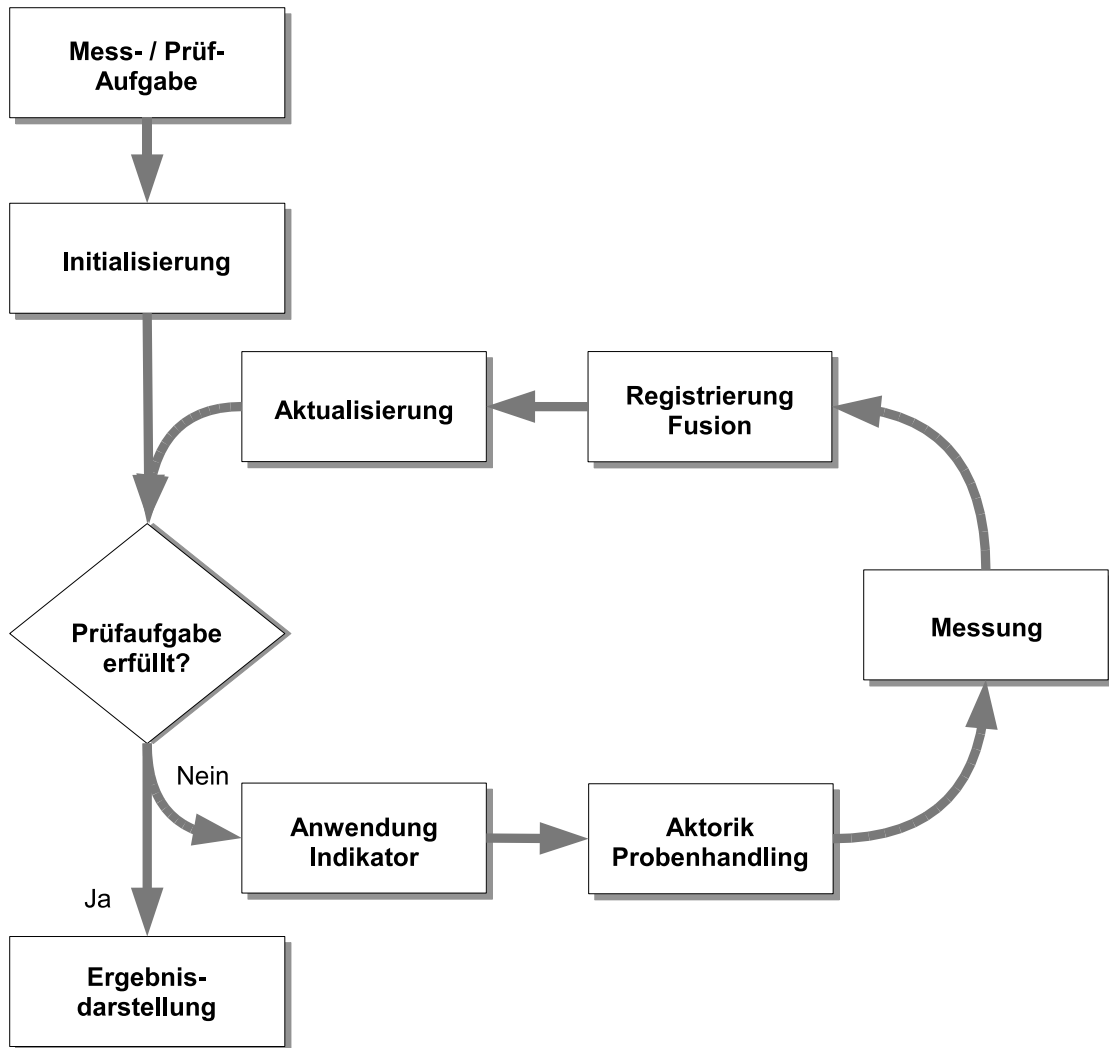
Anschließend wird eine Datenfusion durchgeführt, die alle Messdaten in einem gemeinsamen Modell des Messobjektes zusammenführt. Das Modell wird nach jedem Messzyklusdurchlauf aktualisiert. Anschließend erfolgt die Entscheidung, ob der Zyklus weitergeführt oder abgebrochen werden soll.

## 2.2 Datenmodell

Das multiskalige Datenmodell umfasst die im Messprozess verarbeiteten Daten, von der Aufgabenstellung bis zu den ermittelten Messgrößen. Die Aufgabenstellung, inklusive Vorwissen über das Messobjekt (Geometrie, Material, Oberflächenqualität) und die verfügbaren Messverfahren (Auflösung, Messfeld, Messprinzip), bildet den Rahmen für das Modell. Im Messprozess werden Primärdaten, d. h. Rohdaten der einzelnen Messungen und die jeweiligen Messkonfigurationen, erfasst. Im Datenmodell sind auch Sekundärdaten enthalten, die durch Verarbeitung aus den Primärdaten hervorgehen. Intern werden sowohl Primär- als Sekundärdaten gespeichert, zusammen mit ihrem jeweiligen Bezug zueinander.

## 2.3 Indikatoren

Für den Wechsel von grob- zu feinskaligen Messungen werden Indikatoren benötigt, die ausgehend von einer Übersichtsaufnahme eine Prognose über die feinskalige Beschaffenheit des Messobjektes erlauben. Ziel des Indikatorverfahrens ist, aufwendige Messverfahren lediglich auf kritischen Teilbereichen des Messobjektes anzuwenden, während unkritische Bereiche mittels schnelleren Verfahren vermessen werden. Die fraktale Dimension wurde bereits erfolgreich verwendet als Indikator für Defekte in Mikrolinsen. Es besteht ein Vielzahl weitere Merkmale, die für die Detektion von Anomalien in texturierten Oberflächen geeignet sind, darunter Merkmale der Zwei-Punkt-Statistik wie Abhängigkeitsmatrizen [10] oder Differenzhistogramme [9], lokale binäre Muster [12] und Gaborfilter [11]. Die Aussagekraft dieser Merkmale als Indikatoren ist abhängig von



**Abb. 1.** Ablauf des multiskaligen Messprozesses.

der jeweiligen Anwendung. Daher kommt der anwendungsspezifischen Auswahl von Indikatoren eine hohe Bedeutung zu. Soll der Anwender bei diesem Verfahrensschritt unterstützt werden, bietet sich der Einsatz adaptiver Verfahren zur Merkmalsselektion an [13].

### 3 Anwendung

Für die Umsetzung der vorgeschlagenen Strategie wurde die Oberflächenprüfung im mikrosystemtechnischen Umfeld als Anwendungsbeispiel herangezogen, wobei der Schwerpunkt auf der Detektion und Analyse partikulärer Defekte und Verunreinigungen (Abschnitt 3.1) liegt. Ein Versuchsaufbau, basierend auf einem hochauflösenden Bildverarbeitungssystem kombiniert mit einem AFM, wurde erstellt, um die multiskalige Strategie zu erproben und evaluieren (Abschnitt 3.2).



### 3.1 Partikuläre Fehlstellen

Mikrosystemtechnische Komponenten werden in der Regel auf lateral ausgedehnten Substraten (beispielsweise Siliziumwafern) hergestellt. Um Partikel und Verunreinigungen der Komponenten zu vermeiden, muss die Produktion in einer staubfreien Umgebung oder im Reinraum stattfinden. Dort werden automatisierte Prüfvorgänge, die die Anzahl vorhandener Partikel auf der Oberfläche erfassen, benötigt. Weiter ist eine Analyse der Ausprägung einzelner Partikel sowie eine Charakterisierung der Oberfläche hinsichtlich Textur und Rauheit wünschenswert, insbesondere wenn die Oberfläche anschließend beschichtet oder lackiert wird.

### 3.2 Versuchsaufbau

Der Versuchsaufbau zur Umsetzung der multiskaligen Mess- und Prüfstrategie setzt zwei Sensoren zur Oberflächencharakterisierung ein. Ein Bildverarbeitungssystem dient zur schnellen Charakterisierung von bis zu  $40 \times 40 \text{ mm}^2$  großen Proben. Konfigurierbare Beleuchtungseinheiten ermöglichen eine Anpassung der Aufnahmebedingungen an verschiedenen Proben. Mit dem Bildverarbeitungssystem können Oberflächenstrukturen ab  $5 \mu\text{m}$  aufgelöst werden. Als zweiter Sensor wird ein AFM eingesetzt, dessen untere laterale Auflösungsgrenze  $2 \text{ nm}$  beträgt. Aufgrund des  $100 \times 100 \mu\text{m}^2$  großen AFM-Messfelds besteht eine Überlappung zwischen den Skalen der beiden Sensoren. Damit ist die Grundvoraussetzung für eine multiskalige Prüfung erfüllt. Die Bildverarbeitung liefert eine Übersicht der Probe, woraus, mit Hilfe von Indikatoren, Hinweise auf Oberflächendefekte abgeleitet werden. Die multiskalige Mess- und Prüfstrategie wird umgesetzt, indem Teilbereiche zur AFM-Analyse dynamisch ausgewählt werden.


Der AFM-Messkopf wird mit Linearachsen in Standardausführung zu den jeweiligen Aufnahmepositionen geführt. Da die Unsicherheit der Positionierung (ca.  $20 \mu\text{m}$ ) größer als die Auflösung der Bildverarbeitung ist, müssen die AFM-Aufnahmen in das Übersichtsbild registriert werden, damit eine räumliche Zuordnung der aufgenommenen Bereiche besteht.

## 4 Ergebnisse

Eine Strategie für multiskalige Mess- und Prüfaufgaben wurde entwickelt und für die Detektion und Analyse partikulärer Defekte umgesetzt. Dafür wurde ein Versuchsaufbau konzipiert und aufgebaut. Abbildung 2 zeigt erste Messergebnisse von einem Glassubstrat mit einer Maske zur Auflösungsbestimmung.

## Danksagung

Die Arbeiten wurden im Rahmen des DFG-Schwerpunktprogramms 1159 gefördert (FKZ: OS 111/18-1 WE 1298/62-1).



**Abb. 2.** Erste Aufnahmen von einer Maske zur Auflösungsbestimmung. Eine Übersicht der Maske wurde mit dem Bildverarbeitungssystem aufgenommen (*links oben*). In dem vergrößerten Ausschnitt ist ein Quadrat mit der Seitenlänge 1 mm und einigen punktförmigen Abweichungen zu erkennen (*rechts oben*). Die Ausprägung der Abweichungen wird in der hochaufgelösten Topografieaufnahme dargestellt (*unten*).

## Literatur

1. A. Weckenmann und R. Ernst. Anforderungen an die zukünftige Mikro- und Nanomesstechnik — Herausforderungen und Vorgehensweisen. *Technisches Messen*, 67(7–8):334–342, 2000.
2. U. Brand und S. Büttgenbach. Taktile dimensionelle Messtechnik für Komponenten der Mikrosystemtechnik. *Technisches Messen*, 69(12):542–549, 2002.

3. W. Osten, S. Seebacher, T. Baumbach und W. Jüptner. Messtechnische Grundlagen zur Inspektion von Mikrokomponenten mittels digitaler Holografie. *Technisches Messen*, 68(2):68–79, 2001.
4. H. J. Tiziani, M. Wegner und D. Steudle. Confocal principle for macro- and microscopic surface and defect analysis. *Optical Engineering*, 39(1):32–39, 2000.
5. R. Windecker. *Optische Topometrie im Grenzbereich zwischen mikroskopischer und makroskopischer Formvermessung*. Dissertation, Universität Stuttgart, 1997.
6. K. Herrmann, L. Koenders et al. Dimensionelle Metrologie mittels Rastersondenmikroskopie. *Technisches Messen*, 69(12):519–525, 2002.
7. F. Mesch. Prozess-Tomographie. *Technisches Messen*, 69(7–8):331–332, 2002.
8. T. Wiesendanger, W. Osten, J. Pannekamp, J. Regin und E. Westkämper. Neue multiskalige Mess- und Prüfstrategien für die Produktion von Mikrosystemen. In: *Mikrosystemtechnik Kongress*, VDE Verlag, Berlin, S. 677–680, 2005.
9. M. Unser. Sum and difference histograms for texture classifications. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 8(1):118–125, 1996.
10. R. M. Haralick. Statistical and structural approaches to texture. *Proceedings of the IEEE*, 67(5):786–804, 1979.
11. A. Jain und F. Farrokhnia. Unsupervised texture segmentation using Gabor filters. *Pattern Recognition*, 24:1167–1186, 1991.
12. T. Ojala, M. Pietikäinen und D. Harwood. A comparative study of texture measures with classification based on feature distributions. *Pattern Recognition*, 29:51–59, 1996.
13. J. Pannekamp. *Adaptive Verfahren zur Bewertung texturierter Oberflächen*. Dissertation, Universität Stuttgart, Jost-Jetter Verlag, Heimsheim, 2005.



# Cooperative exploration with multiple robots using low bandwidth communication

Daniel Meier<sup>1</sup>, Cyrill Stachniss<sup>1,2</sup> und Wolfram Burgard<sup>1</sup>

<sup>1</sup> University of Freiburg, Department of Computer Science, D-79110 Freiburg

<sup>2</sup> Eidgenössische Technische Hochschule Zürich (ETH), CH-8092 Zürich, Switzerland

**Zusammenfassung.** In this paper, we consider the problem of exploring an unknown environment with a team of mobile robots. In this context, we assume that the robots have only a low bandwidth communication link. The key problem to be solved in this context is to decide which information should be transmitted over the network to enable the other team mates to choose appropriate target points. In this paper, each robot approximates its representation of the environment by a set of polygons. We present an efficient way to incrementally improve that kind of maps. We furthermore adapt an existing coordination strategy so that it is able to deal with our approximated representations in a distributed fashion. Our technique has been implemented and tested. The results demonstrate that our distributed technique can efficiently spread the robots over the environment even if the communication link provides only a low bandwidth. As a result, the robots are able to quickly accomplish their exploration mission despite the constraints introduced by the limited bandwidth.

## 1 Introduction

Exploring an environment belongs to the fundamental problems in mobile robotics. There are several applications like planetary exploration [1], rescue [17, 19], mowing [11], or cleaning [13, 18] in which the complete coverage of a terrain belongs to the integral parts of a robotic mission.

To efficiently accomplish an exploration task with multiple robots, a coordination strategy is needed to assign target locations to the different robots [4]. To implement such a technique using a team of real robots, a fast network connection is required in order to send the environmental information to each robot. In real applications, all sensor measurements need to be sent to all other robots or the whole team has to exchange the map. Whereas this is feasible for small groups of robots, it introduces a serious communication overhead for big teams. Therefore, taking the available bandwidth into account when exchanging information is an important requirement for larger robot teams.

In this work, we present a distributed approach to multi-robot exploration for situations in which the network connections have unlimited range and are reliable

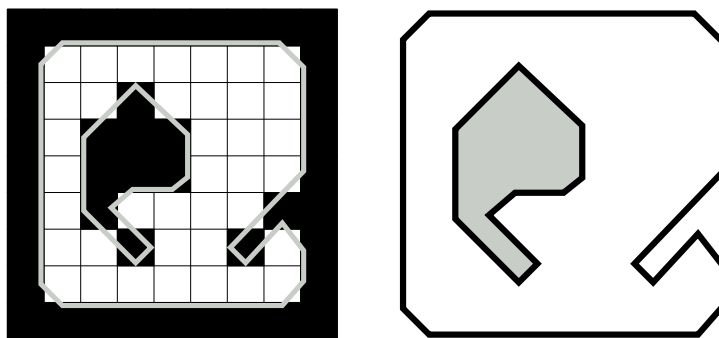
but only provide a limited bandwidth. Our algorithm computes a polygonal approximation for each map learned by a robot and transmits only changes and refinements of this map to the other robots over the communication link. Based on their own maps and the approximated descriptions of the areas covered by the other robots, each team mate chooses a target location it plans to attain. It then broadcasts this location to the other robots, which consider this plan when calculating their own target location.

## 2 Related Work

The various aspects of the problem of exploring unknown environments with teams of mobile robots have been studied intensively in the past. For example, Yamauchi *et al.* [22] present a technique to learn maps with a team of mobile robots. In their approach, the robots exchange information about the map that is continuously updated whenever new sensor input arrives. They furthermore introduced the idea of a frontier, which separates the environment into known and unknown areas. Burgard *et al.* [4] presented a technique to coordinate teams of mobile robots which extends a work published in 2000 [3]. Their approach trades off the cost of moving to frontiers with the expected amount of information that can be obtained when a robot arrives at that frontier. Ko *et al.* [15] apply a similar coordination technique that uses the Hungarian Method [16] to compute the assignments of frontier cells to robots. Howard *et al.* [10] presented an incremental deployment approach that aims to coordinate the robots in a similar way. Zlot *et al.* [23] as well as Gerkey and Mataric [7] have proposed an architecture for mobile robot teams in which the exploration is guided by a market economy. Their approach trades tasks using single-item first-price sealed-bid auctions between the robots. In these approaches, it is typically assumed that the network connections have a sufficiently high bandwidth. In contrast to that, the algorithm proposed in this paper is designed to deal with low bandwidth communication links.

In [2], Balch and Arkin analyze the effects of different kinds of communication on the performance of teams of mobile robots that perform tasks like searching for objects or covering a terrain. The “graze task” carried out by the team of robots corresponds to an exploration behavior. One of the results is that the communication of goal locations does not help if the robots can detect the “graze swathes” of other robots. In this paper, we seek to minimize the communication between the robots by utilizing a polygonal approximation of the maps of the individual robots. Recently, specialized coordination techniques have been published for certain domains. In the context of RoboCup, different coordination behaviors are used in combination with role assignment techniques [12, 20].

In the literature, several techniques are available that reduce polygons consisting of originally  $n$  vertices to similar polygons consisting of a subset of  $m$  vertices (see Heckbert and Garland [8] or Buzer [5] for comprehensive surveys). In our approach, we apply the Douglas-Peucker algorithm [6] which, according to [21], is one of the most visually effective line simplification algorithms. In



**Abb. 1.** This figure shows the polygon map (right) that is derived by our algorithm from the grid map (left).


the past, many improvements have been proposed for the basic Douglas-Peucker algorithm. Hershberger and Snoeyink [9] proposed an  $O(n \log n)$  variant of the basic Douglas-Peucker algorithm whose time complexity is  $O(nm)$ . Another improvement of this algorithm that avoids self-intersecting approximations is the star-shaped Douglas-Peucker algorithm [21].

The contribution of this paper is an approach that is able to efficiently explore an unknown environment with mobile robots that only have a low bandwidth connection to exchange information. Our algorithm approximates the environment using line simplification techniques to obtain a compact geometric model which then is used to coordinate the robots. Compared to the full map, these polygonal approximations require seriously fewer memory and this way can be more efficiently communicated.

### 3 Approximating the Environmental Model

The key idea of our approach to deal with a low bandwidth communication link during exploration is to compute an approximative but compact representation of the environment and to communicate only this compact model between the robots. To obtain the compact approximation of the map, we compute a set of polygons which are extracted from a grid map of each robot. The polygons contained in a polygon map can contain either free or unknown space. Polygons that are contained inside of other polygons have a higher priority and thus overwrite the occupancy values of the outer polygons (compare Figure 1). The boundaries of a polygon can represent either free, occupied or unknown areas. These polygon maps are learned by extracting the contours of a robot's field of view and of the observed obstacles. We then apply an adapted version of the Douglas-Peucker algorithm [6] to approximate the extracted contours. In the following, the contour is also referred as the boundary  $\mathcal{B}$  of the observed area.

We merge polygon maps by building a grid map in the following way. If the information given by other robots is not contradictory, a joined grid map can be constructed in a straightforward manner. If in contrast the information



**Abb. 2.** Case 1: A vertex, which was located on  $\mathcal{B}_{t-1}$  is no longer located on  $\mathcal{B}_t$  due to newly observed areas.

given by other robots is contradictory, we prefer occupied to free and free to unknown information. Note that a robot only updates its own map according to the received information in areas it has not observed on its own.

Since the field of view of each robot changes in every step, the polygonal model can get out-dated quickly. Accordingly, the polygon map needs to be updated appropriately. Since the robots only have a low bandwidth connection, it is not appropriate to transmit the whole polygon map after each update. Instead, we communicate the incremental changes of the model only. This is achieved by introducing the constraint, that points which are a part of the current polygon map model will also be part of the updated model. This constraint, of course, only holds for those points, which after the update still lie on the boundary of an obstacle or on a frontier to unknown terrain.


To update a polygon map based on sensory input, we distinguish the following cases (see Figures 2-4):

1. Vertices of the polygonal approximation of the boundary  $\mathcal{B}_{t-1}$  at time step  $t - 1$  are no longer located on the boundary  $\mathcal{B}_t$  of the observed area in the current time step  $t$  (see Figure 2),
2. the boundary of the observed area can change in a way so that all points of the approximation are still located on the boundary but the approximation becomes inadequate anyway (see Figure 3), or
3. new boundaries can arise or a boundary can split up into several boundaries which are not connected anymore and which can be contained in the original boundary (see Figure 4).

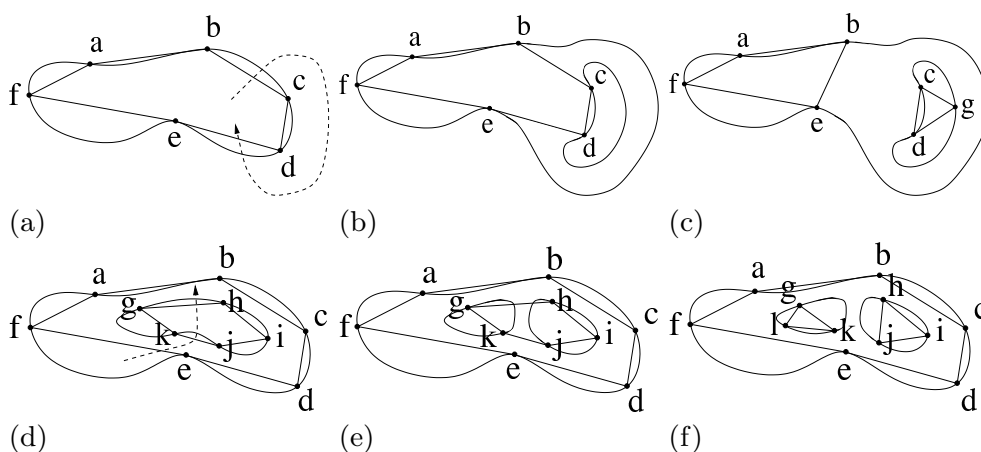
To update the polygon map, we mark all vertices which lay on the boundary of the visible area  $\mathcal{B}_{t-1}$  in the previous step  $t - 1$  but do not lie on  $\mathcal{B}_t$  anymore. After that, we iteratively discard all points that have been marked and connect their former neighbors. After this step, all points that remain part of the approximation are located on  $\mathcal{B}_t$ . In case points have been removed, we typically have to refine the approximation again to appropriately model the environment.

In the next step, we have to identify whether parts of the boundary  $\mathcal{B}_{t-1}$  have split up into several parts (like shown in Figure 4 (a)-(c) and (d)-(f)). This is achieved by labeling the vertices of the polygon map with the number of the





**Abb. 3.** Case 2: All vertices of the approximation lie on the boundary  $\mathcal{B}_t$  but the approximation gets inadequate anyway.



**Abb. 4.** Case 3: A newly raised boundary (a)-(c) and a boundary which splits up into several new boundaries (d)-(f).

contour on which they are situated on  $\mathcal{B}_t$ . Whenever two former neighboring vertices of the polygon map now have different labels, they are disconnected by discarding the edge between these vertices. To close all polygons again the robot traces the underlying contour  $\mathcal{B}_t$  of each vertex  $v$  having less than two neighbors. The process for a vertex  $v$  stops when we find another vertex  $w$  on the underlying contour that also is part of the polygon map and has the same index as  $v$ . Each pair of vertices  $v$  and  $w$  is connected and so all polygons get closed again. In case,  $v$  is the only vertex still lying on the underlying contour  $\mathcal{B}_t$ , a new arbitrary point  $w$  of the underlying contour is taken to close the approximation. This is also done for contours that are not yet approximated by any vertex of the new polygon map.

After this step, we can refine the new polygon map using the Douglas-Peucker algorithm by splitting up edges. Usually, the Douglas-Peucker algorithm inserts a new vertex having the biggest distance to its closest segment into its closest line segment. Since we work with sets of polygons, we would, according to the original Douglas-Peucker algorithm, split up the edge having the biggest segment-point-



**Abb. 5.** The approximation of the environmental model during exploration.

distance of the polygon that has the maximum segment-point-distance of all polygons.

Figure 5 shows the evolution of the approximation process for a single robot exploring an unknown environment. In this figure, white areas outside as well as gray/light blue areas inside the polygon map correspond to inappropriately modeled terrain. Such an approximation is well-suited to be transmitted via a network, because it can be updated incrementally and the individual update steps can be realized with low space complexity.

## 4 Multi-Robot Coordination

Our strategy for coordinating teams of mobile robots is based on the ideas of Burgard *et al.* [4]. Their approach spreads the robots over the environment by introducing a penalty for places already visited by the robots. In contrast to this, our algorithm works in a distributed manner. Instead of using a central component which selects target locations for all robots, our approach considers the decisions so far made by other robots. Whenever a robot selects a new target location, it broadcasts its decision to all other robots. From this point in time, the other robots incorporate this information into their plans by discounting this goal according to [4]. Our approach is described in Algorithm 11.1. In this formulation,  $V_{t'}$  refers to the cost of reaching target location  $t'$  from the current position of the robot. Our approach furthermore combines the polygonal maps of its team mates with its own world knowledge. Since data received from other robots have an approximative character, the robot only updates such parts of its own map using data received by other robots if the robot has not yet covered the corresponding area with its own sensor.

Whenever a target point  $t'$  is selected for a robot, we reduce the utility of the adjacent goals in distance  $d$  from  $t'$  according to the probability  $P(d)$  that the robot's sensors will cover cells in distance  $d$ . In our approach, we approximated  $P(d)$  by

$$P(d) = \begin{cases} 1.0 - \frac{d}{max\_range} & \text{if } d < max\_range \\ 0 & \text{otherwise} \end{cases}, \quad (1)$$

where  $max\_range$  is the maximum range reading provided by the range sensor.

Such a coordination technique is well-suited to spread the robots over the environment and to avoid that several robots approach the same target because it is the closest to its current location. Compared to the coordination scheme

---

**Algorithm 11.1** Goal Assignment for Coordinated, Decentralized Multi-Robot Exploration using Polygons.
 

---

- 1: Compute the union of all polygonal maps received by the other robots and combine them with the own self explored environmental data.
  - 2: Compute the possible goal locations based on the frontier (points that lead to unknown areas).
  - 3: Set the utility  $U_t$  of potential targets to 1.
  - 4: **for all** Received targets from other robots **do**
  - 5:   Reduce the utility of each target point  $t'$  in the visibility area according to  $U_{t'} \leftarrow U_{t'} - P(\|t - t'\|)$ .
  - 6: **end for**
  - 7: Determine the robot's target  $t$  which satisfies:  

$$t = \max_{t'} (U_{t'} - \beta \cdot V_{t'}).$$
  - 8: Broadcast the target  $t$  to all other robots.
- 

in [4], our coordination mechanism typically leads to longer exploration times. However, it is the only possibility to use the discounting technique in a decentralized way. The centralized approach needs a much higher bandwidth, since more information needs to be exchanged.

## 5 Experiments


The experiments described in this paper are designed to demonstrate the effectiveness of our environmental approximation to coordinate a team of robots using a low bandwidth network connection.

### 5.1 Influence of the Network Bandwidth on the Exploration Time

In this experiment, we analyzed the dependency of the quality of the environmental approximation on the overall exploration time.

The central parameter that determines approximation quality is the split rate (SR). With this parameter, we determine an upper bound for the number of edge splits per second. So when we have a SR of 0.04 the robot performs at most one edge split every 25 seconds. Edge splits are not performed when the approximation of the robot is appropriate meaning that the approximation error is equal to zero.

Figure 6 depicts how exploration time for coordinated robots decreases when the quality of the approximation (and thus the network bandwidth) increases. In these plots, we compare the performance of the original centralized coordination approach presented by Burgard *et al.* [4] to our decentralized approach. It furthermore compares our method to an adapted version of the centralized approach, which uses our decentralized coordination. It is important to note that the decentralized coordination leads to worse results than the original centralized approach, since the target assignment process is done in a decentralized way. Only a centralized coordination technique has the ability to choose that robot-target



**Abb. 6.** Exploration time for different split rates (approximation qualities) and numbers of robots. The plot in the first row shows the result for 3 robots in an unstructured environment and the second row depicts the evolution for 5 robots in a corridor environment.

tuple that provides the (globally) highest expected utility. The decentralized method used throughout this paper is necessary to keep the communication costs low. The relative advantage of the original coordination mechanism compared to the decentralized variant increases with the number of robots. Figure 6 demonstrates that for an increasing communication link bandwidth the performance of our approach converges towards the performance of the decentralized coordination approach without polygonal approximations and bandwidth restrictions.

## 5.2 Comparison to Other Approaches

In the second experiment, we compared our approach to the coordination technique presented by Burgard *et al.* [4], which uses an unrestricted communication link. In their approach, the environmental model needs to be integrated by each robot of the team and the sensor information of all robots need to be transmitted to all other robots. In scenarios with a huge amount of robots, this causes a huge amount of network traffic.

Our decentralized coordination method is derived from the centralized coordination technique in [4] and was adapted to our underlying representation and to the bandwidth restrictions. Thus, the original approach with unlimited communication describes a lower bound for our algorithm. This is illustrated in Figure 6. As can be seen from this experiment, even with low bandwidth connections, which allow to transmit around 7.500 integers per second and robot, a similar

**Tabelle 1.** The relative network traffic introduced by the different packages for different approximation refinement frequencies (SR).

SR	TPT (%)	ES (%)	B (%)	VP (%)	EP (%)
0.04	31.12	19.82	11.32	6.16	31.58
0.05	29.00	23.06	13.51	5.45	28.97
0.07	25.68	26.89	15.25	5.37	26.81
0.1	22.00	36.09	16.02	4.54	21.35
0.2	16.77	52.52	14.24	3.90	12.58
1	5.62	78.95	3.46	9.52	2.45
5	1.56	79.90	0.26	17.78	0.50
10	1.01	78.57	0.04	19.97	0.41
15	0.85	78.14	0.03	20.68	0.29
20	0.77	77.99	0.02	20.93	0.28
25	0.76	77.88	0.02	21.05	0.30

coordination result can be achieved compared to the centralized coordination approach which requires a network bandwidth of about 200.000 integers per second.


### 5.3 Analyzing the Network Traffic

In this experiment, we analyzed the network traffic. In particular, we analyzed which kinds of data packages occurred and what was their share compared to the full amount of network traffic.

In our approach, different kinds of data packages need to be sent via the communication link. In our current implementation, we use target point transmissions (TPT) to publish chosen target locations to robots with lower priority. Edge split packages (ES) refer to the situation, in which an edge of the approximation is refined. A broken boundary package (B) is sent via the network if the boundary splits up to several small boundaries and the emerged points data package (EP) is used to describe a newly detected object (see Section 3, case 3). Finally, the vanished points package (VP) corresponds to the situation, in which a point is removed from approximation. To identify a point or edge in the approximation, we use unique IDs and each point is represented by two integer values.

Table 1 depicts the relative network traffic caused by the different data packages. It demonstrates, that in case of low approximation refinement frequencies (SR) the transmission of the goal points causes a high amount of the overall traffic (33.12%), whereas this can be neglected in case of high refinement rates.

To give a more quantitative evaluation of the caused traffic, we compared the used bandwidth of our approach to the centralized coordination approach. Using this technique, each robot transmits its full laser range sweeps to the other robots. This ensures, that all robots have the same world knowledge. Using a broadcast network, the overall network traffic grows linearly in the number of



**Abb. 7.** Comparison of network traffic amounts for the polygonal approach (for different approximation qualities) and for classical approaches transmitting raw sensor data for two robots.

**Tabelle 2.** Low communication rates lead to high approximation errors and vice versa.

Splits per Second	Avg. Approximation Error
0.1	8.92 %
1	0.86 %
10	0.19 %


robots. Figure 7 depicts the overall network traffic caused by both approaches exploring the same environment. As can be seen, our approach clearly outperforms the other technique. Even in the case of high approximation refinement rates, our approach requires only a fragment of the network traffic compared to the centralized coordination algorithm.

#### 5.4 Approximation Error

The last experiment in this paper is designed to illustrate the approximation error of our approach compared to a non-distributed algorithm, which integrates all sensor measurements into one central map.

The approximation error and thus the quality of an approximation directly depends on the SR whereas the higher the SR the lower is the average approximation error (see Table 2).

Figure 8 depicts the approximation error of our polygonal maps for two different approximation refinement rates. The plot in the first row depicts the error in case of a refinement rate of 10 refinement operations per second. As can be seen, the error is quite small. Whenever the robot observes a huge amount of so far unknown terrain, the approximation error increases. As can be seen from the figure, the error is typically reduced within a few steps. Compared to that, the error using a low bandwidth connection (see second row of Figure 8), which allows 0.1 refinements per second, is bigger. Furthermore, it takes much longer to correct the error compared to the faster connection.



**Abb. 8.** Approximation error during exploration for (top image) high and low (bottom image) communication bandwidth.

## 6 Conclusions

In this paper, we presented a distributed approach to multi-robot coordination for systems with reliable but limited bandwidth connections. To deal with low bandwidth networks, we approximate the maps communicated between the robots by polygonal representations. We also describe an incremental scheme for updating the polygons whenever the map has been extended. Finally, we proposed a distributed approach to assign targets to robots.

Our approach has been implemented and tested in extensive simulation runs. The results reveal that our algorithm can efficiently coordinate teams of mobile robots even under severe bandwidth restrictions. One finding is that there is no significant difference to decentralized approaches assuming unlimited bandwidth when each robot broadcasts only very little information in each step.

## Acknowledgment

This work has partly been supported by the German Research Foundation (DFG) under contract number SFB/TR-8 (A3) and by the EC under contract number FP6-004250-CoSy and FP6-IST-027140-BACS.

## Literatur

1. D. Apostolopoulos, L. Pedersen, B. Shamah, K. Shillcutt, M. D. Wagner und W. R. L. Whittaker. Robotic Antarctic Meteorite Search: Outcomes. In: *Proc. IEEE Int. Conf. on Robotics & Automation (ICRA)*, S. 4174–4179, 2001.
2. T. Balch und R. C. Arkin. Communication in Reactive Multiagent Robotic Systems. *Journal of Autonomous Robots*, 1(1):27–52, 1994.
3. W. Burgard, M. Moors, D. Fox, R. Simmons und S. Thrun. Collaborative Multi-Robot Exploration. In: *Proc. IEEE Int. Conf. on Robotics & Automation (ICRA)*, 2000.
4. W. Burgard, M. Moors, C. Stachniss und F. Schneider. Coordinated Multi-Robot Exploration. *IEEE Transactions on Robotics and Automation*, 2005. To appear.
5. L. Buzer. A Survey and a New Competitive Method for the Planar min-# Problem. *CoRR*, cs.CG/0209007, 2002.
6. D. H. Douglas und T. K. Peucker. Algorithms for the Reduction of the Number of Points Required to Represent a Digitized Line or Its Caricature. *The Canadian Cartographer*, 10(2):112–122, 1973.
7. B. P. Gerkey und M. J. Matarić. Sold! Auction methods for multi-robot coordination. *IEEE Transactions on Robotics and Automation*, 18(5):758–768, 2002.
8. P. S. Heckbert und M. Garland. Survey of Polygonal Surface Simplification Algorithms. Technischer bericht, School of Computer Science, Carnegie Mellon University, Pittsburgh, May 1997.
9. J. Hershberger und J. Snoeyink. An  $O(n \log n)$  implementation of the Douglas-Peucker algorithm for line simplification. In: *SCG '94: Proceedings of the tenth annual symposium on Computational geometry*, S. 383–384. ACM Press, 1994.
10. A. Howard, M. J. Matarić und S. Sukhatme. An Incremental Deployment Algorithm for Mobile Robot Teams. In: *Proc. IEEE/RSJ Int. Conf. on Intelligent Robots and Systems (IROS)*, 2002.
11. Y. Huang, Z. Cao, S. Oh, E. Kattan und E. Hall. Automatic Operation for a Robot Lawn Mower. In: *SPIE Conference on Mobile Robots*, volume 727, S. 344–354, 1986.
12. L. Iocchi, D. Nardi, M. Piaggio und A. Sgorbissa. Distributed Coordination in Heterogeneous Multi-Robot Systems. *Journal of Autonomous Robots*, 15(2):155–168, 2003.
13. M. Jäger und B. Nebel. Dynamic Decentralized Area Partitioning for Cooperating Cleaning Robots. In: *Proc. IEEE Int. Conf. on Robotics & Automation (ICRA)*, 2002.
14. R. E. Kalman. A New Approach To Linear Filtering and Prediction Problems. *ASME-Journal of Basic Engineering*, (March):35–45, 1960.
15. J. Ko, B. Stewart, D. Fox, K. Konolige und B. Limketkai. A Practical, Decision-theoretic Approach to Multi-robot Mapping and Exploration. In: *Proc. IEEE/RSJ Int. Conf. on Intelligent Robots and Systems (IROS)*, 2003.
16. H. W. Kuhn. The Hungarian Method for the Assignment Problem. *Naval Research Logistics Quarterly*, 2(1):83–97, 1955.
17. R. Murphy. Human-Robot Interaction in Rescue Robotics. *IEEE Systems, Man and Cybernetics Part C: Applications and Reviews*, 34(2), 2004.
18. M. Simoncelli, G. Zunino, H. I. Christensen und K. Lange. Autonomous Pool Cleaning: Self Localization and Autonomous Navigation for Cleaning. *Journal of Autonomous Robots*, 9(3):261–270, 2000.



19. S. Thrun, D. Hähnel, D. Ferguson, M. Montemerlo, R. Triebel, W. Burgard, C. Baker, Z. Omohundro, S. Thayer und W. Whittaker. A System for Volumetric Robotic Mapping of Abandoned Mines. In: *Proc. IEEE Int. Conf. on Robotics & Automation (ICRA)*, 2003.
20. T. Weigel, J.-S. Gutmann, M. Dietl, A. Kleiner und B. Nebel. CS-Freiburg: Coordinating Robots for Successful Soccer Playing. *IEEE Transactions on Robotics and Automation*, 18(5):685–699, 2002.
21. S.-T. Wu und M. R. Gonzales Márquez. A Non-Self-Intersection Douglas-Peucker Algorithm. In: *SIBGRAPI*, S. 60–66, 2003.
22. B. Yamauchi. Frontier-Based Exploration Using Multiple Robots. In: *Proc. Second Int. Conf. on Autonomous Agents*, 1998.
23. R. Zlot, A. T. Stenz, M. B. Dias und S. Thayer. Multi-Robot Exploration Controlled by a Market Economy. In: *Proc. IEEE Int. Conf. on Robotics & Automation (ICRA)*, 2002.



# Multisensorielle Exploration von Roboterarbeitsräumen

Michael Suppa und Gerd Hirzinger

Institut für Robotik und Mechatronik, Deutsches Zentrum für Luft- und Raumfahrt (DLR), Münchner Str. 20, D-82234 Weßling

**Zusammenfassung.** In diesem Artikel werden Arbeiten aus dem Bereich Arbeitsraumexploration und 3D-Modellierung am Institut für Robotik und Mechatronik des Deutschen Zentrums für Luft- und Raumfahrt vorgestellt. Mit Hilfe der vorgestellten Methoden werden Roboter in die Lage versetzt, (teil-)autonom ihren Arbeitsraum zu explorieren. Die Umgebung des Roboters ist initial vollständig oder teilweise unbekannt, daher muss der Roboter sukzessive eine Repräsentation der Umgebung aufbauen. Zur Umgebungserfassung werden verschiedene optische Sensoren, wie Lichtschnitt, Laserscanner oder Stereo verwendet. Die Lage des Sensors kann über die Roboterkinematik oder externes Tracking bestimmt werden. Die Fusion der Tiefendaten in eine konsistente Repräsentation, z. B. zur Bahnplanung und zur Planung der Sensorlagen, wird vorgestellt. 3D-Sensorik, Sensorsynchronisation, Kalibrierung, Datenverarbeitung und Modellerstellung werden dargestellt. Algorithmen zur Planung der Sensorlagen, den so genannten *Next Best Views* unter Berücksichtigung von Messrauschen und Verdeckungen sind weitere Kernpunkte des Artikels.

## 1 Einleitung

Dieser Artikel beschäftigt sich mit der multisensoriellen Exploration von Roboterarbeitsräumen, zu denen wenig oder kein A-priori-Wissen (CAD oder sonstige Modelldaten) vorhanden sind.

Ein Schwerpunkt liegt in der zeitlichen und räumlichen Synchronisation eines multisensoriellen Systems. Es wird der Bogen von der handgeführten Modellierung, bei der Daten ungeordnet aufgenommen werden, zur automatischen Erfassung von 3D-Objekten gespannt. Bei der robotergestützten Modellierung wird insbesondere auf die Beschreibung und Steigerung des Bewegungsspielraums des Roboters eingegangen. Hierfür wird das Rauschverhalten der verwendeten Sensoren, wie dies in der Datenfusion gebräuchlich ist, modelliert.

Der Prozess der 3D-Modellierung kann in zwei aufeinanderfolgende Schritte unterteilt werden: Datenakquise und Modellierung. Im Allgemeinen ist es nicht möglich, ein 3D-Objekt in einem einzigen Messschritt zu erfassen. Dies ist z. B. durch Selbstverdeckung oder die Objektgröße bedingt. Das bedeutet, dass häufig mehrere Ansichten desselben Objektes aus unterschiedlichen Blickrichtungen

aufgenommen werden müssen, die dann zu einem Modell zusammengeführt werden.

Sind Modelldaten der Umgebung und deren Objekte vorhanden, ist lediglich deren Lage im Arbeitsraum zu bestimmen. Hierbei werden sensoruell (zum Beispiel berührungslos mit Lasersystemen oder auch durch punktuell abtasten) Daten der Oberfläche erfasst. Mit dieser Information wird die Transformation der Objekte in das Weltkoordinatensystem bestimmt.

Zur 3D-Modellierung werden häufig Drehtische verwendet, was jedoch bei komplexen Objekten mit Hinterschneidungen oder großen Objekten Probleme bereitet. Ein Transfer der Methoden auf ein System mit vielen Freiheitsgraden (FhG) mit nicht-trivialer Kinematik ist daher nur schwer möglich. Aus diesem Grunde ist ein Sensorsystem, der multisensorielle 3D-Modellierer (3DMo) entwickelt worden, welches dem Benutzer eine freie Bewegung in allen sechs Raumfreiheitsgraden (FhG) während der Messung ermöglicht. Im Gegensatz zu anderen Systemen [4, 6], wurde beim Entwurf besonders auf die multisensorielle, zeitgleiche Erfassung von Oberflächengeometrien und Texturen Wert gelegt.

Zur Bestimmung der Position und Orientierung (im weiteren als Lage bezeichnet) des Sensorsystems kommen alternative Systeme zum Einsatz. Es kann ein passiver Manipulator, ein optisches Trackingsystem oder ein Roboter verwendet werden.

Mit diesem System, welches in Kapitel 2 vorgestellt wird, wurden zunächst Erfahrungen bei der Erzeugung fotorealistischer 3D-Modelle gesammelt. Das handgeführte System musste für den Robotereinsatz weiterentwickelt werden. Optimierungskriterien waren sowohl die hand- und robotergeführte Einsatzmöglichkeit als auch die Verbesserung der Sensorkomponenten und Eigenschaften.

Die Idee, den Prozess der Modellierung automatisiert mit einem Roboter durchzuführen, wirft darüber hinausgehende Probleme auf. Dies betrifft insbesondere die Planung der Sensorlagen und die Kollisionvermeidung auf Basis multisensorieller Information. Bestehende Verfahren zur automatischen Modellierung, wie in [8] vorgestellt, beschränken sich meist auf wenige Freiheitsgrade, multisensorielle Information wird überhaupt nicht berücksichtigt.

In dem hier dargestellten Ansatz wird die automatische Modellierung in drei Teilaspekte aufgeteilt:

1. Entwicklung eines **multisensoriellen Hand-Auge-Systems** zur Evaluation und Verifikation der Algorithmen und Verfahren.
2. Erfassung der Bewegungsfreiheit eines Roboters, im Folgenden als **Exploration** bezeichnet.
3. Die (semi-)automatische Erfassung (Modellierung) eines Objektes, die **Inspektion**.

Dieser Artikel behandelt die System- und Explorationskomponente des Ansatzes. Es wird davon ausgegangen, dass der Roboter zu Beginn der Exploration/Modellierung kein oder nur sehr wenig Wissen über seinen Arbeitsraum besitzt, und sich diese Informationen über die ihm zur Verfügung stehenden Sensoren sukzessive aufbaut. Die Sensorik ist dabei am Endeffektor des Roboters montiert, es handelt sich um ein so genanntes *Hand-Auge-System*. In Kapitel

3 wird detailliert auf die Planung der Sensorlagen eingegangen, und Ergebnisse für die multisensorielle Exploration des Konfigurationsraums (Gelenkraums) des Roboters werden dargestellt. Siehe hierzu auch [13]. Der Ausblick beschäftigt sich mit der Integration der robotergestützten Modellierung von Objekten (**Inspektion**).

## 2 Multisensorieller 3D-Modellierer

In diesem Abschnitt wird auf das Sensorsystem und die verwendeten Messverfahren eingegangen. Es wird ein Synchronisierungskonzept dargestellt, das die Fusion der verschiedenen Sensordaten erlaubt.

Der 3D-Modellierer (siehe Abbildungen 1 und 2) beinhaltet die folgenden Sensoren:

1. Laserscanner,
2. Stereokamerasensor,
3. Lichtschnittsensor und
4. Textursensor.


Der **Laserscanner** [5] basiert auf dem Triangulationsprinzip. Aufgrund seiner kompakten Bauweise und seines geringen Gewichts eignet er sich als integrierter Kollisions-/Abstandssensor. Der Messbereich beträgt 50 mm bis 300 mm bei einem Öffnungswinkel von  $270^\circ$ .

Der **Stereosensor** setzt sich aus den zwei Videokameras zusammen. Diese haben einen Basisabstand von 110 mm beim handgeführten System in Abbildung 1 beziehungsweise 50 mm beim Robotersystem aus Abbildung 2. Der Messbereich beträgt 250 mm bis 2000 mm.


Als **Lichtschnittsensor** werden die obere Kamera und ein Linienlaserprojektor mit einem Öffnungswinkel von  $60^\circ$  verwendet. Der Messbereich liegt zwischen 150 mm und 500 mm. Die auf die Messoberfläche projizierte Laserlinie wird im Kamerabild ohne die Verwendung eines optischen Filters segmentiert. Nach Kalibration der Laserebene zur Kamera kann daraus die Tiefeninformation gewonnen werden (siehe hierzu [10]).

Als **Textursensor** wird die jeweils nicht beim Lichtschnitt eingesetzte Kamera verwendet.

Um die Sensoren zusammen mit dem Lagesensor betreiben zu können, müssen die Messzeitpunkte synchronisiert und die Messdaten zugeordnet werden können. Zusätzlich soll jeder Sensor räumlich auf einen Lagesensor kalibriert sein. In Abbildung 2 ist der 3D-Modellierer für den Roboterinsatz dargestellt. Dieses System dient zur Auswahl und zum Test der Sensorkomponenten, welche dann in ein System integriert werden, das sowohl handgeführt als auch roboterggeführt eingesetzt werden kann. Neben dem verkleinerten Basisabstand von 50 mm, welcher Stereoprozessierung im Nahbereich ab 250 mm ermöglicht, wurden digitale Kameras mit Firewireschnittstelle anstelle der analogen Kameras des Vorgängersystems verwendet.



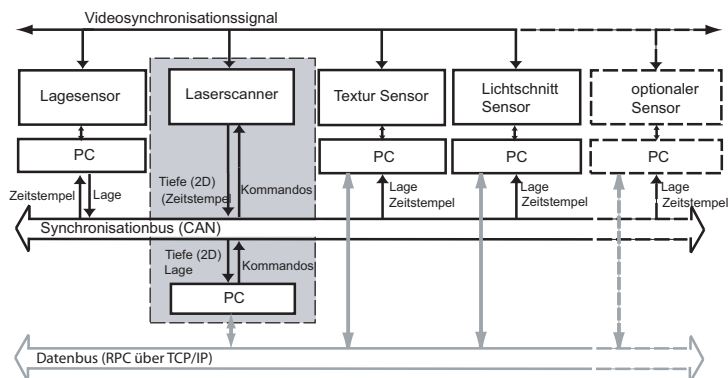
**Abb. 1.** Sensorkomponenten des handgeführten 3D-Modellierers: Laserscanner, Lichtschnittsensor, Textursensor, Stereosensor und externer Lagesensor.



**Abb. 2.** 3D-Modellierer für den Einsatz am Roboter, mit digitalen Firewire-Kameras.

## 2.1 Synchronisationskonzept

Bei der Entwicklung des Synchronisationskonzeptes wurde eine zweistufige Strategie gewählt, die in Abbildung 3 dargestellt ist:



**Abb. 3.** Synchronisationskonzept: Hardwareebene (Videotakt), Softwareebene (CAN-Bus), Sensordatenebene (RPC-Protokoll).

Zunächst ist eine *Hardware synchronisation* notwendig, die einen zeitsynchronen Messtakt in allen Sensoren vorgibt. Ein zeitlicher Drift der Sensoren gegeneinander wird so vermieden. Um dieses Ziel zu erreichen, werden alle Sensoren mit einem Composite Videotaktsignal versorgt, das in der Frequenz angepasst werden kann.

Des Weiteren müssen die Sensordaten synchronisiert werden. Hierfür wird auf den CAN-Bus als *Software Synchronisations Bus* zurückgegriffen. Auf die-

sem Bus werden Zeitstempel und Lagen ausgetauscht. Diese Nachrichten werden von den anderen, ebenfalls am CAN-Bus angeschlossenen Sensoren empfangen. Die Tiefen-/ Lagedatensätze werden mit dem Zeitstempel kodiert und zur Weiterverarbeitung und Übermittlung über eine RPC<sup>1</sup>-Schnittstelle (ebenfalls in Abbildung 3 dargestellt) über TCP/IP zur Verfügung gestellt werden. Über diese Schnittstelle werden die lokalen Sensordaten samt Kalibrierungs- und Lagemessdaten, ergänzt um einen Qualitätswert, übertragen, was die Datenfusion mehrerer Sensoren ermöglicht. Eine Transformation in 3D-Daten erfolgt auf Applikationsseite.

Alle Sensoren arbeiten synchron und in dem gleichen, über den Lagesensor vorgegebenen Koordinatensystem, welches die Fusion der Daten unterschiedlicher Sensoren in ein Modell ermöglicht. Eine detaillierte Abhandlung zum Konzept ist in [9] zu finden.

## 2.2 Räumliche Kalibrierung


Die unterschiedlichen Sensoren müssen nicht nur zeitsynchron messen, sondern die Daten auch im selben Koordinatensystem darstellen. Daher ist eine räumliche Kalibrierung notwendig. Der Lagesensor liefert als Datum die Lage des Endeffektors im Weltkoordinatensystem. Die Transformation vom Koordinatensystem, in dem z. B. die Daten des Entfernung-/ Farbsensors repräsentiert werden, in das Endeffektorsystem des Lagesensors muss über Kalibrierungsverfahren bestimmt werden.

Zur Kalibrierung der Kameras (Textursensor, Lichtschnittsensor) wird eine Software Suite benutzt, die in [3] detailliert dargestellt wird. Beim Lichtschnittverfahren muss zusätzlich die Relation zwischen Laser- und Kameraebene bestimmt werden. Die Kalibrierung wird in [10] ausführlich dargestellt.


Bei der Kalibrierung des Laserscanners genügt es, die extrinsischen Parameter zur ermitteln. Siehe hierzu [9]. Am Roboter sind zwei Lagemesssysteme vorhanden. Zum einen ist dies das optische Trackingsystem, zum anderen der Roboter an sich. An einer Lösung zur Bestimmung der Lage mittels der Kameras und Inertialsensoren wird gearbeitet. Die Möglichkeit, freigeführt und roboter-gestützt den 3D-Modellierer (siehe hierzu Abbildung 2) zu verwenden und gleichzeitig konsistente Lagedaten zu erhalten, erfordert einen weiteren Kalibrierungsschritt. Zunächst werden alle Sensoren im 3D-Modellierer auf das Trackingsystem kalibriert, dies ermöglicht den freigeführten Betrieb des Systems. Dann wird das Trackingsystem auf den Roboter kalibriert, in dem man ca. 10 unterschiedliche Roboterlagen zeitsynchron mit den Lagedaten des Trackingsystems aufzeichnet, und daraus die Transformationen vom 3D-Modellierer zum Endeffektorsystem und vom Weltkoordinatensystem des Roboters auf das Weltkoordinatensystem des optischen Trackingsystems bestimmt. Dies ist in Abbildung 6 dargestellt.

---

<sup>1</sup> Remote Procedure Call



**Abb. 4.** 3D-Modellierer: Kennlinie der Standardabweichung des Laserscanners LRS (strichpunktiert) und des Lichtschnittsensors LSP (gestrichelt).



**Abb. 5.** 3D-Modellierer für den Robotereinsatz: Kennlinie des optimierten Lichtschnittsensors LSP.

### 2.3 Statistische Sensormodelle

Es sind statistische Modelle (siehe hierzu [1]) für den Laserscanner und den Lichtschnittsensor ermittelt worden. Die Standardabweichungen, aufgetragen über die Messentfernung, sind in Abbildung 4 für den 3D-Modellierer und in Abbildung 5 für das optimierte Robotersystem dargestellt. Der Leser wird zu Details, auch in Bezug auf die Kalibrierung der Laserebene, auf [10] verwiesen. Die Kennlinie des Scanners wurde experimentell ermittelt, die des Lichtschnittsensors wurde über die Eigenschaften des Kameramoduls (Auflösung, Abbildungseigenschaften) und des Laserliniengenerators (Linienbreite) ermittelt (gestrichelte Kennlinie in Abbildung 4) und dann experimentell validiert (gepunktete Kennlinie). Man kann erkennen, dass sich die Standardabweichung durch Verbesserungen in der Kalibrierung der Kameras und Verwendung von Vollbildern anstelle von Halbbildern der digitalen Kameras, deutlich reduziert hat.

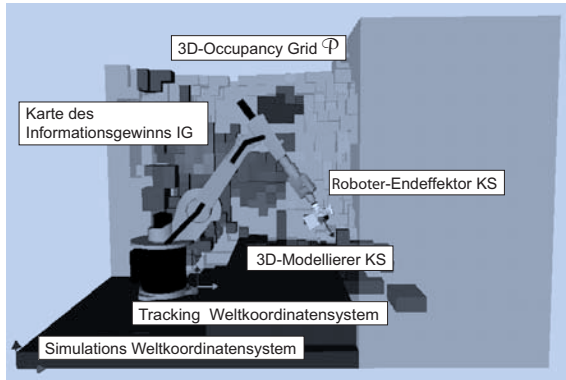
## 3 Multisensorielle Exploration

Erfahrungen, die mit dem multisensoriellen 3D-Modellierer im handgeführten Betrieb gesammelt wurden, werden nun auf einen robotergestützten Einsatz transferiert. In diesem Kontext ist neben der Synchronisation und Kalibrierung ein weiterer Aspekt wichtig, der im handgeführten Betrieb nicht betrachtet werden muß: Eine Kollisionsvermeidung wird bei der handgeführten Modellierung vom Benutzer durchgeführt, seine Bewegungsmöglichkeiten im Arbeitsraum sind vollständig bekannt. Ein Roboter hingegen muss sich dieses Wissen erst aufbauen.


### 3.1 Problemstellung

Die Roboterumgebung, der sogenannte Arbeitsraum  $\mathcal{P}$ , ist zunächst unbekannt. Bei der Modellierung mittels Roboter muß sich dieser zuerst Wissen über sei-





**Abb. 6.** Koordinatensysteme beim Einsatz des 3D-Modellierers am Roboter. Das Umgebungsmodell ist ein 3D-Occupancy-Grid in Voxeldarstellung, die Voxel mit höchsten IG sind dunkel dargestellt.



**Abb. 7.** Ein zweiachsiger Roboter untersucht ausgehend von bekannten Konfigurationen in  $\mathcal{P}_{\text{frei}}$  die unbekannt Konfigurationen (gestrichelt dargestellt).

ne Bewegungsmöglichkeiten (Kollisionsfreiheit, Erreichbarkeit) erwerben. Dieses wird in unserem Ansatz im Konfigurationsraum ( $\mathcal{K}$ -Raum) des Roboters formuliert. Der Konfigurationsraum hat die Dimension  $\mathbb{R}^n$ , wobei  $n$  die Anzahl der Freiheitsgrade des Roboters ist. Er wird daher auch als Gelenkraum bezeichnet. Im Gegensatz dazu steht der dreidimensionale Arbeitsraum (Orientierungen spielen hier keine Rolle), in dem sich die zu inspizierenden Objekte befinden.

### 3.2 $\mathcal{K}$ -Raum Entropie

Zunächst muss ein Kriterium gefunden werden, auf dessen Basis man potentielle Sensorlagen bewertet. Ziel ist, möglichst viel Wissen über den Konfigurationsraum des Roboters zu sammeln. Der Ansatz wird im Konfigurationsraum formuliert, welcher jedoch wegen seiner Dimension (Beispiel: Für einen Roboter mit 6 Achsen und einer Winkelauflösung von nur  $1^\circ$  enthält der diskretisierte  $\mathcal{K}$ -Raum  $360^6$  Elemente) nicht explizit gespeichert wird. Die Roboterkinematik bildet  $\mathcal{K} \in \mathbb{R}^n$  eindeutig auf  $\mathcal{P} \in \mathbb{R}^3$  ab. Zusammen mit den Geometriedaten des Roboters ist damit die Abbildung zwischen Konfigurationsraum und Arbeitsraum beschrieben, und das Problem lässt sich eindeutig im Konfigurationsraum darstellen.

Um das Ergebnis einer Messung zu bewerten, müssen Annahmen über die Hindernisverteilung gemacht werden. Unser Ansatz verwendet das Poisson-Punkt-Modell (ein Markov-Prozess 0-ter Ordnung, siehe hierzu [2]), welches punktförmige Hindernisse, gleichmässig im Arbeitsraum verteilt, annimmt.

Das prinzipielle Vorgehen wird anhand von Abbildung 7 erläutert. Initial befindet sich der Roboter (hier ein planarer Manipulator mit zwei FhG ( $q_1$ ,  $q_2$ ) sowie einem Sensorfreiheitsgrad  $q_S$  zur Ausrichtung des Sensors) im freien Arbeitsraum  $\mathcal{P}_{\text{frei}}$ . Das physikalische Volumen des Roboters in  $\mathcal{P}$  wird mit  $\mathcal{A}$  bezeichnet. Um das Wissen über den  $\mathcal{K}$ -Raum effizient zu erweitern, wird

der Roboter *virtuell* in unbekannte Konfigurationen, d.h. in  $\mathcal{P}_u$  bewegt (siehe gestrichelte Darstellung des Roboters in Abbildung 7). Unter Verwendung des Volumens des Roboters im Unbekannten, mit  $\mathcal{A}_u$  bezeichnet, lässt sich unter dem Poisson-Punkt-Modell (siehe Abbildung 7) ein Maß für die Wahrscheinlichkeit einer Kollision angeben. Da ein Hand-Auge-System mit limitiertem Sichtfeld  $V_S$  verwendet wird, liefert nur der Bereich, in dem sich  $\mathcal{A}_u$  mit dem Sensorsichtfeld schneidet ( $\mathcal{A}_u \cap V$ ), einen Beitrag. Aus bereits bekannten, erreichbaren Konfigurationen, die in einem Graphen (Roadmap) abgespeichert sind, wird der Schnitt zwischen dem Sensorsichtfeld in dieser Konfiguration und dem Volumen des Roboters in den unbekannt Konfigurationen gebildet. Der Ansatz basiert auf Shannons Entropie:

$$H(I) = - \sum_{j=1}^n p_j \log(p_j) .$$

$H(I)$  wird als Entropie (Informationsgehalt) einer Information  $I$  bezeichnet,  $p_j$  beschreibt die Wahrscheinlichkeit der Ereignisse, aus denen sich  $I$  zusammensetzt. Die  **$\mathcal{K}$ -Raum Entropie** wird wie folgt gebildet:

$$H(\mathcal{K}) = - \sum_{Q_1=0,1} \dots \sum_{Q_k=0,1} Pr[Q_1, \dots, Q_k] \log Pr[Q_1, \dots, Q_k] .$$

$Q_i$  stellt die Zufallsvariable dar, die zu einer Konfiguration  $q_i$  gehört und entweder frei (=0) oder in Kollision (=1) ist.  $k$  ist die Zahl der Roboterkonfigurationen,  $Pr[\ ]$  beschreibt die Wahrscheinlichkeit des zugehörigen Ereignisses. Man kann, nachdem man die Region  $V_S \in \mathcal{P}$  (Hindernis/Frei) gemessen hat, mit diesem Formalismus den erwarteten Informationsgewinn (IG) (oder auch die Reduzierung der Entropie)  $\Delta H(\mathcal{K})$  angeben. Die Entropie reduziert sich maximal (zu Null) für eine Konfiguration, wenn im Sichtfeld ein Hindernis ist, da dann die Konfiguration nicht erreichbar ist. Wird das Sensorsichtfeld als frei gemessen, reduziert sich die Entropie, je nachdem wie groß  $\mathcal{A}_u \cap V_S$  ist. Summiert über alle bekannten und unbekannt Konfigurationen, hängt es nur noch vom gewählten Sensormodell ab, welche Sensorlage die Unwissenheit oder auch Entropie des Konfigurationsraumes am stärksten reduziert. Dieses Kriterium wird auch als *MER*-Kriterium (Maximum Entropy Reduction) [7] bezeichnet. In Abbildung 6 ist die Karte der Informationsgewinns zusammen mit dem Arbeitsraum dargestellt. Helle Bereiche stellen einen hohen IG dar. Konfigurationen, von denen aus diese Bereiche messbar sind, werden hoch bewertet. Die Modellierung des Sensor ist daher für die Berechnung der Entropie entscheidend.

### 3.3 Sensormodell

Sollen mehrere Sensoren verwendet werden, müssen die Ergebnisse auf Basis der Sensoreigenschaften verglichen werden. In dem MER-Ansatz [7] wird von idealen Sensoren, die sich nur über ihren Messbereich unterscheiden, ausgegangen. Es wurden bislang Punktsensor-Modelle (nur ein Punkt im Sensorsichtfeld wird untersucht) und, aufbauend darauf, Strahlsensor-Modelle (Untersuchung entlang


des Sensorsichtlinie unter Berücksichtigung von Verdeckung) implementiert und validiert. Die Auflösung und Genauigkeit des Sensors bleibt unberücksichtigt.

Jeder reale Sensor unterscheidet sich jedoch in seinem Rauschverhalten (siehe Abbildung 4 und Abbildung 5). Dies führt dazu, daß Hindernisse nicht oder nur unscharf lokalisiert werden können. Über die Einführung eines Sicherheitsabstandes zu potentiellen Hindernissen wurde bislang versucht, diesen Nachteil auszugleichen. Modelliert man das Sensorrauschen jedoch bereits in der Planungsphase, kann man deutlich realistischere Ergebnisse erreichen. Ausserdem ist es so möglich, mehrere Sensorverfahren, wie sie im 3D-Modellierer integriert sind, für die  $\mathcal{K}$ -Raum Exploration einzusetzen. In der Planung wird die Sensorlage nicht nur auf Basis der maximalen Sensorreichweite, sondern auch aufgrund der Fähigkeit, vorhandene Hindernisse in der richtigen Distanz detektieren zu können, ausgewählt. Die Wahrscheinlichkeit für ein Hindernis läuft von 0 (frei) kontinuierlich auf 1 (Hindernis). In unserem Ansatz wird der Sensor ohne die Berücksichtigung von spiegelnden Reflektionen mit gausschem Rauschen modelliert, der Erwartungswert beschreibt die wahre Position des Hindernisses. Die Auswertung der Simulationen in einem 2D Arbeitsraum mit zwei Roboter-Achsen [11] hat gezeigt, dass die ausgewählten Sensorlagen ein Kompromiss zwischen Erreichbarkeit und Messgenauigkeit sind.


## 4 Experimente

In diesem Abschnitt werden Simulationen mit einem für den Roboter-einsatz weiterentwickelten 3D-Modellierer präsentiert. Dazu wurde eine Simulationsumgebung entwickelt, die auch für die angestrebte *Inspektion* geeignet ist, und Experimente am realen System ermöglicht. In Abbildung 8 sind die zu Beginn bekannten, freien Bereiche im Arbeitsraum dargestellt, bekannte Hindernisse sind schwarz eingezeichnet, die grauen Bereiche sind unbekannt. Die Szene, die sich im Unbekannten verbirgt, ist in Abbildung 9 dargestellt. Der Arbeitsraum  $\mathcal{P}$  ist in Voxel diskretisiert, die Auflösung kann variabel gestaltet werden. Es ist möglich, Sensorlagen zu planen, die so genannten *Next Best Views (NBV)*. Der Lichtschnittsensor und der Laserscanner wurden implementiert, ebenso die dazugehörigen Sensorkennlinien. Die Roadmap der Konfigurationen ist spärlich (wenige Knoten decken einen grossen  $\mathcal{K}$ -Raum ab), die einzelnen Knoten (Konfigurationen) werden nach Sichtbarkeit, d.h. Abstand zu vorhandenen Knoten, in die Roadmap eingefügt. Abbildung 10 zeigt Ergebnisse mit dem Lichtschnittsensor, dargestellt ist  $\mathcal{P}$  nach 401 Iterationen der Szene aus Abbildung 9 mit einer Dimension  $3000\text{mm} \times 2000\text{mm} \times 2000\text{mm}$  und einer Auflösung von  $100\text{mm}$ . Zu beachten ist, dass nicht in jeder Iteration eine geeignete Sensorlage gefunden werden konnte. Weiterhin ist anzumerken, dass pro Roboterlage die letzte Achse des Roboters um  $180^\circ$  gedreht wird, um ein kegelförmiges Volumen aufzuspannen. In der  $\mathcal{P}$ -Raum Auflösung von  $100\text{mm}$  ergibt das 11 Scans pro Roboterlage. Es können folgende Verfahren verglichen werden:


1. **Strahlmodell:** Idealer Sensor mit Verdeckung, Summierung der Entropie entlang der Sichtlinie;



**Abb. 8.** Arbeitsraum mit unbekanntem Bereichen.



**Abb. 9.** Arbeitsraum mit Hindernissen.



**Abb. 10.** Arbeitsraum nach 401 Iterationen mit dem Lichtschnittsensor.

2. **Strahlmodell mit modelliertem Rauschen:** Verdeckung und Standardabweichung sind modelliert;
3. **Strahlmodell mit Sicherheitsabstand:** Analog zu 1., jedoch werden alle  $\mathcal{P}$ -Voxel mit einem virtuellem Sicherheitsabstand von 10 mm versehen;
4. **Maximales  $\mathcal{P}$ -Volumen:** Es wird versucht, das Volumen von  $\mathcal{P}_u$  zu minimieren.

In Abbildung 10 ist zu erkennen, dass auch bei der Exploration des  $\mathcal{K}$ -Raum ebenfalls viel Wissen über den  $\mathcal{P}$ -Raum erlangt wird. Das erkundete Volumen des Strahlmodells mit modelliertem Rauschen ist deutlich grösser als unter Berücksichtigung des Sicherheitsabstands. Eine ausführlichere Auswertung der Verfahren ist in [13] dargestellt

## 5 Zusammenfassung und Ausblick

Der in diesem Artikel vorgestellte 3D-Modellierer implementiert alle notwendigen Prinzipien zur Erzeugung von fotorealistischen Modellen. Es wurden die Sensorprinzipien und die Hardwareimplementierung vorgestellt, die eine handgeführte Erstellung texturierter Modelle ermöglicht. Wird die Modellierungsaufgabe auf ein Robotersystem übertragen, ist der erste Schritt die Erfassung des Bewegungsspielraums des Roboters mit Hilfe des am Endeffektor montierten multisensoriellen Modellierers. Die Simulationen zeigen, daß der *MER*-Ansatz, erweitert um reale Sensormodelle, ein effektiver Ansatz ist, um die Beweglichkeit des Roboters auch nahe an Hindernissen sicherzustellen. Einzelheiten sind in [11] und [13] nachzulesen. Der 3D-Modellierer wurde für den Robotereinsatz angepasst und die Simulationsumgebung um die Roboteransteuerung erweitert. Die Integration der Komponenten von Abbildung 2 wird durchgeführt. Die Sensordaten von unterschiedlichen Tiefensensoren sollen in ein geometrisches 3D-Modell fusioniert werden. Dazu wurde das RPC-Interface in Abbildung 3 erweitert, um Qualitätswerte, lokale Sensorwerte sowie die gemessenen Raumlagen übermitteln zu können. Um eine multisensorielle Modellierungsaufgabe (**Inspektion**) mit

dem Roboter durchführen zu können, müssen jedoch weitere Teilaspekte bearbeitet werden. Es muss ein Verfahren zur Abtastung der Oberfläche des zu modellierenden Objekts entwickelt werden. Es wird davon ausgegangen, dass kein CAD Modell des Objekts vorhanden ist, und daher allein auf Basis der schon erfassten Oberfläche die weiteren Messungen geplant werden. Das 3D-Voxelmodell der Umgebung, was während der Exploration aufgebaut wird, kann hierzu herangezogen werden. Dieses Vorgehen ist analog zum dem Explorationsansatz *Maximales P-Volumen*. So muss nur ein Umweltmodell erzeugt werden. Die Objektmodelle können dann schritthaltend und in hoher Auflösung mit dem Algorithmus aus [12] erstellt werden.

## Literatur

1. M. Abidi und R. Gonzalez. *Data Fusion in Robotics and Machine Intelligence*. Academic Press, 1992.
2. D. Stoyan und W. S. Kendall. *Stochastic Geometry and its Applications*. J. Wiley, 1995.
3. P. Wunsch, G. Koegel, K. Arbter und G. Hirzinger. *Kalibrierung eines nichtlinearen, binokularen Hand-Auge Systems*. Tech. Report IB-515-96-27, Institute of Robotics and System Dynamics, German Aerospace Center, 1996.
4. R. Fisher, A. Fitzgibbon, A. Gionis, M. Wright und D. Eggert. A hand-held optical surface scanner for environmental modeling and virtual reality. In: *Proc. Virtual Reality World*, pp. 13–15, Stuttgart, 1996.
5. F. Hacker, J. Dietrich und G. Hirzinger. A laser-triangulation based miniaturized 2-D range-scanner as integral part of a multisensory robot-gripper. In: *Proc. EOS Topical Meeting on Optoelectronic Distance/Displacement Measurements and Applications*, Nantes, 1997.
6. A. Hilton und J. Illingworth. Geometric fusion for a hand-held 3D sensor. In: *Machine Vision and Applications*, pp. 44–51, Springer-Verlag, 2000.
7. Y. Yu und K. Gupta. An information theoretic approach to viewpoint planning for motion planning of eye-in-hand systems. In: *Proc. 31st International Symposium on Industrial Robotics (ISR)*, Montreal, 2000.
8. W. Scott, G. Roth und J. West. View planning for automated three-dimensional object reconstruction and inspection. *ACM Computing Surveys*, 35(1):64–96, 2003.
9. M. Suppa und G. Hirzinger. A novel system approach to multisensory data acquisition. In: *Proc. 8th Conference on Intelligent Autonomous Systems IAS-8*, Amsterdam, 2004.
10. K. Strobl, E. Wahl, W. Sepp, T. Bodenmüller, M. Suppa und G. Hirzinger. The DLR hand-guided device: The laser-stripe profiler. In: *Proc. Int. Conference on Robotics and Automation ICRA 2004*, New Orleans, 2004.
11. M. Suppa, P. Wang, K. Gupta und G. Hirzinger. C-space exploration using sensor noise models. In: *Proc. Int. Conference on Robotics and Automation ICRA 2004*, New Orleans, 2004.
12. T. Bodenmüller und G. Hirzinger. Online surface reconstruction from unorganized 3D-points for the DLR hand-guided scanner system. In: *Proc. 2nd Symposium on 3D Data Processing, Visualization, Transmission*, Thessaloniki, 2004.
13. M. Suppa und G. Hirzinger. Ein Hand-Auge-System zur multisensoriellen Rekonstruktion von 3D-Modellen in der Robotik. In: *Automatisierungstechnik*, 53(7):323–331, 2005.



# Pilot assistance for approach and landing

Bernd Korn

DLR, Institute of Flight Guidance, Lilienthalplatz 7, D-38108 Braunschweig

**Zusammenfassung.** To increase safety and economy of aviation DLR is developing pilot assistance systems covering all flight phases “gate to gate.” The Pilot assistant system is an integrated system which combines all required assistance functions under a single human machine interface. Within several programs an overall concept including a very specific system architecture was developed in order to provide pilot assistance during all phases of flight from “gate-to-gate.” In this architecture the assistant functions are implemented in function modules grouped around a core system consisting of a central data pool and a module manager. For several tasks of flight guidance, a number of highly specialized modules is being developed and tested in national and international research programs. This contribution will briefly discuss two main subsystems—the Advanced Flight Management System AFMS and the Taxi guidance system TARMAC-AS and then focus on the Enhanced Vision System which supports the crew especially under low visibility conditions in flight phases close to the ground like the approach and landing phase. Within the enhanced vision system (EVS), information coming from weather independent sensors is combined with knowledge provided by terrain databases via data fusion technology. The so derived full picture of the aircraft’s external situation is presented to the aircrew using either head up or head mounted displays.

## 1 Introduction

Addressing aviation safety, recent statistics have shown, that a major part of accidents was caused by a chain of reasons, where the human operator was involved in some sense. Looking more into the details, it can be seen, that the “computerization” of the cockpit, which began in the late 70s, brought lots of highly specialized, but isolated systems for individual tasks into the cockpit. The heterogeneous design and the number of separated subsystems increased the workload of the aircrew.

Again, upcoming new Air Traffic Management (ATM) concepts will bring new tasks like separation assurance or co-operative flight planning into the cockpit. Traditionally, new separate systems would have to be designed and built to handle these tasks. This approach is however reaching its limits, as the situation awareness of the pilots is hindered by having to collect the required information

from a number of devices with inconsistent display formats. Inputs into the system are also becoming more and more difficult, as the individual systems tend to have independently developed and poorly integrated user interfaces.

Analyzing the available statistics on incidents and accidents more detailed information regarding potential causes can be found [4]. It appears that the numbers of accidents within phases close to the ground and within dense traffic are significantly higher compared to the time of flight spent in these phases than others. 82% of all accidents happen between initial approach and initial climb (referencing an en-route - ground -enroute perspective of flight), which take 17% of the time of a typical 1.5 hours flight. One major reason for this can be found in a possible lack of situation awareness regarding terrain and other traffic due to an overload of the air crew caused by conventional automation at flight phases with a highly dynamic flow of information between the air transport system, the aircraft and the air crew.

Therefore DLR's Institute of Flight Guidance is looking deeper into the design and development of so-called "pilot assistance systems" since many years, where all required assistance functions are combined by an integrated human machine interface. Within several programs an overall concept including a very specific system architecture was developed in order to provide pilot assistance during all phases of flight from "gate-to-gate." In this architecture the assistant functions are implemented in function modules grouped around a core system consisting of a central data pool and a module manager. For several tasks of flight guidance, a number of highly specialized modules is being developed and tested in national and international research programs.

Besides the presentation of the core architectures 3 subsystems will be introduced in more detail: the Advanced Flight Management System to support the crew during the enroute flight phases and complex approach procedures, a taxi guidance module for ground operations, and an Enhanced Vision System to for landing operations and ground movements under low visibility conditions.

## 2 Pilot Assistance Gate-To-Gate

### 2.1 Concept

In order to fulfill a given mission an aircrew has to solve a large number of usually quite complex tasks of flight guidance. In a simplified scheme as shown in Figure 1 these tasks can be regarded as a guidance loop the pilot has to run through continuously. The major elements of this loop are

- situation assessment,
- plan generation according to the present state and the given mission,
- decision which plan to follow,
- execution of the plan, and finally
- monitoring if the flight is following the selected plan.



In order to assist aircrews performing this loop, a concept for an “electronic co-pilot,” a so-called Intelligent Pilot Assistant (IPA) has been developed. As depicted in Figure 1 this IPA performs exactly the same loop as the pilot except the task of decision making. In commercial aviation and many military applications this step still has to remain within the authority of the aircrew. Nevertheless the concept can provide complete autonomous operation modes, as they might be required for future single piloted cockpits or unmanned aerial vehicles [3].

The IPA concept enables two significant capabilities:

First, the IPA is able to assess the situation and to generate valid plans autonomously. Especially during critical flight phases with high workloads this capability is most essential. As an example conventional, Flight Management System (FMS)-based flight guidance suffers from the volume and complexity of data to be entered into the management unit. The crew first has to assess the situation by reading several, independently operating systems and by communicating via voice with Air Traffic Control (ATC). Then the pilot has to go through a planning procedure and then has to enter the plan into the FMS by typing sequences of commands and parameters. Performing tasks requiring quick reaction like modifications of the flight plan during approach and landing the crew very often dispenses with FMS and performs the necessary maneuvers manually.

In this case the IPA’s situation assessment and planning functions could assist the crew substantially. By means of sensors, databases, internal state data and data brought on-board via datalink the assistance system continuously is able to assess and interpret the situation. Via datalink or via voice control the IPA can get the instruction to change the flight plan. A valid plan can be computed and offered to the pilot automatically. The pilot just has to accept and activate the IPA’s proposal or to reject and ask for alternative plans.

The second important feature is the common human machine interface for all functions in the cockpit. A homogenous concept of communication between pilot and assistance systems ensures, that the pilot is able to obtain just the information he needs regarding a specific situation. The way, information is presented to the pilot either by passive displays, interactive displays or acoustic or tactile communication is harmonized and optimized regarding the needs of the human operator.

The benefits of such systems have been demonstrated with the “Cockpit Assistant SYstem” (CASSY) [12]. for civil flights under instrument flight rules developed by the University of the German Armed Forces and tested on DLR’s Advanced Technology Testing Aircraft System (ATTAS) as well as the successor system “Crew Assistant for Military Aircraft” CAMA. CAMA was a joint development of several German industrial partners in cooperation with the University of the German Armed Forces. This system has received excellent ratings from military test pilots in two simulator campaigns and was flight tested in DLR’s ATTAS aircraft.

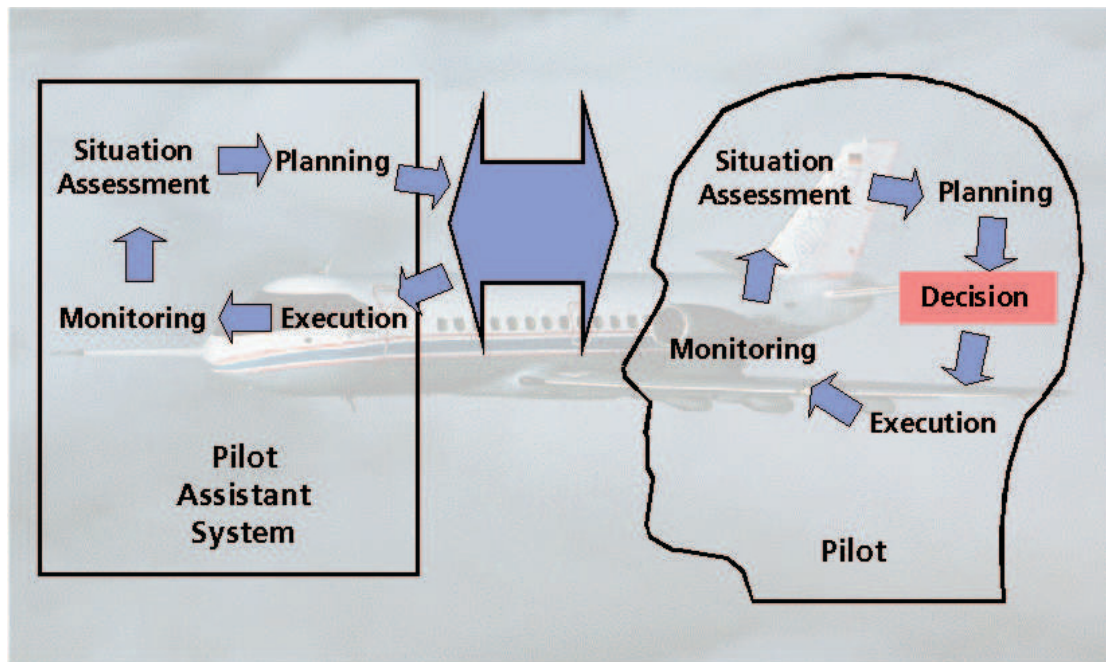


Abb. 1. Pilot Assistant.

## 2.2 Architecture

A generic architecture for intelligent pilot assistance has been developed at DLR's Institute of Flight Guidance (see Figure 3) [7,9]. Within this architecture assistant functions are implemented as modules grouped around a core system consisting of a central data pool and a module manager. This data pool contains all relevant data available on board. Therefore every module connected to the pool is able to access any necessary data via the module manager.

Sophisticated data handling methods are implemented in this architecture to allow modules to be notified whenever relevant data have changed. This architecture allows sequences of actions performed by the system to be modeled entirely by specifying which input data are required for certain functions. Changes in these data will then trigger the corresponding functions. This mechanism is used to achieve the situation assessment and automatic response to critical situations.

The architecture is very flexible and easily extendible. Because of its generic character it easily can be used as core for any kind of assistance system. Predefined templates allow a rapid design of new modules and functions. In addition already existing systems like the Traffic Alert and Collision Avoidance System (TCAS) or the Automatic Flight Control System (AFCS) for the domain of flight guidance can be integrated as well.

Based on this generic architecture a pilot assistance system aiding the pilot during all phases of flight including taxiing. The so-called IPA "Gate to Gate" consists of the already described generic core system containing the data pool and the data management unit. In addition a number of specialized modules

for the involved guidance tasks have been developed. The most important ones are the Advanced Flight Management System to support the crew during the enroute flight phases and complex approach procedures, a taxi guidance module for ground operations, and an Enhanced Vision System to for landing operations and ground movements under low visibility conditions.

### 3 The Advanced Flight Management System (AFMS)

The strategic trajectory generation as well as the automatic guidance along this trajectory according to schedule is the domain of the Flight Management System (FMS). As today's FMS suffer from the poor or not existing interfacing with the aircrew and ATC an Advanced Flight Management System (AFMS) is being developed based on the Experimental FMS developed within the Programme for Harmonized Air traffic management Research in Eurocontrol (PHARE) [1,2]. The conventional Flight Management functionality is extended by co-operative elements, which connect traffic planning modules on the ground to flight planning systems on board the aircraft via data link.

The main features of the AFMS are:

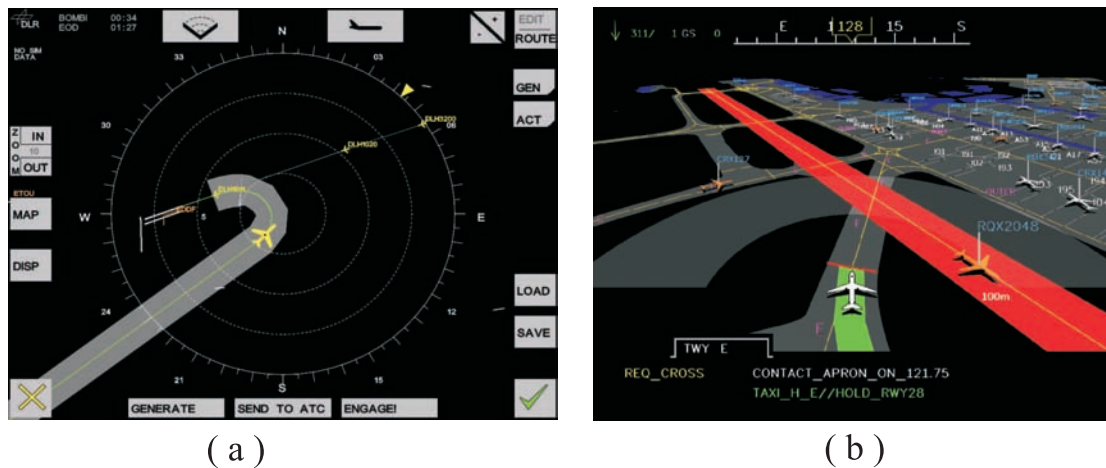
- Computation of 4D trajectories on board considering
  - constraints received via data link from ATC,
  - aircraft performance parameters,
  - economical criteria, etc.
- negotiation of the flight plan with ATC/ATM by means of data link connection, and
- 4D guidance capabilities along the negotiated trajectory.
- FLS approaches including noise abatement approach procedures like Low Power Low Drag or Continuous Descent Approaches

The benefits of this new Flight Management System regarding capacity and safety were validated and demonstrated successfully during intense flight testing on board DLR's Advanced Technology Testing Aircraft System ATTAS.

#### 3.1 Airborne Human Machine Interface

In order to harmonize the human machine interfaces on the flight deck the Airborne Human Machine Interface (AHMI) was developed. The Navigation Display (ND) as essential display of today's cockpits is extended to an "Interactive ND," which now allows the interaction with future flight management systems like the AFMS through the introduction of a touch pad at the arm rest of the pilot. Furthermore, the tactical planning is being transferred to this "Interactive ND," which can be operated through two separate display modes:

- The PLAN mode supports flight planning and enables the pilot to initialize and edit the con-straint list representing the basis for any 4D prediction.



**Abb. 2.** Navigation Display as interface (a) to the AFMS during a continuous descent approach (CDA) and (b) to the TARMAC-AS during taxiing.

- The MONITOR mode supports the pilot monitoring the flight progress with respect to the active 4D trajectory and the contract between aircraft and ATC.

The AHMI already was validated within various simulations and flight tests and was highly recommended by the majority of the evaluation pilots.

## 4 Taxi And Ramp Management And Control (TARMAC)

In 1997 the DLR Institute of Flight Guidance started its A-SMGCS (Advanced Surface Management Guidance and Control System) project named TARMAC (Taxi And Ramp Management And Control) in cooperation with other institutions. This project focuses on systems for all ground based and on-board aspects of an Advanced Surface Management Guidance and Control System:

- A planning system TARMAC-PL (Planning and Controller Machine Interface) for coordinated, efficient and conflict free ground movements from touch-down to on-block and from off-block to take-off,
- an integrated multi-sensor and communication system TARMAC-CS (Communication and Surveillance) for continuous automatic detection, identification and monitoring of the traffic situation at the airport, and
- the cockpit assistance and guidance system TARMAC-AS (Airborne System) for navigation and improved control of the aircraft on the ground.

### 4.1 TARMAC-AS

The cockpit system TARMAC-AS [11] is a major component of DLR's overall solution for future A-SMGCS systems. It provides weather-independent, safe, and efficient navigation even on large airports and under bad weather conditions. It

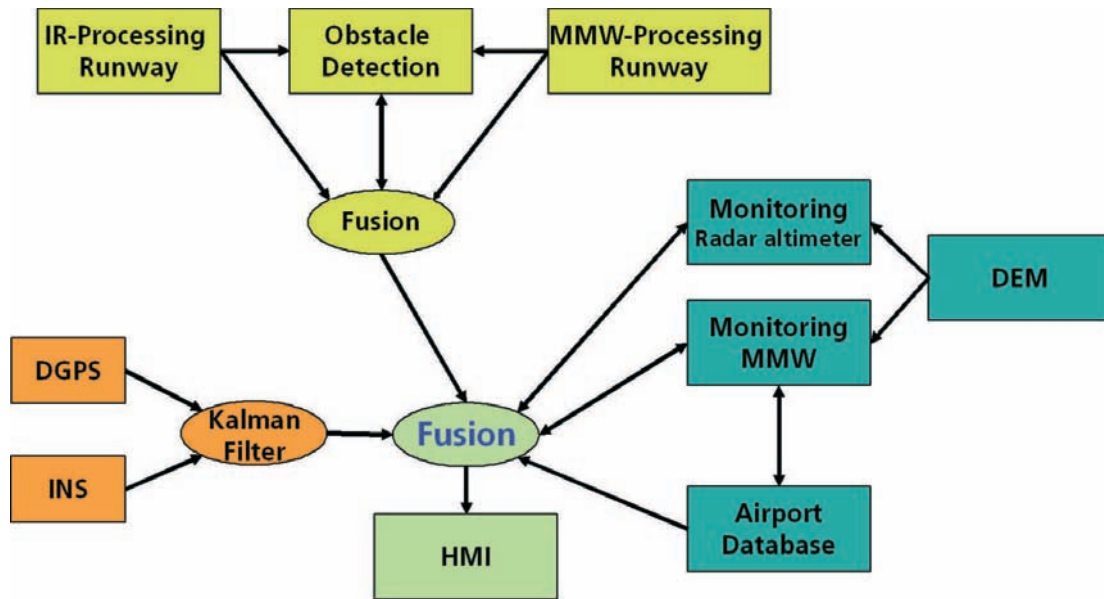
combines an on-board stored airport map with a graphical display of air traffic control advisories. Again, all information is graphically displayed on the Navigation Display (ND) which today's cockpit systems do not use after touch down. The main component of TARMAC-AS is the situation assessment and analysis module which, based on the acquired data, analyses the current situation and generates an action plan. Based on this situation analysis, TARMAC-AS displays the relevant information on the navigation display. Furthermore, TARMAC-AS continuously compares the action plan with the pilot's actions. If a deviation occurs, TARMAC-AS provides an appropriate warning. The system offers the following functions:

- airport is depicted including runways, taxiways, parking positions and buildings,
- cleared taxi route is displayed as text and a green “follow-me” line,
- state of runway occupancy and state of other aircraft are signaled by different colors,
- warnings are displayed in case of runway incursions, deviations from the cleared taxi route, and conflicts with other traffic participants.

## 5 Enhanced Vision System (EVS)

Enhanced Vision Systems (EVS) are aiming to alleviate restrictions in airspace and airport capacity in low-visibility conditions. EVS relies on weather-penetrating forward-looking sensors that augment the naturally existing visual cues in the environment and provide a real-time image of prominent topographical objects that may be identified by the pilot. The basic idea behind the technology is to allow VMC operations under IMC. The recently released (in spring 2004) final rule [6] of the FAA for Enhanced Flight Vision Systems (EFVS) for part 92 aircraft (business aircraft, general aviation aircraft) clearly acknowledges the operational benefits of such a technology by stating the following: “Use of an EFVS with a HUD may improve the level of safety by improving position awareness, providing visual cues to maintain a stabilized approach, and minimizing missed approach situations,” Moreover, “The pilot would use this enhanced flight visibility . . . to continue the approach from DH or MDA down to 100 ft above the touchdown zone elevation of the runway of intended landing.” This rule change marks a significant token of confidence towards EVS technology and clearly demonstrates that EVS offers the capability to decrease landing minima and thus, increase accessibility of airports (even of non-equipped airports) under low visibility conditions. One major advantage of EVS is that it can be easily used in combination with other landing aids like e.g. SBAS (Space Based Augmentation System). Allowing the pilot to “see” under low visibility conditions, EVS increases safety and offers the possibility to increase accessibility and capacity by reducing landing minima or even by reducing separation distances.

It easily can be seen that the performance of the Enhanced Vision System is strongly depending on the selection of imaging sensors. At Decision Height (DH)




**Abb. 3.** Structure of the EVS based landing system.

or Minimum Descend Altitude (MDA) of the flown approach procedure the pilot has to use EVS as primary input to continue the approach down to 100ft after which visual contact to the runway has to be established. Infra-red (IR) and millimeter-wave (MMW) sensors are currently envisaged as EVS support of pilot vision in low visibility. One important benefit of IR-sensors is that these sensors generate a perspective image, from which the human operator can derive the perceptual cues of depth to generate a three-dimensional interpretation of the outside world. This is an important feature of the IR-sensor because a perspective sensor image can be overlaid to the outside scene on a head-up display (HUD). However, the penetration of bad weather in the infrared spectrum is remarkably poorer than the weather penetration that can be achieved by MMW radar. An active MMW radar delivers primarily information about the range and the angular direction (azimuth) of a certain object. This range/angle information can be transformed into a view “out-of-the-window,” but there is still a lack of information about the objects’ height and/or their vertical position. The presentation of such images needs knowledge about the surrounding elevation, which often is estimated by the so-called “flat-earth-assumption.” An important topic for integrating new visual sensors into existing cockpit environments concerns the question on how to visualize the acquired images and/or visual cues. An obvious method for showing this information is a simple overlay onto the head-up-display (HUD). Due to its simplicity this method has been applied in several projects in the past.

### 5.1 The Project ADVISE-PRO

Within the research project ADVISE-PRO (Advanced visual system for situation awareness enhancement – prototype, 2003–2006), DLR has combined elements of



**Abb. 4.** HMD display with “Highway in the Sky” and runway symbol. To “de-clutter” the display and to facilitate the detection of e.g. runway incursions in the outside vision, the display of the terrain around the runway is suppressed.

Enhanced Vision and Synthetic Vision to one integrated system to allow all low visibility operations independently from the infrastructure on ground. The core element of this system is the adequate fusion of all information that is available on-board [5, 10]. In principle, high precision on-board navigation data in combination with an accurate airport database is sufficient to enable the pilot to land the aircraft (Synthetic Vision System). But under low visibility conditions, the pilot cannot verify whether these information is correct, or if there are errors in either the navigation data or in the airport database. Up to now, sufficient integrity neither of available airport databases nor of on-board navigation (combination of DGPS with INS) can be guaranteed. Therefore, without additional means to verify the correctness of such information, approach and landing cannot be performed under such circumstances. In the ADVISE-PRO system, the necessary verification of navigation and airport database (integrity monitoring) is obtained by the additional use of weather penetrating imaging sensors, especially by a MMW radar sensor and a long wave infrared camera. Significant structures, e.g. like the runway itself, are extracted from the sensor data (automatically by means of “machine vision”) and checked whether they match with the navigation data in combination with database information. Furthermore, the sensor images

are analysed to detect obstacles on the runway. Aircraft that are equipped with such a system can perform board-autonomous all-weather approach and landing, only on those airports of which accurate airport databases are available. Thus, one part of ADVISE-PRO was the development of a subsystem that calculates the position of the aircraft relative to the runway threshold based on the analysis of the sensor data only (sensor based navigation). The key modules of the ADVISE-PRO system are:

1. Integrity monitoring of navigation data and terrain data:  
Verification of on-board navigation data ((D)GPS + INS) with sensor data (MMW radar, IR sensor, Radar altimeter) and airport/terrain databases.
2. Sensor based navigation:  
Determination of the aircraft's position relative to the runway by analysing sensor data automatically (MMW, IR, radar altimeter) without using neither (D)GPS nor precise knowledge about the airport geometry.
3. Obstacle detection  
Detection of obstacles on the runway.
4. Consistent description of situation:  
Coordination, evaluation and fusion of the information processing systems (pos 1,2,3) to a consistent and reliable description of the situation to be displayed to the pilot.

The structure of the ADVISE-PRO landing system is depicted in Figure 3. The core part of the system is the fusion of different kinds of information (different due to source, content and reliability). For example the fusion of potential runway structures, which have been extracted from different sensor images (IR or MMW) must be combined to runway hypotheses to enable the determination of the aircraft's position relative to the runway. Further on, such information has to be combined with information from other sources like from GPS, INS, terrain data or from the radar altimeter. All these information result from the automatic analysis of sensor data. Therefore, every piece of information is attached with some uncertainty which can vary from "completely wrong" up to "highly precise." Consequently, the fusion process has to cope with ambiguous, incomplete or even with contradictory information to derive a consistent description of the current situation.

Another important part of the project ADVISE-PRO is the investigation of an adequate HMI for an EVS-based landing system. The objective is to elaborate which kind of information has to be displayed when, how, and on which kind of display to the pilot so that he is able to perform approach and landing under low visibility conditions autonomously. There are investigations of head-down, head-up, and head-mounted displays. Figure 4 shows an HMI example developed in ADVISE-PRO.

In ADVISE-PRO several simulation runs to support and validate HMI developments have been performed in the cockpit simulator (Figure 5). Furthermore, a huge number of flight trials have been conducted with the DLR test aircraft, a Dornier Do 228 (see Figure 6), equipped with the EADS HiVision 35 GHz MMW





**Abb. 5.** DLR's Cockpit simulator which is equipped with raster capable HUD (HGS 4000 from Flight Dynamics) and head-mounted display (Microvision, retinal scanning device).

radar [8], a radar altimeter, a long wave IR-camera and state of the art navigation sensors (INS, (Differential)GPS). During our flight tests about 200000 radar images within more than 100 radar image sequences from approaches to several runways from different airports in Germany (e.g. Hannover, Cologne-Bonn, Braunschweig, Hamburg, Peine, ...) have been acquired. In every sequence the radar image based navigation module extracted the runway correctly. The average distance between runway threshold and aircraft at time of extraction was about 1700 m, which is significantly larger than the minimum RVR (Runway Visual Range) for a non-precision approach. Only for two approaches (one to Braunschweig 08 and one to Peine-Edesse 25) this distance was below 1000 m but this smaller figure can be easily explained by the flown curved approach procedure with a straight final of about 1200 meters. The automatic analysis of the sensor data enables the integration of Enhanced Vision Systems into the overall pilot assistant system. E.g. the aircraft's navigation solution can be monitored or updated by the results of the sensor image analysis process. With an automatic detection of the runway in the sensor images there is no need anymore to display these images to the pilot. Consequently, a "nice" Synthetic Vision image of the surround terrain and the airport can be displayed to the pilot even in the final approach phase close to terrain, knowing that this virtual view has been crosschecked by weather penetrating forward looking imaging sensors.



**Abb. 6.** DLR's test aircraft DO-228, equipped with a sensor suite (HiVision MMW radar sensor of EADS, Ulm, Germany, on top, IR-sensor in the nose, DGPS, INS, radar altimeter) and with high performance data recording and data processing systems.

## 6 Conclusion

DLR's Institute of Flight Guidance explores concepts and systems to increase safety and economy of aviation. A promising approach in this domain is the improvement of the aircrew's situational awareness by introducing pilot assistance systems. DLR developed an overall concept including a generic system architecture in order to provide pilot assistance during all phases of flight from "gate-to-gate." Individual assistance functions are implemented as modules grouped around a core system consisting of a central data pool and a module manager. For several tasks of flight guidance, a number of highly specialized modules was developed and tested in national and international research programs. In addition, evaluations of an overall pilot assistance "gate-to-gate" was carried out integrating modules for en-route navigation, approach, landing and taxiing with the generic structure and testing it on an Airbus A340 full flight simulator. Airline pilots gave a positive response to the presented concept and appreciated DLR's approach.

One of the most important task of the presented pilot assistant system is to provide the right information to the air crew at the right time. To do so, information coming from different source (and of different quality and importance) have to be fused together to establish a comprehensive assessment of the

external and internal situation of the aircraft. Only a good understanding of the situation and as a consequence, an appropriate communication with the human operator to ensure a common understanding of the situation will increase safety and efficiency of aircraft operation.

## Literatur

1. V. Adam and U. Teegen. *PD/2 Final Report, Annex F: Airborne Aspects of PD/2*. EUROCONTROL, DOC 97-10-13, 1997.
2. V. Adam, G. Ingle and R. Rawlings. *Experimental Flight Management System*. AGARD CP 538, Berlin, 1993.
3. V. Adam, P. Hecker, B. Korn and P. Stütz. Procedures and technologies for remotely controlled and autonomous UAV guidance within civil airspace. ODAS 2003, Toulouse, 4.-6. Juni 2003, ONERA/DLR, Dynamic Flow Control, Unmanned Aerial Vehicles, Payload, Control and Mission Management, Space R&T and Missions for Earth Observation, 2003.
4. Boeing Commercial Airplane (Pub.). *Statistical Summary of Commercial Jet Airplanes Accidents; Worldwide Operations; 1959–2001*, 2002.
5. H.-U. Doehler and B. Korn. Enhanced Vision Systeme: Situationserfassung für die bordseitige Flugführung. In: *Künstliche Intelligenz und Expertensysteme bei fliegenden Waffensystemen*, Mannheim, 31.03.2005, Bundesakademie für Wehrverwaltung und Wehrtechnik, 2005.
6. Federal Aviation Administration: Federal Register 14 CFR Parts 1, 91. Enhanced Flight Vision Systems; Final Rule. Washington, DC: Department of Transportation, 2004.
7. P. Hecker. Aircrew assistance by sophisticated vision systems, concepts for increased flight safety. In: *International Workshop On Techn. Elements for Aviation Safety*, Tokyo, 1999.
8. K. Hellemann and R. Zachai. Recent progress in mm-wave-sensor capabilities for enhanced vision. In: *Enhanced and Synthetic Vision 1999*, J. G. Verly, ed., Proc. SPIE, Vol. 3691, pp. 21–28, 1999.
9. H. Helmke, F. Höppner and R. Suikat. Generic architecture for a pilot assistant system. *Conference proceedings of The Human Electronic Crew: The Right Stuff?*, Kreuth, Germany, 1997.
10. B. Korn. Autonomous sensor based landing systems: Fusion of vague and incomplete information by application of fuzzy clustering techniques. *29th Annual Conference of the German Classification Society*, Magdeburg, 09.-11.03.05, Deutsche Gesellschaft für Klassifikation, 2005.
11. B. Korn, T. Ludwig, B. Lorenz and P. Hecker. Taxi Guidance in zukünftigen integrierten Airport Management Konzepten. *DGON Luftfahrtkommission Sitzung 1/2004*, 06. Juli 2004, Flughafen Köln/Bonn, 2004.
12. R. Onken. Knowledge based cockpit assistant for IFR operations. In: *Knowledge Based Systems and Applications in Guidance and Control*, AGARD-CP-474, CGM Symposium, Madrid, pp. 14.1-14.9, 1990.



# Negative Sensorevidenz: Ausgewählte Beispiele aus militärischen Überwachungsanwendungen

Wolfgang Koch

FGAN-FKIE, 53343 Wachtberg, Germany

**Zusammenfassung.** In militärischen Überwachungsanwendungen (Verfolgung von Gruppenzielen/Formationen, adaptives Tracking mit Multifunktionsradar, Verfolgung von Bodenfahrzeugen aus der Luft oder Missile-Tracking unter Störbedingungen) muss alle verfügbare Information über Sensor-, Ziel- und Szenarioeigenschaften ausgenutzt werden. Neben der Verarbeitung der Messdaten selbst schließt dies die Verwendung verfeinerter Sensormodelle ein, in denen Hintergrundinformation über die Sensoreigenschaften formuliert ist. Dadurch wird insbesondere ermöglicht, negative Sensorevidenz zu nutzen, also Schlussfolgerungen aus erwarteten, aber tatsächlich ausbleibenden Detektionen zu ziehen. Wie sich zeigt, können dadurch Positions- und Geschwindigkeitsschätzungen der zu verfolgenden Ziele verbessert werden. Anhand ausgewählter Beispiele erläutert der Beitrag, inwiefern die Kenntnis über einen fehlgeschlagenen Detektionsversuch einen wertvollen Sensor-Output darstellt und mit welchen Methoden er ausgewertet werden kann.

## 1 Einführung

Für militärische Aufklärungs- und Überwachungsaufgaben ist alle verfügbare Information zu nutzen, die zur Verbesserung des Lagebildes beitragen kann. Bei der Anwendung moderner Zielverfolgungs- und Sensordatenfusionsverfahren, die hochentwickelte Sensorsysteme nutzen und auch unter erschwerten operationellen Einsatzbedingungen arbeiten, muss daher neben den aktuell einströmenden Sensordaten selbst auch das verfügbare Hintergrundwissen in den Fusionsprozess einfließen. Insbesondere ist alle greifbare Information über das kinematische Verhalten der zu verfolgenden Ziele sowie die charakteristischen Eigenschaften der zugrundeliegenden Sensorsysteme und des aktuell aufzuklärenden Szenarios zu berücksichtigen. Der vorliegende Beitrag diskutiert speziell solche Hintergrundinformation, die durch verfeinerte statistische Modellierung der Sensoreigenschaften formuliert werden kann, und ist eine ausführlichere von Darstellung von Ergebnissen, die bereits als kurze Konferenzbeiträge [8,9] vorgestellt wurden.

### 1.1 Zum Begriff der ‘negativen Sensorevidenz’

Hintergrundwissen über die Eigenschaften der verwendeten Sensoren ermöglicht insbesondere die Nutzung negativer Sensorevidenz. Unter diesem Begriff wird die Gesamtheit aller Schlussfolgerungen verstanden, die man aus erwarteten, aber

tatsächlich ausbleibenden Sensordetektionen ziehen kann. Negative Evidenz in diesem Sinne zielt ab auf verbesserte Zustandsschätzungen der aufzuklärenden oder zu überwachenden Objekte. Das vorgestellte Konzept wird durch konkrete Beispiele aus verschiedenen Anwendungsbereichen veranschaulicht:

- Verfolgung kleiner Zielgruppen (Formation Tracking)
- Adaptive lokale Suche bei Phase-Array Tracking
- Tracking von Bodenzielen in der Nähe der Clutter Notch
- Zielverfolgung in Gegenwart von Main-Lobe Jammer Suppression.

Anhand der genannten Beispiele wird gezeigt, dass auch ein fehlgeschlagener Versuch, ein Ziel im Überwachungsbereich eines Sensors zu detektieren, einen nützlichen Sensor-Output darstellt, der jedoch nur auf Grundlage geeigneter Modelle der Sensorperformance auszuwerten ist. Die in derartigen Modellen enthaltene Hintergrundinformation kann unmittelbar die Erfüllung der Teilaufgaben Target Tracking, Sensormanagement und Sensordatenfusion verbessern.

Der Fachausdruck ‘negative Evidenz’, der zur Bezeichnung des beschriebenen Sensor-Outputs verwendet wird, scheint in der Fachwelt akzeptiert zu sein. Siehe hierzu die Referenzen [1] und [20].

## 1.2 Methodischer Rahmen: Bayes-Formalismus

Viele konzeptionelle Ideen und mathematische Methoden, die für Multisensordatenfusion relevant sind und mit deren Hilfe insbesondere ‘negative’ Sensorevidenz ausgewertet werden kann, lassen sich in einem einheitlichen begrifflichen Rahmen diskutieren, der wesentlich auf dem Bayes-Formalismus beruht. Diese Methodik ermöglicht die mathematisch strenge Verknüpfung von Informationen, deren ‘Unschärfe’ sich mit statistischen Begriffen beschreiben läßt.

Abstrakt formuliert, will Multisensordatenfusion die bedingten Wahrscheinlichkeitsdichten der Zustandsvektoren aller Objekte von Interesse berechnen. Unter diesem Blickwinkel ist ein Algorithmus für Sensordatenfusion eine iterative Fortschreibungsprozedur für die konditionalen Wahrscheinlichkeitsdichten  $p(\mathbf{x}_k | \mathcal{Z}^k)$  des kinematischen Verbundzustandes  $\mathbf{x}_k$  aller beteiligten Ziele zu jeder Zeit  $t_k$ . Bedingt sind die Wahrscheinlichkeitsdichten durch die akkumulierten Sensordaten  $\mathcal{Z}^k$  der beteiligten Sensoren und die verfügbare Hintergrundinformation insofern sie in Form statistischer Modelle vorliegt.

Konkret besteht jeder Update der Dichtepropagation aus einer *Prädiktion*,

$$p(\mathbf{x}_{k-1} | \mathcal{Z}^{k-1}) \xrightarrow[\text{modell}]{\text{Dynamik-}} p(\mathbf{x}_k | \mathcal{Z}^{k-1}), \quad (1)$$

füßend auf Modellen der Objektdynamik, an die sich ein *Filterungsschritt* anschließt als Verarbeitung der gemessenen Daten. Technisch gesprochen, wird in der Filterung die sensorspezifische Likelihoodfunktion (bestimmt durch aktuelle Messungen und Sensormodelle) mit der prädizierten Dichte unter Verwendung der Bayes-Formel verknüpft [11, 18].

Bei  $m_k$  Sensordaten  $Z_k = \{\mathbf{z}_k^j\}_{j=1}^{m_k}$  zur Zeit  $t_k$  ist die Likelihoodfunktion proportional zu  $\ell(\mathbf{x}_k; Z_k, m_k) \propto p(Z_k, m_k | \mathbf{x}_k)$ . Mit ihrer Hilfe ergibt sich die konditionale Dichte  $p(\mathbf{x}_k | \mathcal{Z}^k)$  gemäß der Bayesschen Regel aus der Dichte  $p(\mathbf{x}_k | \mathcal{Z}^{k-1})$ , die zuvor im Prädiktionsschritt berechnet wurde:

$$p(\mathbf{x}_k | \mathcal{Z}^k) = \frac{p(Z_k, m_k | \mathbf{x}_k) p(\mathbf{x}_k | \mathcal{Z}^{k-1})}{\int d\mathbf{x}_k p(Z_k, m_k | \mathbf{x}_k) p(\mathbf{x}_k | \mathcal{Z}^{k-1})}. \quad (2)$$

In vielen Fällen sind die Sensordaten  $Z_k$  vieldeutig; d. h. es gibt einen vollständigen Satz einander ausschließender Deutungshypothesen  $E_k$ .  $p(Z_k, m_k | \mathbf{x}_k)$  erscheint daher als eine Marginaldichte, d. h. als gewichtete Summe bedingter Wahrscheinlichkeitsdichten:

$$p(Z_k, m_k | \mathbf{x}_k) = \sum_{E_k} p(Z_k, m_k | E_k, \mathbf{x}_k) P(E_k | \mathbf{x}_k). \quad (3)$$

$p(Z_k, m_k | E_k, \mathbf{x}_k)$  ist darin offenbar proportional zu der Likelihoodfunktion, die sich ergibt, wenn die Deutungshypothese  $E_k$  als gültig angenommen wird. Der zugehörige Gewichtungsfaktor  $P(E_k | \mathbf{x}_k)$ , mit dem die Deutung  $E_k$  in die obige Summe eingeht, kann durchaus vom kinematischen Zustand der Objekte abhängig sein. Dieser Umstand wird in den nachfolgenden Abschnitten für die Auswirkung negativer Sensorevidenz auf die Schätzung des Zielzustands wichtig werden.

Offenbar überträgt sich diese allgemeine Struktur auch auf die gesuchten Wahrscheinlichkeitsdichten  $p(\mathbf{x}_k | \mathcal{Z}^k)$ , die daher bis auf eine Normierungskonstante gegeben sind durch:

$$p(\mathbf{x}_k | \mathcal{Z}^k) \propto \sum_{E_k} p(Z_k, m_k | E_k, \mathbf{x}_k) P(E_k | \mathbf{x}_k) p(\mathbf{x}_k | \mathcal{Z}^{k-1}). \quad (4)$$

Die Dichten  $p(\mathbf{x}_k | \mathcal{Z}^k)$  sind offenbar in der Regel sogenannte ‘Finite Mixtures’ [21], also gewichtete Summen individueller Dichten und beschreiben das aktuell verfügbare Wissen über charakteristische Objektzustände auf Grundlage der bisher akkumulierten Sensordaten und der verfügbaren Hintergrundinformation. Aus ihnen können optimale Zustandsschätzungen abgeleitet werden gemäß bestimmter Kostenkriterien, die sich aus der jeweiligen Anwendung ergeben.

### 1.3 Imperfekte Detektion bei Kalman-Filterung

Auf welche Weise sich prinzipiell ‘negative’ Sensorevidenz in den Rahmen des Bayes-Formalismus einfügt, sei an einem äußerst einfachen Beispiel erläutert.

Ein Sensor liefere zu den Zeiten  $t_k$  normalverteilte, voneinander unabhängige Messungen  $\mathbf{z}_k$  eines sich bewegenden Einzelzieles, deren Fehler durch eine konstante Messfehlerkovarianz  $\mathbf{R}$  charakterisiert sei. Die Messung  $\mathbf{z}_k$  ist also eine Gaußsche Zufallsvariable mit Mittelwert  $\mathbf{H}\mathbf{x}_k$  und Kovarianzmatrix  $\mathbf{R}$  und gekennzeichnet durch die Gauß-Dichte:

$$p(\mathbf{z}_k | \mathbf{x}_k) \left\{ \begin{array}{l} = \det(2\pi\mathbf{R})^{-1/2} \exp \\ -\frac{1}{2}(\mathbf{z}_k - \mathbf{H}\mathbf{x}_k)^\top \mathbf{R}^{-1}(\mathbf{z}_k - \mathbf{H}\mathbf{x}_k) \end{array} \right\} \quad (5)$$

$$=: \mathcal{N}(\mathbf{z}_k; \mathbf{H}\mathbf{x}_k, \mathbf{R}). \quad (6)$$

Darin beschreibt die Messmatrix  $\mathbf{H}$ , welche Funktion der Zustandskomponenten gemessen wird. Falschmeldungen seien ausgeschlossen. Die Ziele werden vom Sensor jedoch nur mit einer Entdeckungswahrscheinlichkeit  $P_D < 1$  detektiert.

Die Zielverfolgungsaufgabe reduziert sich in diesem einfachen Fall auf klassische Kalman-Filterung mit der Einschränkung, dass nicht in jedem Zeittakt Sensormessungen zur Verarbeitung vorliegen. In die Modellierung der Sensoreigenschaften, die in den Filterungsprozess eingeht, muss daher neben dem Messfehler auch der Detektionsprozess durch Sensorparameter beschrieben werden. In anderen Worten, die Likelihoodfunktion hängt neben der Messfehlerkovarianz  $\mathbf{R}$  auch von der Entdeckungswahrscheinlichkeit  $P_D$  ab.

Im Sinne der obigen Diskussion bestehen zwei Möglichkeiten: Entweder wurde das Ziel detektiert oder nicht ( $E_k^1$  bzw.  $E_k^0$ ). Unter der Annahme, dass die Wahrscheinlichkeiten  $P(E_k^0|\mathbf{x}_k) = 1 - P_D$  und  $P(E_k^1|\mathbf{x}_k) = P_D$  im untersuchten Fall nicht vom Zielzustand  $\mathbf{x}_k$  abhängen, erhält man mit  $\delta_{ij} = 0$  für  $i \neq j$  und  $\delta_{ij} = 1$  für  $i = j$  folgende Likelihoodfunktion:

$$p(Z_k, m_k|\mathbf{x}_k) = P(m_k|E_k^0) P(E_k^0) + p(Z_k, m_k|E_k^1, \mathbf{x}_k) P(E_k^1) \quad (7)$$

$$= \delta_{0,m_k} (1 - P_D) + \delta_{1,m_k} P_D \mathcal{N}(\mathbf{z}_k; \mathbf{H}\mathbf{x}_k, \mathbf{R}) \quad (8)$$

$$=: \ell(\mathbf{x}_k; \mathbf{z}_k, \mathbf{R}, P_D). \quad (9)$$

Mit dieser Likelihoodfunktion und einer Prädiktion, beschrieben durch die Dichte  $p(\mathbf{x}_k|\mathcal{Z}^{k-1}) = \mathcal{N}(\mathbf{x}_k; \mathbf{x}_{k|k-1}, \mathbf{P}_{k|k-1})$ , erhält man für die Filterung gemäß Gl. (2) folgendes Resultat:

1. Bei positivem Sensor-Output, d. h. für  $m_k = 1$ , erfolgt die Verarbeitung der Sensormessung  $\mathbf{z}_k$  gemäß der Kalman-Iteration. Denn aufgrund einer quadratischen Ergänzung ergibt sich für die Dichte nach der Filterung eine Gauß-Dichte, gegeben durch  $p(\mathbf{x}_k|\mathcal{Z}^k) = \mathcal{N}(\mathbf{x}_k; \mathbf{x}_{k|k}, \mathbf{P}_{k|k})$ , mit einem Erwartungswert  $\mathbf{x}_{k|k}$  und einer Kovarianzmatrix  $\mathbf{P}_{k|k}$  zu berechnen durch:

$$\mathbf{P}_{k|k} = (\mathbf{P}_{k|k-1}^{-1} + \mathbf{H}^\top \mathbf{R}^{-1} \mathbf{H})^{-1} \quad (10)$$

$$\mathbf{x}_{k|k} = \mathbf{P}_{k|k} (\mathbf{P}_{k|k-1}^{-1} \mathbf{x}_{k|k-1} + \mathbf{H}^\top \mathbf{R}^{-1} \mathbf{z}_k). \quad (11)$$

2. Bei negativem Sensor-Output, d. h. für  $m_k = 0$ , ist die Likelihoodfunktion dagegen eine Konstante. Durch die Filterung wird daher die prädierte Dichte nicht weiter modifiziert. Offenbar gilt:  $p(\mathbf{x}_k|\mathcal{Z}^k) = \mathcal{N}(\mathbf{x}_k; \mathbf{x}_{k|k-1}, \mathbf{P}_{k|k-1})$ . Aufgrund der Gleichungen (10) und (11) könnte man dieses Ergebnis jedoch formal auch als das Resultat der Verarbeitung einer *fiktiven* Messung mit unendlich großem Messfehler  $\mathbf{R}$  auffassen; denn in diesem Fall gilt:  $\mathbf{R}^{-1} = 0$ .

Der Bayes-Formalismus und das die Sensoreigenschaften beschreibende Sensormodell beschreibt offenbar eindeutig, wie ein negativer Sensor-Output, d. h. die Meldung einer ausbleibenden Detektion, zu verarbeiten ist.



## 2 ‘Negative’ Evidenz und Formationstracking

Aufgrund der begrenzten Auflösungsleistung vieler Sensorsysteme sind bei eng benachbart operierenden Zielen ständig Übergänge von auflösbaren zu nicht-auflösbaren Situationen zu beobachten. Um die Diskussion überschaubar zu halten, wird ein typisches Mittelbereichsradar betrachtet, das die Entfernungen und Azimutwinkel zu einer Formation misst, die aus zwei Flugzeugen besteht.

### 2.1 Modellierung der Sensorauflösung

Im Falle eines Auflösungskonfliktes wird ein unaufgelöster Sensorplot  $\mathbf{z}_k^g$  zu einer Zeit  $t_k$  als eine Messung des Gruppenschwerpunktes  $\frac{1}{2}(\mathbf{x}_k^1 + \mathbf{x}_k^2)$  aufgefasst mit einer für diese Situation charakteristischen Messfehlerkovarianz  $\mathbf{R}_g$ . Mit anderen Worten, für unaufgelöste Messungen wird folgende Messgleichung betrachtet:

$$\mathbf{z}_k^g = \mathbf{H}_g \mathbf{x}_k + \mathbf{u}_k^g, \quad \text{mit} \quad \mathbf{u}_k^g \sim N(0, \mathbf{R}_g), \quad (12)$$

in der eine Messmatrix  $\mathbf{H}_g$  auftritt, die definiert ist durch:

$$\mathbf{H}_g \mathbf{x}_k = \frac{1}{2} \mathbf{H}(\mathbf{x}_k^1 + \mathbf{x}_k^2). \quad (13)$$

Hierin bezeichnet  $\mathbf{H}$  die zugrundeliegende reguläre Messmatrix definiert durch  $\mathbf{H}\mathbf{x}_k^i = (r_k^i, \phi_k^i)$ ,  $i = 1, 2$ .

Generell ist zu erwarten, dass die Auflösungsleistung des Sensors sowohl von der aktuellen Ziel-Sensor-Geometrie abhängt als auch von der relativen Position der Ziele innerhalb der Gruppe. Aus physikalischen Gründen ist die Auflösung in Entfernung und Winkel voneinander unabhängig. Darüber hinaus hängt die Auflösungsleistung jedoch auch von der jeweils zugrundeliegenden Signalverarbeitung und zufälligen Fluktuationen des Zielsignals ab. Eine vollständige Modellierung wird sensorspezifisch sein. Daher wird ein vereinfachtes, aber qualitativ korrektes und zugleich mathematisch beherrschbares Modell benötigt.

Grundsätzlich ist die Sensorauflösung durch die Band- und Keulenbreite der Radars eingeschränkt. Diese sensorspezifischen Parameter müssen explizit in die Verarbeitung möglicherweise unaufgelöster Meldungen eingehen. Die typische Größe einer Auflösungszelle in mittlerem Abstand vom Radar ist etwa 50 m (Range) und 500 m (Cross Range). Da in Flugformationen durchaus relative Abstände von 50 - 500 m oder weniger üblich sind, erweist sich die Behandlung von Auflösungskonflikten als zwingend [4].

Auflösungsphänomene treten offenbar auf, sobald die Entfernung- und Winkeldifferenzen  $\Delta r$ ,  $\Delta\phi$  zwischen den Zielen klein sind im Vergleich zu den Auflösungsparametern  $\alpha_r$  und  $\alpha_\phi$ :  $\Delta r/\alpha_r < 1$ ,  $\Delta\phi/\alpha_\phi < 1$ . Sind diese Abstände dagegen groß, können die Ziele aufgelöst werden:  $\Delta r/\alpha_r \gg 1$ ,  $\Delta\phi/\alpha_\phi \gg 1$ . Darüber hinaus ist ein schmaler Übergangsbereich zwischen beiden Bereichen zu erwarten. Eine quantitative Beschreibung dieses Sachverhalts wird durch Einführung einer Auflösungswahrscheinlichkeit  $P_r = P_r(\Delta r, \Delta\phi)$  geleistet, die von der Ziel-Sensorgeometrie abhängig ist [14]. Diese Größe kann offenbar durch die

entsprechende Wahrscheinlichkeit  $P_u = P_u(\Delta r, \Delta\phi)$  ausgedrückt werden, mit der die Formation vom Sensor *nicht* aufgelöst werden kann:

$$P_r(\Delta r, \Delta\phi) = 1 - P_u(\Delta r, \Delta\phi). \quad (14)$$

Es wird sich als vorteilhaft erweisen, die Wahrscheinlichkeit  $P_u$  durch folgende Funktion des relativen Abstandes zwischen den Zielen in Entfernung und Winkel auszudrücken, deren Form an eine Gauß-Dichte erinnert:

$$P_u(\Delta r, \Delta\phi) = \exp\left[-\log 2\left(\frac{\Delta r}{\alpha_r}\right)^2\right] \exp\left[-\log 2\left(\frac{\Delta\phi}{\alpha_\phi}\right)^2\right]. \quad (15)$$

Offenbar deckt sich dieses sehr einfache quantitative Modell zur Beschreibung von Auflösungsphänomenen mit den qualitativen Verhältnissen. Insbesondere wird  $P_u$  um einen Faktor  $\frac{1}{2}$  reduziert, sobald einer der Abstände  $\Delta r$  oder  $\Delta\phi$  von Null auf  $\alpha_r$  oder  $\alpha_\phi$  anwächst.

Aufgrund des Gaußschen Charakters ihrer Abhängigkeit von den relativen Zielabständen  $\Delta r$  und  $\Delta\phi$  kann die Größe  $P_u$  durch eine Gauß-Dichte ausgedrückt werden, in die der kinematische Verbundzustand  $\mathbf{x}_k = (\mathbf{x}_k^{1\top}, \mathbf{x}_k^{2\top})^\top$  der Ziele explizit eingeht:

$$P_u = \exp\left[-\log 2\left[\frac{r_k^1 - r_k^2}{\alpha_r}\right]^2\right] \exp\left[-\log 2\left[\frac{\phi_k^1 - \phi_k^2}{\alpha_\phi}\right]^2\right] \quad (16)$$

$$= \exp\left[-\log 2\left(\mathbf{H}\mathbf{x}_k^1 - \mathbf{H}\mathbf{x}_k^2\right)^\top \mathbf{A}^{-1}\left(\mathbf{H}\mathbf{x}_k^1 - \mathbf{H}\mathbf{x}_k^2\right)\right] \quad (17)$$

$$= \exp\left[-\log 2\left(\mathbf{H}_u\mathbf{x}_k\right)^\top \mathbf{A}^{-1}\mathbf{H}_u\mathbf{x}_k\right]. \quad (18)$$

Hierbei ist die *Auflösungsmatrix*  $\mathbf{A}$  definiert durch  $\mathbf{A} = \mathbf{diag}(\alpha_r^2, \alpha_\phi^2)$ . Die ebenfalls auftretende Größe  $\mathbf{H}_u\mathbf{x}_k = \mathbf{H}(\mathbf{x}_k^1 - \mathbf{x}_k^2)$  kann offenbar als eine Messmatrix für Abstandsmessungen aufgefasst werden.

Bis auf einen konstanten Faktor kann daher  $P_u(\mathbf{x}_k)$  formal als eine *fiktive* Likelihoodfunktion aufgefasst werden:

$$P_u(\mathbf{x}_k) = |2\pi\mathbf{R}_u|^{-1/2} \mathcal{N}(\mathbf{0}; \mathbf{H}_u\mathbf{x}_k, \mathbf{R}_u) \quad (19)$$

$$\text{mit } \mathbf{R}_u = \frac{\mathbf{A}}{2 \log 2}. \quad (20)$$

Dadurch wird eine fiktive Messung ‘Null’ für den Abstand  $\mathbf{H}(\mathbf{x}_k^1 - \mathbf{x}_k^2)$  zwischen den Zielen beschrieben. Diese ‘Messung’ ist durch eine entsprechende, ebenfalls fiktive Messfehlerkovarianzmatrix  $\mathbf{R}_u$  charakterisiert, die durch die Auflösungsparameter  $\alpha_r, \alpha_\phi$  festgelegt ist.

Eine Taylor-Entwicklung in erster Ordnung um den prädierten Abstand  $r_{k|k-1}^g$  und Azimutwinkel  $\phi_{k|k-1}^g$  des Gruppenschwerpunktes liefert die Auflösungsmatrix  $\mathbf{A}_c$ , durch die die Auflösungszellen in kartesischen Koordinaten beschrieben werden. Die Matrix  $\mathbf{A}_c$  ist offenbar zeitabhängig und hängt von der aktuell vorliegenden Ziel-Sensor-Geometrie ab. Sie ergibt sich aus der Auflösungsmatrix  $\mathbf{A}$  durch eine Rotation  $\mathbf{R}_{\phi_{k|k-1}^g}$  um den Winkel  $\phi_{k|k-1}^g$  und eine Streckung  $\mathbf{S}_{r_{k|k-1}^g} = \text{diag}[1, r_{k|k-1}^g]$ :

$$\mathbf{A}_c = \mathbf{R}_{\phi_{k|k-1}^g} \begin{pmatrix} \alpha_r^2 & 0 \\ 0 & (r_{k|k-1}^g \alpha_\phi)^2 \end{pmatrix} \mathbf{R}_{\phi_{k|k-1}^g}^\top. \quad (21)$$

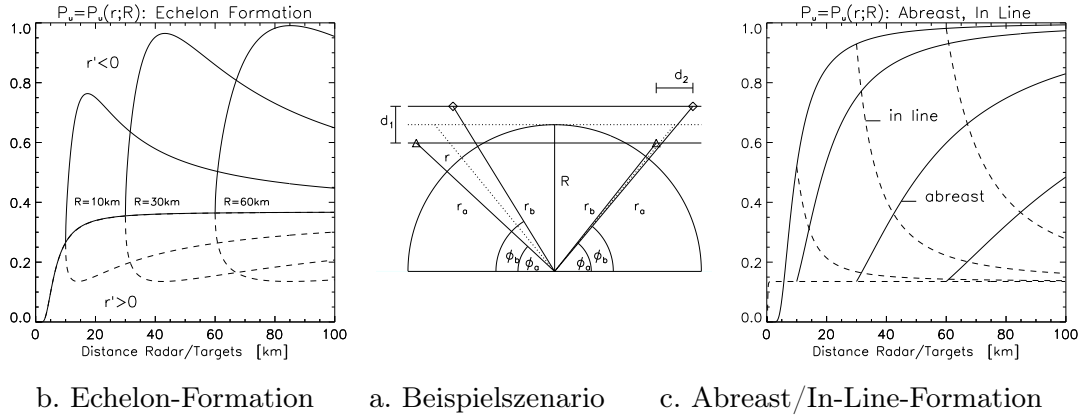


Abb. 1. Sensorauflösung (Auswirkung der Ziel-Sensorgeometrie).

## 2.2 Einfluss der Ziel-Sensor-Geometrie

Zur Veranschaulichung der Verhältnisse sei ein Beispiel betrachtet. Eine Formation aus zwei Zielen passiere mit konstanter Geschwindigkeit ein Radar (Abbildung 1a). Die Auflösungsparameter des Radarsensors in Entfernung und Azimut seien gegeben durch:  $\alpha_r = 150$  m,  $\alpha_\phi = 1.5^\circ$ . Die Distanz  $r_c = \frac{180^\circ}{\pi} \alpha_r / \alpha_\phi$  besitzt eine besondere Bedeutung: Für Ziel-Sensorabstände  $r < r_c$  übertrifft die Azimutauflösung die Entfernungsauflösung und umgekehrt. Für typische Radarparameter ist  $r_c$  jedoch klein. Im vorliegenden Fall gilt:  $r_c = 5.7$  km.

Die Positionsvektoren der Ziele zu den Zeiten  $t$  seien bezeichnet durch  $\mathbf{r}_a(t)$ ,  $\mathbf{r}_b(t)$ . Ihre relative Distanz betrage  $d = |\mathbf{d}| = |\mathbf{r}_b - \mathbf{r}_a| = 150$  m; der Winkel zwischen  $\mathbf{d}$  und  $\mathbf{v}$  sei als konstant angenommen:  $\angle(\mathbf{d}, \mathbf{v}) = \text{const}$ . Die verschiedenen möglichen Formationstypen unterscheiden sich hinsichtlich der relativen Orientierung der Einzelziele zueinander. So fliegt eine Formation ‘abreast’, wenn gilt:  $\angle(\mathbf{d}, \mathbf{v}) = \pi/2$  und ‘in line’, falls  $\angle(\mathbf{d}, \mathbf{v}) = 0$ . Eine ‘Echelon-Formation’ ist charakterisiert durch  $0 < \angle(\mathbf{d}, \mathbf{v}) < \pi/2$ . Im folgenden wird der Fall  $\angle(\mathbf{d}, \mathbf{v}) = \pi/4$  betrachtet.

$r$  bezeichne die jeweiligen Abstände des Gruppenschwerpunktes vom Radar;  $R$  sei das Minimum dieser Abstände. Nach Abbildung 1a kann die Entfernung  $r_{a,b}$  und der Azimutwinkel  $\phi_{a,b}$  der Ziele  $a, b$  als Funktion von  $r$  ausgedrückt werden ( $\dot{r} < 0$ ):

$$r_{a,b}^2 = (\sqrt{r^2 - R^2} \pm \frac{1}{2}d_1)^2 + (R \mp \frac{1}{2}d_2)^2 \quad (22)$$

$$\tan \phi_{a,b} = \frac{R \mp \frac{1}{2}d_2}{\sqrt{r^2 - R^2} \pm \frac{1}{2}d_1}. \quad (23)$$

Die entsprechenden Formeln für den Fall  $\dot{r} > 0$  erhält man durch Ersetzen von  $\pm$  durch  $\mp$ . Offenbar besteht für Echelon-Formationen eine Asymmetrie zwischen einer Annäherung und dem sich Entfernen vom Radarsensor.

Die Abbildung 1b zeigt die sich für die Formation ergebenden inversen Auflösungswahrscheinlichkeit  $P_u(r; R)$  als Funktion vom Abstand  $r$  parametrisiert durch  $R = 0, 10, 30, 60$  km. Die durchgezogenen Linien beziehen sich auf eine

sich dem Sensor nähernde Formation ( $\dot{r} < 0$ ); für die gestrichelt gezeichneten Linien gilt  $\dot{r} > 0$ . Offenbar unterscheiden sich für  $R \neq 0$  beide Flugphasen erheblich. In der Nähe von  $r = R$  variiert die Wahrscheinlichkeit  $P_u$  sehr stark (.85  $\rightarrow$  .15 !). Im Falle eines Radialfluges ( $R = 0$ ) verschwindet die Asymmetrie und  $P_u$  ist über einen weiten Bereich konstant, da in dieser Situation allein die Entfernungsauflösung relevant ist ( $r \gg r_c$ ).

In Abbildung 1c ist  $P_u(r; R)$  dargestellt für Formationen, die ‘abreast’ (durchgezogene Linie) oder ‘in-line’ (gestrichelt) operieren. Für beide Formationstypen verschwindet die bei Echelon-Formationen auftretende Asymmetrie bezüglich Annäherung und sich Entfernen. Im ersten Fall nimmt die Auflösbarkeit der Formation monoton mit wachsendem Abstand vom Sensor zu. Im zweiten Fall liegt das Gegenteil vor. Die Formation ist in dem vorliegenden Beispiel offenbar am besten auflösbar, wenn sie sich ‘in-line’ radial auf den Sensor zubewegt. In dieser Situation ist  $P_u$  konstant und gegeben durch  $e^{-2(d/\alpha_r)^2} = 0.14$ .

Die Diskussion dieses Beispiels verdeutlicht, dass die Auflösungswahrscheinlichkeit einer Zielgruppe signifikant abhängt von der aktuell zugrunde liegenden Ziel-Sensor-Geometrie und der relativen Orientierung der Ziele innerhalb der Gruppe. Dies gilt selbst für den hier betrachteten, stark vereinfachten Fall einer nicht-manövrierenden Formation aus nur zwei Zielen. Das zuvor diskutierte Auflösungsmodell berücksichtigt diese Verhältnisse offenbar zwanglos.

### 2.3 Track Update durch ‘negative’ Evidenz

Für die zu verfolgende Zielgruppe bestehen grundsätzlich drei Möglichkeiten: Die Ziele produzieren eine einzige Schwerpunktmessung, sie sind weder auflösbar noch detektiert oder die Gruppe ist als Ganzes auflösbar. Gemäß der Diskussion in der Einleitung impliziert diese Mehrdeutigkeit eine Likelihoodfunktion, die sich als Summe über diese Deutungshypothesen darstellt (Gl. (3)). Insbesondere muß die Auflösungswahrscheinlichkeit explizit in die Likelihoodfunktion eingehen. Man erhält:

$$p(Z_k, m_k, E_k | \mathbf{x}_k) = \ell(Z_k, m_k | E_k, \mathbf{x}_k) P(E_k | \mathbf{x}_k). \quad (24)$$

Zunächst sei die Deutung  $E_k^{ii}$  betrachtet, die besagt, dass beide Objekte nicht aufgelöst, aber als Gruppe detektiert wurden;  $\mathbf{z}_k^i \in Z_k$  ist die zugehörige Messung des Gruppenschwerpunkts; alle anderen Sensordaten des Frames  $Z_k$  werden als Falschmeldungen betrachtet. Unter dieser Deutung erhält man gemäß der Überlegungen in [11, 14]:

$$\ell(Z_k, m_k | E_k^{ii}, \mathbf{x}_k) = \mathcal{N}(\mathbf{z}_k^i; \mathbf{H}_k^g \mathbf{x}_k, \mathbf{R}_k^g) \frac{p_F(m_k - 1)}{|\text{FoV}|^{m_k - 1}} \quad (25)$$

$$P(E_k^{ii} | \mathbf{x}_k) = \frac{1}{m_k} P_u(\mathbf{x}_k) P_D^u. \quad (26)$$

In diesem Ausdruck bezeichnet  $p_F(m)$  die Wahrscheinlichkeit dafür, dass  $m$  Falschmeldungen im aktuellen Scan vorliegen;  $|\text{FoV}|$  ist das Volumen des Beobachtungsgebietes (Field of View);  $P_D^u$  bezeichnet die Detektionswahrscheinlichkeit im Falle unaufgelöster Ziele.

Gemäß obiger Überlegungen kann die inverse Auflösungs Wahrscheinlichkeit  $P_u(\mathbf{x}_k)$  formal durch eine Gauß-Dichte ausgedrückt werden (Gl. (19)). Bis auf einen konstanten Faktor ist daher die Größe  $\ell(Z_k, m_k, E_k^{ii} | \mathbf{x}_k)$  gegeben durch die folgende Gauß-Dichte:

$$\ell(Z_k, m_k, E_k^{ii} | \mathbf{x}_k) \propto \mathcal{N} \left( \begin{pmatrix} \mathbf{z}_k^i \\ 0 \end{pmatrix}; \begin{pmatrix} \mathbf{H}_g \\ \mathbf{H}_u \end{pmatrix} \mathbf{x}_k, \begin{pmatrix} \mathbf{R}_g & \mathbf{O} \\ \mathbf{O} & \mathbf{R}_u \end{pmatrix} \right). \quad (27)$$

Unter der Hypothese  $E_k^{ii}$  wird offenbar neben der (realen) Messung  $\mathbf{z}_k^i$  des Gruppenschwerpunkts, beschrieben durch  $\mathbf{H}_k^g \mathbf{x}_k = \frac{1}{2} \mathbf{H}(\mathbf{x}_k^1 + \mathbf{x}_k^2)$ , eine fiktive Messung ‘Null’ des Abstands  $\mathbf{H}_u \mathbf{x}_k = \mathbf{H}(\mathbf{x}_k^1 - \mathbf{x}_k^2)$  zwischen den Objekten in der Gruppe verarbeitet. Die zugehörige fiktive Messfehlerkovarianz  $\mathbf{R}_u$  ist dabei durch die Sensorauflösung festgelegt.

In der vorliegenden Situation ist von *negativer Sensorevidenz* zu sprechen, da das Ausbleiben einer zweiten Messung Information über die Zielposition übermittelt. Denn im Falle eines Auflösungskonflikts muss der relative Abstand der Ziele kleiner sein als die Sensorauflösung. Aus dem Formalismus ergibt sich offenbar, dass dieses Zusatzwissen formal durch eine fiktive Messung des Abstands zwischen den Zielen mit der Auflösung als Messfehler repräsentiert werden muss.

Unter der Hypothese  $E_k^{00}$ , dass die Ziele weder aufgelöst noch detektiert wurden, alle Messungen des Scans  $Z_k$  also falsch sind, wird wenigstens die fiktive relative Entfernungsmessung ‘null’ mit einem entsprechenden, durch die Auflösungsparameter bestimmten Messfehler verarbeitet. Denn mit

$$\ell(Z_k, m_k | E_k^{00}, \mathbf{x}_k) = \frac{p_F(m_k)}{|\text{FoV}|^{m_k}} \quad (28)$$

$$P(E_k^{00} | x_k) = P_u(\mathbf{x}_k) (1 - P_D^u) \quad (29)$$

gilt für die entsprechende Komponente der Likelihoodfunktion:


$$\ell(Z_k, m_k, E_k^{00} | \mathbf{x}_k) = \ell(Z_k, m_k | E_k^{00}, \mathbf{x}_k) P(E_k^{00} | x_k) \quad (30)$$

$$\propto \mathcal{N}(0; \mathbf{H}_u \mathbf{x}, \mathbf{R}_u). \quad (31)$$

Im Falle der Deutung  $E_k^{ij}$ , die besagt, dass beide Objekte aufgelöst und detektiert worden sind mit  $\mathbf{z}_k^i, \mathbf{z}_k^j \in Z_k$  als Zielmeldungen und  $m_k - 2$  Falschmeldungen, erscheint die Komponente  $\ell(Z_k, m_k, E_k^{ij} | \mathbf{x}_k)$  der Likelihoodfunktion als Mixture, in der negative Gewichtungsfaktoren auftreten. Wie sich zeigt, summieren sich nichtsdestotrotz die Koeffizienten korrekt zu Eins auf. Ferner sind die Dichten stets positiv. Dies drückt aus, dass in einer aufgelösten Zielgruppe die einzelnen Ziele einen gewissen Mindestabstand voneinander wahren. Denn sonst wären sie ja nicht auflösbar. Denn analog zu den obigen Überlegungen erhält man mit der Entdeckungswahrscheinlichkeit  $P_D$ :

$$\ell(Z_k, m_k | E_k^{ij}, \mathbf{x}_k) = \mathcal{N} \left( \begin{pmatrix} \mathbf{z}_k^i \\ \mathbf{z}_k^j \end{pmatrix}; \begin{pmatrix} \mathbf{H} \\ \mathbf{H} \end{pmatrix} \mathbf{x}_k, \begin{pmatrix} \mathbf{R} & \mathbf{O} \\ \mathbf{O} & \mathbf{R} \end{pmatrix} \right) \frac{p_F(m_k - 2)}{|\text{FoV}|^{m_k - 2}} \quad (32)$$

$$P(E_k^{ij} | \mathbf{x}_k) = \frac{[1 - P_u(\mathbf{x}_k)] P_D^2}{m_k(m_k - 1)}. \quad (33)$$



a. Radardaten (Formation)    b. ohne negative Evidenz    c. mit negativer Evidenz

**Abb. 2.** Verfolgung möglicherweise unaufgelöster Ziele.

Die negativen Mixture-Komponenten kommen ins Spiel aufgrund des Faktors

$$1 - P_u(\mathbf{x}_k) = 1 - |2\pi\mathbf{R}_u|^{\frac{1}{2}} \mathcal{N}(0; \mathbf{H}_u\mathbf{x}, \mathbf{R}_u). \quad (34)$$

## 2.4 Verifikation anhand realer Daten

Die Abbildung 2 zeigt ein charakteristisches Detail eines Radarrohdatensatzes nach Plot-Extraktion. Die Daten stammen von einem typischen L-Band-Mittelbereichsradar. Die Antenne rotiert mit einer Scan-Periode von 5 sec; die Pulslänge beträgt  $1 \mu\text{sec}$ , die Keulbreite ist  $1.5^\circ$ , die Entdeckungswahrscheinlichkeit ungefähr 80%. Da in dem betrachteten Beispiel die räumliche Falschmeldedichte niedrig ist, ist das Joint Probabilistic Data Association Filter (JPDAF) der Algorithmus der Wahl [2].

Das zur Zielverfolgung genutzte Sensormodell ist beschrieben durch folgende Parameter: Sensorauflösung in Entfernung und Azimut:  $\alpha_r = 150 \text{ m}$ ,  $\alpha_\phi = 1.5^\circ$ , Messfehler (Entfernung, Winkel):  $\alpha_r = 150 \text{ m}$ ,  $\alpha_\phi = 1.5^\circ$ , Messfehler (unaufgelöste Plots):  $\sigma_r^u = 75 \text{ m}$ ,  $\sigma_\phi^u = .75^\circ$ , Detektionswahrscheinlichkeit:  $P_D = P_D^u = 0.8$  und räumliche Falschmeldedichte  $\rho_F = 10^{-4}/\text{km}^2$ .

Das Beispiel macht deutlich, dass Auflösungsphänomene modelliert werden müssen, sobald Ziele eng benachbart operieren. Abbildung 2a und 2b zeigen die Schätzfehlerellipsen für beide Ziele (rot, weiß), die sich aus JPDA-Filterung ergeben. Während in Abbildung 2a fälschlicherweise perfekte Auflösung angenommen wird, d. h.  $\alpha_r = \alpha_\phi = 0$ , Auflösungsphänomene also im Filter nicht modelliert sind, werden in Abbildung 2b die oben genannten Auflösungsparameter genutzt. JPDA-Filterung versagt ohne Berücksichtigung der Sensorauflösung offenbar bereits nach wenigen Frames (divergierende Schätzfehlerellipsen).

Dieser Kollaps besitzt eine einfache Erklärung: Ohne das verfeinerte Sensormodell kann ein unaufgelöster Plot offenbar nur als eine einzelne Zieldetektion begleitet von einem Ausfallereignis gedeutet werden. Als Folge wächst die zugehörige Schätzfehlerkovarianz für eines der beiden Ziele an. Dieser Effekt wird durch mehrere aufeinanderfolgende, nicht-aufgelöste Meldungen exponentiell verstärkt und führt zu Spurverlust. Sobald Auflösungshypothesen jedoch zur Deutung der Daten zugelassen werden, bleibt der Zielverfolgungsprozess stabil.

Die Schätzfehlerellipsen in Abbildungen 2a und 2b wurden vergrößert, um die datengetriebene Adaptivität des Verfahrens deutlicher sichtbar werden zu lassen. Wie man sieht, verkleinern sich die Ellipsen, sobald die Ziele zwischenzeitlich aufgelöst werden konnten.

Die vorübergehende Vergrößerung der Ellipsen in der Mitte des Formationsfluges wird durch ein drittes, die Flugbahn der Formation kreuzendes Zielobjekt verursacht. Der Übersichtlichkeit wegen ist der entsprechende Track nicht dargestellt.

### 3 Negative Evidenz und ESA-Tracking

Für elektronisch steuerbares Radar (ESR, *Phased-Array Radar*) sind wesentliche Sensorparameter über einen weiten Bereich variabel und können track-individuell gewählt werden. Diese hohe Flexibilität erfordert eine kombinierte Zielverfolgung und Sensorsteuerung, um die verfügbare Radarzeit und Sendeleistung optimal einsetzen zu können.

In dem zweiten Beispiel, das die mögliche Nutzung negativer Sensorevidenz illustrieren soll, werden stark manövrierfähige Zielobjekte betrachtet, die für militärische Surveillance-Aufgaben typisch sind. Selbst agile Ziele werden jedoch nicht unausgesetzt von ihrer Manövrierfähigkeit Gebrauch machen. Dennoch können abrupte Manöver auftreten. Zur Beschreibung dieses Zielverhaltens sind sogenannte IMM-Modelle gut geeignet (IMM: Interacting Multiple Models). Sie sind durch mehrere Dynamikmodelle für jede der möglichen Manövrierphasen und vorgegebene Übergangswahrscheinlichkeiten zwischen diesen Phasen definiert [3, 6].

Aufgrund der lokalen Zielbeleuchtung durch einen Pencil-Beam ist der Einsatz eines Manövers eine Herausforderung für die Sensorsteuerung. Spurverlust muss so weit wie möglich vermieden werden, da jede Reinitiiierung sehr zeit- und energieintensiv ist. Aus diesem Grunde sind adaptive Methoden der Keulenpositionierung zur optimalen lokalen Suche zu nutzen [5, 12].

#### 3.1 Zur Modellierung der Radarkeule

Vor jeder Radarallokation muss das Tracking-System einen geeigneten Beleuchtungszeitpunkt, die *Revisit-Zeit*  $t_k$ , die nächste Keulenposition  $\mathbf{b}_k$  zu dieser Zeit und die erforderliche Sendeleistung proportional zur *Time-on-Target* [19] ermitteln. Wenn keine Detektion erfolgt, müssen die Versuche wiederholt werden, bis die Sensorallokation zu einer Messung der Richtungsangabe  $\mathbf{d}_k = (u_k, v_k)^\top$  und der Entfernung führt. Die Berechnung des Beleuchtungszeitpunkts  $t_k$  erfolgt bedarfsorientiert und ist durch die anwenderseitig geforderte Spurqualität bestimmt. Die entsprechende Keulenposition ergibt sich zunächst aus der prädiagnostischen Zielrichtung:  $\mathbf{b}_k = (u_{k|k-1}, v_{k|k-1})^\top$ .

Für ein elektronisch steuerbares Radar hängt das Signal-zu-Rauschverhältnis SNR stark von der korrekten Positionierung der Keule in Zielrichtung ab, die in

die Verantwortung des Tracking-Systems gelegt ist. Daher muss jedes Sensormodell, das für Phased-Array-Tracking genutzt wird, den funktionalen Zusammenhang zwischen dem erwarteten Signal-zu-Rausch-Verhältnis  $\text{SNR}_k$  zur Zeit  $t_k$  und den übrigen Parametern für Sensor- und Zielobjekte beschreiben. Unter der Annahme einer Gaußschen Keulenform und Verwendung der Radargleichung [5], sei das mittlere SNR durch eine Gaußsche Funktion modelliert:

$$\text{SNR}_k = \text{SNR}_0 \left( \frac{r_k}{r_0} \right)^{-4} e^{-\log 2 |\mathbf{d}_k - \mathbf{b}_k|^2 / b^2}. \quad (35)$$

Darin bezeichnet der Parameter  $b$  die einseitige 3dB-Keulenbreite, d. h. SNR reduziert sich um einen Faktor 2 im Falle eine Beleuchtungsfehlers gegeben durch  $|\mathbf{d}_k - \mathbf{b}_k| = b$ . Der Radarparameter  $\text{SNR}_0$  hängt ab von der gesendeten Energie und dem Radarrückstreuquerschnitt (RCS) der Ziele.

Aus Gründen der Einfachheit wird den folgenden Überlegungen ein Quadratdetektor zugrundegelegt, der auf Zielentdeckung entscheidet, sobald das empfangene Radarsignal einen gewissen Schwellwert überschreitet. Im Falle eines Swerling-I-Modells zur Beschreibung der RCS-Fluktuationen der Ziele ergibt sich daraus die Entdeckungswahrscheinlichkeit als Funktion des Signal-zu-Rauschverhältnisses SNR und der Falschalarmwahrscheinlichkeit  $P_{FA}$ , die durch die Wahl der Detektionsschwelle bestimmt ist. Konkret besteht der wohlbekannte Zusammenhang:

$$P_D(\mathbf{d}_k, r_k; \mathbf{b}_k) = P_{FA}^{\frac{1}{1 + \text{SNR}(\mathbf{d}_k, r_k; \mathbf{b}_k)}}. \quad (36)$$

Detektionswahrscheinlichkeiten, die eine Funktion des Zielzustands sind, werden auch in der Referenz [15] zitiert.

### 3.2 ‘Negative’ Evidenz als Treiber der lokalen Suche

Intelligente Algorithmen für die Keulenpositionierung und lokale Suche sind von zentraler Bedeutung für Phased-Array-Tracking mit adaptiven Dynamikmodellen (IMM: Interacting Multiple Models [2]). Zu einfache Verfahren können leicht die Vorteile der adaptiven Zielmodellierung zu nichte machen, da in diesem Falle häufig Spurverlust unmittelbar nach einem Modell-Switch auftreten wird. Um dieses Phänomen zu umgehen, wird ein lokal-optimaler Lösungsansatz, der auf der Nutzung der prädierten Dichten  $p(\mathbf{x}_k | \mathcal{Z}^{k-1})$  basiert [5], auf die Verhältnisse bei IMM-Tracking angepasst [12]. Die lokale Suche verläuft wie folgt:

1. Die Keulenposition  $\mathbf{b}_k^1$  für die erste Zielbeleuchtung der Suche zur Zeit  $t_k$  ist durch die prädierte Zielrichtung  $\mathbf{d}_{k|k-1}$  gegeben, die aus der prädierten Wahrscheinlichkeitsdichte  $p(\mathbf{x}_k | \mathcal{Z}^{k-1})$  abzuleiten ist.
2. Erfolgt während des ersten Versuches keine Detektion, so muss doch dieses negative Resultat genutzt werden. Dazu wird die konditionale Dichte der Zielrichtung für den Fall „keine Detektion bei gegebener Keulenposition“ bestimmt werden. Dieses Event werde bezeichnet durch:  $\neg D_k^1$ .



3. Eine Anwendung der Bayesschen Regel ergibt unmittelbar:

$$p(\mathbf{d}_k | \neg D_k^1, \mathcal{Z}^{k-1}) \propto (1 - P_D(\mathbf{d}_k; \mathbf{b}_k^1)) p(\mathbf{d}_k | \mathcal{Z}^{k-1}) \quad (37)$$

bis auf einen durch Normierung zu bestimmenden Faktor. In diesem Ausdruck hängt die Detektionswahrscheinlichkeit  $P_D$  von dem erwarteten SNR (Gl. (35)) ab und daher zugleich von der aktuellen Keulenausrichtung  $\mathbf{b}_k$  des Radars und Zielposition  $\mathbf{d}_k$ .

4. Die sich ergebende zweidimensionale Dichte  $p(\mathbf{d}_k | \neg D_k^1, \mathcal{Z}^{k-1})$  kann leicht auf einem Gitter berechnet werden. Die Keulenposition für die nächste Zielbeleuchtung ist durch das Maximum dieser Funktion gegeben.
5. Dieses Berechnungsschema für die Bayessche lokale Suche wird fortgesetzt, bis eine Detektion vorliegt. Weil nur das Maximum der Wahrscheinlichkeitsdichten  $p(\mathbf{d}_k | \neg D_k^1, \neg D_k^2, \dots, \mathcal{Z}^{k-1})$  gesucht wird, kann die Berechnung des Normierungsintegrals unterbleiben. Numerisch effiziente Realisierungen sind möglich.

Alternativ kann die Dichte  $p(\mathbf{d}_k | \neg D_k^1, \mathcal{Z}^{k-1})$  genutzt werden, um das erwartete SNR für eine bestimmte Richtung  $\mathbf{b}_k$  zu berechnen:

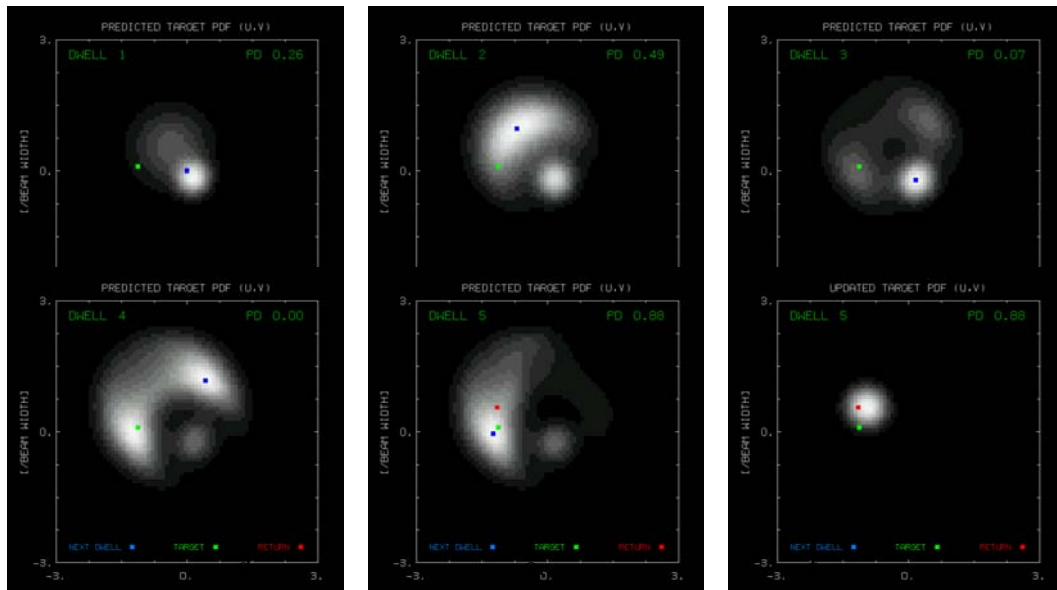
$$\text{SNR}(\mathbf{b}_k) = \int d\mathbf{d}_k \text{SNR}(\mathbf{b}_k, \mathbf{d}_k) p(\mathbf{d}_k | \neg D_k^1, \mathcal{Z}^{k-1}). \quad (38)$$

Die Maximierung von  $\text{SNR}(\mathbf{b}_k)$  führt zu unterschiedlichen lokalen Suchmustern. In dem Beispiel, das anschließend diskutiert wird, wurden jedoch keine signifikanten Verbesserungen beobachtet. Dennoch mag es Anwendungen geben, in denen die Maximierung von  $\text{SNR}(\mathbf{b}_k)$  anstelle der Dichte  $p(\mathbf{d}_k | \neg D_k^1, \neg D_k^2, \dots, \mathcal{Z}^{k-1})$  vorteilhaft ist, z. B. für die Aufgabe der Track Recovery bei intermittierend arbeitenden Betriebsmoden.

Dieses Schema nutzt negative Evidenz, da auch in diesem Fall das Ausbleiben einer erwarteten Sensormeldung Information über die aktuelle Zielposition enthält. Wir beobachten insbesondere, dass negative Sensorevidenz sich offenbar auf das Sensormanagement auswirkt. Auch hier bildet ein adäquates Sensormodell die Voraussetzung, um negative Evidenz nutzen zu können. Wie im Falle der Sensorauflösung impliziert die Nutzung negativer Sensorevidenz Mixture-Dichten mit möglicherweise negativen Koeffizienten; d. h. nicht jede individuelle Komponente besitzt eine unmittelbare probabilistische Deutung. Da sich die Koeffizienten jedoch korrekt auf Eins summieren, ist die volle Mixture wohldefiniert.

### 3.3 Diskussion anhand eines simulierten Beispiels

Abbildung 3 illustriert das besprochenen Schema der lokalen Suche für ein charakteristisches Beispiel. Abbildung 3a zeigt die prädizierte Wahrscheinlichkeitsdichte  $p(\mathbf{d}_k | \mathcal{Z}^{k-1})$  der Zielrichtung (u,v-Koordinaten) zu einer bestimmten Zeit  $t_k$ . Mit hoher Wahrscheinlichkeit wird das Ziel in der hellen Region erwartet. Die tatsächliche Zielrichtung ist durch einen grünen Punkt angezeigt. Der blaue Punkt markiert die Keulenposition für die nächste Zielposition.  $P_D$  beträgt 26%.



**Abb. 3.** Bayessche lokale Suche (Nutzung negativer Evidenz).

Während des ersten Beleuchtungsversuches erfolgt jedoch keine Detektion. Daher ist die konditionale Wahrscheinlichkeitsdichte  $p(\mathbf{d}_k | \neg D_k^1, \mathcal{Z}^{k-1})$  für dieses Ereignis zu berechnen. Das Ergebnis ist in Abbildung 3b dargestellt. Die resultierende Dichte unterscheidet sich signifikant von der Dichte  $p(\mathbf{d}_k | \mathcal{Z}^{k-1})$ , die in Abbildung 3a dargestellt ist und dieses neu verfügbare Wissen über den ersten erfolglosen Versuch noch nicht enthält. Das vorherige Maximum ist kleiner geworden, das globale Maximum befindet sich an einer anderen Stelle.

Wiederum bleibt die Zieldetektion aus. Die sich aus Verarbeitung dieses Sensor-Outputs ergebende Dichte  $p(\mathbf{d}_k | \neg D_k^1, \neg D_k^2, \mathcal{Z}^{k-1})$  enthält jetzt bereits zwei Elemente von negativer Evidenz,  $\neg D_k^1$  und  $\neg D_k^2$ , und ist in Abbildung 3c dargestellt. Nun entscheidet der Suchalgorithmus, erneut in der Nähe der ursprünglichen Keulenposition zu beleuchten. Obwohl dies im vorliegenden Fall falsch ist, ist dieser Versuch nicht unvernünftig; auch bei unmittelbarer Zielbeleuchtung ist die Entdeckungswahrscheinlichkeit in der Regel von Eins verschieden. Zusätzlich werden zwei kleine Nebenmaxima sichtbar, die in der nächsten Abbildung anwachsen (Abbildung 3d). Offenbar ist die nächste Entscheidung nicht eindeutig. Schließlich erfolgt eine Zielbeleuchtung, die zum Erfolg führt. Die letzte Abbildung zeigt die Wahrscheinlichkeitsdichte der Zielrichtung nach Verarbeitung der Messung.

#### 4 ‘Negative’ Evidenz und GMTI-Tracking

Luftgestütztes GMTI-Radar liefert Schätzungen der kinematischen Zielparame-  
ter bewegter Bodenziele sowie gewisse technische Sensorparameter wie aktuelle  
Messgenauigkeiten und die sogenannte Minimum Detectable Velocity (GMTI:  
Ground Moving Target Indicator). In derartigen Anwendungen ist mit Doppler-  
Blindheit als Folge der GMTI Clutter Notch zu rechnen. In Sinne der vorigen

Überlegungen kann auch dieses Phänomen im begrifflichen Rahmen der ‘negativen’ Sensorevidenz interpretiert und in seiner störenden Auswirkung auf den Tracking-Prozess gemildert werden. Die Diskussion betont die Relevanz der ‘negativen’ Evidenz im Hinblick auf Sensorfusion und Sensor-Scheduling.

#### 4.1 Detektionsmodell für GMTI-Radar

Auch nach Kompensation der Plattformeigenbewegung durch STAP-Filterung können sog. Low-Doppler-Ziele durch die Clutter-Notch eines GMTI-Radars maskiert werden [7]. Es bezeichne  $\mathbf{e}_k^p = (\mathbf{r}_k - \mathbf{p}_k)/|\mathbf{r}_k - \mathbf{p}_k|$  den Einheitsvektor, der von der Position der Sensorplattform  $\mathbf{p}_k$  zur Zeit  $t_k$  in Richtung eines Bodenfahrzeuges am Ort  $\mathbf{r}_k$  weist, das sich mit der Geschwindigkeit  $\mathbf{d}r_k$  bewegt. Der kinematische Zustandsvektor ist daher gegeben durch  $\mathbf{x}_k = (\mathbf{r}_k^\top, \mathbf{d}r_k^\top)^\top$ . Technisch formuliert, tritt Doppler-Blindheit auf, sobald die Radialgeschwindigkeiten des Ziels und des Main-Lobe-Clutters gleich sind, d. h. wenn die Funktion

$$h_n(\mathbf{r}_k, \mathbf{d}r_k; \mathbf{p}_k) = \frac{(\mathbf{r}_k - \mathbf{p}_k)^\top \mathbf{d}r_k}{|\mathbf{r}_k - \mathbf{p}_k|} \quad (39)$$

Null ergibt. In anderen Worten: Die Lage der GMTI Clutter Notch im Zustandsraum eines Bodenziels wird definiert durch die Gleichung

$$h_c(\mathbf{x}_k; \mathbf{p}_k) = 0 \quad (40)$$

und spiegelt als solche ein fundamentales physikalisch/technisches Phänomen wider ohne zunächst irgendwelche Modellannahmen zu implizieren. Jedes GMTI-Detektionsmodell muß demnach folgende Phänomene beschreiben:

1. Die Entdeckungswahrscheinlichkeit  $P_D$  hängt vom kinematischen Zustandsvektor der Bodenziele und der zugrundeliegenden Ziel-Sensor-Geometrie ab.
2.  $P_D$  ist klein in einer Umgebung der Clutter-Notch, die durch die Minimum Detectable Velocity (MDV) charakterisiert ist. Die MDV ist daher ein wichtiger Sensorparameter, der explizit in den Trackingprozess eingehen muss.
3. In großer Entfernung von der Clutter-Notch hängt die  $P_D$  nur von der Richtungscharakteristik des Sensors und der Zielentfernung ab.
4. Es gibt eine schmale Übergangsregion zwischen diesen beiden Bereichen.

Diese qualitative Diskussion der Detektionsphänomene, die sich auf die Existenz der Clutter-Notch beziehen, entspricht dem Vorgehen bei der Behandlung der Sensorauflösung (Abschnitt 2). Auch im hier erörterten Fall kann ein einfaches Modell formuliert werden, durch das der beschriebene physikalische Hintergrund im Wesentlichen korrekt wiedergegeben wird [10, 13]. Auch dieses Modell geht in eine spezifische Likelihoodfunktion ein, die ebenfalls als gewichtete Summe von Einzeltermen darstellbar ist. Man betrachte für eine vom kinematischen Zielzustand abhängige Entdeckungswahrscheinlichkeit den Ansatz:

$$P_D(\mathbf{x}_k; \mathbf{p}_k) = P_d \left( 1 - e^{-\log 2 \left( \frac{h_n(\mathbf{x}_k; \mathbf{p}_k)}{\text{MDV}} \right)^2} \right) \quad (41)$$

$$= P_d - P_d^n \mathcal{N}(0; h_n(\mathbf{x}_k; \mathbf{p}_k), R_n) \quad (42)$$

mit einem Detektionsparameter  $P_d^n$  und einer zugehörigen ‘Varianz’  $R_n$ , die gegeben sind durch:

$$P_d^n = P_d \sqrt{2\pi R_n}, \quad R_n = \text{MDV}^2 / (2 \log 2). \quad (43)$$

## 4.2 GMTI-spezifische Likelihoodfunktion

Der Diskussion im Einleitungsabschnitt folgend, wird der Filterungsschritt der Dichtepropagation durch die Likelihoodfunktion getrieben. Unter idealisierten Bedingungen ist sie durch folgenden Ausdruck gegeben (Einzelfahrzeuge, milde Clutter-Umgebung charakterisiert durch die räumliche Falschmeldedichte  $\rho_F$ ,  $m_k$  Sensormeldungen in jedem Datenscan  $Z_k = \{\mathbf{z}_k^j\}_{j=1}^{m_k}$ ) [2, 11]:

$$\ell(Z_k, m_k | \mathbf{x}_k) = (1 - P_D(\mathbf{x}_k; \mathbf{p}_k)) \rho_F + P_D(\mathbf{x}_k; \mathbf{p}_k) \sum_{j=1}^{m_k} \mathcal{N}(\mathbf{x}_k; \mathbf{h}(\mathbf{x}_k), \mathbf{R}) \quad (44)$$

$$= \ell_0(Z_k, m_k | \mathbf{x}_k) + \ell_n(Z_k, m_k | \mathbf{x}_k) \quad (45)$$

Hierin bezeichnet  $\ell_0(Z_k, m_k | \mathbf{x}_k)$  die Standard-Likelihoodfunktion, wie sie sich ohne Vorliegen einer Clutter-Notch ergibt:

$$\ell_0 = (1 - P_d) \rho_F + P_d \sum_{j=1}^{m_k} \mathcal{N}(\mathbf{x}_k; \mathbf{h}(\mathbf{x}_k), \mathbf{R}), \quad (46)$$

während die Funktion  $\ell_n(Z_k, m_k | \mathbf{x}_k)$  denjenigen Teil der Likelihoodfunktion repräsentiert, der für die GMTI-Problematik charakteristisch ist.  $\ell_n$  ist bestimmt durch:

$$\ell_n = \rho_F P_d^n \mathcal{N}(0; h_n(\mathbf{x}_k; \mathbf{p}_k), R_n) - P_d^n \sum_{j=1}^{m_k} \mathcal{N}(\mathbf{z}_k^{n_j}; \mathbf{h}_n(\mathbf{x}_k; \mathbf{p}_k), \mathbf{R}_n). \quad (47)$$

Die in diesem Ausdruck erscheinende Messgröße  $\mathbf{z}_k^{n_j}$ , die nicht-lineare Messfunktion  $\mathbf{h}_n(\mathbf{x}_k; \mathbf{p}_k)$  und die Messfehlerkovarianzmatrix  $\mathbf{R}_n$  sind gegeben durch:

$$\mathbf{z}_k^{n_j} = \begin{pmatrix} \mathbf{z}_k^j \\ 0 \end{pmatrix}, \quad \mathbf{h}_n(\mathbf{x}_k; \mathbf{p}_k) = \begin{pmatrix} \mathbf{h}(\mathbf{x}_k) \\ h_n(\mathbf{x}_k; \mathbf{p}_k) \end{pmatrix}, \quad \mathbf{R}_n = \begin{pmatrix} \mathbf{R} & \mathbf{O} \\ \mathbf{O} & R_n \end{pmatrix}. \quad (48)$$

## 4.3 Filterung unter Nutzung negativer Evidenz

Mit Hilfe der prädierten Dichte  $p(\mathbf{x}_k | \mathcal{Z}^{k-1})$  und der soeben Filterungsschritt gemäß der Bayesschen Regel:

$$p(\mathbf{x}_k | Z_k, m_k, \mathcal{Z}^{k-1}) = \frac{\ell(Z_k, m_k | \mathbf{x}_k) p(\mathbf{x}_k | \mathcal{Z}^{k-1})}{\int d\mathbf{x}_k \ell(Z_k, m_k | \mathbf{x}_k) p(\mathbf{x}_k | \mathcal{Z}^{k-1})}. \quad (49)$$

Nach der obigen Diskussion hängt die Likelihoodfunktion offenbar von den Sensordaten selbst, aber auch von der funktionalen Form des zugrundeliegenden Sensormodells und weiteren charakteristischen Sensorparametern ab. Eine Taylor-Entwicklung der nicht-linearen Funktionen  $\mathbf{h}(\mathbf{x}_k)$  und  $h_n(\mathbf{x}_k; \mathbf{p}_k)$  um den prädierten Zielzustand  $\mathbf{x}_{k|k-1}$  in erster Ordnung ergibt:

$$\mathbf{h}(\mathbf{x}_k) \approx \mathbf{h}(\mathbf{x}_{k|k-1}) + \mathbf{H}_k(\mathbf{x}_{k|k-1}; \mathbf{p}_k)[\mathbf{x}_k - \mathbf{x}_{k|k-1}] \quad (50)$$

$$h_n(\mathbf{x}_k; \mathbf{p}_k) \approx h_n(\mathbf{x}_{k|k-1}; \mathbf{p}_k) + \mathbf{H}_n(\mathbf{x}_{k|k-1}; \mathbf{p}_k)[\mathbf{x}_k - \mathbf{x}_{k|k-1}]. \quad (51)$$

Mit dieser Näherung erweist sich die Likelihoodfunktion als proportional zu einer Gaussian Mixture. Explizit ist die fiktive Messmatrix  $\mathbf{H}_n(\mathbf{x}_{k|k-1}; \mathbf{p}_k)$  gegeben durch:

$$\mathbf{H}_n(\mathbf{x}_{k|k-1}; \mathbf{p}_k) = \left. \frac{\partial h_n}{\partial \mathbf{x}_k} \right|_{\mathbf{x}_k = \mathbf{x}_{k|k-1}} \quad (52)$$

$$= \left( \frac{\mathbf{d}r_{k|k-1}^\top - (\mathbf{e}_{k|k-1}^{p\top} \mathbf{d}r_{k|k-1}) \mathbf{e}_{k|k-1}^{p\top}}{|\mathbf{r}_{k|k-1} - \mathbf{p}_k|}, \mathbf{e}_{k|k-1}^{p\top} \right), \quad \mathbf{e}_{k|k-1}^p = \frac{\mathbf{r}_{k|k-1} - \mathbf{p}_k}{|\mathbf{r}_{k|k-1} - \mathbf{p}_k|}. \quad (53)$$


Die sich daraus ergebende Struktur der approximierten Likelihoodfunktion vereinfacht die mathematische Behandlung des Filterungsschrittes erheblich. Insbesondere erweist sich auch die Wahrscheinlichkeitsdichte  $p(\mathbf{x}_k | \mathcal{Z}^k)$  nach Filterung als eine Gaussian Mixture.

Aus den gleichen Gründen wie bei der Verfolgung möglicherweise unaufgelöster Zielgruppen (Abschnitt 2) können negative Mixture-Koeffizienten auftreten. Diese Tatsache bringt zum Ausdruck, dass die Ziele im Falle ihrer Entdeckung einen gewissen Mindestabstand von der Clutter-Notch haben müssen, sonst wären sie ja nicht entdeckbar. Dennoch summieren sich auch die möglicherweise negativen Mixture-Koeffizienten korrekt zu Eins auf. Die Wahrscheinlichkeitsdichte  $p(\mathbf{x}_k | \mathcal{Z}^k)$  ist also wohldefiniert.

Orientiert an den Approximationsverfahren, die bei PDA oder IMM-Methoden eingesetzt werden [2], sind numerisch effiziente suboptimale Realisierungen möglich, durch die die Anzahl der auftretenden Mixture-Komponenten wirksam unter Kontrolle gehalten werden kann.

#### 4.4 Fusion negativer Sensorevidenz

Die obige Diskussion verdeutlicht, dass ‘negative’ Sensorevidenz, d. h. eine zwar erwartete, aber tatsächlich ausgefallene Detektion, Information über den kinematischen Zielzustand tragen kann. Eine ausgefallene Meldung besagt, dass sich das Ziel offenbar in einer Weise bewegt, in der es von der Clutter-Notch maskiert wird. Gemäß des GMTI-spezifischen Anteils der Likelihoodfunktion (Gl. (47)) ist diese Information formal äquivalent zu einer abstrakten fiktiven Messung einer Funktion des Zielzustands. Da die fiktive Messgröße  $h_n(\mathbf{x}_k; \mathbf{p}_k)$  explizit von der zugrundeliegenden Ziel-Sensor-Geometrie abhängt, ist zu erwarten, dass die Fusion fiktiver Messungen aus unterschiedlichen Sensorstellungen einen Beitrag zur Entdeckung anhaltender Ziele liefert. Daher kann man von einer „Triangulation“ von negativer Evidenz sprechen.



a. Ziel/Sensorplattformen    b. Detektionswahrsch.    c. Radialgeschw. (Boden, Ziel)

**Abb. 4.** Vereinfachtes Szenario für GMTI-Tracking.

**Vereinfachtes GMTI-Szenario.** Zur Veranschaulichung betrachten wir ein vereinfachtes GMTI-Szenario, das für die weiträumige Bodenaufklärung typisch ist. Abbildung 4a zeigt zwei fliegende Sensorplattformen, die ein bewegtes Bodenziel erfassen (Stand-off Surveillance, Gap-filling Mission). Die Revisit-Intervalle betragen 10 beziehungsweise 15 s.


Abbildung 4b stellt die Detektionswahrscheinlichkeit für beide Plattformen als Funktion der Zeit dar. In beiden Fällen zeigt die Detektionswahrscheinlichkeit einen tiefen Einschnitt, die sog. Clutter-Notch. Im zweiten Teil der Zeitachse ist die Detektionswahrscheinlichkeit für beide Sensoren einige Minuten lang Null. Dieses Verhalten wird verständlich durch Abbildung 4c, in der die Radialgeschwindigkeiten von Ziel und Main-Lobe-Clutter für beide Plattformen dargestellt sind. Solange beide Radialgeschwindigkeiten in etwa gleich sind, kann das Ziel nicht durch Dopplerverarbeitung vom Boden-Clutter getrennt werden. Für eine zentralisierte Fusionsarchitektur ergibt sich ein mittleres kumulatives Revisit Intervall von 6 s. Die gestrichelte Linie in Abbildung 4b beschreibt den zeitlichen Verlauf der entsprechenden mittleren kumulativen Entdeckungswahrscheinlichkeit bezogen auf das mittlere kumulative Revisit-Intervall.

Nach etwa 14 min hält das Fahrzeug an. Es kann daher von keinem der beiden Sensoren detektiert werden.

Die frühzeitige Entdeckung eines solchen Ereignisses ist möglicherweise von erheblichem militärischem Interesse. Es könnte einen Sensor-Request zur Produktion eines Spot-light-SAR-Bildes auszulösen, durch das die stationäre Szene analysiert werden kann.

**‘Triangulation’ mit negativer Evidenz.** Die Wahrscheinlichkeitsdichten in den Abbildung 5a und 5b beschreiben die Position des Ziels in ortsfesten kartesischen Koordinaten und wurden für jeden Sensor berechnet, nachdem das Fahrzeug bereits für einige Minuten angehalten war (siehe Abbildung 4a).

Die Dichte in Abbildung 5a ergibt sich aus der Verarbeitung der Daten des Sensors 1 einschließlich negativer Evidenz im beschriebenen Sinne; der Dichte in Abbildung 5b liegt die entsprechende Information von Sensor 2 zugrunde. Die Dissipation der Dichten ist offenbar in eine bestimmte Richtung beschränkt als Konsequenz der Verarbeitung von negativer Sensorevidenz. Beide Dichten sind etwas gegeneinander verdreht.



**Abb. 5.** Fusion negativer Evidenz für GMTI-Tracking.

Die Dichte in Abbildung 5c zeigt das Ergebnis nach Sensorfusion. Der Gewinn ergibt sich vornehmlich aus der unterschiedlichen Orientierung der Dichten in den Abbildungen 5a und 5b. Ein noch größerer Gewinn könnte erzielt werden, wenn sich die Dichten orthogonal schnitten. Aber auch in dem betrachteten Fall ist der Gewinn signifikant.

Obwohl keine gemessenen Daten zur Verfügung stehen, führt die Fusion der Ereignisse ‘target under track is no longer detected’ zu einer verbesserten Ziellokalisierung und ist eine unmittelbare Konsequenz der unterschiedlichen Ziel-Sensor-Geometrien.

## 5 ‘Negative’ Evidenz und Jamming

Die verfügbaren Freiheitsgrade eines Phased-Array-Radars gestatten insbesondere die Unterdrückung von Main-lobe-Störern durch adaptive Keulenformung [16]. Im Geiste der bisherigen Diskussion kann sowohl die aktuelle Jammer-Position als auch Information über die Verteilung der Monopulsmessungen in einem verfeinerten Sensormodell berücksichtigt werden, das etwa zur Beschreibung eines Fighter-Radars genutzt werden könnte [16].

Dadurch steht Hintergrundinformation über die Sensoreigenschaften auch auf der Ebene der Zielverfolgung zur Verfügung. Wie zuvor können erwartete, aber ausfallende Messungen eines im Schatten der Jammer-Notch angreifenden Missiles als ‘negative’ Sensorevidenz verarbeitet werden. Dadurch werden nicht nur die Genauigkeit und Kontinuität der Tracks oder das Aufgriffsverhalten bei der Spurextraktion verbessert, es ergeben sich auch Auswirkungen auf das Sensormanagement. Eine detailliertere Diskussion ist in [17] zu finden.

## 6 Zusammenfassung: Ergebnisse und Erfahrungen

Aus Diskussion verschiedener Anwendungsbeispiele lässt sich eine Reihe von Erkenntnissen ableiten, die für sich durchaus eine gewisse Allgemeingültigkeit in Anspruch nehmen können.

1. Erwarteter, jedoch aktuell ausbleibender, d. h. negativer Sensor-Output kann durchaus wertvolle Sensorevidenz über die momentane Zielposition oder eine abstraktere Funktion des kinematischen Zielzustands beinhalten.
2. ‘Negative’ Sensorevidenz fügt sich nahtlos in den Rahmen des Bayesschen Formalismus ein und kann mit anderer Information fusioniert werden. Es besteht also keine Notwendigkeit, empirische Ad-hoc-Lösungen einzuführen.
3. Wesentliche Voraussetzung für die Verarbeitung negativer Sensorevidenz bildet ein verfeinertes Sensormodell, durch das benötigte Hintergrundinformation zur Interpretation des aktuellen Sensor-Outputs bereitgestellt wird.
4. ‘Negative’ Sensorevidenz kann häufig durch Verarbeitung einer fiktiven Sensormessung beschrieben werden, die durch eine entsprechende Messmatrix mit zugehöriger fiktiver Messfehlerkovarianzmatrix charakterisiert ist.
5. Die jeweils besondere Gestalt der fiktiven Messgleichung ist durch die spezielle funktionale Form des konkret zugrundeliegenden statistischen Modells festgelegt, durch das die Sensor-Performance beschrieben wird.
6. Die fiktive Messfehlerkovarianz ist durch Sensorparameter wie die Sensorauflösung in Entfernung und Winkel, die Breite der Radarkeule, die Minimum Detectable Velocity (MDV) oder die Breite der Jammer-Notch festgelegt.
7. Die Verarbeitung negativer Sensorevidenz führt zu Wahrscheinlichkeitsdichten für die Zielzustände, die sich als Mixtures mit möglicherweise negativen Gewichtungsfaktoren erweisen, die sich jedoch korrekt zu Eins summieren, jedoch nicht mehr als Wahrscheinlichkeiten gedeutet werden können.
8. Anschaulich gesprochen, bringen Mixture-Komponenten mit negativen Gewichtungsfaktoren zum Ausdruck, dass die Ziele einen gewissen minimalen Abstand voneinander, von der letzten Position der Radarkeule oder der Clutter- bzw. Jammer-Notch einhalten.
9. Sobald die fiktive Messgleichung explizit von der zugrundeliegenden Ziel-Sensor-Geometrie abhängt, ist es in gewissem Sinne möglich, von einer ‘Triangulation’ oder Fusion negativer Evidenz zu sprechen.
10. Konkret nachgewiesen werden konnte der Nutzen negativer Sensorevidenz für folgende Beispiele: Verfolgung möglicherweise unaufgelöster Gruppenziele, lokale Suche für elektronisches Radar, Entdeckung anhaltender Bodenziele, Zielverfolgung bei Radar mit adaptive Nulling.

## Literatur

1. K. J. S. Agate. Utilizing negative information to track ground vehicles through move-stop-move cycles. In: *Signal Processing, Sensor Fusion, and Target Recognition XIII*, Proc. SPIE, Vol. 5429, 2004.
2. Y. Bar-Shalom, X.-R. Li und T. Kirubarajan. *Estimation with Applications to Tracking and Navigation*. Wiley & Sons, 2001.
3. S. Blackman und R. Popoli. *Design and Analysis of Modern Tracking Systems*. Artech House, 1999.
4. F. E. Daum und R. J. Fitzgerald. The importance of resolution in multiple target tracking. In: *Signal & Data Processing of Small Targets*, Proc. SPIE, Vol. 2235, S. 329, 1994.



5. G. van Keuk und S. Blackman. On phased-array tracking and parameter control. *IEEE Trans. Aerospace and Electronic Systems*, 29(1), 1993.
6. T. Kirubarajan, Y. Bar-Shalom, W. D. Blair und G. A. Watson. IMM-PDAF solution to benchmark for radar resource allocation and tracking targets in the presence of ECM. *IEEE Trans. Aerospace and Electronic Systems*, 35(4), 1998.
7. R. Klemm. *Principles of space-time adaptive processing*. IEE Publishers, London, UK, 2002.
8. W. Koch. Advanced sensor models: Benefits for target tracking and sensor data fusion. In: *Proc. International Conference on Multisensor Fusion and Integration for Intelligent Systems MFI 2006*, Heidelberg, September 3-6, 2006.
9. W. Koch. On negative information in sensor data fusion: Discussion of selected examples. In: *Proc. 7th International Conference on Information Fusion*, Stockholm, June 2004.
10. W. Koch. GMTI-Tracking and Information Fusion for Ground Surveillance. In: *Signal & Data Processing of Small Targets*, Proc. SPIE, Vol. 4473, S. 381–393, 2001.
11. W. Koch. Target tracking. In: *Advanced Signal Processing Handbook: Theory and Applications for Radar, Sonar, and Medical Imaging Systems*, S. Stergiopoulos (Hrsg.), CRC Press, 2001.
12. W. Koch. On adaptive parameter control for phased-array tracking. In: *Signal & Data Processing of Small Targets*, Proc. SPIE, Vol. 3809, S. 444-455, 1999.
13. W. Koch und R. Klemm. Ground target tracking with STAP radar. *IEE Proceedings Radar, Sonar and Navigation Systems*, Special Issue: Modeling and Simulation of Radar Systems, 148(3), 2001.
14. W. Koch und G. van Keuk. Multiple hypothesis track maintenance with possibly unresolved measurements. *IEEE Trans. Aerospace and Electronic Systems*, 33(2), 1997.
15. S. Mori, C.-Y. Chong, E. Tse und R. P. Wishner. Tracking and classifying multiple targets without a priori identification. *IEEE Trans. Automatic Control*, 31:401, 1986.
16. U. Nickel. Performance measure for monopulse with space-time adaptive processing. In: *Proc. NATO-RTO Symposium on Target Tracking and Data Fusion for Military Observation Systems*, Budapest, Oktober 2003.
17. W. Blanding, W. Koch und U. Nickel. On adaptive phased-array tracking in presence of main-lobe jammer suppression. In: *Proc. 9th Conference on Information Fusion*, Florence, July 2006.
18. B. Ristic und N. Gordon. *Beyond Kalman Filtering*. Wiley, 2004.
19. P. W. Sarunic und R. J. Evans. Adaptive Update Rate Tracking using IMM nearest neighbour algorithm incorporating rapid re-looks. In: *IEE Proceedings of Radar, Sonar, and Navigation*, 144(4), 1997.
20. H. Sidenbladh. Multi-target particle filtering for the probability hypothesis density. In: *Proc. 6th Conference on Information Fusion*, S. 800–806, Cairns, 2003.
21. D. M. Titterton, A. F. M. Smith und U. E. Makov. *Statistical Analysis of Finite Mixture Distributions*. John Wiley & Sons, 1985.



# Fusion von Sensordaten zur Umfeldwahrnehmung für Fahrerassistenzsysteme — eine Übersicht

Jan Becker

Robert Bosch GmbH, Corporate Research and Advance Engineering, Vehicle Safety and Assistance Systems (CR/AEV), Robert-Bosch-Str. 2, D-71701 Schwieberdingen

**Zusammenfassung.** Dieser Artikel gibt eine Übersicht über den Einsatz von Verfahren der Sensordatenfusion in Systemen zur Fahrerassistenz. Assistenzsysteme in Kraftfahrzeugen lassen sich in Komfort- und Sicherheitssysteme sowie in aktive und passive Systeme unterteilen. Gemeinsame Grundlage für solche Systeme ist die Erfassung des Fahrzeugumfeldes durch Sensoren. Aufgrund eingeschränkter Leistungsfähigkeit der Wahrnehmung einzelner Sensoren kann es für fortgeschrittene Fahrerassistenzsysteme, insbesondere für Sicherheitssysteme, notwendig werden, die Daten eines Sensors mit denen eines anderen Sensors zu ergänzen oder zu plausibilisieren, um die Detektionssicherheit zu erhöhen. Ebenso kann es durch technologisch bedingt eingeschränkte räumliche Erfassungsbereiche einzelner Sensoren notwendig sein, mehrere gleiche oder verschiedenartige Sensoren zu einem System zu verknüpfen, um die Detektionsreichweite zu erweitern. Multisensor-Datenfusion ist daher eine der Schlüsseltechnologien zur Realisierung zukünftiger Fahrerassistenzsysteme.

## 1 Einleitung

Das steigende Verkehrsaufkommen verlangt jedem Autofahrer eine immer höhere Konzentration und schnellere Reaktionen ab. An diesem Punkt setzen Fahrerassistenzsysteme an: Komfortsysteme entlasten den Fahrer bei Routineaufgaben. Sie ermöglichen entspannteres und damit sichereres Fahren. Warnende Systeme unterstützen den Fahrer vor allem in komplexen Situationen und verhindern damit, dass er Gefahren übersieht.

Wie sehr solche Systeme zur Verkehrssicherheit beitragen können, belegen die Statistiken. Sie zeigen, dass komplexe Situationen viele Fahrer überfordern [22]:

- Bei rund 38 % der Verkehrsunfälle war der Fahrer abgelenkt oder müde.
- Fast jeder zweite Verkehrsunfall beruht auf einer Fehleinschätzung des Fahrers über die Verkehrssituation, das Verhalten des vorausfahrenden Fahrzeugs, die Fahrdynamik, das Wetter oder den Verlauf der Fahrspur.
- Am höchsten ist die Unfallgefahr bei Nacht. 40 % der tödlichen Unfälle ereignen sich nachts, aber nur 20 % des Verkehrsaufkommens entfallen auf diese Zeit.

Das Statistische Bundesamt hat festgestellt, dass 86 % der Unfallursachen bei den Unfällen mit Personenschäden in Deutschland im Jahr 2004 im Fehlverhalten der Fahrzeugführer liegen [29]. Die häufigsten Unfallursachen der Fahrzeugführer waren hiernach nicht angepasste Geschwindigkeit (17 %), Fehler beim Abbiegen, Wenden, Rückwärtsfahren, Ein- und Anfahren (15 %), Nichtbeachten der Vorfahrt bzw. des Vorranges entgegenkommender Fahrzeuge (15 %) sowie Abstandsfehler (11 %).

Gleichzeitig gibt es Bestrebungen von Seiten der Gesetzgebung. So fordert beispielsweise die Europäische Kommission im Rahmen der eSafety-Initiative [10] eine Reduzierung der Verkehrstoten in der EU von über 40.000 im Jahr 2000 um die Hälfte bis zum Jahr 2010.

Daraus leiten sich die Ziele für die Entwicklung von Fahrerassistenzsystemen ab: Sie sollen den Fahrer bei der Wahrnehmung und Interpretation des Verkehrsgeschehens bestmöglich unterstützen und in Grenzsituationen warnen oder aktiv eingreifen. Hierzu sind hoch auflösende Sensoren zur Fahrzeugumfelderfassung notwendig.

## 2 Klassifikation und Einordnung von Fahrerassistenzsystemen

Was sind Assistenzsysteme? Der Duden [5] beschreibt *assistieren* als „jemandem nach dessen Anweisungen zur Hand gehen“. Fahrerassistenzsysteme sollen den Fahrer also nach seiner Intention in den einzelnen Teilaufgaben der Fahrzeugführung unterstützen, ohne ihn in seiner Entscheidungsfreiheit einzuschränken oder ihn zu belasten. Erste Assistenzsysteme im Fahrzeug waren nach dieser Definition die Servosysteme wie z. B. Bremskraftverstärker und Servolenkung sowie Anzeigeleuchten wie beispielsweise die Öldruckkontrolle.

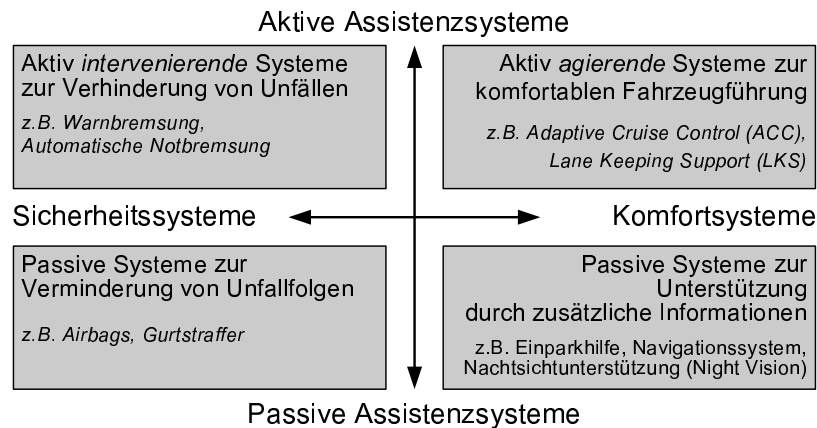
Aktuelle Assistenzsysteme können aufgrund ihres Unterstützungsgrades in verschiedene Klassen unterteilt werden [32]. *Automatisch intervenierende* Systeme sollen die Unzulänglichkeit des Fahrers bei der Fahrzeugführung ausgleichen und werden bisher nur bei der Stabilisierung des Fahrzeugs eingesetzt (ABS<sup>1</sup>, ESP<sup>2</sup>). *Automatisch agierende* Systeme dagegen werden vom Fahrer initiiert und führen dann Aktionen nach seinen Regeln und Vorgaben aus, beispielsweise ACC<sup>3</sup> [21]. Als weitere Klasse sind noch die *informierenden* Systeme zu nennen, die dem Fahrer zusätzliche, häufig für ihn nicht direkt zu erfassende Informationen zur Verfügung stellen. Dabei erfolgt teilweise bereits eine Wertung oder Aufbereitung der Information, wodurch eine *warnende* Funktion des Systems hinzukommt. Neben der reinen Information oder der Warnung kann aus der Aufbereitung der Information auch eine Empfehlung an den Fahrer erfolgen. Servosysteme schließlich erleichtern die Betätigung der Stellelemente des Fahrzeugs, werden aber heutzutage nicht mehr zu den Fahrerassistenzsystemen gerechnet.

---

<sup>1</sup> *Antilock Braking System*

<sup>2</sup> *Electronic Stability Program*

<sup>3</sup> *Adaptive Cruise Control*



**Abb. 1.** Einteilung von Assistenzsystemen.

Es ergibt sich schließlich eine Unterteilung von Fahrerassistenzsystemen nach Abbildung 1 in *aktiv* in die Fahrzeugführung eingreifende Systeme und *passiv* den Fahrer unterstützende Systeme, sowie in *Komfort-* und *Sicherheitssysteme*.

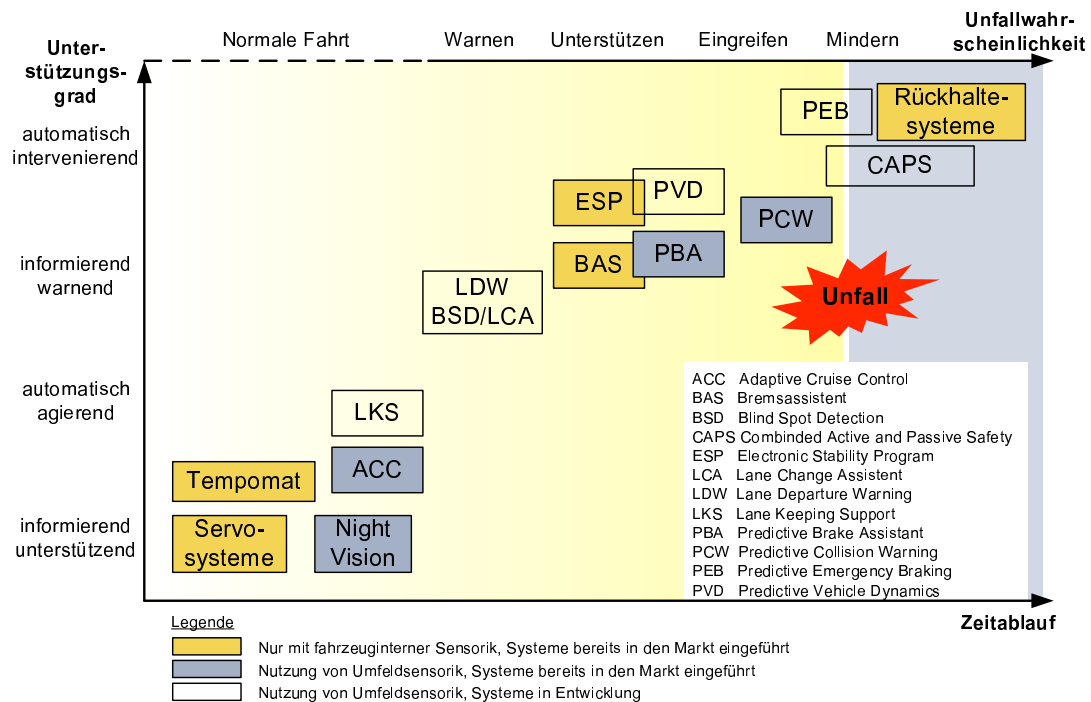
Bei den Systemen der passiven Sicherheit werden die Rückhaltesysteme<sup>4</sup> bislang nur aufgrund von extremen, nur beim Crash auftretenden Fahrzeugbeschleunigungen ausgelöst. Die Informationen zur Auslösung dieser Systeme kommen bislang alleine aus fahrzeuginterner Sensorik.

Systeme der aktiven Sicherheit sind bisher durch den Einsatz auf der Ebene der Fahrzeugstabilisierung gekennzeichnet. Bei ihnen kommt die Vorgabe durch den Fahrer, und das Assistenzsystem soll die Unzulänglichkeiten des Fahrers bei der optimalen Umsetzung ausgleichen. Prominente Beispiele sind das ABS, der Bremsassistent oder das ESP. Der Fahrer hat jederzeit die Möglichkeit, durch eine Zurücknahme seiner Vorgabe (z. B. durch das Lösen der Bremse bei der ABS- oder Bremsassistent-Unterstützung) die Wirkung des Systems aufzuheben. Die Informationen, die diese Assistenzsysteme nutzen, sind auf den Fahrzustand und die Fahrervorgabe beschränkt, die Fahrzeugumgebung wird nicht berücksichtigt, siehe hierzu auch Abbildung 2.

### 3 Fahrerassistenzsysteme mit Umfeldwahrnehmung

Mit der Entwicklung neuer Technologien der Umfelderkennung für Kraftfahrzeuge eröffnet sich ein großes Potenzial für weiterführende Fahrerassistenzsysteme, die nicht mehr alleine den eigenen Fahrzustand, sondern auch die Relation zu anderen Objekten oder zur Fahrbahn berücksichtigen können. Die Basistechnologien für die Umfeldwahrnehmung sind Lidar, Radar und Bilderfassung/Bildverarbeitung.

<sup>4</sup> wie z. B. Airbags oder Gurtstraffer



**Abb. 2.** Einordnung von Assistenzsystemen nach dem Unterstützungsgrad.

## Unterstützende Komfortsysteme

Eingeführt wurden diese Sensortechnologien zunächst über unterstützende Assistenzsysteme, die während der normalen Fahrt fahrerinitiiert automatisch agieren oder informieren. Beispiel hierfür ist *Adaptive Cruise Control* (ACC), das in Erweiterung des konventionellen Fahrgeschwindigkeitsreglers (Tempomat) nicht nur eine vom Fahrer gesetzte Geschwindigkeit hält, sondern ggf. die Geschwindigkeit reduziert, um zu einem vorausfahrenden Fahrzeug einen sicheren Abstand einzuhalten [21]. Derzeit ist der Wirkungsbereich dieser Funktion auf moderate Beschleunigung und Verzögerungen innerhalb eines definierten Geschwindigkeitsbereichs begrenzt. Der Fahrer hat die Aufgabe und die *Verantwortung* der Systemüberwachung und muss übersteuern, wenn ein erforderlicher Eingriff in die Fahrzeugführung außerhalb der Systemgrenzen, d. h. außerhalb des Wirkungsbereichs liegt. Ein Sicherheitsgewinn tritt somit nur indirekt durch die Entlastung des Fahrers auf. Das Potenzial, das sich durch die zusätzlichen Informationen über die Fahrzeugumgebung für die Unfallfolgenminderung und Unfallvermeidung andeutet, lässt den Schritt zur Darstellung auch von warnenden oder automatisch intervenierenden Systemen sinnvoll erscheinen.

Weitere Komfortsysteme, die den Fahrer bei der Querführung, also bei der Führung des Fahrzeugs in der Fahrspur unterstützen, befinden sich derzeit in der Entwicklung und kurz vor der Marktreife bzw. gerade in der Einführung. Hierzu zählen beispielsweise Systeme zur Spurverlassenswarnung (LDW<sup>5</sup>) oder

<sup>5</sup> *Lane Departure Warning*

zur Überwachung des sog. toten Winkels (BSD<sup>6</sup>) sowie der darauf aufbauende Spurwechselassistent (LCA<sup>7</sup>).

### Prädiktive Sicherheitssysteme

Derzeit befinden sich die ersten *aktiven Sicherheitssysteme* zur Verhinderung oder Verminderung von Unfällen in der Markteinführung [23]. Bereits realisiert ist der Prädiktive Bremsassistent (PBA<sup>8</sup>). Das System wertet Daten aus der Umweltwahrnehmung eines Radarsensors wie Relativgeschwindigkeit und Relativabstände zu anderen Fahrzeugen sowie Informationen über den eigenen Fahrzustand aus. In Situationen, in denen ein Notbremswunsch sehr wahrscheinlich scheint, wird für den Fahrer unmerklich die Bremsanlage vorbegefüllt, die Bremsbeläge werden an die Scheiben angelegt und die Ansprechschwelle des hydraulischen Bremsassistenten wird herabgesetzt.

Die Prädiktive Kollisionswarnung (PCW<sup>9</sup>) befindet sich gerade in der Einführung. In ungefähr der Hälfte aller Kollisionen prallen die Fahrer ungebremst auf das Hindernis auf. Ergänzend zu den PBA-Maßnahmen warnt PCW rechtzeitig vor kritischen Verkehrssituationen und kann somit zur Vermeidung vieler Unfälle beitragen. In Gefahrensituationen, die eine direkte Reaktion des Fahrers auf die Warnung erfordern, kann das System je nach Ausprägung einen kurzen, spürbaren Bremsruck auslösen, ihn durch optische oder akustische Signale warnen oder ihn durch ein kurzes Anziehen des normalerweise lose anliegenden Sicherheitsgurtes auf die Situation aufmerksam machen. Der Fahrer wird auf diese Weise rechtzeitig vor einem drohenden Aufprall gewarnt, um Gegenmaßnahmen wie z. B. ein Brems- oder Ausweichmanöver einleiten zu können.

Aufbauend auf den ersten beiden Entwicklungsstufen PBA und PCW befindet sich schließlich ein System zur unfallfolgenvermindernden Bremsung (PEB<sup>10</sup>) in der Entwicklung, das bei einer unvermeidbaren Kollision mit einem vorausfahrenden Fahrzeug eine automatische Notbremsung mit maximaler Verzögerung auslöst. Damit wird insbesondere die Unfallschwere reduziert, wenn der Fahrer nicht oder nur unzureichend auf die vorausgegangenen Warnungen reagiert hat.

Noch weiterführende Sicherheitssysteme werden in Zukunft möglicherweise einen Unfall durch eine Notbremsung verhindern können. Bei einem vollständig autonom eingreifendem Sicherheitssystem geht im Falle einer Auslösung die *Verantwortung* vom Fahrer auf das System über, sofern der Fahrer keine Möglichkeit mehr besitzt, den Eingriff in die Fahrzeugführung zu unterbinden oder zurückzunehmen. Folglich gelten beim Entwicklungsprozess und der Realisierung solcher Funktionen extrem hohe Anforderungen an die Systemsicherheit, d. h. insbesondere eine extrem niedrige Fehlauflöserate solcher Systeme muss realisiert werden. Es ist zu erwarten, dass dies in absehbarer Zeit mit einem Sensor alleine nicht umgesetzt werden kann.

<sup>6</sup> *Blind Spot Detection*

<sup>7</sup> *Lane Change Assistant*

<sup>8</sup> *Predictive Brake Assistant*

<sup>9</sup> *Predictive Collision Warning*

<sup>10</sup> *Predictive Emergency Braking*

## 4 Umfeldwahrnehmung für Fahrerassistenzsysteme

Es wurde bereits im vorigen Abschnitt festgestellt, dass die etablierten Technologien zur Umfeldwahrnehmung für Fahrerassistenzsysteme Lidar, Radar und Bilderfassung mit Bildverarbeitung sind. Diese Technologien weisen jeweils spezifische Eigenschaften auf, die zu Vor- und Nachteilen bei der Realisierung von Assistenzsystemen beitragen, siehe Tabelle 1.

**Lidarsensoren** Lidarsensoren ermitteln den Abstand zu einem reflektierenden Objekt direkt durch Messung der Laufzeit des ausgesendeten Signals. Aufgrund der Wellenlänge im Infrarot-Bereich ist eine gewisse Abhängigkeit der Erfassungsreichweite von den Umweltbedingungen gegeben. Zusätzlich hängt die Erfassungsreichweite von den Reflexionseigenschaften des zu detektierenden Zieles ab. Lidarsensoren mit feststehenden Strahlen sind relativ kostengünstig zu realisieren, scannende Lidarsensoren (Laserscanner) ermöglichen dagegen (zumindest horizontal) eine hohe Auflösung und einen großen Erfassungswinkel.

**Radarsensoren** Radarsensoren für Kraftfahrzeuge sind bereits seit einigen Jahren in Serie und in der Entwicklung entsprechend fortgeschritten; siehe Abbildung 3. Durch eine Erfassungsreichweite von über 200 m und die weitgehende

**Tabelle 1.** Qualitativer Vergleich der unterschiedlichen Sensortechnologien.

	<b>Lidar</b> Feststrahl / scannend	<b>Radar</b>	<b>Video</b> Stereo / Mono
<b>Wellenlänge</b>	Nahes Infrarot	77 GHz	Sichtbares Licht bis nahes Infrarot
<b>Wirkprinzip</b>	aktiv	aktiv	passiv
<b>Reichweite</b>	+	++	o
Beeinträchtigung durch Verschmutzung	o	+	o
Wetter	o	+	o
<b>Messgrößen (Messprinzip)</b>			
Abstand	+ (direkt, Laufzeit)	+ (direkt, Laufzeit)	- (indirekt, Triangul./ Größenvergl., ...)
Geschwindigkeit	- (Ableitung Abstand)	+ (direkt, Freq. -versch.)	- (Änderung Abstand/ Größe)
Ausdehnung	- / +	-	+ / o (nur Breite)
<b>Detektionsfähigkeit</b>			
Spurinformation	o	-	+
Objektdetektion	+	+	+
Objektklassifikation	- / o	-	++ (Mustererkennung)
Mehrzielfähigkeit	o / +	+	++
Verkehrszeichen	-	-	+
Personen	o (nur indirekt)	-	+





**Abb. 3.** Bosch Kfz-Fernbereichs-Radarsensor.



**Abb. 4.** Bosch Kfz-Videosensor.

Witterungsunabhängigkeit ist der Sensor prädestiniert als Basissensor zur Umfelderkennung für Assistenzsysteme. Radarsensoren ermitteln den Abstand zu einem Objekt ähnlich wie Lidarsensoren durch Messung der Laufzeit der ausgesendeten Welle. Weiterhin kann die Geschwindigkeit direkt durch Auswertung der Frequenzverschiebung (Doppler-Effekt) ermittelt werden.

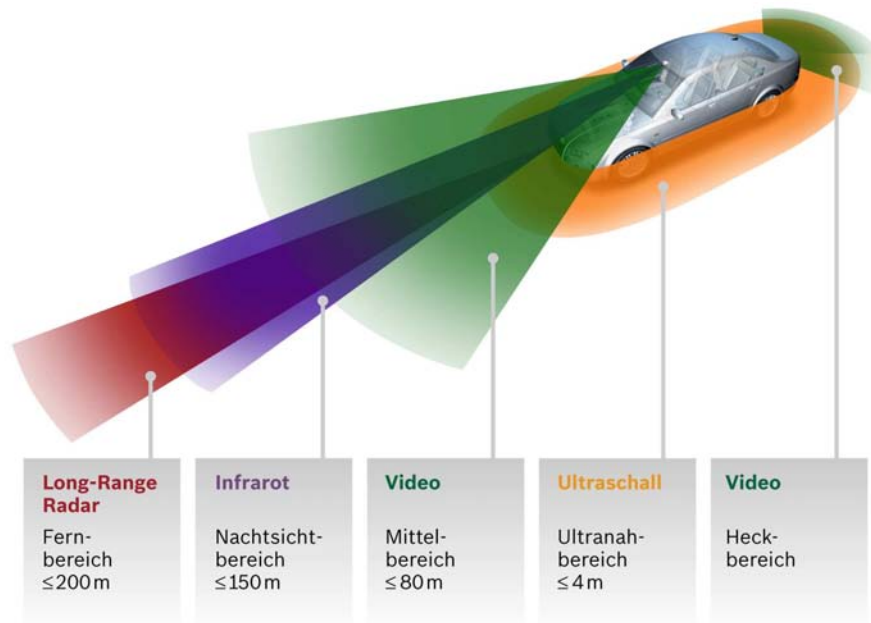
**Videosensoren** Videosensoren kommen der Umfeldwahrnehmung höherer Lebewesen am nächsten [30]. Die für die Fahrzeugführung insbesondere interessierenden Größen Abstand und Geschwindigkeit werden allerdings nicht direkt gemessen. Dafür besitzen die bereits verfügbaren Videosensoren über eine hohe zeitliche und räumliche Auflösung. Abbildung 4 zeigt eine Serien-Kfz-Videokamera mit VGA-Auflösung ( $640 \times 480$  Pixel). Gut geeignet sind Videosensoren zur Vermessung von geometrischen Objekten wie Fahrbahnmarkierungen, die i. d. R. bekannten Modellen [11] folgen. Insbesondere bei den für die Anwendung in Kraftfahrzeugen aus Kosten- und Handhabungsgründen besonders interessanten monoskopischen Verfahren ist eine direkte dreidimensionale Vermessung nur mit explizitem A-priori-Wissen möglich, beispielsweise durch Einsatz von Mustererkennung. Unbekannte Objekte können damit jedoch nicht unmittelbar vermessen werden. Jedoch gerade durch die Möglichkeit der Erkennung von optischen Mustern besitzen Videosensoren ein besonders großes Potenzial.

## 5 Motivation für den Einsatz von Sensordatenfusion

Warum braucht man nun Sensordatenfusion für Fahrerassistenzsysteme?

Bei den bisher realisierten Fahrerassistenzsystemen ist ein Sensor einer einzelnen Funktion zugeordnet, siehe Abbildung 6. Die Sensoren wurden weitgehend für eine bestimmte Funktion entwickelt, und die Leistungsfähigkeit der Funktion wurde im Wesentlichen<sup>11</sup> durch die Leistungsfähigkeit der Sensorik beschränkt.

<sup>11</sup> Hier seien rechtliche Beschränkungen außer Acht gelassen.



**Abb. 5.** Erfassungsbereiche der unterschiedlichen Sensortechnologien am Beispiel der Bosch-Sensoren.

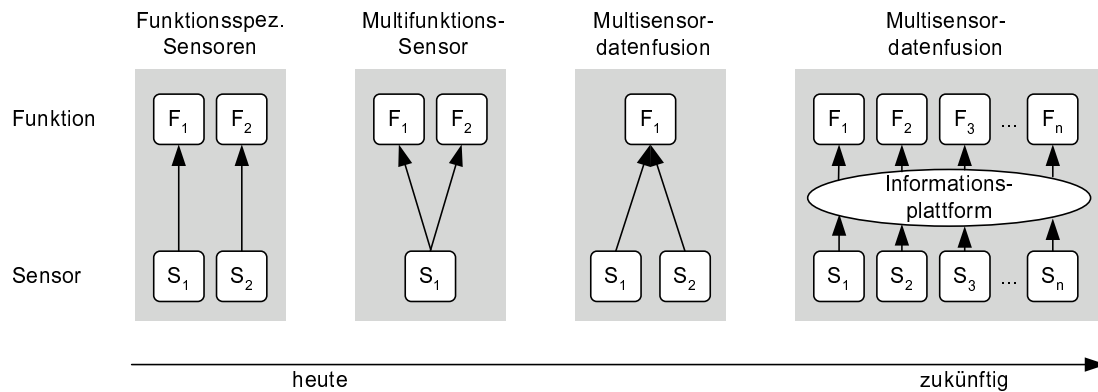
Ein Beispiel hierfür ist die Funktion ACC mit dem hierfür entwickelten Fernbereichsradarsensor.

Die neueren Sicherheitssysteme PBA und PCW verwenden vorrangig getrieben vom *Kosten/Nutzen-Aspekt* den gleichen Sensor, stellen aber grundlegend unterschiedliche Anforderungen an die Objektdaten und damit an die Umweltbeschreibung [20, 33].

Die Anforderungen an vollständig autonome Sicherheitssysteme werden in der Größenordnung von einer Fehlauflösung im Bereich von Betriebsjahren liegen, während bei Komfortsystemen, bei denen die Hoheit über die Fahrzeugführung weiter bei Fahrer liegt, Fehlerraten im Bereich einiger Betriebsstunden oder -tage als noch tolerabel erscheinen. Bei Sicherheitssystemen stellen also Anforderungen an die *Sensorfunktionalität* und *Systemsicherheit* die Treiber für ein Multisensorsystem zur Umgebungserfassung dar, woraus sich die Notwendigkeit einer Fusion der Sensordaten implizit ergibt.

Langfristig ist eine Informationsplattform im Kraftfahrzeug denkbar, die alle Sensoren und weiteren Informationsquellen, wie beispielsweise digitale Straßenkarten, zu einem Gesamtabbild der Fahrzeugumgebung verknüpft und diese Informationen den Funktionen zur Verfügung stellt [17].

Eine einfache Antwort auf die eingangs gestellte Frage lautet also: Nur mit Multi-Sensorsystemen und Verfahren der Sensordatenfusion werden beim aktuellen Stand der Sensortechnik fortgeschrittene Fahrerassistenzsysteme und insbesondere autonome eingreifende aktive Sicherheitssysteme zu realisieren sein.



**Abb. 6.** Systemevolution von Sensorsystemen zur Fahrzeug-Umfeldwahrnehmung.

## 6 Ebenen und Wirkungsweisen der Sensordatenfusion

### Ebenen

Die eingesetzten Verfahren zur Sensordatenfusion für Fahrerassistenzsysteme sind ganz wesentlich abhängig von der verwendeten Abstraktionsebene der Sensordaten.

Unter anderem in [1] wird zwischen vier verschiedenen Ebenen unterschieden, auf denen die Fusion von Daten mehrerer Sensoren betrieben werden kann. Dies sind die Fusion auf

- Signalebene,
- Pixel- oder Bildebene,
- Merkmalsebene<sup>12</sup> sowie
- Symbol- oder Objektebene.

Diese Ebenen unterscheiden sich durch die Art der Sensordaten, die an das Fusionsystem geliefert werden, durch das zugrunde gelegte Sensormodell, durch die für die Datenfusion verwendeten Methoden und schließlich dadurch, wie der Fusionsprozess die Qualität der Information erhöht. Es ist daher offensichtlich, dass die Fusionsebene und damit die Fusionsarchitektur direkt mit der Sensordatenebene und damit mit der Architektur der Umfeldwahrnehmung verbunden ist.

Nach der Informationstheorie optimal erfolgt die Verarbeitung aller Informationen auf Ebene der Sensorrohdaten und in einer zentralen Verarbeitungseinheit [13]. Eine solche Architektur ist sowohl wenig flexibel oder modular als auch aufgrund der hohen Datenraten der Rohdaten ungünstig.

Eine Fusion auf Objektebene ist insbesondere wegen des einfachen Aufbaus, der einfachen Vernetzung der Informationsquellen aufgrund niedriger Datenraten durch das hohe Abstraktionsniveau und der daraus resultierenden Modularität attraktiv. Allerdings ist der große Abstraktionsschritt im Sensor mit einem

<sup>12</sup> engl.: *feature level*

enormen Informationsverlust verbunden. Gleichzeitig steigt das Risiko einer fehlerhaften Abstraktion im Sensor durch unvollständige oder fehlerbehaftete Informationen oder durch bei der Abstraktion implizit gemachte aber unzutreffende Annahmen.

Es bietet sich als Kompromiss eine Fusion auf Merkmalsebene an. An einem Videosensor verdeutlicht stellen Merkmale beispielsweise horizontale oder vertikale Kanten oder Gebiete gleicher Textur im Bild dar. Die letztendlich für die Fahrzeugführung bedeutsame Entscheidung, ob diese Merkmale ein relevantes Objekt darstellen, auf das beispielsweise gebremst werden muss, trifft dann nicht der Sensor alleine, sondern der Fusionsalgorithmus unter Einbeziehung der Informationen aus allen verfügbaren Quellen.

### **Wirkungsweisen**

Ein weiterer wesentlicher Aspekt des Einsatzes von Sensordatenfusion ist die unterschiedliche räumliche und inhaltliche Sicht mehrerer Sensoren. Wird dieselbe reale Szene von mehreren unterschiedlichen Sensoren betrachtet, dann entstehen sowohl aufgrund einer unterschiedlichen räumlichen Perspektive durch unterschiedliche Anbauorte als auch durch die verschiedenen Messprinzipien möglicherweise unterschiedliche Messergebnisse. Diese können komplementär, redundant/konkurrierend oder auch kooperativ sein. Räumlich komplementäre Daten entstehen, wenn gleiche Sensoren in unterschiedliche Richtungen schauen. Inhaltlich komplementäre Daten entstehen dagegen, wenn Sensoren mit unterschiedlichen Messprinzipien die gleiche Szene betrachten. Durch redundante Daten lassen sich beispielsweise die Einflüsse stochastischer Messfehler verringern. Kooperativ arbeitet beispielsweise ein Stereo-Kamerasystem, das erst aus der Verarbeitung zweier Einzelbilder auf die Tiefeninformation schließen kann.

## **7 Anwendung von Verfahren zur Sensordatenfusion für Fahrerassistenzsysteme**

Es ist offensichtlich, dass aufgrund der beschriebenen Vielfalt sowohl bei Sensortypen, als auch den Abstraktionsebenen der Sensordaten, als auch bei den verschiedenen Wirkungsweisen der Sensoren miteinander eine sehr große Vielfalt an möglichen Verfahren besteht. Theoretisch optimale Verfahren [13] lassen sich aufgrund der sensorspezifischen Eigenschaften einerseits und der mitunter komplexen zu beobachtenden Szenarien andererseits nicht ohne weiteres in die Praxis übertragen. Im Folgenden werden daher nur einige Aspekte dieses Themas bezüglich des Anwendungsbereichs Fahrerassistenzsysteme aufgezeigt.

Es zeichnet sich ab, dass die verwendeten Verfahren sehr stark auf die jeweilige Sensorik angepasst vor allem dazu dienen, die jeweiligen Schwächen einzelner Sensoren durch einen weiteren Sensor zu ergänzen, um möglichst genau eine gegebene Funktionsspezifikation zu erreichen. Dieses Vorgehen ist primär getrieben vom hohen Kostendruck im Massenmarkt Kraftfahrzeuge.

In den folgenden Abschnitten werden exemplarisch einige der etablierteren Ansätze anhand von bereits in der Entwicklung befindlichen Systemen erläutert.

## Fusion auf Objektebene

Die Möglichkeiten der Fusion auf Objektebene sind vielfältig. Übersichten hierzu finden sich u. a. in [2, 6]. Gemeinsam ist allen Varianten, dass die grundsätzliche Entscheidung, ob eine Messung als Objekt interpretiert wird, bereits im Sensor gefällt wird. Durch die hohe Abstraktion lässt sich so eine sehr kompakte Beschreibung erreichen, die sich über bereits etablierte Bussysteme im Kraftfahrzeug übertragen lässt. Ein Objekt wird beispielsweise durch Position und Geschwindigkeit sowie falls sensierbar noch durch Ausdehnung und Ausrichtung beschrieben.

Durch den großen Abstraktionsschritt steigt jedoch die Wahrscheinlichkeit der fehlerhaften Interpretation der Messung, beispielsweise durch unvollständige oder fehlerbehaftete Informationen oder durch bei der Abstraktion implizit gemachte aber gerade unzutreffende Annahmen. Die hierbei entstehenden Fehlentscheidungen lassen sich mit den üblichen Sensorkonfigurationen im weiteren Verarbeitungsprozess meist nicht mehr korrigieren, so dass die von Sicherheitssystemen geforderten Fehlerraten mit dieser Verarbeitungsebene kaum erreicht werden können.

Hiermit im Zusammenhang steht auch die Beschreibung der Messunsicherheit<sup>13</sup> auf Objektebene. Eine verlässliche Angabe der Unsicherheit oder Konfidenz ist aufgrund der großen Abstraktion erfahrungsgemäß schwierig. Eine weitere Schwierigkeit bei der Fusion von inhaltlich komplementären Sensordaten ist das Problem der Datenzuordnung unter Berücksichtigung der Unsicherheiten. Für punktförmige Objekte (also beispielsweise Objekte eines Radarsensors) wird dies i. d. R. durch sogenannte Fangbereiche<sup>14</sup> gelöst [6]. Abstandsmaße werden dazu verwendet, die Ähnlichkeit (oder Unähnlichkeit) zwischen Beobachtungen zu quantifizieren. Der Euklidische Abstand ist zwar intuitiv und einfach zu berechnen, vernachlässigt aber die Messunsicherheit. Etabliert haben sich daher die Mahalanobis-Distanz, welche den Euklidischen Abstand mit der inversen Kovarianzmatrix gewichtet, sowie die Chernoff- und die Bhattacharyya-Distanz, welche die Mahalanobis-Distanz weiter verallgemeinern [13]. Für ausgedehnte Objekte ist die Fusion auf Objektebene eher kompliziert, da je nach Messprinzip und abhängig von der Perspektive, aus der ein Sensor ein Objekt sieht, sich unterschiedliche Darstellungen ergeben [3, 4]. Die Datenfusion auf Objektebene bietet sich somit vorrangig für räumlich komplementäre Sensorkonfigurationen an, bei denen keine inhaltliche Datenfusion stattfindet.

## Fusion im Ortsraum

Insbesondere für Sicherheitssysteme scheint sich eine Sensordatenfusion im Ortsraum<sup>15</sup> als Alternative anzubieten. Das aus der Robotik bekannte „*Occupancy*

<sup>13</sup> Aufgrund der komplexen Verarbeitungsschritte von der Rohmessung bis zur Objektebene kann man auch von einer Objektschätzung und dementsprechend auch von der Schätzunsicherheit sprechen.

<sup>14</sup> engl.: *gates*

<sup>15</sup> engl.: *spatial fusion*

*Grid*<sup>4</sup>-Verfahren [9, 31] wurde auf die Fahrzeugführung übertragen [15, 19, 27]. Der interessierende Zustandsraum, beispielsweise bestehend aus Abstand, Winkel und Geschwindigkeit in einem bestimmten Bereich, wird in eine Anzahl diskreter Zellen zerlegt. Jede Zelle enthält als Attribut einen Wahrscheinlichkeitswert, der die Belegung der Zelle angibt. Sensormessungen, vorteilhafterweise Sensorrohdaten, werden dann als Wahrscheinlichkeitsverteilung in das Zellgitter eingetragen. Im Gitter bauen sich nun Gebiete mit hoher Belegungswahrscheinlichkeit und entsprechende Gebiete mit geringer Belegungswahrscheinlichkeit auf. Sowohl Mess- als auch Existenzwahrscheinlichkeiten lassen sich über die Wahrscheinlichkeitsverteilungen einfach und direkt nachvollziehbar abbilden. Die Zuordnung der Daten zueinander erfolgt implizit durch die Position der Zelle im Gitter. Die Diskretisierung des Zustandsraums dient dabei letztendlich nur zur Umsetzung des Verfahrens auf Digitalrechnern in Echtzeit.

In [15, 27] wird die Anwendung des Verfahrens sowohl zur Fusion von Laser-scanner-Einzelmessungen als auch zur Fusion von Daten von mehreren passiven Infrarotsensoren beschrieben. Ein ähnlichen Ansatz wird auch in [19] zur Fusion mehrerer Nahbereichsradarsensoren mit Video verwendet.

### **Fusion und Verifikation von Radar mit Video für Komfort- und Sicherheitsfunktionen auf Merkmalebene**

In [26] wird ein Sensordatenfusionssystem basierend auf einem Fernbereichs-Radarsensor (Abbildung 3) und einem monokularen Videosensor (Abbildung 4) vorgestellt. Der in der Fahrzeugfront eingebaute Radarsensor hat eine hohe Reichweite und einen horizontalen Erfassungswinkel von etwa  $16^\circ$ , während der Videosensor den Erfassungswinkel auf ca.  $40^\circ$  erweitert, dafür jedoch nicht im vollen Reichweitenbereich genutzt wird. Jedoch nicht nur aufgrund der unterschiedlichen Erfassungsbereiche, sondern insbesondere aufgrund der verschiedenen Messprinzipien ergänzen sich die Sensoren auf günstige Weise. Der nach dem FMCW-Verfahren arbeitende Radarsensor bestimmt Entfernungen und Geschwindigkeiten mit hoher Güte, während laterale Positionen im ungünstigen Fall nur auf eine Fahrzeugbreite genau sind, da die rückgestreute Leistung situationsabhängig unterschiedlich über das Objekt verteilt sein kann. Im Gegensatz dazu weist der Videosensor eine sehr hohe laterale Auflösung auf. Mit einem monokularen Videosensor ist es jedoch nicht möglich, Entfernungen bewegter Objekte direkt zu messen. Bei Kenntnis von vertikalem Verlauf der Fahrbahnoberfläche und Kenntnis von Kameraausrichtung bezüglich der Oberfläche ist eine Entfernungsbestimmung jedoch möglich, sofern Objekt und Fahrbahnoberfläche im Bild voneinander getrennt werden können.

Im zentralen Frontbereich bis zu einer Entfernung von ca. 80 m ergänzen sich die longitudinale Genauigkeit des Radarsensors und die laterale Genauigkeit des Videosensors. Hier übernimmt vorwiegend der Radarsensor als übergeordneter Sensor die Detektion von Objekten, während der Videosensor diese verifiziert und lateral vermisst. Diese Verifikation ist insbesondere in Sondersituationen von Bedeutung. Detektiert beispielsweise der Radarsensor ein ruhendes Objekt im eigenen Fahrschlauch, so liefert die Videosensorik den wesentlichen Beitrag

für die Entscheidung, ob auf das Objekt gebremst werden muss (beispielsweise bei Stauende) oder ob das Objekt für die Weiterfahrt kein Hindernis darstellt, z. B. bei einer metallisch beschichteten Lebensmittelverpackung oder einem Kanaldeckel. Die laterale Vermessung des Objekts kann dazu dienen festzustellen, ob dem Fahrer eine ausreichend breite Ausweichmöglichkeit verbleibt, um in diesem Falle von der Einleitung einer automatischen Notbremsung abzusehen.

Die Fusion findet hierbei auf Merkmalsebene statt. Ein wesentliches Merkmal ist der Bildfluss, wobei der durch die Eigenbewegung des Fahrzeugs entstehende Bildfluss subtraktiv berücksichtigt werden muss. Weitere verwendete Bildmerkmale sind solche, die auf das typische Aussehen von relevanten Objekten ansprechen und eine bestimmte Hypothese unterstützen. Für die Hypothese „Fahrzeuge“ sind diese Merkmale z. B. Symmetrie, Kanten und deren Verteilungen, Abmessungen und Verhältnisse, Schatten und Beleuchtung. Daneben werden Merkmale genutzt, die eine Gegenhypothese stützen, beispielsweise wenn die betrachtete Bildregion ein Aussehen wie „Straße“ hat.

Verarbeitet werden diese Merkmals-hypothesen durch eine geeignete Merkmalsfusion. Hierfür wird die Dempster-Shafer-Evidenztheorie [8, 24, 25] verwendet, die als eine Verallgemeinerung der Bayes-Theorie betrachtet werden kann und den Begriff der Unsicherheit einführt.

Gleichzeitig verringert sich i. Allg. die verbleibende Unsicherheit, sobald mehrere Sensoren kombiniert werden. Das Verfahren erlaubt es, beliebig viele solcher Sensoren in beliebiger Reihenfolge miteinander zu kombinieren. Es berücksichtigt stets auch die Gegenhypothese und zeigt die verbleibende Unsicherheit und in einem entsprechenden Konfliktmaß den bei der Fusion auftretenden Widerspruch auf.

## Fusion von Fahrspurinformationen

Die bisher betrachteten Systeme verarbeiten vorrangig Informationen der objekterkennenden Sensoren. Für Aufgaben der Fahrzeugquerführung in der Spur, wie beispielsweise die Fahrspurverlassenswarnung oder die Fahrspurhalteunterstützung, sind vor allem Informationen über die Position der Fahrzeugs relativ zur Fahrspur und über den weiteren Verlauf der Fahrspur von Interesse.

Sowohl videobasierte (siehe z. B. [12, 18]) als auch laserbasierte [28] Verfahren zur Fahrspurmarkierungsdetektion sind seit längerem in der Entwicklung und kurz vor der Serienreife. Diese Sensorsysteme funktionieren unter bekannten Randbedingungen sehr gut und mit hinreichender Reichweite, sind aber auf gut sichtbare Spurmarkierungen angewiesen. Gerade aber in Situationen, in denen ein Fahrer die Unterstützung durch ein Assistenzsystem besonders zu schätzen wüsste, ist diese Voraussetzung meist nicht gegeben, so in der Nacht, bei Regen oder bei schneebedeckter Straße.

Daher werden hier Ansätze verfolgt, um die videobasierte Fahrspurerkennung durch Informationen aus digitalen Straßenkarten [7] (beispielsweise aus zukünftigen Fahrzeugnavigationssystemen) als auch mit Informationen aus den Trajektorien von erkannten Umfeldobjekten [34] oder beidem [14] zu stützen.

## 8 Zusammenfassung und Fazit

Die Nutzung von Umgebungsinformationen des Fahrzeugs für zukünftige Fahrerassistenzsysteme und insbesondere für Sicherheitssysteme lässt ein großes Potenzial zur Steigerung der Verkehrssicherheit erwarten. Während sich Radarsensoren schon seit einigen Jahren als Sensorsystem etabliert haben, findet bei Video- und Lasersensoren gerade der Übergang zu Serienreife statt. Hierdurch ergibt sich die Möglichkeit des Einsatzes von Multisensorsystemen zu Umgebungserfassung. Sensordatenfusion stellt hierfür eine entscheidende Schlüsseltechnologie dar. Anhand von ausgewählten Veröffentlichungen wurde im letzten Abschnitt ein Überblick über die derzeit verwendeten Verfahren zur Sensordatenfusion für Fahrerassistenzsysteme gegeben.

### Literatur

1. M. A. Abidi und R. C. Gonzalez (Hrsg.). *Data Fusion in Robotics and Machine Intelligence*. Academic Press, 1992.
2. Y. Bar-Shalom und X.-R. Li. *Estimation and Tracking: Principles, Techniques and Software*. Artech House, 1993.
3. J. Becker. *Fusion der Daten der objekterkennenden Sensoren eines autonomen Straßenfahrzeugs*. VDI-Verlag, Fortschritt-Berichte, Reihe 8, Nr. 948, 2002.
4. J. Becker und M. Stämpfle. Fusion and Filtering of Multidimensional Objects for Driver Assistance Systems. In: *IEEE Intelligent Vehicles Symposium (IV2004)*, Parma, Italien, 2004.
5. Bibliographisches Institut, Mannheim. *Duden Fremdwörterbuch*. Dudenverlag, 1997.
6. S. Blackman und R. Popoli. *Design and Analysis of Modern Tracking Systems*. Artech House, 1999.
7. H. Cramer, U. Scheunert und G. Wanielik. A New Approach for Tracking Lanes by Fusing Image Measurements with Map Data. In: *IEEE Intelligent Vehicles Symposium (IV2004)*, Parma, Italien, 2004.
8. A. Dempster. A Generalization of Bayesian Interference. *Journal of the Royal Statistical Society*, 30:205–247, 1968.
9. A. Elfes. *Occupancy Grids: A Probabilistic Framework for Robot Perception and Navigation*. PhD thesis, Carnegie Mellon University, Pittsburgh, Pennsylvania, May 1989.
10. European Commission. eSafety Website. [http://europa.eu.int/information\\_society/activities/esafety](http://europa.eu.int/information_society/activities/esafety), 2006.
11. Forschungsgesellschaft für Straßen- und Verkehrswesen, Arbeitsgruppe Straßenentwurf (Hrsg.). *Richtlinie für die Anlage von Straßen, Teil Linienführung (RAS-L)*. FGSV Verlag, 1995.
12. J. Goldbeck und B. Hürtgen. Lane Detection and Tracking by Video Sensors. In: *IEEE Conference on Intelligent Transportation Systems*, Tokyo, Japan, 1999.
13. D. L. Hall. *Mathematical Techniques in Multisensor Data Fusion*. Artech House, Boston, MA, USA, 1992.
14. A. Klotz, J. Sparbert und D. Hötzer. Lane Data Fusion for Driver Assistance Systems. In: *International Conference on Information Fusion (Fusion 2004)*, Stockholm, Schweden, 2004.



15. D. Linzmeier, D. Vogt, R. Prasanna, M. Mekhaiela und K. Dietmayer. Probabilistic Signal Interpretation Methods for a Thermopile Pedestrian Detection System. In: *IEEE Intelligent Vehicles Symposium (IV2005)*, S. 12–16, Las Vegas, USA, 2005.
16. M. Maurer und C. Stiller (Hrsg.). *Fahrerassistenzsysteme mit maschineller Wahrnehmung*. Springer, 2005.
17. W. Niehsen, R. Garnitz, M. Weilkes und M. Stämpfle. Informationsfusion für Fahrerassistenzsysteme. In Maurer and Stiller [16], S. 43–58.
18. F. Paetzold, U. Franke und W. v. Seelen. Lane Recognition in Urban Environment Using Optimal Control Theory. In: *IEEE Intelligent Vehicles Symposium (IV2000)*, Dearborn, USA, 2000.
19. M. Pellkofer, G. von Wichert, U. Deml, T. Köhler und D. Zittlau. Sensor Data Fusion for Automotive Applications. In: *FISITA 2004 World Automotive Congress*, Barcelona, Spanien, 2004.
20. M. Randler, U. Wilhelm und B. Lucas. Anforderungen von Komfort- und Sicherheitsfunktionen an die Umwelthypothese der Umfeldsensorik. In: *Workshop Fahrerassistenzsysteme (FAS 2003)*, Leinsweiler, Pfalz, 2003.
21. Robert Bosch GmbH. Adaptive Cruise Control (ACC). <http://www.bosch-acc.de>, 2006.
22. Robert Bosch GmbH. Fahrerassistenzsysteme: Innovationen für Komfort und Sicherheit. <http://www.bosch.de/k>, 2006.
23. Robert Bosch GmbH. Predictive Safety Systems (PSS) – Fahrerunterstützung in unfallkritischen Situationen. <http://www.bosch-pss.de>, 2006.
24. G. Shafer. *A Mathematical Theory of Evidence*. Princeton University Press, 1976.
25. G. Shafer. Dempster-Shafer Theory. <http://www.glennshafer.com/assets/downloads/article48.pdf>, 2002.
26. S. Simon, W. Niehsen, A. Klotz und B. Lucas. Video-basierte Objekt-Detektion und Verifikation von Radar-Objekt-Hypothesen für Komfort- und Sicherheitsfunktionen. In: *Workshop Fahrerassistenzsysteme (FAS 2005)*, Walting, 2005.
27. M. Skutek und D. Linzmeier. Fusion von Sensordaten am Beispiel von Sicherheitsanwendungen in der Automobiltechnik. *at – Automatisierungstechnik*, 53(7):295–305, 2005.
28. J. Sparbert, K. Dietmayer und D. Streller. Lane Detection and Street Type Classification using Laser Range Images. In: *IEEE Conference on Intelligent Transportation Systems*, Sydney, Australien, 2001.
29. Statistisches Bundesamt. Unfallgeschehen im Straßenverkehr 2004,. [http://www.destatis.de/themen/d/thm\\_verkehr.php](http://www.destatis.de/themen/d/thm_verkehr.php), 2004. 22. August 2005.
30. C. Stiller. Fahrerassistenzsysteme – Von realisierten Funktionen zum vernetzt wahrnehmenden, selbstorganisierten Verkehr. In Maurer and Stiller [16], S. 1–20.
31. S. Thrun, W. Burgard und D. Fox. *Probabilistic Robots*. MIT Press, 2005.
32. M. Weilkes. Auslegung und Analyse von Fahrerassistenzsystemen mittels Simulation. Dissertation RWTH Aachen, 2000.
33. U. Wilhelm, R. Jordan, B. Lucas und M. Randler. Sicherheitsfunktionsspezifische Anforderungen an die Sensordatenauswertung – Sieht eine Sicherheitsfunktion die Umwelt anders als die Komfortfunktion? In: *Haus der Technik, Unfallvermeidung oder Einsatz von Insassenschutz-Systemen*, 2003.
34. Z. Zomotor und U. Franke. Sensor Fusion for Improved Vision Based Lane Recognition. In: *IEEE Conference on Intelligent Transportation Systems (ITSC 1997)*, Boston, USA, 1997.



# Akquisition, Repräsentation und Nutzung von Wissen in der Fahrerassistenz

Christian Duchow, Britta Hummel, Alexander Bachmann, Zongru Yang  
und Christoph Stiller

Universität Karlsruhe (TH), Institut für Mess- und Regelungstechnik,  
Engler-Bunte-Ring 21, D-76131 Karlsruhe

**Zusammenfassung.** Die Wahrnehmung der Fahrspur auf der Autobahn in Standardsituationen kann als gelöst betrachtet werden. Die vorgeschlagenen Lösungen lassen sich jedoch nicht auf innerstädtische Straßen und Kreuzungen übertragen. Den Grund dafür sehen wir darin, dass zu wenig Vorwissen in den Auswertungsprozess einfließt, und propagieren für alle nicht-trivialen Realwelt-Schätzprobleme eine hochgradig modellgestützte Auswertung. Wir schlagen eine Estimationsarchitektur zur innerstädtischen Kreuzungsdetektion vor, die eine ausdrucksstarke Wissensrepräsentation nutzt, um das Schätzproblem auf wenige Merkmalsdetektionen und eine Hypothesenverifikation zu reduzieren. Die vorgeschlagene Hypothesenverifikation basiert auf dem Merkmal der lokalen Orientierung im Bild. Erste Ergebnisse auf realen Testdaten werden präsentiert.


## 1 Einleitung

Das innerstädtische Kreuzungsszenario aus der Perspektive einer Fahrzeugkamera (siehe Abbildung 1) stellt wesentliche Herausforderungen für die videobasierte Wahrnehmung dar:

- eingeschränkter Sichtbereich von weniger als  $50^\circ$  mit Standardhardware im Gegensatz zu Kreuzungen von oftmals  $> 200 \text{ m}^2$  Fläche,
- Verdeckungen durch dichten Verkehr oder Bebauungen
- fehlende Merkmale durch fehlende Markierungen im Kreuzungsbereich,
- wechselnde Wetter- und Beleuchtungsbedingungen,
- eine Fülle von nichtmodellierten Objekten, welche als Rauschen in die Schätzalgorithmen eingehen,
- Notwendigkeit für einen hochdimensionalen Parameterraum aufgrund der komplexen Geometrie.

Die Kombination dieser Eigenschaften führt dazu, dass ein *schlechtgestelltes Schätzproblem* vorliegt. Diese Eigenschaften sind vielleicht die Hauptursache dafür, dass existierende Ansätze zur Fahrspurwahrnehmung (siehe z. B. [7–10]) bis jetzt nicht erfolgreich von Autobahnen auf komplexere Umgebungen übertragen wurden.

Wir formulieren die folgenden Arbeitshypothesen:

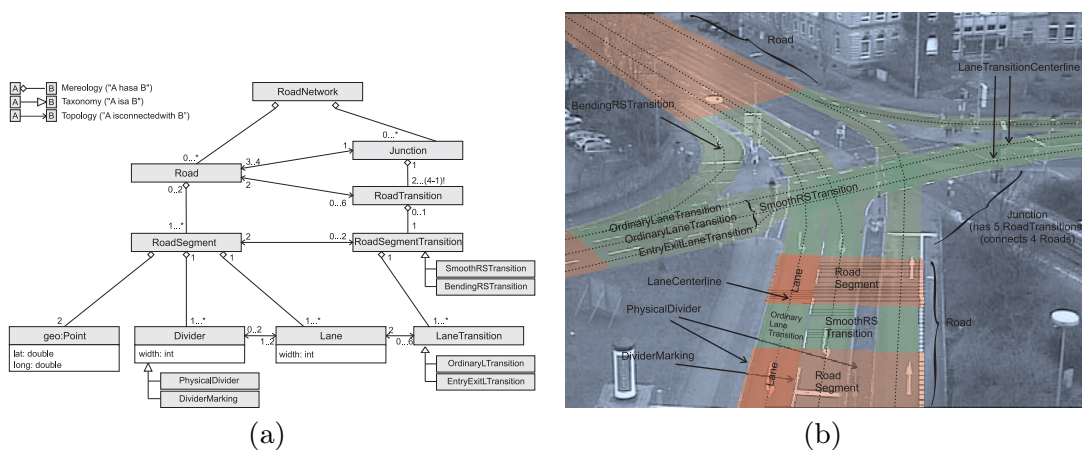


**Abb. 1.** (a) Kreuzung von einer Fahrzeugkamera mit einem Öffnungswinkel von  $45^\circ$  gesehen. Eine korrekte Erkennung der Kreuzungsstruktur ist selbst für einen menschlichen Beobachter kaum machbar. (b) Entsprechender Kartenausschnitt vom Vermessungsamt.

1. Erstens, eine ausdrucksstarke Wissensrepräsentation ist die Voraussetzung für eine videobasierte Kreuzungserkennung.
2. Zweitens, Wissen sollte nicht ausschließlich auf geometrischer, sondern zusätzlich auch auf konzeptueller Ebene repräsentiert sein. Die dadurch mögliche Hypothesengenerierung auf begrifflicher Ebene (z. B. „2-spurige Einbahnstraße trifft nach Fußgängerüberweg auf eine 3-armige Kreuzung!“) erlaubt den Einsatz flexiblerer und intelligenterer Merkmalstests.
3. Drittens, die Komplexität der Schätzaufgabe für die Videoverarbeitung muss durch intelligente und exzessive Nutzung der Wissensrepräsentation massiv reduziert werden.

Eine der wenigen Arbeiten, die terminologische und geometrische Modelle zur Kreuzungsdetektion anwenden, ist [4]. Die Terminologie wird hier jedoch lediglich zur Beschreibung des Detektionsergebnisses eingesetzt. In [1] wird ein geometrisches Modell kombiniert mit einer digitalen Karte zur Detektion eines speziellen Kreuzungstyps angewendet.

Im folgenden Abschnitt wird eine ontologiebasierte Wissensrepräsentation für den Diskursbereich *Roads&Junctions* eingeführt, von der eine ausdrucksstarke geometrische Kreuzungsmodellierung deduktiv ableitbar ist. In Abschnitt 3 wird eine Estimationsarchitektur zur Kreuzungserkennung auf Basis der Wissensrepräsentation vorgeschlagen, welche die Komplexität der Videoverarbeitung auf einige Merkmalsdetektionen und einen Hypothesentest reduziert. Abschnitt 4 beschreibt den videobasierten Hypothesentest. Erste Experimente des Hypothesentesters anhand einer auf Basis von „*Ground truth*“-Daten populierte Wissensrepräsentation werden in Abschnitt 5 vorgestellt.



**Abb. 2.** (a) Ontologie für den *Roads&Junctions*-Diskursbereich, visualisiert als UML-Diagramm. Klassen bezeichnen Konzepte, Pfeile bezeichnen Konzeptrelationen. Kardinalitäten sind exemplarisch für den Fall von maximal vier *Roads* pro *Junction* dargestellt. (b) Graphische Beschreibung der Konzeptsemantik.

## 2 Wissensrepräsentation für Straßen und Kreuzungen

Die Konzepte und Relationen des Diskursbereichs *Roads&Junctions* werden unter folgenden Gesichtspunkten modelliert: *Semantik* (Welche Bedeutung hat ein Konzept?), *Geometrie* (Wie sieht ein Konzept aus?), *Mereologie* (Welche Konzepte beinhalten welche anderen?), *Topologie* (Welche Konzepte sind verknüpft?), und *Taxonomie* (Welche Konzepte sind Spezialisierungen von anderen?).

Zur Definition der Konzeptsemantik wird, an Stelle einer umfangreichen textuellen Definition, auf Abbildung 2(b) für eine intuitive Beschreibung sowie auf [3] für weitere Erläuterungen verwiesen. Alle übrigen Gesichtspunkte sind nachfolgend detailliert.

### 2.1 Ontologie

Die konzeptuelle Modellierung definiert die für die Fahraufgabe relevanten Konzepte des Diskursbereichs *Roads&Junctions* sowie deren taxonomische, mereologische und topologische Relationen untereinander. Sie ist in Abbildung 2(a) visualisiert. Enthalten sind ausschließlich die Menge der für die Modellspezifikation *essentiellen Konzepte*. Deduktiv ableitbare Konzepte werden als *abgeleitete Konzepte* bezeichnet und an geeigneter Stelle eingeführt. Das konzeptuelle Modell entspricht dem Datenbasis-Schema.

### 2.2 Geometrisches Modell

Alle Geometrieparameter sind in der konzeptuellen Beschreibung gemäß Abbildung 2(a) enthalten. Ein *RoadSegment* ist ein durch Start- und Endkoordinaten spezifizierter Teil des Straßennetzes mit glattem Verlauf und konstanter Breite. Seine *Lanes* und *Dividers* liegen parallel, alternierend und lateral

zentriert im `RoadSegment`. Jede `Lane` hat eine lateral in der `Lane` zentrierte `LaneCenterline` (*abgeleitetes Konzept*). Sie entspricht der modellgemäß idealen Fahrzeugtrajektorie. Eine `SmoothRoadSegmentTransition` zwischen zwei `Lanes` bezeichnet einen vom Fahrer im Allgemeinen nicht wahrgenommenen, nahtlosen Segmentübergang. Die `LaneCenterline` aller derart verbundener `Lanes` wird gemeinsam durch parametrisch repräsentierte Hermite-Splines modelliert (siehe z. B. [6]):

$$\mathbf{r}_i(t) = (1 - 3t^2 + 2t^3) \cdot \mathbf{p}_i + (3t^2 - 2t^3) \cdot \mathbf{p}_{i+1} + (t - 2t^2 + t^3) \cdot \dot{\mathbf{r}}_i(0) + (-t^2 + t^3) \cdot \dot{\mathbf{r}}_i(1), \quad (1)$$

wobei  $t \in [0, 1]$ ,  $i = 1 \dots 2n - 1$  und  $n$  der Anzahl der `Lanes` entspricht. Deren  $2n$  Start- und Endpunkte sind die Kontrollpunkte  $\mathbf{p}_i$  des Splines. Für  $\mathcal{C}^2$ -Stetigkeit werden folgende Bedingungen eingeführt:

$$\dot{\mathbf{r}}_i(1) = \dot{\mathbf{r}}_{i+1}(0), \quad i = 1 \dots 2n - 2, \quad (2)$$

$$\ddot{\mathbf{r}}_i(1) = \left( \frac{\mathbf{p}_{i+1} - \mathbf{p}_i}{\mathbf{p}_{i+2} - \mathbf{p}_{i+1}} \right)^2 \cdot \ddot{\mathbf{r}}_{i+1}(0), \quad i = 1 \dots 2n - 2, \quad (3)$$

$$\ddot{\mathbf{r}}_1(0) = \ddot{\mathbf{r}}_{2n-1}(1) = 0. \quad (4)$$

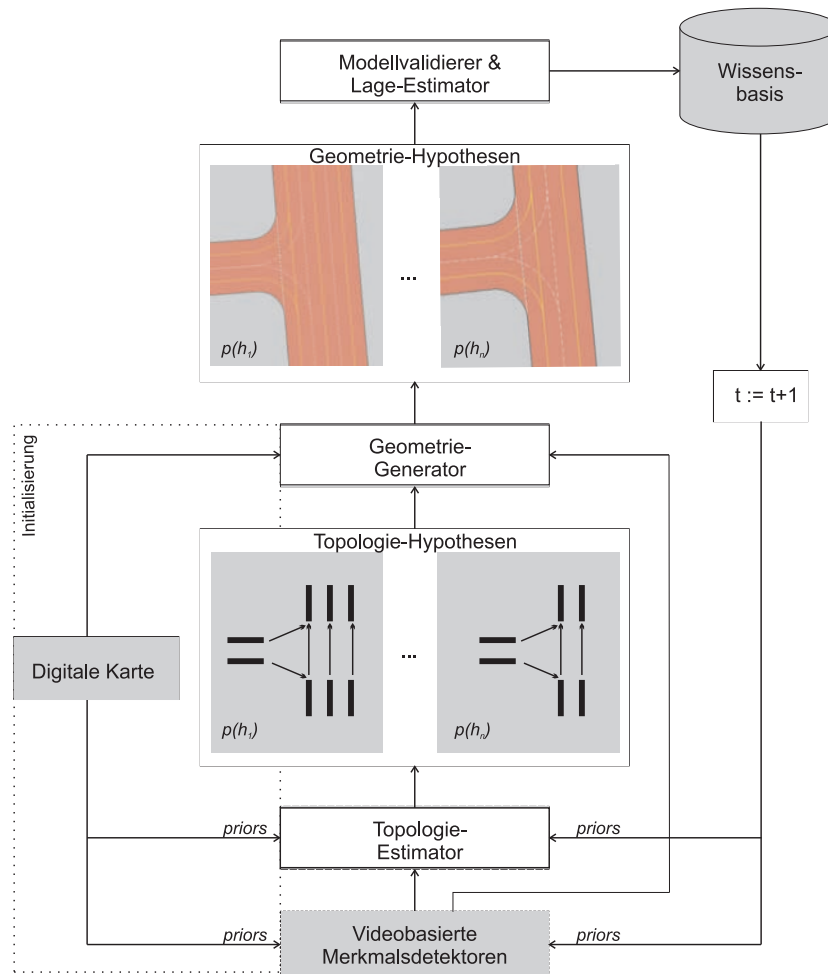
Die Gleichungen(1)–(4) definieren ein lineares Gleichungssystem mit  $4n - 2$  Unbekannten. Auflösung nach den Unbekannten  $\dot{\mathbf{r}}_i(1)$  und  $\dot{\mathbf{r}}_i(0)$  und Einsetzen in Gl. (1) ergibt die gesuchte Interpolationsfunktion. Die Form der `LaneCenterline` hängt demzufolge von den Koordinaten aller nahtlos verbundenen `Lanes` ab! Sind keine nahtlosen Übergänge vorhanden, so entspricht sie einem Geradensegment.

Die `LaneTransitionCenterline` (*abgeleitetes Konzept*) entspricht im Falle eines glatten Übergangs dem Teil des berechneten Splines im Übergangsbereich. Für den Fall einer `BendingRoadSegmentTransition` wird die `LaneTransitionCenterline` durch Kreisbögen modelliert. Derartige Übergänge sind stark gekrümmt und bedingen in der Regel ein Abbiegemanöver. Die Tangenten an den Enden der beiden `LaneCenterlines` entsprechen zwei Kreistangenten und bestimmen damit die Kreisbogenparameter.

Die `EntryExitLaneTransition` repräsentiert eine Spuraufweitung/-verengung (z. B. zu einem Beschleunigungsstreifen). Ihre `LaneTransitionCenterline` besitzt eine S-Form, welche durch Einfügen entsprechender Kontrollpunkte im Übergangsbereich erhalten wird.

Die `DividerCenterline` (*abgeleitetes Konzept*) wird äquivalent zur `LaneCenterline` definiert. Die `DividerTransitionCenterline` wird bewusst nicht eingeführt, da Fahrspur-Trennelemente im Kreuzungsbereich häufig fehlen.

Abschließend wird die `Lane`-Geometrie modelliert als eine Fläche von der Form der `LaneCenterline`, symmetrisch um diese aufgeweitet um die Spurbreite. Die `Divider` und `LaneTransitions` sind analog definiert. Für letztere gilt die Ausnahme, dass eine ungleiche Spurbreite der beiden verbundenen `Lanes` zu einer stetigen Breitenänderung führt. Die `RoadSegment`-Geometrie wird definiert als die Vereinigung aller `Lanes` und aller `Dividers`. Ein `RoadSegmentTransition`



**Abb. 3.** Estimationsarchitektur.

ist die Vereinigung aller LaneTransitions. Eine Junction ist die Vereinigung aller RoadTransitions ihrer Roads.

### 3 Estimationsarchitektur

Abbildung 3 zeigt die vorgeschlagene Estimationsarchitektur. Zur Initialisierung wird eine handelsübliche digitale Karte genutzt, die derzeit auch in Navigationssystemen eingesetzt wird. Sie liefert Informationen bezüglich der Anzahl sowie der Start- und Endkoordinaten der Roads an einer Kreuzung. Alle anderen Modellparameter sind nicht enthalten und werden in den folgenden Schritten geschätzt. Basierend auf anderen Karteninformationen wie der Fahrbahnklasse werden zur Initialisierung bereits schwache Annahmen in Form von heuristisch bestimmten A-priori-Wahrscheinlichkeitsdichteverteilungen formuliert. Damit ist der Schätzer auch beim vollständigen Fehlen von videoseitig detektierten Merkmalen arbeitsfähig, um den Preis einer sehr hohen Anzahl resultierender Geometrie-hypothesen.

Videobasierte Detektoren für die folgenden Merkmale werden als gegeben angenommen: Anzahl der **Lanes**, Markierungspfeile auf den **Lanes**, Fahrtrichtung auf den **Lanes**, Breite der **Lanes** und Breite der **Divider**. Gemeinsam mit den Kartendaten stellen sie die einzige Datenquelle zur Ableitung der Kreuzungsgeometrie Hypothesen dar. Die entsprechenden Schätzaufgaben werden als zum gegenwärtigen Forschungsstand realisierbar betrachtet. Aus den bereits in der Einleitung genannten Gründen werden viele dieser Parameter nicht beobachtbar sein oder sehr unsicherheitsbehaftete Schätzwerte liefern.

Die von den Merkmalsdetektoren geschätzten Parameter werden gemeinsam mit der Information über die Anzahl der **Roads** aus der Karte genutzt, um einen Satz von Topologiehypothesen zu generieren. Eine Kreuzungstopologie ist im folgenden Parameterraum formuliert: Anzahl der **Roads**, Anzahl der **Lanes** pro **Road** und Menge der erlaubten **LaneTransitions**. Nichtbeobachtete Parameter resultieren in einer erhöhten Hypothesenzahl.

Jede Topologiehypothese wird nachfolgend durch die deterministisch bzw. als Wahrscheinlichkeitsdichteverteilung gegebenen geometrischen Informationen ergänzt: die Start- und Endkoordinaten der **Road** bzw. die Breite von **Lanes** und **Dividern**. Eine der Konzeptualisierung aus Abbildung 2(a) entsprechende **Junction**-Instanz  $J_i$  ist damit vollständig bestimmt. Pro Topologiehypothese wird eine Geometriehypothese  $H_i$  entsprechend Abschnitt 2.2 generiert.

Jede Geometriehypothese wird mit dem Hypothesentester aus Abschnitt 4 mit dem Videobild verglichen. Gute Hypothesen werden in der Datenbasis gespeichert und für künftige Schätzungen als A-priori-Information verwendet.

## 4 Hypothesentester

Der Hypothesentester erhält als Eingabe einen Satz von Kreuzungsgeometrie Hypothesen  $H_i$  sowie eine Schätzung  $\hat{\mathbf{X}}_{\text{Welt}}$  zur Fahrzeugposition. Die Schätzung der Fahrzeugposition erfolgt durch Map-Matching wie in [2]. Es ist hier erweitert worden, indem das Map-Matching nicht mehr auf die Liniensegmente der digitalen Karte angewendet wird, sondern auf das generierte Geometriemodell. Die Aufgabe des Hypothesentesters ist die Überprüfung der gegebenen Hypothesen  $H_i$  anhand des gegebenen Grauwertbildes  $g(\mathbf{x}_R) = g(x_R, y_R)$  sowie die Präzisierung der Positionsschätzung zu  $\hat{\mathbf{X}}_{\text{Welt,neu}}$ . Die Schätzung der Position wird durchgeführt, indem der Raum der möglichen Positionen  $\mathbf{X}_{\text{Welt}}$  mit einer Auflösung von 45 cm abgetastet wird. Die Kreuzungsgeometrie Hypothesen  $H_i$  werden an jeder der erhaltenen Abtastpunkte  $\mathbf{X}_{\text{Welt},j}$  getestet. Damit ist ein Test  $T_{ij}$  definiert. Die Hypothese  $\hat{H}$  und die Position  $\hat{\mathbf{X}}_{\text{Welt,neu}}$  mit dem besten Testergebnis  $T_{ij}$  wird ausgewählt; auf diese Weise wird die Schätzung der Position verbessert.

Der Hypothesentester muss die vorhandenen, unsicherheitsbehafteten Informationen über die erwartete Kreuzungsgeometrie möglichst nutzbringend einsetzen und dabei weiter präzisieren. Manche Parameter sind nicht fehlerfrei geschätzt und werden nicht korrigiert, um die Dimensionalität des Suchraumes niedrig zu halten. Zum Beispiel kann die Fahrzeugorientierung oder die Breite




jeder einzelnen Spur fehlerbehaftet sein. Es ergibt sich die Forderung an den Hypothesentester, selbst dann noch ein sinnvolles Ergebnis zu liefern, wenn einzelne Parameter der Kreuzungshypothese fehlerbehaftet sind. Der Test muss tolerant gegenüber diesen Fehlern sein. Zur Durchführung des Tests werden die gegebenen Kreuzungsgeometrie-hypothesen  $H_i$  für jede der abgetasteten Positionspunkte  $\mathbf{X}_{\text{Welt},j}$  in das Videobild projiziert. Als die Bereiche mit besonderem Informationsgehalt werden jene Bereiche untersucht, in denen die Ränder der einzelnen Fahrspuren zu erwarten sind.

Aus der Information über die Kreuzungsgeometrie lassen sich Erwartungen an geeignete Videomerkmale ableiten. Eine Forderung an geeignete Videomerkmale ist die Invarianz gegenüber Einflüssen wie stärkere/schwächere Beleuchtung. Zweitens sollte es sich um ein flächenmäßiges Merkmal handeln, um eine Vielzahl aussagekräftiger Beobachtungen zu erhalten. Der Grauwert scheidet als Merkmal aus; unter entsprechenden Beleuchtungsbedingungen kann der Asphalt relativ hell sein, und umgekehrt können Markierungen relativ dunkel erscheinen. Der Betrag des Gradienten kommt als Merkmal ebenfalls nicht in Frage; an einer Kante ist der Betrag des Gradienten zwar ausgeprägt, jedoch nur direkt an der Kante. Wir wählen als Videomerkmal die lokale Orientierung, welche aus der Richtung des Eigenvektors zum größeren Eigenwert des Grauwertstrukturten-sors berechnet wird [11]. Die lokale Orientierung erfüllt nicht nur die genannten Anforderungen, sie bietet unter anderem noch den Vorteil, dass zum Beispiel auch beim Übergang von Straße zu Bürgersteig eine lokale Orientierung vorhanden ist. Daraus folgt, dass dieser Ansatz allgemeiner ist als einer, der explizit nach den Markierungen und damit nach hellen Bereichen sucht. Zu bemerken ist, dass wir nicht die Richtung des Gradienten betrachten, sondern gerade die Richtung der Kante, d. h. die Tangente der Kurven gleichen Grauwerts.

Wir stellen ein probabilistisches Modell zum Merkmal der lokalen Orientierung auf. Das Modell beschreibt zwei Klassen von Bildern. Dabei ist die eine Klasse gegeben durch die Bilder, die zu einer gegebenen Hypothese als korrekt zu klassifizieren sind. Die andere Klasse enthält jene Bilder, die nicht zu einer gegebenen Hypothese passen. Zum Merkmal der lokalen Orientierung wird ein Beobachtungsmodell formuliert. Über den Satz von Bayes gelangen wir schließlich zu einer Aussage, ob eine Hypothese wahrscheinlich die korrekte Hypothese zu einem gegebenen Bild ist.

Für den Hypothesentest sind nur jene Bildbereiche relevant, die in der Fahrbahnebene liegen. Um auszuschließen, dass bei dem Test Bereiche berücksichtigt werden, die zum Beispiel auf anderen Fahrzeugen in der eigenen Fahrspur liegen, detektieren wir zunächst die Bildbereiche, die in der Fahrbahnebene liegen. Das entsprechende Vorgehen ist im nächsten Abschnitt beschrieben. Abschnitt 4.2 beschreibt die Berechnung der erwarteten Orientierung. Abschnitt 4.3 beschreibt die Berechnung der vorhandenen Orientierung. Abschnitt 4.4 beschreibt den eigentlichen Test.



**Abb. 4.** Das Kameramodell und die benutzten Koordinatensysteme.  $\theta$  entspricht dem Nickwinkel der Kamera.  $h$  ist die Höhe des Kamerazentrums über der Fahrbahn.

#### 4.1 Detektion der Fahrbahnebene

Die Kenntnis der Fahrbahnebene, auf welcher das Fahrzeug sich bewegt, ist notwendig, um solche Bildbereiche von dem Hypothesentest auszuschließen, die außerhalb der Fahrbahnebene liegen. Wir modellieren die Fahrbahnebene als ebene Fläche, wie in Abbildung 4 schematisch dargestellt. Im globalen Koordinatensystem, welches hier mit dem Kamerakoordinatensystem der rechten Kamera zusammenfällt, wird die Ebene beschrieben durch

$$\mathbf{n}^T \mathbf{X} = h, \quad (5)$$

mit dem Ebenenpunkt  $\mathbf{X} = (X, Y, Z)^T$  in kartesischen Koordinaten und dem Parametervektor  $\mathbf{n} = (n_1, n_2, n_3)^T$ .  $h$  entspricht der Distanz vom Koordinatenursprung der Kamera zur Ebene und wird — zur Vereinfachung — im weiteren Verlauf der Herleitung auf  $h = 1$  gesetzt.

Mit Hilfe einer vollständig kalibrierten Stereokamera und der Beziehung

$$\mathbf{X} = \frac{b}{\Delta} \begin{bmatrix} x_R \\ y_R \\ f \end{bmatrix} \quad (6)$$

kann nun Gl. (5) in den Bildbereich transformiert werden.  $\Delta$  entspricht hier der Disparität,  $f$  ist die Brennweite der Kamera und  $b$  steht für die Basisbreite der Stereokameraanordnung. Als Bezugssystem dient die rechte Kamera. Durch die Transformation in den Bildbereich kann die hohe Fehlerempfindlichkeit bei der Ebenenschätzung mit zunehmender Szenentiefe verkleinert werden. Für die Ebenenschätzung wurde ein *Total-Least-Squares*-Ansatz (TLS) gewählt, der die orthogonalen Abstände zwischen gemessenem Ebenenpunkt und korrespondierendem Modellpunkt minimiert. Hierfür wird zuerst Gl. (5) mit Hilfe von Gl. (6) folgendermaßen umformuliert:

$$\frac{b}{d} n_1 x_i + \frac{b}{d} n_2 y_i - \Delta_i = -n_3 f. \quad (7)$$

Die Laufvariable  $i$  bezeichnet hier den jeweiligen Bildpunkt.  $d$  ist eine Normierungskonstante, die im weiteren Verlauf der Herleitung definiert wird.

Mit Gl. (7) kann angenommen werden, dass für einen gegebenen Parametersatz  $(\mathbf{n}, d)$  alle idealen und auf die Varianz  $\sigma$  normierten Beobachtungen

$$\mathbf{z}'_i = \begin{bmatrix} x_i/\sigma_x \\ y_i/\sigma_y \\ \Delta_i/\sigma_\Delta \end{bmatrix} = \begin{bmatrix} x'_i \\ y'_i \\ \Delta'_i \end{bmatrix} \quad (8)$$

in der gleichen Ebene  $\mathcal{P}$  liegen. Einsetzen von  $\mathbf{z}'_i$  in Gl. (7) ergibt

$$\underbrace{\frac{b}{d} n_1 \sigma_x x'_i}_{r_1} + \underbrace{\frac{b}{d} n_2 \sigma_y y'_i}_{r_2} - \underbrace{\sigma_\Delta \Delta'_i}_{r_3} = -n_3 f, \quad (9)$$

oder in Matrixform

$$\mathbf{r}^T \mathbf{z}'_i = -n_3 f. \quad (10)$$

Für einen beliebigen Punkt  $\mathbf{w}$  auf  $\mathcal{P}$ , d. h.  $\mathbf{r}^T \mathbf{w} = -n_3 f$ , ist der Abstand einer verrauschten Messung  $\hat{\mathbf{z}}'_i$  zur Ebene  $\mathcal{P}$  definiert durch

$$\text{dist}(\mathcal{P}, \hat{\mathbf{z}}'_i) = \left| \frac{\mathbf{r}^T}{\|\mathbf{r}\|} (\hat{\mathbf{z}}'_i - \mathbf{w}) \right|. \quad (11)$$

Hierbei wird angenommen, daß die Messungenauigkeiten in  $\mathbf{z}'_i$  unabhängig und homogen verteilt sind. Mit Gl. (11), der Definition  $\mathbf{r}'^T = \mathbf{r}^T/\|\mathbf{r}\|$  und der Randbedingung  $\|\mathbf{r}'\| = 1$ , kann nun das TLS-Kriterium folgendermaßen definiert werden:

$$J(\mathbf{r}', \mathbf{w}) = \sum_{i=1}^N (\mathbf{r}'^T (\hat{\mathbf{z}}'_i - \mathbf{w}))^2 \rightarrow \min. \quad (12)$$

Mit der Einführung des Zentroiden aller idealen Messungen, d. h.  $\bar{\mathbf{z}} = \frac{1}{N} \sum_i^N \hat{\mathbf{z}}'_i$ , wird aus Gl. (12):

$$\begin{aligned} J(\mathbf{r}', \mathbf{w}) &= \sum_{i=1}^N [\mathbf{r}'^T (\hat{\mathbf{z}}'_i - \bar{\mathbf{z}}) - \mathbf{r}'^T (\mathbf{w} - \bar{\mathbf{z}})]^2 \\ &= \sum_{i=1}^N [\mathbf{r}'^T (\hat{\mathbf{z}}'_i - \bar{\mathbf{z}})]^2 + \sum_{i=1}^N [\mathbf{r}'^T (\mathbf{w} - \bar{\mathbf{z}})]^2 \\ &\quad + \underbrace{2 \mathbf{r}'^T \sum_{i=1}^N (\hat{\mathbf{z}}'_i - \bar{\mathbf{z}}) \mathbf{r}'^T (\mathbf{w} - \bar{\mathbf{z}})}_{=0} \rightarrow \min. \end{aligned} \quad (13)$$

Für jedes  $\mathbf{r}'$  ist der erste Summand in Gl. (13) eine Konstante und der zweite Summand wird minimiert mit  $\mathbf{w} = \bar{\mathbf{z}}'_i$ . Die optimale Ebene  $\mathcal{P}$  geht somit durch den Zentroiden  $\bar{\mathbf{z}}$ .

Im weiteren Verlauf kann nun der erste Term in Gl. (13) als gewöhnliches *Least-Squares*-Problem behandelt werden:

$$J(\mathbf{r}', \hat{\mathbf{z}}'_i) = \sum_{i=1}^N [\mathbf{r}'^T (\hat{\mathbf{z}}'_i - \bar{\mathbf{z}})]^2 = \mathbf{r}'^T \sum_{i=1}^N (\hat{\mathbf{z}}'_i \hat{\mathbf{z}}'^T_i) \mathbf{r}' \rightarrow \min. \quad (14)$$

Die Lösung des Eigenwertproblems in Gl. (14) liefert den Eigenvektor  $\hat{\mathbf{r}}'$  und den dazugehörigen Eigenwert von  $\sum_{i=1}^N (\hat{\mathbf{z}}'_i \hat{\mathbf{z}}'^T_i)$ . Mit dieser Lösung wird Gl. (14) minimiert, und es kann  $\mathbf{r} = -\sigma_{\Delta} \hat{\mathbf{r}}' / \hat{r}'_3$  berechnet werden. Mit den Gln. (9)–(10) können danach die Ebenenparameter wie folgt bestimmt werden:

$$n_1 = r_1 \sqrt{\frac{1 - n_3^2}{r_1^2 + r_2^2}}, \quad n_2 = r_2 \sqrt{\frac{1 - n_3^2}{r_1^2 + r_2^2}}, \quad n_3 = -\frac{1}{f} \mathbf{r}^T \bar{\mathbf{z}} \quad (15)$$

und die Normierungskonstante

$$d = \frac{b n_1 \sigma_x}{r_1}. \quad (16)$$

Der Nickwinkel und die Höhe der Kamera über der geschätzten Fahrbahn können nun einfach aus den ermittelten Ebenenparametern extrahiert werden. Um die Schätzung robust gegen Ausreißer zu machen, wurde ein *Least-Median-of-Squares*-Verfahren in Kombination mit einem M-Estimator gewählt, welches bis zu einem Anteil von 50% an Ausreißern gute Ergebnisse liefert.


## 4.2 Die erwartete Orientierung

Für den Test  $T_{ij}$  ist die zu überprüfende Kreuzungsgeometriehypothese  $H_i$  beschrieben durch mehrere **Lanes**, welche wiederum durch ihre **LaneCenterlines** dargestellt werden. Eine **LaneCenterline** ist beschrieben durch eine Abfolge von Punkten in der zweidimensionalen, ebenen Welt. Wir betrachten ein Paar  $\mathbf{x}_i, \mathbf{x}_{i+1}$  aufeinanderfolgender Punkte der **LaneCenterline**. Die Bildpunkte werden auf die Fahrbahnfläche projiziert. Jene Bildpunkte, die neben dem Geradenstück  $\mathbf{x}_i, \mathbf{x}_{i+1}$  in einem Abstand liegen, der ungefähr der halben Spurbreite entspricht, werden für den Hypothesentest  $T_{ij}$  verwendet; siehe Abbildung 5.

In der Kreuzungsgeometriehypothese  $H_i$  ist die Spurtangente in vektorieller Beschreibung  $\Delta X_{\text{Welt}}, \Delta Y_{\text{Welt}}$  enthalten. Dieser Richtungsvektor lässt sich in das Bild umrechnen:

$$\Delta x_R = \frac{\partial x_R}{\partial X_{\text{Welt}}} \cdot \Delta X_{\text{Welt}} + \frac{\partial x_R}{\partial Y_{\text{Welt}}} \cdot \Delta Y_{\text{Welt}} \quad (17)$$

und für  $\Delta y_R$  ebenso. Mit  $\Delta x_R, \Delta y_R$  ist die Spurtangente im Bild in vektorieller Form beschrieben. Daraus folgt sofort die erwartete Orientierung  $\beta$  im Bild.



**Abb. 5.** Zur Berechnung der betrachteten Pixel. Gesucht werden die Pixel, die neben dem Geradenstück  $\mathbf{x}_i, \mathbf{x}_{i+1}$  in einem gewissen Abstand liegen.

### 4.3 Berechnung der vorhandenen Orientierung

Die Berechnung der vorhandenen Orientierung erfolgt wie in [11]. Der Grauwertstrukturtensor  $M(\mathbf{x}_R)$  ergibt sich zu:

$$M(\mathbf{x}_R) = \begin{bmatrix} \left(\frac{\partial g(\mathbf{x}_R)}{\partial x_R}\right)^2 & \left(\frac{\partial g(\mathbf{x}_R)}{\partial x_R}\right)\left(\frac{\partial g(\mathbf{x}_R)}{\partial y_R}\right) \\ \left(\frac{\partial g(\mathbf{x}_R)}{\partial x_R}\right)\left(\frac{\partial g(\mathbf{x}_R)}{\partial y_R}\right) & \left(\frac{\partial g(\mathbf{x}_R)}{\partial y_R}\right)^2 \end{bmatrix}, \quad (18)$$

wobei  $g(\mathbf{x}_R) = g(x_R, y_R)$  der Grauwert ist. Die lokale Orientierung ist gegeben durch

$$\alpha = \frac{1}{2} \arctan \left( \frac{2\left(\frac{\partial g(\mathbf{x}_R)}{\partial x_R}\right)\left(\frac{\partial g(\mathbf{x}_R)}{\partial y_R}\right)}{\left(\frac{\partial g(\mathbf{x}_R)}{\partial x_R}\right)^2 - \left(\frac{\partial g(\mathbf{x}_R)}{\partial y_R}\right)^2} \right) + \frac{\pi}{2}. \quad (19)$$

Die Eigenwerte  $\lambda_{1/2}$  von  $M(\mathbf{x}_R)$  geben an, wie ausgeprägt die lokale Orientierung in Richtung der entsprechenden Eigenvektoren ist.

### 4.4 Wahl der besten Hypothese und der besten Positionsschätzung

Aus den erwarteten Orientierungen  $\beta_k$  und den beobachteten Orientierungen  $\alpha_k$  bilden wir die Differenz und erhalten die beobachteten Größen  $e_k$ . Es gilt  $e_k \in [0, \pi/2)$ . Für den idealen Fall, dass die Kreuzungsgeometrie perfekt geschätzt wurde, dass sämtliche Spuren genauso markiert sind wie erwartet und darüber hinaus keine störenden Umwelteinflüsse vorhanden sind, sollten diese Fehler verschwinden. Wir haben bereits erwähnt, dass dieser ideale Fall nicht eintreten wird und dass der Test auch unter weniger günstigen Bedingungen erfolgreich verlaufen muss. Für den Fall, dass dem Hypothesentest ein Bild und eine Hypothese präsentiert werden, die keinen Zusammenhang aufweisen, sind alle Werte  $[0, \pi/2)$  für  $e$  gleich wahrscheinlich. Natürlich müssen die Fehler  $e_k$  für ein bestimmtes zusammenhangsloses Paar aus Bild und Hypothese nicht gleichverteilt sein. Zum Beispiel wird das Bild eines Zebrastrreifens ein deutliches Maximum im Histogramm der beobachteten Orientierungen aufweisen und damit

auch im Histogramm der Fehler  $e_k$ . Dieses Maximum wird aber wahrscheinlich nicht bei  $e \approx 0$  liegen.

Aus diesen Betrachtungen leiten wir die Wahrscheinlichkeitsdichteverteilung  $p_1(e)$  für den Fall ab, dass ein Zusammenhang zwischen Bild und Hypothese besteht. Ferner leiten wir die Wahrscheinlichkeitsdichteverteilung  $p_0(e)$  für den Fall ab, dass kein Zusammenhang zwischen Bild und Hypothese besteht. Wir wählen

$$p_1(e) = \frac{2 \cdot C_1}{\sigma\sqrt{2\pi}} \cdot e^{-\frac{e^2}{2\cdot\sigma^2}} + \frac{2}{\pi} \cdot (1 - C_1), \quad 0 < e < \pi/2. \quad (20)$$

Man erkennt, dass wir eine Mischung aus einer Gaußverteilung und einer Gleichverteilung für die Fehler gewählt haben.  $\sigma$  ist die Standardabweichung der Gaußverteilung. Der Parameter  $0 < C_1 < 1$  bestimmt die Gewichtung der beiden Verteilungen gegeneinander. Der gleichverteilte Anteil sorgt dafür, dass große Fehler  $e$ , welche durchaus möglich sind, nicht mit einer verschwindenden Wahrscheinlichkeit bestraft werden. Es fällt ferner auf, dass die Gaußverteilung zusätzlich einen Faktor 2 erhalten hat. Das ist nötig und sinnvoll, da die Gaußverteilung den Erwartungswert 0 besitzt und für die Fehler gilt:  $0 < e < \pi/2$ . Wir haben folglich den linken Teil der Gaußverteilung nach rechts gespiegelt, so dass das Integral der Wahrscheinlichkeitsdichteverteilung 1 ergibt.

Die Wahrscheinlichkeitsdichteverteilung für den Fehler  $e$  für den Fall, dass kein Zusammenhang zwischen Bild und Hypothese vorliegt, ist gegeben durch

$$p_0(e) = \frac{2}{\pi}, \quad 0 < e < \pi/2. \quad (21)$$

Die Wahrscheinlichkeit für Zusammenhang in Abhängigkeit der Fehler  $p_Z(e_k)$  ist gegeben mit

$$p_Z(e_k) = \frac{\prod_k p_1(e_k)}{\prod_k p_1(e_k) + \prod_k p_0(e_k)} \quad (22)$$

Gl. (22) lässt damit eine Aussage zu, ob eine bestimmte Kreuzungsgeometriehypothese  $H_i$  und die Position  $\mathbf{X}_{\text{Welt},j}$ , ausgedrückt durch den Test  $T_{ij}$  wahrscheinlich zu einem bestimmten Bild passt. Meistens unterscheiden sich  $\prod_k p_1(e_k)$  und  $\prod_k p_0(e_k)$  um Größenordnungen, so dass  $p_Z(e_k)$  für ähnliche Bilder praktisch gleich ist. Wir führen daher zur besseren Differenzierung die Größe

$$E = -\frac{1}{n} \log \left( \prod_k p_1(e_k) \right) \quad (23)$$

ein.

Im Folgenden wird kurz diskutiert, wie mit Bildbereichen umzugehen ist, in denen keine ausgeprägte Orientierung vorhanden ist. Bildbereiche, in denen eine deutliche Orientierung erwartet wurde und nicht vorhanden ist, sprechen gegen die zu testende Hypothese. Um das Ergebnis des Hypothesentests auf möglichst viele Beobachtungen zu stützen, würde man diese Information in das Testergebnis mit einfließen lassen. Unter der Annahme, dass eine schwach ausgeprägte

Orientierung zufällige Werte annimmt, sollte das dazu führen, dass die zu testende Hypothese als weniger wahrscheinlich bewertet wird. Allerdings sind die wenigsten Markierungen durchgezogen, so dass es zu jeder sinnvollen Hypothese Bereiche geben wird, in denen eine Orientierung erwartet und nicht beobachtet wird. Folglich darf eine fehlende Orientierung nicht überbewertet werden. Zusätzlich muss eine schwach ausgeprägte Orientierung nicht zufälliger Natur sein. Es kann durchaus vorkommen, dass größere Bildbereiche eine einheitliche, schwach ausgeprägte Orientierung besitzen. Für den Fall, dass diese schwach ausgeprägte Orientierung nahe der erwarteten Orientierung liegt, würde die Hypothese also durch völlig irrelevante Informationen gestützt werden. Diese Überlegungen führen dazu, nur solche Bereiche im Bild zu betrachten, die eine ausgeprägte Orientierung aufweisen. In dem Hypothesentest werden daher nur solche Pixel berücksichtigt, für die das Verhältnis der Eigenwerte von  $M(\mathbf{x})$  eine gewisse Schranke übersteigt:  $\frac{\lambda_1}{\lambda_2} > S$ . Diese Bedingung wird also zusätzlich zu der Bedingung gefordert, dass die betrachteten Bildbereiche in der Fahrbahnebene liegen sollen.

## 5 Evaluation

Detailliertere Experimente zu den Geometriemodellen alleine sind in [3] zu finden. Für die Durchführung unserer Experimente zum Hypothesentester haben wir auf Daten vom Vermessungsamt zugegriffen und nicht auf Daten aus der digitalen Karte; in der digitalen Karte ist die Anzahl der Fahrspuren nicht vermerkt, und die Schätzung der Fahrspuren aus dem Videobild wie geplant wurde nicht vorgenommen.

Abbildung 6(a) zeigt beispielhaft ein Bild zusammen mit der Kreuzungshypothese  $\hat{H}$  für die Schätzung der Position  $\hat{\mathbf{X}}_{\text{Welt}}$ , die der Hypothesentest ausgewählt hat. Die entsprechende Positionsschätzung ist gerade nicht die, die von dem Hypothesengenerator zur Verfügung gestellt wurde, sondern es ist der Abtastpunkt, welcher 45 cm nach links und 45 cm nach vorne verschoben ist. Man erkennt, dass die Hypothese einigermaßen gut mit dem Bild zusammenpasst. Insbesondere ist es diejenige Alternative unter den gegebenen Hypothesen und möglichen Positionen, die auch für einen menschlichen Betrachter die beste ist. Im Wesentlichen wird diese Hypothese durch die linke Markierung der eigenen Spur und die Markierung der kreuzenden Spur gestützt. Der Hypothesentest hat also die korrekte Hypothese zum Bild ausgewählt und damit die Positionsschätzung verbessert.

## 6 Zusammenfassung

Wir haben eine Estimationsarchitektur zur Generierung von Kreuzungstopologiehypothesen und Kreuzungsgeometrieypothesen aus digitalen Karten vorgeschlagen. Die Information aus der digitalen Karte soll mit möglicherweise vorhandenen Schätzwerten zur Anzahl der Fahrspuren und der Fahrspurbreite neben



**Abb. 6.** (a) Bild einer Kreuzung mit eingeblendeter Kreuzungshypothese. (b) Die entsprechende Karte vom Vermessungsamt dazu. Das Fahrzeug kommt aus dem linken Kreuzungsarm.

anderen Parametern aus dem Videobild ergänzt werden. Der Satz der generierten Kreuzungsgeometrie-hypothesen sowie die Schätzung zur Fahrzeugposition werden dann in einem Hypothesentester getestet. Der Hypothesentester beruht auf einem probabilistischen Modell zum Merkmal der lokalen Orientierung. Über ein Stereoverfahren wird zusätzlich der Bildbereich detektiert, der der Fahrbahnebene entspricht, um z. B. Bereiche auf anderen Fahrzeugen auszuschließen. Erste Experimente zeigen die Ausdrucksstärke der Wissensrepräsentation, der verwendeten Kreuzungsgeometriemodelle und die Aussagefähigkeit des Hypothesentests.

## Literatur

1. F. Heimes und H. H. Nagel. Towards active machine-vision-based driver assistance for urban areas. *International Journal of Computer Vision (IJCV)*, 50(1):5–34, 2002.
2. B. Hummel. Map matching for vehicle guidance. In: *Dynamic and Mobile GIS: Investigating Space and Time*, J. Drummond und R. Billen (Hrsg.). CRC Press, Florida, 2006.
3. B. Hummel et al. Nutzung konzeptueller Wissensrepräsentationen für videogestütztes Kreuzungsverstehen. *IT Schwerpunktheft Fahrerassistenzsysteme*, Oldenburg Wissenschaftsverlag, 2007.
4. K. Mueck. *Rechnergestützte Erkennung und Beschreibung innerstädtischer Straßenkreuzungen*. Dissertation, Universität Karlsruhe, 2000.
5. M. Schraut. *Umgebungserfassung auf Basis lernender digitaler Karten zur vorausschauenden Konditionierung von Fahrerassistenzsystemen*. Dissertation, TU München, 2000.
6. R. Zavodnik und H. Kopp. *Graphische Datenverarbeitung*. Hanser, München, 1995.
7. E. D. Dickmanns und B. D. Mysliwetz. Recursive 3-D road and relative ego-state recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 14(2):199–213, 1992.
8. R. Labayrade, S. S. Ieng und D. Aubert. A reliable road lane detector approach combining two vision-based algorithms. *IEEE Intelligent Transportation Systems Conference*, Washington D.C., USA, 2004.



9. K. Kluge und C. Thorpe. The YARF system for vision-based road following. *Math. Comput. Modelling*, 22(4), 1995.
10. M. Bertozzi und A. Broggi. GOLD: A parallel real-time stereo vision system for generic obstacle and lane detection. *IEEE Transactions on Image Processing*, 7(1), 1998.
11. J. Zhang und H.-H. Nagel. Texture-based segmentation of road images. In: *Proceedings of the Intelligent Vehicles '94 Symposium*, 260–265, 24–26 Oct. 1994.
12. J. J. Gibson. *The Perception of the Visual World*. Houghton Mifflin, Boston, 1950.



# Fusion von Radar- und Thermopilesensoren zur Fußgängerdetektion

Dirk Linzmeier und Tobias Bär

DaimlerChrysler AG, Group Research & Mercedes Car Group Development,  
D-71034 Böblingen-Hulb


**Zusammenfassung.** Viele fahrzeugtechnische Innovationen der letzten Jahrzehnte zielten auf die Vermeidung oder Verringerung von Personenschäden beim Unfall. Systeme der aktiven und passiven Sicherheit haben signifikant dazu beigetragen, dass die Zahl tödlicher Verletzungen der Fahrzeuginsassen stark zurückgegangen ist. Verstärkt ist die Automobilindustrie nun daran interessiert, die aktiven Sicherheitssysteme zum Schutz von gefährdeten Verkehrsteilnehmern voranzutreiben. Innovative Sicherheitssysteme sollen in der Zukunft durch aktive Maßnahmen dafür sorgen, dass Fußgänger im Straßenverkehr besonders geschützt werden. In diesem Beitrag wird ein System zur Fußgängerdetektion basierend auf Radar- und Infrarotsensoren vorgestellt. Hierbei liegt der Fokus vor allem auf den Methoden der Sensorsignalverarbeitung und der Sensordatenfusion mittels Dempster-Shafer-Theorie.

## 1 Einleitung

Viele fahrzeugtechnische Innovationen der letzten Jahrzehnte zielten auf die Vermeidung oder Verringerung von Personenschäden beim Unfall. Die sogenannte passive Sicherheit hat zu einem großen Teil dazu beigetragen, dass die Zahl tödlicher Verletzungen der Fahrzeuginsassen stark zurückgegangen ist. Mehr noch als bisher ist die Automobilindustrie daran interessiert, die aktiven Sicherheitssysteme zum Schutz von ungeschützten Verkehrsteilnehmern voranzutreiben. Innovative Sicherheitssysteme sollen in der Zukunft durch aktive Maßnahmen dafür sorgen, dass Fußgänger im Straßenverkehr besonders geschützt werden.

Des Weiteren kommt hinzu, dass es den Automobilherstellern ab dem 1. Oktober 2005 nicht mehr selbst überlassen bleibt, Maßnahmen zum Fußgängerschutz durchzuführen. Die europäischen Automobilhersteller haben sich in einer Gesetzesvorlage (2003/102/EC) gegenüber der europäischen Kommission verpflichtet, dass ab diesem Zeitpunkt alle Neufahrzeuge Testverfahren zum Fußgängerschutz bestehen müssen.

In diesem Artikel wird ein System zur Fußgängerdetektion basierend auf Radar- und Infrarotsensoren (*Thermopiles*) vorgestellt. Hierbei liegt der Fokus vor allem auf den Methoden der Sensorsignalverarbeitung und der Sensordatenfusion.



**Abb. 1.** Thermopilemodul mit integriertem ASIC.

Im Folgenden werden die einzelnen Abschnitte des Artikels kurz vorgestellt. Der Artikel beginnt mit der Beschreibung des Aufbaus des Fußgängerdetektionssystems (Abschnitt 2). Die sensorspezifische Signalverarbeitung wird in Abschnitt 3 kurz erläutert. Schwerpunkt des Artikels ist die Fusion der Radar- und Thermopile-Sensordaten, die in Abschnitt 4 beschrieben wird. Das Potential des Fußgängerdetektionssystems wird anhand einer statistischen Messdatenauswertung in Abschnitt 5 aufgezeigt.

## 2 Aufbau des Fußgängerdetektionssystems

Das in diesem Artikel beschriebene Fußgängerdetektionssystem besteht aus zwei Nahbereichsradaren und mehreren Thermopilesensoren, die im Frontbereich des Fahrzeugs angebracht sind. Die Radarsensoren liefern Ziele innerhalb eines Bereiches von etwa 30 m mit einem Öffnungswinkel von ca.  $60^\circ$ . Diese Ziele sind hauptsächlich durch Entfernung und Winkel gekennzeichnet. Die in diesem System verwendeten Radare detektieren Fußgänger bis zu einer Entfernung von ca. 15 m.

Thermopiles gehören zur Kategorie thermischer Detektoren und basieren auf dem Seebeck-Effekt. Ein Thermopilemodul (Abbildung 1) besteht aus einem Infrarotsensor (als Thermopile bezeichnet), einer optischen Abbildungseinheit (Spiegel oder Linse) und einem ASIC<sup>1</sup> zur Signalverarbeitung und zur Kompensation der Umgebungstemperatur. Am Ausgang des Moduls liegt eine Spannung proportional zur gemessenen Temperatur an.

Das Fußgängerdetektionssystem kann grundsätzlich in vier hierarchische Ebenen gegliedert werden (siehe Abbildung 2):

- **Physikalische Ebene:** Dieser Teil beschreibt die Interaktion der Sensoren mit der Umgebung, d. h., die Sensoren erfassen die von Objekten emittierte oder reflektierte Strahlung und wandeln diese in ein elektrisches Signal um. Dieses Signal wird je nach Sensortyp weiterverarbeitet und der nächst höheren Ebene bereitgestellt.
- **Sensorebene:** In diesem Teil findet die sensorspezifische Signalverarbeitung statt. Die von den Sensoren gelieferten Signale werden so verarbeitet, dass

<sup>1</sup> *Application Specific Integrated Circuit*. Darunter wird eine anwendungsspezifische integrierte Schaltung verstanden (Custom-Chip).

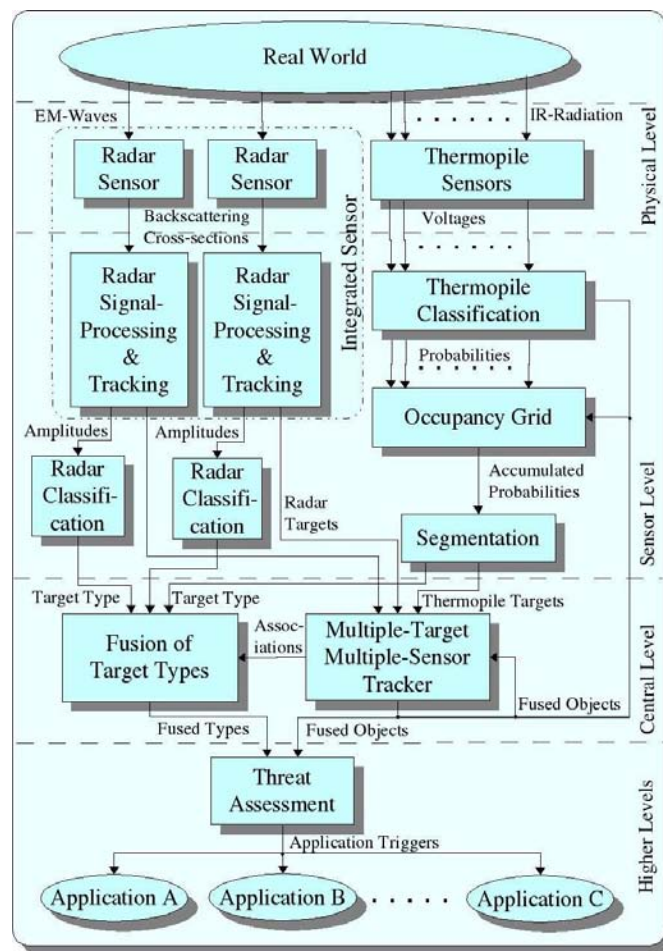



Abb. 2. Aufbau und hierarchische Einteilung des Fußgängerdetektionssystems.

eine einheitliche sensorunabhängige Datenstruktur der nachfolgenden Ebene zur Verfügung steht.

- **Zentrale Datenverarbeitungsebene:** Die zentrale Datenverarbeitungsebene besteht im Wesentlichen aus zwei Teilen: Positionsbestimmung bzw. *Tracking* und Fusion der Klassifikationsinformation. Ausgabe dieser Ebene ist die Position und der Typ (z. B. Fußgänger) detektierter Objekte.
- **Applikationsebene:** In dieser hierarchisch höchsten Ebene werden applikationsspezifische Entscheidungen getroffen. Infolge dieser Entscheidungen ist es möglich, nachgeschaltete Aktuatoren auszulösen.

### 3 Sensorspezifische Signalverarbeitung

Die Fusion von Systemen mit mehreren (unterschiedlichen) Sensoren zu einem Gesamtsystem ist auf vielfache Art und Weise realisierbar. Der in diesem Artikel vorgeschlagene und in Abschnitt 4 näher erläuterte *High-level*-Fusionsansatz sieht eine getrennte sensorspezifische Signalverarbeitung der Thermopile- und Radarsensoren vor. Der Vorteil dieses Ansatzes liegt in der Modularität der



**Abb. 3.** Überlappende Sensorsichtbereiche. Die unterschiedlichen Graustufen geben die Anzahl der Überlappungen wieder. Die einzelnen Überlappungsflächen sind mit Nummern der jeweiligen Sensoren, die dieses Gebiet erfassen, gekennzeichnet. Die Ermittlung der optimalen Sensoranordnung für eine beliebige Anzahl  $N$  von Sensoren ist detailliert in [7] beschrieben.

Fusionsarchitektur. Die einzelnen Sensorsignale der zu fusionierenden Systeme werden soweit vorverarbeitet, bis die gelieferten Daten einer definierten Schnittstelle entsprechen. Die dabei erforderliche sensorspezifische Signalverarbeitung wird im Folgenden erläutert.

### 3.1 Thermopiles

Die entscheidende Frage bei der Verarbeitung von Thermopiles zur Fußgängerdetektion ist: Wie lässt sich die Position eines detektierten Objekts aus den einzelnen Spannungswerten der Sensoren ermitteln?

Eine Methode zur Bestimmung der Position eines Fußgängers, die die Vielfalt der im Straßenverkehr auftretenden Objekte und Szenarien berücksichtigt, basiert auf der Überlappung der Sensorsichtbereiche (FOV). Bei dieser Methode erfolgt die Ermittlung der Position eines Fußgängers über die Kombination der Signale der Sensoren, die das Objekt erfassen. Aufgrund der bekannten Ausrichtung der Sensoren und ihrer FOVs, sind die aus den jeweiligen Aufenthaltsorten resultierenden Sensorkombinationen eindeutig und bekannt (Abbildung 3).

Die Verarbeitung der einzelnen Thermopilesensoren geschieht in vier aufeinander folgenden Schritten, die in Abbildung 4 dargestellt sind. Im ersten Verarbeitungsschritt werden die Signale mit Hilfe eines Tiefpassfilters geglättet und die zum Spannungswert proportionale Temperatur berechnet. Weitere Schritte der Vorverarbeitung (*preprocessing*) beinhalten die Berechnung des Signalanstiegs ( $dU/dt$ ), der Außentemperatur und der Eigengeschwindigkeit des Fahrzeugs.

Die vorverarbeiteten Signale und Hilfsgrößen stellen die Eingangsparameter der zweiten Verarbeitungsstufe, die Signalinterpretation (*signal interpretation*), dar. Um der inhärenten Unsicherheit bei der Detektion gerecht zu werden, findet keine binäre Entscheidung bezüglich der Existenz eines Fußgängers im FOV statt, sondern es erfolgt die Berechnung einer Wahrscheinlichkeit für jeden Sensor. Dieser Wert gibt an, mit welcher Wahrscheinlichkeit die vorliegende Detektion einen Fußgänger repräsentiert. Die Bestimmung dieser Wahrscheinlichkeit geschieht mit Hilfe von Methoden der Mustererkennung und ist ausführlich in [8] beschrieben.

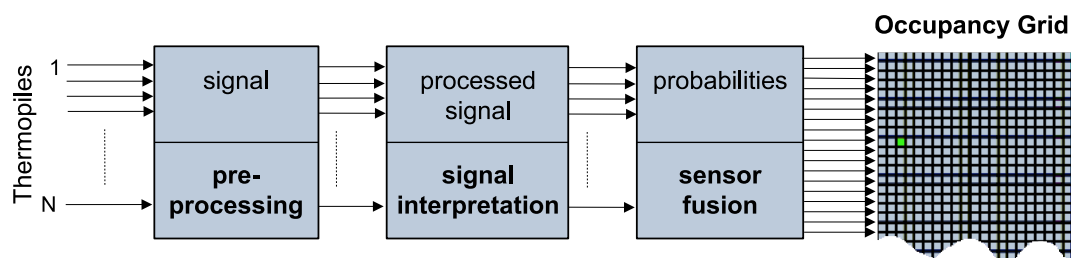


Abb. 4. Gliederung der einzelnen Schritte der Thermopile-Signalverarbeitung.




Abb. 5. Logarithmische Darstellung des Occupancy-Grids. Der höchste Punkt des abgebildeten Wahrscheinlichkeitsgebirge repräsentiert den detektierten Fußgänger.

Die berechneten Wahrscheinlichkeiten der Sensoren ergeben einzeln jedoch noch kein Abbild der Umgebung. Erst die Betrachtung aller Wahrscheinlichkeiten im Gesamtkontext ermöglicht eine Detektion und Lokalisation eines Fußgängers. Dazu werden die Wahrscheinlichkeiten, die mit einem bestimmten Sensor und dessen FOV assoziiert sind, auf ein virtuelles Gitter (*occupancy grid*) abgebildet [5, 6]. Zu jedem Messzeitpunkt wird für jede Zelle innerhalb des Gitters eine solche Wahrscheinlichkeit berechnet und mit der schon vorhandenen Zellenwahrscheinlichkeit kombiniert. Durch die Akkumulation der Wahrscheinlichkeiten entsteht an der Stelle des detektierten Objekts (Fußgänger) ein deutlich höherer Wert als an anderen Stellen (Abbildung 5). Die Zuordnung der Gitterzellen zu den FOVs der einzelnen Sensoren ist dabei durch ein Sensormodell festgelegt.

### 3.2 Radare

Die Nahbereichsradare liefern Ziele innerhalb eines Bereiches von etwa 30 m mit einem Öffnungswinkel von ca.  $60^\circ$ . Die Zielinformationen enthalten Angaben

zu Entfernung, Winkel und Relativgeschwindigkeit der detektierten Objekte. Zusätzlich geben die Amplitudenwerte der Radarsensoren Auskunft über das detektierte Objekt.

Die Sichtbereiche beider Radarsensoren überlappen sich. Vor der eigentlichen Fusion mit den Thermopiles erfolgt die Verknüpfung der Daten der Radare so, dass eine gemeinsame Zielliste entsteht. Auf die Signalverarbeitung dieser Nahbereichsradare wird hier nicht weiter eingegangen.

## 4 Sensordatenfusion

Die im vorherigen Abschnitt beschriebene sensorspezifische Signalverarbeitung liefert pro Sensorsystem ein oder mehrere Objekte mit ihrer jeweiligen Position und Eigenschaft. Die Fusion der Objektinformation kann in zwei Teile gegliedert werden, die auch in Abbildung 2 dargestellt sind.

Ein Teil beschäftigt sich ausschließlich mit der Fusion der Objektpositionen. Diese Aufgabe führt ein Kalman-Filter in Verbindung mit einer Messvektorfusion (*simple weighted fusion*) durch. Diese Methode ist in der Literatur [1, 10] ausführlich erläutert.

Der zweite Teil beinhaltet die Fusion der Objekttypen und ist im Folgenden genauer dargestellt. Für manche Anwendungen (z. B. bei bekannten Objekten) reicht die Fusion der Objektpositionen völlig aus. Im hier beschriebenen Fall ist aber gerade die Fusion der Objekttypen die eigentlich Herausforderung, da es Ziel des Systems ist, nur Fußgänger zu berücksichtigen. Das setzt die Unterscheidung von Fußgängern von anderen Objekten voraus.

Basis der Fusion von Objekttypen ist ein zugrunde liegendes Objektmodell. Die Erstellung dieses Modells erfolgt unter Berücksichtigung, welche Information von den Sensoren verfügbar ist und wie sich diese Information zu einem kohärenten Objekttyp zusammenfassen lässt. Idealerweise sollte jedes detektierbare Objekt seinen eigenen Objekttyp haben, was aber am Rechenaufwand und an dem von den Sensoren gelieferten Informationsgehalt scheitert. Im hier beschriebenen System gibt es drei unterschiedliche Objekttypen:

- Ein Fußgänger ist detektiert ( $P$ ).
- Ein anderes Objekt (kein Fußgänger) ist detektiert ( $O$ ).
- Kein Objekt ist detektiert ( $N$ ).

Mit diesen drei Objekttypen lassen sich insgesamt sieben unterschiedliche Kombinationen erstellen, die in nachfolgendem Vektor als Elemente enthalten sind:

$$\mathbf{p} = \begin{pmatrix} N \\ P \\ O \\ N \cup P \\ N \cup O \\ P \cup O \\ N \cup P \cup O \end{pmatrix}. \quad (1)$$



Die Kombination  $N \cup P$  bedeutet in diesem Zusammenhang entweder  $N$  oder  $P$ . Warum diese drei Objekttypen für das hier vorgestellte System ausreichend sind, wird erst bei folgender Betrachtung der Sensoren plausibel.

#### 4.1 Radar-Objekttypen

Radarsensoren senden elektromagnetische Strahlung aus und empfangen die von Objekten reflektierte Strahlung wieder. Dabei kann der Radarsensor nicht zwischen unterschiedlichen Objekten, die Strahlung reflektieren, unterscheiden. Indirekt ergeben sich aber anhand der reflektierten Leistung (Amplitude) und der Distanz zwischen Sensor und Objekt Aussagen über das detektierte Objekt. Hinreichend grob lässt sich so zwischen metallischen und nichtmetallischen Objekten unterscheiden. Die von den Radaren gelieferten Amplitudenwerte machen es damit möglich, Wahrscheinlichkeiten bezüglich der Objektklassen zu vergeben. Folgende vier Fälle sind plausibel:

- Kein Objekt ist detektiert ( $N$ ).
- Ein metallisches Objekt (kein Fußgänger) ist detektiert ( $O$ ).
- Ein Objekt ist detektiert, der Typ jedoch unbekannt ( $P \cup O$ ).
- Die Messung ist nicht aussagekräftig ( $O \cup N \cup P$ ).

#### 4.2 Thermopile-Objekttypen

Thermopilesensoren detektieren Fußgänger anhand ihrer Wärmestrahlung (Infrarotstrahlung). Aus diesem Grund erfassen diese Sensoren nur Objekte, die entweder über oder unter dem thermischen Gleichgewicht der Umgebung liegen. Objekte senden und empfangen jedoch ständig Wärmestrahlung und infolge dessen befinden sich die meisten Objekte in einem thermischen Gleichgewicht. Der Sensor kann diese Objekte nicht detektieren; er kann also nicht zwischen „kaltem Objekt“ und „keinem Objekt“ unterscheiden. Daraus lassen sich folgende detektierbare Fälle ableiten:

- Kein oder ein sich mit der Umgebung im thermischen Gleichgewicht befindendes Objekt ist detektiert ( $O \cup N$ ).
- Ein Fußgänger ist detektiert ( $P$ ).
- Die Messung ist nicht aussagekräftig ( $O \cup N \cup P$ ).

#### 4.3 Fusion der Objekttypen

Die Fusion der Objekttypen geschieht mit Hilfe der Dempster-Shafer-Theorie (DST), die dafür geeignet ist, Vereinigungen (z. B.  $P \cup O$ ) von Basisereignissen ( $P$ ,  $N$ ,  $O$ ) zu fusionieren.

Die DST ist eine wahrscheinlichkeitsbasierte Datenfusionsmethode, die besonders hilfreich ist, wenn einzelne Sensoren eine unzuverlässige Entscheidung liefern. Die Information über ein von mehreren Sensoren beobachtetes Ereignis lässt sich mit Hilfe von Dempsters Kombinationsregel zu einer Wahrscheinlichkeit verknüpfen.

Den Grundstein der DST legte Arthur Dempster 1967 mit seinem Modell zur Abschätzung von oberen und unteren Wahrscheinlichkeiten eines Ereignisses [3] und seiner Verallgemeinerung des Satzes von Bayes [4]. Diese mathematische Basis erweiterte Glenn Shafer in seinem Werk „A Mathematical Theory of Evidence“ [9]. Barnett [2] verwendete erstmals den Begriff „Dempster-Shafer-Theorie“.

In der Dempster-Shafer-Theorie (DST) wird von einer Menge sich gegenseitig ausschließender Ereignisse ausgegangen. Ein Beispiel für eine solche Menge — auch Wahrnehmungsrahmen (*frame of discernment*)  $\Theta$  genannt — ist  $\theta = \{A, B, C\}$ . Zu diesem Wahrnehmungsrahmen gibt es eine Potenzmenge

$$2^\theta = \{\emptyset, \{A\}, \{B\}, \{C\}, \{A, B\}, \{A, C\}, \{B, C\}, \{A, B, C\}\}.$$

Eine Funktion  $m : 2^\theta \rightarrow [0, 1]$  heißt **Massefunktion**, wenn gilt:

$$m(\emptyset) = 0, \quad (2)$$

$$\sum_{X \in 2^\theta} m(X) = 1. \quad (3)$$

Jedem Ereignis wird eine Wahrscheinlichkeit  $m(\{A\}), m(\{B, C\})$  zugeordnet. Dabei bedeutet  $\{A, B\}$  wörtlich *A oder B*. Die Wahrscheinlichkeit  $m(\{A, B, C\})$  ist dann die Differenz, zwischen der Summe aller anderen Wahrscheinlichkeiten und 1.

Die *Kombinationsregel*  $\oplus$  ist eine Verallgemeinerung des *Satzes von Bayes*. Sie liefert zu zwei *Massefunktionen*  $m_1$  und  $m_2$  eine neue, verknüpfte *Massefunktion*  $m = m_1 \oplus m_2$ . Die Kombinationsregel lautet:

$$m_1 \oplus m_2(X) := \begin{cases} \frac{\sum_{A_i \cap B_j = X} m_1(A_i) \cdot m_2(B_j)}{1 - \sum_{A_i \cap B_j = \emptyset} m_1(A_i) \cdot m_2(B_j)}, & X \neq \emptyset \\ 0 & X = \emptyset. \end{cases} \quad (4)$$

Die Verknüpfung  $\oplus$  ist *kommutativ* und *assoziativ*. Diese Regel ermöglicht die Kombination von Informationen aus mehreren Quellen. Das Verknüpfen zweier Wahrscheinlichkeiten verringert dabei die Unsicherheit.

Das oben eingeführte Objektmodell und die Dempster-Shafer-Theorie bilden die Grundlage für die im Folgenden beschriebene Fusion der Objektvektoren. Dazu wird jedem Ereignis bzw. Vereinigung von Ereignissen eine Wahrscheinlichkeitsmasse zugeordnet.

Die von der Thermopile- und Radarsignalverarbeitung zur Verfügung gestellten Objektvektoren können dann mittels DST zu einem Objektvektor kombiniert

werden.

$$\mathbf{p}_T \oplus \mathbf{p}_R = \begin{pmatrix} m_T(N) \\ m_T(P) \\ m_T(O) \\ m_T(N \cup P) \\ m_T(N \cup O) \\ m_T(P \cup O) \\ m_T(N \cup P \cup O) \end{pmatrix} \oplus \begin{pmatrix} m_R(N) \\ m_R(P) \\ m_R(O) \\ m_R(N \cup P) \\ m_R(N \cup O) \\ m_R(P \cup O) \\ m_R(N \cup P \cup O) \end{pmatrix} = \begin{pmatrix} m_T \oplus m_R(N) \\ m_T \oplus m_R(P) \\ m_T \oplus m_R(O) \\ m_T \oplus m_R(N \cup P) \\ m_T \oplus m_R(N \cup O) \\ m_T \oplus m_R(P \cup O) \\ m_T \oplus m_R(N \cup P \cup O) \end{pmatrix}. \quad (5)$$

Die Anwendung der Kombinationsregel ist nachfolgend beispielhaft für  $m_1 \oplus m_2(N)$  ausgeschrieben:

$$m_T \oplus m_R(N) = \frac{\Phi_N}{1 - k} \quad (6)$$

$$\begin{aligned} \Phi_N &= m_T(N) \cdot m_R(N) + m_T(N) \cdot m_R(N \cup P) + m_T(N) \cdot m_R(N \cup O) \\ &+ m_T(N) \cdot m_R(\theta) + m_T(N \cup P) \cdot m_R(N) + m_T(N \cup P) \cdot m_R(N \cup O) \\ &+ m_T(N \cup O) \cdot m_R(N) + m_T(N \cup O) \cdot m_R(N \cup P) + m_T(\theta) \cdot m_R(N). \quad (7) \end{aligned}$$

$$\begin{aligned} k &= m_T(N) \cdot m_R(O) + m_T(N) \cdot m_R(P) + m_T(O) \cdot m_R(N) \\ &+ m_T(O) \cdot m_R(P) + m_T(P) \cdot m_R(N) + m_T(P) \cdot m_R(O) \\ &+ m_T(N) \cdot m_R(O \cup P) + m_T(O) \cdot m_R(N \cup P) + m_T(P) \cdot m_R(N \cup O) \\ &+ m_T(N \cup O) \cdot m_R(P) + m_T(N \cup P) \cdot m_R(O) + m_T(P) \cdot m_R(N \cup O). \quad (8) \end{aligned}$$

Die Berechnung der restlichen sechs Kombinationen erfolgt entsprechend. Dadurch lässt sich, basierend auf einer mathematisch fundierten Methode, die Wahrscheinlichkeit  $m(P)$ , dass es sich bei dem detektierten Objekt um einen Fußgänger handelt, berechnen. Zusätzlich ist zu jeder Entscheidung die inhärente Unsicherheit  $m(N \cup P \cup O)$  verfügbar.

Anhand der oben dargestellten Gleichungen ist die Komplexität der Kombinationsregel ersichtlich, was entsprechend hohe Anforderungen an die Implementierung in Bezug auf die benötigte Rechenleistung stellt.

Die fusionierten Objektpositionen und -typen dienen, wie in Abbildung 2 dargestellt, als Eingang einer nachfolgenden Situationsbewertungseinheit (*threat assessment*). Diese Einheit bewertet anhand der eigenen Fahrzeugparameter und der detektierten Objektparameter, ob es zu einer kritischen Situation kommt, und löst gegebenenfalls definierte Schutzeinrichtungen aus.

## 5 Ergebnisse

Grundlage der nachfolgenden Statistik ist eine Messdatenbank von über 500 Messungen in Geschwindigkeitsbereichen bis zu 60 km/h. Diese Messdaten umfassen verschiedenste Verkehrssituationen, wie beispielsweise Fahrten in verkehrsberuhigten Bereichen in denen Fußgänger dicht am Fahrzeug vorbeilaufen, Messungen an Ampeln und Zebrastreifen und darüber hinaus Fußgängerkollisionsmessungen, die mit Hilfe eines Fußgängerdummys aufgezeichnet wurden.

Zur statistischen Bewertung des Fußgängerdetektionssystems wurde die Signalverarbeitung unter Verwendung verschiedener Parametersätze über die Messdatenbank evaluiert und so jede Messung bezüglich des verwendeten Parametersatzes zu einem der folgenden vier Fällen zugeordnet:

1. Es tritt eine kritische Verkehrssituation auf. Diese wird vom Fußgängerdetektionssystem erkannt (*true positive*).
2. Es tritt eine kritische Verkehrssituation auf. Das Fußgängerdetektionssystem erkennt jedoch keine kritische Verkehrssituation (*false negative*).
3. Es tritt keine kritische Verkehrssituation auf. Das Fußgängerdetektionssystem erkennt jedoch eine kritische Verkehrssituation (*false positive*).
4. Es tritt keine kritische Verkehrssituation auf. Das Fußgängerdetektionssystem erkennt ebenfalls keine kritische Verkehrssituation (*true negative*).

Mit dieser Kategorisierung der Messungen lassen sich statistische Kenngrößen wie die Erkennungsrate (*true positive rate*, TPR), die Falschalarmrate (*false positive rate*, FPR), die Relevanz (*precision*), die Segreganz (NPV) oder die Korrektheitsklassifikationsrate (*accuracy*) bestimmen. Die beiden wichtigsten Kenngrößen, Erkennungsrate und Falschalarmrate, berechnen sich über die Formeln:

$$\text{Erkennungsrate} = \frac{\text{TP}}{\text{TP} + \text{FN}}, \quad (9)$$

$$\text{Falschalarmrate} = \frac{\text{FP}}{\text{FP} + \text{TN}}. \quad (10)$$

Dabei stehen die beiden Kenngrößen in einer wechselseitigen Beziehung. Das Bestreben, die Erkennungsrate des Fußgängerdetektionssystems zu verbessern, indem durch Veränderungen der Parameter mehr Fußgänger erkannt werden (*true positive*), steigert in der Regel die Anzahl der fälschlicherweise erkannten Fußgänger (*false positive*) und bringt eine Erhöhung der Falschalarmrate mit sich.


Gelöst von der Parametrisierung wird dieser Zusammenhang durch die ROC-Kurve<sup>2</sup> in Abbildung 6(a) verdeutlicht. Die ROC-Kurve stellt die Falschalarmrate der Erkennungsrate gegenüber. Wird die Signalverarbeitung über die gesamte Messdatenbank so parametrisiert, dass kein Falschalarm ausgelöst wird, können ca. 67% aller kritischen Verkehrssituationen erkannt werden.

Abbildung 6(b) zeigt die statistischen Kenngrößen des Fußgängerdetektionssystems bei einer Parameterwahl, die bezüglich der zugrunde liegenden Messdatenbank kein Falschalarm generiert.


## 6 Zusammenfassung

Dieser Artikel stellt ein auf Thermopile- und Radarsensoren basierendes System zur Fußgängerdetektion vor. Die Signalverarbeitung für diese Anwendungen basiert auf der Sensordatenfusion, mit dem Hauptziel, einen robusten Betrieb zu

<sup>2</sup> *receiver operating characteristic*



(a) In der ROC-Kurve wird der Zusammenhang zwischen Erkennungs- und Falschalarmrate deutlich.



(b) Kennwerte des Fußgängerdetektionssystems bei einer Parametrisierung, die keinen Falschalarm erzeugt.

**Abb. 6.** Statistische Bewertung des Fußgängerdetektionssystems.

ermöglichen bzw. die Objektposition mit Hilfe von Sensoren bestimmen zu können, die diese Information originär nicht liefern.

Die dafür vorgestellten Ansätze sind bereits bekannte Verfahren zur Fusion, aber auch neu entwickelte Verfahren, die speziell auf die Anwendung und die Charakteristiken der verwendeten Sensorik zugeschnitten sind.

Die Fusion der Thermopilesensoren stützt sich auf zuvor berechnete Wahrscheinlichkeiten und Unsicherheiten, die mittels der Dempster-Shafer-Theorie zu einer Gesamtwahrscheinlichkeit kombiniert werden. Diese Wahrscheinlichkeit in Verbindung mit einem Occupancy-Grid ermöglicht es, eine Entscheidung anhand akkumulierter Wahrscheinlichkeitswerte innerhalb einer kurzen Zeitspanne zu treffen. Die Auswertung der Messdatenbank mit Hilfe statistischer Verfahren zeigt das Potential des vorgestellten Fußgängerdetektionssystems.

## Literatur

1. Y. Bar-Shalom und L. Campo. The effect of common process noise on the two-sensor fused-track covariance. *IEEE Transactions on Aerospace and Electronic Systems*. AES, 22(6):803–805, 1986.
2. H. Barnett. Computational methods for a mathematical theory of evidence. In: *Proceedings of the 7th International Joint Conference on Artificial Intelligence, Vancouver*, S. 868–875, 1981.
3. A. Dempster. Upper and lower probabilities induced by a multivalued mapping. *Annals of Math. Statistics*, 38:325–339, 1967.
4. A. Dempster. A generalization of Bayesian inference. *Journal of the Royal Statistical Society*, 30:205–247, 1968.
5. A. Elfes. Using occupancy grid for mobile robot perception and navigation. In: *IEEE Computer Magazine, Special Issue on Autonomous Intelligent Machines*, 1989.

6. D. T. Linzmeier, M. Mekhaïel, J. Dickmann und K. C. J. Dietmayer. Pedestrian detection with thermopiles using an occupancy grid. In: *IEEE ITSC Conference on Intelligent Transportation Systems*, Washington, USA, 2004.
7. D. T. Linzmeier, M. Skutek, T. Abay und K. C. J. Dietmayer. Grid-based optimal sensor arrangement within a sensor array for 2-D position estimation. In: *SPIE European Symposium on Optics/Photonics in Defence and Security*, London, England, 2004.
8. D. T. Linzmeier, D. Vogt, R. Prasanna, M. Mekhaïel und K. C. J. Dietmayer. Probabilistic signal interpretation methods for a thermopile pedestrian detection system. In: *Proceedings of the Intelligent Vehicles Symposium 2005*, S. 11–16, Las Vegas, USA, June 2005.
9. G. Shafer. *A Mathematical Theory of Evidence*. Princeton University Press, 1976.
10. R. A. Singer und A. J. Kanyuck. Computer control of multiple site track correlation. *Automatica*, 7:455–462, July 1971.

# Informationsfusion in Multisensorsystemen für die Sportmedizin

Meinhard Schilling<sup>1</sup> und Uwe Tegtbur<sup>2</sup>

<sup>1</sup> TU Braunschweig, Institut für Elektrische Messtechnik und Grundlagen der Elektrotechnik, Braunschweig, Germany

<sup>2</sup> Medizinische Hochschule Hannover, Sportmedizinisches Zentrum, Hannover, Germany

**Zusammenfassung.** Eine wichtige Anwendung von Datenfusion zur Gewinnung höherwertiger Information in der Medizintechnik sind Geräte zur Messung des Energieumsatzes im Körper auf Grund von körperlicher Aktivität. Dies sind einerseits Geräte, die für jedermann verfügbar zum individuellen Lauftraining und bei anderen Sportarten eingesetzt werden. Aus der Herzfrequenz und weiteren personenbezogenen Daten wird ein Wert für den Energieumsatz ermittelt und daraus eine verbrannte Fettmenge berechnet. Andererseits sind höherwertige medizinische Messgeräte zu nennen, die sowohl in der Sportmedizin zur Trainingsbegleitung für Leistungssportler als auch zur Bewegungstherapie beispielsweise bei Diabetes mellitus eingesetzt werden. Zukünftige, eingebettete Systeme in der Kleidung, die für medizinische Zwecke eingesetzt werden sollen, basieren auf den gleichen Überlegungen für die Ermittlung der Stoffwechsellaktivität.

## 1 Einleitung

Die medizinische Diagnose basiert auf der Fusion von Informationen aus verschiedenen Quellen, die aus der Anamnese und medizinischen Untersuchungsverfahren stammen. Zur Interpretation der Information muss mit Hilfe der Erfahrung und des Wissens des Mediziners die individualisierte Diagnose eines Krankheitsbildes erstellt werden. In der Sportmedizin und beim therapeutischen Einsatz sportlicher Aktivität muss das Training und der Therapieerfolg quantitativ überwacht werden. Dazu werden Messungen des Energieumsatzes im Körper eingesetzt.

Der gesamte Energieumsatz (engl. *energy expenditure EE*) des menschlichen Körpers besteht aus drei Anteilen [1]. Der erste Teil dieses Gesamtumsatzes ist der Grundumsatz im wachen Ruhezustand. Auch in Ruhe benötigt der menschliche Körper einen Mindestumsatz an Energie für seine Stoffwechselfunktionen. Dieser Energieumsatz wird im Englischen als *resting energy expenditure* oder *resting metabolic rate RMR* bezeichnet. Er lässt sich am Morgen nüchtern nach dem Aufstehen mit kalorimetrischen Methoden bestimmen. Der Grundumsatz stellt eine wichtige Größe bei Maßnahmen zur Gewichtsreduktion dar.

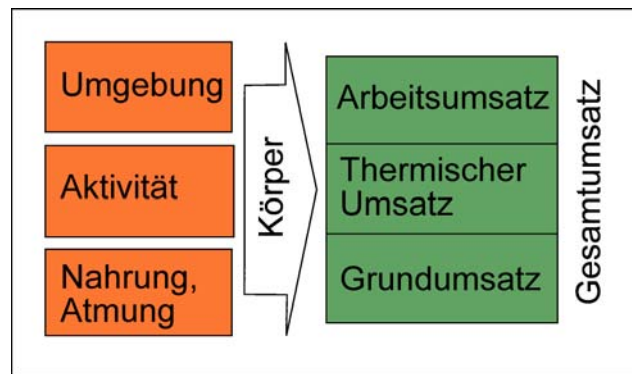


Abb. 1. Einflussgrößen auf den metabolischen Energieumsatz.

Der zweite Teil berücksichtigt die Wärme, die durch die erhöhte Stoffwechsellaktivität nach der Nahrungsaufnahme im Körper entsteht. Dieser Anteil wird in der englischen Literatur als *thermic effect of food* bezeichnet.

Der dritte Teil ist der erforderliche Energieumsatz bei physischer Aktivität, der auch als Arbeitsumsatz bezeichnet wird. Er wird auf Englisch *energy expended in physical activity* genannt. Bei körperlicher Anstrengung erhöht sich die benötigte Leistung und je nach Dauer der Anforderung werden unterschiedliche Energiequellen im Körper aktiviert (Kohlenhydrate, Fett, Eiweiße).

Der Arbeitsumsatz ist für eine gegebene Arbeit bei durchtrainierten Sportlern der gleiche wie bei untrainierten Personen. Der Grundumsatz unterscheidet sich bei durchtrainierten Sportlern vom Mittelwert für die Gesamtbevölkerung wegen des anderen Körperaufbaus (Verhältnis von Muskelmasse zu Körperfettanteil). Der gesamte Energieumsatz ist für die Beurteilung des Trainingserfolgs und -ablaufs bei Patienten eine wichtige Basisgröße, bei Sportlern wird vor allem die Entwicklung des Arbeitsumsatzes im Training bewertet. Der gesamte Energieumsatz im Körper hängt von vielen Einflussfaktoren ab, die in Abbildung 1 schematisch dargestellt sind.

## 2 Grundumsatz und Nahrungsaufnahme


### 2.1 Grundumsatz

In Ruhe wird vom menschlichen Körper Energie umgesetzt, indem Kohlenhydrate, Fette und Eiweiße metabolisiert werden. Der Grundumsatz wird in kJ/h (kcal/h) gemessen und bezeichnet im physikalischen Sinn eine Leistung. Die Umrechnung in Watt kann nach

$$1 \text{ W} = 1 \text{ J/s} = 2,39 \cdot 10^{-4} \text{ kcal/s} = 0,86 \text{ kcal/h}$$

vorgenommen werden. Da sich die Stoffwechselfunktionen mit dem Alter ändern, vom Geschlecht abhängig sind und der Energiebedarf auch noch von Körpergröße und Körpergewicht abhängt, müssen diese Parameter zusätzlich erfasst werden.





**Abb. 2.** Energieumsatz RMR in Abhängigkeit von Gewicht und Körpergröße a) für eine(n) 20-jährige(n) Frau(Mann) und b) für eine(n) 60-jährige(n) Frau(Mann). Die gepunkteten Kurven zeigen die Daten für die männlichen Personen.

Dabei ist von Bedeutung, die typische Muskelmasse aus diesen Daten abzuschätzen. Da der Grundumsatz von der Muskelmasse zu 25 % bestimmt wird und der Arbeitsumsatz von ihr in noch höheren Maße abhängt, ergeben sich signifikante individuellen Unterschiede. Man rechnet als Faustregel mit einem mittleren Grundumsatz bei Männern von 1,2 kcal / h kg und bei Frauen mit 0,95 kcal / h kg Körpergewicht. Der Grundumsatz wird standardmäßig alters-, gewichts- und größenabhängig mit den Harris-Benedict-Gleichungen berechnet, wie bereits bei [2] ausgeführt:

$$\text{Frauen: } RMR = 4.184(655.1 + (9.563 \cdot m) + (1.850 \cdot h)(4.676 \cdot a))$$

$$\text{Männer: } RMR = 4.184(66.5 + (13.75 \cdot m) + (5.003 \cdot h)(6.775 \cdot a))$$

Hierin ist  $m$  das Körpergewicht in kg,  $h$  die Körpergröße in cm und  $a$  das Alter in Jahren. Der Grundumsatz wird dabei in kJ/Tag oder in kcal/Tag ermittelt. Der Vorfaktor 4.184 ergibt sich bei der Umrechnung von kcal nach kJ. Diese Zusammenhänge für den Grundumsatz an Energie in Ruhe sind in Abbildung 2 grafisch nach den angegebenen Harris-Benedict-Gleichungen für zwei verschiedene Altersgruppen (20 Jahre und 60 Jahre) dargestellt.

Da bei jungen Menschen und Sportlern die Harris-Benedict-Gleichungen den Grundumsatz an Energie um etwa 10% überschätzen, werden von vielen Autoren (z. B. Roza et al. [3]) Ergänzungen und Korrekturen vorgeschlagen, die insbesondere bei sehr muskulösen Personen relevant sind [4]. Eine mögliche Korrektur ist auch, statt des gesamten Körpergewichts nur die fettfreie Körpermasse (*fat*

*free mass FFM*), einzusetzen, da das Fettgewebe kaum zur metabolischen Aktivität beiträgt. Um die Masse des fettfreien Gewebes individuell zu bestimmen, kann Ganzkörper-Kernspin-Tomographie [5], Densitometrie durch Wiegen unter Wasser [6] oder die Hautfaltenmessung mittels Calipper eingesetzt werden. Eine mögliche, aber fehlerbehaftete Bestimmung der fettfreien Körpermasse *FFM* in kg ist die Ermittlung durch Messungen der Bioimpedanz *R* in Ohm [7–10], wie sie auch von zahlreichen Körperwaagen angegeben wird:

$$FFM = 0.671 \cdot (h^2/R) + 3.1S + 3.9.$$

Hierin ist *h* die Körpergröße in cm und *S* = 0 für Frauen und *S* = 1 für Männer.

## 2.2 Energieumsatz nach Mahlzeiten

Die erhöhte Stoffwechselaktivität des Körpers nach der Einnahme von Mahlzeiten ist bei Bestimmung des Energieumsatzes bei körperlicher Aktivität zu beachten. Bei gemischter Kost wird durch die Einnahme einer Mahlzeit der Grundumsatz um etwa 6 % erhöht. Diese Erhöhung kann über bis zu 8 Stunden anhalten.

## 3 Energieumsatz bei körperlicher Aktivität

Der Arbeitsumsatz mit einfachsten Bewegungen liegt bei 95–145 kJ/Tag (400–600 kcal/Tag). Bei intensiver Bewegung (Laufen, Wandern, Sport) erhöht sich der Arbeitsumsatz und das erhöhte Herz-Zeit-Volumen HZV, die gesteigerte Durchblutung, die beschleunigte Atmung und der insgesamt erhöhte Stoffwechselumsatz sorgen dafür, dass die Energie für diese Tätigkeiten zur Verfügung steht. Die Intensität der körperlichen Betätigung kann im einfachsten Fall mit zusätzlichen Faktoren für den Grundumsatz innerhalb 24 Stunden zwischen 1,2 (leichte Aktivität) bis 3 (schwere körperliche Anstrengung) berücksichtigt werden. Der Trainingszustand wird dabei nicht erfasst und dadurch lassen sich keine sinnvollen, sportmedizinischen Aussagen zur Trainingssteuerung ableiten. Extreme sportliche Anstrengung kann zu einem erhöhten, momentanen Arbeitsumsatz führen, der um bis zu einem Faktor 20 gegenüber dem Grundumsatz gesteigert ist. Um den Energieumsatz auf einfache Weise zu messen, müssen die Werte der Messgrößen ermittelt werden, die den erhöhten Energieumsatz durch körperliche Aktivität im Körper wiedergeben. Dazu wird in erster Linie die Sauerstoffaufnahme aus der Atemluft gemessen. Um die Messung zu vereinfachen, wird die Herzfrequenz aus dem Elektrokardiogramm herangezogen und der Zusammenhang zwischen Sauerstoffaufnahme und Herzfrequenz zur Berechnung des Energieumsatzes genutzt. Die Herzfrequenz erhöht sich, um dem gesteigerten Energieumsatz durch einen schnelleren Sauerstofftransport im Körper zu genügen. Bei erhöhter Herzfrequenz steigt auch der Blutdruck an. Dieser Zusammenhang ist aber stark von der Elastizität des Gefäßsystems und damit vom Alter und Trainingszustand abhängig.

Durch die stärkere Durchblutung ändert sich auch die Bioimpedanz. Die Atmung beschleunigt sich, um den größeren Sauerstoffaustausch zu bewältigen. Der erhöhte Energieumsatz entspricht einer gestiegenen Leistung. Diese muss als Wärmestrom den Körper wieder verlassen, was zum Ansteigen der Körpertemperatur und zu Schweißbildung führt. Auch aus diesen Werten oder einer Kombination kann durch Datenfusion der individuelle Energieumsatz durch körperliche Aktivität nährungsweise abgeleitet werden.

Die umgesetzte Energie  $W$  nach körperlicher Aktivität lässt sich aus dem Arbeitsumsatz als Leistung  $P$  des Körpers in  $W$  und der Zeit  $t$ , in der diese Leistung erbracht wurde, als Produkt nach  $W = Pt$  ermitteln. Die mechanische Leistung  $P$  lässt sich auf einem Ergometer einfach messen und erlaubt mit einer genauen Zeitmessung die Bestimmung der mechanischen Energie, wobei zusätzlich die thermische Energie zu berücksichtigen ist, die vom Körper an die Umgebung abgegeben wird. Dabei liegt das Verhältnis von mechanischer zur thermischer Energie etwa bei 20:80. Wird mittels indirekter Kalorimetrie (s. u.) der Gesamtumsatz ermittelt, kann aus dem Verhältnis des Arbeitsumsatzes zum Gesamtumsatz der Wirkungsgrad bestimmt werden. Im Training kann dann versucht werden, einen möglichst großen Anteil am Gesamtumsatz als Arbeitsumsatz in mechanische Energie, z. B. beim Laufen oder Schwimmen, umzusetzen und den Wirkungsgrad durch bessere Technik zu steigern. Um einen Zusammenhang zwischen dem Energieumsatz und den genannten Vitalparametern zu ermitteln, können bei einer Ergometer-Sitzung die Vitalparameter und ihre zeitliche Entwicklung erfasst werden. Anschliessend werden die Daten aus den unten beschriebenen Referenzmethoden mit der Herzfrequenz in Beziehung gesetzt und für Menschen mit verschiedenem Geschlecht, Körpergewicht und -größe, Alter und Trainingszustand aufgenommen. Diese Kennlinienfelder können dann im Trainingscomputer abgelegt werden und dazu dienen, den individuellen Energieumsatz im Training zu ermitteln.

## 4 Messverfahren für den Energieumsatz

### 4.1 Doppeltmarkiertes Wasser

Der Energieumsatz bei körperlicher Aktivität wird auch mit dieser Methode bestimmt, wobei eine gemischte Probe doppelt radioaktiv markiertes Wasser ( $^2\text{H}_2^{18}\text{O}$ ) mit 0.15 g  $\text{H}^{18}\text{O}$ /kg Körpergewicht and 0.07 g  $^2\text{H}_2\text{O}$ /kg Körpergewicht) eingenommen werden und die Umsetzung im Stoffwechsel durch Strahlungsmessungen ermittelt wird. Diese Methode erlaubt eine sehr genaue Messung der Stoffwechselaktivität [13].

### 4.2 Direkte Kalorimetrie

Diese Standardmethode zur Ermittlung des Energieumsatzes erfordert, dass die untersuchte Person sich während der Messzeit in einem thermisch isolierten Raum aufhält, in dem die durch den Stoffwechsel der untersuchten Person entstehende Wärme vollständig registriert werden kann. Die Untersuchung kann sich

dabei über 24 h erstrecken, da ein solcher Kalorimeterraum mit Bett, Toilette, Tisch und Ergometer etc. ausgerüstet sein kann. Mit dieser Methode erhält man sehr genaue Werte für den Energieumsatz durch Stoffwechsel, auch bei körperlicher Aktivität. Als Routinemessung für das Training ist sie gleichwohl auf Grund des großen Aufwands nicht geeignet.

Da bei erhöhter Leistung die Körpertemperatur steigt, wächst auch der Wärmestrom aus dem Körper. Deshalb kann aus der Messung des Wärmestroms in  $W$  durch Messung der Temperaturdifferenz zur Umgebung bei bekanntem Widerstand auf die momentane, mittlere Leistung zurückgeschlossen werden. Dazu muss allerdings der lokale Wärmestrom über die gesamte Körperoberfläche integriert werden. In der einfachsten Näherung kann dazu der lokale Wert für die Fläche, auf der er kalibriert wurde, mit der Gesamtoberfläche  $F$  des Körpers multipliziert werden. Diese Gesamtoberfläche  $F$  lässt sich aus der Formel von DuBois und DuBois [11] aus dem Gewicht und der Körpergröße abschätzen:

$$F = (m^{0.425} \cdot h^{0.725}) \cdot 0.007184.$$

Hierin ist  $F$  die Körperoberfläche in  $m^2$ ,  $m$  das Körpergewicht in kg und  $h$  die Körpergröße in cm.

### 4.3 Indirekte Kalorimetrie

Da jeder Energieumsatz im Körper durch Oxidation erfolgt, ist die Messung der vom Körper aufgenommenen Sauerstoffmenge ( $\dot{V}O_2$ ) ein exaktes Maß für die umgesetzte Energie. Die aufgenommene Sauerstoffmenge kann in medizinischen Belastungstests sicher bestimmt werden. Der Sauerstoffumsatz ist unabhängig vom Individuum direkt in den gesamten Energieumsatz  $EE$  umrechenbar nach:

$$EE \text{ (kcal/min)} = \dot{V}O_2 \text{ (L/min)} \cdot 4.862 \text{ kcal/L}.$$

Der Umrechnungsfaktor von 4.862 kcal/L $O_2$  ist nahezu unabhängig von den genauen im Körper ablaufenden Verbrennungsprozessen, obwohl die benötigte Sauerstoffmenge für die Fettmetabolisierung deutlich vom Wert für Kohlenhydrate und Proteine abweicht. Die Messunsicherheit bleibt innerhalb von  $\pm 4\%$ . Unter der Annahme, dass keine Proteine umgesetzt wurden, sondern nur Kohlenhydrate und Lipide, lässt sich der Fettanteil auch ausrechnen. Er beträgt durchschnittlich bei körperlicher Aktivität 50.7% am Energieumsatz. Die restlichen 49.3% entfallen auf die Kohlenhydrate. Der Anteil der Kohlenhydrate steigt mit höherer Belastungsintensität an. Allerdings kann die aufgenommene Sauerstoffmenge während des Trainings im normalen Umfeld nicht einfach bestimmt werden. Deshalb wird als ein einfach zu messender Vitalparameter die Herzfrequenz auf die vom Körper aufgenommene Sauerstoffmenge umgerechnet [12].

## 5 Herzfrequenzmessung (Puls)

Die Erhöhung der Herzfrequenz bei körperlicher Aktivität kann als Maß für den Energieumsatz verwendet werden [14]. Wie aus Abbildung 3 zu ersehen ist,




Abb. 3. Ermittlung des Energieumsatz bei Aktivität aus der Herzfrequenz aus [14].

ist der individuelle Energieumsatz bei körperlicher Aktivität eindeutig aus der Herzfrequenz zu ermitteln. Dazu wird der gezeigte Zusammenhang zum Sauerstoffumsatz ermittelt und dann der Sauerstoffumsatz in den Energieumsatz umgerechnet. Der Energieumsatz in Ruhe oder bei geringer Aktivität ist sehr viel schwerer zu messen und ist erst mit den genauen und häufigen Messungen mit modernen am Körper integrierten Sensoren zugänglich.

Liegt der Zusammenhang zwischen der vom Körper aufgenommenen Sauerstoffmenge ( $\dot{V}O_2$ ) und der Herzfrequenz als individuelle Messung vor, so lässt sich leicht die Bestimmung des Arbeitsumsatzes aus der Herzfrequenz durchführen. Dies wird nur bei der Betreuung von Leistungssportlern im Einzelfall möglich sein. In einem allgemein eingesetzten Gerät zum Lauftraining (Pulsuhr etc.) muss eine Abschätzung des Zusammenhangs verwendet werden. Dazu wurden viele verschiedene Modelle evaluiert [15–18]. Ein neueres Modell [19] setzt zur genaueren Vorhersage des Arbeitsumsatz die Berücksichtigung der Herzfrequenz der vorangegangenen Minute ein. Damit ergibt sich ein Zusammenhang für den Energieumsatz  $EE$  nach

$$EE(kJ/min) = -16.1 + 0.194 \cdot HR + 0.311 \cdot pHR - 0.597 \cdot m + 0.353 \cdot a - 0.002 \cdot HR \cdot pHR + 0.007 \cdot HR \cdot m \quad (\text{Männer})$$

und

$$EE(kJ/min) = -20.2 + 0.397 \cdot HR + 0.155 \cdot pHR - 0.174 \cdot m - 0.08 \cdot a - 0.001 \cdot HR \cdot pHR + 0.001 \cdot HR \cdot m \quad (\text{Frauen}).$$

Darin ist  $HR$  die Herzfrequenz in Schlägen pro Minute,  $pHR$  die Herzfrequenz der vergangenen Minute in Schlägen pro Minute,  $m$  das Körpergewicht in kg und

a das Alter in Jahren. Mit diesem Zusammenhang lässt sich der Energieumsatz aus der Herzfrequenz nährungsweise bestimmen. Werden mit diesen Gleichungen die Kurven aus Abbildung 3 berechnet, so stimmen die Kurven für weibliche Personen gut überein, die Abweichungen für männliche Personen liegen im Rahmen der Fehlergrenzen, die in [19] angegeben werden.

## 6 Sensoren

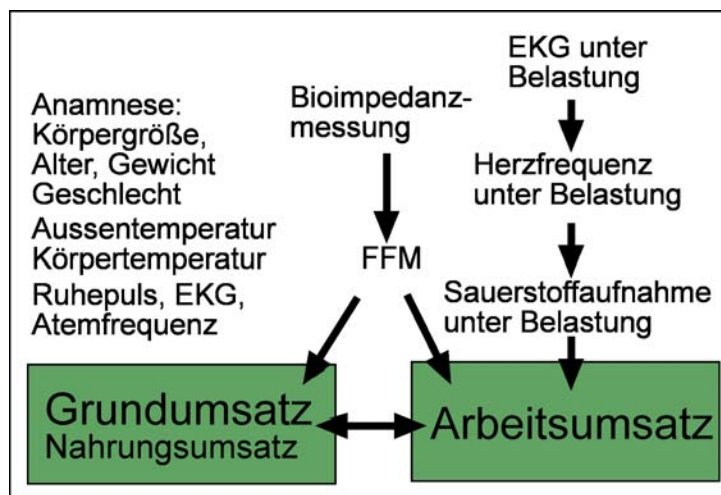
Zur Messung der Herzfrequenz werden Elektroden zur Aufnahme des Elektrokardiogramms (EKG) eingesetzt. Nach der Messung des EKG wird mittels digitaler Signalverarbeitung aus der zeitlichen Abfolge der R-Zacken die Herzfrequenz ermittelt. In den heute gängigen sportmedizinischen Geräten werden EKG-Elektroden eingesetzt, die aus Metall oder leitfähigen Kunststoffen hergestellt sind und auch unter schwierigen Bedingungen noch ein auswertbares, elektrisches Signal liefern.

Eine genauere Beurteilung des Energieumsatzes ist erreichbar, wenn zusätzlich Daten für die Charakterisierung der Bewegung aufgenommen und bei der Berechnung berücksichtigt werden. Dazu lassen sich Accelerometer-Sensoren mit Bewegungsklassifikatoren im Auswertalgorithmus einsetzen [20]. In anderen Geräten wird der Wärmestrom aus dem Körper durch eine differentielle Temperaturmessung ermittelt, in dem die Körpertemperatur direkt ermittelt und mit einer Temperatur in einigen Millimeter Entfernung vom Körper in Beziehung gesetzt wird.

Der Zusammenhang der Messgrößen zur Ermittlung des Energieumsatzes mit einem solchen Gerät ist in Abbildung 4 dargestellt. Solche Geräte sind heute in Form von Pulsuhren mit drahtloser Übertragung des Herzfrequenzsignals aus einem Brustgurt an die Uhr am Handgelenk oder mit einem Oberarmsensor erhältlich. In Zukunft könnten die wesentlichen Sensorkomponenten aber auch in einem Ring am Finger integriert werden [21].

## 7 Zusammenfassung

Der Energieumsatz im Körper wird zur quantitativen Untersuchung des Stoffwechsels und seiner Beeinflussung durch Ernährung und körperliche Aktivität gemessen. Für medizinische Diagnosen wird der Energieumsatz dazu z.B. direkt oder indirekt kalorimetrisch bestimmt. Diese Methoden sind für das sportliche Training im Normalfall zu aufwändig. Als einfach zu messender Vitalparameter im Training wird stattdessen die Herzfrequenz gewählt. Die Ermittlung des Energieumsatzes im Körper durch physische Aktivität auf der Basis der Herzfrequenz ist durch eine sehr große individuelle Variabilität gekennzeichnet. Deshalb müssen zusätzliche Daten herangezogen werden, wie Alter, Gewicht, Geschlecht und Körpergröße. Erst aus der Fusion dieser Informationen mit Gewichtsfaktoren, die statistisch aus großen Stichproben von individuell untersuchten Personen stammen, gelingt eine individuelle Vorhersage des Energieumsatzes mit akzeptablen Messunsicherheiten.



**Abb. 4.** Blockschaltbild für ein tragbares Gerät („health watch“) zur Ermittlung des Energieumsatzes für die Sportmedizin.

## Literatur

1. P. L. Pellett. Food energy requirements in humans. *Am. J. Clin. Nutr.*, 51:711, 1990.
2. J. Harris und F. Benedict. *A biometric study of basal metabolism in man*. Carnegie Institute of Washington, Washington D.C., 1919.
3. A. M. Roza und H. M. Shizgal. The Harris Benedict equation reevaluated: Resting energy requirements and the body cell mass. *Am. J. Clin. Nutr.*, 40:168, 1984.
4. B. Müller, S. Merk, U. Bürgi und P. Diem. Predictive equations for basal metabolic rate in severe and very severe obesity (class II and III). *PRAXIS, Schweizerische Rundschau für Medizin*, 45, 2001.
5. Z. Wang, S. Heshka, S. B. Heymsfield, W. Shen und D. Gallagher. A cellular-level approach to predicting resting energy expenditure across the adult years. *Am. J. Clin. Nutr.*, 81:799, 2005.
6. O. E. Owen, J. L. Holup, D. A. D'Alessio, E. S. Craig, M. Polansky, K. J. Smalley, E. C. Kavle, M. C. Bushman, L. R. Owen, M. A. Mozzoli, Z. V. Kendrick und G. H. Boden. A reappraisal of the caloric requirements of men. *Am. J. Clin. Nutr.*, 46:875, 1987.
7. H. C. Lukaski, W. W. Bolonchuk, C. B. Hall und W.A. Siders. Validation of tetrapolar bioelectrical impedance method to assess human body composition. *J. Appl. Physiol.*, 60:1327, 1986.
8. P. Deurenberg, K. van der Kooij, P. Evers und T. Hulshof. Assessment of body composition by bioelectrical impedance in a population aged > 60 y. *Am. J. Clin. Nutr.*, 51:3, 1990.
9. R. Roubenoff. Applications of bioelectrical impedance analysis for body composition to epidemiologic studies. *Am. J. Clin. Nutr.*, 64(suppl):459, 1996.
10. S. S. Sun, W. C. Chumlea, S. B. Heymsfield, H. C. Lukaski, D. Schoeller, K. Friedl, R. J. Kuczmarski, K. M. Flegal, C. L. Johnson und V. S. Hubbard. Development of bioelectrical impedance analysis prediction equations for body composition with the use of a multicomponent model for use in epidemiologic surveys. *Am. J. Clin. Nutr.*, 77:331, 2003.

11. D. DuBois und E. F. DuBois. A formula to estimate the approximate surface area if height and weight be known. *Arch. Intern. Medicine*, 17:863, 1916.
12. R. B. Andrews. Net heart rate as a substitute for respiratory calorimetry. *Am. J. Clin. Nutr.*, 24:1139, 1971.
13. D. A. Schoeller. Measurement of energy expenditure in free-living humans by using doubly labeled water. *J. Nutr.*, 118:1278, 1988.
14. G. B. Spurr, A. M. Prentice, P. R. Murgatroyd, G. R. Goldberg, J. C. Reina und N. T. Christman. Energy expenditure from minute-by-minute heart-rate recording: comparison with indirect calorimetry. *Am. J. Clin. Nutr.*, 48:552, 1988.
15. M. Whaley et al. Predictors of over- and underachievement of age-predicted maximal heart-rate. *Med. Sci. Sports Exerc.*, 24:1173, 1992.
16. H. K. Hilloskorpi, M. G. Fogelholm, R. Laukkanen et al. Factors affecting the relation between heart rate and energy expenditure during exercise. *Int. J. Sports Med.*, 20:438, 1999.
17. L. R. Keytel, J. Goedecke, T. Noakes et al. Estimating energy expenditure by heart rate monitoring without individual calibration. *Med. Sci. Sports Exerc.*, 33:939, 2001.
18. K. L. Rennie, S. J. Hennings, J. Mitchell und N. J. Wareham. Factors affecting the relation between heart rate and energy expenditure during exercise. *Int. J. Sports Med.*, 20:438, 1999.
19. L. R. Dugas, L. van der Merwe, H. Odendaal, T. D. Noakes und E. V. Lambert. A novel energy expenditure prediction equation for intermittent physical activity. *Med. Sci. Sports Exerc.*, 37:2154, 2005.
20. D. M. Karantonis, M. R. Narayanan, M. Mathie, N. H. Lovell und B. G. Celler. Implementation of a real-time human movement classifier using a triaxial accelerometer for ambulatory monitoring. *IEEE Trans. Information Technology in Biomedicine*, 10(1):156–167, 2006.
21. H. H. Asada, P. Shaltis, A. Reisner, S. Rhee und R. C. Hutchinson. Wearable technomobile monitoring with wearable photoplethysmographic biosensors. *IEEE Eng. Med. Biol. Mag.*, 22:28, 2003.



# Elektronische Nase und Signalgewinnung

Frank Röck und Udo Weimar

Institut für Physikalische und Theoretische Chemie, Universität Tübingen  
Auf der Morgenstelle 15, D-72076 Tübingen

**Zusammenfassung.** Mehrere Gassensoren in einer Messkammer zusammengefasst (Array) mit nachgeschalteter Elektronik und Auswertelgorithmen werden in der Literatur und darüber hinaus oft als „elektronische Nasen“ bezeichnet. Der vorliegende Aufsatz gibt einen kurzen Überblick über die Grundlagen sowohl der verwendeten Sensoren als auch der eingesetzten Mustererkennung und Multikomponentenanalysemethoden. Er beschreibt den Systemaufbau und zeigt praktische Einsatzbereiche. Die Sensordatenfusion ist hier gegeben durch die Kombination unterschiedlicher Transduktionsmethoden (Sensorprinzipien), wobei die Vorteile an Beispielen erläutert werden. Der Artikel zeigt aber auch klar die Grenzen aktueller Technologie und warnt vor einem direkten Gleichsetzen von natürlicher und „elektronischer“ Nase.

## 1 Einleitung

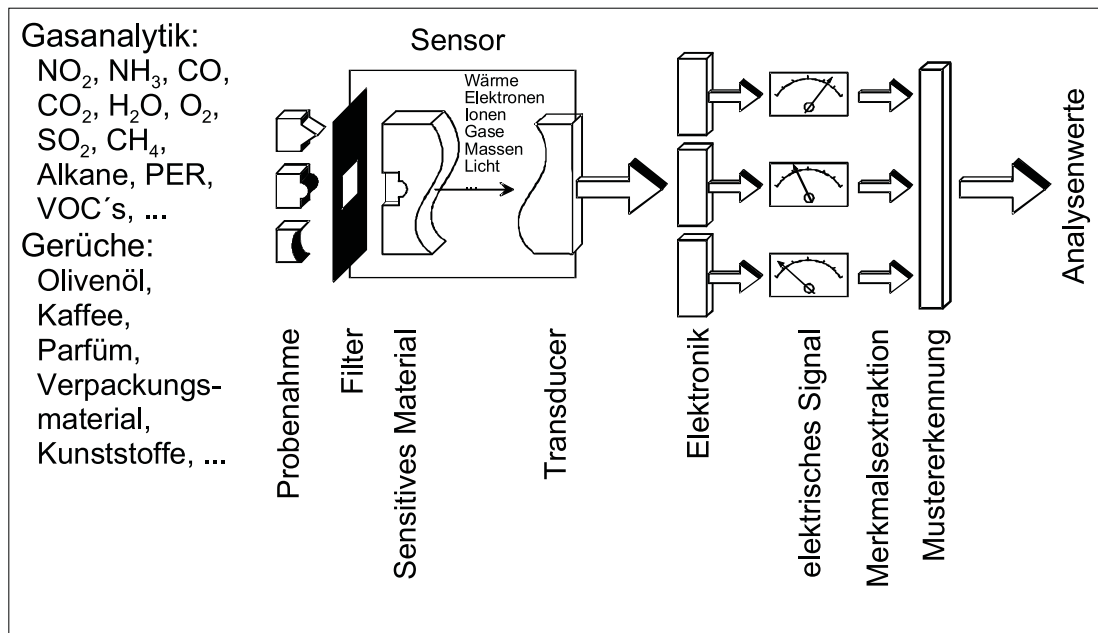
Chemische Sensoren bieten sich auf dem Gebiet der Gas- und Geruchsanalytik an, etablierte analytische Methoden wie beispielsweise die Gaschromatographie, die Massenspektrometrie oder die Infrarotspektroskopie zu ergänzen, zu ersetzen, oder vor allem im Consumer- und Low-Cost-Segment neue Anwendungsbereiche zu eröffnen. Unter dem Schlagwort „Elektronische Nase“ (Sensorsystem, siehe Abbildung 1) ist in den letzten 10 bis 15 Jahren ein neuer Typ von Messinstrument entstanden, der mehrere Sensoren in einem Array zusammenfasst und deren Signale auf die Analytexposition durch Methoden der Mustererkennung oder Multikomponentenanalyse auswertet [1].

Als Ergebnis einer Messung mit einem Sensorarray erhält man ein komplexes Signalmuster. Dieses muss in einer Mustererkennung mit Referenzmustern verglichen werden, um ihm einen analytischen Aussagegehalt zuzuordnen. Somit ist die Information, die man aus einem Sensorsystem ziehen kann, nicht nur von der Art der Mustererkennung, sondern in erster Linie auch vom Vorwissen, d. h. den Referenzmessungen, abhängig. Elektronische Nasen benötigen eine aufwendige Kalibration, mittels vollständig charakterisierten Proben, um mit ihrer Hilfe aussagefähige Ergebnisse zu liefern.

## 2 Grundlagen

### 2.1 Transducer

Es gibt eine Reihe unterschiedlicher Funktionsprinzipien für chemische Sensoren, die prinzipiell nach Art der sensitiven Schicht und des Transducers (Signalwand-




**Abb. 1.** Schematische Darstellung eines Sensorsystems und der zugehörigen Einzelkomponenten. Über einen optionalen Filter als erster Komponente zur Selektion werden die Teilchen der chemischen Rezeptorebene (Erkennungsschicht) zugeführt. Der Transducer setzt die in der Rezeptorebene veränderten physikochemischen Größen in elektrische Größen um, die danach von der Elektronik zu auswertbaren Signalen verwandelt werden. Diese Signale werden abschließend in einer numerischen Erkennungsschicht zu qualitativen und quantitativen Analysenwerten umgesetzt [2].

ler) unterschieden werden. Die sensitive Schicht tritt dabei in Wechselwirkung mit den Analytmolekülen, wohingegen der Transducer die dabei auftretenden Änderungen physikalischer Eigenschaften in ein messbares Signal umsetzt. Dabei gibt es eine Vielzahl denkbarer Möglichkeiten, wie beispielsweise die Änderung des Widerstands, der Impedanz, des Stroms, der Kapazität, der Austrittsarbeit, der Masse, der Temperatur, der optischen Absorption oder der optischen Schichtdicke. Im Folgenden soll exemplarisch auf zwei Transducerprinzipien eingegangen werden: einerseits auf die Änderung des Widerstands, wie es bei Metalloxidsensoren auftritt, und andererseits auf die Detektion der Massenänderung bei Schwingquarzen.

**Metalloxidsensoren (MOX-Sensoren)** Die klassischen Metalloxid-Sensoren sind keramische Dickschichtsensoren aus halbleitenden Metalloxiden. Als Substratmaterial wird  $\text{Al}_2\text{O}_3$  verwendet, das über eine Platinwendel geheizt wird. Über den Platin- oder Goldkontaktelektroden wird die sensitive Schicht aufgebracht, für die oft  $\text{SnO}_2$  eingesetzt wird. Die Sensoren werden über eine Heizspannung am Platindraht auf  $150\text{--}400^\circ\text{C}$  erhitzt, um heterogene katalysierte Reaktionen an der Sensoroberfläche zu ermöglichen. Im stationären Fall liegt ein dynamisches Gleichgewicht zwischen adsorbiertem Sauerstoff ( $\text{O}^-$ ,  $\text{O}_2^-$ ,  $\text{O}^{2-}$ ,

-OH) und Sauerstoff aus der Umgebung vor, das den Grundwiderstand bestimmt [3]. Durch Diffusion von Analyt an die Oberfläche findet eine katalytische Umsetzung des Sauerstoffs statt. Die Änderung der Konzentration an Ladungsträger (Ionen, Elektronen) führt zu einer Änderung der Leitfähigkeit. Reduzierende Gase haben eine Abnahme, oxidierende Gase eine Zunahme des elektrischen Widerstandes zur Folge. Die Selektivität für verschiedene Zielanalyten kann mit Hilfe mehrerer Parameter verändert werden. Neben einer Auswahl von möglichen Metalloxiden sind unterschiedliche Dotierungen / katalytische Aktivierung (Palladium, Platin, Gold) der sensitiven Schicht möglich. Dem genauen Herstellungsverfahren und der damit verbundenen unterschiedlichen Korngröße kommt ebenfalls eine große Bedeutung bei. Zudem kann durch die Wahl der geeigneten Betriebstemperatur zusätzlich Einfluss auf das Ansprechverhalten des Sensors genommen werden.

**Schwingquarzsensoren (QMB-Sensoren)** Das Messprinzip von Schwingquarzsensoren beruht auf der Massenänderung einer beschichteten Oberfläche. Auf einer dünnen Scheibe eines piezoelektrischen Materials, das beidseitig mit Elektroden versehen ist, wird eine sensitive Oberfläche aufgebracht; siehe Abbildung 2. Durch Ad- und Absorption von Molekülen aus der Gasphase wird diese Schicht schwerer und die Eigenfrequenz des gesamten Systems erniedrigt sich [4].

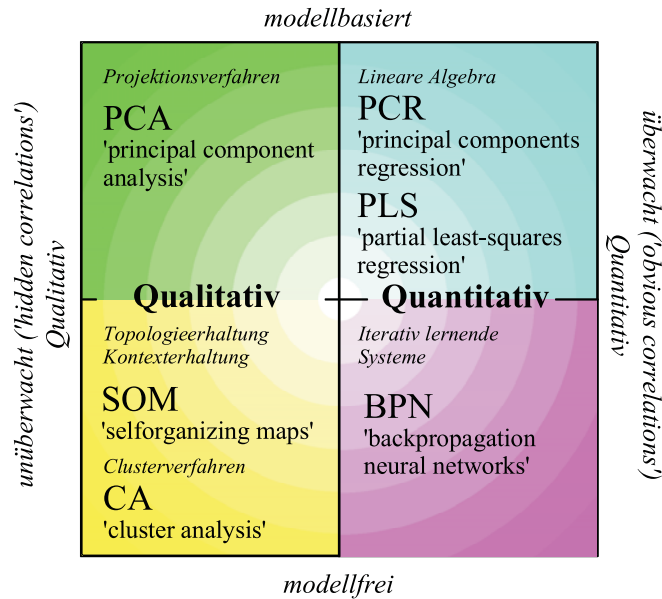


**Abb. 2.** Aufbau eines Schwingquarzsensors.

Wechselwirkungsmechanismen zwischen den Analytmolekülen und der sensitiven Schicht sind z. B. London-Kräfte, polare Wechselwirkungen, Polarisierbarkeit und Lewis-Säure-Base-Wechselwirkungen. Durch geeignete Wahl der Materialien lässt sich der Anteil der einzelnen Mechanismen verschieben und Selektivität schaffen. In der Praxis haben sich besonders langkettige Kohlenwasserstoffe, sowie unterschiedlich modifizierte organische und anorganisch Polymere, wie sie auch als stationäre Phase in der Gaschromatographie Verwendung finden, bewährt.

## 2.2 Mustererkennung und Multikomponentenanalyse

Eine Übersicht über mögliche Verfahren mit hohem Potential in diesem Bereich ist in Abbildung 3 schematisch dargestellt. Die Methoden lassen sich nach ver-



**Abb. 3.** Übersicht über wichtige Methoden zur Klassifizierung (qualitative Analyse) und Korrelation (quantitative Analyse) von Sensordaten (Details s. Text).

schiedenen Gesichtspunkten klassifizieren. Abbildung 3 liegt die Unterteilung nach den Gegensatzpaaren „Modellbasierte Verfahren“ – „Modellfreie Verfahren“ und „Überwachte Verfahren“ – „Unüberwachte Verfahren“ zugrunde. Alle Methoden stellen während der Kalibrierung einen Zusammenhang zwischen Messwerten und Konzentrationen von Gasen oder Flüssigkeiten her.

Modellbasiert bedeutet dabei, dass dieser Zusammenhang funktional (über eine Kalibrierfunktion) mit einem exakt definierten Satz von Parametern beschrieben werden kann. Diese Parameter können oft mit einer physikalischen Bedeutung verknüpft werden (z. B. die partielle Empfindlichkeit aus der Steigung der Kalibrierfunktion). Im einfachsten Fall handelt es sich bei der quantitativen Bestimmung um eine lineare Beziehung zwischen Messdaten und Konzentration.

Durch explizite Bestimmung der Umkehrfunktion der Kalibrierfunktion erhält man die Analysenfunktion, mit der anschließend die Konzentration unbekannter Proben ermittelt werden kann. Modellfreie Verfahren benutzen dagegen eine implizite Darstellung des gesuchten Zusammenhangs ohne Definition von Parametern mit physikalischer Bedeutung.

Die weitere Einteilung der Verfahren in überwacht und unüberwacht arbeitende Methoden bezieht sich auf die Art, in der der Kalibrierzusammenhang hergestellt wird. Überwachte Algorithmen benötigen zur Kalibrierung sowohl die Sensorsignale als auch die zugehörigen Konzentrationswerte eines Kalibrierdatensatzes. Die Kalibrierinformation wird durch einen Vergleich von Sensorsignalen und Konzentrationen berechnet (z. B. durch lineare oder nichtlineare Ausgleichsrechnung, iterative Anpassung der Gewichte in Backpropagation-Netzen). Überwachte Verfahren können damit sowohl in der qualitativen Analytik als auch in der quantitativen Analytik eingesetzt werden. Unüberwacht arbeitende Ver-

fahren benötigen dagegen zur Kalibrierung nur die Sensorsignale. Während der Kalibrierung wird dann versucht, die Sensorsignale nach Ähnlichkeitskriterien oder Unterschieden zu ordnen. Daher handelt es sich bei all diesen Verfahren um rein qualitativ arbeitende Algorithmen, die auf eine Klassifizierung der Sensorsignale abzielen.

Im Folgenden wird eine grobe Einteilung in vier verschiedene Bereiche gegeben, die jeweils in eigenen Abschnitten näher erläutert werden:

- modellbasierte unüberwachte Verfahren zur qualitativen Analyse,
- modellbasierte überwachte Verfahren zur quantitativen Analyse,
- modellfreie unüberwachte Verfahren zur qualitativen Analyse,
- modellfreie überwachte Verfahren zur quantitativen Analyse.

**Modellbasierte unüberwachte Verfahren zur qualitativen Analyse.** Zu dieser Gruppe von Verfahren zählt die Hauptkomponentenanalyse (engl. *Principal Component Analysis*, PCA).

Multivariate Daten einer Anordnung aus  $N$  Sensoren (Daten, die von mehr als einer Variable abhängen, z. B. die Signale mehrerer Sensoren für dieselbe Analytzusammensetzung) spannen i. a. nicht den gesamten  $N$ -dimensionalen Raum auf, der ihnen zur Verfügung steht. Bestehen zwischen den Sensoren Querempfindlichkeiten, so sind die Messwerte der Sensoren (die Variablen  $S$ ) untereinander zumindest teilweise korreliert. Durch die bestehenden linearen Abhängigkeiten der Sensorsignale ist die tatsächliche Dimension des Datenraums der  $N$ -Sensoren immer kleiner als die maximale Dimension  $N$ . Ziel der Hauptkomponentenanalyse ist es, eine optimale Beschreibung eines gegebenen Datensatzes in einer Dimension kleiner  $N$  zu finden. Möglichst gesucht ist die Reduktion auf einen zweidimensionalen oder dreidimensionalen Raum  $S^*$ , die eine Visualisierung der Ähnlichkeiten oder Unterschiede im Datenmaterial gestattet. Die Koordinatenachsen des neuen Raumes sollen unkorreliert (orthogonal) sein, damit jede Koordinate unabhängig von den anderen Eigenschaften (Information) der ursprünglichen Daten repräsentiert. Die Hauptkomponentenanalyse ist damit den Orthogonalprojektionsverfahren zuzuordnen. Das berechnete orthogonale Koordinatensystem  $S^*$  wird Merkmalsraum genannt. Dies lässt sich durch Gl. (1) beschreiben:

$$S^* = g(S). \quad (1)$$

**Modellbasierte überwachte Verfahren zur quantitativen Analyse.** Die gängigsten Methoden dieser Gruppe sind die Multivariate Lineare Regression (engl. *Multivariate Linear Regression*, MLR), die Hauptkomponentenregression (engl. *Principal Components Regression*, PCR) sowie die *Partial Least-Squares Regression* (PLS).

Bei der Multivariaten Linearen Regression handelt es sich um ein Verfahren, das einen funktionalen Zusammenhang zwischen den Sensorsignalen  $S$  und den Konzentrationswerten  $c$  in der allgemeinen Form beschreibt:

$$S = b_0 + b_1c + b_2c^2 + \dots + b_l c^l + \dots \quad (2)$$

Da diese Gleichung linear in den Parametern  $b_i$  ist, lassen sich die entstehenden Gleichungssysteme mit den Methoden der linearen Matrix-Algebra lösen.

Die Methode der Hauptkomponentenregression benutzt die in der Hauptkomponentenanalyse vorgenommene Orthogonalprojektion (Gleichung 1) in einen Raum mit reduzierter Dimension zur Herstellung eines quantitativen Zusammenhangs zwischen Konzentration und projizierten Sensorsignalen. Die Berechnung der Konzentration erfolgt über die Beziehung

$$c = f(S^*), \quad (3)$$

wobei hier  $S^*$  hier eine Teilmenge der orthogonal zerlegten Sensorsignale darstellt.

Die Methode der *Partial Least Squares* benutzt denselben funktionalen Zusammenhang (Gleichung 3). Der Unterschied zwischen den beiden Methoden besteht in der Art der Orthogonalzerlegung. (Eigenwert-Eigenvektor-Zerlegung bzw. Singulärwertzerlegung bei PCR, Lancosz-Bidiagonalisierung bei PLS [5]).

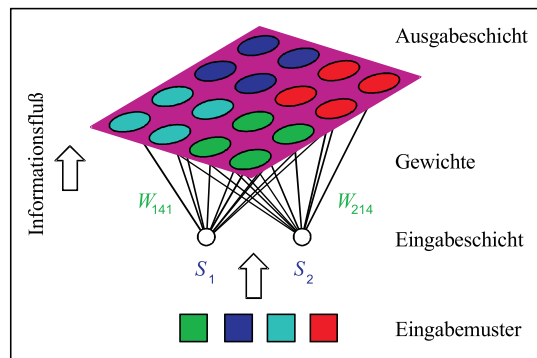
**Modellfreie unüberwachte Verfahren zur qualitativen Analyse** Zu den Verfahren dieser Kategorie zählen Methoden der Ballungsanalyse (engl. *Cluster Analysis*, CA) und Selbstorganisierenden Karten (*Self-Organizing feature Map*, SOM) nach T. Kohonen [6]. Klassifikationsprobleme im Sinne einer Mustererkennung lassen sich mit topologieerhaltenden Netzen bearbeiten. Die einfachste Architektur solcher Netze ist schematisch in Abbildung 4 dargestellt.

Die kontinuierlich veränderlichen Werte der Eingabeknoten ( $S_1, S_2$ ) sind über Gewichte mit jedem Knoten der Ausgabeschicht verknüpft. Durch die geometrische Anordnung der Knoten der Ausgabeschicht ergeben sich entgegen den im nächsten Abschnitt vorgestellten mehrschichtigen Netzen Nachbarschaftsbeziehungen zwischen den Ausgabeelementen.

Der Algorithmus von Kohonen nutzt diese Nachbarschaft für eine unüberwachte Clusterung der Eingabedaten nach Ähnlichkeitskriterien (nahegelegene Ausgabeelemente korrespondieren mit ähnlichen Eingabemustern, Informationsträger ist die Lage einer Ausgabeeinheit auf der Karte). Auf der planaren Karte werden die Eingangsmuster (z. B. Sensorsignale), dadurch von einem  $N$ -dimensionalen Datenraum auf eine zweidimensionale Darstellung abgebildet.

Vereinfacht wird dieser Netztyp nach folgendem Verfahren trainiert: Die Eingabemuster liegen als Vektoren vor. Für jedes Ausgabeelement der Karte gibt es genau einen Gewichtsvektor  $W$  derselben Dimension (je eine Verbindung zu jedem Eingabeelement). Zu Beginn des Trainings werden alle Gewichte zufällig mit Werten z. B. im Bereich  $-1$  bis  $+1$  belegt. Damit weisen alle Gewichtsvektoren zufällige Richtungen auf. Nun werden die Eingabevektoren nacheinander in zufälliger Reihenfolge ausgewählt und für jeden Eingabevektor der Gewichtsvektor als „Gewinner“ bestimmt, der dem Eingabevektor nach dem zuvor gewählten Ähnlichkeitskriterium am nächsten liegt (im einfachsten Fall wird die euklidische Distanz) eingesetzt.

Die Gewichtsvektoren werden dann, ausgehend vom Gewinnerelement als Zentrum, um einen vorgegebenen Faktor in Richtung des Eingabevektors ge-



**Abb. 4.** Schematische Darstellung einer topologieerhaltenden Karte nach Kohonen. Die verschiedenen Eingabemuster werden auf unterschiedliche Gebiete der Karte abgebildet.  $S_1$  = Sensor 1,  $S_2$  = Sensor 2, schematisch.

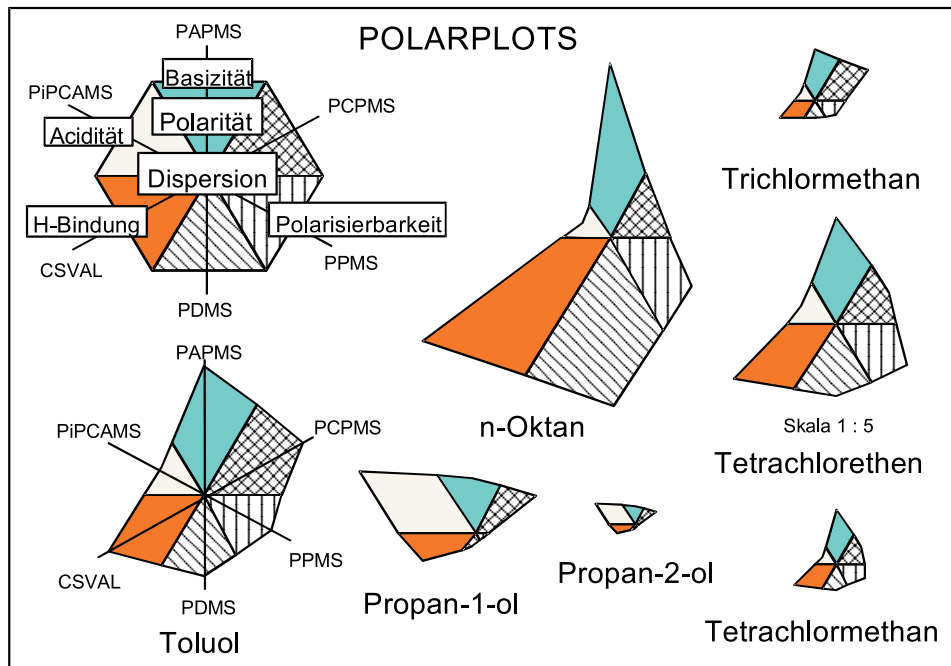
dreht. Das Ausmaß dieser Drehung (die Adaption) wird in dem Maße geringer, je weiter entfernt die Ausgabelemente vom Gewinner liegen. Diese radiale Abhängigkeit der Adaption vom Abstand zum Gewinnerelement wird durch die sogenannte Nachbarschaftsfunktion definiert. Dieser Vorgang wird für alle Vektoren des Kalibrierdatensatzes solange wiederholt, bis jedes Eingabemuster für eine vorgegebene Anzahl präsentiert wurde.

Ordnet man den Eingangsvektoren nach abgeschlossenem Training Bedeutung zu, kann die Fähigkeit der Karte zur Clusterbildung an einer Auftragung der Verteilung der einzelnen Klassen über der Lage auf der Karte überprüft werden. Die Größe der Karte (die Anzahl der notwendigen Ausgabelemente) kann nach der Verteilung der Kalibrierdaten auf der Kartenfläche beurteilt werden.

Unter der Bezeichnung Clusteranalyse werden Verfahren zusammengefasst, die einen Satz von Messdaten (Sensorsignale) in unterschiedliche Gruppen oder Klassen einteilen. Damit diese Verfahren zufrieden stellende Ergebnisse liefern, müssen die Gruppen und Klassen sich untereinander unähnlicher sein als die einzelnen Objekte in einer Gruppe resp. Klasse (Homogenität der Klassen) [8]. Ein vielverwendetes Ähnlichkeitsmaß ist der euklidische Abstand.

Visuelle Analysen auf Ähnlichkeiten und Differenzen der Sensormuster verschiedener Sensoren können anhand von Polardigrammen vorgenommen werden. Ein Beispiel hierzu ist in Abbildung 5 dargestellt. Dabei werden die Sensorantworten jedes der sechs Einzelsensoren mit seiner sensitiven Beschichtung (PAPMS, PCMS, ...) durch die Länge der um  $60^\circ$  versetzten angegeben und die Endpunkte aller Linien zu einem Hexagon verbunden.

**Modellfreie überwachte Verfahren zur quantitativen Analyse** Diese Gruppe von multivariaten Methoden wird in der Hauptsache durch die mehrschichtigen *Feed-forward*-Netze nach dem *Error-backpropagation*-Algorithmus vertreten [9]. Die Architektur für ein zweischichtiges, vollständig verbundenes Netz ist in Abbildung 6 dargestellt. Die Diskussion soll auf diesen Fall mit einer




**Abb. 5.** Polardiagramme für sechs verschiedene polymerbeschichtete Schwingquarzsensoren (PDMS Poly(dimethylsiloxan), PPMS Poly(phenylmethylsiloxan), PCPMS Poly(cyanopropylmethylsiloxan), PAPMS Poly(aminopropylmethylsiloxan), PiPCAMS Poly(isopropylcarbonsäuremethylsiloxan), CSVAL Chirasil-Val) und unterschiedliche Kohlenwasserstoffe (nach [7]). Ähnliche Sensorantworten korrespondieren mit ähnlichen Formen der Polardiagramme, d. h. die Form charakterisiert den Analyt und die Größe der Diagramme ist ein Maß für die Empfindlichkeit.


Ausgabeschicht und einer Zwischenschicht bei kontinuierlich veränderlichen Ein- und Ausgabewerten beschränkt bleiben.

Die Eingabemuster liegen wie im Fall der Kohonen-Karte als  $N$ -dimensionale Vektoren aus Sensorsignalen vor. Für die Adaption der Gewichte während des Trainings wird zu jedem Eingangsvektor ein korrespondierender Ausgabevektor benötigt. Die Eingangswerte sind über Gewichte mit den Knoten der Zwischenschicht verbunden; die Knoten der Zwischenschicht über weitere Gewichte mit der Ausgabeschicht. Jeder Knoten der Zwischenschicht und der Ausgabeschicht wird zusätzlich durch eine (nichtlineare) Transferfunktion beschrieben, die die Berechnung des Ausgangssignals aus dem Eingabewert steuert. Die Transferfunktion wird meist vor Beginn des Trainings definiert und bleibt während des Trainings fest. Die Zwischenschicht bleibt für den Benutzer unsichtbar und wird deshalb als verborgene Schicht bezeichnet. Die gezeigte Anordnung ist in der Lage, für jeden Eingangsvektor ein Ausgabemuster (Konzentrationen von verschiedenen Analyten) zu berechnen. Führt man die Adaption der Gewichte dann von der Ausgabeschicht ausgehend proportional zur Differenz zwischen gewünschtem Ausgabewert und tatsächlichem Ausgabewert in Richtung auf die Eingabeschicht durch, spricht man von *Error Backpropagation*. Mögliche Kriterien für





**Abb. 6.** Schematische Darstellung eines zweischichtigen *Feed-forward*-Netzes. Die Eingangsvektoren der Dimension 4 ( $S_1$  bis  $S_4$ ) werden über die Zwischenstufe der verborgenen Schicht auf die Ausgangswerte ( $S_1^*$  und  $S_2^*$ ) abgebildet. Diese Abbildung entspricht einem Informationsfluß in der angedeuteten *Feed-forward*-Richtung. Die Adaption der Gewichte wird ausgehend von der Differenz zwischen gewünschter und tatsächlicher Netzausgabe in der entgegengesetzten Richtung durchgeführt (*backpropagation of errors*).



**Abb. 7.** Typischer Signalverlauf bei einer Headspace-Extraktion. Zusätzlich dargestellt mögliche Merkmale extrahiert aus den Daten (vgl. auch Tabelle 1) [10].

den Abbruch der Trainingsphase können hier Unterschreitungen einer minimalen Abweichung zwischen Netzausgabe und Vorgabe sein.


### 3 Systemaufbau

#### 3.1 Probennahme

Gasförmige Proben, wie beispielsweise Luftschadstoffe, können direkt der Elektronischen Nase zugeführt werden, wohingegen flüchtige Substanzen aus flüssigen und festen Proben erst geeignet aufbereitet werden müssen. Für gewöhnlich geschieht dies mittels einer Headspace-Extraktion. Die einfachste Form stellt dabei die statische Headspace-Extraktion dar, bei der in einem abgeschlossenen Probegefäß bei definierter Temperatur die flüchtigen Substanzen in Matrix und Gasphase ins thermodynamische Gleichgewicht gebracht werden. Ein Aliquot der Gasphase wird entnommen und dem Sensorsystem zugeführt. Ebenso sind Ansätze mit dynamischer Headspace-Extraktion denkbar.

### 3.2 Probenvorbereitung

Für schwierig zu bestimmende Analytgemische bietet sich eine Probenvorbereitung vor Aufgabe aufs System an. Diese kann in zwei Untergruppen aufgeteilt werden. Einerseits ist zur Steigerung der Empfindlichkeit eine vorhergehende Aufkonzentrierung von mittel bis schwerflüchtiger Substanzen per Adsorptionsröhrchen oder Kryofokussierung möglich, andererseits lässt sich die Qualität des Ergebnisses verbessern, indem störende Substanzen mittels Filter oder dispersiven Elementen abgetrennt werden.



**Abb. 8.** Beispiel des Einsatzes eines dispersiven Elements zur Voraufftrennung der Proben vor der Aufgabe auf das Sensorsystem. Das dispersive Element besteht in diesem Fall aus einer kurzen gepackten Säule, die den Sensoren vorgeschaltet ist und die polare Analyte wie Wasser zu einem gewissen Umfang zurückhält [11].

### 3.3 Merkmalsextraktion (*Feature Extraction*)

Aus den oben gezeigten Messkurven werden nun charakteristische Merkmale (engl. *features*) abgeleitet, die für die nachfolgende Mustererkennung bzw. Multikomponentenanalyse als Eingangsdaten dienen. Hierbei kann durchaus mehr als ein feature pro Sensor (so z. B. der maximale Signalhub und die Fläche unter der Kurve) „gleichzeitig“ verwendet werden und damit den Signaleingangsraum eine  $n$ -fach Sensorarrays auf  $2 \cdot n$  oder mehr Dimensionen vergrößern. Eine Übersicht zu typischen Features, wie sie z. B. von der Software Argus bzw. MultiSens verwendet werden [12,13], zeigt Tabelle 1. Selbstredend werden hier teilweise stärker korrelierte Daten generiert, wobei eine nachfolgende Dimensionsreduktion durch Verfahren wie in Abbildung 3 dargestellt automatisch erfolgt.

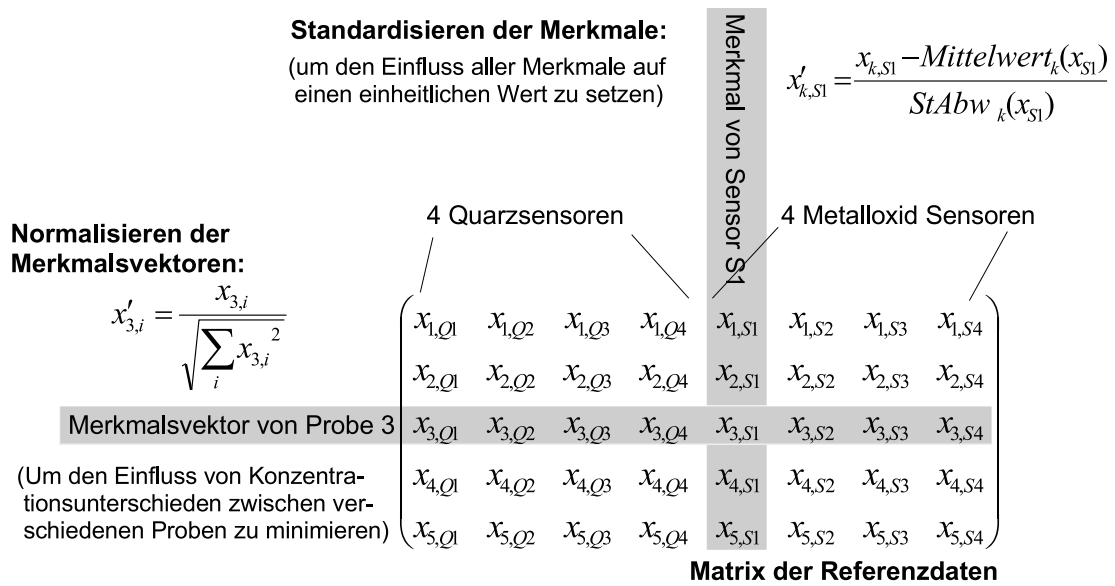
**Tabelle 1.** Die wichtigsten Merkmalsextraktionsverfahren in Argus.  $S(x)$  ist der Wert des Sensors zum Zeitpunkt  $x$  in den Messdaten.  $N$  ist die Anzahl der Messwerte [2,14].

<b>Merkmal</b>	<b>Parameter</b>	<b>Formel</b>	<b>Beschreibung</b>
<i>Min</i>	-	$\max(S(x))$	Minimum der Messwerte
<i>Max</i>	-	$\min(S(x))$	Maximum der Messwerte
<i>Max-Min</i>	-	$Max - Min$	Spanne der Messwerte
<i>Average</i>	-	$\sum S(x) / N$	Durchschnitt der Messwerte
<i>Base</i>	-	$S(1)$	Basislinie ermittelt als erster Messwert
<i>Base3</i>	-	$S(1)+S(2)+S(3)$	Basislinie ermittelt als Mittelwert der ersten drei Messwerte
<i>Sig-Base</i>	-	$\max(Max - Base, Base - Min)$	Signalhöhe als Wert des größten Unterschiedes zu Basislinie
<i>Sig-Base3</i>	-	$\max(Max3 - Base3, Base3 - Min3)$	Wie Sig-Base, nur wird jeweils über drei Werte gemittelt.
<i>Sig/Base</i>	-	$Sig-Base / Base$	Signalhöhe geteilt durch Basislinie
<i>SigAt</i>	T, Av	$\sum_{T-(Av/2)}^{T+(Av/2)} S(x) - \sum_1^{Av} S(x)$	Signalhöhe zum Zeitpunkt T gemittelt über Av Messwerte.
<i>SigAt-BaseAt</i>	SigT, BaseT, Av	$\sum_{SigT-(Av/2)}^{SigT+(Av/2)} S(x) - \sum_{BaseT-(Av/2)}^{BaseT+(Av/2)} S(x)$	Differenz der gemittelten Messwerte zwischen Zeitpunkt SigT und BaseT.
<i>MaxDev</i>	-	$\max(S(x) - S(x - 1))$	Maximale Ableitung als Differenz zweier aufeinander folgender Messwerte
<i>TMax</i>	-	$\min\{x \mid f(x) = Max\}$	Zeit bis zum Erreichen des maximalen Messwertes.
<i>A</i>	-	$\sum (S(x) - Base)$	Fläche zwischen Messkurve und Basislinie
<i>AMax</i>	-	$\sum_1^{TMax} (S(x) - Base)$	Fläche zwischen Messkurve und Basislinie bis zum Zeitpunkt des Maximums

### 3.4 Sensordatenfusion


Wie im Abschnitt 2.1 bereits erläutert, stehen je nach Applikation eine ganze Reihe unterschiedlicher Transducertypen zur Anwendung als Sensorarray zur Verfügung. Neben physikalisch-chemischen Randbedingungen (Sensoren die Analyten zersetzen, sollten am physikalischen Ende der Kette stehen) ergeben sich auch Implikationen für die Datenauswertung. Da bei unterschiedlichen Transducertypen ganz unterschiedliche physikalische Parameter gemessen werden (so z. B. Leitfähigkeiten bzw. Widerstandsänderungen im Falle von Metalloxidsensoren, Frequenzverstimungen im Falle von schwingquarzsensoren, Potenzialänderungen bei elektrochemischen Zellen, Spannungsänderungen im Falle von kalorischen Sensoren etc.), ist der Eingangsdatenraum der nachgeschalteten Muste-

rererkennung bzw. Multikomponentenanalyse ebenfalls nicht homogen. Um dennoch vergleichbare Signale (bzw. Merkmale) den Algorithmen zur Verfügung zu stellen, werden die Daten vorverarbeitet. Ein wichtiger Schritt ist hierbei das Standardisieren der Merkmale, welches ermöglicht, eine vergleichbare Gewichtung der einzelnen Merkmale (Sensorsignale auch in heterogenen Anordnungen und unterschiedliche Merkmale pro Sensor, vgl. Tabelle 1) sicherzustellen. Die Vorgehensweise ist in Abbildung 9 dargestellt. Die so behandelten Merkmale können nun gemeinsam einer Auswertung (z. B. einer Hauptkomponentenanalyse) zugeführt werden.



**Abb. 9.** Standardisieren und Normalisieren von Merkmalen. In diesem Beispiel ist ein Datensatz mit 4 Quarzsensoren, 4 Metalloxidsensoren und 5 Proben dargestellt.

Abbildung 9 zeigt auch noch einen weiteren wichtigen Vorverarbeitungsschritt. Dieser wird angewandt wenn eine konzentrationsunabhängige Aussage bezüglich eines Analyten erfolgen soll. Im Sprachgebrauch hat sich hier der Begriff „Normalisieren“ eingebürgert, wobei mathematisch korrekt Normieren wäre. Diese Methode wird immer dann angewandt wenn klassifiziert, d. h. Proben in Gruppen eingeteilt werden sollen. Ein Beispiel ist die Untersuchung von Mehrweg-Leergutgebinden für Chemikalien. Je nach Außentemperatur ist der Dampfdruck im Gebinde (z. B. 100-Liter-Chemikalienfass) durchaus stark unterschiedlich. Dies interessiert jedoch bei der gestellten Aufgabe der korrekten Wiederbefüllung nicht, wenn nur zwischen den Produkten A, B, C unterschieden werden soll, die sich zuvor im Gebinde befunden haben. Bildlich gesprochen ist der Schritt des Normierens das Abbilden des Durchstoßpunktes des gemessenen Richtungsvektors der Probe durch die höherdimensionale Einheitskugel im Merkmalsraum.



**Abb. 10.** PCA-Biplot, in dem Scores und Loadings einer PCA überlagert eingetragen sind [10].

## 4 Beispiele

### 4.1 Klassifikation von Lösungsmitteln


Wie oben bereits angesprochen, ist die Aufgabe das korrekte klassifizieren von Lösungsmitteln. Die Lösungsmittel im Beispiel sind Propanol, Toluol, Anisol und Cyclohexanon sowie ein Kalibriergemisch als Mischung aus den vorgenannten Einzelkomponenten. Die Lösungsmittel wurden mit einem Sensorsystem bestehend aus acht Schwingquarzsensoren (Q1–Q8) und vier Metalloxidsensoren (M1–M4) vermessen. Abbildung 10 zeigt das Ergebnis der Messungen, ausgewertet über eine Hauptkomponentenanalyse (PCA) in Form eines Bi-Plots an. Die Vorteile des hybriden Systems erkennt man daran, dass der Parameterraum aufgespannt durch die beiden verschiedenen Sensorarten (Metalloxide und Schwingquarze) deutlich größer und „orthogonaler“ zueinander ist, im Vergleich zum Aufspannen des Parameterraums „nur“ durch entweder Schwingquarze oder Metalloxide.

An dieser Stelle soll aber auch deutlich erwähnt werden, dass diese Aussage nicht grundsätzlich generalisiert werden soll, sondern an diesem Beispiel verdeutlicht wurde. Es gibt auch eine ganze Reihe von Applikationsbeispielen, bei denen nur ein Sensortyp zur Lösung der Aufgabenstellung ausreicht, ja sogar die

Hinzunahme von weiteren Sensortypen nur Rauschen beiträgt. Der praktische Nutzen der Datenfusion über die verschiedenen Sensortypen hinweg muss im Einzelfall überprüft werden.

## 4.2 Weinklassifikation

Analog zur Klassifikation von Lösungsmitteln wäre es auch wünschenswert, komplexere Proben wie beispielsweise verschiedene Weine, Kaffeesorten oder Olivenöle zuordnen zu können und im Idealfall sogar nach Qualitätskriterien zu klassifizieren. Die Idee dahinter ist das Bouquet im Dampfraum der Probe zu vermessen und ähnlich der menschlichen Nase die einzelnen geruchsaktiven Komponenten der Probe zu erfassen und zu einem Summensignal zu gelangen, das mit der Güte und dem Charakter des Weines korreliert. Wie der PCA-Plot in diesem Beispiel zeigt (Abbildung 11), ist auf den ersten Blick eine Identifizierung verschiedener Rebsorten ohne weiteres möglich. Allerdings korreliert diese keinesfalls mit dem Geschmack des Weines, oder eventuellen Geruchsstoffen, sondern vor allem mit dem Alkoholgehalt. Das Ethanol ist in diesem Fall nach Wasser der Hauptbestandteil und somit ein Störanalyt, der das Signal sämtlicher anderen flüchtigen Substanzen überdeckt. Allerdings ist es auch selbst mit klassischen analytischen Methoden, wie beispielsweise der Gaschromatographie, sehr schwer, und bei einigen Substanzen teilweise sogar unmöglich, in den Empfindlichkeitsbereich der menschlichen Nase zu gelangen. Somit ist dies ein zu komplexes Problem, dem ein Lösungsversuch mittels einer Elektronischen Nase nicht gerecht wird.



**Abb. 11.** PCA-Plot verschiedener Weinsorten. Wie das Ethanol-Wasser-Beispiel zeigt, erfolgt die Diskriminierung alleine auf Grund des unterschiedlichen Alkoholgehalts.

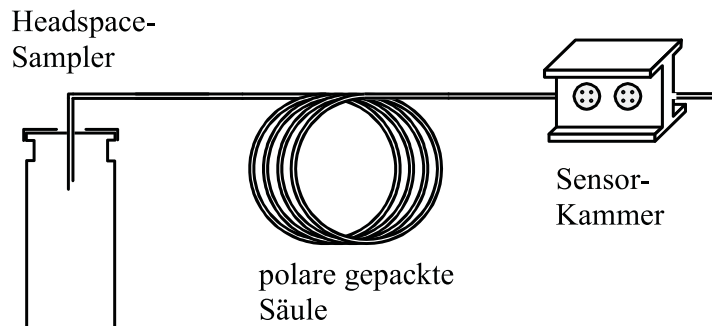
### 4.3 Quantifikation von Lösungsmittlemissionen

Die Reduzierung von Gerüchen und Emissionen bei Lebensmittelverpackungsmaterialien, wie auch bei anderen Verbrauchsgütern, ist ein Anliegen der Hersteller, weshalb sowohl klassische Analytik als auch humansensorischen Test-Panels zur Qualitätskontrolle herangezogen werden. Dies ist durchaus mit einem hohen Aufwand verbunden, da die Beurteilung von Emissionen aus Verpackungsmaterialien die Konzentration an Restlösemittel und der Geruchseindruck einer Probe nicht gleichgesetzt werden dürfen. Der Grund dafür ist, dass für klassische Lösungsmittel die Geruchsschwellen in der Regel um ein vielfaches höher liegen und daher von der menschlichen Wahrnehmung schlechter erkannt werden. Im Vergleich dazu gibt es Spurenanalyte, die den Geruch des Verpackungsmaterials entscheidend prägen. Diese entstehen vorwiegend durch oxidativen Abbau, wie er beispielsweise bei der Trocknung von Druckfarbe auftritt.

Bereits die Überprüfung nach Einhalten der Lösungsmittelgrenzwerte bedeutet einen großen apparativen Aufwand. Üblicherweise wird hierzu die Kapillarchromatographie nach einer Probenvorbereitung mittels Headspacetechnik eingesetzt [3]. Eine definierte Probenmenge ( $100 \text{ cm}^2$ ) wird dazu in ein Gläschen mit festgelegtem Volumen ( $20,3 \text{ ml}$ ) gegeben und verschlossen. Danach erfolgt die Äquilibrierung bei einer vorgegebenen Temperatur ( $85^\circ\text{C}$ ), solange bis sich die flüchtigen Komponenten in der Matrix und in der Gasphase im Gleichgewicht befinden (1 Stunde). Durch ein Septum wird mit einer Hohnadel in das Gläschen gestochen. Der Innenraum wird auf einen vorgegebenen Druck gebracht und anschließend ein Aliquot des Gasraumes (engl. *headspace*) entnommen. Dieses wird dem Gaschromatographen zugeführt, wo die Trennung der Einzelkomponenten in der Regel an einer Fused-Silica-Kapillarsäule stattfindet. Die Untersuchungsdauer lässt sich wesentlich verkürzen, indem man ein Temperaturprogramm fährt und die Säulentemperatur langsam erhöht. Dadurch erreicht man eine gute Auftrennung von Substanzen mit kurzer Retentionszeit, aber dennoch eine Reduktion der Retentionszeiten von Substanzen, die erst spät eluiert werden. Für die Analytdetektion gibt es mehrere Möglichkeiten. Gebräuchliche Systeme sind der Flammenionisationsdetektor (FID) oder das Massenspektrometer (MS), mit dem gleichzeitig noch eine Identifikation der gefundenen Substanzen möglich ist. Für eine genaue Quantifizierung muss allerdings im Voraus erst das System für jede einzelne der zu untersuchenden Substanzen kalibriert werden. Durch Aufgabe bekannter Lösungsmittelmengen wird für jeden Einzelanalyten der Responsefaktor, der den Zusammenhang zur Peakfläche darstellt, berechnet oder noch besser eine Kalibriergerade erstellt. Als Grenzwert für die Gesamtmenge an organischen Lösungsmitteln gelten  $20 \text{ mg/m}^2$ .

Für die Routineüberprüfung von Verpackungsmaterialien mit einer bekannten Auswahl von möglichen flüchtigen Substanzen stellt die Elektronische Nase eine einfache und schnelle Alternative zur oben beschriebenen Methode dar. Der Hauptunterschied ist, dass sämtliche Inhaltsstoffe nicht sequentiell sondern gleichzeitig detektiert werden, woraus sich zusätzlich auch noch ein zeitlicher Vorteil ergibt. Frühere Messungen mit einem einfachen Sensor-Array ergaben sehr zufriedenstellende Ergebnisse sowohl was die Beurteilung der Restlösemit-

telmenge, als auch des Geruchs von Verpackungsfolie anbelangt [15]. Jedoch schon der Übergang von Kunststoff- zu Papier- und Kartonmaterialien bereitet Schwierigkeiten, da Störanalyte das Ergebnis verfälschen. In einem robusteren Ansatz wurde die Elektronische Nase deshalb um eine kurze polare Säule erweitert, wodurch eine Abtrennung von der sich im Headspace befindlichen Feuchte möglich ist, und zuverlässige Aussagen über die Restlösemittelmenge ermöglicht [11].



**Abb. 12.** Nach dem Headspace-Sampler wird der Gasstrom über eine polare gepackte Säule geleitet, die zur Abtrennung von Wasser dient. Mit diesem experimentellen Aufbau ist es möglich, sehr schnell den Gesamtlösemittelgehalt zu bestimmen. Dieser Aufbau erzeugt Signale, wie in Abbildung 8 gezeigt.


Für die Messkammern wurden Metalloxidsensoren gewählt, da diese sehr empfindlich sind und eine hohe Langzeitstabilität aufweisen. Sie bestehen aus einem Substrat (SiN), auf das Zinndioxid als sensitive Schicht aufgebracht wird. Um unterschiedliche Sensitivitäten zu erreichen, wurden die vier Sensoren mit zwei verschiedenen Palladiumkonzentrationen dotiert und bei zwei unterschiedlichen Temperaturen betrieben. Die verwendeten Sensoren wurden dabei mit der Pulvermethode hergestellt, da es hier leichter möglich ist, eine poröse Schicht mit großer aktiver Oberfläche und kontrollierter Korngrößenverteilung herzustellen.

Die Datenauswertung erfolgt mittels einer Hauptkomponentenregression (engl. *Principal Component Regression*, PCR) und führt zu einer Vorhersagegenauigkeit die innerhalb der geforderten  $2 \text{ mg/m}^2$  liegt, was einem Zehntel des Grenzwertes entspricht.

## 5 Schlussfolgerung

Wie das Beispiel mit der Klassifikation verschiedener Weinsorten gezeigt hat, ist eine deutliche Gefahr gegeben, den Begriff „Elektronische Nase“ falsch zu verstehen und mit dem biologischen Vorbild gleichzusetzen [16]. Ohne eine geeignete Fragestellung und Wissen über die Beschaffenheit einer Probe kann das Ergebnis einer Messung falsch gedeutet werden. Allerdings bieten Sensor-Arrays





**Abb. 13.** Hauptkomponentenregression (PCR) für die Gesamtkonzentration an organischen Lösungsmitteln. Aufgetragen sind die vorhergesagten Lösungsmittelkonzentrationen (aus den Sensorsignalen) für jeweils drei Messungen einer Probe (hier Verpackungsmaterialien) über den Mittelwert aus GC/MS-Messungen. Wie aus der Abbildung ersichtlich wird, wurde für jede Probe der Grenzwert von  $20 \text{ mg/m}^2$  eingehalten.

in Kombination mit einer intelligenten Probenvorbereitung und einer Datenauswertung durchaus für definierte Problemstellungen einen brauchbaren Lösungsansatz, der etablierten Methoden in Aufwand und Preis überlegen ist. Liegen geeignete Referenzproben vor, so bietet die Elektronische Nase die Möglichkeit, selbst in einer Fabrikationsumgebung (engl. *factory floor*) eine schnelle und verlässliche Klassifikation (gut/schlecht) oder eine quantitative Vorhersage (Wieviel Rest-Lösungsmittel ist vorhanden?) von routinemäßig hergestellten Proben vorzunehmen.

Neben der „intellektuell gesteuerten“ Merkmalsextraktion werden in jüngster Zeit vermehrt sogenannte 3D-Methoden bzw. „*multiway methods*“ [17] entwickelt und getestet. Statt der Auswahl signifikanter Punkte aus einer Messkurve (wie z. B. der maximale Signalwert) werden in diesem Fall alle Messdaten der gesamten Kurve als Eingangsdaten für die Auswertung verwendet. Hiermit können auch automatisch u. U. weniger stark korrelierte Messdaten von den Algorithmen selektiert und für die nachfolgende Klassifikation / quantitative Vorhersage herangezogen werden. Praktische Erfahrungen sind bisher jedoch noch in geringem Umfang vorhanden. Versuche hierzu sind im Gange und Publikationen sind in Zukunft zu erwarten.

## Danksagung

Die Autoren bedanken sich für intensive Diskussionen mit Dr. Jan Mitrovics (JLM innovation), welcher auch als aktiver Partner in den EU-Netzwerken NOSE

I und II (<http://www.nose-network.org>) wichtige Beiträge zum Fortschritt in diesen Bereichen geleistet hat.

## Literatur

1. J. W. Gardner und P. N. Bartlett. A brief history of electronic noses. *Sensors and Actuators B*, 18–19:211–220, 1994.
2. W. Göpel. Chemical imaging I: Concepts and visions for electronic and bioelectronic noses. *Sensors and Actuators B*, 52:125–142, 1998.
3. K.-D. Schierbaum. *Elektrische und spektroskopische Untersuchungen an Dünnschicht-SnO<sub>2</sub>-Gassensoren*. Dissertation, Universität Tübingen, 1987.
4. M. S. Nieuwenhuizen und A. Venema. Mass-sensitive devices. In *Sensors: Volume 2: Chemical and Biochemical Sensors Part I*, W. Göpel, J. Hesse und J. N. Zemel (Hrsg.), S. 647–680, VCH Verlag Chemie, Weinheim, 1991.
5. R. Marbach und H. M. Heise. Calibration modeling by principal component regression and its optimization using an improved leverage correction for prediction testing. *Chemom. Intell. Lab. Syst.*, 9:45–63, 1990.
6. T. Kohonen. *Self-Organization and Associative Memory*, 3rd ed. Springer-Verlag, Berlin, New York, 1989.
7. A. Hierlemann, U. Weimar, G. Kraus, G. Gauglitz und W. Göpel. Environmental chemical sensing using quartz microbalance sensor arrays: Application of multi-component analysis techniques. *Sensors and Materials*, 7:179–189, 1994.
8. N. Bratchell. *Cluster Analysis in Data Handling in Science and Technology 9: Multivariate Pattern Recognition in Chemometrics, illustrated by case studies*. R. G. Brereton (Hrsg.), Elsevier, Amsterdam, London, New York, Tokyo, 1992.
9. B. J. Wythoff. Backpropagation neural networks: A tutorial. *Chemom. Intell. Lab. Syst.*, 18:115–155, 1993.
10. J. Mitrovics. *Auswerteverfahren für Gassensorarrays*. Dissertation, Universität Tübingen, <http://w210.ub.uni-tuebingen.de/dbt/volltexte/2004/1535>, 2004.
11. F. Röck, A. Gurlo und U. Weimar. Multisensor system for characterization of packaging emissions: Prediction of total solvent amount and odor scores. *Analytical Chemistry*, 9(77):2762–2769, 2005.
12. Argus 1.15, AppliedSensor, <http://www.appliedsensor.com>.
13. MultiSens 1.0, JLM Innovation, <http://www.jlm-innovation.de>.
14. T. Hermle. *Bewertung und Optimierung rechnerbasierter Auswertemethoden für chemische Gassensoren*. Diplomarbeit, Universität Tübingen, 1998.
15. M. Frank, H. Ulmer, J. Ruiz, P. Visani und U. Weimar. Complementary analytical measurements based upon gas chromatography-mass spectrometry, sensor system and human sensory panel: a case study dealing with packaging materials. *Anal. Chim. Acta*, 431:11–29, 2001.
16. M. Schweizer-Berberich, A. Harsch und W. Göpel. Wie menschlich sind elektronische Nasen? *Technisches Messen*, 62:237, 1995.
17. R. Bro und T. Skov. *Multiway analysis* (Vortrag zum Download). NOSE network (<http://www.nose-network.org>), NOSE II, Alpbach short course, 2004.

# Sensorik in der elektrischen Energietechnik

Ernst Gockenbach

Universität Hannover, Institut für Energieversorgung und Hochspannungstechnik,  
Fachgebiet Hochspannungstechnik (Schering-Institut)

**Zusammenfassung.** Die Sensorik in der elektrischen Energietechnik ist geprägt durch die rauen Umgebungsbedingungen, die hohen Anforderungen an die Zuverlässigkeit und die Vielzahl der zu erfassenden Parameter. Ein weiteres Merkmal sind die allgemein geringen Anforderungen an die Messunsicherheit, die auf der großen Streuung der zu erfassenden Parameter und der Unsicherheit der Interpretation der Ergebnisse beruhen. In den Einrichtungen der elektrischen Energietechnik gibt es eine große Zahl von Messgrößen, deren Erfassung für den Betrieb und die Bewertung des Betriebszustandes erforderlich ist. Bereits die Vielzahl der einzelnen Komponenten wie Generatoren, Transformatoren, Übertragungssysteme wie Freileitung oder Kabel, Schaltanlagen, Schalter, Überspannungsableiter lässt erkennen, dass die Sensorik einen großen Bereich von zu erfassenden Parametern abdecken muss. Die Sensorsysteme lassen sich aus der Sicht des Gerätebetreibers in zwei große Gruppen unterteilen, Sensorsysteme für die Betriebsführung und Sensorsysteme für die Diagnostik. Aus der Sicht der Messtechnik und der zu erfassenden Parameter ist eine andere Einteilung möglich, Sensorsysteme für die differentielle Erfassung und Sensorsysteme für die integrale Erfassung. Es werden die verschiedenen Messgrößen und der dazugehörigen Sensorsysteme wie Strom und Spannung, Teilentladungen, Gas-in-Öl, Feuchte und Temperatur anhand von Beispielen beschrieben. Teilentladungen werden als ein sehr frühes Warnsignal für lokale Defekte genutzt, allerdings ist neben der Erfassung auch die Ortung für die Beurteilung der Gefährdung der Komponenten von großer Bedeutung. Die Analyse der in einer Isolierflüssigkeit gelösten Gase erlaubt eine Diagnose der im Isoliersystem aufgetretenen Vorgänge. Neben der Menge der durch die Vorgänge erzeugten Gase ist auch das Verhältnis der Gasarten untereinander von Bedeutung. In Abhängigkeit dieser Verhältnisse ist dann eine Diagnose möglich. Für Isoliersysteme ist der Einfluss der Feuchte von großer Bedeutung, da die elektrischen Eigenschaften sich bei ihrer Zunahme verschlechtern. Ein Maß für den Zustand des Papiers in Leistungstransformatoren ist daher die Länge der Molekülketten. Eine mittelbare Methode der Bestimmung der Feuchte in einem Isoliersystem ist die Nutzung der Gleichgewichtsbedingungen bezüglich der Feuchte in einem abgeschlossenem System aus festem und flüssigem Isolierstoff. Eine empfindlichere Methode der Feuchtebestimmung ist der Einsatz eines Feuchtesensors, der an die jeweilige Komponenten angepasst werden muss. Für die Beanspruchung eines Isoliersystems ist die Temperatur sehr wichtig, da eine Temperaturerhöhung zu einer schnelleren Alterung des Isolierstoffes führt. Es werden für verschiedene Komponenten Temperatursensoren vorgestellt, die an die jeweiligen Anforderungen angepasst sind.

## 1 Einleitung

Die Sensorik in der elektrischen Energietechnik ist geprägt durch die rauen Umgebungsbedingungen, die hohen Anforderungen an die Zuverlässigkeit und die Vielzahl der zu erfassenden Parameter. Ein weiteres Merkmal sind die im allgemeinen geringen Anforderungen an die Messunsicherheit, die auf der großen Streuung der zu erfassenden Parameter und der Unsicherheit der Interpretation der Ergebnisse beruhen. Aufgrund der erwarteten Betriebszeiten der Komponenten der elektrischen Energietechnik von 40 Jahren sollen auch die Sensoren und die dazugehörigen Erfassungssysteme über diesen langen Zeitraum einwandfrei und möglichst wartungsfrei arbeiten.

Die im folgenden beschriebenen Sensorsysteme bestehen grundsätzlich aus drei Komponenten, dem Sensor oder Messwertaufnehmer, in dem die zu messende Größe oft in ihrer Amplitude verringert wird, um einem Erfassungssystem zugeführt zu werden, dem Übertragungssystem vom Sensor zum Erfassungssystem und dem eigentlichen Erfassungssystem. Die damit mögliche Erfassung von betriebsrelevanten Daten wird im allgemeinen mit dem Begriff Monitoring bezeichnet und beinhaltet eine in der Regel unbewertete Erfassung von Messdaten. Die aufgrund von Erfahrungen und Vergleichsdaten dann sich anschließende Bewertung der Messdaten und sich daraus ergebende Ableitung von Maßnahmen wird Diagnostik genannt.

## 2 Charakterisierung der Sensorsysteme

In den Einrichtungen der elektrischen Energietechnik gibt es eine große Zahl von Messgrößen, deren Erfassung für den Betrieb und die Bewertung des Betriebszustandes erforderlich ist. Bereits die Vielzahl der einzelnen Komponenten wie Generatoren, Transformatoren, Übertragungssysteme wie Freileitung oder Kabel, Schaltanlagen, Schalter, Überspannungsableiter etc. lässt erkennen, dass die Sensorik in der Energietechnik einen großen Bereich von zu erfassenden Parametern abdecken muss.

Die Sensorsysteme lassen sich aus der Sicht des Gerätebetreibers in zwei große Gruppen unterteilen:

- Sensorssysteme für die Betriebsführung,
- Sensorsysteme für die Diagnostik.

Aus der Sicht der Messtechnik und der zu erfassenden Parameter ist eine andere Einteilung möglich:

- Sensorsysteme für die differentielle Erfassung,
- Sensorsysteme für die integrale Erfassung.

Die verschiedenen Komponenten der elektrischen Energieversorgung erfordern jeweils spezifische Sensorsysteme, die im Rahmen dieses Beitrages nicht vollständig beschrieben werden können. Eine kurze Aufzählung der zu erfassenden Messgrößen für einige Geräte soll dieses belegen.

Bei einem Generator in einem Kraftwerk sind folgende Größen von Bedeutung:

- Elektrische Größen: Strom, Spannung, Leistung;
- Mechanische Größen: Drehzahl, Geräuschpegel, Körperschall
- Thermische Größen: Temperatur der Wicklungen, Temperatur der Lager;
- Dielektrische Größen: Zustand der Isolierung.

Bei einem Leistungstransformator, der zu den kostenintensivsten Einrichtungen der elektrischen Energieversorgung gehört, ist die Zahl der zu erfassenden Parameter etwa mit der eines Generators vergleichbar, wobei die spezifische elektrische Beanspruchung der Isolierung höher und deren Aufbau in der Regel komplexer ist.

Bei einem Mittel- oder Hochspannungskabel ist die Anzahl der zu beachtenden Parameter deutlich geringer, da hier nur die elektrischen, thermischen und dielektrischen Größen zu beachten sind. Erschwerend ist allerdings die räumliche Ausdehnung des Kabels, so dass hier sehr oft nur integrale Größen erfasst werden können, die eine Bewertung schwieriger gestalten.

Alle anderen Geräte in der elektrischen Energietechnik wie Schaltanlagen, Schalter, Überspannungsableiter weisen im allgemeinen eine geringe Zahl von zu erfassenden Parametern auf, was allerdings keine geringere Schwierigkeit bei der Erfassung der Messgröße bedeutet.

Die im folgenden näher beschriebenen Sensorsysteme beziehen sich beispielhaft auf die elektrischen und dielektrischen Größen zur Beurteilung des Zustandes der Isolierung in den Geräten der elektrischen Energietechnik.

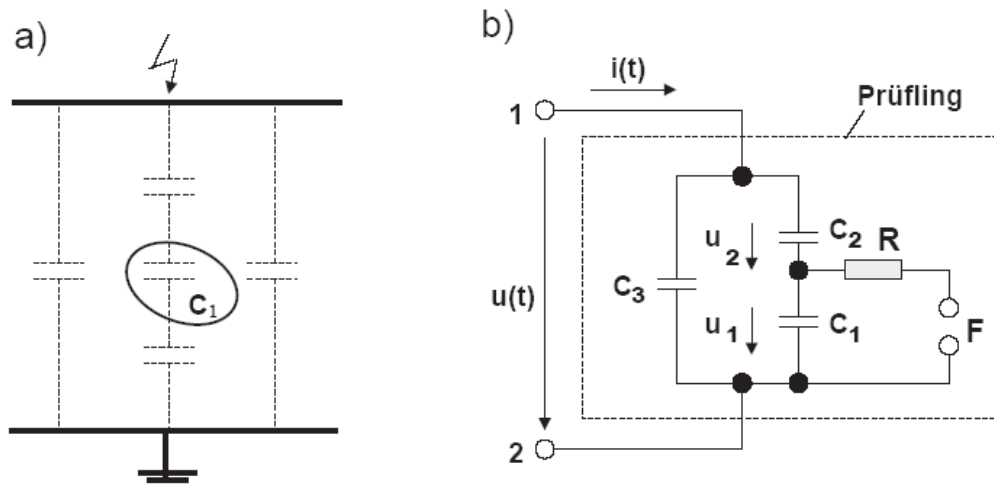
### **3 Beschreibung der Messgrößen und der dazugehörigen Sensorsysteme**

#### **3.1 Strom und Spannung**

Die beiden Basisgrößen der elektrischen Energie, Strom und Spannung, werden durch Stromwandler und Spannungswandler erfasst, die sehr häufig nach dem transformatorischen Prinzip arbeiten und im allgemeinen nicht störanfällig sind. Die geforderten Unsicherheiten im Bereich von Prozent lassen sich gut erreichen und auch der Schutz gegen zu hohe Ströme oder Überspannungen ist gewährleistet. In der letzten Zeit werden vermehrt Strom- und Spannungswandler eingesetzt, die auf der Beeinflussung von Lichtwellen in einem Lichtwellenleiter durch das magnetische oder elektrische Feld beruhen. Diese Systeme bieten den Vorteil einer geringeren Anfälligkeit auf elektromagnetische Störungen durch das Energiesystem, allerdings sind noch nicht alle Fragen bezüglich der Zuverlässigkeit und der Langzeitstabilität vollständig geklärt.

#### **3.2 Teilentladungen**

Das Auftreten von Teilentladungen ist im allgemeinen ein sehr frühes Warnsignal für lokale Defekte infolge einer zu hohen elektrischen Feldstärke. Für eine Diagnose ist nun zu berücksichtigen, in welchem Isolierstoff diese Teilentladungen



**Abb. 1.** Ersatzschaltbild für Teilentladungen: (a) schematische Darstellung der Isolierung; (b) kapazitives Ersatzschaltbild.


auftreten, unter welchen Randbedingungen und an welcher Stelle. Teilentladungen sind Entladungen in einem sehr eng begrenzten Gebiet innerhalb der Isolierung und führen nicht zu einem vollständigen Durchschlag. Die Schwierigkeit der Erfassung der Teilentladungen ist die Nichtzugänglichkeit der Stelle, an der die Teilentladungen entstehen. Abbildung 1 zeigt beispielhaft die schematische Darstellung des Isolierstoffes und das daraus abgeleitete Ersatzschaltbild.

Es ist nun erforderlich, die durch die Entladungen entstehende Signale zu erfassen. Eine einfache Möglichkeit ist die Erfassung des durch die Entladung des Kondensators  $C_1$ , der die Teilentladung darstellt, erzeugten impulsförmigen Stromes mit Hilfe eines zusätzlichen Kondensators. Abbildung 2 zeigt das vereinfachte Ersatzschaltbild einer elektrischen Teilentladungsmessung.


Die Messsysteme werden in schmalbandige und breitbandige Messsysteme unterteilt, wobei bei beiden Systemen die durch die Teilentladungen entstehenden Stromimpulse mit sehr kleinen Amplituden und sehr kurzer Dauer von den betriebsfrequenten Strömen durch die Wahl des Messfrequenzbereiches getrennt werden können.

Die Empfindlichkeit des Messsystems wird in der Regel durch die Anforderungen an die zu messenden Teilentladungspegel bestimmt. Der im Bereich der Mittel- und Hochspannungskabel eingesetzte polymere Isolierstoff VPE ist sehr empfindlich auf Teilentladungen, so dass sehr geringe Werte der scheinbaren Ladung von 5 pC (Picocoulomb) erfasst werden müssen. Hier bietet sich auch eine andere Art der Erfassung der Teilentladungssignale an. Abbildung 3 zeigt eine Kabelverbindung mit integriertem Teilentladungserfassungssystem.

Mit dieser Einrichtung können nicht nur die Teilentladungssignale in ihrem zeitlichen Verlauf und Häufigkeit erfasst werden sondern auch in ihrer Richtung, so dass eine Ortung möglich ist. Eine andere Variante der Richtungsbestimmung bei der Messung Teilentladungen in einem Kabel ist in Abbildung 4 dargestellt, bei dem zwei sogenannte Rogowskispulen zum Einsatz kommen, die auf eine



**Abb. 2.** Ersatzschaltbild der Teilentladungsmessung:  $U$  – Transformator,  $Z$  – Impedanz zwischen Prüfling und Messkreis,  $C_a$  – Prüfling,  $C_k$  – Koppelkondensator,  $CD$  – Ankopplungseinheit,  $MI$  – Messsystem.




**Abb. 3.** Teilentladungserfassung in einer Kabelverbindung (Muffe).

Änderung des Stromimpulses reagieren und im Vorzeichen des Ausgangssignals eine Richtungsinformation enthalten.

Bei Transformatoren und insbesondere bei Generatoren sind die erlaubten Teilentladungswerte um Größenordnungen höher. Hier können dann auch andere Methoden wie akustische oder optische Erfassung der Teilentladungssignale eingesetzt werden.

In komplexen Geräten wie Transformatoren ist oft auch der Ort der Teilentladungsentstehung von Bedeutung, so dass zusätzlich zu der Erfassung der Teilentladungen auch deren Ortung wichtig ist. Auch hier bieten sich akustische und elektrische Ortungsverfahren an. Beim elektrischen Verfahren wird davon ausgegangen, dass der durch die Teilentladung entstehende Impuls an zwei Stellen des Transformators gemessen werden kann. Bei Kenntnis der Verformung des Impulses auf dem Übertragungsweg von der Entstehung bis zur Erfassung kann



**Abb. 4.** Teilentladungsartung mit Hilfe von zwei Rogowskispulen.

dann auf die ursprüngliche Form am Entstehungsort geschlossen werden. Wenn diese Rechnung von beiden Messstellen aus durchgeführt wird, kann ohne vorherige Kenntnis der Entstehungsort bestimmt werden, indem der Ort ermittelt wird, an dem die beiden berechneten Signale deckungsgleich sind.

In Abbildung 5 sind die gemessenen und berechneten Kurven dargestellt. Das linke obere Bild zeigt die an den Messstellen Sternpunkt und Durchführung erfassten Signale, die von einer Teilentladung im Inneren des Transformators erzeugt wurden. Das rechte obere Bild zeigt den berechneten Verlauf des Signals an der Stelle, die mit Klemme 3 bezeichnet wurde, ausgehend von der jeweiligen gemessenen Kurve unter Nutzung der Übertragungsfunktionen für den Signalweg. Die beiden berechneten Kurven unterscheiden sich noch deutlich. Das linke und rechte untere Bild zeigen die berechneten Kurven für die Stellen, die mit Klemme 4 und Klemme 5 bezeichnet wurden. Hier ist die Übereinstimmung sehr viel besser und es zeigt sich eine Änderung in der zeitlichen Zuordnung der beiden Kurven. Daraus kann geschlossen werden, dass der Ort der Entstehung der Teilentladungen zwischen den Klemmen 4 und 5 liegen muss.

Für Transformatoren mit einer Feststoffisolierung, die von außen zugänglich ist, kann die Erfassung und Ortung der Teilentladungen auch durch Messung an verschiedenen Stellen und Auswertung der Amplituden der gemessenen Signale erfolgen. Abbildung 6 zeigt ein vereinfachtes Schaltbild zur Ortung der Teilentladungen in einem Feststoffisolierten Verteilungstransformator. Die Empfindlichkeit der Messung wird durch die Lage des Entstehungsortes der Teilentladungen beeinflusst, so dass für eine genaue Bestimmung des Fehlerortes in der Regel mehrere Messungen mit Sensoren an verschiedenen Stellen notwendig sind. Aufgrund der Häufigkeit der Teilentladungen ist eine serielle Erfassung der Signale






Abb. 5. Gemessene und berechnete Teilentladungssignale in einem Transformator.

Tabelle 1. Gasarten und deren Interpretation.

Gasart	Konzentration	Indikator für
$C_2H_2$	> 20	Durchschlag
$H_2$	> 100	Teilentladungen
$\Sigma C_xH_y$	> 1000	thermische Beanspruchung
$CO_x$	> 10.000	Papieralterung


an den verschiedenen Messpunkten möglich, ohne dass dabei die Messunsicherheit wesentlich erhöht wird.

### 3.3 Gas-in-Öl

Die Analyse der in einer Isolierflüssigkeit gelösten Gase oder der in einem Buchholz-Relais oder elektronischen Buchholz-Relais vorhandenen freien Gase erlaubt eine Diagnose der im Isoliersystem aufgetretenen Vorgänge wie Teilentladungen, thermische Überbeanspruchung oder energiewache oder energiestarke Durchschläge. Neben der Menge der durch die Vorgänge erzeugten Gase ist auch das Verhältnis der Gasarten untereinander von Bedeutung. In Abhängigkeit dieser Verhältnisse werden dann Koeffizienten gebildet, mit deren Hilfe eine Diagnose möglich ist. Eine vereinfachte Tabelle soll die Diagnose der Gas-Analyse exemplarisch darstellen. In Tabelle 1 sind die Gasarten, die Konzentrationen und die wahrscheinlichen Ursachen dargestellt.

Eine verfeinerte Analyse der im Öl gelösten Gase in Abhängigkeit der jeweiligen Verhältnisse der Gasanteile untereinander ist durch das in Abbildung 7 dargestellte Dreieck möglich.

Die zur Zeit verfügbaren Sensoren zur Detektion der Gasanteile haben noch die Schwierigkeit, dass sie nicht spezifisch auf nur eine Gasart reagieren, sondern durch andere Gasanteile in ihrer Anzeige beeinflusst werden.




**Abb. 6.** Erfassung und Ortung der Teilentladungen (TE-Quelle) an einem feststoffisolierten Transformator.

In allen großen Leistungstransformatoren wird zur Zeit das sogenannte Buchholz Relais eingesetzt, das bei einer bestimmten Menge von ungelösten Gasen einen Alarm gibt und bei einer weiteren Steigerung der Gasmenge auch den Transformator abschaltet. Der Behälter zum Sammeln der Gase befindet sich zwischen dem Transformator und dem Ausdehnungsgefäß. Allerdings gibt es bei Auslösung dieses Relais keine Information darüber, wie die zum Auslösen erforderliche Gasmenge entstanden ist. Eine weitaus empfindlichere Methode der Erfassung der Gasmenge und der Gasrate ist das sogenannte „Elektronische Buchholzrelais“, das auf einer Bestimmung der Gasmenge durch Änderung der Kapazität des mit Öl und Gas gefüllten Zylinderkondensators beruht. Abbildung 8 zeigt eine Messung mit dem Elektronischen Buchholzrelais.

### 3.4 Feuchte

Für Isoliersysteme der Energietechnik ist der Einfluss der Feuchte von großer Bedeutung, da in der Regel die elektrischen Eigenschaften sich bei Zunahme der Feuchte verschlechtern und bei einigen Alterungsprozessen sogar Feuchte generiert wird. Ein typisches Beispiel ist Papier, bei dem sich bei Trennung der Zellulosemoleküle Wasser bildet und das Papier dann elektrisch und mechanisch geringer belastbar wird. Ein Maß für den Zustand des Papiers in Leistungstransformatoren ist daher die Länge der Molekülketten. Diese Information ist aber nur über eine Papierprobe aus dem Transformator erhältlich und somit sehr ungeeignet. Eine mittelbare Methode der Bestimmung der Feuchte in einem Isoliersystem ist die Nutzung der Gleichgewichtsbedingungen bezüglich der Feuchte in einem abgeschlossenem System aus festem und flüssigem Isolierstoff. Abbildung 9 zeigt den Anteil der Feuchte in Papier und Mineralöl als Beispiel für eine



**Abb. 7.** Gasanteile als Indikator für Fehler in der Isolierung: D, D1, D2 – Durchschlag mit unterschiedlicher Energie; T, T1, T2, T3 – Thermische Überlastung mit unterschiedlichen Temperaturen; PD – Teilentladungen.

Transformatorisolation, wobei zu beachten ist, dass die Angabe der Feuchte im Papier in Prozent und die Angabe der Feuchte in der Flüssigkeit in ppm erfolgt.

Es ist gut zu erkennen, dass diese Kurven nur genutzt werden können, wenn sich ein Gleichgewichtszustand eingestellt hat, der aber je nach Beanspruchungsart des Transformators nur sehr selten erreicht wird. Eine empfindlichere Methode der Feuchtebestimmung ist der Einsatz eines Feuchtesensors. Abbildung 10 zeigt den grundsätzlichen Aufbau.


Die Elektroden stellen einen Kondensator dar, dessen Kapazität sich mit der Feuchte ändert, so dass nach Justierung aus der Kapazitätsmessung die Feuchte des Papiers im Sensor bestimmt werden kann, die auch mit der Feuchte im übrigen Transformator gut übereinstimmt, wenn sich der Sensor am richtigen Platz innerhalb des Transformator befindet.

Auch bei polymeren Isolierstoffen, die bei Mittel- und Hochspannungskabeln eingesetzt werden, ist die Feuchte von sehr großer Bedeutung, da bei Eindringen von Feuchte in das Kabel sich die sogenannten Wasserbäumchen bilden, die den Isolierstoff schwächen und zu einem Durchschlag führen. Abbildung 11 zeigt Wasserbäumchen mit einem sich daraus entwickelten Durchschlagskanal.

Hier ist für die Erfassung ein Sensor erforderlich, der auf der gesamten Länge des Kabel wirkt. Abbildung 12 zeigt einen Wassersensor, der allerdings bereits bei der Herstellung des Kabels eingebracht werden muss.

Der Sensor besteht aus einem Widerstandsdraht mit einer wasserdurchlässigen Umhüllung. Wenn an einer Stelle der Kabelmantel beschädigt wird und Wasser eindringt, dann gibt es zwischen dem Widerstandsdraht und den Schirmdrähten eine leitende Verbindung, die von einem Ende des Kabels mit Hilfe des Sensors detektiert werden kann. Zusätzlich kann durch Messung des Widerstandes zwischen Kabelanfang und Fehlerstelle bei Kenntnis des Widerstandes der Gesamtlänge des Kabels die genaue Lage des Fehlers ermittelt werden.

Eine andere Möglichkeit der Ermittlung der Feuchte und oft auch des Alterungszustandes einer Isolierung ist die Ermittlung des dielektrischen Verhaltens



**Abb. 8.** Verlauf der differentiellen (1) und integralen Gasmenge (2) und Rücksetzung (3) in einem Transformator.

in Form der Bestimmung der Polarisations- und Depolarisationsvorgänge. Hier wird ein relativ einfaches Ersatzschaltbild des Isolierstoffs zugrunde gelegt, indem die Isolierung mit einer Kapazität in ihrer Geometrie mit einem Widerstand in ihrem Leitungsverhalten nachgebildet wird. Die im Isolierstoff dann auftretenden Polarisationserscheinungen, die von der Feuchte und der molekularen Struktur des Isolierstoffes abhängen, werden durch mehrere RC-Glieder nachgebildet. Abbildung 13 zeigt das vereinfachte Ersatzschaltbild.

Das Isoliersystem wird nun mit einer Gleichspannung mit geringer Amplitude im Vergleich zur Betriebsspannung für eine bestimmte Zeit beansprucht (Polarisation) und dann für eine sehr kurze Zeit entladen. Anschließend erfolgt je nach Schaltung die Messung des sich anschließenden Entladestroms oder die Messung der sogenannten Wiederkehrspannung (Depolarisation). In Abbildung 14 ist der Verlauf des Stromes in Form des Produkts Strom  $\times$  Zeit über der Zeit im logarithmischen Maßstab aufgetragen. In dieser Darstellung sind die verschiedenen Zeitkonstanten der in Abbildung 13 dargestellten RC-Glieder erkennbar.

Es ist bei diesen Verfahren jedoch darauf zu achten, dass der Stromverlauf sehr stark von der Temperatur abhängt und dieses bei Vergleichsmessungen berücksichtigt werden muss.

### 3.5 Temperatur

Für die Beanspruchung eines Isoliersystems ist die Temperatur sehr wichtig. Eine Temperaturerhöhung führt in der Regel zu einer schnelleren Alterung des Isolierstoffes. Bei Öl-Papierisolierung gilt eine einfache Abschätzung, dass sich je  $6^{\circ}\text{C}$  Temperaturerhöhung über  $98^{\circ}\text{C}$  der Alterungsprozess verdoppelt. Es ist




Abb. 9. Feuchteverteilung in Papier und Flüssigkeit.

daher notwendig, die Temperaturen in Geräten der Energietechnik so gut zu erfassen, dass eine hinreichende Aussage über die Temperaturen im gesamten Gerät möglich ist. Bei Transformatoren wird über ein thermisches Ersatzschaltbild von den an verschiedenen zugänglichen Stellen gemessenen Temperaturen auf die unzugänglichen sogenannten „hot spots“ im Inneren eines Transformators geschlossen. Möglichkeiten der direkten Temperaturmessung durch Lichtwellenleiter wurden bereits erprobt, haben sich in der Praxis aber aus technischen und wirtschaftlichen Gründen nicht durchgesetzt.

Bei Kabeln kann eine lokale Temperaturerhöhung zu einem Ausfall der Isolierung und somit zu einem Durchschlag führen. Ähnlich wie bei der Erfassung der Feuchte ist hier eine Temperaturmessung entlang der gesamten Kabelstrecke erforderlich. Dazu eignet sich ein in das Kabel integriertes Lichtwellenleiter, der allerdings auch bereits bei der Fertigung eingebracht werden muss. Durch Messung der Lichtbrechung, die temperaturabhängig sich verändert, kann ein Temperaturabbild der Kabelstrecke erzeugt werden. Abbildung 15 zeigt eine Temperaturmessung an einem Mittelspannungskabel.

Es ist deutlich eine lokale Temperaturerhöhung zu erkennen, so dass in Abhängigkeit der Ursache Maßnahmen zur Reduktion der Temperatur getroffen werden können.

Für Verteilungstransformatoren mit Feststoffisolierung kann eine Temperaturüberwachung sehr sinnvoll sein, wenn dadurch bei einem Windungsschluss eine unzulässige Temperaturerhöhung und ein möglicher Brand verhindert werden können. Abbildung 16 (a) und (b) zeigen zwei baugleiche Transformatoren, bei denen einer ohne Temperaturüberwachung und einer mit Temperaturüberwachung durch einen Lichtwellenleiter ausgestattet war.




Abb. 10. Feuchtesensor.




Abb. 11. Wasserbäumchen in einer Isolierung aus vernetztem Polyethylen.

## 4 Zusammenfassung


Die Sensorik in der Energietechnik muss unter rauen Betriebsbedingungen mit Umwelt- und elektromagnetischen Einflüssen über viele Jahre zuverlässig arbeiten. Die zu erfassenden Parameter weisen in der Regel eine große Streuung auf, so dass die Anforderungen an die Messunsicherheit relativ gering sind, aber die Messergebnisse einer Interpretation bedürfen.

Aus der Vielzahl der zu erfassenden Parameter wurden einige ausgewählt und näher betrachtet. Selbstverständlich sind Strom und Spannung als die Basisgrößen der elektrischen Energietechnik zu erfassen und richtig zu messen, aber dieses ist keine Schwierigkeit im Hinblick auf die geforderte Messunsicherheit, so dass darauf nicht näher eingegangen wurde.

Die in Isoliersystemen auftretenden lokalen Entladungen, die als Teilentladungen bezeichnet werden, sind ein sehr guter Indikator für den Zustand des



**Abb. 12.** Wassersensor in einem Hochspannungskabel.



**Abb. 13.** Ersatzschaltbild für ein Isoliersystem.

Isoliersystems. Mit Hilfe des vereinfachten Ersatzschaltbildes wird gezeigt, wie die Informationen gewonnen werden können und wie mit Hilfe der Übertragungsfunktion eine Ortung der Fehlerstelle auch in komplexen Geräten wie einem Transformator erfolgt. Für ausgedehnte Systeme wie Hochspannungskabel ist eine Ortung durch Erfassung der Laufrichtung der Teilentladungssignale möglich.

Für Isoliersysteme aus der Kombination fester-flüssiger Isolierstoff ist die Analyse der in der Flüssigkeit, in der Regel Öl, gelösten Gase eine sehr gute Methode, Fehler im Isoliersystem zu erkennen und anhand der Gasarten und deren Verhältnisse untereinander auf die Fehlerursache zu schließen. Eine differentielle Erfassung der Menge der ungelösten Gase und deren Analyse erlaubt eine weitere Fehlerdifferenzierung.

Feuchtigkeit in Isoliersystemen führt immer zu einer Minderung der elektrischen und mechanischen Eigenschaften. Analysen mit Hilfe von Gleichgewichtsbedingungen oder eingebauten Sensoren erlauben die Ermittlung des Feuchtege-




Abb. 14. Relaxationsstrom in Abhängigkeit der Zeit.


haltes und die Einleitung von Maßnahmen zur Verhinderung weiterer Feuchtebildung oder Minderung des Feuchtegehaltes. Bei ausgedehnten Systemen wie Hochspannungskabel ist ein Eindringen von Feuchte durch einen einfachen Feuchtesensor möglich.

Erhöhte Temperaturen führen zum Verlust der elektrischen Eigenschaften und zu einer verstärkten Alterung der Isoliersysteme. Mit Hilfe von Temperaturmessungen und thermischen Ersatzschaltbildern können die an sogenannten "hot spots" auftretenden Temperaturen bestimmt werden. Bei Feststoffisolierten Transformatoren dienen einfache Lichtwellenleiter zur Ermittlung und Meldung von unzulässigen Temperaturen z. B. infolge eines Windungsschlusses. Auch hier ist bei ausgedehnten Systemen wie Mittel- und Hochspannungskabel ein Sensor notwendig, der über die Streuung des Lichtes in einem mit dem Kabel geführten Lichtwellenleiter das Temperaturprofil entlang der gesamten Kabelstrecke erfassen kann.

## Literatur

1. J. Fabre und A. Pichon. Deteriorating processes and products of paper in oil. Application to Transformers. *CIGRE Paris*, paper 137, 1960.
2. P. Werelius und U. Gaefvert. High voltage dielectric response analysis for cable diagnostics in field condition. *11th ISH Graz*, paper 5662, 1995.
3. IEC 60270, High voltage test techniques — Partial discharge measurement.
4. IEC 60599 Ed. 2, Interpretation of analysis of gas in transformers and other oil-filled electrical equipment.





**Abb. 15.** Temperaturverlauf in einem Mittelspannungskabel mit einer Länge von ca. 2,6 km.

5. R. Müller, H. Schliesing und K. Solder. Prüfung und Überwachung von Transformatoren durch Analyse der im Öl gelösten Gase. *Elektrizitätswirtschaft*, 73(23):683–691, 1974.
6. E. Bräsel. Neue Erkenntnisse zum Gas-Monitoring an Transformatoren. *Micafil Symposium Werterhaltung von Isolationssystemen in Transformatoren, Schaltanlagen und Kabeln*, 2002.
7. W. Zaengl. Dielectric spectroscopy in time and frequency domain for HV power equipment, Part I: Theoretical considerations. *IEEE Electr. Insul. Magazine*, 19(5):5–19, 2003.
8. V. M. Montsinger. Loading transformers by temperature. *AIEE Transactions* 49:776–792, 1930.
9. E. Grossmann und K. Feser. Empfindliche Online TE-Überwachung von Transformatoren durch optimierte akustische Messtechnik. *ETG Fachtagung Diagnostik elektrischer Betriebsmittel*. ETG Fachbericht 87, S. 201–204, 2002.
10. P. Werle, A. Akbari, H. Borsi, und E. Gockenbach. Localisation and evaluation of partial discharges on power transformers using sectional winding transfer functions. *12th ISH Bangalore*, paper 6–15, 2001.
11. U. Schichler. *Erfassung von Teilentladungen an polymerisolierten Kabeln bei der Vor-Ort-Prüfung und im Netzbetrieb*. Dissertation, Universität Hannover, 1996.



**Abb. 16.** Transformatorschaden ohne und mit Temperaturüberwachung.

12. D. Pommerenke, I. Krage, W. Kalkner, E. Lemke und P. Schmiegel. On-site PD measurement on high voltage cable accessories using integrated sensors. *9th ISH Graz*, paper 5608-1, 1995.
13. A. Bognar, G. Csepes, E. Nemeth und J. Schidt. Diagnosis tests of high voltage oil-paper insulating systems (in particular transformer insulation) using dc dielectrometrics. *CIGRE Paris*, paper 15/33-08, 1990.
14. A. J. Kachler. Aging and moisture determination in power transformer insulation systems: contradiction of RVM methodology, effects of geometry and ion conductivity. *2nd International Workshop on Transformers*, Lodz, 1999.
15. CIGRE WG 15.01, Task Force 09. Dielectric response methods for diagnostic of power transformers. *ELECTRA*, No. 202, S. 24–37, 2002.
16. M. Beigert, H.-G. Kranz, D. Kaubisch und D. Meurer. Computergestützte zerstörungsfreie Alterungsdiagnose für VPE-isolierte Mittelspannungskabel. *Elektrizitätswirtschaft*, 93(11):615–618, 1994.
17. H. Borsi, M. Ulrich und T. Leibfried. Elektronisches Buchholz-Relais. *Elektrizitätswirtschaft*, 97(13):46–52, 1998.

# Stichwortverzeichnis

- Übertragungssystem, 279
- 3D-Messtechnik, 127, 128, 132
  
- A-priori-Wissen, 25, 26, 33
- Abstraktionsebenen, 6, 22, 83, 215
- Adaptives Tracking, 185, 195, 198
- AFM, 140, 141
- Aktivierungsfunktion, 97, 101
- Aktivierungsgrad, 106
- Arbeitsraumexploration, 159
- ARX, 109
- Assistenzsysteme, 208
  
- Backpropagation, 101, 118
- Bahnplanung, 159
- Basisfunktion, 93, 95, 97, 99, 101, 102, 106, 108
- Bayessche Fusion, 24, 25, 31
- Bayessche Netze, 115
- Bayessche Wahrscheinlichkeitstheorie, 21, 23, 25, 31, 39, 41, 47, 85, 186, 187, 196, 200
- Bedrohungsanalyse, 4, 247
- Bidirektionale Reflektanzverteilungsfunktion (BRDF), 90
- Bilderfassung, 212
- Bildfusion, 79, 81, 83, 84
- Bildsensor, 128, 129
- Bildsensoren, 80
- Bildserien, 80
- Bildsignale, 79
- Bildverarbeitung, 140, 141, 212
  
- Clustering, 93, 102, 108
- Correlation, 51, 52, 54, 56–59
- Covariance matrix, 51–56, 59
  
- Data-Mining, 113, 115
- Datenfusion, 1, 83, 113
- Datenmodell, 138, 139
- Decision-level fusion, 83
- Degree of belief, 25–27, 29–33
- Dempster-Shafer-Evidenztheorie, 23, 39, 47, 218, 239, 245
- Dempsters Kombinationsregel, 44, 245
- Depth from motion, 81
  
- Deutungshypothese, 186, 192
- Display, 178
  
- Eigenvalue, 51, 57, 59
- Eigenvalue decomposition, 57, 59
- Eigenwert, 51, 57, 59
- Eigenwertzerlegung, 57, 59
- Elektrische Energietechnik, 279
- Elektrokardiogramm, 254, 258
- Elektronische Nase, 261
- Energieminimierung, 85
- Energieumsatz, 251, 252
- Enhanced vision system, 171, 177, 178
- Entropie, 25
- Entscheidungsfusion, 83
- Erkennungsrate, 7, 247
- Erwartungswert, 51, 55
- Evidenztheorie, 23, 39, 47, 245
- Expectation, 51, 55
- Expectation maximization algorithm (EM), 51
- Expertenregeln, 116, 121, 122
- Exploration, 145–147, 151, 152
  
- Fahrerassistenzsysteme, 207–209, 223
- Fahrspur, 223, 228
- Fahrzeugführung, 208, 210
- Falschalarmrate, 7, 247
- Falschmeldung, 187, 192, 194, 200
- FDM, 68
- Feature-level fusion, 83, 87
- FEM, 68
- Feuchtesensor, 279, 286
- Flight management system, 175
- Fokussierung, 22, 27
- Fouriertransformation, 85
- Frame of discernment, 43, 246
- Freiheitsgrad, 132
- Fußgängerdetektion, 239, 240, 242
- Fuselets, 28
- Fusion, 21, 22, 24–33
- Fusion auf Merkmalsebene, 87, 218
- Fusion auf Objektebene, 83, 217, 244
- Fusion auf Signalebene, 86
- Fusionsagenten, 28, 29

- Fusionsdomäne, 86
- Fusionskarte, 84, 86
- Fusionsmethodik, 22, 25
- Fusionsmodelle, 3
- Fuzzy-Datenanalyse, 113
- Fuzzy-Modell, 113, 118
- Fuzzy-Regel, 113, 115, 118, 121
- Fuzzy-Systeme, 113, 115
- Fuzzy-Theorie, 23
  
- Gaschromatographie, 261
- Gassensor, 261
- Gaußmischverteilung, 63
- Generator, 279
- Geometriemodell, 228, 235
- Geometrische Transformation, 85
- Gitter, 99, 102
- Gitterbasierte Ansätze, 9, 217, 242
  
- Hauptachsentransformation, 85
- Hauptkomponentenanalyse, 265
- Head-mounted display, 178
- Herzfrequenz, 251, 254, 256, 258
- Heterogene Sensoren, 21, 81
- Heuristic estimator, 51, 56, 58, 59
- Heuristischer Schätzer, 51, 56, 58, 59
- Hintergrundinformation, 185, 186, 203
- Homogene Sensoren, 81
- Homotopie, 73
- Human operator, 171, 172, 177
- Human-machine interface, 175, 178
- Hypothesentests, 228, 233
- Hypothesenverifikation, 223
  
- Indikator, 137–139, 141
- Information, 21, 22, 24–29, 33
- Informationsfusion, 21, 113
- Infrarotsensoren, 239, 240, 242, 245
- Infrarotspektroskopie, 261
- Inhomogene Sensoren, 81
- Intensitätstransformation, 85
- Isoliersystem, 279, 286
  
- JDL-Modell, 3
  
- Kalibrierung, 162–164
- Kalman-Filter, 9, 10, 63, 70, 85, 132, 187, 244
- Klassifikation, 266, 273
- Klassische Statistik, 10
- Kollisionsvermeidung, 164
- Kollisionswarnung, 211
- Kollokierte Sensoren, 81
- Kolmogorovsche Axiome, 25
- Kommensurable Daten, 80
- Komplementäre Fusion, 83
- Komplementäre Information, 81, 216
- Konjunktion, 106
- Konkurrierende Fusion, 81, 83
- Konkurrierende Information, 216
- Kontaminationskontrolle, 137
- Konzentriert-parametrische Systeme, 63, 65, 66, 68
- Kooperative Information, 216
- Koordinatenmessgerät, 132
- Koordinatenmesstechnik, 127
- Koordinatensystem, 162–164
- Koordination, 145, 146, 150–153
- Korrelation, 51, 52, 54, 56–59, 85, 132
- Kovarianzmatrix, 51–56, 59, 71, 128
- Kreuzungsdetektion, 223
  
- Lagesensor, 161, 163
- Laserscanner, 81, 161, 164, 167
- Least squares estimator, 56
- Least-squares approach (LS), 51, 56, 57, 60
- Least-squares-fit, 130
- Lichtschnittsensor, 161, 163, 164, 167
- Lidar, 212
- Likelihoodfunktion, 54–57, 59, 186, 187, 200, 201
- Lineare Regression, 265
- Log-Likelihoodfunktion, 54–57, 59
- Lokale Fusion, 28, 32
- Lokale Operatoren, 85
  
- Marginalisierung, 27
- Markow-Netze, 115
- Massefunktion, 43–46, 246
- Massenspektrometrie, 261
- Maximum likelihood estimator, 51, 53, 57
- Maximum-Entropie-Prinzip, 25
- Maximum-Likelihood-Schätzer, 51, 53, 57
- Mean square error (MSE), 51, 59
- Medizintechnik, 251
- Mensch-Maschine-Schnittstelle, 175, 178
- Merkmalsdetektion, 223, 227
- Merkmalsextraktion, 270
- Merkmalsfusion, 83

- Merkmalsselektion, 139  
 Messpunktewolke, 127, 128, 132  
 Messunsicherheit, 129  
 Metalloxidsensor, 262, 271, 273  
 Methode der finiten Differenzen (FDM), 68  
 Methode der finiten Elemente (FEM), 68  
 Methode der kleinsten Quadrate, 93, 95, 102, 106, 108  
 Mikrolinsenarray, 137, 139  
 Mikrostrukturen, 138  
 Mikrosystemtechnik, 137, 141  
 Militärische Überwachung, 185  
 Minimum mean square error (MMSE), 51, 56, 57, 59  
 Mittelwertbildung, 85  
 Modell, 159, 161, 163–165, 167  
 Morphologische Hat-Transformationen, 85  
 Multikomponentenanalyse, 263, 271  
 Multilayer-Perzeptron, 95, 101  
 Multisensorsystem, 3  
 Multiskalenansatz, 137–141  
 Mustererkennung, 213, 263, 266  
  
 Nahbereichsradar, 240  
 Nanostrukturen, 138  
 NARX, 109  
 NEFCLASS, 118, 121, 122  
 Negative Sensorevidenz, 185, 186, 192, 195, 198, 201, 203  
 Neuro-Fuzzy-Modell, 118  
 Neuro-Fuzzy-Netz, 95, 106, 108  
 Neuron, 95, 97, 99, 101, 102, 109  
 Neuronales Netz, 93, 95, 97, 99, 101, 102, 109  
  
 Oberflächengeometrie, 127, 128  
 Oberflächenmesstechnik, 127, 128  
 Objektdetektion, 7  
 Objekterfassung, 138  
 Occupancy grid, 9, 217, 242  
 Omnibus-Modell, 4  
 Optimierung, 85  
 Optische Messtechnik, 127, 128  
 Optischer Fluss, 218  
 Orientierung, 228, 232, 233  
 Orthogonale Information, 81  
 Orthogonales Least-Squares-Verfahren (OLS), 102  
  
 Parameterlernen, 118  
 Partielle Differentialgleichungen, 63, 65, 67–69  
 Partikelfilter, 63, 70, 73  
 PDE, 63, 65, 67–69  
 Perzeptron, 95, 101  
 Photometrisches Stereo, 81, 90  
 Physikalische Phänomene, 63, 65, 66, 68, 69  
 Pilot assistance system, 171, 172, 174, 176  
 Pixel-level fusion, 83, 86  
 Plausibilität, 39, 41, 46  
 Plausibilitätsfunktion, 46  
 Polygonal approximation, 145–147, 151  
 Positioniersystem, 132  
 Positionsbestimmung, 228, 233, 241  
 Progressive Schätzverfahren, 73  
 Pruning, 118, 122  
 Punktewolke, 88  
 Pyramidentransformation, 85  
  
 Radar, 177, 189, 191, 194, 195, 198, 199, 203, 212, 218, 239, 240, 243, 245  
 Random variable, 51  
 Rasterkennfeld, 99  
 Receiver operating characteristic, 7, 248  
 Redundante Information, 81, 83, 216  
 Regellernen, 118  
 Registrierung, 81  
 Roboter, 145, 147, 150  
  
 Schätzproblem, 223  
 Schwingquarzsensoren, 263, 273  
 Seebeck-Effekt, 240  
 Sensordatenfusion, 207, 213  
 Sensoreinsatzplanung, 71  
 Sensorintegration, 1  
 Sensormodell, 166, 186, 194, 195, 200, 203  
 Sensorpositionierung, 138  
 Sensorsichtbereich, 242  
 Sensorsichtfeld, 165, 166  
 Shape from shading, 81  
 Signal-Rausch-Verhältnis, 128, 130  
 Singleton, 106, 108  
 Singleton-Fuzzy-System, 106  
 Skalen, 22  
 Skalenraum, 85  
 Skalenraumdarstellung, 85  
 Spectral-Element-Methode (SEM), 68  
 Sportmedizin, 251

- Stereobilder, 88
- Stereosensor, 161
- Stitching, 132
- Stoffwechsel, 251, 252, 254, 255
- Strahlmodell, 167
- Strukturlernen, 113, 116, 118
- Support-Vector-Maschine, 85
- Symbolfusion, 83
- Synchronisation, 159, 162, 164
  
- Takagi-Sugeno-Fuzzy-System, 106
- Teilentladung, 279, 281
- Temperatursensor, 279
- Tensorprodukt, 99, 106
- Textur, 159, 161, 163
- Textursensor, 161, 163
- Thermopilesensoren, 239, 240, 242, 245
- Threat assessment, 4, 247
- Tiefenkarte, 88
- Total-Least-Squares, 230
- Tracking, 159, 163, 241
- Training, 113, 116, 118, 121, 122
- Trainingserfolg, 251
- Transformation, 22, 24, 25, 85
  
- Transformator, 279
- Triangulation, 81, 128, 130
  
- Umfeldwahrnehmung, 207, 212
- Umgebungserfassung, 159
- Umgebungsmodell, 145, 147, 150, 152
- Unsicherheit, 40, 43
  
- Verteilt-parametrische Systeme, 63, 65–68, 73
- Verteilte Information, 81
- Verteilte Systeme, 63, 65, 69
- Vertrauen, 40, 41, 45
- Vertrauensfunktion, 45
- Videosensoren, 213, 218
- Videoverarbeitung, 223
- Virtuelle Sensoren, 80
  
- Wahrnehmungsrahmen, 43, 44, 246
- Wang-Mendel-Algorithmus, 118
- Wavelettransformation, 85
- Wenn-dann-Regeln, 113
- Wissensrepräsentation, 223, 225
  
- Zustandsschätzung, 185, 186





ISBN-13: 978-3-86644-053-1

ISBN-10: 3-86644-053-7

---

[www.uvka.de](http://www.uvka.de)