

# Einführung

## in Techniken und Methoden der Multisensor-Datenfusion

Dr.-Ing. Ferdinand Klaus, Siegen

urn:nbn:de:hbz:467-575

„Careful - we don't want to learn from this!“

- Calvin and Hobbes -

## **Vorwort**

Multisensorielle Datenfusion ist eine noch recht junge Technik, die sich mit dem Problem auseinandersetzt, wie Daten mehrerer und auch unterschiedlicher Sensoren kombiniert werden können, um daraus Schlußfolgerungen über physikalische Ereignisse, Aktivitäten oder Situationen ziehen zu können. Datenfusionsanwendungen decken einen weiten Bereich ab, der z.B. militärische Anwendungen wie Überwachung, taktische Situations- und Bedrohungsanalyse, aber genauso nichtmilitärische Anwendungen aus den Bereichen der Automatisierung, des Remote Sensing u.a. [3, 4, 29, 40, 44, 49, 65, 71-74, 79-80] einschließt. Das Studium der Datenfusion wird kompliziert durch die Breite der gegebenen Applikationsmöglichkeiten und durch die Vielfalt der anwendbaren Techniken, die scheinbar eine Mischung mathematischer und heuristischer Techniken aus den Gebieten der Statistik, künstlicher Intelligenz, digitaler Signalverarbeitung und Entscheidungstheorie beinhalten. Multisensorielle Datenfusion ist ein durch und durch interdisziplinäres Arbeitsgebiet, was einerseits zu seiner Schwierigkeit und Komplexität beiträgt, andererseits auch den Reiz ausmacht, sich mit dieser Materie zu beschäftigen.

Dieser Text konzentriert sich auf mathematische Techniken zur Datenfusion. Es sollen Techniken für alle Aspekte dieses Problemkreises vorgestellt werden.

Kapitel 1 stellt eine Einleitung zur Datenfusion dar mit Betonung militärischer Techniken. Das Kapitel beschreibt und erklärt die verwendete Technologie, Funktionen, zu verarbeitende Daten und resultierende Folgerungen. Ein Datenfusionsmodell sowie eine Zusammenfassung von möglichen Vorteilen der Fusion, Architekturkonzepten und von wesentlichen Implementierungsgesichtspunkten wird vorgestellt.

Das Kapitel 2 gibt eine Übersicht über Datenfusionstechniken und Algorithmen. Eine Einschätzung für Positions- und Identitätsfusion wird in Zusammenhang mit verwendeten Hilfs- bzw. unterstützenden Funktionen gegeben. Nicht auf mathematische Rigorosität fixiert gibt die Einschätzung eine Art Karte oder Organisationskonzept an die Hand, die die verschiedenen anwendbaren Methoden miteinander in Verbindung setzt.

Das Problem der Datenassoziation wird in Kapitel 3 entwickelt. Datenassoziation beschreibt das Problem der Eingruppierung von Beobachtungen, wenn jede Gruppe die Beobachtungen einer einzelnen physikalischen Art oder eines Ereignisses repräsentiert. Die Behandlung dieses Problems ist besonders wichtig für Vielfachzielverfolgungen in einer Situation, in der viele Ziele gleichzeitig beobachtet werden sollen. Datenassoziationsmethoden messen die Ähnlichkeit zwischen Beobachtungen und entwickeln eine Logik, mit der entschieden werden kann, ob und ggf. wie die Beobachtungen zusammenhängen. Kapitel 3 beschreibt spezifische Assoziationsmetriken, alternative Entscheidungsstrategien und einen allgemeinen Ablaufplan für Assoziationsaufgaben.

Kapitel 4 führt in das Konzept der Estimation ein, die mathematischen Techniken zur Fusion der Daten, um System-charakterisierende Zustandsvektoren zu schätzen. In diesem Zusammenhang beinhaltet ein Zustandsvektor die fundamentalen Variablen, die eine physikalische Betrachtungseinheit oder Situation beschreiben. Ein Zustandsvektor kann Koordinaten  $(x, y, z)$ , kinematische Variablen wie die Geschwindigkeit oder Parameter beschreiben, die die Attribute einer Betrachtungseinheit charakterisieren (z.B. Größe, Frequenz eines Strahlers, usw.). Estimationstechniken sind z.B. „Batch Least Squares“ und „Maximum Likelihood“, aber auch sequentielle Techniken wie die Kalman- oder  $\alpha$ - $\beta$ -Filter.

In den Kapiteln 5 und 6 werden Techniken der Identitäts-Estimation vorgestellt. Kapitel 5 konzentriert sich dabei auf Merkmal-basierte Methoden wie Cluster-Algorithmen, adaptive neuronale Netzwerke und parametrische Templates. Kapitel 6 erweitert die Diskussion hin zur Entscheidungsebenenfusion, bei der Ergebnisse von mehreren Sensoren zusammengeführt werden. Traditionelle Methoden wie klassische oder Bayes'sche Inferenz und Dempster-Shafer-Methode werden zusammen mit neueren Techniken wie der von Thomopoulos entwickelten „Generalized Evidential Processing“ (GEP)-Methode und heuristischen Methoden, die menschliche Konsensfindungsprozesse simulieren, beschrieben.

Ein Überblick über wissensbasierte Techniken wird in Kapitel 7 gegeben. Eine Einleitung zu künstlicher Intelligenz führt zu einer Diskussion bzgl. Expertensystemen und logischen Templates. Diese Methoden ermöglichen Situations- oder Bedrohungsanalysen und ähnliche

Schlußfolgerungen, die normalerweise von Menschen durchgeführt werden, durch das Erreichen höherwertiger Entschlußebenen.

Abschließend möchte ich mich für die Ermutigung und Anregung zu dieser Arbeit bei Herrn Prof. Dr.-Ing. R. Schwarte bedanken. Auch das positive Interesse von Herrn Prof. Dr.-Ing. O. Loffeld, Herrn Prof. Dr.-Ing. H. Bessai und Herrn Prof. Dr.-Ing. B. Bundschuh sowie die Hilfe zahlreicher weiterer Personen, denen ich zu herzlichem Dank verpflichtet bin, waren für mich überaus wertvoll. Besonders hervorgehoben seien hierbei Frau Dagmar Krumm, Herr Dr.-Ing. Christoph Arndt und Herr Dr. rer.-nat. Martin S. Brandt. Den größten Dank schulde ich meiner Familie, deren Liebe und Gemeinschaft mir Kraft, Ausdauer und genügend Zeit gegeben haben.

Siegen, November 1999

# Inhaltsverzeichnis

<b>1. Einführung in die multisensorielle Datenfusion .....</b>	<b>1</b>
1.1 Einleitung .....	1
1.2 Anwendungen der Sensordatenfusion.....	3
1.3 Sensoren und Sensordaten .....	8
1.4 Inferenzhierarchie: Ausgangsdaten.....	17
1.5 Ein Datenfusionsmodell .....	20
1.6 Nutzen der Datenfusion .....	25
1.7 Architekturkonzepte und -fragen.....	29
<b>2. Algorithmen zur Multisensordatenfusion.....</b>	<b>33</b>
2.1 Überblick.....	33
2.2 Taxonomie der positionellen Fusionsalgorithmen .....	36
2.2.1 Parametrische Assoziation .....	37
2.2.2 Estimationstechniken .....	40
2.3 Identitätsfusionsalgorithmen .....	42
2.4 Hilfs- und Unterstützungsalgorithmen.....	46
<b>3. Datenassoziation.....</b>	<b>48</b>
3.1 Einleitung .....	48
3.2 Ein allgemeiner Assoziationsprozeß .....	53
3.3 Gating .....	60
3.4 Assoziationsmetriken.....	64
3.4.1 Abstandsmaße .....	66
3.4.2 Korrelationskoeffizienten.....	68
3.4.3 Assoziationskoeffizienten und Übereinstimmungsmaße .....	69
3.4.4 Korrelationsmaße.....	74
3.4.5 Auswahl einer Assoziationsmetrik.....	75
3.5 Zuweisung.....	77
3.5.1 Anzahl der Scans .....	77
3.5.2 Mehrfach- oder Einzelzuweisung .....	78
3.5.3 Mehrfach- oder Einzelhypothese .....	80

3.6 Zusammenfassung.....	81
<b>4. Estimationstechniken .....</b>	<b>82</b>
4.1 Einleitung .....	82
4.2 Überblick der Estimationsalternativen .....	85
4.2.1 System-Modelle für die Estimation.....	86
4.2.2 Optimalitätskriterien .....	89
4.2.3 Optimalitätsansatz.....	93
4.2.4 Verarbeitungsansatz.....	96
4.3 Batch-Estimation.....	98
4.3.1 Ableitung der Weighted-Least-Squares-Lösung .....	98
4.3.2 Ablauf.....	104
4.3.3 Implementierungsfragen.....	107
4.4 Sequentielle Estimation.....	109
4.4.1 Ableitung einer sequentiellen WLS-Lösung .....	109
4.4.2 Prozeßablauf der sequentiellen Estimation.....	115
4.4.3 Implementierungsfragen.....	116
4.4.4 Alpha-Beta-Filter .....	119
4.5 Kovarianzfehler-Estimation.....	125
<b>5. Identitätsdeklaration .....</b>	<b>128</b>
5.1 Identitätsdeklaration und Mustererkennung.....	128
5.1.1 Parametrische Templates.....	131
5.1.2 Cluster-Algorithmen .....	132
5.1.3 Neuronale Netzwerke .....	132
5.1.4 Physikalische Modelle .....	132
5.1.5 Wissensbasierte Ansätze .....	132
5.2 Charakteristikaextraktion.....	136
5.3 Parametrische Templates .....	144
5.4 Cluster-Analyse .....	146
5.5 Adaptive neuronale Netzwerke .....	152
5.6 Physikalische Modelle .....	156
5.7 Wissensbasierte Methoden.....	159

<b>6. Identitätsfusion auf Entscheidungsebene .....</b>	<b>161</b>
6.1 Einleitung .....	161
6.2 Klassische Inferenz .....	166
6.3 Bayes'sche Inferenz .....	172
6.4 Methode von Dempster-Shafer .....	178
6.4.1 D-S-Fusionsprozeß .....	178
6.4.2 Dempster'sche Kombinationsregel .....	180
6.5 GEP .....	190
6.6 Heuristische Methoden .....	199
<b>7. Wissensbasierte Ansätze.....</b>	<b>204</b>
7.1 Einführung in die künstliche Intelligenz .....	204
7.2 Expertensystemkonzept .....	209
7.3 Inferenzprozeß.....	211
7.4 Wissensdarstellung.....	213
7.5 Unsicherheitsdarstellung .....	217
7.6 Suchtechniken .....	222
7.7 Logische Templates (Schablonen).....	226
7.8 Figures of Merit.....	229
<b>8. Schlußbemerkungen und Perspektive.....</b>	<b>231</b>
<b>A.1 Herleitung Gl. (1.1).....</b>	<b>232</b>
<b>A.2 Berechnung eines Schätzwerts des Korrelationskoeffizienten</b>	
<b>für zwei Vektoren <math>\underline{y}</math> und <math>\underline{z}</math> mit <math>\dim[\underline{y}] = \dim[\underline{z}] = n</math> .....</b>	<b>238</b>
<b>A.3 Listing „IDL 3.6.1b“-Programm zum Vergleich Alpha- und</b>	
<b>Kalman-Filter.....</b>	<b>240</b>
<b>A.4 Wavelet-Transformation .....</b>	<b>244</b>



**A.5 Herleitung Gl. (4.77).....275**

**Literaturverzeichnis .....285**

# 1. Einführung in die multisensorielle Datenfusion

## 1.1 Einleitung

In den letzten Jahren entwickelte sich eine neue Disziplin zur Lösung verschiedener Problemstellungen mit gemeinsamen Charakteristika: Multisensorielle Datenfusion (engl. Multisensor Data Fusion) bzw. verteilte Erkundung (engl. Distributed Sensing). Die multisensorielle Datenfusion versucht, Daten mehrerer Sensoren zu kombinieren, um Schlußfolgerungen zu ermöglichen, die aus den Ergebnissen einer einzigen Quelle nicht möglich wären. Die Anwendungen reichen von militärischen Problemen wie der automatischen Zielidentifizierung, der Gefechtsfeld- und Bedrohungsanalyse über Fernerkundungsprobleme, wie der Bestimmung der Zusammensetzung von Bodenvegetation oder Vorkommen natürlicher Ressourcen (Öl, Mineralien, Erze, usw.) bis zu industriellen Anwendungen wie der Steuerung komplexer Ausrüstungen (AKWs usw.) oder automatisierter Fabrikation. Daten verschiedener Sensoren und Typen von Sensoren werden durch bestimmte Techniken interdisziplinär verbunden, die aus unterschiedlichen Bereichen stammen: Signalprozessierung, Statistik, Künstliche Intelligenz, Mustererkennung, kognitive Psychologie und Informationstheorie. Die zu verarbeitenden Sensordaten umfassen parametrische Positionsdaten wie Winkelinformation (Azimut, Höhe, Bildkoordinaten), Entfernungsinformationen und Daten, die die Objektidentität beschreiben (tatsächliche Identitätsaussagen eines Sensors oder parametrische Daten, die einer Identität zugeordnet werden können, wie der Radarquerschnitt (RCS) oder spektrale Daten).

Datenfusion kann verglichen werden mit dem kognitiven Prozeß, den der Mensch ausnutzt, um aus den beständig auf seine Sinne einströmenden Daten Schlußfolgerungen über seine Umwelt zu ziehen. Den Menschen erreicht Sensordatenmaterial - Bilder, Geräusche, Gerüche, Geschmäcke und Berührungen - , welches er dann im Normalfall analysiert, um daraus auf die Umgebung schließen zu können, zu erkennen, was die Sensoren aufnehmen. Die Wiedererkennung eines Bekannten nach langer Zeit z.B. kann die Analyse von Faktoren wie der allgemeinen Gesichtsform, der Identifikation bestimmter visueller Charakteristika (z.B. hervorstechende Nase, Haarfarbe, usw.), der Einordnung und Erkennung von Stimmustern oder sogar von bestimmten Arten des Gehens oder Gesten erfordern.

Komödianten und Kabarettisten imitieren bestimmte Eigenschaften berühmter Zeitgenossen, um das Wiedererkennen zu ermöglichen, um sie manchmal zu karikieren. Erkennung und Be-

stimmung einer Situation durch einen Menschen werden stark beeinflusst durch Faktoren wie Training, Aufmerksamkeit, momentane Stimmung und Verfassung. Ein Mediziner z.B. wird ganz andere Signale wahrnehmen als ein vielleicht flüchtiger Bekannter. Trotzdem benutzt der Mensch eine Art natürlicher Sensordatenfusion zur Erkennung und Analyse. Viele der zur Datenfusion entwickelten Techniken versuchen, diese natürlichen Fähigkeiten des Menschen zu simulieren.

Dieses Kapitel dient der Einführung in die Problemstellungen, denen sich die Sensordatenfusion zu stellen hat und gibt einen Abriß der in diesem Themenkomplex gebräuchlichen Terminologie. Ein Modell für die Datenfusionsverarbeitung wird mit einer Zusammenfassung der Anwendungen, der verwendeten Ein- und Ausgangsdaten, der Sensortypen und grundsätzlichen Implementierungsfragen vorgestellt. Zu bedenken ist dabei auch, daß die Datenfusion keine Disziplin in dem Sinne wie schon etablierte wissenschaftliche Gebiete wie die Signalverarbeitung ist. Klar definierte Techniken und Terminologien existieren nur ansatzweise. Stattdessen bringt die Sensordatenfusion, wie sie als erstes in dem grundlegenden Text von Waltz und Llinas [44] dargelegt wurde, ein Konglomerat von Algorithmen und Techniken zur Anwendung.

## 1.2 Anwendungen der Sensordatenfusion

Datenfusionsanwendungen umfassen ein weites Gebiet. Militärische Anwendungen schließen ozeanographische Überwachung, Luft-Luft- und Boden-Luft-Abwehr ein, außerdem Aufklärung, Überwachung und Zielakquisition in Kampfsituationen oder strategische Warnung und Abwehr. Nichtmilitärische Anwendungen sind z.B. Justizvollzug, Fernerkundung [3], automatisierte Beobachtung von Installationen, medizinische Diagnostik und Robotik.

Ozeanographische Überwachung dient der Erkennung und Verfolgung von Zielen, Ereignissen und Aktivitäten. Beispiele für interessierende feindliche Aktivitäten sind der Abschluß eines Torpedos von einem U-Boot, Oberflächendurchtritt einer unter Wasser abgefeuerten Rakete oder die Kommunikation eines U-Bootes mit anderen Fahrzeugen. Das Gebiet der ozeanographischen Überwachung schließt Ziele in allen Höhenebenen ein. Zahlreiche Schiffe, U-Boote und Flugzeuge können dabei involviert sein: Sowohl als Sensorträger bzw. -plattformen als auch als Ziele. Die dabei zu beobachtenden Daten stammen aus den unterschiedlichsten Bereichen: Akustische Daten von Bojen, Schleppbojennetzen und Unterwassersensoren bis zu Daten von nuklearen und/oder nichtnuklearen Partikeln.

Die Luft-Luft- und Boden-Luft-Abwehr soll Flugzeuge oder Raketen so frühzeitig erkennen, verfolgen und identifizieren können, daß eventuelle Gegenmaßnahmen noch möglich sind. Systeme zur Identifizierung einzelner Flugkörper werden IFFN (Identification-Friend-Foe-Neutral) genannt. Die primären beobachtbaren Phänomene sind elektromagnetischer Natur (Infrarot, sichtbarer Wellenlängenbereich, Radiofrequenzen) und werden sowohl mit passiven als auch aktiven Sensoren wie Radar, Infrarotkameras, Laser-Radar und elektrooptischen (TV) Empfängern aufgenommen. Der Beobachtungsraum reicht von hunderten von Raumkilometern für strategische Anwendungen wie der Luftverteidigung einer Küste bis zu dem einige Kilometer großen Radius der Abwehr eines einzelnen taktischen Flugkörpers. Eine nah verwandte nichtmilitärische Anwendung ist die Identifizierung ankommender Flugzeuge auf zivilen Flughäfen.

„Battlefield“-Intelligenz zielt darauf, potentielle Bodenziele zu entdecken und zu identifizieren, um daraus Schlüsse über feindliche Kapazitäten, Taktiken und Strategien zu ziehen. Elektromagnetische Strahlung ist eine der Hauptgrößen, die dabei von Interesse sind. Zu diesen Größen gehören infrarote Strahlung von Motoren, die Abstrahlung der Kommunikationsausrüstung (Radios, Sprechfunkgeräte), Radar, Photos eines interessierenden Gebietes. Das interessierende Areal reicht dabei von einigen zehn bis zu einigen hundert Quadratkilometern. Die

Entwicklung moderner Waffen dehnt das taktische Beobachtungsgebiet dabei entsprechend des vergrößerten Wirkungskreises neuer Waffensysteme aus.

Es gibt zwei Aufgaben für die strategische Warnung und Abwehr: 1) Entdeckung von Anzeichen drohender strategischer Aktionen und 2) die Entdeckung und Verfolgung ballistischer Raketen und ihrer Sprengköpfe. Im Rahmen des SDI genannten Forschungs- und Rüstungsprogrammes der U.S.A. während der Reagan-Jahre wurden einige der massiven Schwierigkeiten deutlich, denen eine Realisierung eines solchen Programmes gegenübergestanden hätte. Ein erdumspannendes System von Sensoren (Satelliten, Flugzeuge) wäre dafür notwendig gewesen. Hauptbeobachtungsgröße wäre die Auffindung elektromagnetischer (z.B. tatsächliche visuelle Bestätigung von Abschußbasen, IR-Strahlung von Raketenabgasen, Erhitzung wieder-eintretender Sprengköpfe) Strahlung (in großer Bandbreite) gewesen. Die zuverlässige Entdeckung strategischer Indikatoren und daraus resultierender Warnungen beruht auf einer ungeheuren Vielfalt zu beobachtender Größen, wie der gegnerischen Kommunikation, Truppenbewegungen, Alarmstati und auch zunächst nicht militärischen politischen Aktivitäten. Datenfusion für diesen Problembereich würde eine riesige Menge ständig aufzunehmender und zu verarbeitender Daten bedeuten.

Nichtmilitärische Anwendungen der multisensoriellen Datenfusion behandeln ebenfalls Probleme, bei denen neben der Informationsflut die Einordnung und Koordination derselben zu sehen ist. Beispiele dafür sind z.B. die Durchsetzung (inter-) nationaler Gesetze gegen das organisierte Verbrechen (z.B. globaler Drogenhandel), Fernerkundung, medizinische Diagnose und die automatische Steuerung und Regelung komplexer Anlagen [71-74, 79-80].

Populäre und eindringliche Beschreibungen dieser und anderer Anwendungen von Systemen der multisensoriellen Datenfusion finden sich z.B. in den Techno-Thrillern des U.S.-Autors Tom Clancy.

Anwendungen im Bereich Kriminalitätsbekämpfung wie die Be- und Verhinderung des internationalen Drogenhandels können recht ähnliche Vorgehensweisen erfordern wie die militärische Aufklärung und Überwachung. Die Drogenhandelsbekämpfung z.B. kann Grenzpatrouillen einschließen, um Bewegungen der Drogenmafia nicht nur zu quantifizieren, sondern auch zu qualifizieren. Die dabei verwendbaren Sensoren kommen auch im militärischen Bereich vor. Ein Drogenhund z.B. ist ein ziemlich einzigartiger biologischer Sensor. So wie die Drogenmafia sich immer weiter entwickelt und bessere „Vertriebswege“ erschließt, so muß auch deren Bekämpfung durch intelligentere Sensoren und höhere Verarbeitungskapazitäten zur Prozessierung der damit gewonnenen Daten unterstützt werden.

Ein Beispiel für ein Werkzeug zur Fusionsverarbeitung multisensorieller Daten im Bereich der Kriminalitätsbekämpfung ist das Softwarepaket PROMIS (Prosecutors Management Information System) der U.S.-Firma Inslaw, das vor allem in den Reagan-Jahren dazu benutzt wurde, durch die Verknüpfung von Informationen Verdächtige zu ermitteln. Es handelt sich dabei um ein „intelligentes“ Datenbankprodukt, das mit verschiedensten Algorithmen nach Art einer Rasterfahndung unterschiedlichste und vielfältige Informationen aus einer Vielzahl von Datenquellen zusammenführt und bewertet [14].

Anwendungen aus dem Bereich der Fernerkundung (Remote Sensing) sind z.B. die Beobachtung der Erde, um Getreide, Wetterbedingungen [4], mineralogische Vorkommen, Umweltbedingungen und deren Bedrohung durch Ölteppiche, Strahlungslecks usw. aufzufinden und zu kontrollieren. Auch hier kann wieder ein ganzes Spektrum von Datenquellen Verwendung finden. Spezielsensoren wie SAR (Synthetic Aperture Radar) erlauben eine aktive Überwachung, während passive Sensoren eher den sichtbaren und IR-Anteil des elektromagnetischen Spektrums abdecken. Besondere Beispiele für Fernerkundungsanwendungen sind z.B. der Gebrauch der Landsat-Satelliten der NASA zur Landüberwachung, anderer Satelliten zur Erforschung der Planeten (Mars-Mobil Sojourner) und anderer Sonnensysteme und das Hubble Space Teleskop. Jedes dieser Beispielsysteme enthält eine ganze Reihe von Sensoren, deren Zusammenwirken es erlaubt, physikalische Phänomene und Ereignisse zu lokalisieren, zu identifizieren und zu interpretieren; wobei Fehler nicht ausgeschlossen sind [15].

Datenfusionssysteme werden ebenfalls entwickelt und eingesetzt, um komplexe Ausrüstungen und Produktionssysteme zu optimieren [65], zu überwachen und zu regeln. Bestimmte Systeme, wie Nuklearanlagen und Flugzeuge, erfordern eine ständige Überwachung, die die Möglichkeiten menschlichen Bedienpersonals überfordert. Eine zumindest teilautomatisierte Überwachung ist zur Sicherstellung eines geordneten Betriebes solcher Systeme zwingend notwendig. Daten vieler Sensoren werden zusammengeführt, um den Zustand eines solchen Systems bestimmen zu können, z.B. zur Qualitätssicherung [29]. Viele Datenfusionssysteme wurden auch schon zum Thema der automatischen Fehlerdiagnose entwickelt. Ableitbare Folgerungen reichen von der einfachen Überwachung einer Funktion (z.B. ob Daten wie Temperatur, Druck, Geschwindigkeit innerhalb akzeptabler Grenzen liegen) bis zu komplexen Schlußfolgerungen (z.B. Anzeichen drohender Kernschmelze in einem AKW) unter Zugrundelegung vieler möglicher Beobachtungen und Indikatoren. Ein Beispiel aus der industriellen Praxis sind die Bemühungen um sogenannte OLAP-Strategien (Online Analytical Processing), bei denen unter dem Stichwort „Data Mining“ mit Hilfe neuronaler Netze versucht wird, Zusammenhänge und

Regeln in Unternehmensdaten zu finden, um aus im gesamten Unternehmen zersplitterten Detailinformationen wertvolle Gesamtinformationen zu bilden.

Andere Beispiele für die Anwendung der multisensoriellen Datenfusion sind Techniken, die zur Unterstützung der medizinischen Diagnostik genutzt werden. Auf niedriger Ebene, um gewisse häufig vorkommende Krankheiten zu erkennen, kann ein Arzt die Berührung (tastende Untersuchung von Gewebe, Untersuchung der Bewegbarkeit eines Gelenks), die optische Begutachtung (allgemeines Aussehen), Geräusche (Atmung eines Patienten, Lungenzustand) und auch die durch den Patienten selbst beschriebenen Symptome in die Diagnose einfließen lassen. Schwierigere Problemstellungen können bedeuten, daß zunächst eine weitaus größere Datenbasis aus den Beobachtungen vieler Sensoren aufgebaut werden muß (z.B. Röntgenbilder, CT, chemische und biologische Tests, Ultraschall). Aus diesen Daten gewinnt der Arzt wertvolle Einsichten in das, was zu tun ist (z.B. Gehirnoperationen, die durch CT und andere Sensoren vorbereitet, eine weitaus ungefährlichere Operation ermöglichen).

Ein letztes Beispiel für die Anwendung der multisensoriellen Datenfusion ist die Integration mehrerer Sensoren für den Einsatz von Robotern [49]. Industrieroboter verwenden z.B. Mustererkennungs- und Stereobildverarbeitungstechniken, um dreidimensionale Objekte zu klassifizieren und zu erkennen. Die nicht nur auf diesem Feld berühmte Carnegie-Mellon-Universität experimentiert z.B. mit Systemen, die zur Entwicklung eines beweglichen Roboters führen sollen, der Hindernisse vermeidet und allgemeinen Regeln folgt. [49] adressiert das Problem der Multisensordatenfusion und -integration mit besonderer Berücksichtigung der optimalen Estimation kombinierter Sensordaten.

Die genannten Beispiele sind nicht erschöpfend. Vielmehr sollen sie andeuten, wie weit die potentiellen Anwendungen der multisensoriellen Datenfusion reichen können.

Anwendungen der multisensoriellen Datenfusion können entsprechend den folgenden Fragen und Themengebieten charakterisiert werden:

1. Welche spezifischen Schlußfolgerungen sollen durch das Datenfusionssystem gezogen werden? Wie wichtig sind Lokalisierung, Identifizierung oder Charakterisierung eines bestimmten Ereignisses? Können diese Schlußfolgerungen direkt den Eingangsdaten zugeordnet werden (z.B. Eingangsdaten überschreiten eine A-Priori-Schwelle) oder sind komplexe Muster und Schlußfolgerungen von Bedeutung? Sind (speziell ausgebildete) Menschen in der Lage, diese Schlußfolgerungen zu treffen?
2. Welche Daten sind potentiell beobachtbar? Welche physikalischen Phänomene treten auf?

3. Wie sieht das Umfeld aus? Stören Interferenzen, Rauschen oder aktive Gegenmaßnahmen die Sensorbeobachtungen? Hat der Beobachtende eine gewisse Kontrolle über dieses Umfeld und wie weit geht diese?
  4. Welche Sensoren sind verfügbar (Typ, Anzahl)? Welche Datenqualität bzw. Empfindlichkeit besitzen sie? Sind es aktive, passive, gesteuerte oder durch das Datenfusionssystem geführte Sensoren?
  5. Welche Arten von Daten können beobachtet werden und wie groß ist deren Menge?
  6. Wie groß darf die Spanne sein zwischen Aufnahme der Daten und gewünschter Art der Schlußfolgerung bzw. wieviel Zeit kann auf die Verarbeitung der Daten verwendet werden?
- Diese Fragestellungen charakterisieren eine Datenfusionsanwendung. Sie bestimmen die Auswahl und den Gebrauch von Datenfusionstechniken wie auch die Implementierung eines derartigen Systems.



### 1.3 Sensoren und Sensordaten

Die Daten, die ein Sensordatenfusionssystem verarbeiten soll, stammen allgemein aus drei verschiedenen Quellen:

- 1) Daten, die über Sensoren beobachtet werden,
- 2) Daten und Befehlsfolgen von Bedienpersonal und
- 3) A-Priori-Daten einer bestehenden Datenbasis.

Der folgende Abschnitt gibt einen kurzen Abriß über Sensoren, Sensordaten und die Sensorumgebung.

Einen generellen Überblick über hier betrachtete Sensoren liefert [44]. Tabelle 1.1 ordnet einige beispielhafte Sensorsysteme den dabei verwendeten Frequenzbereichen zu:

Sensorsystem	Spektraler Bereich
Akustikdetektoren Aktives, passives Sonar Seismometer	1 Hz .. 100 KHz
Magnetometer	1 Hz .. 1 MHz
Mono-, Multistatisches Radar	10 MHz .. 50 GHz
Millimeterradar, Radiometer	30 GHz .. 300 GHz
IR-Radiometer	300 GHz .. 400 THz, 1 mm .. 750 pm
Multispektrale Arrays, Laser-Radar, Elektrooptische Sensoren	384 THz .. 769 THz, 781 pm .. 390 pm

Tabelle 1.1: Sensorspektrum

Über das gesamte Energiespektrum betrachtet verwenden Sensoren entweder aktive oder passive Ansätze. Um in einem Ziel (allgemein: für ein Ereignis) ein beobachtbares Phänomen auszulösen, sendet ein aktiver Sensor Energie aus. Beispiele aktiver Sensoren sind Radar, Laser, Röntgenapparate und Maschinen, die nukleare magnetische Resonanz oder elektromagnetische Induktion verursachen. Passive Sensoren nehmen die natürlichen Emissionen eines Zieles oder eines Ereignisses auf. Beispiele passiver Sensoren sind optische oder Infrarotkameras, passive akustische Sensoren, Röntgen- oder Gammastrahlungsdetektoren. Die Auswahl eines aktiven

oder passiven Systems hängt von vielen Faktoren ab, z.B. dem Wunsch nach Geheimhaltung (sehen oder nicht gesehen werden) oder Fragen, die sog. Destruktive Beobachtung betreffen (z.B. ob ein aktiver Sensor das zu beobachtende Objekt ungünstig beeinflusst).

Bild 1.1 illustriert einen beispielhaften Sensor. Der Sensor nutzt ein Sammelelement, um eintreffende Energie zu detektieren und eine Mischung aus zu detektierender Energie eines Zieles (elektromagnetische Strahlung, akustische Energie, nukleare Partikel) und Energie aus der Umgebung wie Rauschen (thermisch, galaktisch, irdisch), Mehrwegsignale und Interferenz zu beobachten. Ein Teil der nicht vom Ziel stammenden Energie kann auch vom Sensor bzw. Kollektor selbst verursacht sein. Eine Infrarotkamera z.B. strahlt infrarote Strahlung aus, die teilweise zur Beobachtung beiträgt. Ähnlich werden Antennen im radiofrequenten Bereich von thermischem Rauschen aufgrund der Umgebungstemperatur beeinflusst. Eine weitere Quelle eintreffender Energie kann auch elektronische Störsignale beinhalten, die absichtlich von einem Gegner generiert werden, um einen Beobachter zu täuschen, indem das Signal-zu-Rausch-Verhältnis (SNR) der beobachteten Umgebung verringert wird.

Die internen funktionalen Komponenten des Sensors sind in Bild 1.1 dargestellt. Die Sensor-komponenten sind in zwei Gruppen aufgeteilt: 1) die Teile eines aktiven Sensors, die benötigt werden, um Energie abzustrahlen (Sensorelemente zur Abstrahlung), und 2) die Teile, die Energie detektieren und eine Beobachtung als Ergebnis erzeugen. Diese Funktionen sind im unteren Teil des Kastens in Bild 1.1 angedeutet und beinhalten Signalaufbereitung und -prozessierung, Informationsbildungsprozesse sowie die Ausgabeprozessierung. Der Signalaufbereitungsprozeß ändert den informationellen Inhalt der Daten nicht, aber er führt Transformationen durch, die die folgende Prozessierung vereinfachen (z.B. Frequenzumsetzungen, Zeitverzögerungen, A/D- bzw. D/A-Wandlungen). Die Signale werden an diesem Punkt der Prozeßkette oft auf eine Normierungsfrequenz oder eine Standardzeit bezogen. Verknüpfungen mit der Ankunftszeit, der Ankunftsfrequenz oder Dopplerprozessierungen finden hier ebenfalls ihren Platz.

Eine zweite Aufgabe der internen Signalprozessierung ist die Prozessierung selbst. Das Ziel ist dabei, den interessierenden Energieanteil aus der gesamten vom Sensor empfangenen Energie auszuwählen bzw. zu isolieren. Dazu gehören Transformationen vom Zeit in den Frequenzbereich [37], Schwellwertdetektion von Amplituden aus dem Hintergrundrauschen, Filteroperationen aller Art, Interferenzenbeseitigung oder -begrenzung und Bandbegrenzung. An diesem Punkt wird das vom Sensor empfangene Originalsignal durch die Prozessierung verändert, um den interessierenden Signalanteil zu detektieren und zu isolieren. Die gewonnenen Daten kön-

nen dann direkt aus der Prozeßkette ausgekoppelt oder weiteren Arbeitsschritten unterworfen werden.

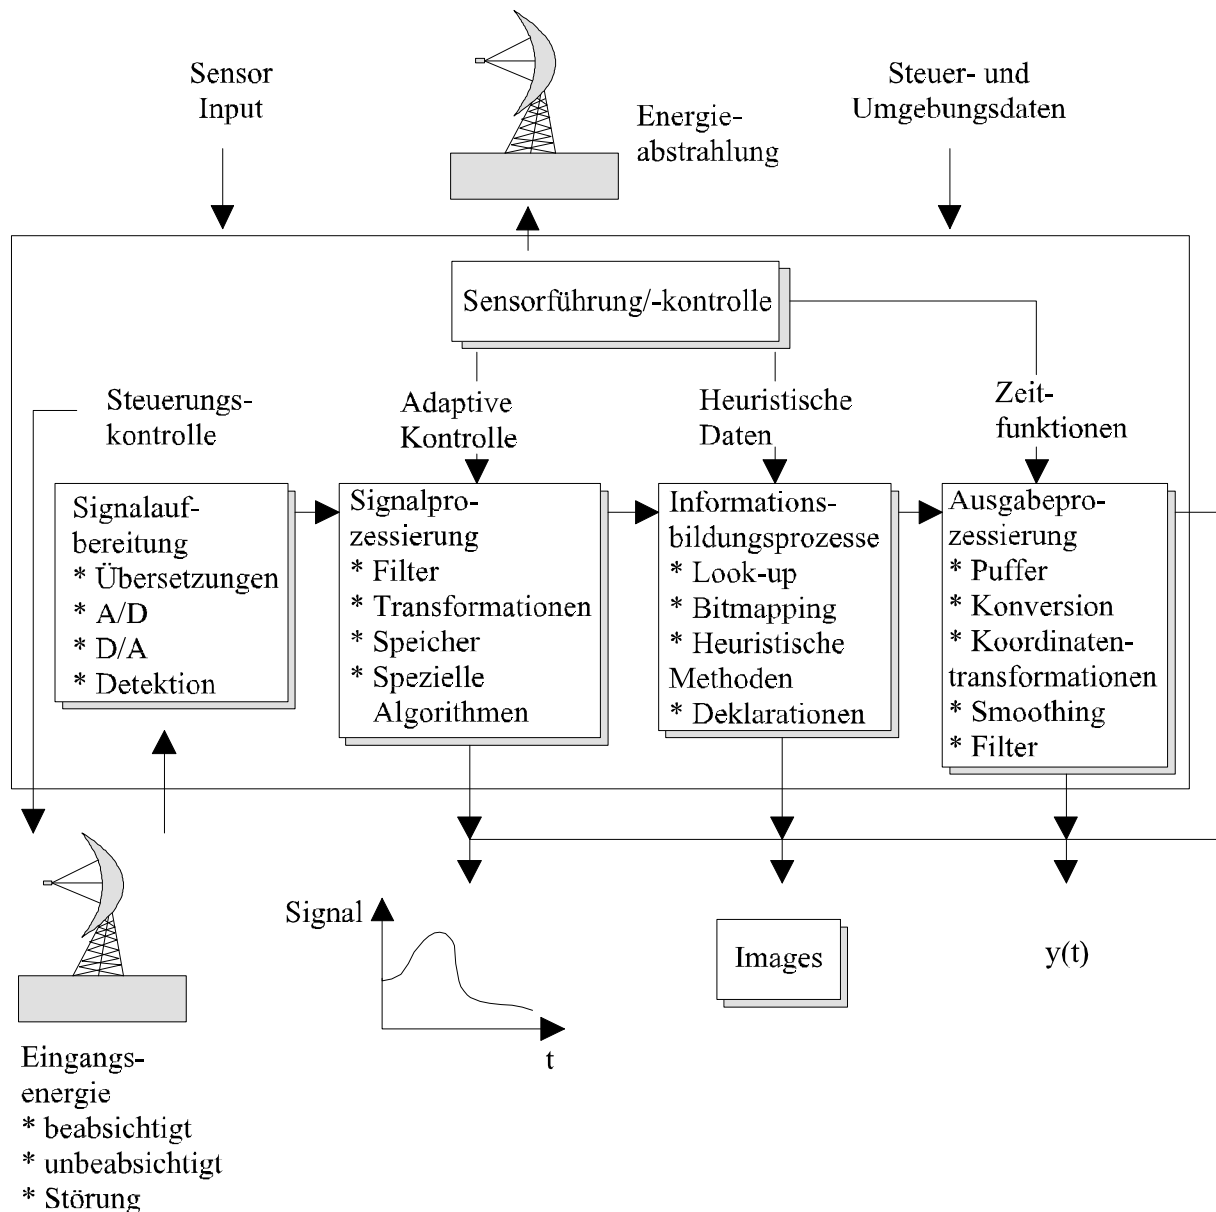


Bild 1.1: Beispielhafter Sensor

Wenn ein interessierendes Signal isoliert werden konnte, können Informationsbildungsprozesse angewendet werden, um die Daten einer höheren Integrationsstufe zuzuführen. Klassifikationsalgorithmen [64] dienen zur Mustererkennung, um Fragen wie die folgende zu behandeln: Ist das empfangene Signal ein Strom von Bits oder das von einem Ziel zurückgestrahlte Signal? Der Teil der Prozeßkette, der sich mit Klassifikation beschäftigt, benutzt Methoden wie Mu-

stererkennung, um unbehandelte Beobachtungsdaten zu einer Deklaration der Zielidentität zu transformieren. Z.B. können Radarrückstreuquerschnitt-Daten (RCS) automatisiert analysiert werden, um Größe und Form eines Zieles zu bestimmen, um daraus schließen zu können, ob es sich bei dem beobachteten Ziel um ein Flugzeug, Vögel, Wolken o.ä. handelt. Auf ähnliche Weise können Bilddaten verarbeitet werden, um Größe, Form und Identität eines Objekts zu bestimmen. Methoden, die dabei angewandt werden, können z.B. einfaches Bitmapping sein, Bestimmung von Identifikationsparametern über Look-up-Tabellen, Cluster-Analyse-Methoden und adaptive neuronale Netzwerke.

Wenn ein Sensor eine Klassifikationsfunktion ausführt, verwenden die Identitätsdeklarationen dabei eine von zwei grundsätzlichen Bestimmungsstrategien. Sog. Hard-Decision-Sensoren erkennen eine Zielidentität nur dann, wenn die parametrischen Klassifiziererdaten eine vorherbestimmte Schwelle überschreiten. Ein Hard-Decision-Sensor prozessiert die ankommenden Daten und verwendet eine Bestimmungsregel, um etwas über die Zielidentität auszusagen. Demgegenüber stehen sog. Soft-Decision-Sensoren, die teilweise Identitätsdeklarationen liefern, sobald das Signal eines Zieles entdeckt ist, die also Identitäten mit variablen Wahrscheinlichkeiten als Ergebnis ausgeben bzw. einem assoziierten Vertrauensintervall. Soft-Decision-Sensoren akkumulieren bzw. integrieren ihre Erkenntnisse, liefern jeweils ihre bis zu diesem Punkt gesammelten Erkenntnisse und damit verbundenen Unsicherheiten mit Hilfe von Wahrscheinlichkeitsaussagen, „Fuzzy Membership“-Funktionen, Vertrauensfaktoren oder Erkenntnisintervallen.

Die Ausgabeprozessierung eines Sensors umfaßt Datenpufferung, Koordinatentransformationen, Glättungs- und Filterfunktionen. Z.B. können Positionsdaten so prozessiert werden, daß als Ergebnis der Verarbeitung Schätzwerte der Position und der Geschwindigkeit eines Objektes generiert werden. Die Resultate eines Sensors sind von einer der folgenden Arten:

1. Eine kontinuierliche oder abgetastete Signalform, die aus Amplituden, Frequenz oder Phase über der Zeit besteht.
2. Ein zweidimensionales Bild aus Koordinaten und assoziierten Amplituden- bzw. spektralen Daten.
3. Ein Vektor aus parametrischen Positionsdaten (z.B. Abstand, Winkelinformationen), Zustandsvektor des Zieles (tatsächlich geschätzter Zielpunkt), parametrischen Daten mit Bezug zur Zielidentität oder zugehörigen Charakteristika (z.B. Frequenz, Größe, Form) oder einer Zielidentitätsaussage (z.B. Flugzeugtyp Airbus A310).

4. Andere nützliche Ausgabedaten eines Sensors sind z.B. Informationen über den Zustand eines Sensors (Status, Betriebsbereitschaft) und Charakterisierung der Beobachtungsumgebung (Hintergrundrauschen).

Sensoreingabedaten sind i.A. Daten, die zur Steuerung des Sensors benötigt werden: Kommandos, Sichtwinkeldaten, Hilfsdaten für die Klassifikation usw. Bis zu welchem Grad ein Sensorsystem wie in Bild 1.1 seine Aufgaben erfüllen kann, hängt von seinem Zweck, seinem Aufbau und Einsatzbeschränkungen ab. Moderne Mikroprozessoren, ASICs (Application Specific Integrated Circuit) und Hochgeschwindigkeitsbausteine (VHSIC = Very High Speed Integrated Circuit) erlauben zunehmend intelligentere Sensoren, in die immer komplexere Funktionalitäten integriert werden können, statt diese Aufgaben an Nachverarbeitungs- oder Fusionsysteme zu delegieren. Dieser Trend zur Integration von Prozessierungsfunktionalitäten in den Sensor bestimmt auch den Entwurf und Aufbau einer Fusionsystemarchitektur und die Auswahl von Fusionsalgorithmen.

Jeder Sensor kann entsprechend seiner Detektionsfähigkeiten charakterisiert werden, seines räumlichen bzw. zeitlichen Auflösungsvermögens, der räumlichen Abdeckung, den Detektions- und Track-Modi (starr, scannend, Ein-/Mehrfachzielverfolgung), der Häufigkeit der Messungen, der Art des Sensors (Hard- oder Soft-Decision-Sensor) und der Detektions- bzw. Track-Ausgabe (einzelnes Ziel wird bei Detektion angegeben oder zeitlich-kontinuierliche Repräsentierung des Zielverhaltens).

Tabelle 1.2 zeigt eine Zusammenfassung der Meßmöglichkeiten von 11 Sensorarten: Radar, „Electronic Intelligence“-Empfänger (ELINT), elektronische Hilfsmaßnahmen (ESM, Electronic Support Measures), Radar mit synthetischer Apertur (SAR, Synthetic Aperture Radar), IFFN (Identification Friend Foe Neutral)-Sensoren, „Homing and Warning“-Radar, Infrarot- und Laserwarnsensoren, Infrarot, Kommunikationssensoren (z.B. Empfänger) und elektrooptische Sensoren (EO). Zu jeder Sensorart zeigt die Tabelle die Messung und die abgeleiteten Beobachtungsdaten. Die Spalte Zustandsbestimmung gibt einen Hinweis darauf, bis zu welchem Punkt diese Sensoren typischerweise genutzt werden, um Position, Geschwindigkeit und Identität von Objekten zu bestimmen.

Jede Analyse der Sensorfähigkeiten führt zwangsweise zu der Erkenntnis, daß es den perfekten Sensor nicht gibt, d.h. kein einziger Sensortyp kann zur genauen Detektion, Positionsbestimmung und Identifizierung in allen Bereichen, d.h. allen Szenarien eingesetzt werden. Einige Sensoren sind genauer, wenn es um Positionsbestimmungsaufgaben geht, während andere am

besten geeignet sind für Identifikationsaufgaben. Diese Tatsache ist eine der Ursachen für den Einsatz von Fusionstechniken.

Die Umgebung, in der ein Sensor arbeitet, um Daten zu sammeln, umfaßt natürliche physikalische Umgebungen (z.B. Atmosphäre, Ozean) und für militärische Applikationen evt. gegnerische Versuche, die Effektivität des Sensors durch Gegenmaßnahmen zu verringern. Die natürliche Umgebung beeinflusst die Ausbreitung von elektromagnetischen Wellen durch Brechung, Beugung und Dämpfung. In der Atmosphäre z.B. verringert das Vorhandensein von Wasserdampf die elektromagnetische Ausbreitung rasant um Faktoren von 1 bis 10 dB/km. Dichter Nebel kann zu Abschwächungen von über 100 dB/km im Infrarotbereich und für sichtbare Wellenlängen führen. Für den Radiofrequenzbereich ist die Ausbreitungsfähigkeit durch die Atmosphäre eine Funktion mit starker Abhängigkeit von der Wellenlänge und wird besonders beeinflusst von den geladenen Partikeln der Ionosphäre der Erde.

Sensor	Messung	Abgeleitete Meßgrößen	Zustandsbestimmung	Hinweis
Radar	RCS, Frequenz, Zeit	Range, Azimut, Elevation, Radialgeschwindigkeit, Zielgröße bzw. -form, Signatur	Position, Geschwindigkeit, Identität	Aktiver Sensor 1) Zielidentifikation begrenzt möglich aus RCS-Signatur 2) Zielgröße bzw. -form in bestimmten Fällen
ELINT-Empfänger	Amplitude, Frequenz, Zeit	SNR, Polarisation, Pulsform, PRF	Identität	3) Senderkennung 4) Schluß auf Radar-Charakteristika
ESM	Ähnlich wie ELINT	Ähnlich wie ELINT	Position, Geschwindigkeit, Identität	Ähnlich wie ELINT
SAR	kohärente RCS	Form, Größe, Richtung	Identifikation	Vergrößerte Radarauflösung durch kohärente Prozessierung einer bewegten Antenne
Homing and	RF-Intensitäts-	Richtung, Intensität	Identifikation	Warnung vor Beleuchtung durch evt. gegnerische

Warning Radar	Identifikation			sches Radar
IR Warnung	IR-Intensitätsdetektion	Richtung, Intensität	Identität	Warnung vor Herankommen von Hitzequellen
Laser Warnung	Optische Intensitätsdetektion	Intensität	Identität	Warnung vor Auftreffen von Laserstrahlen
EO	Bildelemente (Pixel), Pixelintensität, Pixelfarbe	Standort, Größe, Form	Position, Identität	Bestimmung von Größe und Form, aber aufwendige Prozessierung
IR	Pixelintensität, Farbe	Standort, Größe, Form, Temperatur, spektrale Charakteristika	Position, Identität	Identifikation aufgrund spektraler Daten, relativ schlecht zur Positions- bzw. Geschwindigkeitsbestimmung
Kommunikation	EXT: Externe Signale, INT: Interne Signale	EXT: RF-Modulation, Kodierung, Standort; INT: Text, Sprache, Schlüsselwörter, Sprecher	Position, Identität	

Tabelle 1.2: Messungen und Zustandsbestimmungen verschiedener Sensoren

Bild 1.2 illustriert repräsentativ den Effekt der Atmosphäre auf die Wellenausbreitung. Beobachtungsmodelle, die die Interaktionen von Sensor, Wellen, Ausbreitungsraum und Ziel handhabbar machen, sind außerordentlich komplex [38-39].

Im militärischen Umfeld werden aktive oder passive Gegenmaßnahmen benutzt, um den Informationsgehalt zu verringern.

Zwei grundsätzliche Strategien sind dabei anwendbar:

1. der Zusatz von Zufallssignalen, um das SNR der empfangenen Signale zu vermindern, und damit den Informationsgehalt (Jamming) oder
2. der Zusatz von speziellen Signalen (Deception), um die Fehlerrate des Sensors zu erhöhen.

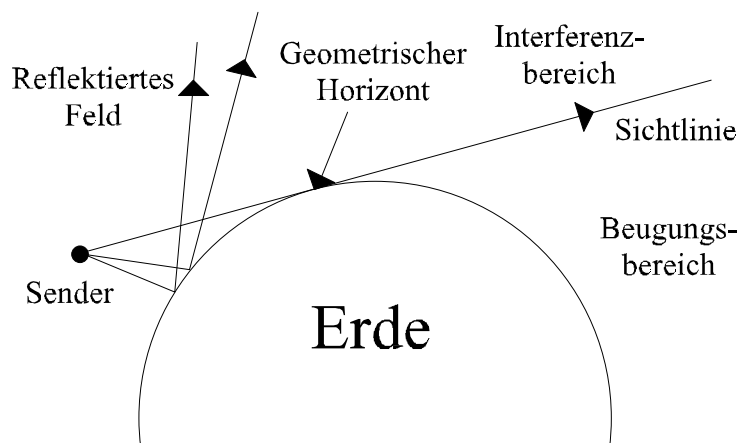
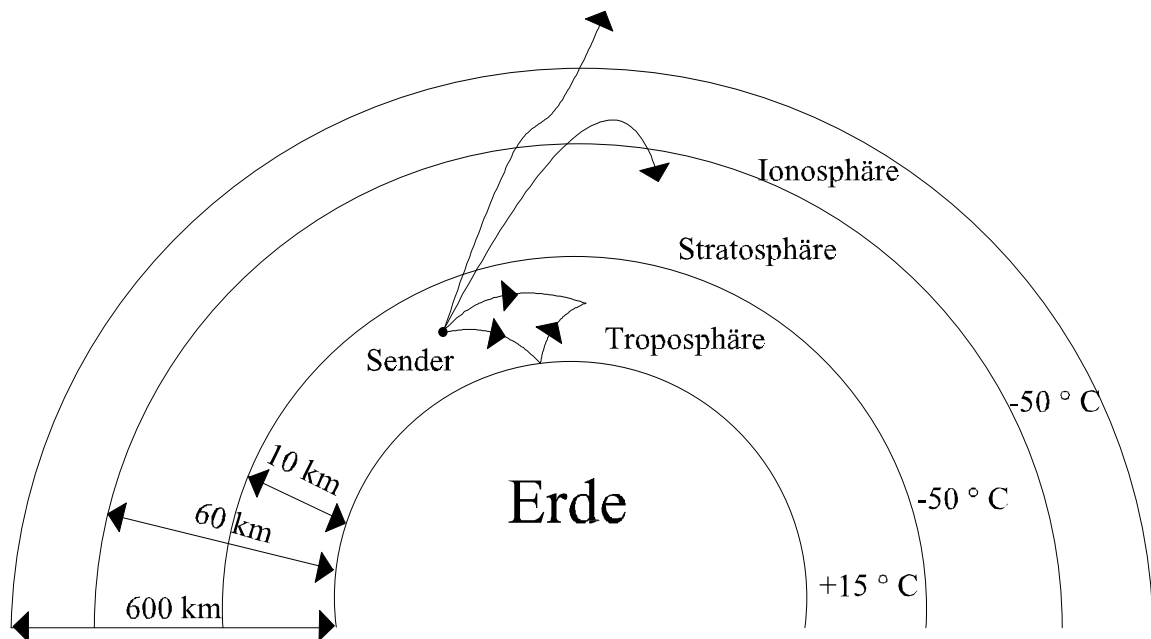


Bild 1.2: Atmosphärische Effekte

Elektronische Gegenmaßnahmen (ECM) werden in drei Kategorien klassifiziert:



1. die Benutzung von aktiven Strahlern oder von Täuschungstechniken wie der Erzeugung von falschen Signalen,
2. der Gebrauch von Mediumsmodifizierern wie absorbierenden Aerosolen und
3. die Modifikation der Reflektivität eines Zieles z.B. durch das Design des Fahrzeuges, die Verwendung von Radar-absorbierenden Materialien, Echoverstärkern bzw. sog. „Corner Reflectors“.

Die Möglichkeit von täuschenden und störenden Signalen verkompliziert Datenfusionsprobleme i.A. sehr.

## 1.4 Inferenzhierarchie: Ausgangsdaten

Die Eingangsdaten eines Datenfusionssystems bestehen aus Sensordaten, Kommandos und A-Priori-Informationen. Das Ergebnis eines Datenfusionsprozesses repräsentiert die kombinierten bzw. fusionierten Daten. Diese Ausgangsdaten sind spezifische und genaue Schätzwerte des Standortes und der Identität eines Zieles, einer Betrachtungseinheit, einer Aktivität oder Situation. Bild 1.3 zeigt eine Hierarchie von Inferenzen, wie sie durch Datenfusionssysteme erreicht werden soll.

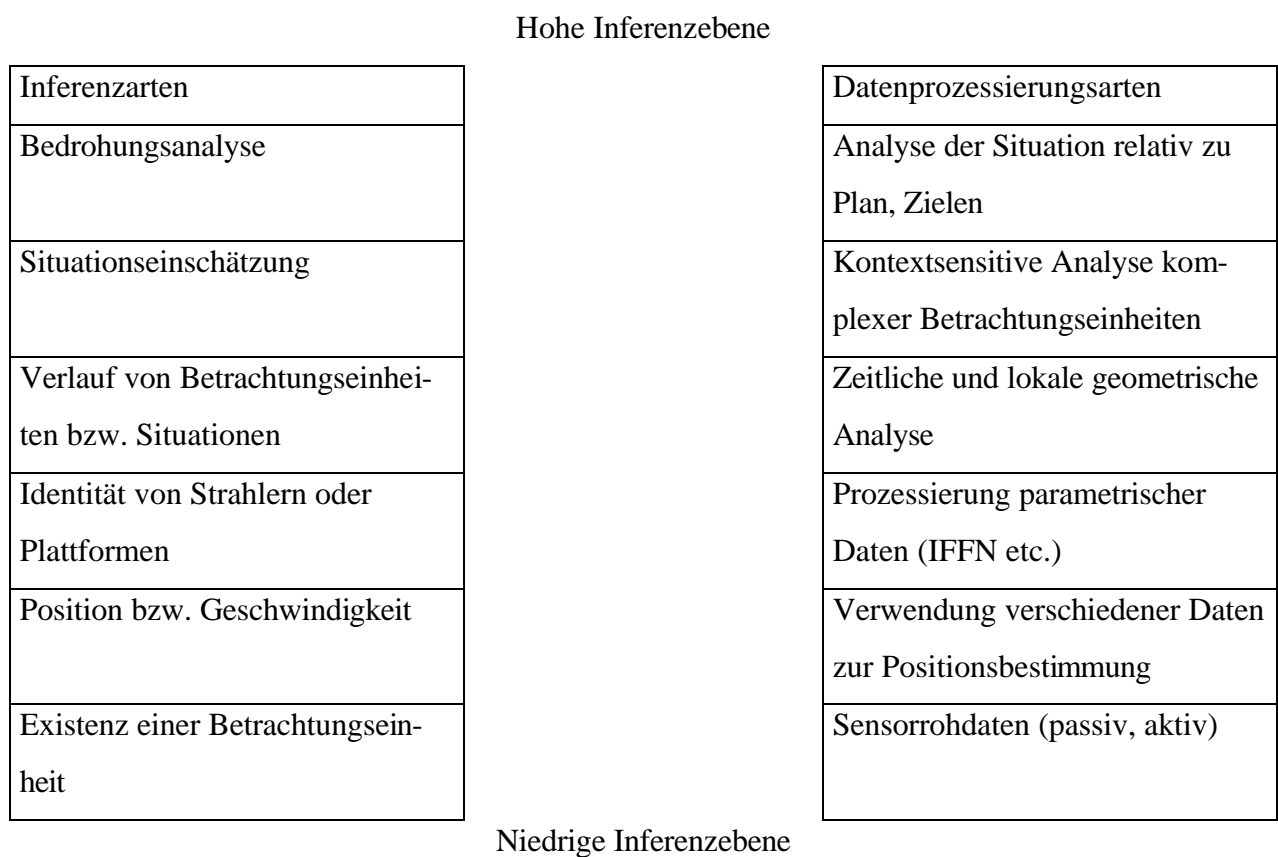


Bild 1.3: Inferenzhierarchie

Auf unterster Ebene versucht ein Sensor- bzw. Fusionssystem Energie zu detektieren und die Existenz bzw. das Vorhandensein einer Betrachtungseinheit bzw. Situation zu bestimmen. Dabei steht Betrachtungseinheit bzw. Situation für ein physikalisches Phänomen, eine Plattform oder ein Fahrzeug, eine gegnerische Einheit, ein Ziel, Präsenz und Identität eines Systemfeh-

lers, die Ursache einer Krankheit oder eine andere Situation, zu deren Beobachtung das Fusionssystem gedacht ist.

Die referenzierte Betrachtungseinheit hängt von der speziellen Applikation ab (s. 1.2). Die Existenz einer Betrachtungseinheit vorausgesetzt, ist die Bestimmung von Position und Geschwindigkeit die nächsthöhere Inferenz- bzw. Schlußfolgerungsebene. Idealerweise wird dabei ein vollständiger sechsdimensionaler Zustandsvektor angestrebt: drei Komponenten, die die Position  $(x, y, z)$  bestimmen, und drei Komponenten, die die Geschwindigkeit beschreiben. Der Zustandsvektor umfaßt allgemein diejenigen Parameter, die, wenn hinreichend bekannt, eine Voraussage über den zukünftigen Systemzustand erlauben. Für ein dynamisches System erlaubt die Kenntnis des Systemzustandes und der Bewegungsgleichungen zu einem Zeitpunkt  $t_0$  die Voraussage über den Systemzustand zu einem beliebigen späteren Zeitpunkt  $t$ .

Eng verbunden mit der Position ist die Identität einer Betrachtungseinheit. Identität könnte z.B. durch eine allgemeine Klassifikation erreicht werden, mit der ein beobachtetes Flugzeug in eine bestimmte Klasse eingeteilt wird. Inferenzen bzw. Schlußfolgerungen bzgl. der Identität einer Gegebenheit bedingen Transformationen von parametrischen Datensätzen hin zu Identitätsdeklarationen durch die Verwendung von Mustererkennungsmethoden (PRM, Pattern Recognition Method).

Höhere Schlußfolgerungsebenen behandeln das Verhalten von Betrachtungseinheiten, deren Absichten, Situationsbestimmungen und - besonders für militärische Systeme - Bedrohungsanalysen. Die höchsten Ebenen sollen die Überlegungen von menschlichen Experten emulieren. Die Steigerung der Schlußfolgerungsebene bzw. das „Erklettern“ der Inferenzhierarchie geschieht durch Verwendung von Techniken, die von Signalprozessierungsalgorithmen und statistischen Estimationsmethoden zur Kombination parametrischer Daten bis zu heuristischen Methoden wie dem sog. Templating oder Expertensystemen reichen. Die dazu verwendeten Daten sind parametrische Rohdaten oder - höher in der Inferenzhierarchie - nichtparametrische Daten wie Meinungen von menschlichen Experten.

Im Bewußtsein zu halten ist bei der Beschäftigung mit Datenfusionssystemen, daß das Ergebnis dieser Systeme und die Arbeit damit menschliche Entscheidungsprozesse unterstützen soll. Manche der verfügbaren Systeme tun so, als ob sie nur dazu geschaffen worden wären, die Bedürfnisse der Sensoren zu befriedigen, nicht aber der Menschen, die mit diesen Systemen arbeiten müssen. Z.B. ist die eigentliche Aufgabe eines medizinischen Diagnosesystems nicht,

möglichst viele Röntgenbilder in kürzester Zeit zu prozessieren, sondern den Arzt bei einer korrekten spezifischen Diagnose zu unterstützen.

## 1.5 Ein Datenfusionsmodell

Ein Datenfusionsprozeß kann von verschiedenen Standpunkten aus betrachtet werden: Ein funktionales Modell vergegenwärtigt die Primärfunktionen, die relevanten Datenbasen und die Verbindungswege, auf denen die Datenfusion ausgeführt wird. Ein architektonisches Modell kann Hard- und Softwarekomponenten spezifizieren, assoziierte Datenwege und externe Interfaces. Ein mathematisches Modell kann die verwendeten Algorithmen und logischen Prozesse beschreiben. Der vorliegende Abschnitt beschreibt ein funktionales Modell zur Datenfusion. Dieses Modell ist von der JDL-DFS (Joint Directors of Laboratories, Data Fusion Subpanel) aufgestellt worden als Referenz zur Betrachtung und Diskussion von Datenfusionsthemen und -problemen.

Das in Bild 1.4 dargestellte Modell basiert auf einer Darstellung von Edward Waltz und James Llinas [44], die von der JDL-DFS zur Etablierung einer gemeinsamen Terminologie und einheitlicher Konzepte als erste zweier Versionen eingeführt wurde. Dieses Modell wurde auf einigen Symposien der Johns-Hopkins-Universität zur Datenfusion präsentiert und hat bisher nichts von seiner Gültigkeit verloren [44].

Links zeigt das Modell Eingangsdaten, die von verschiedenen Sensoren herrühren. Indirekte Informationsquellen - kollateral genannt - wie Umweltdaten, A-Priori-Wissen und menschliche Steuerung bzw. Eingriffe gehören ebenfalls zu den Eingangsdaten des illustrierten Fusionsystems.

Hauptfunktionen sind Vorfilterung, Zuordnung der Daten in einem Managementsystem, Prozessierung in verschiedenen Stufen sowie Erzeugung und Pflege von Situations- und Hilfsdatenbasen. Externe Interfaces dienen als Mensch-Maschine-Schnittstelle und kontinuierliche oder offline Evaluierungsmöglichkeiten für das System. Maschine-Maschine-Interfaces sind im Modell nicht vorgesehen. Schnittstellen zur Aktuation bzw. zur Interaktion des Datenfusionsystems mit Maschinen machen das System jedoch gerade in Anwendungsfällen, in denen es genau darauf ankommt (z.B. Industrieroboter, komplexe Produktionssysteme), erst sinnvoll.

Die Vorfilterung der Eingangsdaten bedeutet eine automatisierte Möglichkeit zur Steuerung des Datenflusses in das Fusionsystem. Typischer- und auch unangenehmerweise besteht immer die Möglichkeit, daß ein Fusionsystem die Menge der hereinkommenden Daten nicht bewältigen kann, d.h. daß ein Fusionsystem unter bestimmten Voraussetzungen (z.B. Eingangsdaten vieler unterschiedlicher Sensoren) nicht in der Lage ist, die anstehenden Datenmengen zu verarbeiten.

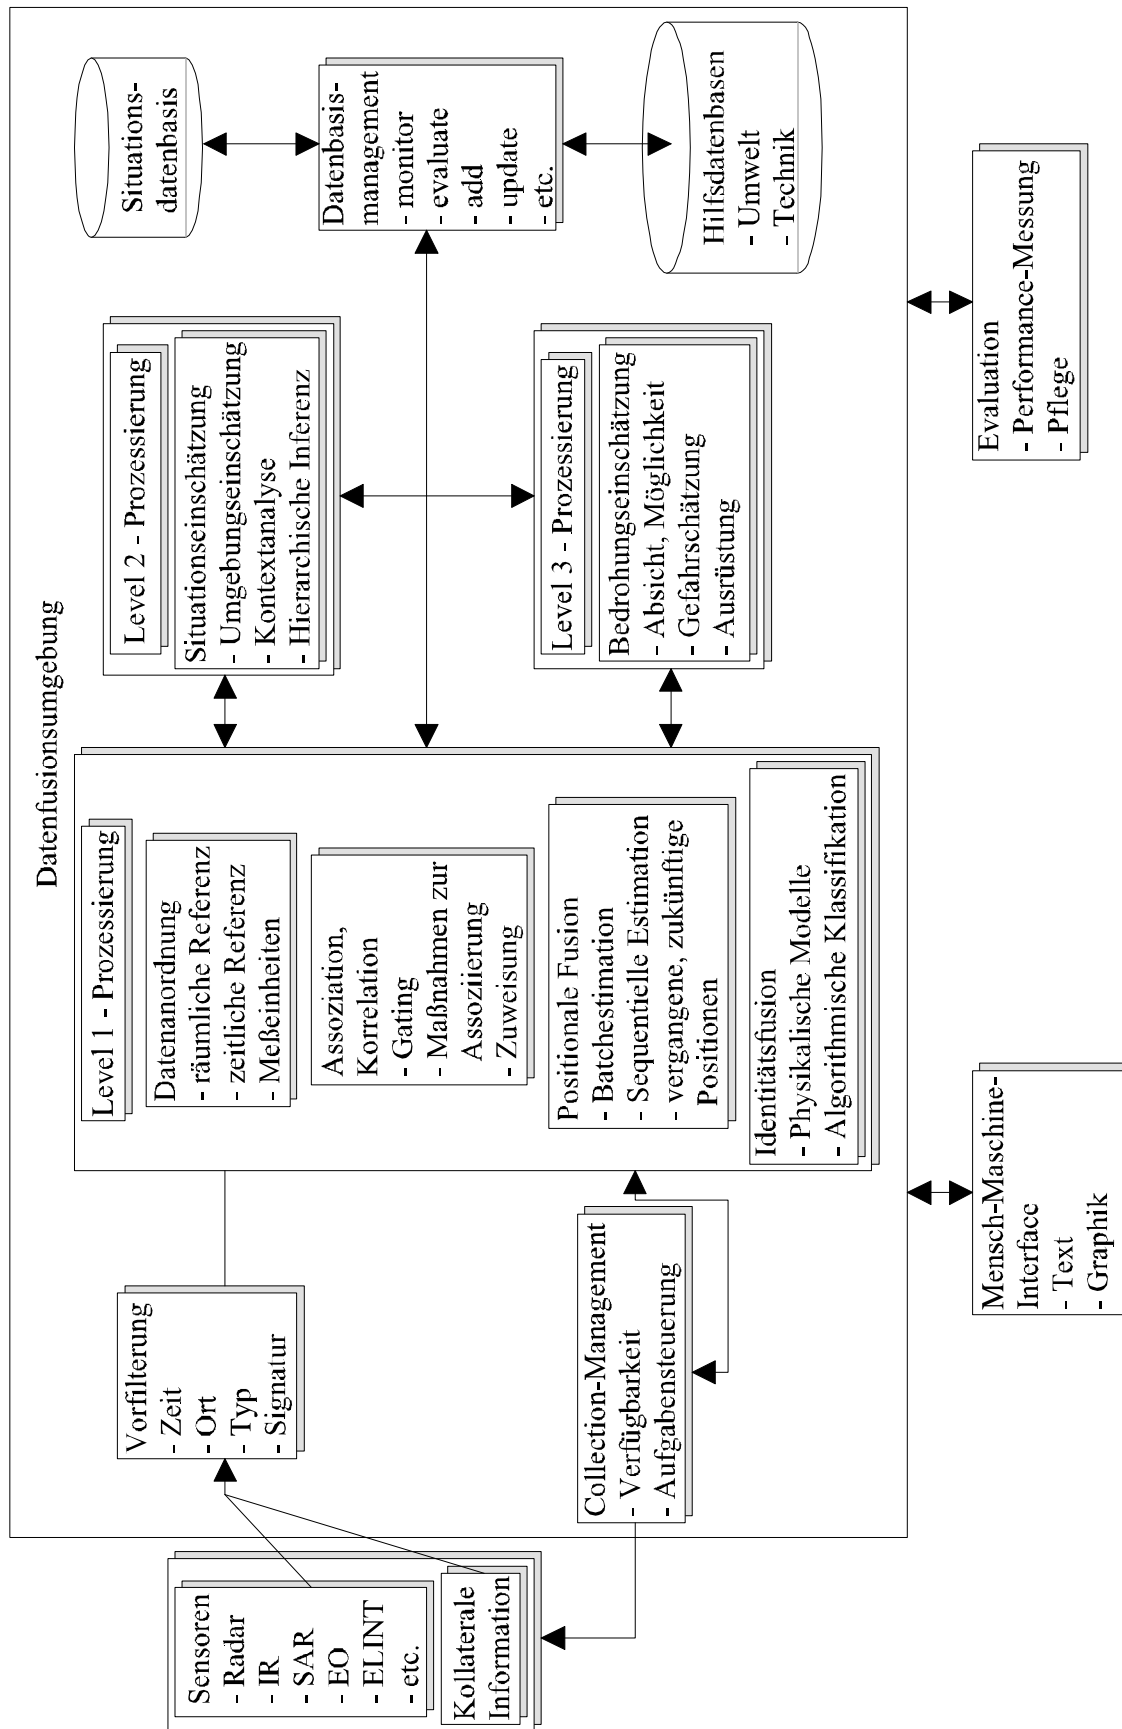


Bild 1.4: JDL-DFS Prozeß-Modell Datenfusion [44]

Die Datenraten der Sensoren übersteigen häufig die Berechnungsmöglichkeiten eines Fusions-systems. Daher ist eine Vorfilterung in vielen Fällen nicht nur sinnvoll, sondern auch notwendig. Die Vorfilterung kann dazu genutzt werden, die ankommenden Daten entsprechend definierter Kriterien zu sortieren: Beobachtungszeit, gemessener Ort, Daten- oder Sensortyp, Identitäts- oder Signaturinformation. Zur Filterung werden auch Informationen genutzt, die aus dem Umfeld stammen oder der Sensorqualität (z.B. SNR, Covariance-Error-Schätzwerte). Diese Informationen ermöglichen es, die Daten nach verschiedenen Kategorien zu ordnen und für die nachfolgende Prozessierung zu gewichten.

Die Funktion des sog. Collection-Managements ist es, die verfügbaren Datenkollektoren (Sensoren) zu koordinieren. Spezifische Funktionen sind die Bestimmung der Sensor-Verfügbarkeit, die Ablaufsteuerung in Bezug auf Datenaufnahme und die Priorisierung bestimmter Aufgaben sowie die Beobachtung des Sensorstatus in einer Rückkopplung. Die Sensorablaufsteuerung setzt die Positionsvorhersage dynamischer zu beobachtender Objekte voraus, die Berechnung von Abstrahlrichtungen eines Sensors (aus der geschätzten zukünftigen Position eines Objekts und des Ortes des Sensors werden die Richtungen, Range-Abstände usw. berechnet, die zur korrekten Ausrichtung des Sensors notwendig sind) und der dazu notwendigen Steuersequenzen, die Festsetzung von Beobachtungszeitpunkten und -räumen und die Optimierung der Sensorressourcen. Das Collection-Management ist besonders für umfangreiche Sensornetzwerke eine herausfordernde Aufgabe.

Drei Prozessierungsstufen werden in Bild 1.4 aufgezeigt. Die „Level 1“-Prozessierung verknüpft Daten zur Auffindung von Position, Geschwindigkeit und Identität von Betrachtungseinheiten oder Aktivitäten auf niedriger Ebene, wobei eine Betrachtungseinheit hier ein Ziel, eine Plattform, einen Sender oder ein bestimmtes geographisches Objekt bezeichnet, welches von verschiedenen Sensoren beobachtet wird. Die „Level 1“-Prozessierung kombiniert Positions- und Identitätsdatensätze verschiedener Sensoren zur Erstellung einer Datenbasis identifizierter Gegebenheiten, Zieltracks (Bewegung eines Ziels in einem bestimmten Zeitraum) und nichtkorrelierter Rohdaten. Diese Stufe der Prozessierung kann grob in vier Bereiche unterteilt werden:

1. Datenangleichung
2. Assoziation
3. Tracking und
4. Identifizierung.

Funktionen zur Datenangleichung transformieren die von verschiedenen Sensoren empfangenen Daten in einen gemeinsamen räumlichen und zeitlichen Referenzrahmen. Spezielle Angleichungsfunktionen beinhalten Koordinatentransformationen und Einheitenumrechnungen.

Datenassoziation behandelt das Problem der Sortierung bzw. Korrelation von Beobachtungen verschiedener Sensoren in Gruppen, die Daten einer bestimmten Gegebenheit darstellen. In einer komplexen Tracking-Umgebung, in der viele Ziele unbestimmter Identität in enger physikalischer Nähe zusammen sind, erfordert die Lösung des Problems verschiedene Strategien. Assoziation vergleicht Beobachtungspaare (z.B. Beobachtung N mit Beobachtung N-1) und entscheidet darüber, welche Beobachtungen zusammengehören bzgl. der gleichen Gegebenheit, des gleichen Ereignisses oder derselben Aktivität. Die Assoziation bestimmt auch darüber, welche - wenn überhaupt - neuen Beobachtungen zu einer bereits in der Fusionsdatenbasis etablierten bzw. bekannten Beobachtung oder Gruppe von Beobachtungen gehören.

Das Tracking-Problem gehört zu einem Prozeß, in dem verschiedene Beobachtungen von Positionsdaten zu einem Schätzwert der Ziel- bzw. Betrachtungseinheitsposition und seiner Geschwindigkeit verknüpft werden. Ein gängiges Tracking-Problem ist die Richtungsfindung, bei der unterschiedliche Winkelmessungen verarbeitet werden, um die Position eines stationären Ziels zu bestimmen. Ein weiteres übliches Tracking-Problem ist die Bestimmung der Bewegung eines Flugzeugs oder Schiffs mittels Radar. Tracking-Algorithmen starten mit einem A-Priori-Schätzwert von Position und Geschwindigkeit des Objekts und aktualisieren diese geschätzten Werte mit jedem neu hinzukommenden Beobachtungsmesswert.

Identifikation komplettiert die Kategorie der „Level 1“-Prozessierungsfunktionen. Identifikationsmethoden dienen dazu, Informationen bzgl. der Identität zu kombinieren; ähnlich zur Schätzung der Position anhand vorhandener Positionsdaten. Die dabei verwendeten Methoden sind z.B. Cluster-Methoden, adaptive neuronale Netzwerke, Templating und Dempster-Shafer- und Bayes'sche Inferenz-Methoden.

„Level 2“-Prozessierung bzw. Situationseinschätzung soll einen höheren Inferenzgrad als die „Level 1“-Prozessierung erreichen. Z.B. kann die „Level 1“-Verarbeitung eine bestimmte Anordnung bzgl. vorhandener Gegebenheiten analysieren (z.B. Ort, Identität), während die „Level 2“-Prozessierung einige Schritte weitergeht und z.B. Muster und/oder Bedeutungen in einer Aufstellung feststellt.

Für militärische bzw. aufklärerische Fusionssysteme führt die „Level 3“-Prozessierung durch einen schlußfolgernden Prozeß eine Bedrohungsanalyse durch. Dabei werden Aufgaben wie die Bestimmung der Gefährlichkeit von freundlich oder feindlich gesonnenen Kräften, Auswertung



von Vermutungen und Warnungen vor bevorstehenden Ereignissen, Zielberechnungen usw. ausgeführt.

Hilfsfunktionen eines Fusionssystems bestehen z.B. aus der Verwaltung der Datenbasen, Mensch-Maschine- bzw. Maschine-Maschine-Schnittstellen und Auswertungsfunktionen.

## 1.6 Nutzen der Datenfusion

Die Fusion von Daten unterschiedlicher Sensoren resultiert in einem sowohl qualitativen als auch quantitativen Nutzen. Das primäre Ziel der Fusion ist die Schätzung eines wie auch immer gearteten Zustandes von Betrachtungseinheiten oder die Ziehung von Schlußfolgerungen, die nicht aus den Daten eines einzelnen Sensors getroffen werden könnten.

Tabelle 1.5 faßt den qualitativen Nutzen der Multisensordatenfusion zusammen.

Kategorie	Allgemeiner Nutzen	Operationelle Vorteile
Robuste operationelle Performanz	Ein Sensor liefert Informationen, während andere nicht verfügbar, gestört sind oder das betreffende Ziel oder Ereignis nicht „sehen“	<ul style="list-style-type: none"> <li>• Weitergehende Messungen trotz Störungen</li> <li>• Erhöhte Detektionswahrscheinlichkeit</li> </ul>
Erweiterte räumliche Abdeckung	Ein Sensor kann immer noch messen, während ein anderer die Arbeit zumindest vorübergehend einstellen muß	Erhöhte Detektionswahrscheinlichkeit
Erweiterte zeitliche Abdeckung	s.o.	s.o.
Erhöhtes Vertrauen	Einer oder mehrere Sensoren bestätigen dasselbe Ziel bzw. Ereignis	Erhöhte Wahrscheinlichkeit korrekter Analyse
Reduzierte Mehrdeutigkeit	Von mehreren Sensoren zusammengeführte Informationen reduzieren die Anzahl der Hypothesen bzgl. eines Zieles bzw. Ereignisses	<ul style="list-style-type: none"> <li>• Priorisierung von Zielen bzw. Ereignissen</li> <li>• Mögliche stärkere Automatisierung</li> <li>• Früheres Eingreifen möglich</li> </ul>
Verbesserte Detektion	Effektive Integration mehrfacher Messungen vergrößert die Sicherheit der Detektion	Mögliche verbesserte Reaktionszeit
Verbesserte räumliche Auflösung	Mehrere Sensoren können geometrisch eine synthetische Apertur formen	Verbesserte Positionsdaten

Verbesserte Verlässlichkeit des Systems	Inhärente Redundanz mehrerer Sensoren	Redundante Systeme
Erhöhte Dimensionalität	Ein System mit unterschiedlichen Sensoren ist weniger verwundbar	Operation auch in schwierigem Umfeld möglich

Tabelle 1.5: Nutzen der Multisensordatenfusion

In quantitativer Hinsicht ist das Ziel der Datenfusion die Verbesserung der Genauigkeit von Schlußfolgerungen wie der Schätzung von Zuständen, z.B. der Position oder der Deklaration von Identitäten. Typischerweise hat ein Pulsradar die Fähigkeit, den Slant-Range (radialer Abstand von der Radarantenne zum beobachteten Objekt) genau zu bestimmen, aber die Genauigkeit bei der Bestimmung der Winkelposition, d.h. der Richtung eines Zieles ist begrenzt. Daher ist die mit einer Radarbeobachtung assoziierte Unsicherheit ein Volumen, dessen Dimensionen senkrecht zur Sichtlinie groß sind, aber schmal entlang dieser Linie. Im Gegensatz dazu bestimmt ein FLIR (Forward Looking Infrared Radar) die Winkelposition eines beobachteten Objekts, d.h. seine Position innerhalb eines zweidimensionalen Bildes, relativ genau, während die Unsicherheit bzgl. des Rangeabstandes groß ist. Wenn die Daten beider Sensoren verknüpft werden, wird die Unsicherheit der geschätzten Position des Zieles geringer als die Unsicherheit einer Messung allein. Die kombinierte Unsicherheit ist relativ gering sowohl bzgl. der Richtung als auch bzgl. des Rangeabstandes. Ein Fusionsschätzwert einer Position verbindet die spezifischen Stärken beider Sensoren, verbessert den Positionsschätzwert und verringert die Unsicherheit bzgl. der Position.

Die besondere quantitative Verbesserung der Schätzung, die aus der Verwendung verschiedener Sensoren herrührt, hängt von verschiedenen Faktoren ab, z.B. von Effekten des Umfelds oder den spezifischen für den Datenfusionsprozeß verwendeten Algorithmen. Eine genaue Bestimmung der Verbesserung, die durch den Einsatz von Datenfusion erzielt werden kann, erfordert numerische Simulationen, Monte-Carlo-Simulationen oder Covariance-Error-Analysen. Ein Versuch, den Nutzen der Datenfusion quantitativ zu illustrieren, stammt von Nahin und Pokoski [53]. Bild 1.5 zeigt den marginalen Zuwachs an korrekter Klassifikation durch eine erhöhte Anzahl von Sensoren. Nahin und Pokoski nehmen an, daß N identische Sensoren zur Beobachtung eines Phänomens zur korrekten Identifikation bzw. Klassifikation des Phänomens verwendet werden.

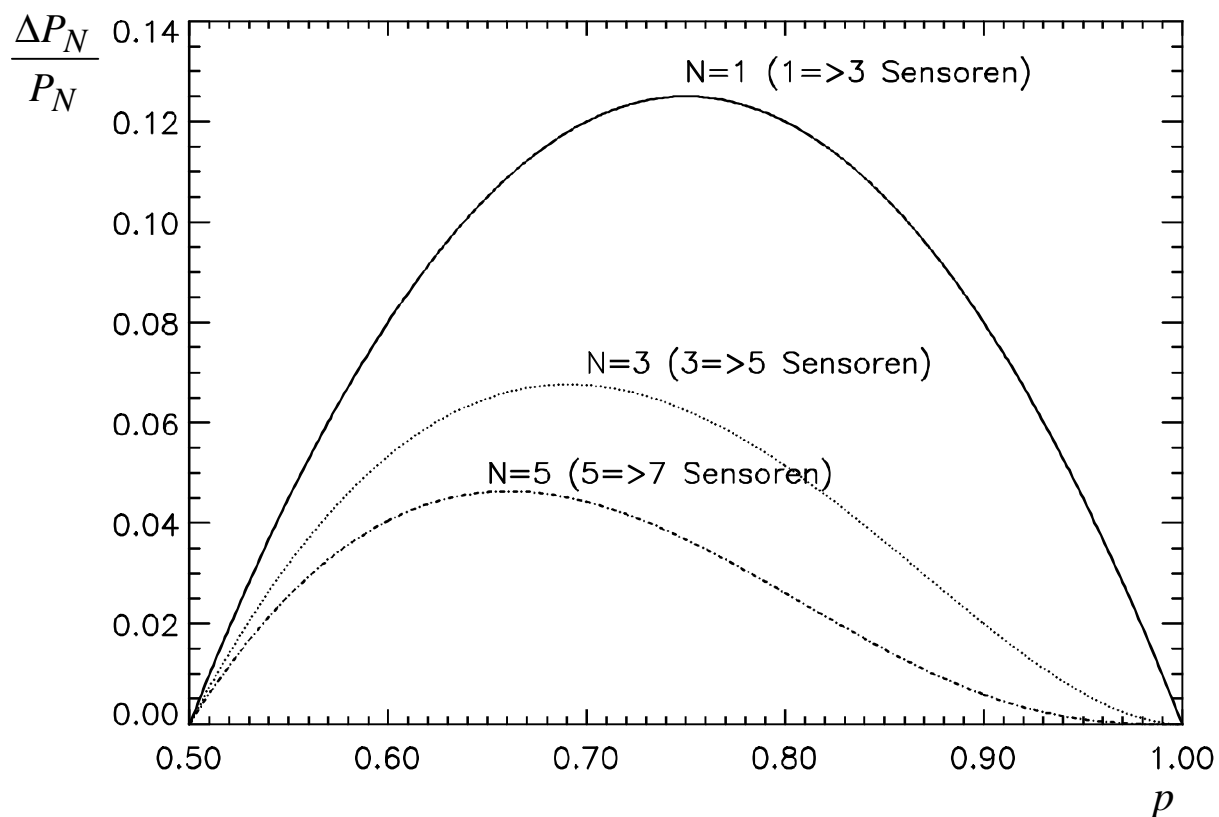


Bild 1.5: Marginaler Zuwachs an korrekter Klassifikation durch zusätzliche Sensoren [53]

Unter der Voraussetzung statistischer Unabhängigkeit der Sensoren und der Gleichheit der A-Priori-Wahrscheinlichkeiten zeigt Bild 1.5 die vergrößerte Wahrscheinlichkeit korrekter Inferenz, wenn die Anzahl der Sensoren von 5 auf 7 erhöht wird (untere Kurve), von 3 auf 5 Sensoren (mittlere Kurve) und von 1 auf 3 (obere Kurve).

Angenommen wird dabei ebenfalls, daß die Sensordaten entsprechend einer Mehrheitsentscheidung verknüpft werden. In Bild 1.5 wird auf der Abszisse die Wahrscheinlichkeit  $p$  für eine korrekte Zielklassifikation durch einen einzelnen Sensor, wobei identische Sensoren mit quadratischen Matrizen der A-Priori-Wahrscheinlichkeiten eines bestimmten Outputs für einen bestimmten Sensor angenommen sind, variiert und auf der Ordinate sind die resultierenden Werte für den folgenden Ausdruck aufgetragen [53, A.1]:

$$\frac{\Delta P_{MR}(A)}{P_{MR,N}(A)} = \frac{\left(\frac{N}{N+1}\right) \cdot [P(A) \cdot (1-P(A))]^{\frac{N+1}{2}} \cdot (2 \cdot P(A) - 1)}{\sum_{k=\frac{N+1}{2}}^N \binom{N}{k} \cdot P^k(A) \cdot (1-P(A))^{N-k}} \quad (1.1)$$

Dabei bezeichnet  $P_{MR,N}(A)$  die Wahrscheinlichkeit dafür, daß N Sensoren ein Ziel korrekt identifizieren werden.  $\Delta P_{MR}(A)$  quantifiziert die Änderung der Performanz der N Sensoren bei Hinzunahme von zwei weiteren Sensoren:

$$\Delta P_{MR}(A) = P_{MR,N+2}(A) - P_{MR,N}(A) \quad (1.2)$$

Die Ergebnisse von Nahin und Pokoski zeigen den quantitativen Nutzen der Multisensordatenfusion. Die Ergebnisse liefern auch einige konzeptionelle Regeln:

1. Die Kombination von Daten verschiedener ungenauer Sensoren (mit einer individuellen Wahrscheinlichkeit für korrekte Inferenz  $< 0.5$ ) ergibt keinen signifikanten Gesamtvorteil.
2. Die Kombination von Daten verschiedener hochgenauer Sensoren (mit einer individuellen Wahrscheinlichkeit für korrekte Klassifikation  $> 0.95$ ) ergibt keinen signifikanten Gesamtvorteil.
3. Wenn die Anzahl der Sensoren N groß wird (z.B.  $> 8$ ), ergibt sich wiederum kein signifikanter Gesamtvorteil durch die Hinzunahme weiterer identischer Sensoren.
4. Die größte Verbesserung durch die Datenfusion tritt für eine moderate Anzahl von Sensoren auf ( $N=1..7$ ).

## 1.7 Architekturkonzepte und -fragen

Die Transformation des in Kapitel 1.5 vorgestellten funktionalen Modells in ein reales System mit Computer-Hard- und -software erfordert einige Anstrengung und die Beantwortung mancher Fragen. Zur Implementierung wird die Entwicklung von Hilfsfunktionen wie Verwaltungsroutinen für die Datenbasen, Mensch-Maschine-Interfaces, Kommunikationssoftware und vieles anderes gebraucht. Der Anteil rein durch Software implementierter Fusionssysteme, der ganz konkret den speziellen Datenfusionsalgorithmen zuzuordnen ist, liegt weitgehend unter 20% der Gesamtsoftware.

Fusionsverarbeitung kommt nicht aus ohne Funktionen wie Kommunikation, Message-Bearbeitung, Datenbasisverwaltung, User-Interfaces und Sensor-Management. Kommunikationsfunktionen empfangen Daten von verteilten Sensoren und senden Steuerungssignale zurück an die Sensoren. Der Inhalt der transportierten Daten wird mit Message-Processing-Software bearbeitet, um spezielle Ereignisse zu detektieren, einen Systembenutzer über besondere Daten zu informieren und um Daten zu geeigneten Prozessen weiterzuleiten. Die Eingangsbearbeitung zerlegt die ankommenden Daten in Header, eigentliche Nachricht usw., extrahiert bestimmte Daten und archiviert sie in der Datenbasis. Die Ausgangsbearbeitung konstruiert Datenpakete für die nach außen gehende Kommunikation, verpackt die Nachrichten in die richtigen Datenformate.

Ein Datenbasis-Management ist eine weitere Hauptfunktion, die in einem implementierten System erforderlich ist. Eine Vielzahl von Dateien muß in einem Fusionssystem gepflegt werden. Dazu gehören die Sensordaten, die Sensormodelle, andere dynamische Modelle, Zustandsvektor- und Trajektoriendateien, Daten, die das Sensorumfeld repräsentieren (z.B. Terrainmodelle). Managementfunktionen sind z.B. speichern, auslesen, archivieren, Test auf Datenintegrität und Transformationen zwischen den diversen verwendeten Formaten. Die Verwaltung der Datenbasen ist für Fusionssysteme gerade deshalb so komplex, weil sowohl die Anzahl als auch die Art der Daten so vielfältig ist und auch die Datenrate als nicht gering anzusehen ist. Bei der Implementierung der Datenbasis-Software muß ein Kompromiß geschlossen werden zwischen effizienter Speicherung der Daten und schneller Archivierung gegen die Verwendung allgemeiner und komfortabler Datenbankabfragemöglichkeiten (Rapid Boolean Query). Wenn ein Expertensystem verwendet wird, muß die Datenbanksoftware außerdem die Wissensbasis verwalten.

Das User-Interface eines Fusionssystems ist ein weiterer Schlüsselbereich für eine gute Funktionalität. Anzeigen bestehen oft aus Karten, Overlays, die die Positionen von Sendern oder Plattformen und Umfelddaten anzeigen, speziellen graphischen Darstellungen usw. Moderne Interfaces verwenden eine Kombination von fensterorientierten Anzeigen, graphischen Overlays, Befehlsspracheneingabemöglichkeiten, Auswahlmenüs usw. Die Mensch-Maschine-Interfaces müssen flexible Anzeigemöglichkeiten anbieten, die dem Benutzer nur die Daten anzeigen, die er oder sie zu einer bestimmten Zeit benötigt. In diesem viel zu oft vernachlässigten Forschungsfeld ist noch eine Menge zu tun, gerade da die Informationen, die auf den Benutzer einströmen, immer vielfältiger werden und das Interface dem Benutzer, der häufig in einem stressigen Umfeld wichtige Entscheidungen treffen muß, helfen und ihn unterstützen und nicht noch weiter verwirren soll.

Maschine-Maschine-Schnittstellen stellen die Kommunikation mit und zu Steuerelementen sicher. Die zu steuernde Maschine führt Aufgaben aus, die sich als Konsequenz aus der Datenfusion ergeben.

Eine weitere Hauptunterstützungsfunktion ist das Sensormanagement. Dies zieht eine Anzahl von numerisch schwierigen Aufgaben nach sich wie die Prädiktion einer Beobachtung für jeden Sensortypus und jede Betrachtungseinheit in der Datenbasis. Basierend auf Sensormodellen und den differentiellen Bewegungsgleichungen [36] setzt das Management die Sensoren so ein, daß eine maximale Abdeckung der Aktivitäten bzw. Interessen gegeben ist. Diese Funktion dient auch als Monitor für den Status der Systemsensoren.

Neben der Identifikation der erforderlichen Support-Funktionen und der Etablierung geeigneter Modelle bzw. Ansätze verbleiben noch eine Reihe von Implementierungsfragen. Einige davon sind durchaus bekannt aus Projekten zur Implementierung anderer großer Hard- und Softwaresysteme: Externe Interfaces zu Realzeitsensoren oder Kommunikationsgeräten, schwierig zu erfüllende Anforderungen an Durchsatz und Antwortzeiten sowie an Verlässlichkeit und Pflegbarkeit. Einige spezifische Fragen betreffen die Auswahl von Algorithmen, die Auswahl geeigneter Fusionspunkte innerhalb der Prozesse usw.

Das Problem der Algorithmenauswahl hängt stark von der Art der durch das Datenfusionssystem gesuchten Inferenzen ab, der spezifischen Applikation und den verfügbaren Sensordaten. Die Algorithmen für ein System, das sich mit Bilddaten auseinanderzusetzen hat, sind z.B. gänzlich anders als diejenigen, die für ein System, dessen Eingangsdaten Identitätsdeklarationen sind, gebraucht werden.

Die in Kapitel 2 vorgestellte Kategorisierung gibt einen Überblick über anwendbare Algorithmen. Für eine gegebene Anwendung, eine Sensoranordnung und eine zu erstellende Inferenzhierarchie sind i.A. eine Anzahl konkurrierender Algorithmen zur Fusionsverarbeitung anwendbar. Einige Abstriche können dabei aufgrund der mathematischen Eigenheiten der Algorithmen und der Verfügbarkeit bzw. des Mangels an Verfügbarkeit von A-Priori-Information gemacht werden. Andere diesbezügliche Beschränkungen betreffen Durchsatzbetrachtungen, Rechnererfordernisse (z.B. Speicherausbau) von Algorithmen und Einsatzbeschränkungen. Allgemein kann ein strukturierter Prozeß für die Auswahl der Algorithmen, der auf vier separaten Perspektiven fußt, angewendet werden: ein Systemanalyse-Standpunkt, ein Einsatz-Standpunkt, ein mathematischer Standpunkt und ein Endanwender-Standpunkt. Nachdem die Auswahl der Algorithmen stattgefunden hat, ist zu bestimmen, wo im Prozeßfluß die Fusion auszuführen ist. Dabei sind drei grundsätzliche Ansätze zu unterscheiden, wobei Mischformen immer wieder auftreten:

1. Eine zentralisierte Architektur sendet die Sensorrohdaten zu einem zentralen Fusionsprozeß, der die Grundfunktionen wie Datenangleichung und -assoziation durchführt, gefolgt von Korrelation, dynamischer Estimation und Zielklassifikation.
2. Eine autonome Architektur ermöglicht jedem Sensor eine maximale Menge von Vorverarbeitung zur Generierung von Zustandsvektoren und Identitätsdeklarationen, die dann zu einem Fusionsprozeß übermittelt werden. Hierbei werden die Grundfunktionen auf Zustandsvektoren angewendet und nicht auf Rohdaten.
3. Eine dritte Variante ist eine Hybrid-Kombination der zentralisierten und der autonomen Architekturen.

Faktoren, die eine Architekturauswahl zulassen, sind die Verfügbarkeit intelligenter Systeme zur Datenvorverarbeitung, die Verfügbarkeit von Kommunikationsverbindungen, die die Übertragung großer Datenmengen zu einem Prozessor erlauben und die Möglichkeiten des Prozessors in Bezug auf Rechenleistung usw.

Ein letzter fundamentaler Implementierungsaspekt betrifft die Rolle des Anwenders. Zu entscheiden ist, inwieweit das Fusionssystem autonom sein soll bzw. kann. Für ein Tracking-System z.B. würde ein vollkommen autonomes System alle Aufgaben selbständig ausführen: Zuordnung von Beobachtungen zu Zieltrajektorien, Schätzung von Objektlokationen und -geschwindigkeiten usw.

Ein System, das menschliche Eingaben und Reaktionen erfordert, kann per definitionem nicht in dem Maße automatisiert sein wie ein autonomes System. Für höherwertige Inferenz-



Systeme wie ein medizinisches Diagnosesystem ist z.B. zu bestimmen, ob das System beratend oder tatsächlich diagnostisch tätig sein soll. Das operationelle Konzept eines Datenfusionssystems bestimmt das Design und die Implementierung entscheidend.

## 2. Algorithmen zur Multisensordatenfusion

### 2.1 Überblick

In Kapitel 1 wurde ein Konzept zur Multisensordatenfusion zusammen mit einem funktionalen Modell vorgestellt, das die Datenfusionsfunktionen in drei grundlegende Prozeßebenen aufteilte.

„Level 1“-Verarbeitung akzeptiert Sensordaten und verknüpft diese, um Zustände (z.B. Ort, Identität) grundlegender Betrachtungselemente zu schätzen. Für militärisch nutzbare Fusionsysteme werden die Ergebnisse der „Level 1“-Prozessierung als „Order of Battle“-Datenbasis bezeichnet, die geschätzten Ort, Identität und beobachtete Charakteristika von Betrachtungselementen wie Plattformen (Panzer, Schiffe, Flugzeuge), Sender wie Radar und Kommunikationssysteme und geographisch kompakte militärische Einheiten umfaßt. Für andere Anwendungen bestehen die Ergebnisse der „Level 1“-Verarbeitung aus Ort und Identität lokaler interessierender Phänomene (z.B. Hardware-Fehler, Hindernisse für robotische Manöver usw.).

Die „Level 2“-Verarbeitung bearbeitet die Ergebnisse der „Level 1“-Prozessierung, um Situationsanalysen durchzuführen. Basierend auf räumlichen, zeitlichen und situationsbezogenen Analysen der „Level 1“-Ergebnisse werden dabei Inferenzen gesucht.

Die „Level 3“-Verarbeitung schließlich führt für militärische Arten von Fusionssystemen Bedrohungsanalysen durch.

Kapitel 1 beschreibt die Funktionen und Prozesse der Datenfusion, stellt aber keine spezifischen Algorithmen oder Techniken zur Bearbeitung dieser allgemeinen Prozesse vor.

Das folgende Kapitel gibt einen Überblick über die für die Fusionsverarbeitung anwendbaren Arten von Algorithmen. Hall und Llinas [26] haben in einer Studie 30 Datenfusionssysteme untersucht und dabei mehr als 75 gebräuchliche Algorithmen identifiziert.

Die hier vorgestellte Charakterisierung definiert konzeptionelle Kategorien, in die die spezifischen Techniken eingruppiert werden. Eine solche Einteilung muß eher konzeptionell als streng mathematisch sein, da die identifizierten Techniken sowohl rein mathematische Algorithmen (wie statistische Estimation) als auch heuristische Methoden (wie Expertensysteme) beinhalten. Einen Überblick über die vorgeschlagene Gruppierung für die „Level 1“-Prozessierung zeigt Bild 2.1.

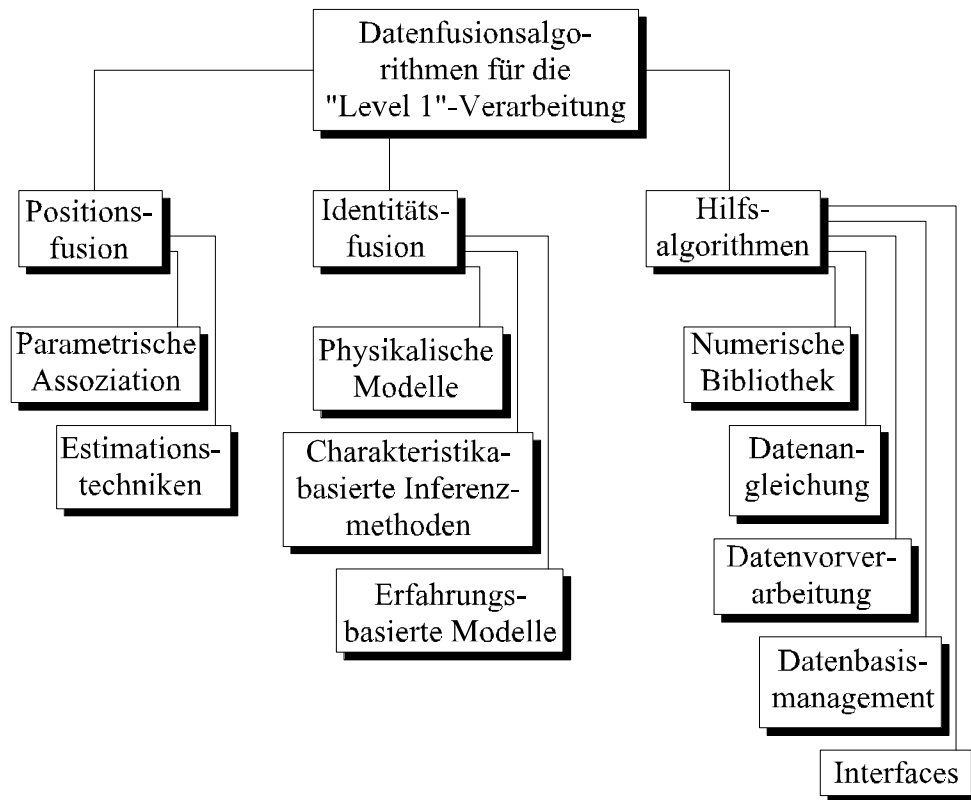


Bild 2.1: Überblick zur Kategorisierung der „Level 1“-Prozessierung

Es werden drei Kategorien identifiziert:

1. Techniken zur Positionsfusion,
2. Methoden zur Identitätsfusion und
3. Hilfs- und Unterstützungsalgorithmen.

Diese Techniken sind logisch klar abgetrennt dargestellt. In einem implementierten System sind sie jedoch integriert.

Die erste Kategorie von Algorithmen zur Positionsfusion kombiniert parametrische Daten von verschiedenen Sensoren, um einen möglichst korrekten Schätzwert für Position und Geschwindigkeit einer Betrachtungseinheit zu erlangen. Die dafür verwendeten Eingangsdaten bestehen aus Beobachtungen der verschiedenen Sensoren wie Range-Abstand, Radialgeschwindigkeit, Azimut, Höhe oder Bildkoordinaten (von bildgebenden Sensoren).

Positionsfusionsalgorithmen assoziieren zunächst Beobachtungen zu Beobachtungsgruppen, die zur gleichen dynamischen Betrachtungseinheit gehören. Diese Assoziationen geschehen mit Hilfe von parametrischen Assoziationsalgorithmen.

In einem nächsten Schritt verknüpfen Estimationsmethoden wie Kalman-Filter oder Batch-Estimation die Daten zu einem Schätzwert von Position und Geschwindigkeit der Betrachtungseinheit.

Die zweite in Bild 2.1 dargestellte Kategorie, die Identitätsfusion, kombiniert die Sensordaten zur Etablierung der Identität von Objekten. Identitätsalgorithmen werden in Unterkategorien unterteilt, die physikalische Modelle, Charakteristika-basierte Klassifikation und erfahrungsbasierte Modelle umfassen, die emulieren, wie ein Mensch die Identität einer Betrachtungseinheit zu erkennen versuchen würde.

Während Positionsfusionsalgorithmen i.A. statistisch basiert sind, tendieren die Methoden, die zur Kombination von Identitätsdaten verwendet werden, in eine nichtparametrische oder heuristische Richtung.

Die dritte in Bild 2.1 dargestellte Kategorie von Algorithmen behandelt die Hilfstechniken, die zur Unterstützung der „Level 1“-Prozessierung erforderlich sind. Dabei handelt es sich um allgemeine numerische Methoden, Datenangleichungsroutinen, Datenvorverarbeitungstechniken, Datenbasis-Managementfunktionen und Mensch-Maschine-Interface-Prozeduren.

## 2.2 Positionelle Fusionsalgorithmen

Die Entwicklung von Methoden zur positionellen Fusion und Estimation reicht weit zurück. 1795 fand Gauß unabhängig von Legendre die „Least Squares“-Methode und damit eine Lösung für das Problem, durch Kombination diverser Beobachtungswerte den besten Schätzwert orbitaler Parameter von Asteroiden zu erhalten. Die Arbeit von Fisher um 1912 etablierte ein statistisches Fundament für die Estimation und führte zur „Maximum Likelihood“-Methode. In den vierziger Jahren des 20-ten Jahrhunderts entwickelten Kolmogorov (1941) und Wiener (1942) unabhängig voneinander eine lineare „Minimum Mean Square“-Estimation und schufen damit die Basis für die spätere Entwicklung der Kalman-Filter-Theorie. Mitte der sechziger Jahre des 20-ten Jahrhunderts entwickelte Kalman das Kalman-Filter zur sequentiellen Verarbeitung diskreter Daten [21, 31-32, 35, 44-46, 50, 66].

Die positionelle Fusion verwendet eine Kombination physikalischer Modelle (z.B. differentielle Bewegungsgleichungen und Beobachtungsmodelle) und statistischer Annahmen über Rauschprozesse von Beobachtungen, um beobachtete Daten durch Zustandsvektoren abzubilden.

Der Ausdruck Zustandsvektor beschreibt eine Menge von Variablen z.B. für Ort und Geschwindigkeit, die es - wenn bekannt - erlauben, das zukünftige Verhalten einer Betrachtungseinheit einigermaßen korrekt zu projizieren. Der Zustand eines Systems bzw. einer Betrachtungseinheit zu jeder Zeit  $t$  wird durch eine minimale Menge von Werten  $x_1(t), \dots, x_n(t)$  repräsentiert, die zusammen mit den Eingangswerten des Systems für alle Zeiten  $t, t > t$ , genügen, das Verhalten des Systems für alle  $t \geq t$  zu beschreiben. Positionsfusionsalgorithmen ermöglichen einen Schätzwert des Zustandsvektors, der den beobachteten Daten mathematisch optimal entspricht. Basierend auf den Differenzen zwischen den tatsächlichen (beobachteten) Daten und den geschätzten Beobachtungen (gestützt auf den augenblicklichen Schätzwert des Zustandsvektors und assoziierten Sensorbeobachtungsgleichungen) verfeinern bzw. korrigieren diese Algorithmen den Zustandsvektor inkremental. Die verschiedenen Sensordaten werden durch die Verwendung physikalischer Beobachtungsmodelle für jeden Sensor getrennt verarbeitet. Mit den Schätzwerten als Basis ermöglichen diese Beobachtungsmodelle die Prädiktion der Beobachtungen der spezifischen Sensoren.

Das Konzept der positionellen Fusion ist in Bild 2.2 dargestellt. Mehrere verschiedene Sensoren beobachten mehrere verschiedene dynamische Objekte. Die Sensoren liefern parametrische

Daten wie Winkelinformationen (z.B. Azimut, Höhe, Bildkoordinaten), Rangeabstand oder Radialgeschwindigkeit. In den Daten enthaltene Informationen beschreiben parametrische Vektoren, Bilder oder tatsächliche Zustandsvektoren der beobachteten Plattformen (Schätzwerte der dreidimensionalen Position und Geschwindigkeit).

Die beobachteten Objekte können stationär sein wie Betrachtungseinheiten, die relativ zur Oberfläche stillstehen oder nichtstationär wie sich schnell bewegende Flugzeuge oder Raketen. Die Sensordaten werden im Fusionssystem zur Datenangleichung vorverarbeitet. Die Vorverarbeitung transformiert die ankommenden Sensordaten häufig, aber nicht notwendigerweise in ein gemeinsames Referenzsystem, wobei das Referenzsystem i.A. nur aus einer Referenzierung z.B. bzgl. eines gemeinsamen Zeitrahmens besteht. Dies geschieht über Koordinatentransformation und Einheitenumrechnungen. Danach werden parametrische Assoziation und Zustandsvektorschätzung durchgeführt.

### 2.2.1 Parametrische Assoziation

Parametrische Assoziation stellt Verbindungen zwischen Beobachtungen mehrerer, aber auch einzelner Sensoren und Plattformen oder Betrachtungselementen her. In einer realen Umgebung wird ein Sensor während einer bestimmten Zeitspanne mehrere verschiedene Ziele beobachten. Es muß nun sichergestellt werden, daß die Beobachtungen zusammengefaßt werden, die zu einer bestimmten physikalischen Gegebenheit, d.h. einem Flugzeug, Schiff, Sender usw. gehören. Assoziation geschieht dadurch, daß ein Assoziationsmaß definiert wird, das die Ähnlichkeit zwischen Beobachtungspaaren quantifiziert. Übliche Maße sind Korrelationskoeffizienten, Abstandsmaße, Assoziationskoeffizienten oder auf statistischer Ähnlichkeit beruhende Maße.

Parametrische Assoziation versucht, die Beziehung zwischen Beobachtungspaaren zu bestimmen, d.h. zu bestimmen, ob in Bild 2.2 zwischen  $\underline{y}_{1i}$  (die i-te Beobachtung von Sensor 1) und  $\underline{y}_{2j}$  (die j-te Beobachtung von Sensor 2) eine Verbindung besteht. Dazu müssen zwei Fragen beantwortet werden:

1. Wenn die Sensoren 1 und 2 unterschiedliche Arten von Daten beobachten, müssen einige Transformationen durchgeführt werden, um die physikalische Nähe von  $\underline{y}_{1i}$  und  $\underline{y}_{2j}$  zu bestimmen.

2. Wenn die Beobachtung  $\underline{y}_{1i}$  zu einer anderen Zeit ausgeführt wurde als  $\underline{y}_{2j}$  (d.h.  $t_i \neq t_j$ ), dann müssen die Beobachtungen über die Bewegungsgleichungen synchronisiert werden.

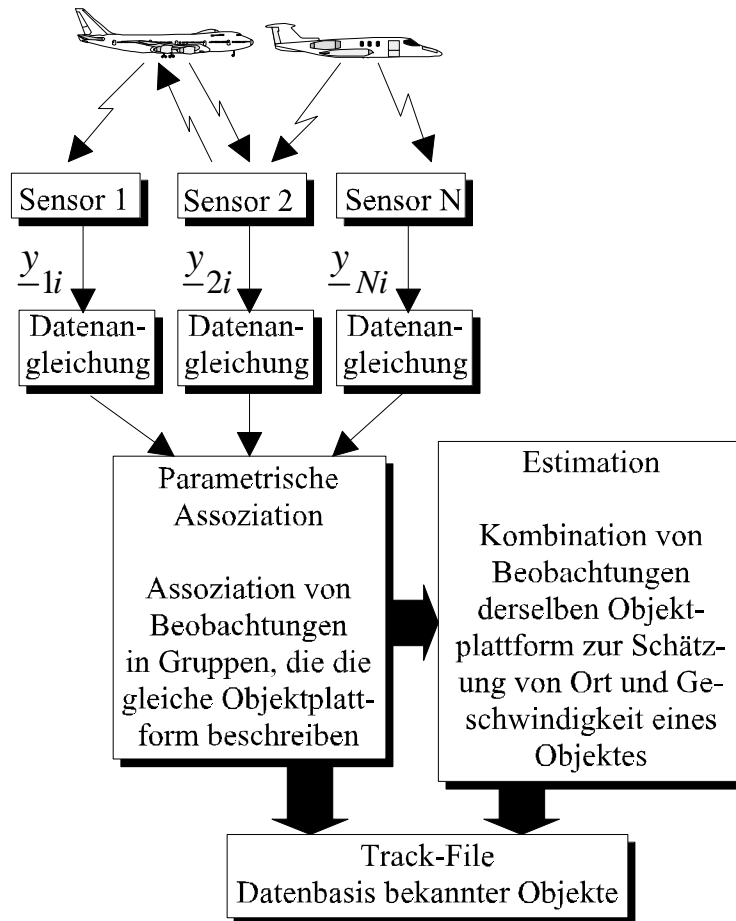


Bild 2.2: Konzept der positionellen Fusion

Wenn die Beobachtung  $\underline{y}_{1i}$  zu einer anderen Zeit ausgeführt wurde als  $\underline{y}_{2j}$ , d.h.  $t_i \neq t_j$ , dann müssen die Beobachtungen durch Bewegungsgleichungen synchronisiert werden, die die Fortschreibung einer Beobachtung zu einer Zeit  $t_i$  zu einer folgenden Zeit  $t_j$  erlauben. Eine solche Beobachtungsfortschreibung basiert auf einem angenommenen dynamischen Modell. Entsprechende Transformationen und Synchronisationen hängen von den verwendeten Sensoren und der Dynamik der beobachteten Objekte ab.

Ein weiteres Ziel der parametrischen Assoziation ist die Verknüpfung der Sensorbeobachtungen  $\underline{y}_{1i}$  mit existierenden Tracks im Track-File bekannter Objekte. Für diesen Fall erfordert der Assoziationsprozeß, daß für jeden bekannten Track  $\underline{x}_k(t)$  in der Datenbasis der aktuelle

Track mit dynamischen Modellen auf die Zeit  $t_i$  der Beobachtung  $\underline{y}_{1i}$  aktualisiert wird. D.h. es wird ein Beobachtungsmodell benutzt, das es erlaubt, eine Beobachtung vorherzusagen, die für Objekt  $k$  durch Sensor 1 beobachtet würde, wenn das Objekt tatsächlich zur Zeit  $t_i$  im Sichtfeld des Sensors wäre. Systemtheoretisch wird dieser Fall durch die Gleichung:

$$\underline{y}_{1, \text{Predicted}}(t_i) = \underline{g}[\underline{x}_k(t_i)] + \underline{n} \quad (2.1)$$

erfaßt. Dabei repräsentiert  $\underline{g}$  ein Beobachtungsmodell, das üblicherweise mehrere Koordinatentransformationen umfaßt und  $\underline{n}$  i.A. unbekanntes Beobachtungsrauschen.

In diesem Fall vergleicht ein Assoziationsmaß die tatsächliche Beobachtung  $\underline{y}_1$  mit der vorhergesagten Beobachtung  $\underline{y}_{1, \text{Predicted}}$ .

Nach der Berechnung eines Assoziationsmaßes zur Bestimmung der Verbindung zwischen zwei Beobachtungen müssen spezielle Assoziationsstrategien bzw. -logiken angewendet werden, um zu bestimmen, ob zwei Beobachtungen als tatsächlich zueinandergehörig zu bezeichnen sind oder nicht. Gating-Techniken setzen Grenzwerte zu einer ersten Bestimmung, ob zwei Beobachtungen physikalisch verbunden sind. Sie reduzieren die Kombinationen von Beobachtungspaaren, die als potentiell zur gleichen Betrachtungseinheit gehörend berücksichtigt werden müssen.

Zuordnungstechniken werden dann zur endgültigen Korrelation von Beobachtungen zu Beobachtungen oder Beobachtungen zu Tracks verwendet. Die einfachste Technik (Nearest Neighbour) ordnet eine Beobachtung einfach ihrer nächstgelegenen Beobachtung zu. Die Distanz ist dabei durch das Assoziationsmaß gegeben.

Um in der Darstellung von Bild 2.2 zu bleiben, kann dies z.B. bedeuten, daß die  $i$ -te Beobachtung von Sensor 1,  $\underline{y}_{1i}$ , zu Objekt 2 zugeordnet wird bzw. als zu Objekt 2 zugehörig bzw. als von diesem herrührend bezeichnet wird, wenn die berechnete Distanz des Assoziationsmaßes dies nahelegt, also z.B. kleiner ist als die Distanz des Assoziationsmaßes zu Objekt 1, obwohl die Beobachtung tatsächlich von Sensor 1 herrührt und nicht von Sensor 2.

Der K-Nearest-Neighbour-Ansatz [20] bezeichnet eine nichtparametrische statistische Estimationstechnik, bei der ein Schätzwert der Verteilungsdichtefunktion jeder Beobachtungsklasse dazu benutzt wird, eine Klassifikationsentscheidung für eine Beobachtung herbeizuführen. An-



genommen sei z.B., daß der Euklidische Abstand zwischen der Beobachtung  $\underline{y}$  und jedem von  $N$  Werten einer Verteilung berechnet wurde. Daraufhin wird eine „angemessene“ Anzahl von Nachbarwerten  $K$  ausgewählt. Aus diesem Satz von  $K$  nächsten Nachbarwerten zu  $\underline{y}$  innerhalb der Verteilung wird nun die Distanz  $r$  zwischen  $\underline{y}$  und seinem weitest entfernten Nachbarwert berechnet.  $\underline{y}$  wird der Klasse zugeordnet, zu der die meisten der  $K$  nächsten Nachbarwerte gehören. Der Wert von  $K$ , der die besten Resultate ergibt, kann nicht einfach berechnet werden, wenn die Größe der Stichprobe bzw. des Wertevorrates nicht signifikant ist, aber er kann durch Versuche annähernd bestimmt werden.

Andere Methoden prüfen gleichzeitig die Gültigkeit mehrerer Hypothesen.

### 2.2.2 Estimationstechniken

Sobald die Beobachtungen in Gruppen verteilt worden sind, die mit separaten dynamischen Betrachtungseinheiten bzw. Plattformen assoziiert sind, werden Estimationstechniken angewendet, um die Daten zu verknüpfen bzw. um sie einem Fusionsprozeß zu unterwerfen. Die Estimation bestimmt den Wert eines Zustandsvektors (z.B. Position und Geschwindigkeit), der am besten zu den Daten paßt. Z.B. versucht die „Least Squares“-Methode, den Wert eines (unbekannten) Zustandsvektors  $\underline{x}$  zu finden, der die aufsummierte und quadrierte Differenz zwischen den tatsächlichen und den geschätzten Beobachtungen minimiert. Genauer gesagt wird eine Funktion definiert, die ein Maß der Paßgenauigkeit angibt. Für die „Least Squares“-Methode wird eine skalare Größe  $l(\underline{x})$  definiert:

$$l(\underline{x}) = \left[ \underline{y}_i - \underline{y}_{i, \text{Predicted}}(\underline{x}) \right]^T \cdot \left[ \underline{y}_i - \underline{y}_{i, \text{Predicted}}(\underline{x}) \right] \quad (2.2)$$

die die Summe der Quadrate der Residuen minimiert [44]. Die geschätzten Beobachtungen sind entsprechend Gl. (2.1) eine Funktion des unbekanntem Zustandsvektors  $\underline{x}$ . Zu den Funktionen, die definiert werden können, zählen „Least Squares“- , „Weighted Least Squares“- , „Likelihood“-Funktionen und Bayes'sche Formulierungen.

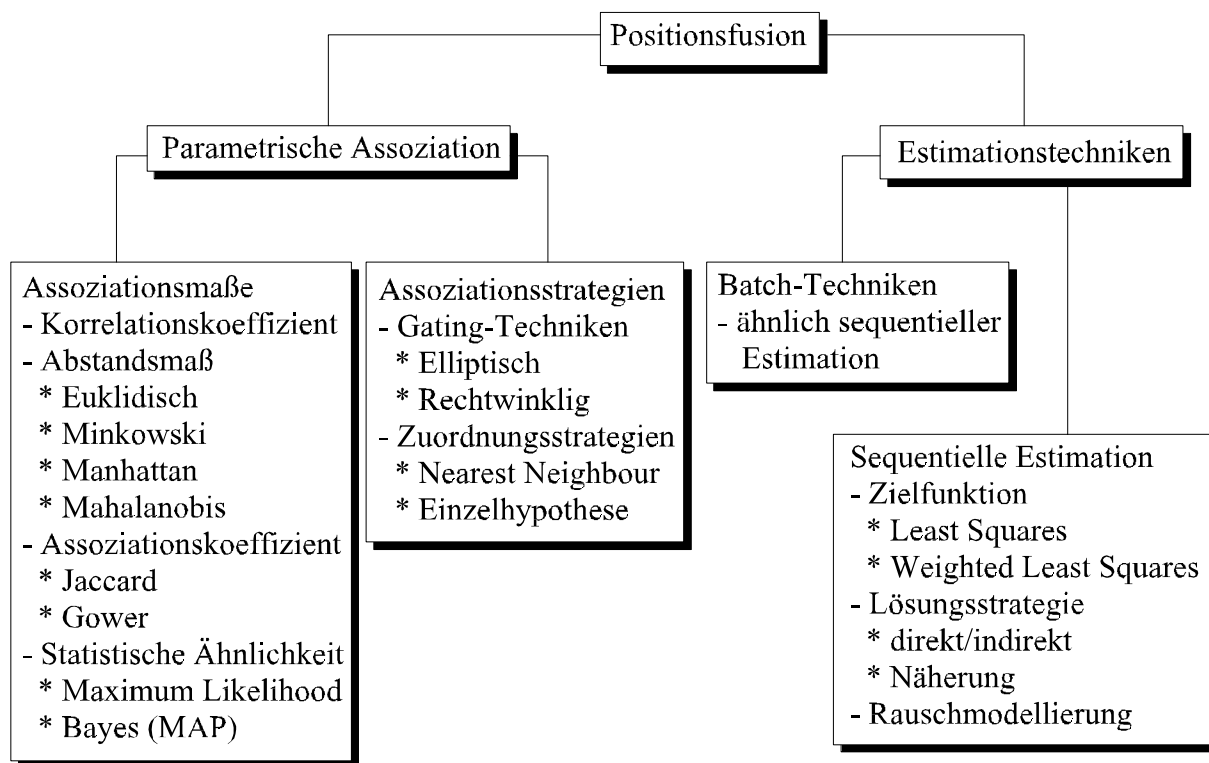


Bild 2.3: Kategorisierung der Positionsfusionsalgorithmen

Um das Estimationsproblem zu lösen, muß der Zustandsvektor  $\underline{x}$  systematisch variiert werden. Dadurch können die Bedingungen der Zielfunktion erfüllt werden. Dazu können zwei Strategien verfolgt werden: Die gleichzeitige Bearbeitung aller Daten in einem Batch-Modus oder die sequentielle Verarbeitung, die den Schätzwert des Zustandsvektors mit jeder neu hinzukommenden Beobachtung ändert. Zu den bewährten sequentiellen Estimationstechniken gehören Kalman- und „Extended Kalman“-Filteralgorithmen [2, 45, 50]. Die Auswahl einer Zielfunktion, die Strategie zur Lösung dieser Funktion und die Art der Rauschmodellierung (Beobachtungs- und Prozeßrauschen) sind grundsätzliche Design-Kriterien bei Estimationsproblemen.

Die Bewertung dieser Alternativen hängt von der speziellen Fusionsapplikation und den verfügbaren Rechnerressourcen ab. Ergebnis der Kombination von Assoziations- und Estimationsverarbeitung sind Daten, die Ort und Geschwindigkeit dynamischer Betrachtungseinheiten korrekt bestimmen. Die Alternativen sind in der Kategorisierung in Bild 2.3 dargestellt.

## 2.3 Identitätsfusionsalgorithmen

Das Problem der Identitätsfusion besteht in der Verknüpfung von Identitätsdeklarationen verschiedener Sensoren zu einem gemeinsamen Schätzwert der Identität. Das Konzept der Identitätsfusion ist in Bild 2.4 veranschaulicht.

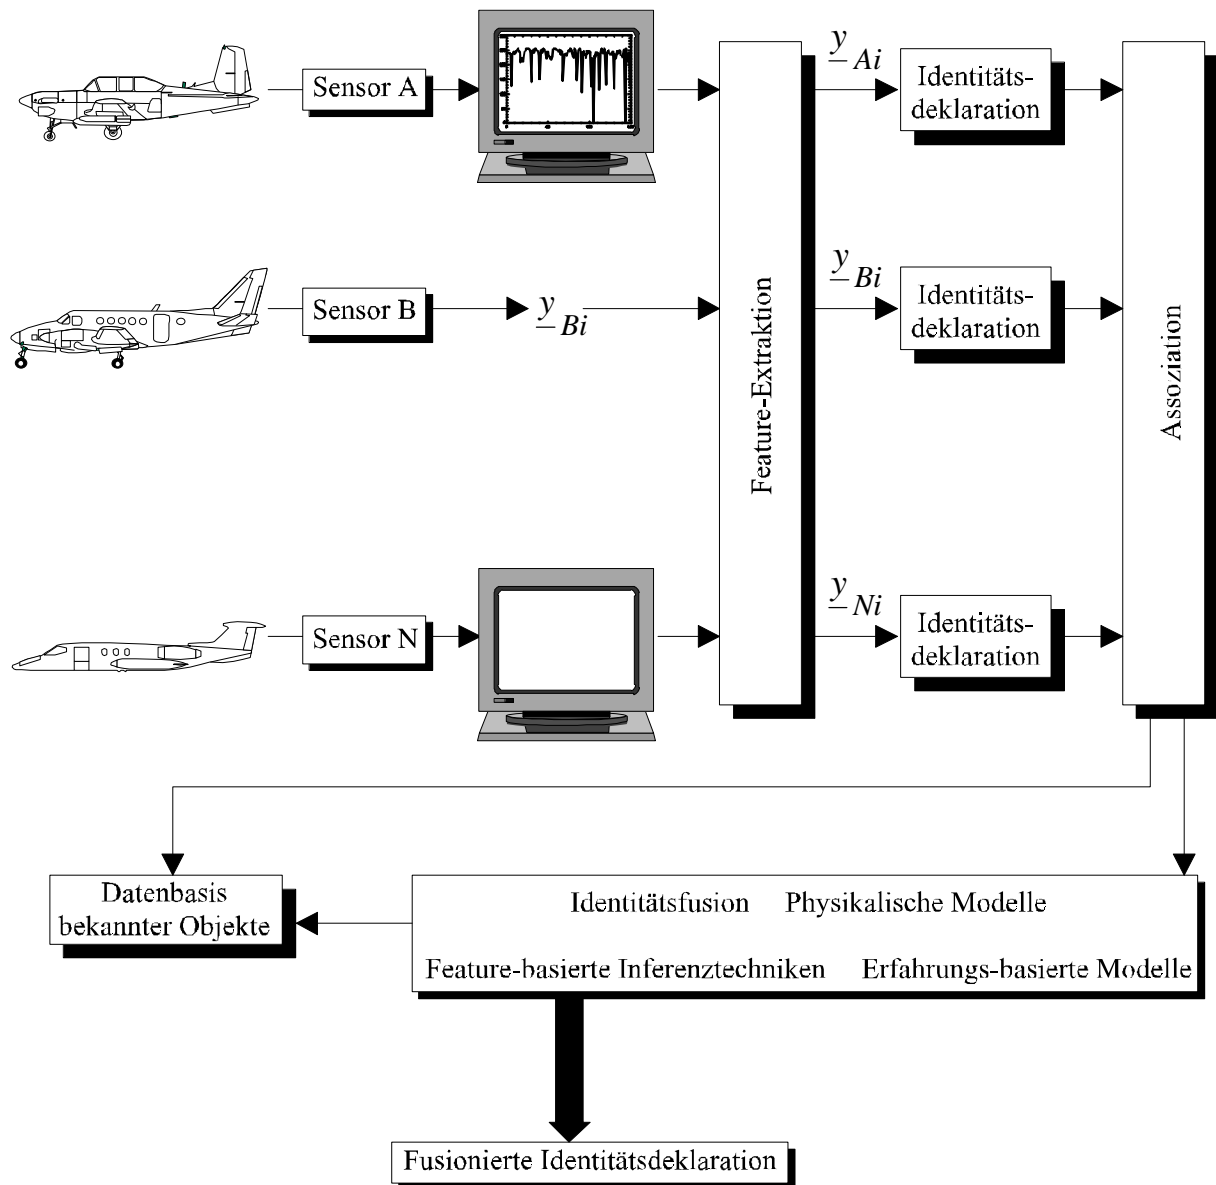


Bild 2.4: Identitätsfusion

Das Bild zeigt die Datenaufnahme  $N$  verschiedener Sensoren. Beispielsweise könnte es sich bei den Daten um RCS-Daten, eine Folge von Impulsen oder Bilddaten handeln. Die Sensoren können aktiv oder passiv diskrete oder kontinuierliche Daten als Funktion der Zeit, einen Aus-

gabevektor, Bilddaten oder Identitätsdeklarationen liefern. Diese Daten können durch eine oder mehrere Transformationen so vorverarbeitet werden, daß ein Feature-Vektor  $\underline{y}_i$  aus ihnen extrahiert werden kann, der die beobachteten Daten repräsentiert. Beispiele für Feature-Extraktionstransformationen sind Sampling-Funktionen, FFT- und Bildverarbeitungsalgorithmen zur Mustererkennung (z.B. Kanten-Detektoren, Segmentierungsalgorithmen und Mustererkenner).

Nach der Extraktion einer Feature-Gruppe bzw. eines Feature-Vektors  $\underline{y}_i$  kann eine Identitätsdeklaration durch einen Mustererkennungsprozeß geführt werden. Techniken wie Cluster-Algorithmen, adaptive neuronale Netzwerke oder andere statistische Mustererkennungsmethoden können dazu verwendet werden, von einem Feature-Vektor  $\underline{y}_i$  zu einer Identitätsdeklaration eines beobachteten Objekts zu transformieren. Wie bei dem Problem des Assoziationsprozesses bei der Positionsfusion müssen diese Identitätsdeklarationen in Gruppen, die die zum gleichen beobachteten Objekt gehörenden Beobachtungen repräsentieren, partitioniert werden. Das Identitätsfusionskonzept in Bild 2.4 deutet die Fusion von Identitätsdeklarationen an. Dies ist analog zur Fusion von Zustandsvektoren bei der Positionsfusion zu sehen. Alternativ dazu könnte die Identitätsfusion auch auf der Rohdatenebene stattfinden (vor der Feature-Extraktion), auf der Feature-Vektor-Ebene (vor der Identitätsdeklaration) oder auf der Entscheidungsebene (nachdem jeder Sensor eine unabhängige Identitätsdeklaration abgegeben hat). Die Auswahl, wann die Fusion durchzuführen ist, hängt von der Art der verfügbaren Sensordaten und den unterschiedlichen von den Sensoren ausgeführten Vorverarbeitungsschritten ab.

Eine weitere Vereinfachung in Bild 2.4 ist die Annahme, daß die Aufgabe des Systems nur aus der Identitätsfusion besteht. In der Praxis können Positions- und Identitätsfusion zusammen bzw. gemischt auftreten.

Konzeptionell könnte die Identitätsfusion in gleicher Weise wie die Positionsfusion ausgeführt werden. Einige typische Schwierigkeiten verhindern jedoch einen solchen Ansatz: Zunächst sind physikalische Modelle für die Identitätsdeklaration i.A. nicht verfügbar oder nur mit großem Aufwand zu entwickeln. Eine zweite Schwierigkeit besteht in der Tatsache, daß Identität i.A. hierarchisch ist. Auf der untersten Inferenzebene können die zu identifizierenden Objekte aus einzelnen Sendern (Radar, Radio, Beacon-Signale) oder physikalischen Betrachtungseinheiten (z.B. Motor eines Flugzeugs) bestehen. Auf höheren Inferenzebenen jedoch sind die Objekte

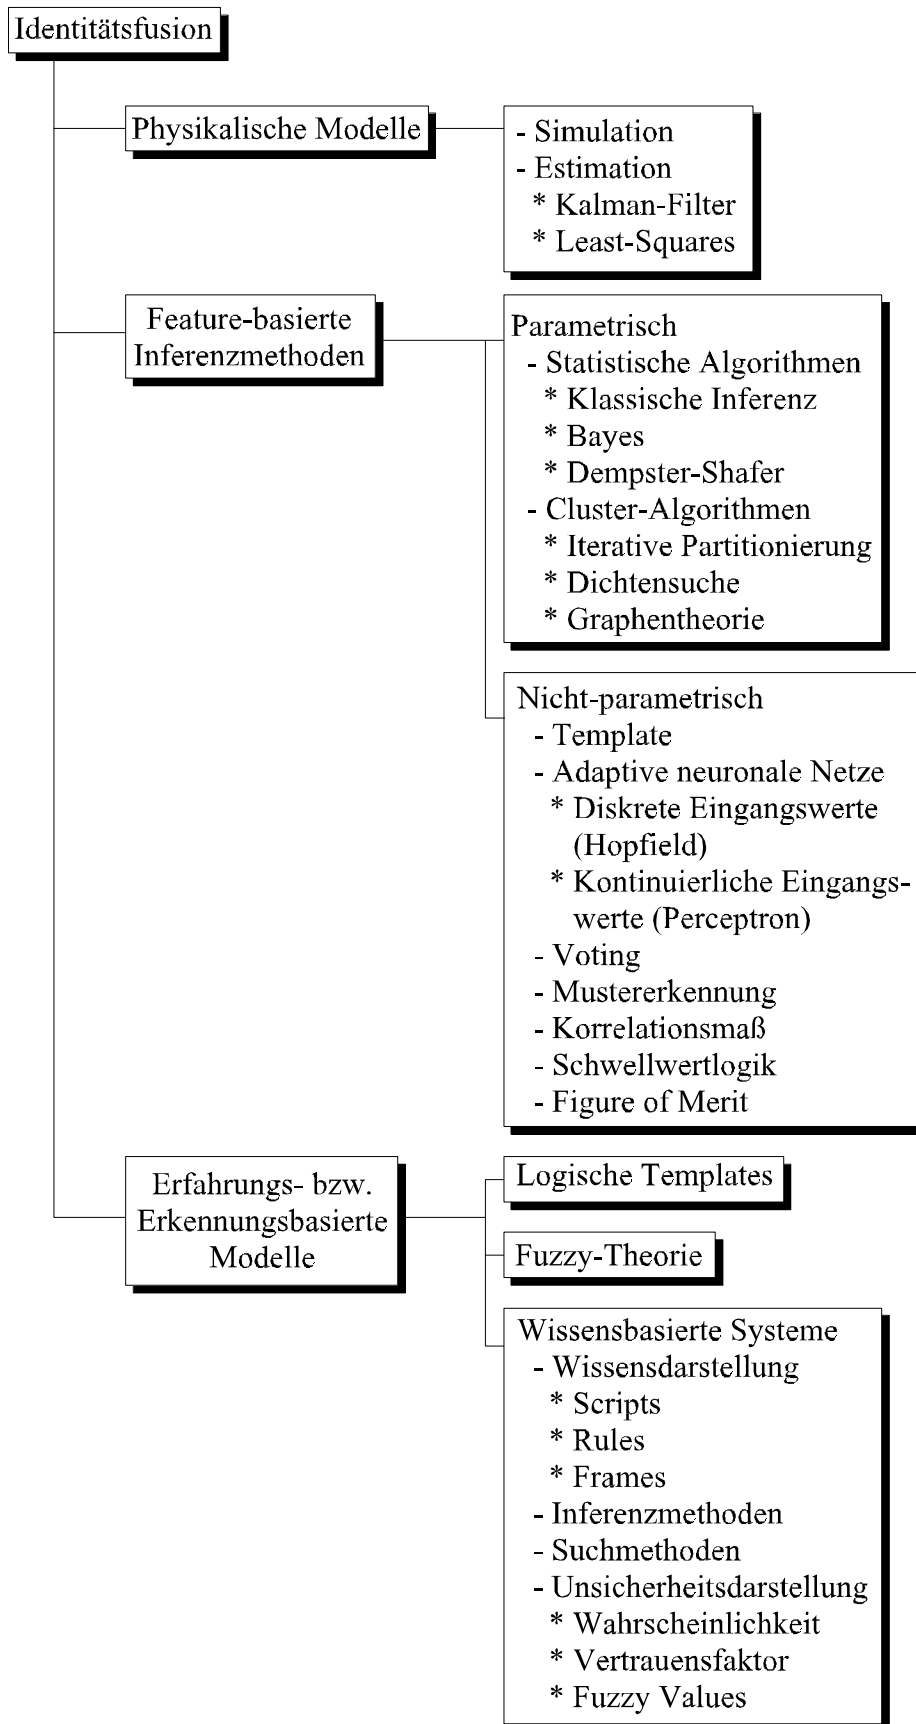


Bild 2.5: Kategorisierung von Identitätsfusionsalgorithmen

jedoch i.A. abstrakter. Identität kann komplexe Beziehungen zwischen mehreren verschiedenen Komponenten implizieren. Präzise Kategorien von Algorithmen zur Identitätsfusion existieren nicht. Ein Vergleich der Methoden in diesem Umfeld (Klassische Inferenz, Bayes, Templating, Voting, Adaptive neuronale Netzwerke) bzw. eine Kategorisierung der Algorithmen kann nur willkürlich sein. Details der Techniken sind in [44] zu finden.

In der konzeptionellen Einteilung in Bild 2.5 sind drei Hauptkategorien gezeigt:

1. Physikalische Modelle,
2. Feature-basierte Inferenztechniken und
3. Erfahrungs- bzw. Erkennungs-basierte Modelle.

Physikalische Modelle versuchen, die vom Sensor beobachteten Daten möglichst genau zu modellieren und die Identität durch den Vergleich modellierter Beobachtungen mit realen Daten zu schätzen. Zu diesen Techniken gehören Simulation und Estimationsmethoden wie Kalman-Filter. Obwohl es, wie oben erwähnt, schwierig ist, Identität zu modellieren, ist es doch konzeptionell möglich und erlaubt so die Verwendung klassischer Estimationstechniken, wobei der Estimationsprozeß dann vollkommen analog zu dem in der Positionsfusion verläuft.

Die Feature-basierten Inferenztechniken treffen die Identitätsaussagen auf Grundlage von Identitätsdaten ohne die Verwendung physikalischer Modelle. Zwischen Identitätsdaten und -aussagen wird eine unmittelbare Abbildung durchgeführt. Diese Techniken können in zwei weitgefaßte Kategorien unterteilt werden:

1. Parametrische (oder statistische) Techniken, die A-Priori-Annahmen über die statistischen Eigenheiten (z.B. Verteilungen) der Identitätsdaten erfordern, und
2. Nicht-parametrische Techniken, die keine A-Priori-Informationen brauchen.

Zur ersten Kategorie gehören klassische und Bayes'sche Inferenz, die Dempster-Shafer-Methode und Cluster-Routinen. Nichtparametrische Techniken sind z.B. Templating, Voting, adaptive neuronale Netze und Entropie-Methoden.

Erfahrungs- bzw. Erkennungs-basierte Modelle bilden die dritte Hauptkategorie, in die Identitätsfusionsalgorithmen einzuordnen sind. Diese Methoden simulieren den Inferenzprozeß, der einen Menschen Identität erkennen läßt. Zu dieser Kategorie gehörende Techniken sind, wie in Bild 2.5 gezeigt, logische Templates, Expertensysteme und Fuzzy-Techniken.

## 2.4 Hilfs- und Unterstützungsalgorithmen

Neben den Algorithmen zur Positions- und Identitätsfusion sind einige weitere Funktionen notwendig zur Unterstützung der „Level 1“-Verarbeitung. Dazu gehören eine Bibliothek grundlegender numerischer Methoden, Datenangleichungsalgorithmen, Datenvorverarbeitung, Datenbasiemanagement und Mensch-Maschine-Interfaces. In einem operationellen Datenfusionssystem machen diese in Bild 2.6 zusammengefaßten Funktionen den weitaus größten Teil der Gesamtsoftware aus.

Datenangleichung bezieht sich auf Funktionen, die genutzt werden, um beobachtete Sensordaten (z.B. Rangeabstand, Azimut, Elevation) in ein gemeinsames im Datenfusionssystem verwendetes Koordinatensystem zu transformieren. Der für jeden Sensor spezifische Datenangleichungsprozeß ist rechenintensiv. Neben den erforderlichen Transformationen können bei diesem Schritt auch Sensorkalibrierung und Bias-Unterdrückung berücksichtigt werden.

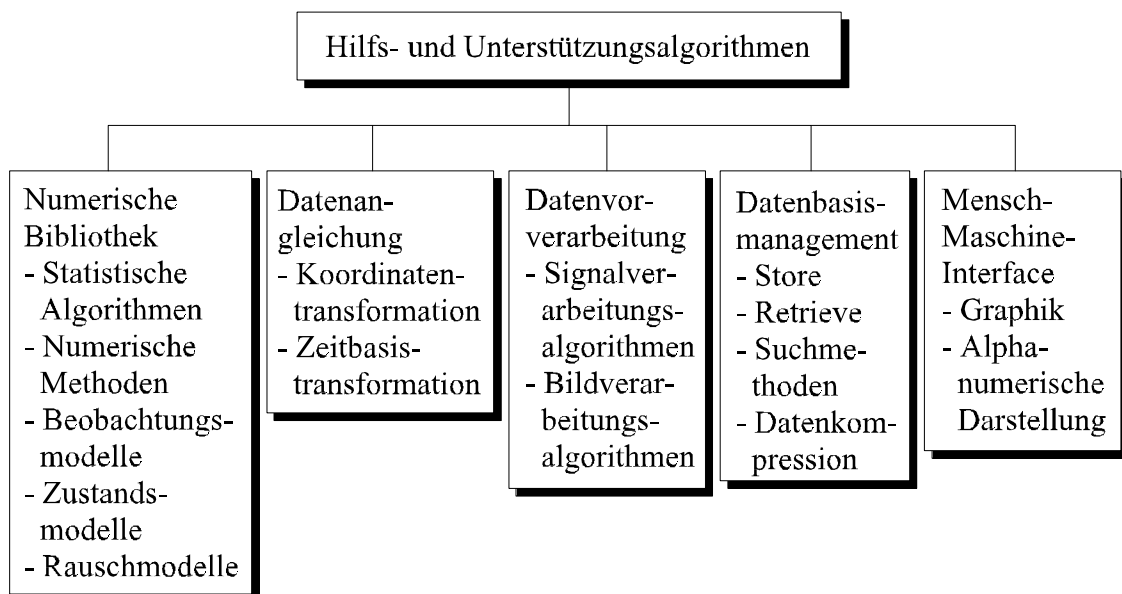


Bild 2.6: Kategorisierung von Hilfs- und Unterstützungsalgorithmen

Datenvorverarbeitung bezeichnet die Algorithmen, die auf die Rohdaten angewendet werden. Dazu gehören Schwellwerte, Mittelwertbildner, allgemeine Signalprozessierungsmethoden (Smoothing [35], Filterfunktionen, FFT [37] usw.) oder Bildverarbeitungs-algorithmen für bildgebende Sensoren. Solche Prozesse verbrauchen i.A. ebenfalls sehr viel Rechenleistung (z.B.

Synthetic Aperture Radar). Auch hier gilt wieder, daß die Auswahl der Techniken spezifisch für die Sensoren zu erfolgen hat, die in dem Datenfusionssystem zum Einsatz kommen.



### 3. Datenassoziation

#### 3.1 Einleitung

Eines der schwierigsten Probleme der Multisensordatenfusion ist die Datenassoziation. Die Frage besteht darin, wie bei  $N$  gegebenen Beobachtungen  $\underline{y}_i$  von einem oder mehreren Sensoren bestimmt werden kann, ob und, wenn ja, welche Beobachtungspaare zusammengehören, d.h. Beobachtungen derselben Betrachtungseinheit sind. Bei der Datenassoziation muß die Entscheidung getroffen werden, ob die  $i$ -te Beobachtung durch Sensor A,  $\underline{y}_{Ai}$ , von der gleichen Betrachtungseinheit herrührt wie die  $j$ -te Beobachtung durch Sensor B,  $\underline{y}_{Bj}$ .

In Kapitel 2 wurde die Datenassoziation in Bild 2.2 als eine Komponente der Positionsfusion illustriert, die als Bearbeitungsschritt zwischen den Blöcken Datenangleichung und Estimation liegt. Die Assoziation von Beobachtungen wird hier allein auf Basis der Positionsinformationen durchgeführt. In Bild 2.4 basiert die Assoziation für den Identitätsfusionsprozeß auf den Identitätsinformationen ohne jede Berücksichtigung des beobachteten Ortes. Diese Unterscheidung für Positions- und Identitätsfusion dient jedoch nur der Darstellung. Unter realen Verhältnissen laufen die beiden Fusionsprozesse integriert ab.

Zur Einführung eines Konzeptes für die Datenassoziation und diese betreffende Fragen sollen drei Beispiele erläutert werden:

1. Beobachtungs- zu Beobachtungsassoziation für stationäre Objekte,
2. Beobachtungs- zu Track-Assoziation für dynamische Objekte und
3. Beobachtungs- zu Beobachtungsassoziation zur Klärung von Identitätsfragen.

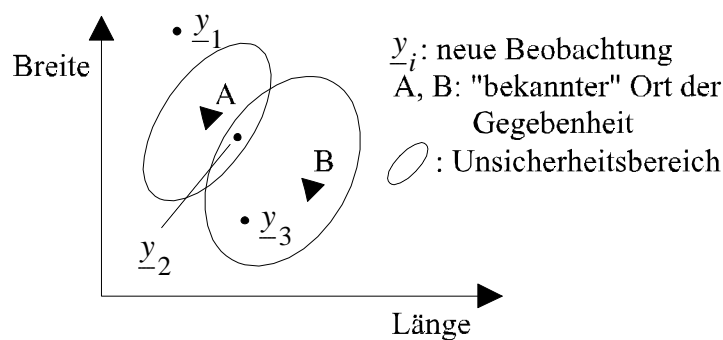


Bild 3.1: Positionelle Assoziation geographisch fixierter Betrachtungseinheiten

Für das erste Beispiel sei angenommen, daß einer oder mehrere Sensoren den geographischen Ort (z.B. Breiten- und Längengrad) stationärer Betrachtungseinheiten direkt beobachten. Eine Darstellung der Situation zeigt Bild 3.1.

Die Positionen zweier Betrachtungseinheiten A und B seien mit einem gewissen Grad an Sicherheit bzw. Unsicherheit bestimmt worden. Der Unsicherheitsbereich ist im Bild durch die beiden ellipsenförmigen Bereiche dargestellt, die die beiden identifizierten Orte umgeben. Diese Unsicherheit kann von einer Kombination mehrerer Faktoren verursacht sein. Dazu beitragen können der Beobachtungsprozeß (Rauschen), potentielle Mobilität der relativ fixen Betrachtungseinheiten oder auch eine tatsächliche geographische Verteilung der beobachteten Objekte, die aus mehreren Teilobjekten bestehen könnte (z.B. eine Einheit aus mehreren kleinen Plattformen oder Objekten). In Bild 3.1 sind drei neue Beobachtungen durch  $\underline{y}_1$ ,  $\underline{y}_2$  und  $\underline{y}_3$  angedeutet. Dabei soll jeder dieser Vektoren aus den Komponenten gemessener Breiten- und Längengrade bestehen. Für jede dieser Beobachtungen gibt es nun vier Möglichkeiten, zu welcher bekannten Betrachtungseinheit diese zugeordnet werden können:

1.  $\underline{y}_i$  ist assoziiert mit Objekt A,
2.  $\underline{y}_i$  ist assoziiert mit Objekt B,
3.  $\underline{y}_i$  gehört weder zu A noch zu B, ist die Beobachtung einer neuen Betrachtungseinheit, und
4.  $\underline{y}_i$  ist eine zu ignorierende Fehlbeobachtung.

Aus Gründen der Darstellungsklarheit soll darauf verzichtet werden, im weiteren die Möglichkeit einer Fehlbeobachtung (z.B. wegen Rauschen) näher zu betrachten. Es soll versucht werden, die neu hinzugekommenen Beobachtungen  $\underline{y}_i$  mit den in der Datenbasis bekannten Betrachtungseinheiten zu assoziieren bzw. die Beziehungen zwischen den Beobachtungen  $\underline{y}_i$  aufzuzeigen, wenn die Objekte A und B noch nicht beobachtet wurden.

Für das Beispiel sei angenommen, daß die Positionen direkt beobachtet werden können, daß keine Identitätsinformationen wie z.B. Frequenz oder Infrarotspektrum verfügbar sind und daß die beobachteten Objekte relativ stationär sind.

Allgemein wird nun für die gegebenen Beobachtungen  $\underline{y}_i$  und die bekannten Objekte A, B, ...,

N eine Assoziationsmatrix  $A(i, j)$  aufgestellt mit dem Reihenindex  $i$  und dem Spaltenindex  $j$

für die Beobachtungen  $\underline{y}_i$  und die Betrachtungseinheiten  $x_j$ , deren Elemente  $s_{ij}$  eine skalare Assoziationsmaßzahl darstellen, die die Ähnlichkeiten zwischen der  $i$ -ten Beobachtung und dem  $j$ -ten Objekt quantifizieren:

$$A(i, j) = \begin{bmatrix} s_{11} & s_{12} & s_{13} & \dots \\ s_{21} & s_{22} & s_{23} & \dots \\ \dots & \dots & \dots & \dots \\ s_{N1} & s_{N2} & s_{N3} & \dots \end{bmatrix} \quad (3.1)$$

Ein Beispiel für das skalare Ähnlichkeitsmaß  $s_{ij}$  ist der geometrische Abstand:

$$s_{ij} = \sqrt{|\underline{y}_i - \underline{l}_j|^2} \quad (3.2)$$

mit  $\underline{y}_i$  der neuen Beobachtung und  $\underline{l}_j$  der bekannten Position der Betrachtungseinheit  $j$ .

Für jedes Beobachtung-Objekt-Paar wird dann das Ähnlichkeitsmaß  $s_{ij}$  mit einem vorbestimmten Schwellwert verglichen und daraus entschieden, ob Beobachtung  $i$  mit Objekt  $j$  zu assoziieren ist oder nicht. Wenn keine Assoziation hergestellt werden kann, ist mit zusätzlichen Überlegungen die Stichhaltigkeit anderer Hypothesen zu prüfen (z.B. Beobachtung  $i$  repräsentiert ein neues Objekt). Anschließend an die Zuordnung der Beobachtungen zu den verschiedenen Objekten verwendet der Fusionsprozeß Estimationstechniken zur Kombination der Daten bzw. zur Verbesserung der Schätzwerte der Positionen bzw. Identitäten der einzelnen Objekte, s. z.B. [45].

Für das zweite Beispiel sei wiederum angenommen, daß der Ort direkt zu beobachten sei. Bild 3.2 zeigt zwei Objekte A und B, die sich auf vorhersagbaren Pfaden bewegen (gestrichelte Linien).

Zur Zeit  $t_0$  befindet sich Objekt A an der Position  $A(t_0)$ . Mit Hilfe dieses Anfangswertes und den Bewegungsgleichungen läßt sich die Position A zu einem späteren Zeitpunkt  $t$  schätzen. Der Unsicherheitsbereich für Objekt B zum Zeitpunkt  $t_0$  führt entsprechend zu einem i.A. größeren Unsicherheitsbereich für den Zeitpunkt  $t$ . Das Assoziationsproblem besteht bei die-

sem Beispiel darin, die drei Positionsbeobachtungen  $\underline{y}_1$ ,  $\underline{y}_2$  und  $\underline{y}_3$  einem der beiden Tracks bzw. einem neuen zuzuordnen bzw. zu diesen zu assoziieren.

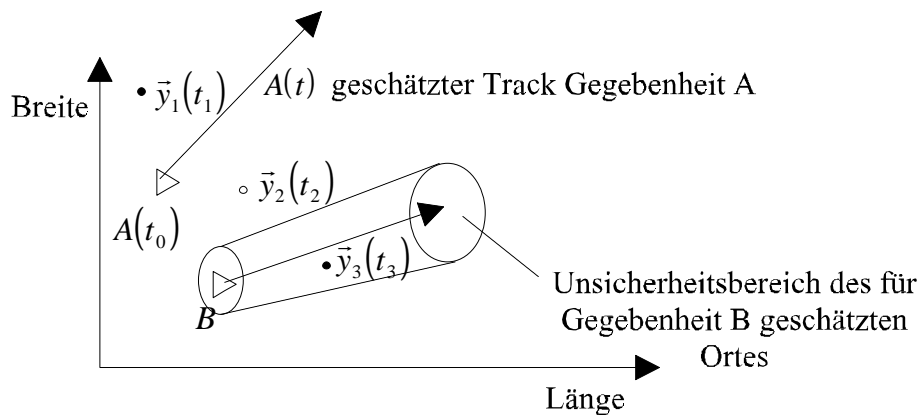


Bild 3.2: Positionelle Assoziation dynamischer Objekte

Der Beispielloassoziationsprozeß sieht wie folgt aus: Extrapolation der Positionen der bekannten Objekte zu dem Zeitpunkt der hinzugekommenen Beobachtung  $\underline{y}_i$  ( $A(t_0) \Rightarrow A(t_i)$  und  $B(t_0) \Rightarrow B(t_i)$ ), Erstellung der Assoziationsmatrix durch Berechnung der Ähnlichkeiten zwischen der Beobachtung  $\underline{y}(t_i)$  und der geschätzten Position der bekannten Objekte A und B zur Zeit  $t_i$ , Bestimmung des Tracks, dem die Beobachtung  $\underline{y}(t_i)$  zuzuordnen ist, auf Basis des skalaren Ähnlichkeitsmaßes  $s$  und Korrektur der geschätzten Positionen der Objekte mit Hilfe von Estimationsmethoden.

Das dritte Beispiel behandelt die Assoziation von Identitätsinformation ohne Berücksichtigung des Ortes. Das Problem bestehe darin, Klassen von gepulsten Strahlern zu beobachten, die eine Schwankungsbandbreite sowohl in Bezug auf die Frequenz als auch auf die Pulswiederholrate PRI aufweisen. Angenommen sei dabei, daß die Strahler dieselbe Position haben, so daß Informationen bzgl. des Ortes keinen Hinweis auf die Identifizierung der Strahler geben können. Für das Beispiel sei weiter angenommen, daß es zwei Strahlerklassen A und B gebe. In Bild 3.3 weist Klasse A eine Schwankungsbandbreite im Intervall (3;7) bzgl. der PRI und eine Schwankungsbandbreite bzgl. der Frequenzen im Bereich (3;9) auf.

Analog dazu liegen die Schwankungsbreiten für Klasse B in den Intervallen (1;5) und (6;12). Für dieses Assoziationsproblem sind wiederum drei Beobachtungen  $\underline{y}_i^T = (PRI, Frequenz)^T$  gegeben, die den beiden Klassen zuzuordnen sind.

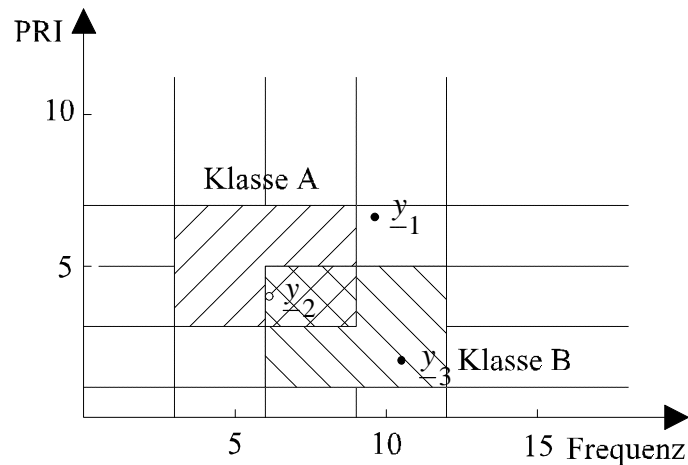


Bild 3.3: Identitätsassoziation für gepulste Strahler

Der Assoziationsprozeß verläuft hierbei nahezu identisch zu dem des ersten Beispiels, wobei jedoch zu beachten ist, daß die Definition eines geeigneten Ähnlichkeitsmaßes schwierig ist, besonders wenn die beobachteten Daten diskret statt kontinuierlich sind.

Diese Beispiele sollen die Art der Assoziationsproblematik verdeutlichen. Es soll dabei versucht werden, eine Beziehung zwischen Beobachtungspaaren oder Beobachtungen zu Tracks zu etablieren. Für eine Menge von  $N$  Beobachtungen werden Beobachtungspaare verglichen, um zu entscheiden, ob Beobachtung  $\underline{y}_i$  zu Beobachtung  $\underline{y}_j$  in Beziehung steht oder nicht. Für die  $N$  Beobachtungen sind  $N \cdot (N - 1)$  Vergleiche anzustellen. Weiter müssen für jeden  $(i, j)$ -Vergleich mehrere Hypothesen geprüft werden. Für größere  $N$  explodiert das Assoziationsproblem kombinatorisch.

### 3.2 Ein allgemeiner Assoziationsprozeß

In Bild 3.4 ist ein Prozeß zur Datenassoziation dargestellt. Unter der Annahme, daß die Beobachtungen sequentiell abgearbeitet werden, beginnt der mehrstufige Prozeß mit der Aufnahme einer neuen Beobachtung  $\underline{y}_i(t_i)$  und vergleicht diese mit den bekannten Objekten (dargestellt durch den Zustandsvektor  $\underline{x}_j(t_j)$ ) und/oder den vorherigen Beobachtungen  $\underline{y}_j(t_j)$ . Die Beobachtung  $\underline{y}_i(t_i)$  kann dabei die beobachtete Position eines Objektes, positionelle Parameter (z.B. Azimut oder Elevation), Identitätsinformation oder Parameter bzgl. der Identität repräsentieren. Der Vergleichsprozess verläuft systematisch, wobei ein Assoziationsmaß benutzt wird, um die Ähnlichkeit zwischen Beobachtung-Objekt- oder Beobachtung-Beobachtung-Paaren zu bestimmen.

Der erste Schritt in diesem Assoziationsprozeß, der wegen seiner Vereinfachungen keinen Anspruch auf Allgemeingültigkeit erhebt, betrifft das Auslesen zu prüfender Objekte aus der Datenbasis, in der frühere Beobachtungen  $\underline{y}_j(t_j)$  gespeichert sind und auch früher bestimmte Zustandsvektoren  $\underline{x}_j(t_j)$ , die den Augenblicksschätzwert des Zustandes repräsentieren. Üblicherweise findet dieses selektive Auslesen mit Hilfe Boole'scher Datenbankabfragen statt, deren Formulierung von den Meßdaten und der internen Darstellung der gespeicherten Objekte abhängt.

Für dynamische Situationen ist der Zustand einer Betrachtungseinheit zeitvariant, z.B. ist die Position einer mobilen Plattform zu einer bestimmten Zeit  $t_0$  i.A. verschieden von ihrer Position zu einem späteren Zeitpunkt  $t_j$ , d.h.:

$$\underline{x}_j(t_0) \neq \underline{x}_j(t_j) \quad (3.3)$$

Aus diesem Grund besteht der zweite erforderliche Assoziationsschritt für dynamische Objekte aus der Berechnung des Zustandsvektors der zu prüfenden Betrachtungseinheit für die Beobachtungszeit  $t_i$  des neuen Beobachtungsvektors  $\underline{y}_i(t_i)$ , d.h. für jede zu prüfende Betrachtungseinheit  $\underline{x}_j(t_j)$  müssen die Bewegungsgleichungen zur Bestimmung des Vorhersagewer-

tes  $\underline{x}_j$  zum Zeitpunkt  $t_i$  gelöst werden. Dieser Zusammenhang kann mathematisch sehr vereinfacht durch:

$$\underline{x}(t_i) = \mathbf{f}(t_i, t_j) \cdot \underline{x}(t_j) + \underline{w}(t_j) \quad (3.4)$$

beschrieben werden.

Gl. (3.4) repräsentiert eine Transformation, die den Zustandsvektor  $\underline{x}$  von einem Zeitpunkt  $t_j$  zu dem Zeitpunkt  $t_i$  überführt.  $\underline{w}$  beschreibt unbekanntes Rauschen, das üblicherweise durch eine Gaußverteilung mit Mittelwert 0 modelliert wird. In ihrer einfachsten Form kann Gl. (3.4) als eine Taylorreihenentwicklung mit der Übergangsmatrix:

$$\mathbf{f}(t_i, t_j) = \left| \frac{\mathcal{J}\underline{x}(t_i)}{\mathcal{J}\underline{x}(t_j)} \right| \quad (3.5)$$

betrachtet werden, deren Komponenten die partiellen Ableitungen der Zustandsvektorelemente zur Zeit  $t_i$  nach den Zustandsvektorelementen zur Zeit  $t_j$  sind. Allgemeingültigere Ausdrücke von Gl. (3.5) können simultane nichtlineare differentielle Bewegungsgleichungen verwenden. Die Wahl der Näherung für die Bewegungsgleichungen hängt von einigen Faktoren, darunter die zugrundeliegenden physikalischen Phänomene, die die Änderungen des Zustandsvektors steuern, die Länge der Zeit  $t_i - t_j$ , für die eine Prädiktion berechnet werden soll und Systemüberlegungen wie der Verfügbarkeit von Rechnerressourcen ab.

Die Prädiktion des Zustandsvektors schließt auch die Prädiktion des Unsicherheitsbereiches ein. Hier wie dort findet die Übergangsmatrix Verwendung.  $P(t_j)$  repräsentiert die Kovarianz von  $\underline{x}_j$  zum Zeitpunkt  $t_j$ . Für einen k-dimensionalen Zustandsvektor ist:

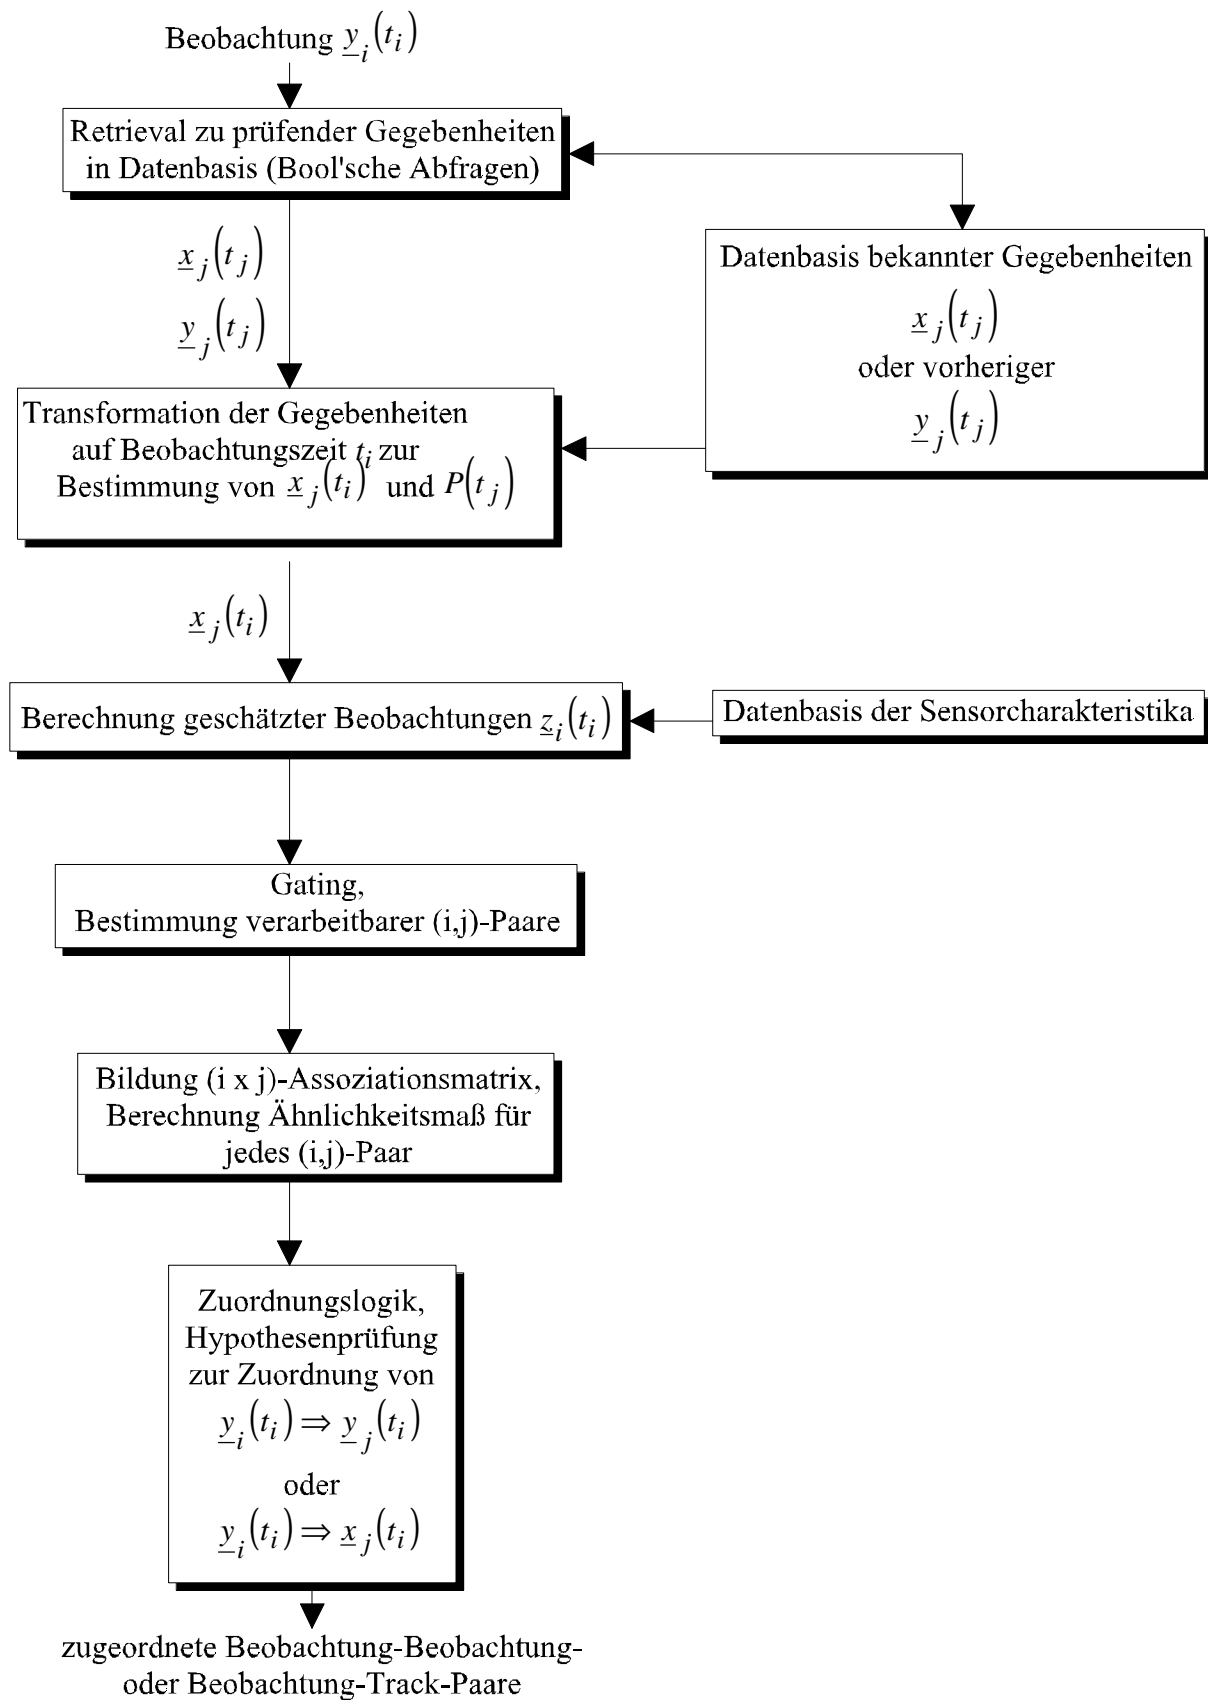


Bild 3.4: Assoziationsprozeß



$$P_{\underline{x}_j}(t_j) = \begin{pmatrix} \mathbf{s}_{\underline{x}_1}(t_j)^2 & r_{12} \cdot \mathbf{s}_{\underline{x}_1}(t_j) \cdot \mathbf{s}_{\underline{x}_2}(t_j) & \dots & r_{1k} \cdot \mathbf{s}_{\underline{x}_1}(t_j) \cdot \mathbf{s}_{\underline{x}_k}(t_j) \\ r_{12} \cdot \mathbf{s}_{\underline{x}_2}(t_j) \cdot \mathbf{s}_{\underline{x}_1}(t_j) & \mathbf{s}_{\underline{x}_2}(t_j)^2 & \dots & r_{2k} \cdot \mathbf{s}_{\underline{x}_2}(t_j) \cdot \mathbf{s}_{\underline{x}_k}(t_j) \\ \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \mathbf{s}_{\underline{x}_k}(t_j)^2 \end{pmatrix} \quad (3.6)$$

mit  $r_{ij} = \frac{E\{(x_i - m_i) \cdot (x_j - m_j)\}}{\left(E\{(x_i - m_i)^2\}\right)^{\frac{1}{2}} \cdot \left(E\{(x_j - m_j)^2\}\right)^{\frac{1}{2}}}$  dem normierten Korrelationskoeffizienten

der i-ten und j-ten Komponenten des Zustandsvektors  $\underline{x}_j(t_j)$  zum Zeitpunkt  $t_j$  und  $\underline{m} = [m_1 \ m_2 \ \dots \ m_k]^T = [E\{x_1\} \ E\{x_2\} \ \dots \ E\{x_k\}]^T$  dem Mittelwertvektor sowie mit  $\mathbf{s}_{\underline{x}_k}(t_j)^2$  der Varianz der k-ten Komponente des Zustandsvektors  $\underline{x}_j(t_j)$  zum Zeitpunkt  $t_j$  [45]. Damit stellt:

$$P_{\underline{x}_j}(t_i) = \mathbf{f}(t_i, t_j) \cdot P_{\underline{x}_j}(t_j) \cdot \mathbf{f}^T(t_i, t_j) + Q(t_j) \quad (3.7)$$

eine Näherung der Kovarianzmatrix des Zustandsvektors zur Zeit  $t_i$  basierend auf der Unsicherheit zur Zeit  $t_j$  unter der Annahme weißen Rauschens dar. Die Matrix  $Q(t_j)$  modelliert

das zeitliche Anwachsen von  $P_{\underline{x}_j}(t_j)$ , wenn keine weiteren Beobachtungen hinzukommen.

Eine allgemeinere Darstellung des Konzepts der Übergangsmatrix findet sich z.B. in [21, 45, 50]. Die Resultate des zweiten Schrittes des Assoziationsprozesses sind Werte von zu prüfenden Betrachtungseinheiten für die Zustände des Vektors  $\underline{x}_j(t_i)$  für die projizierte Beobachtungszeit  $t_i$ . Zusätzliche Resultate sind die ebenfalls projizierten bzw. vorhergesagten Kovarianzmatrizen  $P_{\underline{x}_j}(t_i)$ .

Der dritte Schritt im Assoziationsprozeß ist nur dann nicht notwendig, wenn die Sensoren den Zustand der Betrachtungseinheit  $\underline{x}_j$  nicht direkt beobachten können. Dieser Prozeßschritt

verwendet eine Beobachtungsgleichung zur Prädiktion der Beobachtungen  $\underline{z}_i(t_i)$ , die von der Betrachtungseinheit  $j$  resultieren würden.

Die Funktion  $\underline{g}$  in:

$$\underline{z}_i(t_i) = \underline{g}\left[\underline{x}_j(t_i)\right] + \underline{n} \quad (3.8)$$

repräsentiert die zur Prädiktion einer Beobachtung  $\underline{z}_i$  erforderlichen Transformationen unter der Annahme, daß der wahre Zustand des Objektes  $j$  durch den Zustandsvektor  $\underline{x}_j$  zum Zeitpunkt  $t_i$  dargestellt werden kann. Zum Beispiel kann  $\underline{g}$  für die Koordinatentransformationen stehen, die zur Prädiktion von beobachteten topozentrischen (relativ zu einem Beobachter auf der Oberfläche der Erde) Azimut- und Elevationsdaten auf Basis eines geozentrischen (relativ zum Erdmittelpunkt) dreidimensionalen Positionsvektors notwendig sind. Die Vektorgröße  $\underline{n}$  beschreibt unbekanntes Beobachtungsrauschen, das wiederum typischerweise eine Gauß'sche Verteilung und einen Mittelwert von 0 besitzt. Für jeden Sensortyp eines Datenfusionssystems wird ein auf die Eigenschaften des Sensors angepaßtes System von Beobachtungsgleichungen gebraucht. Die Modellierung des Beobachtungsprozesses hängt von den Charakteristika der verwendeten Sensoren, der zugrundeliegenden physikalischen Situation und einigen weiteren Faktoren ab. Für intelligente Sensoren wie z.B. bildgebende Sensoren oder andere sog. „Smart Sensors“ kann die Beobachtungsmodellierung sehr aufwendig werden.

Der vierte Assoziationsschritt ist das Gating. Dessen Zweck ist die Reduzierung der Anzahl der möglichen Kombinationen von Beobachtung-Beobachtung- oder Beobachtung-Track-Paaren, die für die Assoziation zu berücksichtigen sind. Dies geschieht mit Hilfe von A-Priori-Wissen oder statistischen Annahmen. Zur Erfüllung dieses Zwecks sollte das Gating so früh wie möglich in den Assoziationsprozeß eingreifen, wozu auch eine günstige Formulierung der anfänglichen Boole'schen Datenbankabfrage beitragen kann, da diese die Anzahl der später zu prüfenden Kombinationen festlegt.

Der fünfte Schritt im Assoziationsprozeß formuliert die Assoziationsmatrix. Der Skalar  $s_{ij}$  (d.h. Element  $(i, j)$  der Assoziationsmatrix  $A$ ) bezeichnet die Assoziationsmetrik oder das Ähnlichkeitsmaß, das vergleicht, wie nah die Beobachtung  $\underline{y}_i(t_i)$  der Prädiktion  $\underline{z}_j(t_i)$  ist.

Für kontinuierliche Variablen ist der sog. Mahalanobis-Abstand ein weitverbreitetes Assoziationsmaß [20]:

$$s_{ij} = \left[ \underline{y}_i(t_i) - \underline{z}_j(t_i) \right]^T \cdot \left[ P_i + P_j \right]^{-1} \cdot \left[ \underline{y}_i(t_i) - \underline{z}_j(t_i) \right] \quad (3.9)$$

mit  $\underline{y}_i(t_i)$  der i-ten Beobachtung zur Zeit  $t_i$ ,  $\underline{z}_j(t_i)$  der Prädiktion der Beobachtung der Gegebenheit  $j$  zur Zeit  $t_i$ ,  $P_i = E \left\{ \left( \underline{y}_i(t_i) - E \left\{ \underline{y}_i(t_i) \right\} \right) \cdot \left( \underline{y}_i(t_i) - E \left\{ \underline{y}_i(t_i) \right\} \right)^T \right\}$  der Unsicherheit im Beobachtungsprozeß und  $P_j = E \left\{ \left( \underline{z}_j(t_i) - E \left\{ \underline{z}_j(t_i) \right\} \right) \cdot \left( \underline{z}_j(t_i) - E \left\{ \underline{z}_j(t_i) \right\} \right)^T \right\}$  der Unsicherheit im Prädiktionsprozeß.  $s_{ij}$  repräsentiert den mit der inversen Kovarianzmatrix gewichteten geometrischen Abstand zwischen dem Beobachtungsvektor  $\underline{y}_i(t_i)$  und dem Prädiktionsvektor  $\underline{z}_j(t_i)$ .

Der Vektor:

$$\underline{r} = \underline{y}_i(t_i) - \underline{z}_j(t_i) \quad (3.10)$$

wird als Innovation oder Beobachtungsresiduum bezeichnet. Der durch die Matrizenaddition von  $P_i$  und  $P_j$  gewonnene Gewichtungsfaktor ist die kombinierte inverse Kovarianzmatrix und repräsentiert die Unsicherheit im Beobachtungsprozeß und die Unsicherheit der Beobachtungsprädiktion. Andere gebräuchliche Assoziationsmaße sind z.B. geometrischer Abstand, City-Block- und Bhattacharyya-Distanz.

Die Assoziationsmatrix  $A$  enthält skalare Werte  $s_{ij}$ , die die Ähnlichkeit zwischen jedem Beobachtung-Beobachtung- oder Beobachtung-Track-Paar quantifizieren.

Der letzte Schritt des Assoziationsprozesses ist die Anwendung einer Entscheidungslogik zur Feststellung, ob die Beobachtung  $\underline{y}_i(t_i)$  mit der Beobachtung  $\underline{y}_j(t_i)$  bzw. dem Zustandsvektor  $\underline{x}_j(t_i)$  assoziiert ist oder nicht. Die Zuordnungslogik ist dem Hypothesentest der Stati-

stik ähnlich: Formulierung alternativer Hypothesen und Berechnung ihrer relativen Wahrscheinlichkeiten.

### 3.3 Gating

Gating ist einer der Schritte in dem allgemeinen Assoziationsprozeß, der im letzten Abschnitt beschrieben wurde. Es führt eine Anfangsüberprüfung zur Eliminierung unwahrscheinlicher Beobachtung-Beobachtung- oder Beobachtung-Track-Paare durch. Der Zweck dieser Überprüfung ist, die Anzahl der (i,j)-Kombinationen zu reduzieren, die im Assoziationsprozeß überprüft werden müssen. Hintergrundwissen über die beteiligten physikalischen Prozesse oder statistische Testmethoden können zur Lösung dieser Aufgabe verwendet werden.

Es soll noch einmal das Beispiel für die positionelle Assoziation dynamischer Gegebenheiten aus Abschnitt 3.1 betrachtet werden.




Bild 3.5: Gating durch dynamische Information

In Bild 3.5 sind zwei Objekte A und B für bekannte geographische Orte zur Zeit  $t_0$  dargestellt. Die Objekte seien nicht stationär und ihre Pfade gegeben. Wenn A-Priori-Information bzgl. der maximalen Geschwindigkeiten der Objekte und der Anzahl der Bewegungen vorliegt, können diese Daten verwendet werden, um wahrscheinliche Beobachtungsassoziationen auszuschließen, z.B. sei die maximale Geschwindigkeit von Objekt B gleich  $V_{\max}$ . Dann ist die maximale örtliche Veränderung von Objekt B gegenüber seiner Anfangsposition durch den Ausdruck:

$$r = V_{\max} \cdot (t - t_0) \quad (3.11)$$

gegeben, worin  $t_0$  die Anfangszeit und  $t$  einen beliebigen späteren Zeitpunkt bezeichnen. Diese mögliche örtliche Veränderung von Objekt B ist in Bild 3.5 als schattierter Kreis um B dargestellt.

Wie aus Bild 3.5 ersichtlich, können die drei Beobachtungen  $\underline{y}_1(t_1)$ ,  $\underline{y}_2(t_2)$  und  $\underline{y}_3(t_3)$  durch den Gating-Mechanismus von einer potentiellen Assoziation mit Objekt B ausgeschlossen werden, da die drei Beobachtungen nicht innerhalb des schattierten Bereichs um Objekt B liegen bzw. Objekt B innerhalb des Zeitintervalls nicht in die Nähe der drei Beobachtungen gelangen könnte. Für Objekt A ist neben einer maximalen Geschwindigkeit das zusätzliche Gate einer Maximalrate der Winkelgeschwindigkeit illustriert.

Für nichtdynamische Betrachtungseinheiten können andere parametrische Grenzen verwendet werden, um Beobachtungskombinationen auszuschließen. Im dritten Beispiel von Abschnitt 3.1 können z.B. bekannte physikalische Grenzen für die PRI und Frequenzvariation dazu führen, daß potentielle Beobachtungen für eine Assoziation mit den Strahlern ausgeschlossen werden können. Die Beobachtung  $\underline{y}_1$  in Bild 3.3 kann z.B. für den Assoziationsprozeß vernachlässigt werden, da die physikalischen Schranken für die PRI- und Frequenzänderungen diese Beobachtung nicht einschließen. Zusätzlich zu positionsbezogener Information kann auch vorhandene Identitätsinformation zur Eingrenzung der Kombinationspaare verwendet werden. Ein Beispiel dazu wäre der Gebrauch von RCS-Daten eines Radars zur Unterscheidung eng beieinanderliegender Ziele im Fall eines Suchradars für Mehrfachziele. Mittlere und Spitzenwerte der RCS können bei der Unterscheidung zwischen großen Fahrzeugen (z.B. Flugzeug) und Trümmerstücken bzw. Fragmenten als Gating-Parameter dienen. Die Gating-Technik verhindert durch die Reduzierung der möglichen Kombinationen und der damit einhergehenden Verbesserung der Systemperformanz durch Verringerung der Rechenlast evt. mögliche Fehllassoziationen im weiteren Verlauf des Assoziationsprozesses.

Neben physikalischen Modellen gibt es auch statistische Testmethoden zur Ausführung des Gatings [61], zu denen das Chi-Quadrat-Kriterium gehört. Gegeben sei eine neue Beobachtung  $\underline{y}_i(t_i)$  und ein möglicher Track  $\underline{x}_j(t_j)$ . Gl. (3.4) bis (3.8) beschreiben den Prädiktionsprozeß für die Beobachtung  $\underline{z}_j(t_i)$ , die eine Beobachtung repräsentiert, die für eine Betrachtungseinheit mit dem Zustandsvektor  $\underline{x}_j(t_j)$  vorausgesagt werden könnte.  $\underline{y}_i(t_i)$  und  $\underline{z}_j(t_i)$  können

als Zufallsvariablen aufgefaßt werden. Wenn der Meßprozeß keinen Bias aufweist, dann repräsentiert  $\underline{y}_i(t_i)$  einen Sample-Wert einer Gauß-verteilten Zufallsvariablen mit Mittelwert 0 und Varianz  $P_i$ . Wenn dann der zur Prädiktion von  $\underline{z}_j(t_i)$  verwendete Estimator ebenfalls keinen Bias aufweist, dann repräsentiert  $\underline{z}_j(t_i)$  wiederum einen Sample-Wert einer Gauß-verteilten Zufallsvariablen, diesmal mit der Varianz  $P_j$ . Unter diesen Bedingungen ist das Beobachtungsresiduum [21, 45, 50]:

$$\underline{r} = \underline{y}_i(t_i) - \underline{z}_j(t_i) \quad (3.12)$$

auch eine normalverteilte Zufallsvariable mit einem Mittelwert 0 und einer Varianz:

$$P_{ij} = P_i + P_j \quad (3.13)$$

wenn die  $\underline{y}_i(t_i)$  und  $\underline{z}_j(t_i)$  unkorreliert sind.

Der Wert:

$$s_{ij} = \underline{r}^T \cdot P_{ij}^{-1} \cdot \underline{r} \quad (3.14)$$

ist Chi-Quadrat-verteilt mit  $m$  Freiheitsgraden und stellt eine weitere Zufallsvariable dar. Die Verteilungsdichtefunktion dieser Zufallsvariablen ist gegeben durch (Euler'sche Definition):

$$f_{s_{ij}}(\mathbf{c}^2) = \frac{1}{2^{\frac{m}{2}} \cdot \Gamma\left(\frac{m}{2}\right)} \cdot (\mathbf{c}^2)^{\frac{m-2}{2}} \cdot \exp\left\{-\frac{\mathbf{c}^2}{2}\right\} \quad (3.15)$$

wobei  $m$  die Anzahl der Freiheitsgrade und  $\Gamma$  die Gamma-Funktion [9]:

$$\Gamma(x) = \int_0^{\infty} \exp\{-t\} \cdot t^{x-1} \cdot dt \quad (3.16)$$

repräsentiert. Die Wahrscheinlichkeit, daß  $\mathbf{c}^2 \geq \mathbf{c}_a^2$ , ist:

$$P(s_{ij} > \mathbf{c}_d^2) = \int_{\mathbf{c}_d^2}^{\infty} f_{s_{ij}}(\mathbf{c}^2) \cdot d\mathbf{c}^2 \quad (3.17)$$

Für einen gegebenen Schwellwert  $\mathbf{c}_a^2$  für  $\mathbf{c}^2$  beschreibt Gl. (3.17) die Wahrscheinlichkeit, daß der beobachtete Wert von  $\mathbf{c}^2$  größer als der Schwellwert  $\mathbf{c}_a^2$  ist, d.h. daß ein solches Gating unwahrscheinliche Assoziationen durch die Berechnung der Wahrscheinlichkeit, daß  $s_{ij}$  innerhalb eines bestimmten Intervalls liegt, vermeidet, wenn die Beobachtungen  $i$  und  $j$  tatsächlich dem gleichen physikalischen Phänomen zugrundeliegen.

Gating-Techniken auf Basis der vorgestellten Methoden wie physikalischen Modellen (z.B. parametrische Templates), statistischen Tests und wahrscheinlichkeitstheoretischen Schwellwerten sind sehr nützlich. Die Anwendung dieser Technik muß jedoch gegen die Menge der Beobachtungen und Tracks abgewogen werden. Sehr dichte Umgebungen, in denen viele Beobachtungen innerhalb enger Parametergrenzen liegen, erfordern ausgefeilte und durchdachte Gating-Techniken zur Reduktion der  $(i, j)$ -Kombinationsmöglichkeiten. Für weniger dichte Umgebungen kann dagegen der Rechenaufwand für eine i.A. komplexe Gating-Routine den Nutzen überwiegen. In einem solchen Fall wäre es günstiger, den Rechenaufwand in Kauf zu nehmen, der zur Assoziationsverarbeitung ohne Gating notwendig wäre.



### 3.4 Assoziationsmetriken

Um die Ähnlichkeiten zwischen Beobachtungspaaren (oder Beobachtung-Track-Paaren) zu quantifizieren, müssen Assoziationsmetriken bzw. -maße definiert sein. Bereits eingeführt wurden geometrische Abstände (z.B. vektorieller Abstand zwischen den Orten zweier Objekte) und wahrscheinlichkeitstheoretische Abstandsmaße. Der folgende Abschnitt beschreibt das allgemeine Konzept von Assoziationsmetriken unter Berücksichtigung der Eigenschaften der Metriken sowie Beispiele für kontinuierliche und diskrete Variablen und Richtlinien für die Auswahl geeigneter Metriken.

Es gibt vier Standardkriterien [1] zur Entscheidung, ob ein Ähnlichkeitsmaß tatsächlich eine Metrik ist oder nicht: Symmetrie, Dreiecksungleichung, Unterscheidbarkeit von Nichtidentitäten und Nichtunterscheidbarkeit von Identitäten:

1) Symmetrie: für zwei Objekte A und B erfüllt die Distanz  $d$  den Ausdruck:

$$d(A, B) = d(B, A) \geq 0 \quad (3.18a)$$

Der Abstand zwischen zwei Beobachtungen ist größer oder gleich Null und besitzt denselben Wert, ob die Distanz von A nach B gemessen wird oder von B nach A.

2) Dreiecksungleichung: Für drei Objekte A, B und C gilt für die Abstände zwischen ihnen die Ungleichung:

$$d(A, B) \leq d(A, C) + d(B, C) \quad (3.18b)$$

Die Ungleichung besagt, daß die Länge einer beliebigen Seite eines Dreiecks kleiner oder gleich der Summe der Längen der beiden anderen Seiten ist.

3) Unterscheidbarkeit von Nichtidentitäten:

$$d(A, B) \neq 0 \Leftrightarrow A \neq B \quad (3.18c)$$

d.h., daß zwei Objekte A und B dann nichtidentisch sind, wenn der Abstand zwischen ihnen ungleich 0 ist.

4) Nichtunterscheidbarkeit von Identitäten: Im Falle zweier identischer Objekte A und A' gilt:

$$d(A, A') = 0 \quad (3.18d)$$

d.h. der Abstand zwischen zwei identischen Objekten ist 0.

Die Wichtigkeit dieser Kriterien beruht darauf, daß aus ihnen Charakteristika und Beziehungen für Assoziationsmetriken abgeleitet werden können. Eine Reihe von Assoziationsmaßen, wie Figure-of-Merit (FOM), die nicht die Eigenschaften einer Metrik besitzen, können definiert werden. Der Gebrauch nichtmetrischer Maße kann gerechtfertigt sein aufgrund der Natur des Assoziationsproblems. Solche Maße müssen jedoch immer im Bewußtsein ihrer Beschränkungen verwendet werden.

Vor der Einführung einiger Klassen von Ähnlichkeitsmaßen sind einige kurze Anmerkungen zur Beschreibung der Variablentypen angebracht:

Unterschieden wird in kontinuierliche und diskrete Variablen. Als kontinuierlich werden diejenigen Variablen bezeichnet, die zumindest theoretisch jeden Wert aus einem nicht abzählbaren Wertevorrat innerhalb eines Intervalles annehmen können (z.B. Position).

Diskrete Variablen dagegen können nur eine abzählbare Menge von Werten annehmen und werden oft verwendet, um Kategorien zu beschreiben, zu denen Mitglieder einer Population zuzuordnen sind. Diskrete Variablen werden weiter in drei Unterklassen differenziert: Nominal-, Ordnungs- und Skalarvariablen.

Nominalvariablen werden nur zur Identifizierung von Kategorienklassen verwendet. Sie besitzen zunächst keine bedeutsame Information zur Beziehung der Variablen. „Geschlecht“ ist ein Beispiel einer solchen Variablen. Die zwei möglichen Kategorien können als „M“ und „F“ oder „1“ und „2“ oder auf eine andere beliebige Art bezeichnet werden. Ein Radar z.B. kann als „Pulsed“ (P) oder „Continuous Wave“ (CW) identifiziert werden. Wenn die Zahl 1 dem P-Radar und die Zahl 2 dem CW-Radar zugeordnet werden, dann sind die Zahlen Realisationen einer Nominalvariablen. Die Werte einer Nominalvariablen haben keine quantitative Bedeutung (z.B. das CW-Radar (2) ist nicht das doppelte eines P-Radars (1)).

Ordnungs- bzw. ordinale Variablen dienen der Darstellung ordinaler Kategorien. Noten für Klausuren z.B. ermöglichen eine relative Anordnung derselben, spezifizieren aber nicht unbedingt eine quantitative Zuordnung. Eine Klausur mit der Note 1 ist nicht notwendigerweise dreimal besser als eine Klausur mit der Note 3. Ordinale Variablen sind diejenigen, für die die Ordnungsfunktion signifikant ist, für die jedoch numerische Beziehungen nicht aufgestellt werden können.

Für Skalarvariablen sind sowohl Ordnungs- als auch numerische Beziehungen signifikant, z.B. werden Radarsysteme oft entsprechend des Frequenzbereiches bezeichnet, in dem sie arbeiten (z.B. L-Band-Radar im Bereich 390 MHz bis 1550 MHz, S-Band-Radar im Bereich 1550 MHz bis 5200 MHz oder X-Band-Radar im Bereich 5200 MHz bis 10900 MHz). Diesen Bandbereichen kann eine Numerik zugeordnet werden, z.B. 1=L-Band, 2=S-Band, 3=X-Band. Zwischen den Radar-Kategorien existiert eine quantitative Beziehung, da die relativen Frequenzen von Radarsystemen zweier verschiedener Kategorien bestimmbar sind. Diese Definitionen kontinuierlicher und diskreter Variablen sind insoweit von Bedeutung, da die Auswahl geeigneter Assoziationsmaße von der Klasse der zu vergleichenden Variablen abhängt.

### 3.4.1 Abstandsmaße

Abstandsmaße werden oft dazu verwendet, die Ähnlichkeit bzw. Unähnlichkeit zwischen Beobachtungspaaren zu quantifizieren. Sie entsprechen den Metrieregeln und können auf kontinuierliche Variablen angewendet werden. Tabelle 3.1 faßt eine Reihe von Abstandsmaßen zur Quantifizierung der Distanz zwischen zwei zu prüfenden Beobachtungen  $\underline{y}$  und  $\underline{z}$  mit  $\dim[\underline{y}] = \dim[\underline{z}] = m$  zusammen.

Abstandsmaß	Formulierung	Interpretation
Euklid	$\left[ (\underline{y} - \underline{z})^T \cdot (\underline{y} - \underline{z}) \right]^{\frac{1}{2}}$	geometrische Distanz zwischen den Vektoren $\underline{y}$ und $\underline{z}$
Euklid gewichtet	$\left[ (\underline{y} - \underline{z})^T \cdot W \cdot (\underline{y} - \underline{z}) \right]^{\frac{1}{2}}$	Gewichtung mit Matrix $W$
City-Block	$\sum_{k=1}^m  y_k - z_k $	Minkowski-Abstand erster Ordnung, sog. Manhattan-Abstand

Minkowski	$\left[ \sum_{k=1}^m  y_k - z_k ^P \right]^{\frac{1}{P}}$	Verallgemeinerter Euklidischer Abstand der Ordnung $P$ mit $1 \leq P \leq \infty$
Mahalanobis	$(\underline{y} - \underline{z})^T \cdot P^{-1} \cdot (\underline{y} - \underline{z})$	Gewichteter Euklidischer Abstand (Gewicht gleich inverser Kovarianzmatrix)
Bhattacharyya	$\frac{1}{8} \cdot (\underline{y} - \underline{z})^T \cdot \left\{ \frac{P_y + P_z}{2} \right\}^{-1} \cdot (\underline{y} - \underline{z}) + \frac{1}{2} \cdot \ln \left\{ \frac{ P_y + P_z }{2} \right\} \cdot \left[ \sqrt{ P_y } \cdot \sqrt{ P_z } \right]$	Verallgemeinerung der Mahalanobis-Distanz mit ungleichen Kovarianzmatrizen (gleich Chernoff-Distanz für $s = \frac{1}{2}$ )
Chernoff	$\frac{s \cdot (1-s)}{2} \cdot (\underline{y} - \underline{z})^T \cdot (s \cdot P_y + (1-s) \cdot P_z)^{-1} \cdot (\underline{y} - \underline{z}) + \frac{1}{2} \cdot \ln \frac{ s \cdot P_y + (1-s) \cdot P_z }{ P_y ^s \cdot  P_z ^{1-s}}$	Verallgemeinerung der Mahalanobis-Distanz, ebenfalls mit ungleichen Kovarianzmatrizen $P_y$ und $P_z$ , $0 < s < 1$

Tabelle 3.1: Zusammenfassung gebräuchlicher Abstandsmaße [1, 20]

Der Euklidische Abstand ist der geometrische Abstand zwischen diesen beiden Vektoren, während der Minkowski-Abstand eine Verallgemeinerung des euklidischen Abstands darstellt. Gewichtungsfaktoren können dazu eingesetzt werden, die Komponenten der zu prüfenden Beobachtungen effektiv zu skalieren. Im Fall der Gewichtung durch die inverse Kovarianzmatrix ergibt sich die resultierende Metrik als der sog. Mahalanobis-Abstand. Die Bhattacharyya- und die Chernoff-Distanz sind wiederum Verallgemeinerungen des Mahalanobis-Abstandes. Einzelheiten zu den beiden zuletzt genannten Abstandsmaßen können in [20] gefunden werden.

Distanzmaße sind weit verbreitet und intuitiv erfaßbar aufgrund ihrer offensichtlichen geometrischen Interpretierbarkeit. Probleme mit Abstandsmetriken bereiten vor allem Variablen, die große Differenzen und Standardabweichungen aufweisen. Diese Variablen können die Effekte anderer Variablen stark beeinträchtigen, die kleine Werte und Standardabweichungen besitzen. Dieser Tatsache kann durch Transformationen bzw. Skalierungen begegnet werden. Ein solches Vorgehen verlagert die Probleme aber nur.

### 3.4.2 Korrelationskoeffizienten

Korrelationskoeffizienten sind weit verbreitete und seit langem anerkannte Assoziationsmaße, welche sowohl auf kontinuierliche als auch diskrete Variablen anwendbar sind.

Der Pearson'sche Korrelationskoeffizient wurde im neunzehnten Jahrhundert von Galton, Edgeworth und Pearson eingeführt und ist ein Maß für die Verbundvariabilität zweier Variablen, z.B.:

$$r_{zy} = \frac{P(y,z)}{\mathbf{s}_y \cdot \mathbf{s}_z} = \frac{\mathbf{s}(y,z)}{\mathbf{s}_y \cdot \mathbf{s}_z} \quad (3.19)$$

mit den Standardabweichungen  $\mathbf{s}_y$  und  $\mathbf{s}_z$  der beiden Variablen  $y$  und  $z$  und der Kovarianz der beiden Variablen  $P(y,z)$ .

Als Schätzwert kann für zwei Beobachtungsvektoren  $\underline{y}$  und  $\underline{z}$  mit  $n$  Komponenten geschrieben werden [9, A.2]:

$$\begin{aligned} r_{zy} &= \frac{\frac{1}{n-1} \cdot \sum_{i=1}^n \left[ \left( y_i - \frac{1}{n} \cdot \sum_{i=1}^n y_i \right) \cdot \left( z_i - \frac{1}{n} \cdot \sum_{i=1}^n z_i \right) \right]}{\sqrt{\frac{1}{n-1} \cdot \sum_{i=1}^n \left( y_i - \frac{1}{n} \cdot \sum_{i=1}^n y_i \right)^2 \cdot \frac{1}{n-1} \cdot \sum_{i=1}^n \left( z_i - \frac{1}{n} \cdot \sum_{i=1}^n z_i \right)^2}} \\ &= \frac{\sum_{i=1}^n y_i \cdot z_i - \frac{1}{n} \cdot \sum_{i=1}^n y_i \cdot \sum_{i=1}^n z_i}{\sqrt{\left[ \sum_{i=1}^n y_i^2 - \frac{1}{n} \cdot \left( \sum_{i=1}^n y_i \right)^2 \right] \cdot \left[ \sum_{i=1}^n z_i^2 - \frac{1}{n} \cdot \left( \sum_{i=1}^n z_i \right)^2 \right]}} \end{aligned} \quad (3.20)$$

Korrelationskoeffizienten werden häufig wegen ihrer geometrischen Interpretierbarkeit als Winkelmaße bezeichnet. Im Vergleich zu Abstandsmaßen sind Korrelationskoeffizienten relativ unempfindlich bzgl. der Größen der Variablen, die zu ihrer Berechnung verwendet werden. Deshalb werden diese Koeffizienten auch als Formmaße bezeichnet. Vergleiche von Attributvektoren können zu unterschiedlichen bzw. widersprüchlichen Ergebnissen führen bei der An-

wendung von Korrelationskoeffizienten und Abstandsmaßen. [1] gibt ein quantitatives Beispiel bzgl. des unterschiedlichen Effekts von Korrelationskoeffizienten und Abstandsmaßen aus der Psychopathologie.

Korrelationskoeffizienten stellen häufig keine Metrik dar, d.h. die Werte unterschiedlicher Koeffizienten ergeben nicht notwendigerweise dasselbe Ergebnis, wenn sie auf die gleichen Daten angewandt werden. Die praktische Bedeutung der Bestimmung, ob ein Maß die Metrik-kriterien erfüllt, zeigt sich z.B. daran, daß der Pearson'sche Korrelationskoeffizient Gl. (3.18c) nicht erfüllt, und wie [1] ausführt, Gl. (3.18b) in manchen Anwendungen ebenfalls nicht erfüllt. Daß der Pearson'sche Korrelationskoeffizient Gl. (3.18c) nicht erfüllt, kann daraus gesehen werden, daß zwei Attributvektoren eine Korrelation von 1.0 haben können, und trotzdem nicht identisch sind. Angenommen seien z.B. die Attributvektoren  $\underline{y}_1 = (100.0, 180.0, 9.8, 220.0)^T$  und  $\underline{y}_2 = (137.0, 258.9, 13.4, 301.4)^T$ , die PS-Zahlen, maximale Geschwindigkeiten, durchschnittliche Benzinverbräuche und Nenndrehmomente zweier unterschiedlicher Autos beschreiben. Der Pearson'sche oder empirische Korrelationskoeffizient ist jedoch gleich 1.0.

Trotzdem sind Korrelationskoeffizienten weit verbreitet und besonders robust bei ihrer Anwendung in Cluster-Algorithmen.

### 3.4.3 Assoziationskoeffizienten und Übereinstimmungsmaße

Assoziationskoeffizienten [42] dienen dazu, Ähnlichkeiten zwischen Vektoren mit binären Komponenten festzustellen, während Übereinstimmungsmaße kategorische Beobachtungen vergleichen, z.B. Identitätsdeklarationen.

Gegeben seien zwei Vektoren  $\underline{y}$  und  $\underline{z}$  mit ihren Komponenten  $y_i$  und  $z_i$ , die entweder 1 oder 0 sein können. Die binären Komponenten repräsentieren die Anwesenheit ( $y_i$  bzw.  $z_i$  gleich 1) bzw. die Abwesenheit ( $y_i$  bzw.  $z_i$  gleich 0) eines Faktors. [1] beschreibt die Assoziationskoeffizienten zur Bestimmung der Ähnlichkeit zwischen  $\underline{y}$  und  $\underline{z}$ :

1. einfacher Match-Koeffizient,
2. Jaccard-Koeffizient
3. Gower'scher Koeffizient.

Gegeben sei die folgende Assoziationstabelle Gl. (3.21):

$\underline{y} \downarrow, \underline{z} \rightarrow$	1	0
1	a	b
0	c	d

Dabei repräsentiert a die Anzahl der Komponenten von  $\underline{y}$  und  $\underline{z}$ , die gleichzeitig vorhanden sind, b die Anzahl der Komponenten von  $\underline{z}$ , die nicht vorhanden sind, wenn die entsprechenden Komponenten von  $\underline{y}$  vorhanden sind, c die Anzahl der Komponenten von  $\underline{z}$ , die präsent sind, wenn die entsprechenden Komponenten von  $\underline{y}$  dies nicht sind und d die Anzahl der Komponenten von  $\underline{y}$  und  $\underline{z}$ , die gleichzeitig nicht präsent sind. Vollkommene Übereinstimmung zwischen  $\underline{y}$  und  $\underline{z}$  würde dann existieren für  $a=d=n$  und  $b=c=0$ . Der Match-Koeffizient wird definiert als:

$$s = \frac{a + d}{a + b + c + d} \quad (3.22)$$

Der Match-Koeffizient nimmt Werte zwischen 0 und 1 an, wobei  $s = 1$  Übereinstimmung zwischen  $\underline{y}$  und  $\underline{z}$  anzeigt und  $s = 0$  vollkommene Nichtübereinstimmung.

Angenommen seien z.B. die beiden Vektoren  $\underline{y} = (1,0,0,1,1,1)^T$  und  $\underline{z} = (1,0,0,1,1,1)^T$ . Die Assoziationstabelle ergibt sich dann wie folgt:

$\underline{y} \downarrow, \underline{z} \rightarrow$	1	0
1	4	0
0	0	2

Der Match-Koeffizient wird dann als  $s = \frac{4 + 2}{4 + 0 + 0 + 2} = 1.0$  berechnet und bestätigt die Übereinstimmung der beiden Vektoren.

Eine Variation dieses Ähnlichkeitskoeffizienten ist der Jaccard-Koeffizient:

$$s = \frac{a}{a + b + c} \quad (3.23)$$

der den Gebrauch von Verbundabwesenheiten einer Variablen bei der Berechnung von Ähnlichkeit vermeidet (keine Berücksichtigung des Wertes der Zelle d). Bei der Ähnlichkeitsberechnung wird dadurch eine Falschdeklaration für den Fall zweier Variablen, denen beiden dieselben Eigenschaften fehlen, ausgeschlossen.

Der Gower'sche Koeffizient [22] stellt eine Verallgemeinerung des Jaccard-Koeffizienten dar, die den gleichzeitigen Gebrauch von Variablen unterschiedlicher Skalierung erlaubt:

$$s_{ij} = \frac{\sum_{k=1}^v p_{ijk} \cdot w_k(x_{ik}, x_{jk})}{\sum_{k=1}^v d_{ijk} \cdot w_k(x_{ik}, x_{jk})} \quad (3.24)$$

Dabei steht  $s_{ij}$  für die Ähnlichkeit, wenn zwei Datensätze  $i$  und  $j$  auf eine Eigenschaft  $k$  hin untersucht werden und eine Punktzahl  $p_{ijk}$  zugewiesen bekommen: 0, wenn  $i$  und  $j$  als unterschiedlich zu betrachten sind, und eine positive Zahl oder 1, wenn sie einen gewissen Übereinstimmungsgrad bzw. Ähnlichkeit besitzen. Die Möglichkeit, überhaupt Vergleiche anzustellen, kann durch das Kroneckersymbol  $d_{ijk}$  beschrieben werden. Es ist 1, wenn die Eigenschaft  $k$  für  $i$  und  $j$  verglichen werden kann, und sonst 0. Wenn  $d_{ijk} = 0$ , dann ist  $p_{ijk}$  unbekannt, wird aber i.A. zu 0 gesetzt. Wenn  $d_{ijk} = 0$  für alle Eigenschaften gilt, dann ist  $s_{ij}$  un-

definiert. Sind alle Vergleiche möglich, dann ist  $\sum_{k=1}^v d_{ijk} = v$ , der Gesamtzahl der Eigenschaften

ten. Ist dies nicht der Fall, reduziert sich  $\sum_{k=1}^v d_{ijk}$  auf die Anzahl der Eigenschaften, die vergli-

chen werden können. Die Möglichkeiten der Gewichtung einzelner Eigenschaften sind zahlreich. Die Form in Gl. (3.24) sieht die Gewichte als eine Funktion des Resultates der Werte  $x_{ik}$  und  $x_{jk}$  der Sätze  $i$  und  $j$  der verglichenen Eigenschaft  $k$ . So können Unterschiede in einer Eigenschaft z.B. höher als Übereinstimmung bewertet werden, oder der Übereinstimmung zwischen seltenen Eigenschaften könnte mehr Gewicht zugemessen werden als häufiger vorkommenden Eigenschaften.



Für rein binäre Daten ist der Gower'sche Koeffizient identisch mit dem Jaccard-Koeffizient.

Der Vergleich kategorischer Variablen ist ebenfalls mit einer Reihe von Übereinstimmungsmaßen möglich, von denen einige in [42] beschrieben sind.

Zur Verdeutlichung des Vergleichs kategorischer Variablen seien zwei Sensoren angenommen, die unabhängig Einzelheiten bzw. Daten in eine von  $i$  sich gegenseitig ausschließenden Kategorien einordnen. Es sei  $P_{ij} = P\left(\left\{\mathbf{w}: A \rightarrow K_i \wedge B \rightarrow K_j\right\}\right)$  die unbekannte Wahrscheinlichkeit, daß Sensor A ein Objekt zu Kategorie  $i$  gehörig klassifiziert, während Sensor B dasselbe Objekt zu Kategorie  $j$  gehörig klassifiziert. Dann repräsentiert:

$$\Theta_1 = \sum_{i=1}^I P_{ii} \quad (3.25)$$

die Übereinstimmung zwischen den Sensoren. Wenn die Sensoren unabhängig sind, ist der Anteil von Fällen, in denen sie rein zufällig übereinstimmen, gegeben durch:

$$\Theta_2 = \sum_{i=1}^I P_{i+} \cdot P_{+i} \quad (3.26)$$

mit der Wahrscheinlichkeit  $P_{i+} = P\left(\left\{\mathbf{w}: A \rightarrow K_i\right\}\right)$  dafür, daß Sensor A die Beobachtungen zu Kategorie  $i$  zuordnet, unabhängig davon, wie Sensor B klassifiziert, und  $P_{+i} = P\left(\left\{\mathbf{w}: B \rightarrow K_i\right\}\right)$  der Wahrscheinlichkeit dafür, daß Sensor B die Beobachtungen zu Kategorie  $i$  zuordnet, ebenfalls unabhängig vom Verhalten von Sensor A.

Als Beispiel seien zwei Sensoren A und B gegeben, die 100 Beobachtungen in eine von drei Auto-Kategorien einordnen, Bild 3.6. Danach haben z.B. Sensor A und Sensor B in 28 Fällen übereinstimmend geurteilt, daß das beobachtete Objekt ein Kleinwagen war.

Die korrespondierenden Wahrscheinlichkeiten für diese Kategorien seien gegeben in Bild 3.7. In diesem Beispiel ist die Wahrscheinlichkeit, daß Sensor A seine Beobachtungen als Kleinwagen klassifiziert, gleich 0.3. Dieser Wahrscheinlichkeitswert kommt zustande unter der Bedingung, daß die Klassifikationen durch Sensor B als nicht maßgeblich betrachtet werden.

$A \Rightarrow$	<b>Kleinwagen</b>	<b>Mittelklasse</b>	<b>Luxusklasse</b>	$\wedge_{i+}$
$B$				
$\Downarrow$				
<b>Kleinwagen</b>	28	2	0	30
<b>Mittelklasse</b>	10	25	5	40
<b>Luxusklasse</b>	2	8	20	30
$\wedge_{+i}$	40	35	25	100

Bild 3.6: KFZ-Klassifikation durch zwei Sensoren

$A \Rightarrow$	<b>P(Kleinwagen)</b>	<b>P(Mittelklasse)</b>	<b>P(Luxusklasse)</b>	$P_{i+}$
$B$				
$\Downarrow$				
<b>P(Kleinwagen)</b>	0.28	0.02	0.00	0.30
<b>P(Mittelklasse)</b>	0.10	0.25	0.05	0.40
<b>P(Luxusklasse)</b>	0.02	0.08	0.20	0.30
$P_{+i}$	0.40	0.35	0.25	1.00

Bild 3.7: Wahrscheinlichkeiten von KFZ-Klassifikationen durch zwei Sensoren

Die Zahl 0.3 wird bestimmt durch die Summation über die Einzelwerte der Kleinwagen-Reihe für Sensor A. Die Wahrscheinlichkeit dafür, daß Sensor B die Beobachtungen in die Kategorie „Kleinwagen“ einordnet - ohne Berücksichtigung der Klassifizierung durch Sensor A - ist 0.4, wobei hier der numerische Wert durch Summation über die Einzelwerte der Kleinwagen-Spalte für Sensor B entsteht. Der Wert für die übereinstimmende Klassifikation durch beide Sensoren ist  $\Theta_1 = 0.73$  ( $=0.28+0.25+0.20$ ) und der Anteil der Fälle, in denen die Sensoren rein zufällig übereinstimmen, nimmt den Wahrscheinlichkeitswert 0.335 an ( $=0.3*0.4+0.4*0.35+0.3*0.25$ ). Ein weiteres Ähnlichkeitsmaß ist:

$$K = \frac{\Theta_1 - \Theta_2}{1 - \Theta_2} \quad (3.27)$$

K stellt ein Maß für die Übereinstimmung zwischen zwei Sensoren dar, die die Klassifikation von Objekten versuchen und korrigiert zufällige Übereinstimmung. Der Wert von K reicht von  $-\frac{\Theta_2}{1-\Theta_2}$  bis 1 (Übereinstimmung für  $K = \Theta_1 = 1$ ).

Die Wahrscheinlichkeiten  $P_{ij}$  sind i.A. unbekannt und werden daher meist durch empirische oder geschätzte Werte, d.h. die Werte, die im Rahmen des Meßprozesses gewonnen werden können, ersetzt bzw. durch solche Werte, in die mehrere gemittelte Beobachtungen desselben Sensors einfließen.

### 3.4.4 Korrelationsmaße

Zur Bearbeitung von Sensorfusionsproblemen werden verschiedene Ad-Hoc-Assoziationsmaße verwendet. In [78] wird der Gebrauch von Korrelationsmaßen zur Bestimmung der Ähnlichkeit zwischen Datensätzen mit unterschiedlicher Information beschrieben. Z.B. können zwei ELINT-Datensätze Schätzwerte des Senderortes, der Modulation, der Pulsbreite, der Frequenz, der PRI und anderer Parameter enthalten. Die Aufgabe besteht dann darin, zu entscheiden, ob die beiden Datensätze dieselbe physikalische Betrachtungseinheit beschreiben. In [76] wird ein Korrelationsmaß (Measure of Correlation, MOC) als:

$$MOC = \frac{\sum_{i=1}^N \mathbf{d}_i \cdot W_i \cdot FOM_i}{\sum_{i=1}^N \mathbf{d}_i \cdot W_i} \quad (3.28)$$

definiert. Dabei bezeichnet  $N$  die Anzahl der Komponenten jeden Datensatzes,  $W_i$  ist ein A-Priori-Gewichtungsfaktor ( $0 < W_i < 1$ ) und  $FOM_i$  (Figure of Merit) ist ein weiterer Gewichtungsfaktor für die  $i$ -te Komponente des aufgezeichneten Datensatzes. Das FOM-Gewicht ist ein funktionales Assoziationsmaß mit numerischen Werten zwischen 0 und 1. Die Größe  $\mathbf{d}_i$  stellt einen Faktor dar, der 1 ist, wenn zwei Einzelheiten in dem Datensatz gegeben sind, und sonst 0. Die FOMs werden auf Basis der Eigenschaften des einzelnen Datensatzes ausgewählt. Für kontinuierliche Variablen wie den Ort ist eine skalierte Verteilung für den Versatzvektor

(Innovation) eine geeignete FOM, für skalare numerische Attribute mit Gauß'scher Verteilung kann eine skalierte Chi-Quadrat-Verteilung nützlich sein.

Es gibt eine Klasse numerischer Attribute, bei denen die Unsicherheit beschrieben wird durch Angabe eines Wertebereiches. Eine geeignete FOM für diese Klasse ist das Kreuzkorrelogramm der beiden Intervalle. Als Ergebnis liefert dieser Prozeß eine FOM mit dem Wert 1, wenn die Intervalle gleich sind. So wie die Intervalle ungleich werden, vermindert sich der FOM-Wert linear auf 0 für den Fall, daß keine Überschneidung der beiden Intervalle auftritt.

Alphanumerische Attribute wie z.B. Ausrüstungsbezeichnungen erfordern einen anderen Ansatz. Im einen Extrem kann der Vergleich durch einen Boole'schen Test durchgeführt werden (FOM gleich 1 für exakte Überdeckung, sonst 0), im anderen auf der Ebene einzelner Buchstaben z.B. mit Hilfe eines Match-Maßes wie in Gl. (3.22).

Die Art der Kombination von FOMs zur Bildung eines Korrelationsmaßes wird empirisch entwickelt. Eine gewichtete Summe wie in Gl. (3.28) wird häufig wegen ihrer Einfachheit verwendet, andere Formulierungen benutzen gewichtete Produkte.

### **3.4.5 Auswahl einer Assoziationsmetrik**

Die Auswahl eines geeigneten Assoziationsmaßes beeinflusst die Möglichkeit, Variablen entsprechend ihrer physikalischen Ursache oder Betrachtungseinheit zuzuordnen. Die Auswahl hängt ab von der Art der zu vergleichenden Variablen, der Verfügbarkeit von A-Priori-Information und Modellen und natürlich auch von ihrer Handhabbarkeit. Kontinuierliche Variablen können mit Abstandsmaßen oder Korrelationskoeffizienten verglichen werden. Der Vergleich binärer oder deklarativer Variablen (Klassifikation) geschieht mit Hilfe von Assoziationskoeffizienten. Auf Nominalvariablen werden Übereinstimmungsmaße, z.B. Gl. (3.27), angewendet. Datensätze mit mehreren Komponenten werden mit Ad-Hoc-Korrelationsmaßen und FOMs behandelt. Eine allgemeine Anleitung zur Verwendung dieses oder jenes Maßes könnte jedoch nur rein willkürlich sein.

Das Thema der Assoziationsmaße berührt sehr stark das Feld der Mustererkennung. Dabei gibt es wie bei der Assoziation keinen Ersatz für unzweideutige Variablen, d.h. wenn zwei Variablen so eng nebeneinander liegen, daß sie mehrdeutig werden, wird auch die geschickteste Auswahl eines Assoziationsmaßes diese Mehrdeutigkeit nicht beseitigen können. Stattdessen müssen andere Datenquellen wie Identitäts- oder Verhaltensinformationen herangezogen werden.

Als Fazit ist zu ziehen, daß die Auswahl eines Assoziationsmaßes zwar wichtig ist, jedoch keinen korrekten Assoziationsprozeß garantieren kann.

### 3.5 Zuweisung

Der letzte Schritt des Assoziationsprozesses ist die tatsächliche Zuweisung von Beobachtungen zu bestimmten Beobachtungen. Dieser Schritt besteht in dem Aufruf der Entscheidungslogik, um festzustellen, ob zwei Beobachtungen (oder eine Beobachtung und ein zu prüfender Track) zusammengehören bzw. dieselbe zugrundeliegende physikalische Betrachtungseinheit oder denselben Prozeß repräsentieren.

Zur Zuweisung sind viele Methoden entwickelt worden. Der folgende Abschnitt faßt die wichtigsten Auswahlkriterien zur Entwicklung einer Zuweisungsstrategie zusammen. Die Diskussion konzentriert sich auf die Datenzuweisung für Aufgaben des Multitarget-Tracking. Die behandelten Techniken sind aber ebenso für andere Applikationen anwendbar.

Die Entwicklung einer Zuweisungsstrategie umfaßt vier grundlegende Kriterien:

1. Auswahl einer Metrik zur Bestimmung der Ähnlichkeit zwischen Beobachtungen
2. Bestimmung der Anzahl der Scans, die genutzt werden müssen bzw. können
3. Treffen einer Aussage, ob eine Beobachtung exklusiv einer anderen Beobachtung bzw. einem Track zuzuordnen ist
4. Bestimmung der Anzahl und der Art der Hypothesen, die zu berücksichtigen sind.

Abschnitt 3.4 befaßte sich mit Assoziationsmetriken und deren Auswahl. Abschnitt 3.5 behandelt die anderen drei Kriterien.

#### 3.5.1 Anzahl der Scans

Nach der Auswahl eines Assoziationsmaßes besteht die primäre Frage bei der Entwicklung einer Zuweisungsstrategie in der Bestimmung der Anzahl der zugelassenen Scans. Die Möglichkeiten reichen von Einfach-Scans über Mehrfach-Scans bis zur Batch-Prozessierung.

Ein Einfach-Scan-Ansatz prozessiert jeden Datenpunkt in der Reihenfolge des Eintreffens an einem Datenprozessierungssystem. Dieser Ansatz verwertet die Beobachtungen damit vollständig, d.h. mit jeder Beobachtung wird eine Entscheidung getroffen. Die Zuweisung wird unwiderruflich, d.h. daß, nachdem eine Zuweisung geschehen ist, die Zuweisungsentscheidung weder wieder in Frage gestellt noch revidiert wird.

Der in Bild 3.4 dargestellte Zuweisungsprozeß zeigt einen Einfach-Scan-Ansatz. In einem Mehrfach-Scan-System werden die Daten sequentiell prozessiert. Als Besonderheit erlaubt es dieser Ansatz jedoch, Datenzuweisungen bis zu  $N$  Scans nachzukontrollieren, d.h. nachdem

$N$  neue Beobachtungen verarbeitet worden sind. Diese Nachverarbeitung dient der Kontrolle der Effektivität der Zuweisungen. Ein solcher Ansatz ist besonders dann sinnvoll, wenn die Aufgabe darin besteht, neue Tracks für ein Tracking-Problem zu initiieren. Eine Beobachtung, die zunächst wie ein Fehlalarm erscheint, kann sich später als Startpunkt eines neuen Tracks herausstellen. Die Nachteile eines Mehrfach-Scan-Ansatzes liegen in der Komplexität und in der erhöhten benötigten Rechenleistung für ein solches System.

Wenn der Wert von  $N$  für ein Mehrfach-Scan-System über alle Grenzen wachsen darf, wird der Mehrfach-Scan-Ansatz zu einem Batch-Ansatz, d.h. alle Daten werden erst nach Erhalt der letzten Beobachtung verarbeitet. Zuweisungsentscheidungen werden iterativ hypothetisiert und anschließend für alle Daten ausgewertet. Jede mögliche Assoziationskombination kann ausgiebig getestet und in ihren Konsequenzen untersucht werden, aber ein praktikablerer Ansatz maximiert eine übergeordnete Funktion, z.B. könnte eine Bewertungsfunktion entwickelt werden, die ein übergeordnetes Maß zur Verfügung stellt, das beschreibt, wie gut Daten assoziiert wurden, z.B. mit anderen Beobachtungen.

Beispiele solcher Maße sind:

- a) die A-Priori-Wahrscheinlichkeit einer Verbundwahrscheinlichkeit von zu Tracks zugeordneten Beobachtungen (Maximum-A-Posteriori-Wahrscheinlichkeit, MAP)
- b) eine Wahrscheinlichkeitsfunktion, die die Wahrscheinlichkeit schätzt, daß die aufgetretenen Beobachtungsresiduen die erwartete Verteilung - basierend auf Annahmen bzgl. des Beobachtungsprozesses - aufweisen, oder
- c) andere Bewertungsschemata.

Ein Batch-Ansatz ermöglicht optimale Datenzuweisungen auf Kosten der Wartezeit, bis alle Daten beobachtet sind. Eine solche Strategie ist daher nicht praktikabel für dynamische Tracking-Probleme wie z.B. die Verfolgung eines sich bewegenden Zieles durch mehrere Sensoren.

### **3.5.2 Mehrfach- oder Einzelzuweisung**

Eine zweite Basisentscheidung bei der Entwicklung einer Zuweisungsstrategie ist die Auswahl, ob eine Beobachtung zu einer einzigen anderen Beobachtung gehörend zugeordnet werden kann oder ob erlaubt wird, eine Beobachtung mit mehreren zu prüfenden Beobachtungen zu assoziieren. Bei dem ersten Ansatz (Hard Decision) wird angenommen, daß eine Beobachtung nur einer einzigen physikalischen Gegebenheit zugeordnet werden kann. In einer Tracking-Anwendung besteht damit die Annahme, daß eine Beobachtung zu einem einzigen Ziel gehört.

Eine für eine solche Zuordnung typische Vorgehensweise ist, die Beobachtung der nächsten daneben liegenden Beobachtung bzw. dem entsprechenden Track zuzuweisen (Nearest Neighbour Ansatz). Ein alternativer „Soft Decision“-Ansatz wurde von Bar Shalom u.a. entwickelt [5, 19]. Darin werden eine probabilistische Datenassoziationsstrategie (PDA) und eine Verbundwahrscheinlichkeitsdatenassoziation (JPDA) definiert. Die PDA-Vorgehensweise wird für einzelne Tracks genutzt. Alle Messungen innerhalb eines begrenzenden Fensters werden als potentiell richtige Beobachtungen bewertet. Für jede Kombination Beobachtung-Track wird mit der Bayes'schen Regel eine A-Posteriori-Wahrscheinlichkeit berechnet. Dies repräsentiert die aktualisierte Wahrscheinlichkeit eines Tracks, wenn eine neue Beobachtung dazugekommen ist. Die Menge aller möglichen Beobachtungen wird einem Track zugeordnet, der mit der A-Posteriori-Wahrscheinlichkeit gewichtet ist. Die JPDA-Methode dehnt dieses Konzept auf alle angrenzenden Tracks und gültigen Messungen aus. Damit kann eine einzige Messung so zugeordnet werden, als gehörte sie zu Mehrfach-Tracks in einer Umgebung mit mehreren Zielen. Die JPDA wurde entwickelt für ein passives Sonar-Tracking-Problem mit mehreren Sensoren und Zielen, die nicht vollständig von einem Einzelsensor beobachtet werden können. Der PDA-Algorithmus nimmt an, daß jedes Ziel von allen anderen Zielen isoliert ist: Falschmessungen in einem begrenzenden Fenster werden als unabhängige Rauschpunkte einer Poisson-Verteilung, und die Entdeckung eines Zieles als ein unabhängiges Ereignis modelliert. Die Poisson-Annahme ergibt meist akzeptable Ergebnisse. Die Annahme führt jedoch nicht zum Ziel, wenn sie auf ein von einem oder mehreren Sensoren entdecktes weiteres Ziel trifft. In diesem Fall ist das Ziel meist verfolgbar und der Algorithmus, der in [19] mit einem Extended-Kalman-Filter zusammenarbeitet, kann erweitert werden, um die diskrete Interferenz zu korrigieren, indem die Posteriori-Wahrscheinlichkeiten im Verbund über Cluster von Zielen berechnet werden.

Wenn analog dazu eine solche Vorgehensweise für das Identitätsassoziationsproblem (Bild 3.3) gewählt würde, dann würde Beobachtung  $y_2$  sowohl dem Strahler der Klasse A als auch dem Strahler der Klasse B zugeordnet. Ähnlich würde dann in Bild 3.1 Beobachtung  $y_2$  so zugeordnet, als gehörte sie zu den Objekten A und B.



### 3.5.3 Mehrfach- oder Einzelhypothese

Das erste in diesem Kapitel zur Datenassoziation eingeführte Beispiel betrachtet die Akquisition dreier neuer Beobachtungen  $\underline{y}_1$ ,  $\underline{y}_2$  und  $\underline{y}_3$ , die Positionsbeobachtungen von geographisch stationären Objekten darstellen. Für jede neue Beobachtung  $\underline{y}_i$  können vier Hypothesen aufgestellt werden:

1. Beobachtung  $\underline{y}_i$  ist mit dem bekannten Objekt A assoziiert
2. Beobachtung  $\underline{y}_i$  ist mit dem bekannten Objekt B assoziiert
3. Beobachtung  $\underline{y}_i$  repräsentiert ein neues Objekt
4. Beobachtung  $\underline{y}_i$  stellt einen durch Rauschen verursachten Fehlalarm dar

Eine fundamentale Wahl für das Design einer Zuweisungsstrategie betrifft die Frage, wie diese Hypothesen zu behandeln sind. Ein Ansatz besteht darin, jede Beobachtung  $\underline{y}_i$  zu verarbeiten, sobald sie bereitsteht, die alternativen Hypothesen zu prüfen, eine als wahr auszuwählen und dann fortzufahren. Wenn die empfangene Beobachtung z.B. als aus Rauschen resultierend zu betrachten ist, dann sind diese Daten als Falschalarm zu ignorieren. Wenn dagegen die Beobachtung  $\underline{y}_i$  höchstwahrscheinlich mit Objekt A assoziiert ist (Hypothese 1 wahr), dann werden die Daten durch Estimationstechniken kombiniert und die Verarbeitung geht weiter. Diese sequentielle Auswertung und Auswahl alternativer Hypothesen wird „Single Hypothesis Estimation“ genannt, d.h., obwohl mehrere alternative Hypothesen ausgewertet werden, wird nur eine Hypothese als wahr ausgewählt.

Eine alternative Assoziierungsstrategie sieht zunächst alle möglichen Hypothesen als potentiell wahr an und überprüft die Konsequenzen aus diesen Hypothesen mit der Ankunft neuer Beobachtungen. Damit wird eine größer werdende Menge von Hypothesenkombinationen generiert und ausgewertet. Diese Kombination von Hypothesen wird oft als Hypothesen-Baum bezeichnet. Assoziation durch Mehrfachhypothesen entwickelt einen Baum möglicher Hypothesen mit Bezug auf die Assoziation der Hypothesen und wertet die Konsequenzen dieser Hypothesen aus. Die Anzahl der zu behandelnden Hypothesen wächst mit der Anzahl der Beobachtungen und existierender bekannter Objekte. Um tatsächlich zu einem Ergebnis zu kommen, müssen unwahrscheinliche Zweige des Hypothesenbaumes frühzeitig entfernt werden, da sonst der potentielle Nutzen von der erforderlichen Rechenleistung zunichte gemacht wird.

### 3.6 Zusammenfassung

Kapitel 3 stellt eine Einführung in das Problem der Datenassoziation dar. Ein allgemeines Prozeßflußdiagramm für Einfach-Scans wurde in Bild 3.4 entwickelt. Einige wichtige Designauswahlkriterien wurden vorgestellt, zu denen die folgenden gehören:

1. Gating-Techniken: Methoden zur Eliminierung unwahrscheinlicher Assoziationen, um die Anzahl der zu berücksichtigenden Assoziationspaare zu reduzieren
2. Assoziationsmaße: Auswahl von Maßen zur Quantifizierung der Ähnlichkeit zwischen Beobachtungen
3. Zuweisungsprozeduren: Auswahl der Anzahl der Scans, Hypothesenverarbeitung

Eine erfolgreiche Datenassoziation sortiert Beobachtungen korrekt in Gruppen, wobei jede Gruppe Beobachtungen derselben physikalischen Gegebenheit bzw. eines Ereignisses repräsentiert. Assoziation kann auf positioneller Information, Identitätsinformation oder jeder parametrischen Messung basieren. In jedem realen Datenfusionssystem sind die Prozesse der Assoziation und der Estimation, die die assoziierten Daten kombinieren, miteinander verwoben und laufen interaktiv ab. Datenassoziation ist für die Anwendung von Estimationstechniken zur Datenfusion notwendig. Estimationstechniken ermöglichen die Aktualisierung der Zustandsschätzwerte des Assoziationsproblems. Das folgende Kapitel beschreibt den Estimationsprozeß und den Einfluß der Datenassoziation.

## 4. Estimationstechniken

### 4.1 Einleitung

In Kapitel 2 wurde eine Einführung in das Problem der Fusion multisensorieller parametrischer Daten zur Erzeugung eines verbesserten Schätzwertes des Zustandes eines Objektes gegeben.

Beispiele solcher Schätzprobleme sind:

1. Verwendung positioneller Datensätze wie Range- oder Radialgeschwindigkeit-Beobachtungen zur Bestimmung des Ortes einer stationären Betrachtungseinheit.
2. Tracking-Problem: Kombination positioneller Datensätze mehrerer Sensoren zur Bestimmung von Ort und Geschwindigkeit eines sich bewegenden Objektes als Funktion der Zeit.
3. Estimation der Charakteristika einer Betrachtungseinheit wie Größe oder Form aufgrund von Beobachtungsdaten.
4. Estimation der Parameter eines Modells (z.B. Polynomkoeffizienten), das Beobachtungsdaten beschreibt bzw. repräsentiert.

Für diese Beispiele geht es bei dem Estimationsproblem um den Versuch, den Wert eines Zustandsvektors (z.B. Position, Geschwindigkeit, Polynomkoeffizienten) zu finden, der in einem mathematisch definierten Sinn am besten zu den Beobachtungsdaten paßt. Estimationsprobleme können dynamisch sein, wobei der Zustandsvektor in Abhängigkeit der Zeit variiert, oder statisch, wobei der Zustandsvektor konstant über der Zeit ist.

Dieses Kapitel führt in die Estimationsproblematik ein und entwickelt spezifische Lösungsansätze. Die Kovarianzfehleranalyse als verwandtes Thema wird dabei auch behandelt. Der Einfachheit halber sei dabei angenommen, daß die dazu in Bezug stehende Datenassoziationsproblematik, die in Kapitel 3 behandelt wird, mit den bisher dargestellten Methoden gelöst sei, d.h. es sei angenommen, daß die Beobachtungsdaten bestimmten Gruppen zugeordnet wurden, wobei jede Gruppe zu einer bestimmten Betrachtungseinheit bzw. einem bestimmten Objekt gehört. Um eine Lösung - besonders bei Vielfachziel-Tracking-Problemen - zu erreichen, können Datenassoziation und Estimationstechniken praktisch nicht getrennt werden.

Ein großer Schritt vorwärts in der Geschichte der Estimation war die Entwicklung der Methode der kleinsten Quadrate durch Karl-Friedrich Gauß, um die Orbitalbewegungen von Planeten, Asteroiden und Kometen aus redundanten Datensätzen zu bestimmen. Das Vorliegen redundanter Datensätze bezieht sich dabei auf eine Situation, in der mehr Beobachtungen ver-

füßbar sind als das Minimum dessen, das notwendig zur Erreichung einer Lösung wäre. Techniken der Himmelsmechanik zur Bestimmung orbitaler Parameter aus minimalen Datensätzen werden als Initial-Orbit- oder Minimum-Data-Set-Techniken bezeichnet. Gauß fand die Methode der kleinsten Quadrate 1795 und veröffentlichte eine Beschreibung dieser Technik im Jahr 1809. Unabhängig davon fand auch Legendre die Methode der kleinsten Quadrate und veröffentlichte seine Ergebnisse 1806, woraus eine heftige Kontroverse bzgl. des geistigen Eigentums entstand. Gauß ist aber nicht nur die Erfindung der Methode der kleinsten Quadrate zu verdanken, sondern auch die Einführung moderner Konzepte wie:

1. Beobachtbarkeit: Behandlung der Fragen wieviele und welche Beobachtungsarten notwendig sind, um einen Schätzwert eines Zustandsvektors zu entwickeln.
2. Dynamische Modellierung: Die Notwendigkeit genauer Bewegungsgleichungen zur Beschreibung eines Zustandsvektors über der Zeit.
3. A-Priori-Schätzwert: Die Rolle eines Startwertes eines Zustandsvektors zur Erreichung einer Lösung.
4. Beobachtungsrauschen: Wahrscheinlichkeitstheoretische Interpretation von Beobachtungsrauschen.

Zu den weiteren historischen Entwicklungen der Estimationstheorie gehören Fisher's wahrscheinlichkeitstheoretische Interpretation der „Least Squares“-Methode und die Definition des „Maximum Likelihood“-Ansatzes [8], Wiener und Kolmogorov's Entwicklung der „Linear Minimum Mean Square Error“-Methode und Kalman's Formulierung einer zeitdiskreten rekursiven „Minimum Mean Squares“-Filtertechnik [45].

Einen Überblick des Estimationsproblems zeigt Bild 4.1. Die Situation ist für ein positionelles Fusionsproblem dargestellt. Eine Reihe von Sensoren beobachten Parameter wie Azimut, Elevation, Range- oder Range-Rate. Diese Parameter stehen in Beziehung zu dynamischer Position und Geschwindigkeit einer Betrachtungseinheit. Diese Beziehungen seien durch die entsprechenden Beobachtungsgleichungen gegeben. Für jeden einzelnen Sensor sorgt eine Datenangleichungsfunktion für die Transformation der entsprechenden Rohdaten in ein standardisiertes Einheitensystem und ein ebensolches Referenzkoordinatensystem. Ein Assoziationsprozeß gruppiert die Beobachtung entsprechend ihrer Bedeutung, wobei jede Gruppe die Beobachtungen eines physikalischen Objektes oder eines Ereignisses repräsentiert. Die assoziierten Beobachtungen stellen Sammlungen von Beobachtung-zu-Beobachtung-Paaren dar bzw. Beobachtung-zu-Track-Paaren, die zusammengehören. Ein Estimationsprozeß verarbeitet die

Beobachtungen, um einen neuen bzw. verbesserten Schätzwert eines Zustandsvektors  $\underline{x}(t)$  zu erhalten, der am besten zu den beobachteten Daten paßt.

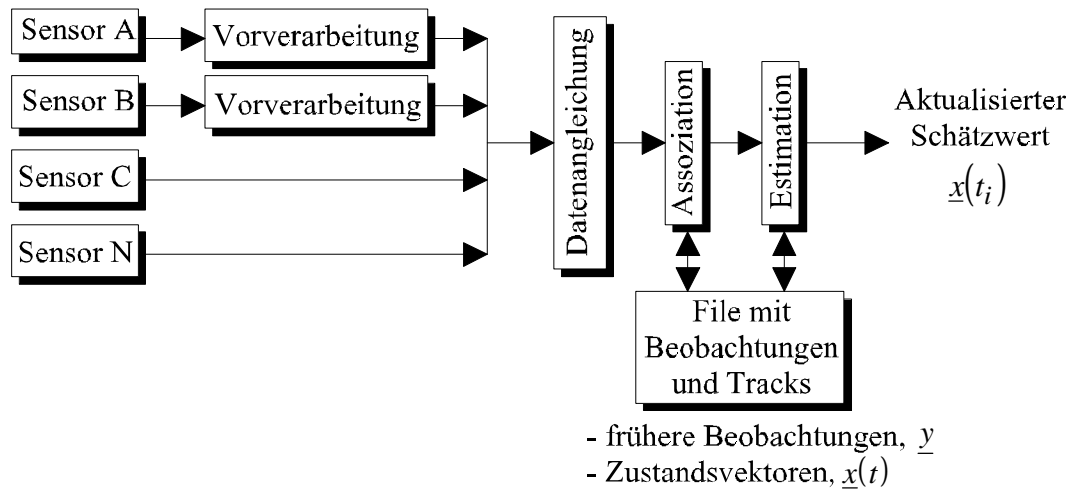


Bild 4.1: Positionelles Estimationsproblem

Das in Bild 4.1 dargestellte Estimationsproblem setzt eine zentralistische Architektur voraus, in der die Beobachtungen die Eingangsdaten eines Estimationsprozesses sind, während ein autonomer Fusionsansatz die Estimationsaufgaben - bildlich gesehen - eher parallelisiert ausführen würde und ein hybrider Ansatz einen Kompromiß beider Architekturen implizieren würde.

Die im folgenden beschriebenen Estimationstechniken sind bzgl. des Architekturansatzes relativ unabhängig voneinander. Sie sind jedoch anwendbar auf alle drei Verfahren.

## 4.2 Überblick der Estimationsalternativen

Eine Menge ist schon über Estimationstechniken geschrieben worden. Bild 4.2 faßt die Alternativen und Themen zusammen.

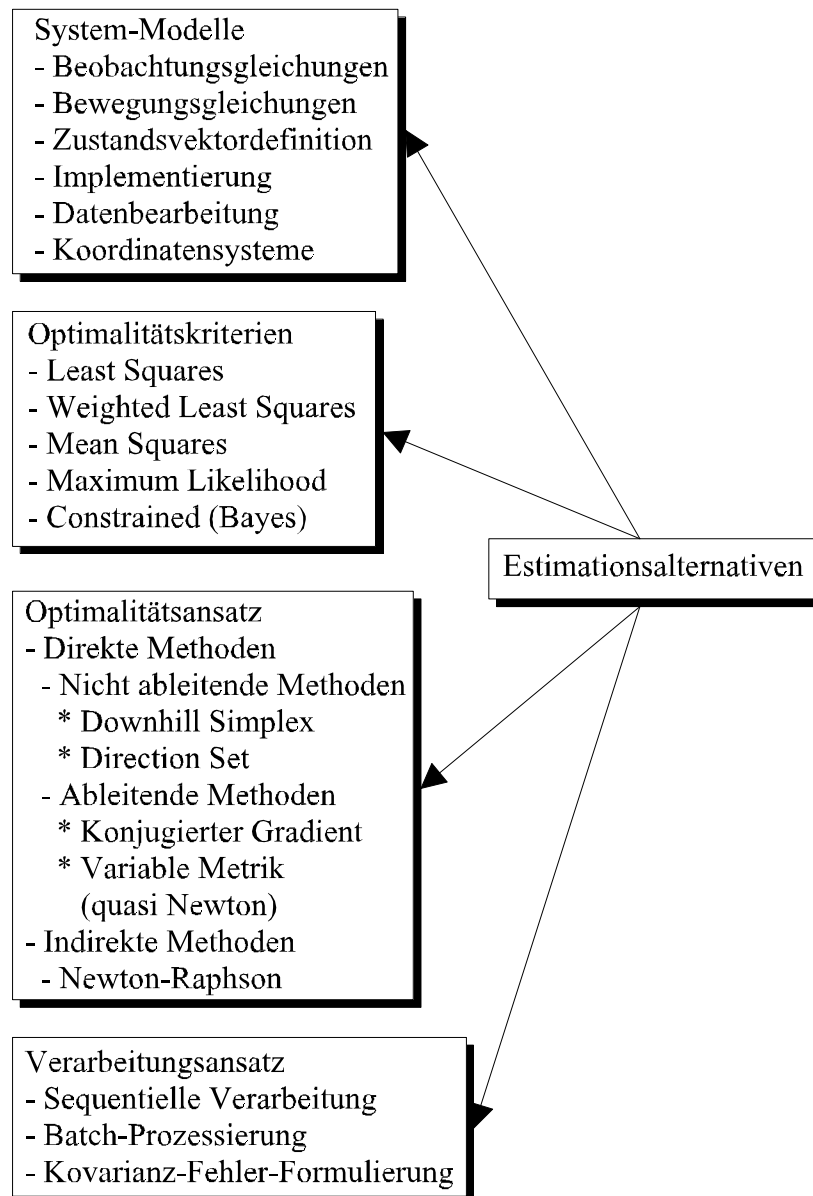


Bild 4.2: Überblick der Estimationsalternativen

Dazu gehören:

1. System-Modelle: Auswahl der das Problem definierenden Modelle; Bestimmung des gesuchten Zustandsvektors; Beziehung der Beobachtungen zum Zustandsvektor; Annahmen bzgl. des Beobachtungsprozesses (z.B. Rauschen)
2. Optimalitätskriterien: Auswahl der Gleichungen, die spezifizieren, daß ein Zustandsvektor „am besten“ zu einer Menge von Beobachtungen „paßt“
3. Optimalitätsansatz: Auswahl einer Methode zur Bestimmung des unbekanntes Wertes des Zustandsvektors, die dieses Kriterium erfüllt
4. Verarbeitungsansatz: Batch- oder sequentieller Modus

#### 4.2.1 System-Modelle für die Estimation

Ein Estimationsproblem wird durch die Spezifikation des Zustandsvektors, der Beobachtungsgleichungen, der Bewegungsgleichungen (für dynamische Probleme) und anderes wie die Auswahl von Datenbearbeitungsmethoden, Konvergenzkriterien und Koordinatensysteme definiert. Eine fundamentale zu treffende Auswahl ist die exakte Festlegung, welche Parameter zu schätzen sind bzw. die Beantwortung der Frage, welches die unabhängige Variable bzw. der Zustandsvektor  $\underline{x}(t)$  ist, dessen Wert gesucht ist. In der positionellen Estimation sind dies typischerweise die zur Lokalisierung eines Zieles bzw. einer Gegebenheit notwendigen Koordinaten. Beispiele dafür sind die geodätische Breite und Länge  $(f, l)$  eines Objektes auf der Oberfläche der Erde oder die dreidimensionalen kartesischen Koordinaten  $(x, y, z)$  eines Objektes in Bezug zu einem erdzentrierten inertialen Koordinatensystem. Für andere Estimationsaufgaben kann der Zustandsvektor als Daten darstellende bzw. charakterisierende Modellierungskoeffizienten (z.B. Polynomkoeffizienten) angegeben werden. Zustandsvektoren können auch aus Koeffizienten bestehen, die Sensorabweichungen und wichtige Systemparameter modellieren. Die Behandlung der Frage, was zu schätzen ist, hängt von der Definition ab, welche Parameter notwendig sind, um spätere Systemzustände zu bestimmen und welche Parameter aus den Beobachtungsdaten geschätzt werden können. Letzteres Thema betrifft die Beobachtbarkeit [45]. Beobachtbarkeit stellt die Frage, inwieweit es möglich ist, Komponenten eines Zustandsvektors aus den beobachteten Daten zu schätzen. Zwischen dem Element eines Zustandsvektors und den Daten kann eine nur schwache Beziehung bestehen, oder zwischen zwei oder mehr Komponenten eines Zustandsvektors herrscht starke Korrelation, wodurch es vorkommen kann, daß die Variation einer Komponente, um sie an die Beobachtungsdaten anzupassen, nicht un-

terscheidbar von einer Variation der anderen Komponenten ist. Eine allgemeine Regel bei der Festlegung eines Zustandsvektors ist, den minimalen Satz von Komponenten auszuwählen, der notwendig ist, das zu untersuchende System zu charakterisieren. Es ist oft eine große Versuchung, eher mehr als weniger Komponenten zu wählen. Dies geschieht besonders oft bei der Repräsentierung von Beobachtungsdaten durch Polynome. Polynome höherer Ordnung resultieren unweigerlich in kleineren Residuen (Differenz zwischen tatsächlichen Daten und dem die Daten darstellenden Polynomwert). Wenn  $N$  Beobachtungen verfügbar sind, paßt ein Polynom mit dem Grad  $N - 1$  exakt zu diesen Daten. Ein solches Polynom kann jedoch sehr unrealistisch und für prädiktive Zwecke ungeeignet sein. Ein vorsichtiger „Weniger ist mehr“-Ansatz ist bei der Auswahl der Komponenten eines Zustandsvektors i.A. anzuraten.

Der zweite Punkt in der Definition des Estimationsproblems ist die Spezifikation der Beobachtungsgleichungen. Diese Gleichungen verknüpfen den unbekanntem Zustandsvektor mit den vorhergesagten Beobachtungen, d.h. wenn  $\underline{x}(t)$  der Zustandsvektor und  $\underline{y}_i(t_i)$  eine Beobachtung sind, dann sagt:

$$\underline{z}(t_i) = \underline{g}[\underline{x}_j(t_i)] + \underline{n} \quad (4.1)$$

eine Beobachtung  $\underline{z}_i(t_i)$  voraus, die  $\underline{y}_i(t_i)$  genau entsprechen würde unter der Voraussetzung, daß die Werte des Zustandsvektors  $\underline{x}(t_i)$  und des Beobachtungsrauschens  $\underline{n}$  bekannt wären. Die Funktion  $\underline{g}[\underline{x}_j(t_i)]$  ist in Gl. (4.1) für die notwendige Koordinatentransformation zuständig, um auf Grundlage eines angenommenen Wertes des Zustandsvektors eine Beobachtung vorauszusagen. Wenn der Zustandsvektor nicht konstant über der Zeit ist, dann ist das Estimationsproblem dynamisch und erfordert die Hinzunahme einer Bewegungsgleichung, die den Zustandsvektor zur Zeit  $t_0$  in den Zeitpunkt der Beobachtung  $t_i$  überführt, d.h.:

$$\underline{x}(t_i) = \Phi(t_i, t_0) \cdot \underline{x}(t_0) \quad (4.2)$$

Die zeitliche Transformation des Zustandsvektors kann u.U. aus einer einfachen Taylorreihenentwicklung bis zum zweiten Glied bestehen:



$$\underline{x}(t_i) = \underline{x}(t_0) + \frac{d}{dt}[\underline{x}(t_0)] \cdot \Delta t + \frac{1}{2} \cdot \frac{d^2}{dt^2}[\underline{x}(t_0)] \cdot \Delta t^2 \quad (4.3)$$

mit  $\Delta t = t_i - t_0$ , wobei  $\frac{d}{dt}[\underline{x}(t_0)]$  die Geschwindigkeit zur Zeit  $t_0$  und  $\frac{d^2}{dt^2}[\underline{x}(t_0)]$  die Beschleunigung zur selben Zeit darstellen. Diese Umstände ergeben einen sehr simplen Fall. In den meisten Anwendungsfällen sind die beteiligten Bewegungsgleichungen jedoch sehr viel komplexer. Die Bewegungsgleichungen eines astrodynamischen Problems z.B. können nichtlineare Differentialgleichungen zweiter Ordnung beinhalten, in denen die Beschleunigung von der Position, der Geschwindigkeit und Richtung eines Körpers im Raum sowie den Positionen dritter Körper wie der Sonne oder des Mondes abhängen [36]. Die Lösung solcher differentieller Bewegungsgleichungen erfordert i.A. einen erheblichen Berechnungsaufwand unter Verwendung numerischer Techniken. Die Auswahl der Bewegungsgleichungen hängt letztlich von der Physik des Problems ab. Tracking-Probleme können Modelle erfordern, die die Berechnung der Bewegung in allen Variationen erfordern: Plattformbewegung, Variation des Ziels, Bewegung über ein Gelände oder durch das umgebende Medium usw. Zu berücksichtigen ist dabei auch ein Kompromiß zwischen dem Wunsch nach möglichst genauer Berücksichtigung aller Einflußfaktoren und dem davon abhängenden Berechnungsaufwand sowie dem Prädiktionzeitraum. Für kurzzeitige Beobachtungen (z.B. für ein Radar, welches ein Objekt nur über einen kurzen Zeitraum verfolgt) ist ein lineares Modell ausreichend.

Eng zusammenhängend mit dem Themenkomplex Bewegungsgleichungen ist die Auswahl eines Koordinatensystems, in dem die Berechnung erfolgen soll. Einige Koordinatensysteme sind sozusagen natürlich, d.h. sie sind besonders geeignet für eine bestimmte Anwendung. Erdzentrierte kartesische Koordinaten ermöglichen eine besonders einfache Formulierung der Gleichungen, die die Bewegung eines Satelliten um die Erde beschreiben. Im Gegensatz dazu müssen zur Beschreibung derselben Bewegung in einem topozentrischen Nicht-Inertial-System künstliche Beschleunigungskomponenten (aufgrund Coriolis-Kräften) einbezogen werden.

Eine ganze Bandbreite anderer bzw. weiterer Themen ist daneben bei der Definition von Systemmodellen zur Charakterisierung von Estimationsproblemen zu behandeln. Zu den besonderen Implementierungsthemen gehören die Ansätze zur (interaktiven) Datenmanipulation und -assoziation, Techniken zur Bestimmung der Konvergenz, Methoden zur Initialisierung des Estimationsprozesses (Startwertproblem).

## 4.2.2 Optimalitätskriterien

Mit der Aufstellung der Beobachtungsgleichungen, die einen Zustandsvektor mit vorhergesagten Beobachtungen verbinden, und der Bewegungsgleichungen für dynamische Probleme sind wichtige Voraussetzungen zur Lösung des Estimationsproblems gegeben.

Ein weiterer wichtiger Punkt ist die Definition dessen, was „am besten“ paßt. Es geht um die Bestimmung des Wertes eines Zustandsvektors  $\underline{x}(t)$ , der „am besten“ zu den beobachteten Daten paßt. Es bleibt dabei nur die Frage, was die Aussage „best fit“ konkret bedeutet, da „best fit“ ein unscharfer Ausdruck ist, der im Alltagssprachgebrauch subjektiver Deutung unterliegt. Es gibt dazu sehr viele Ansätze. Jede dieser Formulierungen verwendet eine Funktion der Residuen:

$$\underline{r}_i(t_i) = \underline{y}_i(t_i) - \underline{z}_i(t_i) \quad (4.4)$$

Dabei ist  $\underline{r}_i$  die vektorielle Differenz zwischen der  $i$ -ten Beobachtung  $\underline{y}_i$  zur Zeit  $t_i$  und der vorhergesagten Beobachtung  $\underline{z}_i$  zur Zeit  $t_i$ . Die vorhergesagte Beobachtung  $\underline{z}_i$  ist eine Funktion des Zustandsvektors  $\underline{x}(t_0)$ , s. Gl. (4.1). Damit ist  $\underline{r}_i$  ebenfalls eine Funktion von  $\underline{x}(t_0)$ .

Eine Reihe von Funktionen von  $\underline{r}$  sind definiert und auf Estimationsprobleme angewandt worden. Eine Zusammenfassung einiger dieser Kriterien gibt Tabelle 4.1. Kurz gefaßt wird eine Funktion ausgewählt, die ein umfassendes Maß dafür angibt, wie weit die vorhergesagten mit den tatsächlichen Beobachtungen übereinstimmen. Diese Funktion des unbekanntem Zustandsvektors  $\underline{x}(t)$  wird manchmal als Verlustfunktion bezeichnet, weil sie ein Maß für die „Strafe“ für einen nicht korrekten Wert von  $\underline{x}(t)$  angibt, d.h. wenn die Daten nicht gut zueinander passen. Der Zustandsvektor wird so lange variiert, bis die Verlustfunktion - je nach Definition - ein Minimum oder ein Maximum annimmt. Die Lösung des Estimationsproblems wird dann zu einem Optimierungsproblem. Die wahrscheinlich bekanntesten Definitionen sind die Least-Squares- (LS) und Weighted-Least-Squares-Formulierungen (WLS). Der WLS-Ausdruck kann in Vektornotation wie folgt geschrieben werden:

$$l(\underline{x}) = \underline{r}^T \cdot W \cdot \underline{r} \quad (4.5)$$

<b>Optimalitätskriterium</b>	<b>Beschreibung</b>	<b>Mathematische Formulierung</b>	<b>Kommentar</b>
<b>Least-Squares (LS)</b>	Minimierung der Summe der Residuen	$l(\underline{x}) = \underline{r}^T \cdot \underline{r}$	A-Priori-Wissen nicht notwendig
<b>Weighted-Least-Squares (WLS)</b>	Minimierung der Summe der gewichteten Quadrate der Residuen	Gl. (4.5)	identische Resultate im Vergleich zur Maximum Likelihood Estimation (MLE) für den Fall Gauß'schen Rauschens und Wichtungsmatrix gleich inverser Kovarianz
<b>Mean-Square-Error (MSE)</b>	Minimierung des Erwartungswerts des quadratischen Fehlers	Gl. (4.10)	Minimum-Kovarianz-Lösung
<b>Bayes'sche Weighted-Least-Squares (BWLS)</b>	Minimierung der Summe der gewichteten Quadrate der Residuen eingeschränkt durch A-Priori-Wissen von $\underline{x}$	Gl. (4.8)	Einschränkung der Lösung von $\underline{x}$ auf einen „vernünftigen“ Wert nahe dem A-Priori-Schätzwert $\underline{x}_0$
<b>Maximum-Likelihood-Estimate (MLE)</b>	Maximierung der multivariaten Wahrscheinlichkeitsverteilungsfunktion	Gl. (4.12)	Erlaubt Spezifikation der Wahrscheinlichkeitsverteilung für Rauschprozeß

Tabelle 4.1: Überblick der Optimalitätskriterien

bzw. gleichwertig:

$$l(\underline{x}) = \begin{bmatrix} (y_1 - z_1) \\ \vdots \\ (y_n - z_n) \end{bmatrix} \cdot \begin{bmatrix} w_{11} & 0 & 0 & \dots & 0 \\ 0 & w_{22} & 0 & \dots & 0 \\ & & \dots & & \\ & & & \dots & \\ 0 & 0 & 0 & \dots & w_{nn} \end{bmatrix} \cdot \begin{bmatrix} y_1 - z_1 \\ \vdots \\ y_n - z_n \end{bmatrix} \quad (4.6)$$

oder:

$$l(\underline{x}) = \sum_{i=1}^n (y_i - z_i) \cdot w_{ii} \cdot (y_i - z_i) \quad (4.7)$$

Die Verlustfunktion  $l(\underline{x})$  ist eine skalare Funktion von  $\underline{x}$ , die die Summe der mit  $W$  gewichteten quadrierten Beobachtungsresiduen darstellt. Die LS- bzw. WLS-Kriterien werden genutzt, wenn es keine Basis gibt, auf der Wahrscheinlichkeiten  $\underline{x}$  und  $\underline{y}$  zugeordnet werden können und wenn nur eine begrenzte Kenntnis bzgl. der Meßfehler besteht. Ein Spezialfall betrifft „Linear-Least-Squares“ (LLS), wobei die vorhergesagten Beobachtungen eine lineare Funktion des Zustandsvektors sind. In diesem Fall kann  $l(\underline{x})$  explizit durch einen geschlossenen Ansatz gelöst werden [58].

Eine Variation des WLS-Kriteriums ist die ebenfalls beschränkte Funktion [44]:

$$l(\underline{x}) = \underline{r}^T \cdot W \cdot \underline{r} + (\underline{x} - \underline{x}_0)^T \cdot P_{\Delta x_0} \cdot (\underline{x} - \underline{x}_0) \quad (4.8)$$

Dieser manchmal als Bayes'sches WLS-Kriterium bezeichnete Ausdruck grenzt die WLS-Lösung für  $\underline{x}$  so ein, daß nur eine Lösung nahe des A-Priori-Wertes von  $\underline{x}$ , d.h.  $\underline{x}_0$ , in Frage kommen kann.  $P_{\Delta x_0}$  repräsentiert dabei einen Schätzwert der Kovarianz von  $\underline{x}$ , die durch die folgende symmetrische Matrix gegeben ist:

$$P_{\Delta x_0} = \begin{bmatrix} \mathbf{s}_{x_1}^2 & r_{12} \cdot \mathbf{s}_{x_1} \cdot \mathbf{s}_{x_2} & \dots & r_{1n} \cdot \mathbf{s}_{x_1} \cdot \mathbf{s}_{x_n} \\ & & \dots & \\ & & & \mathbf{s}_{x_n}^2 \end{bmatrix} \quad (4.9)$$

Wenn die Komponenten von  $\underline{x}$  unabhängig sind, ist  $P_{\Delta x_0}$  eine diagonale Matrix. Das Bayes'sche Kriterium wird benutzt, wenn es Vorwissen über den Wert von  $\underline{x}$  und über die Unsicherheit, d.h. die Kovarianz, gibt. Die resultierende „optimale“ Lösung für  $\underline{x}$  liegt nahe dem A-Priori-Wert  $\underline{x}_0$ .

Die MSE-Formulierung minimiert den Erwartungswert des quadrierten Fehlers, d.h.:

$$l(\underline{x}) = \int_{-\infty}^{\infty} (\underline{x} - \hat{\underline{x}})^T \cdot W \cdot (\underline{x} - \hat{\underline{x}}) \cdot P_{\underline{x}/\underline{y}}(\underline{x} / \underline{y}_T) \cdot d\underline{x} \quad (4.10)$$

wobei  $P_{\underline{x}/\underline{y}}(\underline{x} / \underline{y}_T)$  die bedingte Wahrscheinlichkeit für den Zustandsvektor  $\underline{x}$  unter der Voraussetzung, daß die Beobachtungen  $\underline{y}$  mit dem Wert  $\underline{y}_T$  gegeben sind, angibt. Die Formulierung setzt  $\underline{x}$  und  $\underline{y}$  als Verbundwahrscheinlichkeitsvariablen voraus.  $\hat{\underline{x}}$  ist der bedingte Erwartungswert von  $\underline{x}$ :

$$\hat{\underline{x}} = \int_{-\infty}^{\infty} \underline{x} \cdot P_{\underline{x}/\underline{y}}(\underline{x} / \underline{y}_T) \cdot d\underline{x} \quad (4.11)$$

Das letzte Optimalitätskriterium in Tabelle 4.1 ist das Maximum-Likelihood-Kriterium [8]:

$$l(\underline{x}) = \prod_{i=1}^n l_i(n_i / \underline{x}) \quad (4.12)$$

Die Verlustfunktion  $l(\underline{x})$  ist hierbei eine multivariate Wahrscheinlichkeitsverteilung zur Modellierung des Beobachtungsrauschens  $\underline{n}_i$ . Sie stellt die bedingte Wahrscheinlichkeit dar, daß das Beobachtungsrauschen zu den Zeiten  $t_1, \dots, t_n$  die Werte  $\underline{n}_1, \dots, \underline{n}_n$  hat, wenn  $\underline{x}$  der tatsächliche bzw. wahre Wert des Zustandsvektors ist. Bei Verwendung des Maximum-Likelihood-Kriteriums wird der Wert von  $\underline{x}$  gesucht, der die Likelihoodfunktion  $l(\underline{x})$  maximiert [9].

Wenn die Meßfehler  $\underline{n}_i$  unabhängig von  $\underline{x}$  und normalverteilt um den Mittelwert 0 sind, dann ist  $l_i(\underline{n}_i / \underline{x})$  gegeben durch:

$$l_i(\underline{n}_i / \underline{x}) = \frac{1}{(2 \cdot \mathbf{p})^{\frac{m}{2}} \cdot |M_i|^{\frac{1}{2}}} \cdot \exp\left\{-\frac{1}{2} \cdot \underline{n}_i^T \cdot M_i^{-1} \cdot \underline{n}_i\right\} \quad (4.13)$$

Die Zahl  $m$  bezieht sich dabei auf die Anzahl der Komponenten des Beobachtungsvektors und  $M_i$  ist die Kovarianzmatrix zur Zeit  $t_i$ . Das MLE-Kriterium erlaubt die Postulierung nicht-Gauß'scher Verteilungen für die Rauschstatistiken.

Die Auswahl eines Optimalitätskriteriums hängt vom A-Priori-Wissen bzgl. des Beobachtungsprozesses ab. Die Verwendung des MLE-Kriteriums setzt voraus, daß die Wahrscheinlichkeitsverteilungen des Beobachtungsrauschens bekannt sind. Das MSE-Kriterium erfordert die Kenntnis einer bedingten Wahrscheinlichkeitsfunktion, während die Bayes'sche WLS-Methode A-Priori-Wissen der Varianz des Zustandsvektors bedingt. Unter den folgenden Bedingungen führt der Gebrauch der verschiedenen Kriterien zu einer identischen Lösung für  $\underline{x}$ :

1. Die Meß (Beobachtungs-) -fehler sind gaußverteilt mit dem Mittelwert 0.
2. Die Fehler  $\underline{n}_i$  zur Zeit  $t_i$  sind stochastisch unabhängig von den Fehlern  $\underline{n}_j$  zur Zeit  $t_j$ .
3. Die Gewichtung des WLS-Kriteriums ist die inverse Kovarianzmatrix von  $\underline{x}$ .

### 4.2.3 Optimalitätsansatz

Der Wert des Zustandsvektors  $\underline{x}$  kann auf verschiedene Weise bestimmt werden. Der folgende Abschnitt gibt einen Überblick über die Optimalitäts- bzw. Optimierungsansätze. Details und direkt verwendbare Programmlistings finden sich in [58]. Optimierungstechniken können grob - wie in Bild 4.3 dargestellt - in zwei Klassen eingeteilt werden.

Direkte Methoden versuchen den Wert von  $\underline{x}$  zu ermitteln, der das Optimierungskriterium (Suche nach einem  $\underline{x}$  so, daß die Verlustfunktion  $l(\underline{x})$  ein Extremum annimmt) erfüllt. Die dabei angewandten Techniken fallen in zwei Klassen: Ableitende Methoden erfordern die Kenntnis der Ableitung der Verlustfunktion nach  $\underline{x}$ , während die nichtableitenden Methoden

„nur“ die Möglichkeit zur Berechnung der Verlustfunktion bedingen. Geometrisch sind direkte Methoden „Hillclimbing“ (Maximum) oder „Downhill“ (Minimum).

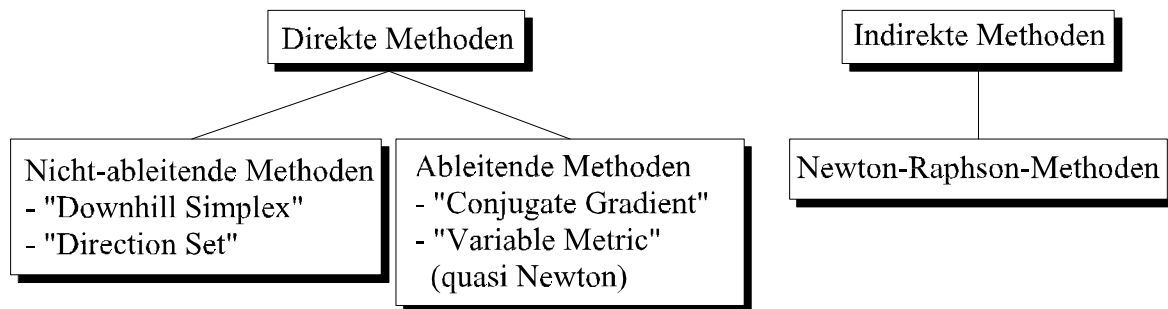


Bild 4.3: Überblick über Optimalitäts- bzw. Optimierungsansätze

Ableitende Methoden zur direkten Optimierung verwenden Ableitungen erster und auch höherer Ordnung der Verlustfunktion zur Suche nach einem Optimum. Spezifische Methoden dieser Gattung sind die „Conjugate Gradient“-Techniken, die zur Auffindung der Extrema multidimensionale Ableitungsinformation (Gradient) verwenden (z.B. Fletcher-Reeves, Polak-Ribiere) und die „Variable Metric“-Techniken, die eine Verallgemeinerung des eindimensionalen Newton-Ansatzes verwenden (z.B. Davidson-Fletcher-Powell, Broyden-Fletcher-Goldfarb-Shanno) [58].

Nichtableitende Methoden umfassen Simplex-Methoden, die einen geometrischen Ansatz verfolgen (Polygonzüge), um die Extrema der Verlustfunktion herauszufinden, und „Direction Set“-Methoden, die eine sukzessive Minimierung entlang präferierter Koordinatenrichtungen verwenden.

Demgegenüber suchen indirekte Methoden die Nullstellen eines Systems von Gleichungen unter Einbeziehung der partiellen Ableitungen der Verlustfunktion nach dem Zustandsvektor. Die einzigen erfolgreichen Techniken sind multidimensionale Newton-Raphson-Methoden [58]. Die indirekten Methoden versuchen die Lösung des folgenden nichtlinearen Gleichungssystems:

$$\frac{\nabla l(\underline{x})}{\nabla \underline{x}} = \begin{bmatrix} \frac{\nabla l(\underline{x})}{\nabla x_1} & \frac{\nabla l(\underline{x})}{\nabla x_2} & \dots & \frac{\nabla l(\underline{x})}{\nabla x_m} \end{bmatrix} = \underline{0}^T \quad (4.14)$$

mit  $m$  der Anzahl der Komponenten des Zustandsvektors [58].

Indirekte Methoden erfordern explizit die Differentiation des durch die Verlustfunktion dargestellten Optimierungskriteriums. Damit wird das Problem des Findens der Extrema eines nicht-linearen Gleichungssystems überführt in das Problem der Nullstellensuche  $m$  simultaner nicht-linearer Gleichungen. Es erscheint intuitiv einfacher, die Lösungen bzw. Nullstellen simultaner nichtlinearer Gleichungssysteme zu finden als das Extremum einer Funktion.

Die Komponenten des Gradientenvektors sind jedoch keine unabhängigen Funktionen. Sie sind Integritätsbedingungen unterworfen, die sehr restriktiv sind. Vereinfacht ausgedrückt ist es immer möglich, z.B. ein Minimum zu finden, indem auf einer Oberfläche hinuntergegangen wird. Die Suche nach einem Minimum ist eindimensional. Es gibt kein vergleichbares Konzept für die multidimensionale Suche nach einer Nullstelle, bei der das Herabgehen gleichzeitig in  $N$  separaten Funktionenräumen vonstatten gehen müßte und damit eine Vielzahl von neuen zu behandelnden Problemen auftauchen würde, z.B. inwieweit der Fortschritt in einer Dimension vergleichbar wäre mit dem Fortschritt in einer anderen.

[58] zeigt, daß es nur eine effektive Methode zur Lösung von Gl. (4.14) gibt: Die multidimensionale Newton-Raphson-Methode. Für einen eindimensionalen Zustandsvektor kann diese Technik wie folgt zusammengefaßt werden: Es soll  $x$  so gefunden werden, daß die Gleichung:

$$\frac{\partial l(x)}{\partial x} = f(x) = 0 \quad (4.15)$$

erfüllt wird.

Die Taylorreihenentwicklung von  $f(x)$  ergibt:

$$f(x + \Delta x) = f(x) + \frac{\partial f(x)}{\partial x} \cdot \Delta x + \frac{\partial^2 f(x)}{\partial x^2} \cdot \Delta x^2 + \dots \quad (4.16)$$

Die Vernachlässigung der Terme zweiter und höherer Ordnung führt zu einer linearen Gleichung:

$$f(x + \Delta x) \cong f(x) + \frac{\partial f(x)}{\partial x} \cdot \Delta x \quad (4.17)$$



Um Gl. (4.17) zu lösen, wird  $f(x + \Delta x)$  gleich 0 gesetzt und nach  $\Delta x$  aufgelöst:

$$\Delta x = -\frac{f(x)}{f'(x)} \quad (4.18)$$

Die Lösung von Gl. (4.15) kann dann durch Iteration gefunden werden. Ein verbesserter Wert für  $x_i$  ist:

$$x_{i+1} = x_i + \Delta x_i \quad (4.19)$$

Diese Iteration wird solange durchgeführt, bis  $\Delta x_i < \epsilon$  ist, wobei  $\epsilon$  ein willkürlich klein zu wählendes Konvergenzkriterium darstellt. Eine Beschreibung der Newton-Raphson-Methode für den mehrdimensionalen Fall findet sich in [58].

#### 4.2.4 Verarbeitungsansatz

Bei der Einführung zum Estimationsproblem und alternativen Designauswahlen wurde bisher die grundlegende Frage ausgeklammert, wie die Daten zu verarbeiten sind. Wie in Bild 4.2 dargestellt, gibt es in dieser Richtung zwei generelle Alternativen: Die sequentielle und die Batch-Verarbeitung.

Die Batch-Verarbeitung nimmt an, daß alle zu verarbeitenden Daten aufgelaufen sind und gleichzeitig berücksichtigt werden können, d.h. das Prozedere ist wie folgt: Alle  $n$  Beobachtungen sind verfügbar, ein Optimierungskriterium wird ausgewählt, und dann wird mit geeigneten Techniken der Wert von  $\underline{x}$  gesucht, der am besten zu den  $n$  Beobachtungen paßt. Der Batch-Ansatz ist verbreitet bei Modellierungs- oder Curve-Fitting-Problemen. Batch-Estimation wird dann vorteilhaft angewendet, wenn die Lösung kein zeitkritisches Element enthält, also praktisch offline verlaufen kann. Allgemeine Beispiele sind etwa die Estimation des heliozentrischen Orbits eines Kometen oder Asteroiden, die Beobachtungen über eine Periode von einigen Tagen und anschließende Analyse der Daten zur Bestimmung der Ephemeris erfordert, oder die Beschreibung bestimmter Daten über verschiedene Funktionen. Batch-Ansätze haben eine Reihe von Vorteilen, besonders für Situationen, in denen Schwierigkeiten bei der Assoziation auftreten. Theoretisch wenigstens ist es ein Ansatz, eine optimale Assozia-

tion von Beobachtungen zu Tracks oder Beobachtungen zu Beobachtungen zu finden, indem einfach alle  $n \cdot (n - 1) / 2$  Kombinationen versucht werden. Praktisch sind solche Ansätze nicht, jedoch bieten Batch-Techniken bei solchen Ansätzen eine höhere Flexibilität als sequentielle Techniken.

Die sequentielle Estimation aktualisiert den Schätzwert des Zustandsvektors inkremental mit jeder dazukommenden Beobachtung, d.h. wenn  $\underline{x}_n(t_0)$  der Schätzwert eines Zustandsvektors zur Zeit  $t_0$  ist, basierend auf  $n$  vorherigen Beobachtungen, dann ist die sequentielle Estimation die Methode, einen neuen Schätzwert des Zustandsvektors,  $\underline{x}_{n+1}(t_0)$ , auf der Basis von  $n + 1$  Beobachtungen durch Modifikation des letzten Schätzwerts des Zustandsvektors  $\underline{x}_n(t_0)$  zu erhalten. Dieser neue Schätzwert bewertet alle vorangegangenen  $n$  Beobachtungen nur indirekt neu. Es werden jedoch nicht alle vorangegangenen Beobachtungen erneut verarbeitet. In dem alten Schätzwert  $\underline{x}_n(t_0)$  steckt die bewertete Information von  $n$  Beobachtungen. Durch Hinzunahme der Beobachtung  $n + 1$  wird der neue Schätzwert gewonnen. Bei der Batch-Estimation wurde z.B. der Vektor  $\underline{x}_n(t_0)$  durch die Verwendung aller bisherigen  $n$  Beobachtungen erhalten. Stehen nun  $n + 1$  Beobachtungen zur Verfügung, dann werden zur Erreichung des Schätzwertes  $\underline{x}_{n+1}(t_0)$  alle dann verfügbaren  $n + 1$  Beobachtungen verarbeitet. Das Kalman-Filter ist ein weit verbreiteter Ansatz der sequentiellen Estimation [45]. Vorteile der sequentiellen Estimationstechniken sind z.B.:

1. Bestimmung eines Schätzwertes eines Zustandsvektors mit jeder neuen Beobachtung
2. Rechenleistungseffiziente skalare Formulierungen
3. Fähigkeit zur Anpassung an veränderte Beobachtungsbedingungen (z.B. Rauschen)

Nachteile der sequentiellen Estimationstechniken liegen in potentiellen Problemen bei der Datenassoziation, Divergenzerscheinungen (sequentieller Estimator ignoriert neue Daten) und Initialisierungsproblemen. Trotzdem werden sequentielle Estimatoren zur Lösung von Trackingproblemen und Positionsbestimmungsaufgaben eingesetzt.

Sog. Kalman-Smoother [35] können bei geeigneter Aufgabenstellung durch Batchverarbeitung eine Verbesserung der Filterschätzwerte im Vergleich zum sequentiellen Kalman-Filter-Ansatz herbeiführen. Weitere Verbesserungen sind prinzipiell durch den Einsatz pseudoredundanter Messungen möglich [2].

## 4.3 Batch-Estimation

### 4.3.1 Ableitung der Weighted-Least-Squares-Lösung

Zur Verdeutlichung der Formulierung und des Ablaufes der Batch-Estimation werde nun eine Weighted-Least-Squares-Lösung auf ein dynamisches Tracking-Problem angewandt. Ein oder mehrere Sensoren beobachten ein sich bewegendes Objekt.




Bild 4.4a: Beispielszenario




Bild 4.4b: Beispiel Meßwertverlauf für Sensor n mit Meßrauschen

Aus diesem Szenario ergeben sich  $n$  Beobachtungen  $\underline{y}_M(t_i)$  bzgl. der Position des Zieles; der Index  $M$  steht dabei für das Adjektiv „Measured“ (gemessen). Die Beobachtungen seien als unbeeinflusst angenommen mit Beobachtungsrauschen mit einer Standardabweichung  $\mathbf{s}_i$ . Die (unbekannte) Zielposition und Geschwindigkeit zur Zeit  $t_i$  werden durch den 1-dimensionalen Vektor  $\underline{x}(t_i)$  dargestellt. Da das Ziel beweglich ist, ist  $\underline{x}$  eine Funktion der Zeit und durch die Bewegungsgleichung:

$$\underline{\dot{x}}(t) = f(\underline{x}, \underline{\dot{x}}, t) \quad (4.20)$$

gegeben. Gl. (4.20) stellt 1 verknüpfte nichtlineare Differentialgleichungen dar. Es handelt sich dabei um ein Anfangswertproblem. Wenn die Anfangsbedingungen, d.h.  $\underline{x}_0$  und  $\underline{\dot{x}}_0$  zur Zeit  $t_0$ , gegeben sind, kann Gl. (4.20) gelöst werden bzw.  $\underline{x}(t)$  zu einer beliebigen späteren Zeit  $t$  geschätzt werden. Dazu wird auf numerische Ansätze zur Integration wie Runge-Kutta-Methoden, Prädiktor-Korrektor-, Perturbationsmethoden bzw. in einfachen Fällen auf analytische Lösungen zurückgegriffen [37].

Ein Beobachtungsmodell erlaubt es, die vorauszuschätzenden Beobachtungen in Abhängigkeit des unbekanntes Zustandsvektors auszudrücken:

$$\underline{y}(t) = \underline{g}[\underline{x}(t), t] \quad (4.21)$$

Es bestehen dabei keinerlei Kenntnisse bzgl. der statistischen Eigenschaften der in den Messungen enthaltenen Fehler (Meßrauschen) [45].

Die Residuen sind die Differenzen zwischen den Sensordaten und den berechneten Meßwerten zur Zeit  $t_i$ :

$$r_i(t_i) = \underline{y}_M(t_i) - \underline{g}[\underline{x}(t_i), t_i] \quad (4.22)$$

Das WLS-Kriterium bzw. die Verlustfunktion wird durch:

$$l(\underline{x}) = \sum_{i=1}^n \frac{1}{\mathbf{s}_i^2} \cdot \underline{r}_i^T \cdot \underline{r}_i \quad (4.23)$$

ausgedrückt.  $l(\underline{x})$  ist ein Maß für die Ähnlichkeit zwischen den tatsächlichen und den vorausgesagten Daten als Funktion von  $\underline{x}$ . Wenn unterschiedliche Sensortypen verwendet werden, dann ändert sich die Form der Funktion  $\underline{g}[\underline{x}, t_i]$  für jeden Sensortyp, z.B. könnte  $\underline{g}[\underline{x}, t_i]$  eine Gruppe von Gleichungen für ein Radar zur Prädiktion von Range, Azimut, Elevation und Range-Rate repräsentieren sowie eine weitere Gruppe von Gleichungen für einen optischen Tracker zur Prädiktion der „Right Ascension“- und „Declination“-Winkel (RA und DEC). Weiterhin sei die durch  $\underline{y}_M(t_i)$  dargestellte Beobachtung ein Vektor, z.B.:

$$\underline{y}_M(t_i) = \begin{bmatrix} Range(t_i) \\ Range - Rate(t_i) \\ Azimut(t_i) \\ Elevation(t_i) \end{bmatrix}$$

für die Radarbeobachtung oder:

$$\underline{y}_M(t_i) = \begin{bmatrix} RA(t_i) \\ DEC(t_i) \end{bmatrix}$$

für den optischen Tracker. In diesem Fall würden  $\underline{g}[\underline{x}, t_i]$  und  $\underline{r}_i$  korrespondierende Vektorgößen sein. In Matrixschreibweise wird Gl. (4.23) zu:

$$l(\underline{x}) = \left[ \underline{y}_M - \underline{g}[\underline{x}] \right]^T \cdot W^{-1} \cdot \left[ \underline{y}_M - \underline{g}[\underline{x}] \right] \quad (4.24)$$

Der WLS-Schätzwert ist der Wert  $\underline{x}_0$  von  $\underline{x}$ , der die Verlustfunktion minimiert. Um diesen Wert zu finden, wird die Ableitung der Verlustfunktion nach  $\underline{x}$  berechnet und gleich dem Nullvektor gesetzt [21]:

$$\frac{\mathcal{J}}{\mathcal{J}\underline{x}}[l(\underline{x})] = -2 \cdot \left[ \underline{y}_M - \underline{g}[\underline{x}] \right]^T \cdot W^{-1} \cdot \frac{\mathcal{J}}{\mathcal{J}\underline{x}}[\underline{g}[\underline{x}]] = \underline{0}^T \quad (4.25)$$

Gl. (4.25) stellt eine Gruppe von nichtlinearen Gleichungen mit 1 Unbekannten, den Komponenten von  $\underline{x}_0$ , dar.

Wie im vorigen Abschnitt angedeutet, kann die Lösung für Gl. (4.25) durch einen mehrdimensionalen Newton-Raphson-Ansatz angegangen werden. Die folgende Ableitung zeigt explizit eine linearisierte iterative Lösung. Zunächst wird dazu die Meßwertprädiktion  $\underline{g}[\underline{x}(t), t]$  in eine Taylorreihe um einen Referenzpunkt  $\underline{x}_{Ref}(t)$  entwickelt:

$$\underline{g}[\underline{x}, t_i] = \underline{g}[\underline{x}_{Ref}, t_i] + H_i \cdot \Delta \underline{x}_i \quad (4.26)$$

mit:

$$\Delta \underline{x}_i = \underline{x}(t_i) - \underline{x}_{Ref}(t_i) \quad (4.27)$$

und:

$$H_i = \frac{\mathcal{J}}{\mathcal{J}\underline{x}}[\underline{g}[\underline{x}, t_i]] \quad (4.28)$$

Eine weitere Vereinfachung ergibt sich, wenn die Bewegungsgleichungen linearisiert werden:

$$\Delta \underline{x}_i = \Phi(t_i, t_j) \cdot \Delta \underline{x}_j \quad (4.29)$$

mit der Zustandsübergangsmatrix:

$$\Phi(t_i, t_j) = \frac{\mathcal{J}\underline{x}(t_i)}{\mathcal{J}\underline{x}(t_j)} \quad (4.30)$$

Substitution von Gl. (4.29) in Gl. (4.26) ergibt:

$$\underline{g}[\underline{x}, t_i] = \underline{g}[\underline{x}_{Ref}, t_i] + H_i \cdot \Phi(t_i, t_j) \cdot \Delta \underline{x}_j \quad (4.31)$$

Einsetzen dieses Ausdrucks in Gl. (4.25) liefert:

$$\left[ \Delta \underline{y} - H(\underline{x}_j) \cdot \Delta \underline{x}_j \right]^T \cdot W^{-1} \cdot H(\underline{x}_j) = \underline{0}^T \quad (4.32)$$

mit:

$$\Delta \underline{y} = \underline{y}_M - \underline{g}[\underline{x}_{Ref}] \quad (4.33)$$

und:

$$H(\underline{x}_j) = H_i \cdot \Phi(t_i, t_j) \quad (4.34)$$

Auflösung des Ausdrucks Gl. (4.32) nach  $\Delta \underline{x}_j$  ergibt das Inkrement:

$$\begin{aligned} \left[ \Delta \underline{y} - H(\underline{x}_j) \cdot \Delta \underline{x}_j \right]^T \cdot W^{-1} \cdot H(\underline{x}_j) &= \underline{0}^T \\ H(\underline{x}_j)^T \cdot W^{-1} \cdot \left[ \Delta \underline{y} - H(\underline{x}_j) \cdot \Delta \underline{x}_j \right] &= \underline{0} \\ H(\underline{x}_j)^T \cdot W^{-1} \cdot \Delta \underline{y} - H(\underline{x}_j)^T \cdot W^{-1} \cdot H(\underline{x}_j) \cdot \Delta \underline{x}_j &= \underline{0} \end{aligned} \quad (4.35a)$$

zu:

$$\Delta \underline{x}_j = \left[ H(\underline{x}_j)^T \cdot W^{-1} \cdot H(\underline{x}_j) \right]^{-1} \cdot H(\underline{x}_j)^T \cdot W^{-1} \cdot \Delta \underline{y} \quad (4.35b)$$

Der aktualisierte Schätzwert des Zustandsvektors wird durch Addition von  $\Delta \underline{x}_j$  zu  $\underline{x}_{Ref}(t_j)$

berechnet:

$$\hat{\underline{x}}(t_j) = \underline{x}_{\text{Ref}}(t_i) + \Delta \underline{x}_j \quad (4.36)$$

Dieser verbesserte Wert für  $\underline{x}(t_j)$  wird dann als neuer Referenzwert definiert. Die Gl. (4.35) und (4.36) werden solange iteriert, bis  $\Delta \underline{x}_j$  eine willkürlich klein gewählte Schranke erreicht.

Tabelle 4.2 zeigt die linearisierte iterative Lösung für einige Optimierungskriterien.

Optimierungskriterium	Mathematische Formulierung	Linearisierte iterative Lösung
Least-Squares	$l(\underline{x}) = \underline{r}^T \cdot \underline{r}$	$\Delta \underline{x}_{j,LS} = \left[ H^T \cdot H \right]^{-1} \cdot H^T \cdot \underline{r}$
Weighted-Least-Squares	$l(\underline{x}) = \underline{r}^T \cdot W^{-1} \cdot \underline{r}$	$\Delta \underline{x}_{j,WLS} = \left[ H^T \cdot W^{-1} \cdot H \right]^{-1} \cdot H^T \cdot W^{-1} \cdot \underline{r}$
Bayes'sche WLS	$l(\underline{x}) = \underline{r}^T \cdot W^{-1} \cdot \underline{r} +$ $(\underline{x} - \underline{x}_0)^T \cdot P_{\Delta x_0} \cdot$ $(\underline{x} - \underline{x}_0)$ s. Gl. (4.8)	$\Delta \underline{x}_{j,BWLS} = \left[ H^T \cdot W^{-1} \cdot H + P_{\Delta x}^{-1} \right] \cdot$ $\left[ H^T \cdot W^{-1} \cdot \underline{r} + P_{\Delta x}^{-1} \cdot \Delta \underline{x}_{j-1} \right]$ s. Gl. (4.76)
Maximum-Likelihood-Schätzwert	$l(\underline{x}) = \prod_{i=1}^n l_i(n_i / \underline{x})$ s. Gl. (4.12)	$\Delta \underline{x}_{j,MLE} = \left[ H^T \cdot M^{-1} \cdot H \right]^T \cdot$ $\left[ H^T \cdot M^{-1} \cdot \underline{r} \right]$

Tabelle 4.2: Zusammenfassung der Batch-Estimationslösungen

In Gl. (4.35) stellt der Vektor  $\Delta \underline{y}$  die Differenz zwischen geschätzten und tatsächlichen Beobachtungen dar. Die Matrix  $H(\underline{x}_j)$  ist ein Maß für das Verhältnis zwischen Änderungen in den geschätzten Beobachtungen und den Änderungen der Komponenten des Zustandsvektors. Im Fall statischer Problemstellungen ist der Zustandsvektor  $\underline{x}(t)$  konstant über der Zeit und die Zustandsübergangsmatrix reduziert sich zur Einheits- bzw. Identitätsmatrix:



$$\Phi(t_i, t_j) = I = \begin{bmatrix} 1 & 0 & 0 & \dots & 0 \\ 0 & 1 & 0 & \dots & 0 \\ 0 & 0 & 1 & \dots & 0 \\ \dots & & & & \\ 0 & 0 & 0 & \dots & 1 \end{bmatrix} \quad (4.37)$$

### 4.3.2 Ablauf

Der Prozeßablauf zur Lösung eines Batch-Estimationsproblems ist beispielhaft für eine WLS-Formulierung in Bild 4.4 dargestellt. Dabei wird der indirekte Ansatz des vorigen Abschnitts genutzt. Eingangswerte des Prozesses sind ein Anfangsschätzwert des Zustandsvektors,  $\underline{x}_0$ , zum Zeitpunkt  $t_0$  und  $n$  Beobachtungen  $\underline{y}_{M,k}$  zu den Zeitpunkten  $t_k$  mit den zugehörigen Unsicherheiten  $\mathbf{s}_k$ . Ergebnis des Prozesses ist ein verbesserter Schätzwert des Zustandsvektors  $\underline{x}_{i+1}(t_0)$  für den Zeitpunkt  $t_0$ .

Der Prozeßablauf in Bild 4.4 verwendet zwei geschachtelte Iterationen. Eine innere Schleife ( $k = 1, 2, \dots, n$ ) bearbeitet jede Beobachtung  $\underline{y}_{M,k}$  und führt eine Reihe von Berechnungen aus. Eingangswerte sind hier die  $k$ -te Beobachtung  $\underline{y}_{M,k}$ , die zugehörige Beobachtungszeit  $t_k$  und die Beobachtungsunsicherheit  $\mathbf{s}_k$ . Dann wird die differentielle Bewegungsgleichung Gl. (4.20) zur Erreichung von  $\underline{x}_{ki}(t_k)$  gelöst, d.h. der Schätzwert des Zustandsvektors,  $\underline{x}_i(t_0)$ , wird auf die Zeit  $t_k$  aktualisiert. Mit den Sensormodellen (unterschiedlich für verschiedene Sensortypen (Radar, optisch, usw.)) wird die Beobachtung  $\underline{g}[\underline{x}_i(t_k), t_k]$  geschätzt, bevor die Übergangsmatrix  $\Phi(t_k, t_0)$  berechnet wird. Der nächste Schritt besteht in der Berechnung des Wertes  $H_k \cdot \Phi(t_k, t_0)$  und des Beobachtungsresiduums  $\underline{d}_{y_k} = \underline{y}_{M,k}(t_k) - \underline{g}[\underline{x}_i, t_k]$ . Die Hilfsmatrizen  $A$  und  $B$  (Initialisierungswert = 0) werden entsprechend den Gleichungen:

$$A = A + H_k^T \cdot H_k / \mathbf{s}_k^2 \quad (4.38)$$

und:

$$B = B + H_k^T \cdot \bar{d}y_k / \mathbf{s}_k^2 \quad (4.39)$$

akkumuliert. Diese sechs Schritte werden für jede Beobachtung  $k = 1, 2, \dots, n$  durchgeführt. Die äußere Verarbeitungsschleife  $i = 0, 1, \dots$  korrigiert den Zustandsvektor, bis ein Konvergenzkriterium erfüllt wird. Für jede Iteration werden:

$$A^{-1} = (H^T \cdot W^{-1} \cdot H)^{-1} \quad (4.40)$$

$$\Delta \hat{x}_0(t_0) = A^{-1} \cdot B \quad (4.41)$$

sowie:

$$\underline{x}_{i+1}(t_0) = \underline{x}_i(t_0) + \Delta \hat{x}_0 \quad (4.42)$$

berechnet. Damit wird der Zustandsvektor sukzessiv verbessert, bis  $\Delta \hat{x}_0$  beliebig klein geworden ist.

Der beschriebene und in Bild 4.5 dargestellte Prozeß soll die grundlegenden Eigenschaften einer Batch-Lösung durch einen linearisierten iterativen Ansatz vermitteln. Deutlich wird dabei, daß die Lösung sehr rechenintensiv werden kann. Für jede von u.U. tausenden Beobachtungen muß ein nichtlineares Differentialgleichungssystem gelöst und Koordinatentransformationen durchgeführt, eine Übergangsmatrix berechnet sowie einige Matrizenmultiplikationen ausgeführt werden. Außerdem müssen für alle Beobachtungen Schleifen durchlaufen werden, um einen Schätzwert für  $\underline{x}(t_0)$  zu erhalten.

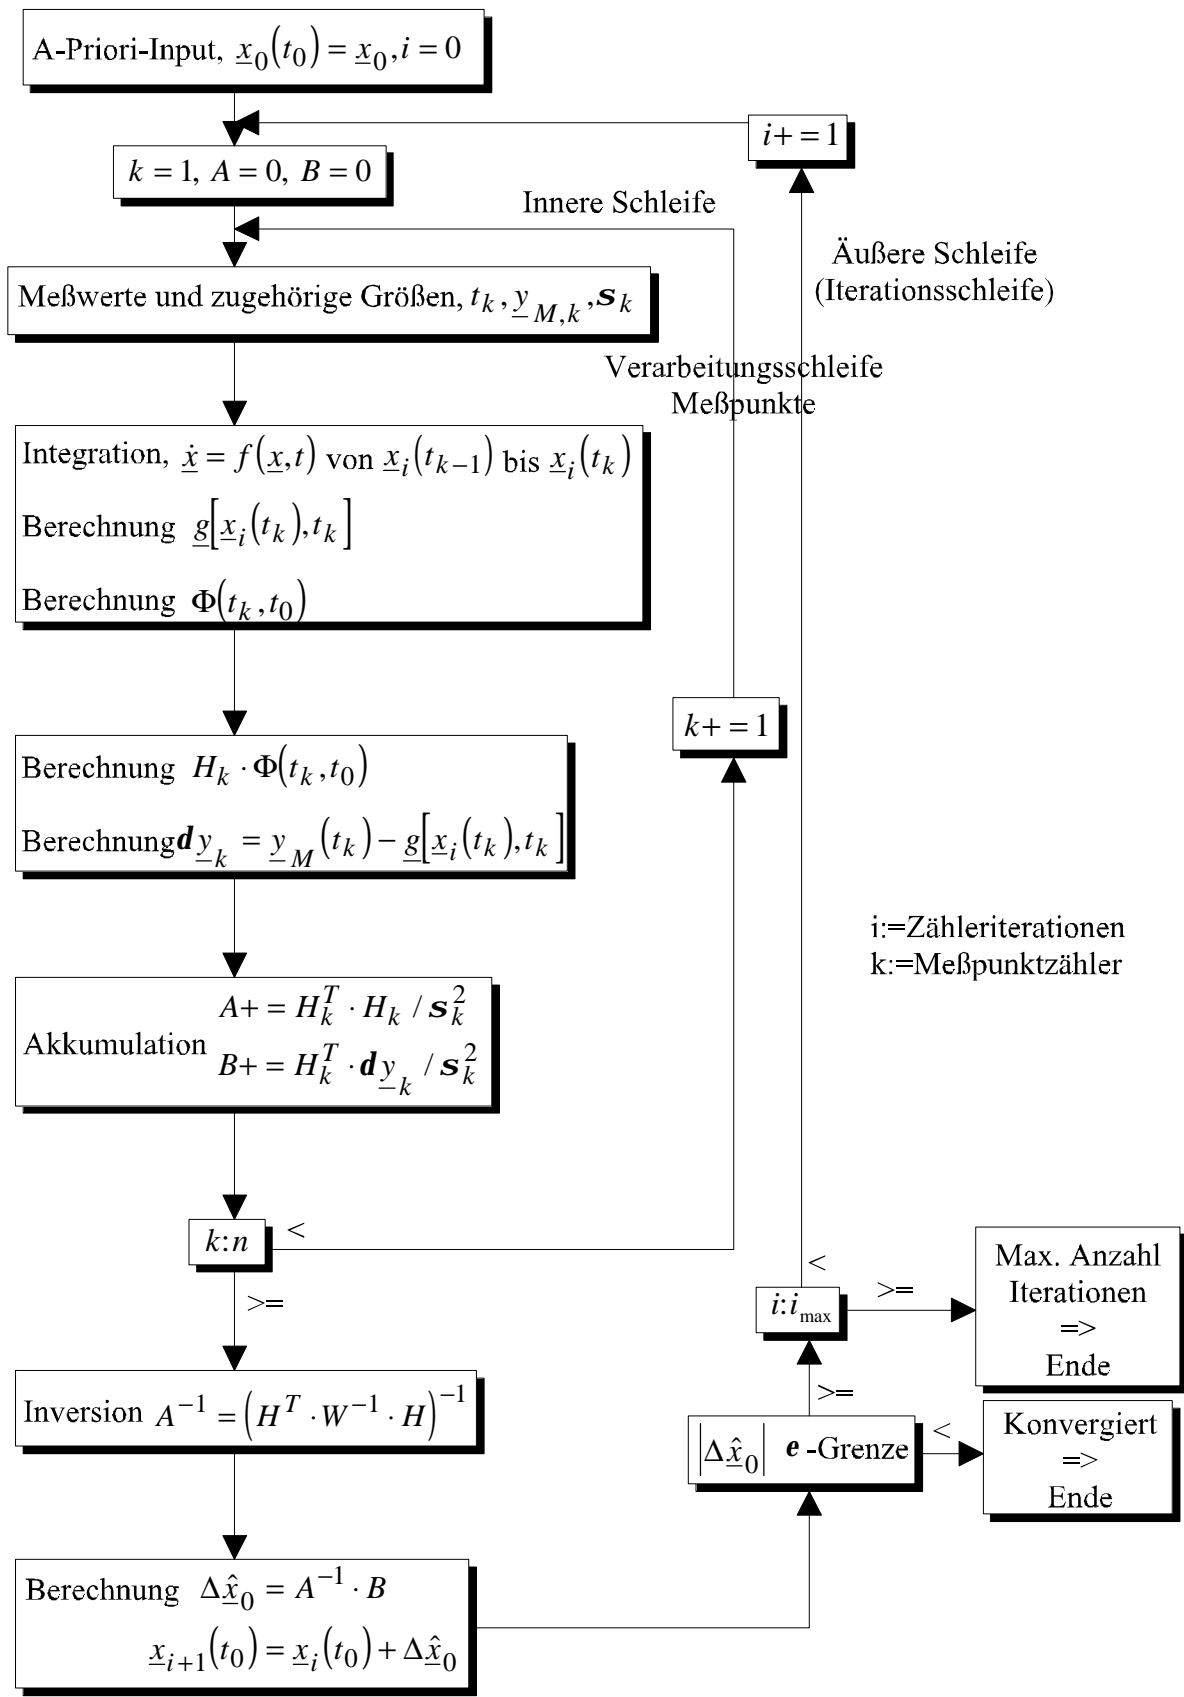


Bild 4.5: WLS-Prozessierung, Prozeßablauf

### 4.3.3 Implementierungsfragen

Das Prozeßablaufdiagramm in Bild 4.4 ist keine Anleitung für eine softwaretechnische Implementierung. Es soll den Gedankengang der Batchestimation verdeutlichen. Zu den tatsächlichen Fragen, die bei einer Implementierung auftreten, gehören die Konvergenz, der Anfangswert von  $\underline{x}$ , die Beobachtbarkeit usw.

Der Ablauf in Bild 4.4 zeigt eine äußere Verarbeitungsschleife, in der sukzessive Verbesserungen des Schätzwertes des Zustandsvektors berechnet werden. Das Konvergenzkriterium testet dabei den Betrag von  $\Delta \underline{x}$ . Konvergenz ist erreicht, wenn:

$$|\Delta \underline{x}_0| < \mathbf{e} \quad (4.43)$$

Der letzte Iterationsschritt ist dann ausgeführt, wenn die inkrementalen Änderungen des Zustandsvektors kleiner als eine beliebig klein gewählte  $\mathbf{e}$ -Schranke geworden sind. Diese Art der Beschränkung kann durchaus logisch begründet sein, wenn die  $\mathbf{e}$ -Schranken physikalisch begründbar sind, z.B. kann es der Fall sein, daß Distanzen kleiner 1 m, Geschwindigkeiten unter 1 cm/s oder Frequenzen unter 1 Hz unter eine Auflösbarkeitsgrenze fallen. Andere Konvergenzkriterien wie z.B. ein Verhältniskriterium:

$$\frac{|\Delta \underline{x}_0|}{|\underline{x}_0|} < \mathbf{e} \quad (4.44)$$

können ebenfalls verwendet werden. Es gibt keine Garantie, daß eine iterative Lösung innerhalb einer endlichen Zahl von Schritten konvergiert. Deshalb müssen auch immer logische Abfragen in die Schleifen integriert sein, die eine maximale Anzahl von durchzuführenden Iterationen definieren, damit es nicht zu unendlichen Schleifen kommt.

Bei der Batch-Estimation kann der Anwender geneigt sein, in der äußeren Schleife die Daten zu editieren bzw. zu verändern. Gemeinhin werden z.B. Beobachtungen mißachtet bzw. ausgesondert, deren Residuum entweder eine A-Priori-Grenze oder einen Standardabweichungstest (z.B.  $3 \cdot \mathbf{s}$ ) überschreitet. Diese Verfahrensweise kann zu Problemen führen. Iterative Daten-

Veränderung kann die Verarbeitungsschleife verlängern. Es ist möglich, für den  $i$ -ten Schätzwert von  $\underline{x}_0(t_0)$  eine oder mehrere Beobachtungen zu verwerfen, nur um sie für den  $(i+1)$ -ten Schätzwert zu akzeptieren.

Ein zweiter Problemfall kann dann auftreten, wenn alle Beobachtungen gültig und hochgenau sind. Statistisch gesehen gibt es einige gültige Beobachtungen, deren Residuen  $3 \cdot \mathbf{s}$  überschreiten. Verwerfung oder Veränderung solcher Beobachtungen verfälscht die Lösung für  $\underline{x}_0(t_0)$ . Verfügbare Daten sollten nur dann verworfen werden, wenn es für ein solches Vorgehen triftige physikalische Gründe gibt.

Eine weitere Implementierungsfrage der Batchverarbeitung betrifft die Frage, wie ein Anfangsschätzwert des Zustandsvektors  $\underline{x}_0(t_0)$  gefunden werden kann. Generell können einige Beobachtungen genutzt werden, um für den Anfangswert eine Minimallösung zu erreichen. Alternativ können einige Sensoren Schätzwerte des Zustandsvektors liefern, oder es wird eine A-Priori-Information verwendet. Die Generierung eines Startwertes für  $\underline{x}$  hängt sehr stark von den verwendeten Sensoren und der Beobachtungsgeometrie ab. Manchmal werden mehrere Minimallösungen verwendet (Anfangsschätzwert entwickelt aus jeder Gruppe, z.B. Beobachtungen  $\underline{y}_M$ ,  $\underline{y}_{3M}$ , und  $\underline{y}_{5M}$  sowie Beobachtungen  $\underline{y}_{2M}$ ,  $\underline{y}_{4M}$  und  $\underline{y}_{6M}$ ) und daraus durch Mittelwertbildung ein Startwert für den Estimationsprozeß gewonnen.

Die letzte hier zu behandelnde Implementierungsfrage ist die Frage der Beobachtbarkeit, die entscheidet, ob Verbesserungen in den Komponenten von  $\underline{x}(t)$  auf den beobachteten Daten basieren. Mathematisch tritt das Problem in Gestalt einer schlecht konditionierten Matrix auf:

$$H^T \cdot W^{-1} \cdot H \tag{4.45}$$

Zur Lösung dieses Problems sind verschiedene Ansätze entwickelt worden, z.B. kann die Forderung erhoben werden, daß die Determinante der Matrix ungleich 0 sein muß für jeden Iterationsschritt. Alternativ können auch nichtlineare Terme eingeführt werden. Der Nutzen dieser Techniken ist nicht von der Hand zu weisen. Dennoch können sie kein Ersatz sein für eine sorgfältige Auswahl und Analyse der Zustandsvektorkomponenten.

## 4.4 Sequentielle Estimation

In den frühen 60er Jahren wurde eine Reihe von Veröffentlichungen publiziert, die sich mit sequentiellen Estimationsansätzen befaßten. In [31] und [32] wurde eine linearisierte sequentielle Technik vorgestellt, die eine diskrete Implementierung kontinuierlicher Formulierungen von Wiener und Kolmogorov in den späten 40er Jahren darstellte. Eine sehr lesenswerte Beschreibung der Entwicklung und Formulierung des Kalman-Filters und seiner Anwendung in der Raumfahrt, aber auch der Schwierigkeiten, denen sich die Forscher und Entwickler damals gegenüberstanden, findet sich in [51]; neben den Anwendungsmöglichkeiten in der Luft- und Raumfahrt, bei der Entdeckung von Bodenschätzen u.a. werden dort auch so scheinbar exotische Anwendungen wie die Vorhersage von Kuhpopulationen in Frankreich beschrieben.

Seitdem wurde viel Arbeit in die Entwicklung der diskreten Estimation investiert. Eine Vielzahl von Techniken existiert auf diesem Feld. Im folgenden Abschnitt wird ein Ansatz herausgegriffen, der ein Kalman-Filter nutzt. Interessanterweise werden diskrete lineare Estimationstechniken gemeinhin unter dem Begriff Kalman-Filter zusammengefaßt und vernachlässigen mit dieser Namensgebung etwas die Arbeit von Forschern wie Swerling und Bucy [51].

Verschiedene Ansätze können zur Ableitung der sequentiellen Estimationsgleichungen genutzt werden. Im folgenden sollen die Gleichungen für ein WLS-Optimierungskriterium für eine dynamische Tracking-Problemstellung aufgestellt werden. Daran anschließend wird ein Ablaufdiagramm vorgestellt sowie verschiedene Implementierungsfragen behandelt.

### 4.4.1 Ableitung einer sequentiellen WLS-Lösung

Angenommen sei, daß  $n$  Beobachtungen von verschiedenen Sensoren verfügbar seien und daß eine WLS-Lösung erreicht wurde:

$$\Delta \hat{x}_{-n} = \left[ H_n^T \cdot W_n^{-1} \cdot H_n \right]^{-1} \cdot H_n^T \cdot W_n^{-1} \cdot \Delta y_{-n} \quad (4.46)$$

wobei  $H_n$  die partiellen Ableitungen der Beobachtungskomponenten nach dem Zustandsvektor und  $\Delta y_{-n}$  die Differenz zwischen gemessenen und geschätzten Beobachtungen darstellt.

Angenommen sei eine weitere Beobachtung  $y_{-n}(t_{n+1})$ . Die Frage ist nun, wie diese  $(n+1)$ -te Beobachtung den Schätzwert von  $\underline{x}$  beeinflusst.

Mit der Modellierung des Meßprozesses durch:

$$\Delta \underline{y}_{-n} = H_n \cdot \Delta \underline{x}_n + \underline{n}_n \quad (4.47)$$

mit dem zufälligen additiven Meßfehler  $\underline{n}_n$  mit den Eigenschaften:

$$E\{\underline{n}_n\} = 0, \quad E\{\underline{n}_n \cdot \underline{n}_n^T\} = R \quad (4.48)$$

werden die Ansatzbedingungen:

$$\begin{aligned} \Delta \hat{\underline{x}}_{n+1} &= K' \cdot \Delta \hat{\underline{x}}_n + K \cdot \Delta \underline{y}_{-n+1} \\ \Delta \hat{\underline{x}}_{n+1} &= \Delta \underline{x}_n + \Delta \underline{x}_{e,n+1} \\ \Delta \hat{\underline{x}}_n &= \Delta \underline{x}_n + \Delta \underline{x}_{e,n} \end{aligned} \quad (4.49)$$

mit den zeitvarianten Gewichtungsmatrizen  $K'$  und  $K$  sowie den Estimationsfehlern  $\Delta \underline{x}_{e,n}$  bzw.  $\Delta \underline{x}_{e,n+1}$ , Gl. (4.29) und dem tatsächlichen Wert des Inkrements umgeformt:

$$\begin{aligned} \Delta \underline{x}_{e,n+1} &= \Delta \hat{\underline{x}}_{n+1} - \Delta \underline{x}_n \\ &= K' \cdot \Delta \hat{\underline{x}}_n + K \cdot \Delta \underline{y}_{-n+1} - \Delta \underline{x}_n \\ &= K' \cdot \Delta \underline{x}_n + K' \cdot \Delta \underline{x}_{e,n} + K \cdot \Delta \underline{y}_{-n+1} - \Delta \underline{x}_n \\ &= K' \cdot \Delta \underline{x}_n + K' \cdot \Delta \underline{x}_{e,n} + K \cdot H_{n+1} \cdot \Phi(t_{n+1}, t_n) \cdot \Delta \underline{x}_n + K \cdot \underline{n}_{n+1} - \Delta \underline{x}_n \\ &= [K' + K \cdot H_{n+1} \cdot \Phi(t_{n+1}, t_n) - I] \cdot \Delta \underline{x}_n + K' \cdot \Delta \underline{x}_{e,n} + K \cdot \underline{n}_{n+1} \end{aligned} \quad (4.50)$$

Da der Estimator „unbiased“ sein soll, d.h. die Estimationsfehler im Mittel 0 sein sollen

( $E\{\Delta \underline{x}_{e,n}\} = 0$  und  $E\{\Delta \underline{x}_{e,n+1}\} = 0$ ), wird die Forderung:

$$\begin{aligned}
K' + K \cdot H(\underline{x}_{n+1}) - I &= 0 \\
K' &= I - K \cdot H(\underline{x}_{n+1})
\end{aligned} \tag{4.51}$$

erhoben. Mit Gl. (4.51) wird Gl. (4.49a) zu:

$$\Delta \hat{\underline{x}}_{n+1} = \Delta \hat{\underline{x}}_n - K \cdot \left\{ H(\underline{x}_{n+1}) \cdot \Delta \hat{\underline{x}}_n - \Delta y_{n+1} \right\} \tag{4.52}$$

und Gl. (4.50):

$$\Delta \underline{x}_{e,n+1} = \left[ I - K \cdot H(\underline{x}_{n+1}) \right] \cdot \Delta \underline{x}_{e,n} + K \cdot \underline{\mathbf{n}}_{n+1} \tag{4.53}$$

Die Kovarianz des aktualisierten Estimationsfehlers berechnet sich wie folgt:

$$\begin{aligned}
P_{n+1} &= E \left\{ \Delta \underline{x}_{e,n+1} \cdot \Delta \underline{x}_{e,n+1}^T \right\} \\
&= E \left\{ \left[ \left[ I - K \cdot H(\underline{x}_{n+1}) \right] \cdot \Delta \underline{x}_{e,n} + K \cdot \underline{\mathbf{n}}_{n+1} \right] \cdot \left[ \left[ I - K \cdot H(\underline{x}_{n+1}) \right] \cdot \Delta \underline{x}_{e,n} + K \cdot \underline{\mathbf{n}}_{n+1} \right]^T \right\} \\
&= E \left\{ \left[ I - K \cdot H(\underline{x}_{n+1}) \right] \cdot \Delta \underline{x}_{e,n} \cdot \Delta \underline{x}_{e,n}^T \cdot \left[ I - K \cdot H(\underline{x}_{n+1}) \right] \right\} \\
&\quad + E \left\{ \left[ I - K \cdot H(\underline{x}_{n+1}) \right] \cdot \Delta \underline{x}_{e,n} \cdot \underline{\mathbf{n}}_{n+1}^T \cdot K^T \right\} \\
&\quad + E \left\{ K \cdot \underline{\mathbf{n}}_{n+1} \cdot \Delta \underline{x}_{e,n}^T \cdot \left[ I - K \cdot H(\underline{x}_{n+1}) \right]^T \right\} + E \left\{ K \cdot \underline{\mathbf{n}}_{n+1} \cdot \underline{\mathbf{n}}_{n+1}^T \cdot K^T \right\} \\
&= \left[ I - K \cdot H(\underline{x}_{n+1}) \right] \cdot P_n \cdot \left[ I - K \cdot H(\underline{x}_{n+1}) \right]^T + K \cdot R_{n+1} \cdot K^T
\end{aligned} \tag{4.54}$$

mit  $P_n = E \left\{ \Delta \underline{x}_{e,n} \cdot \Delta \underline{x}_{e,n}^T \right\}$ ,  $R_{n+1} = E \left\{ \underline{\mathbf{n}}_{n+1} \cdot \underline{\mathbf{n}}_{n+1}^T \right\}$  und der Unkorreliertheit der Meßfehler,

d.h.  $E \left\{ \Delta \underline{x}_{e,n} \cdot \underline{\mathbf{n}}_{n+1}^T \right\} = E \left\{ \underline{\mathbf{n}}_{n+1} \cdot \Delta \underline{x}_{e,n}^T \right\} = 0$ .

Das Kriterium zur Bestimmung von  $K$  [21] ist die Minimierung der Verlustfunktion:

$$l = \text{trace} \left[ P_{n+1} \right] \tag{4.55}$$



Die Verlustfunktion Gl.(4.55) wird mit:

$$\frac{\partial}{\partial A} \left\{ \text{trace} \left[ A \cdot B \cdot A^T \right] \right\} = 2 \cdot A \cdot B, \quad (B \text{ symmetrisch}) \quad (4.56)$$

partiell nach  $K$  differenziert und zu 0 gesetzt. Mit [45] ist das Ergebnis dieser Manipulation:

$$-2 \cdot \left[ I - K \cdot H(\underline{x}_{n+1}) \right] \cdot P_n \cdot H(\underline{x}_{n+1})^T + 2 \cdot K \cdot R_{n+1} = 0 \quad (4.57)$$

Weiteres Umformen und Auflösen nach  $K$  ergibt:

$$\begin{aligned} -2 \cdot P_n \cdot H(\underline{x}_{n+1})^T + 2 \cdot K \cdot H(\underline{x}_{n+1}) \cdot P_n \cdot H(\underline{x}_{n+1})^T + 2 \cdot K \cdot R_{n+1} &= 0 \\ K \cdot \left\{ H(\underline{x}_{n+1}) \cdot P_n \cdot H(\underline{x}_{n+1})^T + R_{n+1} \right\} &= P_n \cdot H(\underline{x}_{n+1})^T \\ K &= P_n \cdot H(\underline{x}_{n+1})^T \cdot \left[ H(\underline{x}_{n+1}) \cdot P_n \cdot H(\underline{x}_{n+1})^T + R_{n+1} \right]^{-1} \end{aligned} \quad (4.58)$$

das sog. Kalman-Filter-Gain.

Die Manipulation der quadratischen Form von Gl. (4.54) führt dann zu der bekannten Formel [21, 45] für die aktualisierte Fehlerkovarianz:

$$\begin{aligned} P_{n+1} &= \left[ I - K \cdot H(\underline{x}_{n+1}) \right] \cdot P_n \cdot \left[ I - K \cdot H(\underline{x}_{n+1}) \right]^T + K \cdot R_{n+1} \cdot K^T \\ &= \left[ I - K \cdot H(\underline{x}_{n+1}) \right] \cdot P_n \cdot \left\{ \begin{array}{c} \left[ I - K \cdot H(\underline{x}_{n+1}) \right]^T \\ + P_n^{-1} \cdot \left[ I - K \cdot H(\underline{x}_{n+1}) \right]^{-1} \cdot K \cdot R_{n+1} \cdot K^T \end{array} \right\} \\ &= \left[ I - K \cdot H(\underline{x}_{n+1}) \right] \cdot P_n \cdot \left\{ \begin{array}{c} \left[ I - K \cdot H(\underline{x}_{n+1}) \right]^T \\ + \left[ \left[ K \cdot R_{n+1} \cdot K^T \right]^{-1} \cdot \left[ I - K \cdot H(\underline{x}_{n+1}) \right] \cdot P_n \right]^{-1} \end{array} \right\} \end{aligned}$$

$$\begin{aligned}
&= [I - K \cdot H(\underline{x}_{n+1})] \cdot P_n \cdot \left\{ \begin{array}{l} [I - K \cdot H(\underline{x}_{n+1})]^T \\ + \left[ \begin{array}{l} [K \cdot R_{n+1} \cdot K^T]^{-1} \cdot P_n \\ - [K \cdot R_{n+1} \cdot K^T]^{-1} \cdot K \cdot H(\underline{x}_{n+1}) \cdot P_n \end{array} \right]^{-1} \end{array} \right\} \\
&= [I - K \cdot H(\underline{x}_{n+1})] \cdot P_n \cdot \left\{ \begin{array}{l} [I - K \cdot H(\underline{x}_{n+1})]^T \\ + \left[ \begin{array}{l} [R_{n+1} \cdot K^T]^{-1} \cdot P_n \\ - [R_{n+1} \cdot K^T]^{-1} \cdot H(\underline{x}_{n+1}) \cdot P_n \end{array} \right]^{-1} \end{array} \right\}
\end{aligned} \tag{4.59}$$

$$P_{n+1} = [I - K \cdot H(\underline{x}_{n+1})] \cdot P_n \cdot \left\{ \begin{array}{l} [I - K \cdot H(\underline{x}_{n+1})]^T \\ + \left[ \begin{array}{l} [R_{n+1} \cdot K^T]^{-1} \cdot \left[ \begin{array}{l} H(\underline{x}_{n+1}) \cdot P_n \\ \cdot H(\underline{x}_{n+1})^T \\ + R_{n+1} \end{array} \right]^{-1} \\ H(\underline{x}_{n+1})^{T-1} \cdot P_n^{-1} \cdot P_n \\ - [R_{n+1} \cdot K^T]^{-1} \cdot H(\underline{x}_{n+1}) \cdot P_n \end{array} \right]^{-1} \end{array} \right\}$$

$$\begin{aligned}
&= [I - K \cdot H(\underline{x}_{n+1})] \cdot P_n \cdot \left\{ \begin{array}{l} [I - K \cdot H(\underline{x}_{n+1})]^T + \\ \left[ [R_{n+1} \cdot K^T]^{-1} \cdot R_{n+1} \cdot H(\underline{x}_{n+1})^{T-1} \right]^{-1} \end{array} \right\} \\
&= [I - K \cdot H(\underline{x}_{n+1})] \cdot P_n \cdot \left\{ [I - K \cdot H(\underline{x}_{n+1})]^T + H(\underline{x}_{n+1})^T \cdot R_{n+1}^{-1} \cdot [R_{n+1} \cdot K^T] \right\} \\
&= [I - K \cdot H(\underline{x}_{n+1})] \cdot P_n \cdot \left\{ [I - K \cdot H(\underline{x}_{n+1})]^T + H(\underline{x}_{n+1})^T \cdot K^T \right\} \\
&= [I - K \cdot H(\underline{x}_{n+1})] \cdot P_n
\end{aligned}$$

Um in der Notation der üblichen Literatur zu bleiben, werden die Gl. (4.52), (4.58), (4.59) sowie die Gleichungen für die Zustandsschätzwert- und Fehlerkovarianzextrapolation noch

einmal zusammengefaßt dargestellt mit den Zeichen „-“ und „+“, die die Zeiten direkt vor und direkt nach einer Messung repräsentieren.

Zustandsschätzwertextrapolation:

$$\Delta \hat{\underline{x}}_{n+1}^- = \Phi(t_{n+1}, t_n) \cdot \Delta \hat{\underline{x}}_n^+ \quad (4.60a)$$

Fehlerkovarianzextrapolation:

$$P_{n+1}^- = \Phi(t_{n+1}, t_n) \cdot P_n^+ \cdot \Phi(t_{n+1}, t_n)^T \quad (4.60b)$$

Zustandsschätzwertaktualisierung:

$$\Delta \hat{\underline{x}}_{n+1}^+ = \Delta \hat{\underline{x}}_{n+1}^- - K \cdot \left[ H(\underline{x}_{n+1}) \cdot \Delta \hat{\underline{x}}_{n+1}^- - \Delta \underline{y}_{n+1} \right] \quad (4.60c)$$

Fehlerkovarianzaktualisierung:

$$P_{n+1}^+ = \left[ I - K \cdot H(\underline{x}_{n+1}) \right] \cdot P_{n+1}^- \quad (4.60d)$$

Kalman-Filter-Gain:

$$K = P_{n+1}^- \cdot H(\underline{x}_{n+1})^T \cdot \left[ H(\underline{x}_{n+1}) \cdot P_{n+1}^- \cdot H(\underline{x}_{n+1})^T + R_{n+1} \right]^{-1} \quad (4.60e)$$

$(\cdot)_{n+1}^-$  bedeutet, daß die zugehörige Quantität auf den bisherigen  $n$  Beobachtungen basiert, aber auf den weiteren Beobachtungszeitpunkt  $t_{n+1}$  extrapoliert ist.  $(\cdot)_{n+1}^+$  deutet an, daß die assoziierte Quantität für den Zeitpunkt  $t_{n+1}$  gültig ist und aktualisiert wurde, um den Effekt der  $(n+1)$ -ten Beobachtung herauszuarbeiten.

Die Gl. (4.60) stellen einen Satz von Gleichungen zur rekursiven Bearbeitung eines Zustandsvektors dar. Wenn  $n$  Beobachtungen  $\underline{y}_M(t_n)$ ,  $t = 1, 2, 3, \dots, n$ , und ein zugehöriger Schätz-

wert für  $\underline{x}(t)$  gegeben sind, ergeben diese Gleichungen ein Rezept zur Aktualisierung von  $\underline{x}_n(t_n)$  basierend auf einer neuen Beobachtung  $\underline{y}_M(t_{n+1})$ .

Gl. (4.60c) ist ein linearer Ausdruck, der den aktualisierten Wert von  $\underline{x}(t_{n+1})$  als eine Funktion des vorhergehenden Wertes  $\underline{x}(t_n)$ , einer Matrix  $K$  und dem Beobachtungsresiduum  $\Delta \underline{y}_{n+1} = \underline{y}_M(t_{n+1}) - \underline{g}[\underline{x}_{Ref}, t_{n+1}]$  ausdrückt. Die Matrix  $K$  wird Kalman-Gain genannt. Sie ist eine Funktion der Unsicherheit bzgl. des Zustandsvektors, d.h. der Kovarianz von  $\underline{x}_n$ , gegeben durch  $P_n(t_{n+1})$  und der Unsicherheit bzgl. der Beobachtung. Gl. (4.60d) aktualisiert die Unsicherheit bzgl. des Zustandsvektors, während Gl. (4.60a) die Zustandsübergangsmatrix zur Aktualisierung des Wertes des Zustandsvektors vom Zeitpunkt  $t_n$  auf den Zeitpunkt  $t_{n+1}$  angibt. Analog aktualisiert Gl. (4.60b) die Kovarianzmatrix.

Das Kalman-Gain skaliert die Korrekturgröße direkt auf den Zustandsvektor  $\Delta \hat{\underline{x}}_n$ . Das Gain bzw. der Gewinn ist relativ groß, d.h. er verursacht eine starke Änderung für den Zustandsvektorschätzwert unter zwei Bedingungen: Die Unsicherheit bzgl. des Zustandsvektors ist groß (wenn  $P_n(t_{n+1})$  groß ist), die Unsicherheit bzgl. der  $n+1$ -ten Beobachtung ist gering (wenn  $R_{n+1}$  klein ist). Dagegen wird der Gewinn klein sein, wenn der Zustandsvektor sehr genau bekannt ist (wenn  $P_n(t_{n+1})$  klein ist) und/oder wenn die  $n+1$ -te Beobachtung mit großer Unsicherheit behaftet ist (wenn  $R_{n+1}$  groß ist). Dieses Resultat ist schon vom Ansatz her sehr befriedigend, da der Sinn der Prozedur die Verbesserung ungenauer Zustandsvektorschätzwerte mit genauen neuen Beobachtungen ist und nicht die Verschlechterung genau geschätzter Zustandsvektoren durch ungenaue neue Daten.

#### 4.4.2 Prozeßablauf der sequentiellen Estimation

Eine Darstellung des Prozeßablaufs der sequentiellen Estimation zeigt Bild 4.5. Der Prozeßablauf geht von einem sog. Extended Kalman-Filter [2, 21, 45] mit dynamischem Rauschen aus. Eingangswerte sind ein Startwert für den Zustandsvektor,  $\underline{x}_0(t_0)$ , und eine zugehörige Kovarianzmatrix  $P_0(t_0)$ . Für jede Messung  $k = 1, 2, \dots, n$  werden die folgenden Schritte ausgeführt:

1. Bestimmung der Beobachtung  $\underline{y}_M(t_k)$  und ihrer zugehörigen Unsicherheit  $\mathbf{s}_k$ .

2. Lösung der differentiellen Bewegungsgleichungen Gl. (4.20) zur Überleitung des Zustandsvektors von der Zeit  $t_{k-1}$  zur Zeit  $t_k$ .
3. Berechnung der Zustandsübergangsmatrix  $\Phi(t_k, t_{k-1})$ .
4. Überleitung von  $\Delta \hat{x}$  und  $P_{k-1}$  von Zeit  $t_{k-1}$  zu Zeit  $t_k$  mit Hilfe der Zustandsübergangsmatrix (Gl. (4.60a) und Gl. (4.60b)).
5. Berechnung eines Prädiktorwertes der Beobachtung,  $g[\underline{x}(t_k), t_k]$  (Gl. (4.21)), des Beobachtungsresiduums Gl. (4.22) und der partiellen Ableitung des Prädiktorwertes der Beobachtung nach dem Zustandsvektor.
6. Berechnung des Kalman-Gains Gl. (4.60e).
7. Aktualisierung der Zustandsvektorkorrektur,  $\Delta \hat{x}^+(t_k)$  (Gl. (4.60c)), und der Kovarianzmatrix  $P_k^+(t_k)$  (Gl. (4.60d)).
8. Update des Referenzzustandsvektors:

$$\hat{\underline{x}}(t_k) = \underline{\hat{x}}(t_k) + \Delta \hat{\underline{x}}^+(t_k) \quad (4.61)$$

Die Schritte 1 bis 8 werden wiederholt, bis alle Beobachtungen verarbeitet sind.

Der Output der sequentiellen Estimation besteht aus einem aktualisierten Zustandsvektor  $\underline{\hat{x}}(t_n)$  und einer zugehörigen Kovarianzmatrix  $P_n(t_n)$ , jeweils basierend auf den  $n$  verfügbaren Beobachtungen.

#### 4.4.3 Implementierungsfragen

Die Implementierung eines sequentiellen Estimationsprozesses kann sehr effizient vollzogen werden. Dabei treten jedoch einige Implementierungsfragen auf, die hier wenigstens zum Teil und in Kürze adressiert werden sollen.

Ein potentiell Problem der sequentiellen Estimation ist die Divergenz. Das Problem tritt dann auf, wenn die Größe der Zustandsvektorkovarianzmatrix relativ klein wird. Das Kleinerwerden von  $P_{\Delta x}$  kommt nicht überraschend, wenn das Filter effektiv arbeitet, wenn das Wissen über den Zustandsvektor also immer größer wird, je mehr Beobachtungen prozessiert werden.

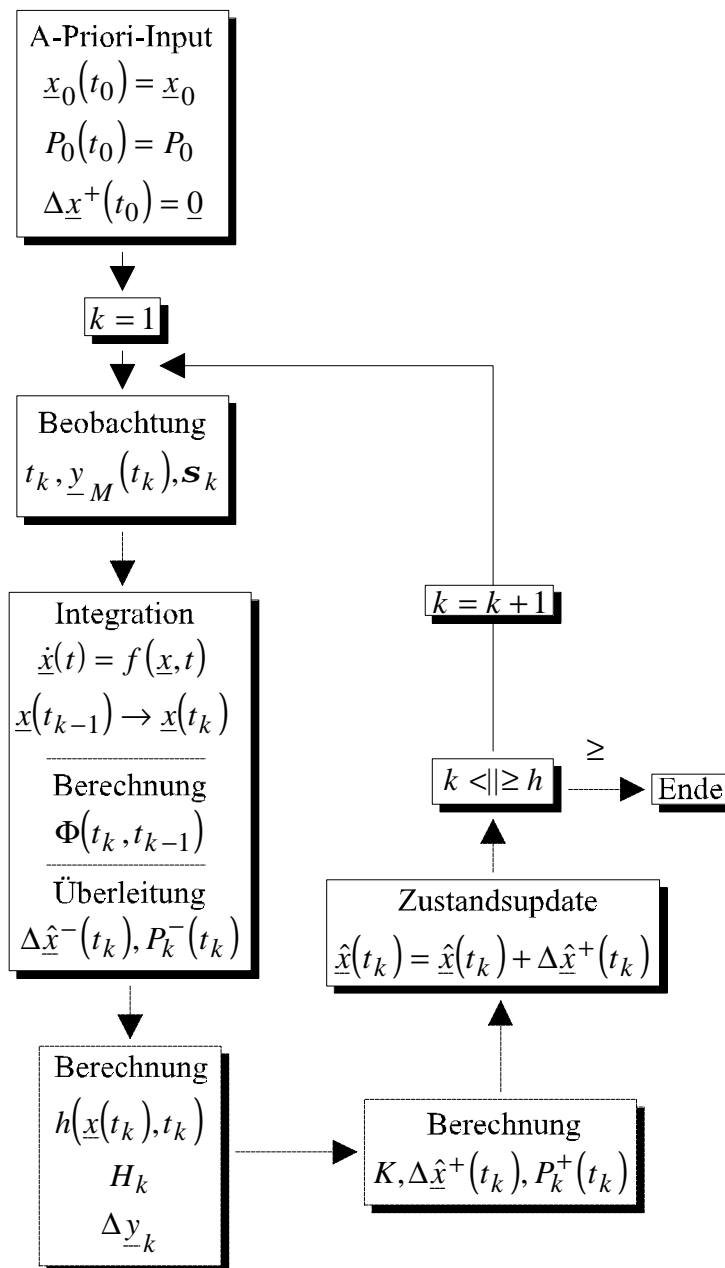


Bild 4.6: Rekursiver Filter-Prozeß mit dynamischem Rauschen

Wenn  $P_{\Delta x}$  kleiner wird, verringert sich das Kalman-Gain entsprechend. Daraus resultiert, daß der Estimator neue Datensätze praktisch ignoriert und keine signifikanten Verbesserungen für  $\Delta x$  auftreten. Im Prinzip ist dieses Filterverhalten erwünscht. Ein Problem wird es aber dann, wenn  $P_{\Delta x}$  sehr klein geworden ist und neue Messungen praktisch nicht mehr wahrgenommen werden. Um dieses Divergenzproblem zu bearbeiten, werden zwei Techniken benutzt: Die

Einführung von Prozeßrauschen und der Gebrauch eines Kurzzeitgedächtnisfaktors (Aging Timer).

Prozeßrauschen oder dynamisches Rauschen wird als weißes Rauschen zu einem linearen Zustandsperturbationsmodell addiert, d.h.:

$$\Delta \underline{\hat{x}}(t_{n+1}) = \Phi(t_{n+1}, t_n) \cdot \Delta \underline{x}(t_n) + \underline{\mathbf{h}} \quad (4.62)$$

Der Vektor  $\underline{\mathbf{h}}$  wird dabei mit den Eigenschaften:

$$E\{\underline{\mathbf{h}}\} = 0, E\{\underline{\mathbf{h}} \cdot \underline{\mathbf{h}}^T\} = Q \quad (4.63)$$

angenommen. Dieses dynamische Rauschen repräsentiert Ungenauigkeiten oder zufällige Fehler in dem dynamischen Zustandsmodell. Der Rauschvektor beeinflusst die Überleitung der Kovarianzextrapolationsgleichung:

$$P_n(t_{n+1}) = \Phi(t_{n+1}, t_n) \cdot P_n(t_n) \cdot \Phi^T(t_{n+1}, t_n) + Q(t_n) \quad (4.64)$$

Die Kovarianzmatrix hat damit eine minimale Größe von  $Q(t_n)$ . Dies reduziert das Divergenzproblem. Eine andere Technik zur Verringerung der Divergenz ist der Gebrauch eines „Fading Memory“. Das Konzept dabei ist die stärkere Gewichtung neuerer Daten. Dies kann durch die Multiplikation der Kovarianzmatrix mit einem Gedächtnisfaktor geschehen:

$$s = \exp\{\Delta t / \mathbf{t}\} \quad (4.65)$$

$\Delta t$  ist dabei das Intervall  $(t_{n+1}, t_n)$  und  $\mathbf{t}$  eine A-Priori spezifizierte Gedächtnis-Konstante. Der Faktor  $s$  verstärkt oder skaliert den gesamten Kovarianzprozeß:

$$P_n(t_{n+1}) = s \cdot \Phi(t_{n+1}, t_n) \cdot P_n(t_n) \cdot \Phi^T(t_{n+1}, t_n) \quad (4.66)$$

Jede dieser beiden Techniken kann das Divergenzproblem effektiv adressieren. Der Gebrauch hängt von physikalischen oder statistischen Einsichten in das Estimationsproblem ab.

Eine zweite Implementierungsfrage betrifft die Formulierung der Filtergleichungen. Der vorige Abschnitt zeigte einen linearisierten Gleichungssatz. Nichtlineare Formulierungen sind aber ebenso möglich. [21] beschreibt eine Näherung zweiter Ordnung. Auch wenn lineare Näherungen genutzt werden, gibt es Variationsmöglichkeiten bzgl. der Formulierung der Gleichungen (s. Matrixinversionslemmata, [35, 50]). [21] beschreibt eine sog. „Square-Root“-Formulierung und eine  $U \cdot D \cdot U^T$ -Formulierung, die beide darauf abzielen, die Stabilität des Estimators zu erhöhen.

Die Frage der Beobachtbarkeit ist sowohl für die Batch- als auch für die sequentielle Estimation von hoher Relevanz. Der Zustandsvektor kann nur schwach bezogen sein auf die Beobachtungsdaten, oder es kann ein hoher Grad von Korrelation zwischen den Komponenten des Zustandsvektors herrschen. In jedem Fall wird der Zustandsvektor dann unbestimmt sein mit Blick auf die Beobachtungsdaten. Daraus resultierend wird das Filter keinen genauen Schätzwert der Zustandsparameter generieren.

Die letzte hier adressierte Implementierungsfrage ist die der Daten-Editierung. Wie bei der Batchprozessierung ist auch für den sequentiellen Prozeß ein nicht unterscheidendes Editieren (Ignorieren) von Daten ohne eine solide physikalische Grundlage nicht zu empfehlen.

#### **4.4.4 Alpha-Beta-Filter**

Bevor das Kalman-Filter zur sequentiellen Estimation populär wurde, wurde das deterministische Alpha-Beta-Filter zum Tracking sich bewegender Objekte verwendet. Variationen dieses Filters wurden seit den späten 50-er Jahren für Einzelsensor-Tracking-Aufgaben genutzt. Die Formulierung dieses Filters ist besonders für analoge Implementierungen geeignet. Einen Überblick und Details geben [30, 41, 56]. Im folgenden Abschnitt wird das Alpha-Beta-Filter kurz zusammengefaßt dargestellt.

Alpha-, Alpha-Beta- und Alpha-Beta-Gamma-Filter beziehen sich auf deterministische sequentielle MSE (Mean Square Error) -Prozesse erster, zweiter bzw. dritter Ordnung, die jeweils einen MSE-Schätzwert des Zielzustandsvektors auf mit Rauschen behaftete Beobachtungen beziehen. [30] leitet Formulierungen für alle drei Formen ab.



Im Fall des Alpha-Beta-Filters sei nun ein eindimensionales Zielverfolgungsproblem zu lösen. Gesucht werden Position und Geschwindigkeit eines Objekts mit Beobachtungen in gleichen Zeitintervallen:

$$\underline{x} = \begin{pmatrix} x \\ \dot{x} \end{pmatrix}, \text{ Beobachtungen } \underline{z}(t_k) \text{ mit } t_k = 0, T, 2 \cdot T, \dots, k \cdot T \quad (4.67)$$

Die Bewegungsgleichungen seien modelliert durch eine abgeschnittene Taylor-Reihe:

$$\underline{x}(t_{k+1}) = \Phi(t_{k+1}, t_k) \cdot \underline{x}(t_k) \quad (4.68)$$

mit:

$$\Phi(t_{k+1}, t_k) = \begin{bmatrix} 1 & T \\ 0 & 1 \end{bmatrix} \quad (4.69)$$

Die Beobachtungen seien mit dem (unbekannten) Zustandsvektor durch die Gleichung:

$$\underline{z}(t_k) = h \cdot \underline{x}(t_k) \quad (4.70a)$$

verknüpft. Wenn nur die Position direkt beobachtet werden kann, gilt:

$$h = [1 \quad 0] \quad (4.70b)$$

Das Filter nimmt an, daß die geschätzte Position des Zieles aus dem gewichteten Mittelwert von geschätzter Position und einer neuen Beobachtung berechnet werden kann:

$$\begin{aligned} x_S(t_k) &= x_P(t_k) + \mathbf{a} \cdot [x_m(t_k) - x_P(t_k)] \\ \dot{x}_S(t_k) &= \dot{x}(t_{k-1}) + \frac{\mathbf{b}}{T} \cdot [x_m(t_k) - x_P(t_k)] \\ x_P(t_{k+1}) &= x_S(t_k) + T \cdot \dot{x}(t_k) \end{aligned} \quad (4.71)$$

wobei  $x_S(t_k)$  die geglättete (geschätzte) Position des Objektes zur Zeit  $t_k$ ,  $\dot{x}_S(t_k)$  die geglättete Geschwindigkeit zur selben Zeit und  $x_P(t_k)$  den vorhergesagten Positionswert zur Zeit  $t_k$  beschreiben. Der gemessene Wert des Zustandsvektors - hier skalar -  $x_m(t_k)$  ist entweder direkt beobachtbar oder über Gl. (4.70) berechenbar. Die Größen  $\mathbf{a}$  und  $\mathbf{b}$  sind Glättungskonstanten, deren Werte A-Priori bestimmt sind.

Die Performanz des Alpha-Beta-Filters hängt sehr stark von der Wahl der Werte für die Konstanten  $\mathbf{a}$  und  $\mathbf{b}$  ab, die wiederum von der Dynamik des Objekts und dem Beobachtungsrauschen abhängen.  $\mathbf{a}$  und  $\mathbf{b}$  werden häufig miteinander verknüpft, so daß sich das Auswahlproblem auf die Wahl eines einzigen Parameters reduziert, z.B. [41]:

$$\mathbf{a} = 2 \cdot \sqrt{\mathbf{b}} - \mathbf{b} \quad \text{und} \quad \mathbf{b} = \frac{\mathbf{a}^2}{2 - \mathbf{a}} \quad (4.72)$$

Die relativen Werte von  $\mathbf{a}$  und  $\mathbf{b}$  sind als Kompromiß zu suchen zwischen der Rauschbeeinflussung und der Fähigkeit des rekursiven Filters, auf abrupte Beschleunigungen des zu verfolgenden Objekts zu reagieren.

Im Gegensatz zu dieser Formulierung für ein Alpha-Beta-Filter nimmt ein Alpha-Filter an, daß sich das Ziel auf jeden Fall mit gleichförmiger Geschwindigkeit bewegt, d.h. Gl. (4.71b) reduziert sich zu:

$$\dot{x}_S(t_k) = \dot{x}(t_{k-1}) \quad (4.73)$$

Das Alpha-Beta-Gamma-Filter erweitert das Konzept zur Aufnahme einer Beschleunigungskomponente.

Der Wert des Alpha-Beta- und anderer ähnlicher Filter liegt in der Einfachheit, mit der sie implementiert werden können und den geringen benötigten Rechenleistungen. Dies erlaubt die gleichzeitige Verfolgung mehrerer Ziele mit Hilfe relativ leistungsschwacher Rechner. Daraus resultiert die Popularität dieser Filter in früheren Zeiten. Die Alpha-Beta-Formulierung kann für den Fall mehrerer Sensoren ausgeweitet werden [41]. Jedoch muß für diesen Fall eine umfangreiche Ausgleichsrechnung aufgrund der asynchronen Beobachtungen durchgeführt wer-

den. Das Alpha-Beta-Filter liefert bei weitem nicht die Ergebnisse einer Kalman-Filterung, aber in einigen Fällen ist es zur Problemlösung vollkommen ausreichend.

Als Beispiel seien Ergebnisse eines Alpha- und eines Kalman-Filters [35] dargestellt mit dem Modell:

$$\begin{aligned}x(k+1) &= x(k) + \frac{T^2}{2} \cdot w(k) \\y(k) &= x(k) + v(k)\end{aligned}\tag{4.74}$$

wobei  $w(k)$  unbekannte Zielmanöver beschreibe und  $v(k)$  das Meßrauschen. Diese Rauschgrößen seien Gauß-verteilt und weiß.

Es bestätigt sich, daß die Ergebnisse des Alpha-Filters nicht an die des Kalman-Filters herankommen, jedoch ist der Rechenaufwand für letzteres um ein Vielfaches größer [A.3].



Bild 4.7a: Beispiel: Simulierte wahre Zustandswerte

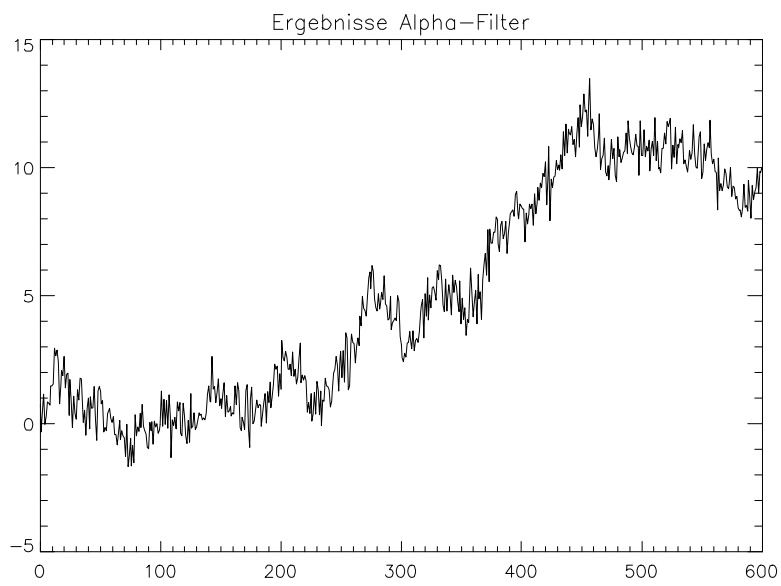


Bild 4.7b: Beispiel: Zustandswerte nach Alpha-Filterung

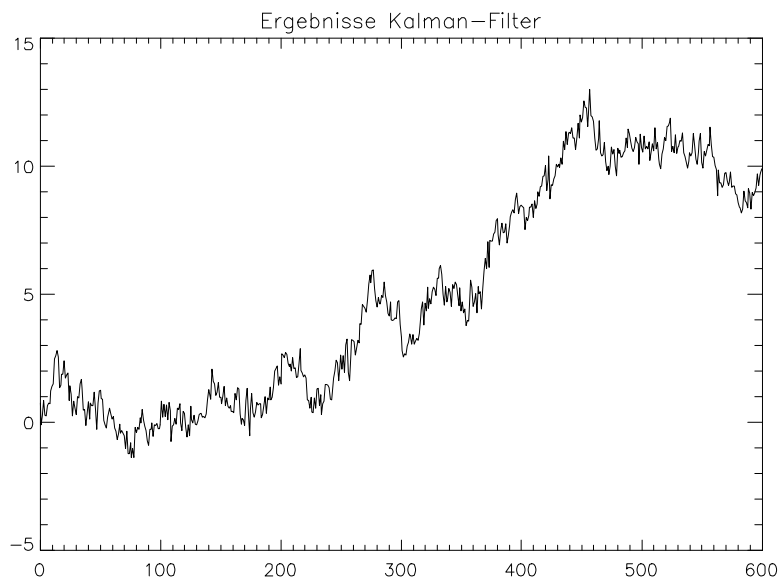


Bild 4.7c: Beispiel: Zustandswerte nach Kalman-Filter




Bild 4.7d: Beispiel: Fehler Alpha-Filter




Bild 4.7e: Beispiel: Fehler Kalman-Filter

## 4.5 Kovarianzfehler-Estimation

Bei der Diskussion der Estimationstechniken in den beiden letzten Abschnitten bestand das Ziel aus der Schätzung des Wertes eines Zustandsvektors  $\underline{x}$  bei gegebenen Beobachtungen  $\underline{y}_i$ .

Batch- sowie sequentielle Ansätze wurden zur Datenverarbeitung mit dem Ziel eines optimalen Schätzwertes für den Zustandsvektor entwickelt. Bei einigen Anwendungen liegt das Interesse jedoch nicht in dem spezifischen Wert für den Zustandsvektor, sondern in der resultierenden Unsicherheit, z.B. kann das Design einer neuen Sensorpalette bzw. -konfiguration für eine Plattform einen Kompromiß zwischen der Anzahl und der Genauigkeit von Sensoren und Messungen zur Bestimmung des Zustandsvektors innerhalb bestimmter Grenzen erfordern.

Die Raumexpeditionen von Weltraumbehörden wie der NASA sind ein weiteres Beispiel für Applikationen, in denen die Zustandsvektorgenauigkeit von hohem Interesse ist. Sie erfordern genaue Planungen zur Bestimmung der verwendeten Sensoren, der Beobachtungsraten und -intervalle sowie anderer Faktoren, um dann entscheiden zu können, ob eine Trajektorie mit ausreichender Genauigkeit eingehalten und bestimmt werden kann, damit der Kontakt zu einem Space-Shuttle oder einem Satelliten über eine längere Zeitperiode aufrechterhalten werden kann. Der folgende Abschnitt beschreibt die Methode der Kovarianzfehleranalyse, die solche Berechnungen erlaubt.

Das gegebene Problem ist das übliche Beobachtungsproblem, bei dem ein oder mehrere Sensoren ein Objekt mit unbekanntem Zustandsvektor  $\underline{x}$  beobachten. Die Beziehung zwischen Beobachtungen und Zustandsvektor ist gegeben durch:

$$\underline{y} = f(\underline{x}, \underline{z}) + \underline{h} \quad (4.75)$$

mit dem Zustandsvektor  $\underline{x}$ , dem unbekanntem Beobachtungsrauschen  $\underline{h}$  und  $\underline{z}$  einem Vektor, der Modellparameter beschreibt. Er umfaßt eine Gruppe von Parametern, deren Wert als konstant angenommen wird, aber nicht genau bekannt ist. Beispiele solcher Parameter sind Koeffizienten des Geopotentials der Erde, der atmosphärischen Dichte oder Parameter mit Bezug auf das Beobachtungsmodell (z.B. Sensor-Bias) [36].

Der Batch-Ansatz zur Bestimmung des besten Schätzwertes eines Zustandsvektors  $\underline{x}$  minimiert die Verlustfunktion:

$$l(\underline{x}) = \left[ \underline{y} - f(\underline{x}, \underline{z}) \right]^T \cdot W \cdot \left[ \underline{y} - f(\underline{x}, \underline{z}_0) \right] + (\underline{x} - \underline{x}_0)^T \cdot P_{\Delta x_0} \cdot (\underline{x} - \underline{x}_0) \quad (4.76)$$

die eine gewichtete Bayes'sche Verlustfunktion darstellt mit der Kovarianz  $P_{\Delta x_0}$  von  $\underline{x}$  und einer A-Priori-Gewichtungsmatrix  $W$ .

Der beste Schätzwert für den Zustandsvektor  $\underline{x}$  wird durch eine linearisierte iterative Lösung von Gl. (4.73) erreicht. Die Form der Lösung kann aus Tabelle 4.2 entnommen werden.

Der Wert von  $P_{\Delta x_0}$  sei im folgenden gesucht. Angenommen sei dazu, daß die Meßgrößen  $y_i$  keinen Bias aufweisen, Zufallsvariablen mit einer Gauß'schen Wahrscheinlichkeitsverteilung seien und daß die Beobachtungen stochastisch unabhängig seien, d.h. daß der Meßfehler zur Zeit  $t_i$  unabhängig von den Meßfehlern zu jeder anderen Zeit  $t_k$  sei. Unter diesen Bedingungen berechnet sich die Kovarianz wie folgt [A.5]:

$$P_{\Delta x} = \Psi \cdot \left\{ \begin{array}{l} F^T \cdot W \cdot E \cdot P_{\Delta z_0} \cdot E^T \cdot W \cdot F \\ + \Psi^{-1} + F^T \cdot W \cdot E \cdot C^T_{\Delta x_0 \Delta z} \cdot P_{\Delta x_0}^{-1} \\ + P_{\Delta x_0}^{-1} \cdot C_{\Delta x_0 \Delta z} \cdot E^T \cdot W \cdot F \end{array} \right\} \cdot \Psi^T \quad (4.77)$$

mit:

$$\Psi = \left[ F^T \cdot W \cdot F + P_{\Delta x_0}^{-1} \right]^{-1} \quad (4.78)$$

Dabei ist  $F$  die Matrix der partiellen Ableitungen der Funktion  $f$  entsprechend Gl. (4.72) nach dem Zustandsvektor  $\underline{x}$ :

$$F = \frac{\mathcal{J}f}{\mathcal{J}\underline{x}} \quad (4.79)$$

und  $E$  die Matrix der partiellen Ableitungen der Funktion  $f$  nach dem Vektor  $\underline{z}$  der Modellparameter:

$$E = \frac{\mathbb{I}f}{\mathbb{I}z} \quad (4.80)$$

Die Größe  $P_{\Delta z_0}$  ist die A-Priori-Kovarianzmatrix der Modellparameter. Die Korrelationsmatrix zwischen A-Priori-Zustandsvektor  $\underline{x}_0$  und A-Priori-Vektor der Modellparameter  $\underline{z}_0$  wird durch  $C_{\Delta x_0 \Delta z_0}$  beschrieben.

In Gl. (4.74) tauchen die Beobachtungsresiduen  $\Delta \underline{y}$  nicht auf. Die Kovarianzmatrix des Zustandsvektors kann damit aus den folgenden Informationen berechnet werden:

1. A-Priori-Kovarianz des Zustandsvektors,  $P_{\Delta x_0}$
2. A-Priori-Kovarianz der Modellparameter,  $P_{\Delta z_0}$
3. Partielle Ableitungen der Beobachtungsgrößen nach dem Zustandsvektor und dem Vektor der Modellparameter
4. Korrelationsmatrix  $C_{\Delta x_0 \Delta z_0}$  (i.A. unbekannt und daher vernachlässigt)

Diese Formulierung erlaubt die Berechnung der Unsicherheit bzgl. des Zustandsvektors als eine Funktion der Unsicherheiten bzgl. der Beobachtungen und der Modellparameter ohne tatsächliche Beobachtungen und ohne die Schätzung von  $\underline{x}$ .

Ein Kovarianzfehlerschätzwert kann sowohl sequentiell als auch in einem Batch-Modus formuliert werden.

Die Kovarianzfehleranalyse kann wertvolle Ergebnisse liefern für das Design von Sensoren. Dieser Technik gebührt jedoch auch eine gehörige Portion Skepsis. Besonders die Annahme von nicht mit einem Bias behafteten, Gaußverteilten, stochastisch unabhängigen Messungen kann in die Irre führen. Effekte wie nicht-weißes Rauschen, Beobachtungs-Bias und Nebenkana-  
 linterferenz können eine Estimation stören. Die Kovarianz  $P_{\Delta x}$ , Gl. (4.77), wird optimistisch getönt sein, d.h. die tatsächlichen Fehler bzgl. des geschätzten Zustandes werden i.A. größer als durch die Analyse berechnet sein. Die Kovarianzfehleranalyse ist nützlich zur Untersuchung der relativen Größe vielfältiger Effekte wie z.B. Modellierungsfehlern. Absoluten Fehlerprä-  
 diktionen ist jedoch zu mißtrauen.



## 5. Identitätsdeklaration

### 5.1 Identitätsdeklaration und Mustererkennung

Das Problem der Positions- und Identitätsfusion wurde in Kapitel 2 behandelt. Bild 2.2 illustrierte das Konzept der positionellen Fusion, indem mehrere Sensoren gezeigt wurden, die Daten aufnehmen und die in Beziehung zum kinematischen Zustand einer Betrachtungseinheit gesetzt werden konnten. Kapitel 3 behandelte die Datenassoziation und das letzte Kapitel beschrieb Techniken, durch die mehrere verschiedene Datensätze fusioniert werden können, um einen Schätzwert für Position und Geschwindigkeit eines Objektes zu erhalten. Diese Techniken sind auch anwendbar auf die Fusion von Attributdaten wie der Frequenz eines Emitters oder anderer nichtkinematischer Charakteristika. Bei der Diskussion der positionellen Fusion wurden alternative Architekturen beschrieben, die diese Fusion auf verschiedenen Ebenen erlauben: Von der Fusion von Rohdaten bis zu der von Zustandsvektoren unterschiedlicher Sensoren.

Positionelle Fusion und die Fusion der Daten mehrerer Sensoren zur Bestimmung des Schätzwertes einer Objektidentität sind verwandte Probleme: Positionelle Information kann bei der Bestimmung der Identität (und Funktion) einer Betrachtungseinheit wichtig sein, während Identitätsinformation nützlich sein kann beim Estimationsproblem, besonders zur Unterscheidung eng beieinander liegender Ziele. In einem realen Fusionssystem wären diese Prozesse miteinander verbunden.

Identitätsfeststellungsprobleme treten in einer ganzen Reihe von Situationen auf. Die militärischen Applikationen (s. Kap. 1) beschreiben Beispiele, bei denen ein oder mehrere Sensoren Sender, Plattformen und Waffensysteme beobachten. Militärische Datenfusionsapplikationen versuchen, die beobachteten Objekte zu lokalisieren, zu charakterisieren und zu identifizieren. Ein spezifisches Beispiel könnte ein Bedrohungsindikator an Bord eines taktischen Flugzeuges sein, der anzeigt, ob das Flugzeug durch ein Waffenleitsystem illuminiert wird (z.B. Laser oder Raketenleitradar). Ein weiteres Beispiel ist der Gebrauch von Radarrückstreuquerschnittsdaten (RCS) zur Bestimmung, ob ein Objekt ein Raketenkörper, ein Fragment oder sonst irgend etwas darstellt. Identification-Friend-Foe-Neutral (IFFN) -Ausrüstungen benutzen Signaturen und verwandte Daten, um die Identifizierung eines gegnerischen oder freundlichen Flugzeuges zu versuchen. Detailliertere und mehr Zeit benötigende Analysen werden manchmal unter-

nommen, um bestimmte Sender oder Waffenplattformen wie über einen Fingerabdruck zu identifizieren.

Nichtmilitärische Beispiele für Identitätsfeststellungsprobleme sind z.B. die Identifikation und Isolation von Gerätefehlern in komplexen Systemen, der Gebrauch von Sensordaten zur Kontrolle von Fertigungsprozessen [40] und teilautomatisierte Systeme zur Überwachung der menschlichen Gesundheit über medizinische Proben und Monitore. Das Konzept der Identitätsdeklaration bzw. -feststellung wurde in Kapitel 2 vorgestellt. In Bild 2.4 wurden mehrere Sensoren dargestellt, die einige Objekte beobachten. Ein Entscheidungsebenenprozeß wurde gezeigt, bei dem die Sensordaten (z.B. Zeitreihen, Attribut-Vektor, Bilddaten) in Charakteristikavektoren  $\underline{y}_i$  transformiert wurden, die die Rohdaten darstellten. Anschließend wurde jeder Charakteristikavektor durch einen Mustererkennungsprozeß in die Feststellung einer Objektidentität transformiert.

Am Ende der Prozeßkette wurden die Identitätsdeklarationen mehrerer Sensoren zur Bildung einer gemeinsamen Objektidentitätsfeststellung fusioniert. Die ersten beiden Schritte dieses Prozesses - Charakteristika-Extraktion und Identitätsdeklaration - sind in Bild 5.1 für einen Sensor dargestellt.

Die Charakteristika-Extraktion transformiert die vom Sensor gelieferten Daten zu einer Repräsentation dieser Daten. Charakteristika können für analoge, digitale und Bilddaten entwickelt werden. Beispiele für aus Zeitreihen abgeleitete Charakteristika sind:

- Identifikation, Ort und Amplitude von Spitzen
- Spitzenbreite und -dauer
- Mittlere Signalamplitude
- Standardabweichung der Varianz um einen Mittelwert
- Frequenztransformationsparameter wie Fourier-Koeffizienten
- Ort und Amplitude spektraler Spitzen

Charakteristika, die zur Repräsentation von Bilddaten dienen können, sind z.B.:

- Identifikation und Bestimmung von Eigenschaften von Bildsegmenten
- Form, Länge, Breite und Orientierung von Objekten sowie spektrale Eigenschaften (z.B. Farbe)

Charakteristika sind eine Darstellung von Daten, die in einem Identifikationsprozeß nützlich sein können. Zum Beispiel kann der Mensch andere Menschen durch einen Abstraktionsprozeß erkennen, der auf bestimmte Charakteristika wie besondere Bewegungen, Stimmlage, Haarfar-

be oder bestimmte Gesichtszüge (z.B. große Nase) fokussiert. (Politische) Karikaturisten verwenden diese Eigenschaften zur Erzeugung sehr einfacher, aber sofort erkennbarer Figuren. Die Charakteristikaextraktion vermindert ganz allgemein - nicht nur bei Karikaturen - den Informationsgehalt von Sensordaten.

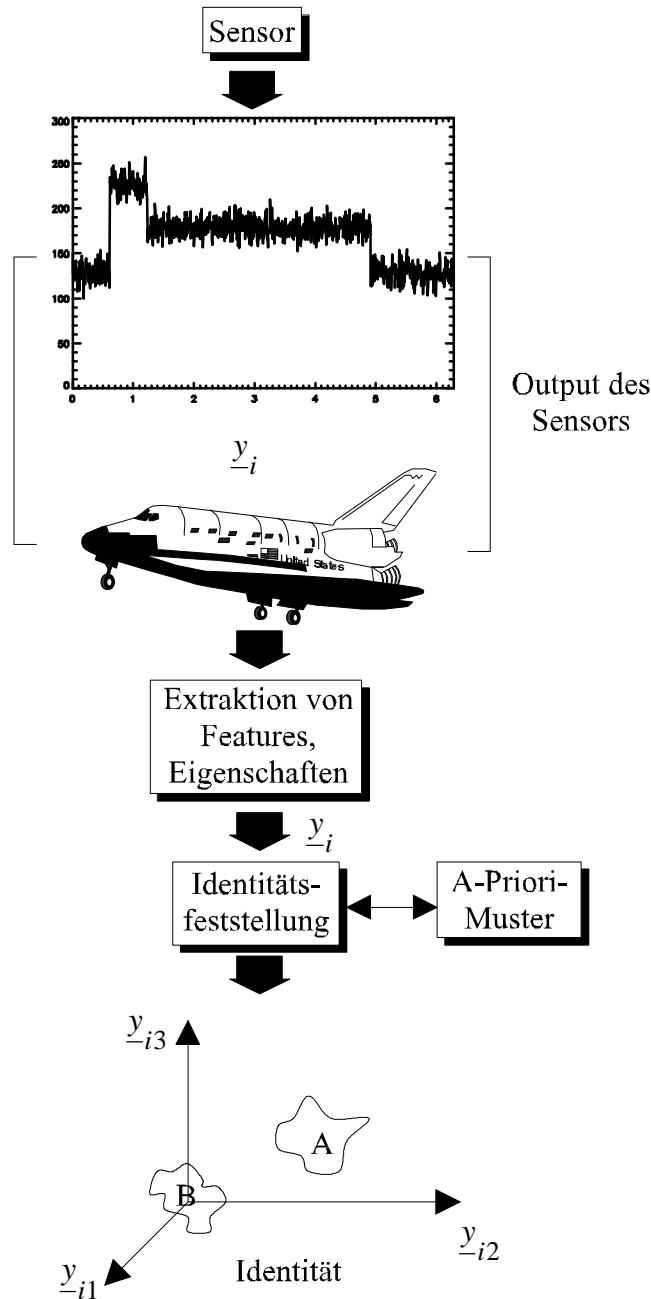


Bild 5.1: Konzept einer Identitätsfeststellung bei einem Sensor

Der zweite in Bild 5.1 illustrierte Schritt ist ein Identitätsdeklarationsprozeß, der einen Charakteristikavektor in einen Bereich des Charakteristikaraumes abbildet. Der untere Bereich von Bild 5.1 zeigt einen dreidimensionalen Charakteristikavektor  $\underline{y}_i$  mit den Einheitsvektoren  $\underline{y}_{i1}$ ,  $\underline{y}_{i2}$  und  $\underline{y}_{i3}$ . Die Komponenten von  $\underline{y}_i$  können in den durch die Einheitsvektoren aufgespannten Raum abgebildet werden. Wenn die abgebildeten Regionen A und B die Identitäten zweier separater Objekte darstellen, dann bedingt der Ort von Vektor  $\underline{y}_i$  in Region A des Charakteristikaraumes die Identität des Vektors  $\underline{y}_i$  mit Objekt A. Damit kann der Identitätsfeststellungsprozeß mit Hilfe von Charakteristikavektoren als analog zum Prozeß bei der Datenassoziation angesehen werden.

Eine Schwierigkeit im Identifikationsprozeß tritt dann auf, wenn die Regionen im Charakteristikaraum, die unterschiedliche Objekte darstellen, sich überlappen. Dabei entsteht eine Mehrdeutigkeit, die es nicht erlaubt, aufgrund der beobachteten Charakteristika eine eindeutige Identität festzustellen. Der Identitätsfeststellungsprozeß benutzt Mustererkennungstechniken wie Templating (Schablonisierung), Cluster-Analyse, adaptive neuronale Netzwerke oder wissensbasierte Techniken zur Erkennung der Identität eines Objektes. Jede dieser Techniken erfordert eine zweiphasige Struktur. In einem Trainingsmodus werden Daten bekannter Betrachtungseinheiten zur Etablierung von Grenzwerten genutzt, die den Charakteristikaraum in Regionen partitionieren. Dabei steht jede Region für die Identität eines Objektes oder einer Betrachtungseinheit (z.B. parametrische Grenzwerte für Templates oder Cluster-Grenzwerte für die Cluster-Analyse). Mit der Etablierung der Beziehungen zwischen Charakteristikavektoren und Identität können die Mustererkennungstechniken in einem Erkennungs- oder Klassifikationsmodus betrieben werden. In diesem Modus werden einzelne Charakteristikavektoren dadurch klassifiziert, daß der Ort des beobachteten Vektors in Bezug auf die Entscheidungsgrenzwerte des Charakteristikaraumes festgestellt wird.

### 5.1.1 Parametrische Templates

Vorbestimmte parametrische Grenzwerte definieren hierbei Identitätsklassen, z.B. kann eine gepulste Senderklasse durch vorbestimmte Grenzwerte für Frequenz  $f$ , Pulsbreite  $\Delta t$  und Pulswiederholrate  $PRF$  charakterisiert sein. Wenn für die beobachtete Sendung  $(f, \Delta t, PRF)$  gilt:

$$\begin{aligned}
f_{A,\min} &< f < f_{A,\max} \\
\Delta t_{A,\min} &< \Delta t < \Delta t_{A,\max} \\
PRF_{A,\min} &< PRF < PRF_{A,\max}
\end{aligned}
\tag{5.1}$$

dann wird sie als Mitglied der Senderklasse A festgestellt. Die Klassifikation basiert auf dem Ort eines Charakteristikavektors relativ zu den Template-Grenzwerten. S. 5.2.

### **5.1.2 Cluster-Algorithmen**

Cluster-Algorithmen bezeichnen eine Klasse von Algorithmen, die heuristische Methoden zur Gruppierung von Daten in natürliche Schwerpunkte, die die Objektidentität feststellen, verwenden. Die Klassifikation basiert hier auf der Nähe eines Charakteristikavektors zu trainierten Schwerpunkten im Charakteristikaum. S. 5.3.

### **5.1.3 Neuronale Netzwerke**

Adaptive neuronale Netzwerke emulieren biologische Nervenverbindungen, um hiermit eine nichtlineare Transformation zwischen einem Eingangscharakteristikavektor und Ausgangsidentitätsklassen durchzuführen. S. 5.4.

### **5.1.4 Physikalische Modelle**

Physikalische Modelle können benutzt werden, um beobachtete Signaturen auf vorhergesagte Signaturen abzubilden. Wenn die Korrelation zwischen den Daten aus dem physikalischen Modell und den Beobachtungsdaten eine bestimmte Schwelle überschreitet, dann ist die Identität eines Objektes mit einer spezifizierten Wahrscheinlichkeit gefunden, die durch den Schwellwert bestimmt wird. S.5.5.

### **5.1.5 Wissensbasierte Ansätze**

Inferenztechniken bieten einen Ansatz zur Lösung des Identitätsfeststellungsproblems. Verbreitete Methoden bilden die Identität über syntaktische Darstellungen (Aufteilung der Objektidentität in erkennbare Elemente) auf parametrische Charakteristika ab. S. 5.6.

Der Entscheidungsebenenansatz zur Identitätsfusion, der in Bild 5.1 illustriert wurde und in diesem Abschnitt beschrieben wird, verläuft analog zur Zustandsvektorfusion bei der positionellen Estimation. Jeder Sensor führt eine unabhängige Verarbeitung zur Generierung eines Schätzwertes durch. Diese Schätzwerte werden danach durch einen Fusionsprozeß kombiniert. Bild 5.2 zeigt drei Ansätze für die Fusion von Identitätsdaten:

1. Entscheidungsebenenfusion,
2. Charakteristikaebenenfusion und
3. Datenebenenfusion.

Neben diesen generellen Ansätzen können auch hybride Ansätze verwendet werden. Bild 5.2a illustriert die Entscheidungsebenenfusion. Bei diesem Ansatz führt jeder Sensor eine Transformation durch, um eine unabhängige Identität festzustellen. Diese Deklarationen werden dann einem Fusionsprozeß unterworfen. Techniken dazu sind z.B. Voting-Verfahren, Bayes'sche Inferenz, Dempster-Shafer, verallgemeinerte Beweisverarbeitungstheorie und einige Ad-hoc-Methoden. Diese Techniken werden in Kapitel 6 beschrieben.

In Bild 5.2b ist ein Charakteristikaebenenansatz dargestellt. Jeder Sensor beobachtet ein Objekt und erzeugt durch Eigenschaftextraktion einen Charakteristikavektor jeden Sensors. Diese Charakteristikavektoren führen dann über einen Fusionsprozeß zur Feststellung einer Identität auf Basis des gemeinsamen Charakteristikavektors. Hierfür anwendbare Techniken sind z.B. Cluster-Analyse, neuronale Netzwerke, Templates und wissensbasierte Techniken. In diesem Charakteristikaebenenansatz muß ein Assoziationsprozeß verwendet werden, um die Charakteristikavektoren in sinnvolle Gruppen einzuteilen. Positionsinformation kann dafür nützlich sein, weil die Charakteristikavektoren im Prinzip sehr unterschiedliche Größen (z.B. Fourierkoeffizienten, Zeitbereichscharakteristika) darstellen.

Bei der Datenebenenfusion in Bild 5.2c werden Daten von entsprechenden Sensoren direkt einem Fusionsprozeß unterworfen. Die weiteren Glieder dieser Prozeßkette sind Charakteristikaextraktion und Identitätsfeststellung. Um diese Datenebenenfusion ausführen zu können, müssen die Sensoren entweder identisch sein (z.B. mehrere Infrarotsensoren) oder ergänzend (z.B. ein Infrarot- und ein bildgebender Sensor). Um sicherzustellen, daß die durch den Fusionsprozeß verarbeiteten Daten sich auf dasselbe Objekt bzw. dieselbe Gegebenheit beziehen, wird der Assoziationsprozeß auf die Rohdaten angewandt. Nach der Fusion der Sensordaten verläuft der Identifikationsprozeß genau wie der Prozeß für einen Einzelsensor (s. Bild 5.1). Für bildgebende Sensoren wird die Datenebenenfusion oft als Pixelebenenfusion bezeichnet.

Das Ausmaß, in dem Datenebenenfusion für verschiedene Datentypen durchgeführt werden kann, hängt von der Verfügbarkeit genauer physikalischer Modelle ab, z.B. können Daten eines synthetischen Aperturradars mit in verschiedenen Wellenlängenbereichen (sichtbar, Infrarot) gewonnenen Daten einem Fusionsprozeß zugeführt werden, wenn die entsprechenden Korrekturen zur Berücksichtigung der geometrischen Perspektive, der Bildskalierung und anderer Faktoren modelliert werden können.

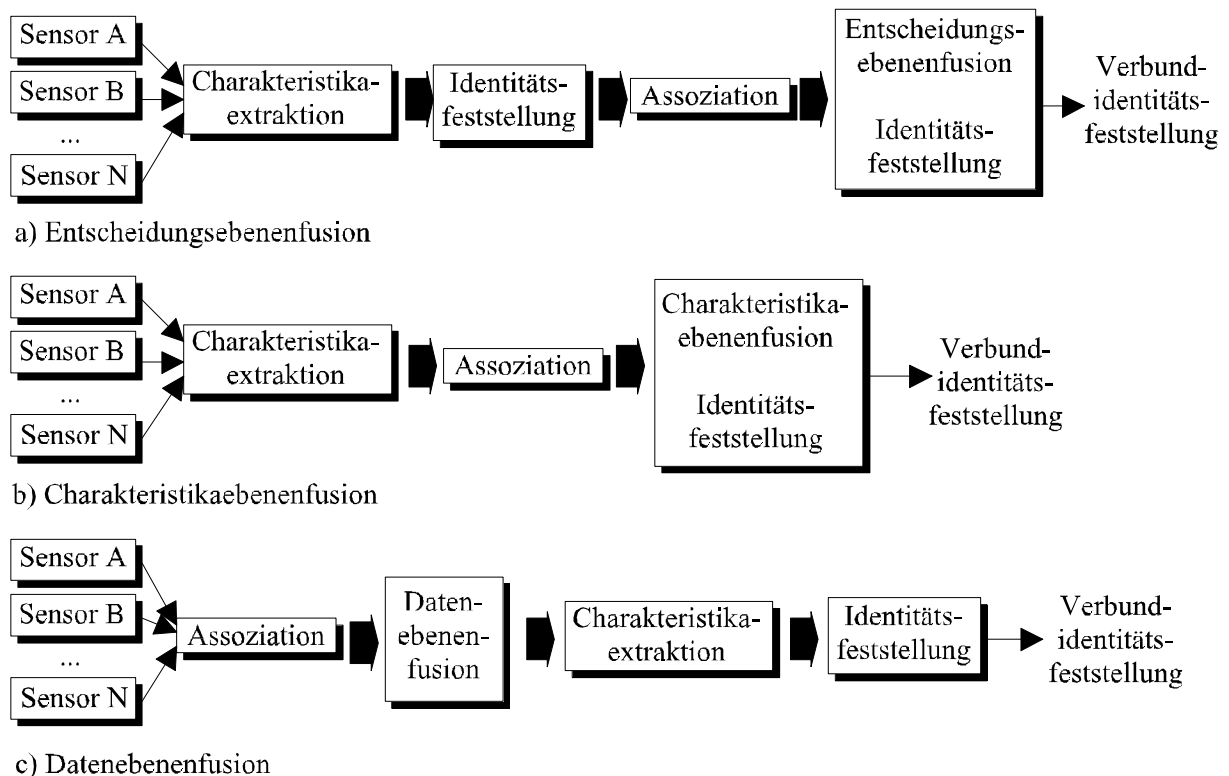


Bild 5.2: Alternative Architekturen zur Datenfusion

Eine Gewichtung der einzelnen Ansätze kann nur ähnlich wie bei den positionellen Fusionsarchitekturen vorgenommen werden. I.A. ist die Genauigkeit um so höher, je näher die Information zur Quelle dem Fusionsprozeß unterworfen wird. Damit ist die Datenebenenfusion potentiell genauer als die Charakteristikaebenenfusion, und diese wiederum genauer als die Entscheidungsebenenfusion. Die Datenebenenfusion ist jedoch i.A. nur sinnvoll für Sensoren, die dieselben Beobachtungstypen erzeugen. Die Auswahl eines Fusionsansatzes hat auch Auswirkungen auf die Systemimplementierung, z.B. ist die prozeßinterne Datenlast sehr unterschiedlich, je nachdem, ob Daten, Charakteristika oder Identitätsdeklarationen an einen zentralen Fusionsprozeß geschickt werden müssen. Auch hier gilt wieder, daß ein allgemeines Kochre-

zept nicht gegeben werden kann, daß stattdessen im Einzelfall nach einer genauen Analyse der Situation entschieden werden muß.



## 5.2 Charakteristikaextraktion

Charakteristika bzw. Eigenschaften werden oft bei Identitätsdeklarationen und in Identitätsfusionsprozessen genutzt. Charakteristika sind eine Abstraktion der Rohdaten mit dem Ziel, einen reduzierten Datensatz zu erhalten, der genau und pointiert die eigentliche Information enthält. Die Transformation der Rohdaten auf einen Charakteristikavektor wird Charakteristikaextraktion genannt. Der Prozeß ist mit einigen Einschränkungen dem der Datenkompression vergleichbar. Datenkompression sucht eine reduzierte Form der Daten, die es erlaubt, die Daten zu einem späteren Zeitpunkt ohne Verlust der relevanten Information wiederherzustellen. Ein Beispiel für Datenkompression ist die Anwendung eines Differentiators auf eine binäre Folge. Ein binärer Datensatz:

$$\{y(t_i)\} = \{0,0,1,1,1,0,0,0,0,\dots\} \quad (5.2)$$

kann komprimiert werden in:

$$\{y(t_i)\} = \{0(2),1(3),0(4),\dots\} \quad (5.3)$$

wobei die Zahlen in runden Klammern die Länge bedeuten, bevor ein Übergang von 0 nach 1 oder 1 nach 0 in der Folge eintritt.

Die Charakteristikaextraktion versucht, Eigenschaften der Daten zu finden, die bei der Identifikation helfen können. I.A. erlauben diese Eigenschaften keine vollständige Rekonstruktion der originalen Daten. Z.B. würde die genaue Darstellung von empfangenen Sendedaten die Spezifikationen von Signalamplitude, Polarisation, Frequenz und anderer Kenngrößen als Funktion der Zeit erfordern. Die zur Senderidentifikation notwendigen Eigenschaften können aber nur in mittlerer Frequenz, Polarisation und PRF bestehen. Andere Informationen wie die Signalamplitude sind von geringem Wert für die Identifikation, d.h. die Darstellung der Daten für Komprimierungszwecke kann sehr unterschiedlich sein von der Entwicklung eines Charakteristikavektors für Identifikationszwecke.

Es ist nicht unbedingt notwendig, Eigenschaften für den Identifikationsprozeß zu extrahieren. Rohdaten können auch direkt genutzt werden. Ein Beispiel dafür ist der Prozeß, der für die „Absolute Image Registration“-Verarbeitung von Landsat-Daten genutzt wird. Hall beschreibt

in [25] eine Methode zur Lokalisierung von Referenzpunkten in diesen Bildern. Die Methode verwendet vorgeschichtete Bilder von einfach erkennbaren geographischen Bereichen. Diese Referenzbilder werden durch Korrelation mit neuen Bildern verglichen. Wegen der dafür benötigten Rechenleistung wird dies i.A. nur innerhalb eines kleinen Ausschnitts des Gesamtbilds durchgeführt. Das Zentrum des Referenzbildes wird an jeden  $(i,j)$ -Pixelort des neuen Bildes gelegt. Von dort aus wird dann die zweidimensionale Korrelation durchgeführt. Das globale Maximum der Korrelationskoeffizienten wird gefunden. Wenn dieser maximale Koeffizient einen A-Priori-Schwellwert überschreitet, dann werden die Pixelkoordinaten im neuen Bild als präziser Ort des Referenzbildes festgestellt, dessen geographische Koordinaten bekannt sind. Dieses Vorgehen ermöglicht eine genaue geographische Referenzierung der Landsat-Bilder. Temporäre Phänomene wie z.B. Wolken können so geographisch genau bestimmt werden. Ähnlich können auch Flugzeuge, Panzer usw. in Überwachungsdaten identifiziert werden.

Analog kann auch für nicht bildhafte Daten vorgegangen werden. Z.B. könnte die RCS eines beobachteten Objektes mit den RCS-Signaturen einer Bibliothek verglichen werden. In diesem Fall wird der Identifikationsprozeß durch die Berechnung von Korrelationskoeffizienten zur Bestimmung der Korrelation zwischen beobachteten Daten und gespeicherten Signaturdaten durchgeführt. Wenn der berechnete Korrelationskoeffizient einen A-Priori-Schwellwert überschreitet, dann kann das beobachtete Objekt mit einiger Wahrscheinlichkeit als identifiziert gelten. Wenn keine gespeicherten Daten der Bibliothek zutreffen, können mit physikalischen Modellen simulierte Signaturdaten verwendet werden.

Für einige Sensortypen wie Infrarot-Bilddaten und Radar können modellierte Daten sinnvoller als Signaturdaten sein, weil tatsächliche Daten nur unter Bedingungen anwendbar sein können, die denen sehr ähnlich sind, unter denen die Referenzsignaturen aufgenommen wurden. Daher können Variationen der Beobachtungsbedingungen genaue Vergleiche zwischen gespeicherten Signaturen und neuen Beobachtungen unmöglich machen.

In der Praxis wird die Identifikation i.A. nicht durch einen direkten Vergleich zwischen beobachteten und gespeicherten Daten durchgeführt. Dieser Ansatz wäre zu langwierig und würde zuviel Rechenleistung erfordern. Wenn repräsentative Eigenschaften gefunden werden können, ist ein direkter Vergleich auch nicht unbedingt notwendig. Dies ist vergleichbar mit einer Situation, in der versucht wird, ein Auto auf einem großen Parkplatz zu finden, indem das Photo des Autos systematisch mit den Photographien jeden anderen Autos verglichen wird. Ein wesentlich effizienterer Ansatz würde das Nummernschild als Vergleichskriterium heranziehen. Selbst wenn alle Autos auf dem Parkplatz gleich alt wären, dieselbe Farbe hätten und das glei-

che Modell von einem einzigen Hersteller wären, würde das Nummernschild doch eine eindeutige (und relativ schnelle) Identifikation ermöglichen (zumindest solange kein „Scherzbold“ auch dieses Kriterium gleichgeschaltet hätte).

Der Gebrauch von Eigenschaften bzw. Charakteristika zur Erleichterung der Identitätsfeststellung ist nicht nur wegen der Rechenleistung notwendig. Menschliches Erkennen basiert ebenfalls auf der Erkennung bestimmter Eigenschaften.

Erfolgreiche auf den Eigenschaften basierende Identifikation hängt von der Auswahl der Charakteristika ab, die separierbare Regionen im Charakteristikaraum ergeben. Die Auswahl sollte sich auf physikalische Modellierung und/oder experimentellen Ergebnissen gründen. Tabelle 5.1 zeigt eine Reihe von möglichen Eigenschaften für die Analyse von ein- und mehrdimensionalen Daten. Die Extraktion dieser Eigenschaften kann auf sehr verschiedene Art und Weise durchgeführt werden, z.B. mit Hilfe von Wavelets [A.4, 23, 53-54, 57, 66]: Eine Diskontinuität in einem Signal kann wie in Bild 5.3a und Bild 5.3b dargestellt durch Haar'sche Wavelets detektiert werden.




Bild 5.3a: Signal mit Diskontinuitäten




Bild 5.3b: Haar-Wavelet, Level 1

Dieser und ähnliche Ansätze arbeiten sehr zufriedenstellend für rauschfreie Signale. Die Kanten bzw. Diskontinuitäten können detektiert werden. Für das gleiche Input-Signal plus additivem Rauschen ergeben sich jedoch viele Falschalarme, Bild 5.3c und Bild 5.4d.




Bild 5.3c: Signal mit Diskontinuitäten plus additives Rauschen




Bild 5.3d: Haar-Wavelet, Level 1

Die Bilder 5.3e-5.3i zeigen ein durch additives Rauschen gestörtes Signal mit Diskontinuitäten sowie einige Wavelet-Skalierungsstufen. Mit einer geeigneten Verarbeitung [24] lassen sich auch in diesem Fall die Diskontinuitäten detektieren.




Bild 5.3e: verrauschtes Signal




Bild 5.3f: Daubechies-4-Wavelet, Level 1




Bild 5.3g: Daubechies-4-Wavelet, Level 2




Bild 5.3.h: Daubechies-4-Wavelet, Level 3




Bild 5.3i: Daubechies-4-Wavelet, Level 4

Beispiele für Charakteristika zur Identitätsfeststellung (Bildbereich) [25]

<b>Charakteristiktyp</b>	<b>Repräsentatives Charakteristikum</b>	<b>Beschreibung</b>
Geometrisch	Kanten	Geometrische Größe/Form von Objekten; von Menschen hergestellte Objekte weisen i.A. regelmäßige geometrische Formen mit bestimmten Grenzen auf
	Linien	
	Längen	
	Winkel	
	Bögen	
	Kreise	
	Größe	
	Fläche	
Strukturell	Oberfläche	
	Relative Orientierung	Strukturelle Eigenschaften entwickeln ein höhermaßstäbliches und kontextbezogenes Bild von Bildsegmenten
	Nebeneinanderstellung von Flächen, Zylindern usw.	
Statistisch	Anzahl der Oberflächen	

	Momente	
	Fourierbeschreibung	
	Mittelwert/Varianz	
	Entropie	
Spektral	Farbkoeffizienten	von Menschen hergestellte Objekte tendieren dazu, bestimmte Infrarot-Signaturen zu haben
	Effektive Blackbody-Temperatur	
	Spektrale Spitzen	
	Spektrale Signatur	

Beispiele für Charakteristika zur Identitätsfeststellung (Folgen) [55]

Zeitbereich	Pulscharakteristika
	<ul style="list-style-type: none"> <li>• Rise-Time</li> <li>• Fall-Time</li> <li>• Amplitude</li> </ul>
	Pulsbreite/-dauer
	Momente
	PRF
	Beziehung von Pulsen zu Umgebungsrauschen
Frequenzbereich	Fourierkoeffizienten
	Tschebyscheff-Koeffizienten
	Periodizität
	Spektrale Linien
Hybride Charakteristika	Wavelet-Darstellung
	Wigner-Ville-Verteilung

Tabelle 5.1

Eine weitere Ansicht von Charakteristika zeigt Tabelle 5.2, die eine Reihe verbreiteter Sensoren benennt sowie die verfügbaren Signaturdaten und Charakteristika, die zur Identifikation nützlich sind.

Ein Spezialfall der Signalverarbeitung zur Identifikation ist die Verarbeitung menschlicher Sprache zur Erkennung von Wörtern, zur Identifikation der gesprochenen Sprache oder des Sprechers. Käufliche Spracherkennungssysteme verwenden typischerweise einen Vergleich zwischen gespeicherten Signatur- und Sprachdaten. Das System wird „trainiert“, indem ein

Sprecher Wörter spricht (i.A. < 1000 Wörter). Syntaktische Regeln der Satzstruktur werden in höherwertigen Systemen verwendet, um herauszufinden, welche Wörter normalerweise vor oder hinter erkannten Wörtern eingesetzt werden können.

Worterkennung in menschlicher Sprache ist besonders schwierig für Signalverarbeitungstechniken. Der Mensch erkennt die von anderen Menschen gesprochenen Wörter anhand von Kontextinformation, Bedeutung, Stimmmodulation und auch der Mimik und Gestik des Gegenübers. Ein Mensch ist i.A. fähig, seinen Gesprächspartner trotz Unterschieden in Stimmhöhe, Akzent, Geschwindigkeit und anderer Faktoren zu verstehen. Ein weiterer Faktor, der die Erkennung kompliziert, bezieht sich darauf, ob ein Sprecher in seiner oder einer Fremdsprache spricht. [59] gibt eine Einführung in die Sprachverarbeitung.

Allgemein, d.h. nicht nur für die Sprachverarbeitung, gilt, daß die Auswahl von Eigenschaften zur Hilfe bei der Identifikation eine Analyse der Situationsphysik und viele Experimente erfordert. Es gibt kein Kochrezept zur Auffindung nützlicher Eigenschaften. Schlüsselthemen sind z.B. Beobachtbarkeit, Orthogonalität und Invarianz. Das Beobachtbarkeitsthema ist identisch zu dem der Beobachtbarkeit bei der Parameterestimation (Kapitel 4). Bei der Orthogonalitätsfrage geht es darum, zu entscheiden, ob die ausgewählten Charakteristika unabhängig sind oder nicht. Die Invarianz beschäftigt sich mit der Frage, wie sich die ausgewählten Charakteristika in Bezug auf die Zeit verhalten.

Nachdem ein Charakteristikatz ausgewählt worden ist, kann eine Vielzahl von Mustererkennungstechniken zur Identitätsfeststellung angewendet werden. Die nächsten Abschnitte beschreiben einige dieser Methoden.

<b>Sensortyp</b>	<b>Signaturformat</b>	<b>Nützliche Eigenschaften</b>
Hitzebildgeber	2D-Temperaturbild	Form, Textur, Kontext
Millimeterwellen	1D-Reflektivitätsprofil, 1D-/2D-Polarisationsbild, Doppler-Modulation	Verteilung und Entfernung von Scatterern
Laserradar	3D-Reflektivitätsbild, Doppler-Modulation, 2D-Geschwindigkeitsbild	Größe, 3D-Form, Ort von Scatterern; räumliche Verteilung sich bewegender Komponenten
SAR	2D-Reflektivitätsbild	Größe, Anzahl und Ort von Scatterern
TV	2D-Reflektivitätsbild	Form; Textur; interne Struktur; Kontext

Mikrowellenra- dar	Doppler-Modulation, 2D- Reflektivitätsbild	Geschwindigkeit; Größe, Anzahl und Ort von Scatterern
Akustisch	Spektrum und Zeitabhängigkeit der akustischen Emission	Harmonische; Frequenzverhältnisse; Ge- räuschquellen
Interferometer	Spektrum und Zeitabhängigkeit der Mikrowellenemission	Frequenz; Frequenzmodulation; Amplitu- denmodulation; Pulsdauer; Pulsintervalle

Tabelle 5.2: Charakteristika unterschiedlicher Quellen



### 5.3 Parametrische Templates

Vielleicht die einfachste Technik zur Mustererkennung ist der Gebrauch sog. Templates oder Schablonen. Die Idee ist einfach: Es wird angenommen, daß der multidimensionale Charakteristikaraum in spezifische Regionen, die jeweils eine Identitätsklasse darstellen, aufgeteilt werden kann. Ein Beispiel für die Identifikation gepulster Sender zeigt Bild 5.4, worin ein Sensor die ausgesandten Energiepulse der Sender 1 und 2 beobachtet und die Amplitude über der Zeit ausgibt. Ein Charakteristikaextraktionsprozeß erzeugt einen zweidimensionalen Charakteristikavektor (Pulsbreite, PRF). Dieser Vektor wird auf einen zweidimensionalen Charakteristikaraum abgebildet. Angenommen sei, daß durch bereits durchgeführte Messungen bzw. Analysen zwei Senderklassen A und B gefunden worden sind. Identitätsklassifizierung bedeutet einfach den Prozeß der Bestimmung, ob die beobachteten Daten ( $\underline{y}_1$  und  $\underline{y}_2$ ) zu einer der beiden Senderklassen gehören oder nicht.

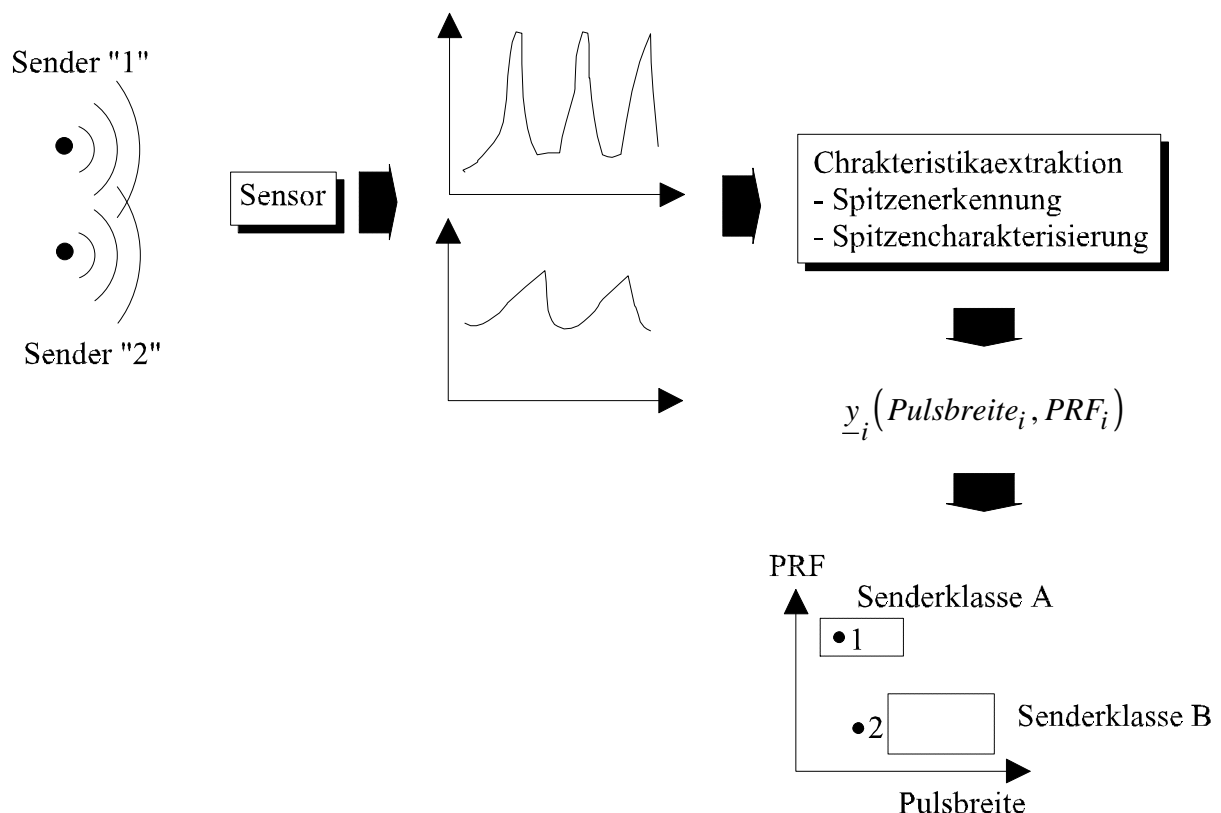


Bild 5.4: Templates-Konzept zur Identitätsklassifikation

Der Prozeß der Identitätsdeklaration mit parametrischen Templates ist mit dem Assoziationsprozeß aus Kapitel 3 vergleichbar. Der Ort eines Charakteristikavektors wird mit spezifizierten

Orten im Charakteristikaraum verglichen. Wenn eine Beobachtung  $\underline{y}_1$  nahe oder zwischen die Grenzwerte einer Identitätsklasse fällt, dann ist die Beobachtung als zu der assoziierten Identitätsklasse gehörig identifiziert, d.h. es muß ein Ähnlichkeitsmaß berechnet werden. Jede neue Beobachtung wird mit den A-Priori-Klassen verglichen.

Ein Charakteristikaraum kann durch vielfältige Arten von Grenzwerten unterteilt werden: geometrisch (rechteckige oder ellipsoide Formen), statistisch (Bayes) oder andere. [20] beschreibt eine Vielzahl dieser Techniken. Ein Faktor, der die Template-Methode kompliziert, ist das mögliche Überlappen von Regionen im Charakteristikaraum. Ein solches Überlappen verursacht Mehrdeutigkeiten, die möglicherweise nicht auflösbar sind. Trotzdem können die gleichen Techniken wie in Kapitel 3 beschrieben angewendet werden, um die Mehrdeutigkeiten aufzulösen zu versuchen.

Da konzeptionell einfach, wird der Template-Ansatz zur Identitätsfeststellung oft in Datenfusionssystemen angewendet. Auch die Implementierung ist i.A. einfach. Die Effektivität hängt jedoch stark von der Wahl der Charakteristika und ihrer Verteilung im Charakteristikaraum ab.

## 5.4 Cluster-Analyse

Cluster-Analyse-Methoden bezeichnen Gruppen von heuristischen Algorithmen, die in der Biologie und den Sozialwissenschaften populär geworden sind. Cluster-Analyse ist ein Name für eine breite Palette von Prozeduren, die Daten in natürliche Gruppen bzw. Cluster plazieren. Diese Daten-Cluster werden von Analysten interpretiert als Klassifikation oder Identifikation. PRI- und RF-Parameter können z.B. verwendet werden, um Radarsysteme funktional bzw. bzgl. der Aktivität zu unterscheiden. Das Konzept ist in Bild 5.5 dargestellt. Bild 5.5a zeigt einen Trainingszyklus, in dem Daten von bekannten Zielen oder Objekten von einem oder mehreren Sensoren beobachtet werden. Charakteristikavektoren werden extrahiert und einem trainierbaren Klassifizierer übergeben. Der Klassifizierer formiert Entscheidungsflächen bzw. Grenzwerte für den Charakteristikaraum. Idealerweise erlauben die Entscheidungsflächen jedem Ziel oder Objekt einen eindeutig identifizierbaren Platz im mehrdimensionalen Charakteristikaraum. Mit Abschluß des 'Trainingszyklus' kann der Klassifizierer dann in einem Klassifizierungszyklus wie in Bild 5.5b zum Einsatz kommen.

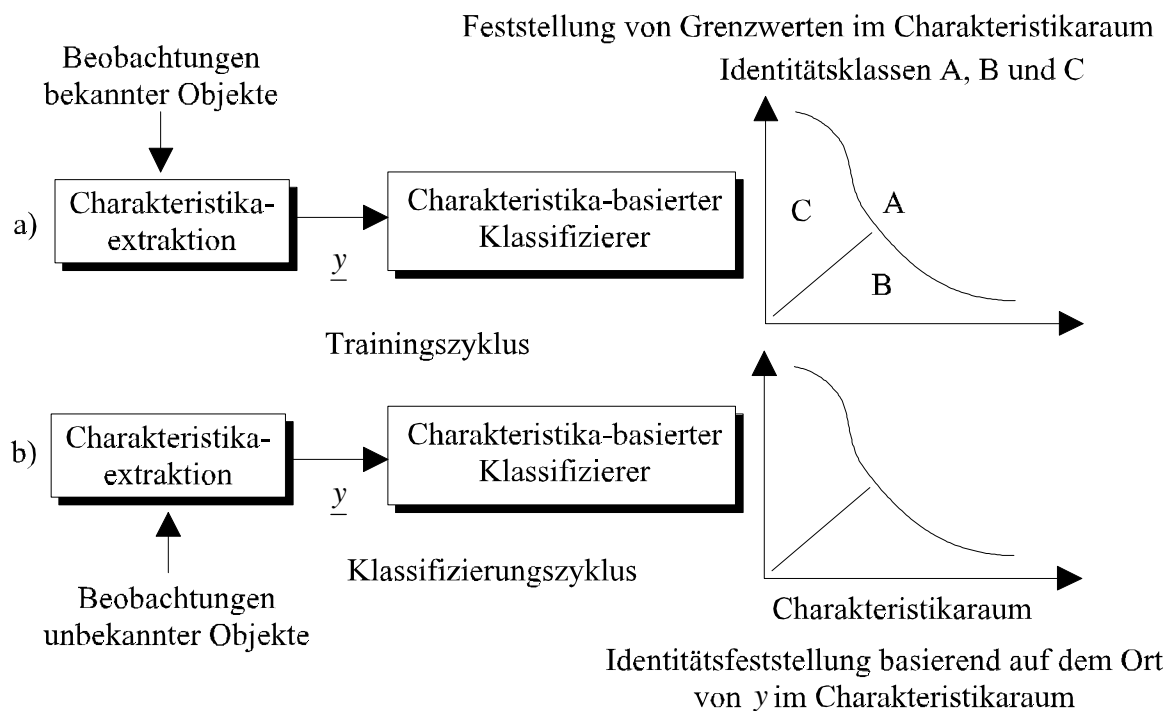


Bild 5.5: Konzept der Cluster-Analyse

Wenn der Klassifizierer im Klassifikationsmodus arbeitet, wird er unbekannte Ziele beobachten. Der resultierende Charakteristikavektor wird in den Charakteristikaraum abgebildet und die Nähe zu bekannten Identitätsklassen ist damit etabliert.

Der Output des trainierten Klassifizierers besteht aus einer Liste potentieller Identitäten der unbekanntem Ziele, abgestuft nach abnehmender Ähnlichkeit.

Fünf Schritte sind für jeden Typ von Cluster-Algorithmus notwendig:

1. Auswahl der Daten
2. Definition von Charakteristikasätzen, auf die die Daten abgebildet werden sollen
3. Berechnung der Ähnlichkeiten zwischen den Betrachtungseinheiten
4. Gebrauch der Cluster-Analyse-Methode zur Bildung von Gruppen ähnlicher Betrachtungseinheiten
5. Verifikation der resultierenden Cluster-Lösung

Die genannten Schritte sind alle wichtig bei der Cluster-Analyse. Dabei werden Beobachtungscharakteristika definiert bzw. erzeugt, die die Separation der Daten in identifizierbare Gruppen erlauben sollten. In dem Beispiel in Bild 5.4 sind die ausgewählten Charakteristika das Puls-wiederholungsintervall PRI und die Frequenz RF. Andere Charakteristika, die in potentiell anderen Clustern resultiert hätten, hätten ebensogut gewählt werden. Charakteristika können auch durch Prozesse wie Fourier-Transformationen erzeugt werden. Das Ergebnis würde dabei aus Fourierkoeffizienten bestehen. Die Auswahl nützlicher Charakteristika hängt letztlich entweder von einem tiefen Wissen über die physikalischen Zusammenhänge oder einfach Versuch-und-Irrtum ab. Die dabei gefundenen Charakteristika können dann mit Methoden wie der Faktoranalyse, logarithmischen Transformationen, Normierung auf die Varianz usw. skaliert bzw. gewichtet werden.

Alle Cluster-Algorithmen benötigen die Definition eines Ähnlichkeits- oder Assoziationsmaßes, das einen numerischen Wert beisteuert, der den Grad der Ähnlichkeit bzw. der Unähnlichkeit zwischen zwei beobachteten Charakteristikavektoren  $\underline{y}_i$  und  $\underline{y}_j$  bewertet. Die Komponenten von  $\underline{y}_i$  sind die beobachteten Charakteristika wie PRI, RF, Fourierkoeffizienten usw.

Für skalierte Datensätze und ausgewählte Ähnlichkeitsmaße sind eine Reihe von Algorithmen entwickelt worden, die die Suche nach natürlichen Gruppierungen von Clustern im Charakteristikaraum ermöglichen. [1] identifiziert sieben Gruppen von Cluster-Methoden. Zusammengefaßt sind diese Methoden in Tabelle 5.3.

Um das Konzept der Cluster-Analyse zu verdeutlichen, soll eine Methode etwas genauer beschrieben werden: eine hierarchisch-agglomerative Methode. [1] zitiert eine von den Autoren durchgeführte Studie zum Thema Applikation von Cluster-Techniken. Die Studie zeigt, daß zwei Drittel der veröffentlichten Forschung einen hierarchisch-agglomerativen Ansatz gewählt haben.

<b>Cluster-Familie</b>	<b>Algorithmus</b>
Hierarchisch-agglomerative Methoden	Berechnung des Ähnlichkeitsmaßes für jedes Beobachtungspaar; Clustering der Beobachtungspaare, die das höchste Ähnlichkeitsmaß aufweisen mit aufgestellten Regeln; hierarchisches Vergleichen bzw. Clustering von Beobachtungen zu Beobachtungen, Beobachtungen zu Clustern, Clustern zu Clustern, bis kein weiteres Clustering mehr möglich
Iterative Partitionierungsmethoden	Initialisierung durch Anfangspartition in bestimmte Anzahl von Clustern, Berechnung von Cluster-Centroiden; Zuweisung jeden Datums zum Cluster mit dem nächsten Centroiden; Berechnung/Update der Cluster-Centroiden; Wiederholung bis keine Punkte mehr das Cluster wechseln
Hierarchische Vererbungsverfahren	Logisches Gegenstück zu „Hierarchisch-agglomerative Methoden“. Anfänglich werden alle Daten zu einem einzigen Cluster zugeordnet, welches dann in immer kleinere Stücke aufgeteilt wird
Dichtesuchmethoden	Algorithmen suchen den Charakteristikaraum nach natürlichen Erscheinungsformen in den Daten ab, die Bereiche hoher Dichte darstellen
Faktoranalysemethoden	Erstellung einer Korrelationsmatrix von Ähnlichkeiten zwischen Fällen; Klassische Faktoranalyse wird dann auf die $N \times N$ Matrix angewandt; Daten werden den Clustern entsprechend ihrer Faktoren zugewiesen
Gruppenmethoden	Gruppenmethoden erlauben eine Fallzugehörigkeit zu mehr als einem Cluster; Fälle werden iterativ einem oder mehreren Clustern zugeordnet, um den Wert eines Kriteriums zu optimieren, das Kohäsionsfunktion genannt wird
Graphentheoretische Methoden	Gebrauch der Graphentheorie zur Entwicklung einer Hierarchie, die die Daten in Cluster ordnet

Tabelle 5.3: Zusammenfassung von Clusteralgorithmusfamilien [1]

In der Trainingsphase besteht der Ansatz aus den folgenden Schritten:

1. Die Attribut- bzw. Charakteristikavektordaten werden zusammengesetzt bzw. einem Clustering-Prozeß übergeben.
2. Die Daten werden skaliert oder normalisiert, z.B. auf den Bereich  $\{0,1\}$ . Diese Skalierung dient zur Vermeidung dominierender Charakteristikavektorkomponenten.
3. Für jeden Charakteristikavektor  $\underline{y}_i$  wird der Ähnlichkeitskoeffizient unter Berücksichtigung jeden anderen Charakteristikavektors  $\underline{y}_k$  berechnet, z.B. für eine Euklidische Distanz-Metrik:

$$s_{jk} = \left| \frac{1}{n} \cdot \sum_{i=1}^n (y_{ij} - y_{ik})^2 \right|^{\frac{1}{2}} \quad (5.3)$$

wobei  $y_{ij}$  die  $i$ -te Komponente des  $j$ -ten Datums ist,  $n$  die Anzahl der Komponenten des Charakteristikavektors und  $s_{jk}$  die Euklidische Distanz (im normalisierten Charakteristikaum) zwischen dem  $j$ -ten und dem  $k$ -ten Charakteristikavektor. Jedes der in Kapitel 3 beschriebenen Ähnlichkeitsmaße kann dabei statt Gl. (5.3) verwendet werden. Eine symmetrische Ähnlichkeitsmatrix:

$$s = \begin{bmatrix} 0 & s_{12} & \dots & s_{1M} \\ s_{21} & 0 & \dots & s_{2M} \\ \dots & & & \\ s_{M1} & s_{M2} & \dots & 0 \end{bmatrix} \quad (5.4)$$

kann damit erzeugt werden, wobei die  $s_{ij}$  ein Maß der Ähnlichkeit zwischen  $i$ -tem und  $j$ -tem Charakteristikavektor darstellen.

4. Eine Clustering-Regel wird angewandt, ein Hierarchiebaum erzeugt. Am Fuß des Baumes sind  $M$  bestimmte Cluster, wobei jedes Cluster eine einzige Beobachtung umfaßt. Auf der nächsten Ebene gibt es dann  $M - 1$  Cluster usw. Diese Hierarchie potentieller Cluster führt sich fort, bis an der Spitze alle Beobachtungen in einem einzigen Cluster zusammengefaßt sind.

Dargestellt ist der Vorgang in Bild 5.6. Auf der rechten Seite sind fünf Datenpunkte in einem zweidimensionalen Charakteristikaraum eingezeichnet. Links wird das zugehörige Dendrogramm (Cluster-Baum) gezeigt. Diese Graphik zeigt die Euklidischen Abstände zwischen den Charakteristikavektoren in einem Hierarchiebaum. Unten werden alle Beobachtungen als zu individuellen Clustern gehörig betrachtet. Die Cluster-Methode durchsucht die Ähnlichkeitsmatrix nach dem kleinsten Wert von  $s_{ij}$  (die zwei ähnlichsten Objekte). Diese Objekte werden in ein gemeinsames Cluster eingeordnet. Der Prozeß geht solange weiter, bis alle Objekte in einem einzigen großen Cluster eingeordnet sind.

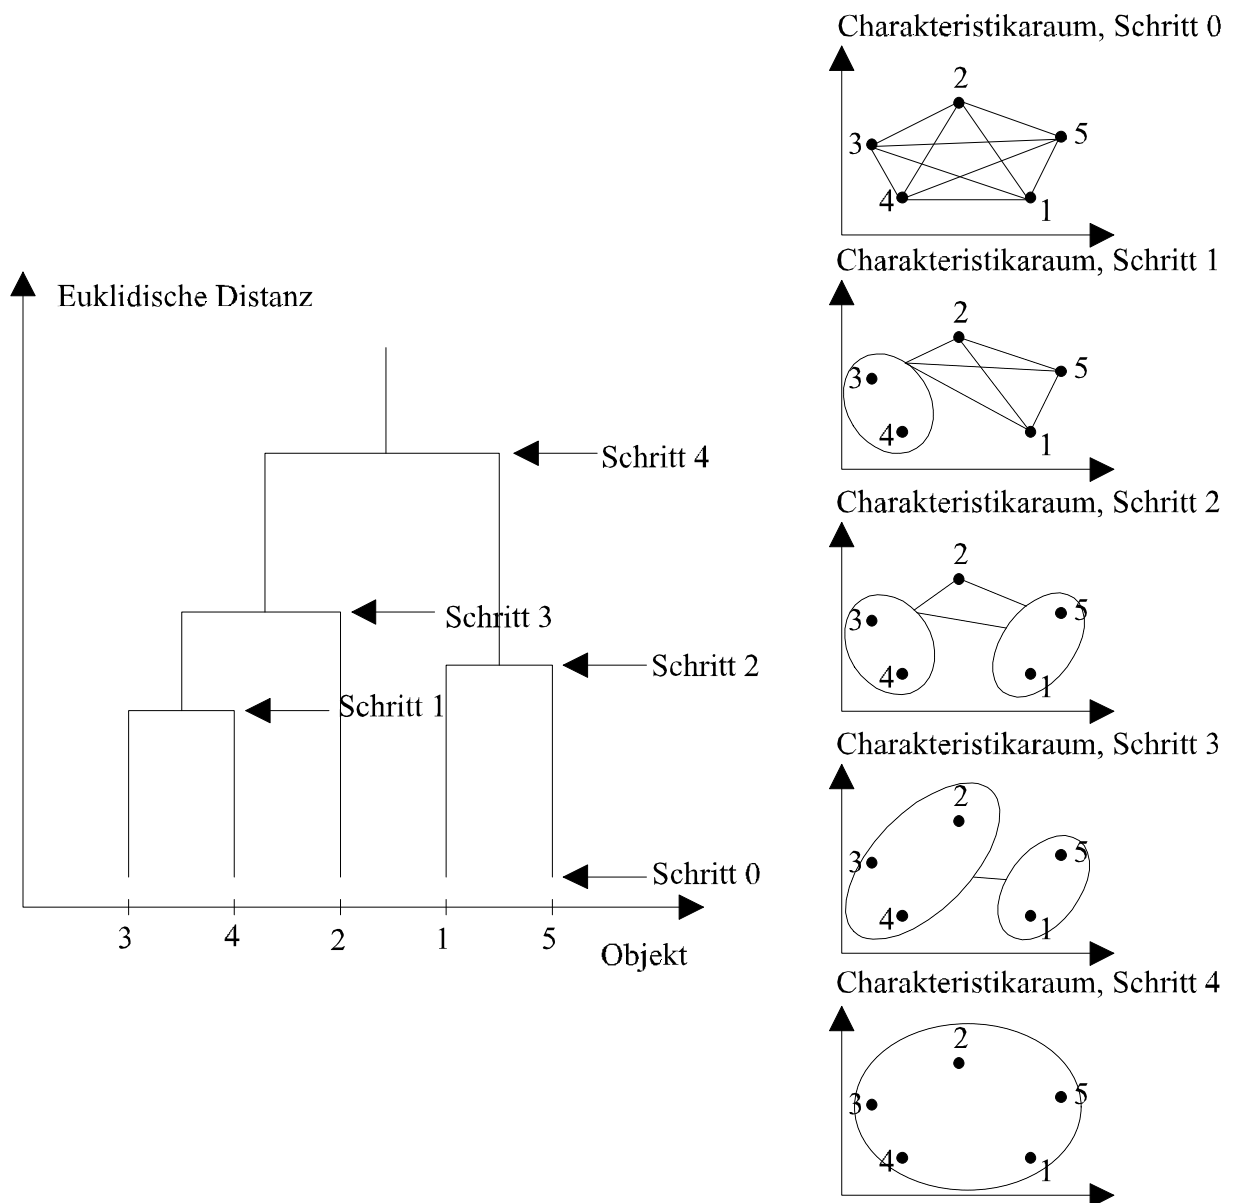


Bild 5.6: Hierarchisches agglomeratives Clustering

Bei dieser Methode wird die Ähnlichkeit zwischen Cluster k und jedem anderen Cluster l bei jeder hierarchischen Iteration (die diversen Schritte in Bild 5.6), nachdem die beiden Cluster i und j zum Cluster k zusammengefügt sind, durch die Metrik:

$$s_{lk} = \min(s_{il}, s_{jl}) \quad (5.5)$$

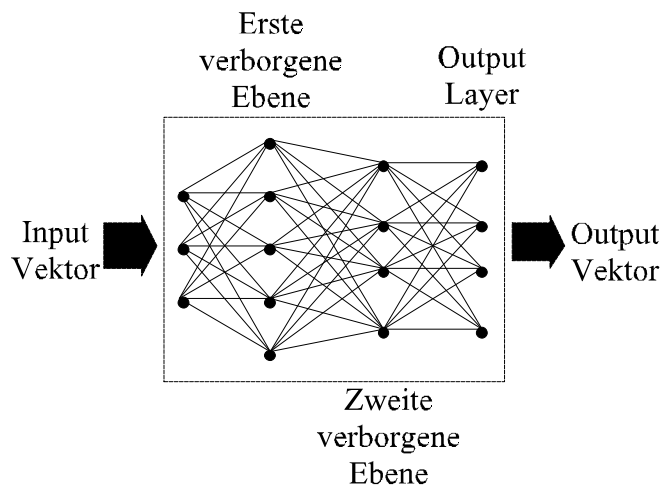
spezifiziert.

Cluster-Analyse beschreibt eine Art Werkzeugkiste, mit deren Inhalt neue Zusammenhänge zwischen Daten gefunden werden können, die zu Identifikationsmusterbeispielen führen können. Aufgrund der heuristischen Natur der Cluster-Algorithmen ist ihre Anwendung nicht ohne Fragezeichen und Vorsicht zu sehen. I.A. können Datenskalierung, Auswahl eines Ähnlichkeitsmaßes und eines Clustering-Algorithmus', manchmal sogar die Reihenfolge der Eingabe der Daten die resultierenden Cluster stark beeinflussen. Der Gebrauch von Cluster-Methoden muß hinsichtlich ihrer Effektivität und ihrer Fähigkeit, wiederholbare sinnvolle Identitätscluster zu erzeugen, beurteilt werden.




## 5.5 Adaptive neuronale Netzwerke

Künstliche neuronale Netzmodelle bzw. adaptive neuronale Systeme sind Hard- und/oder Softwaresysteme, die die Prozesse, die in biologischen Nervensystemen ablaufen, abbilden sollen. Ein neuronales Netzwerk besteht aus Ebenen von Verarbeitungselementen bzw. Knoten, die unterschiedlich verbunden sein können. Bild 5.7a illustriert ein Netzwerk mit vier Ebenen, die jede mehrere Verarbeitungselemente besitzen.



a) Netzwerk mit vier Ebenen



b) Adaptive Linear Combiner

Bild 5.7: Überblick über adaptive neuronale Systeme

Datenvektoren bilden den Input auf der linken Seite. Das neuronale Netz transformiert diese nichtlinear in den Ausgangsvektor auf der rechten Seite. Eine solche Transformation kann die Art von Abbildung schaffen, die Eingangsdaten Identitätskategorien zuordnet. Damit können

neuronale Netze dazu benutzt werden, multisensorielle Daten zu einer gemeinsamen Identifizierung für ein Objekt zu transformieren.

[73] zeigt einige Beispiele aus den Bereichen adaptive Signalverarbeitung (Systemmodellierung, statistische Prädiktion, Rauschunterdrückung, adaptive Echounterdrückung, inverse Modellierung, Nachrichtenkanal-Equalization) und adaptive Mustererkennung auf, bei denen neuronale Netzwerke vorteilhaft einsetzbar sind.

Ein sehr anschauliches Beispiel für Anwendung und Wirkung eines neuronalen Netzwerkes wird in [33] gegeben, wo die Lösung der Aufgabe beschrieben wird, die 26 Buchstaben des Alphabets automatisiert zu erkennen.

Ein medizinisches Anwendungsbeispiel stellt das Diagnosesystem „Papnet“ [17] dar. Es geht dabei um routinemäßige Abstriche vom Gebärmutterhals, die Krebs möglichst schon im Frühstadium erkennen lassen sollen. Das Diagnosesystem auf der Basis eines neuronalen Netzes liegt mit einer Trefferquote von 80% für den Befund „richtig positiv“ gleichauf mit der Quote von Ärzten, jedoch stempelten Ärzte fälschlich doppelt so häufig Gesunde zu Kranken („falsche positive Befunde“) und schneller ist das System auch: Für eine Diagnose benötigte „Papnet“ in Tests im Schnitt 3.9 Minuten, die Ärzte 10.4 Minuten.

[74] vergleicht neuronale Netze mit eher klassischen Klassifikationsalgorithmen wie Templates (s. Abschnitt 5.3) und K-Nearest-Neighbour (s. Abschnitt 2.2) bei der Klassifizierung von Radarsignalen.

Das Verarbeitungskonzept für einen Einzelknoten eines neuronalen Netzes zeigt Bild 5.7b. Jeder Knoten in einer Ebene erhält Eingangsdaten von bis zu  $N$  Knoten der vorherigen Ebene. Diese Eingangsdaten  $x_0, x_1, \dots, x_n$  werden in dem Verarbeitungselement zu einem Ausgangswert  $y$  kombiniert, der dann als Eingangswert für weitere Ebenen des Netzes dienen kann. Die Kombination der  $x_i$  zur Erzeugung von  $y$  wird als nichtlineare Funktion der gewichteten Werte der  $x_i$ :

$$z = f(y) = f\left(\sum_{j=0}^n w_j \cdot x_j - \Theta_i\right) \quad (5.6)$$

berechnet, wobei die Funktion  $f$  eine Vielzahl von Formen annehmen kann, darunter z.B. Sprungfunktionen, Sigmoidfunktionen usw. Das Argument von  $f$  ist das skalare Vektorpro-

dukt aus dem Eingangsvektor  $\underline{x}$  und dem internen Gewichtungsvektor  $\underline{w}$ .  $\Theta_i$  stellt einen additiven Schwellwert bzw. Bias dar. Die nichtlineare Funktion  $f(y)$  wird manchmal als Activation-Funktion bezeichnet.

Eine Menge von Variationen kann zur Formulierung eines neuronalen Netzwerks genutzt werden. Diese Variationen betreffen die Anzahl der Ebenen des Netzwerks, die Anzahl der Knoten pro Ebene, die Verbindungswege zwischen den Knoten, die Auswahl der Funktion  $f$  und andere Details. [43] gibt neben einer guten und ausführlichen Einführung in das Thema eine Beschreibung dieser Variationen sowie eine Zusammenfassung der für Klassifikationsaufgaben häufig genutzten Netzwerke. Diese sind [6]:

#### 1. Binary Input Netzwerke

- # Supervised (Hopfield, Hamming)

- # Unsupervised (Carpenter, Grossberg)

#### 2. Continuous-Valued Input Netzwerke

- # Supervised (Perceptron, Multilayer Perceptron)

- # Unsupervised (Kohonen Self-Organizing Feature Maps)

Die Adjektive Supervised und Unsupervised beziehen sich auf den benutzten Trainingsmodus. Ein neuronales Netz kann adaptiert oder trainiert werden, um genaue Klassifikationen durchzuführen, indem die Gewichte  $w_i$  systematisch variiert und justiert werden. Dies wird i.A. durch einen Trainingsdatensatz erreicht. Den unter Supervision trainierten Netzen werden Informationen geliefert, die die korrekte Abbildung zwischen Eingangsdaten und Ausgangsklassifikationen spezifizieren. Unsupervised Training bedeutet, daß die Netze einfach trainiert werden, Output-Datencluster zu formen, ohne ihnen die korrekte Input/Output-Abbildungsvorschrift mitzugeben. Die Netze können auch adaptiv trainiert werden. Dabei dürfen die Gewichte wie in der adaptiven Signalverarbeitung variieren.

Eine häufig genutzte Technik für supervised Training von neuronalen Netzwerken ist der Back-Propagation (BP) - Algorithmus. BP minimiert eine Fehlerfunktion, die i.A. als die mittlere quadratische Abweichung zwischen dem tatsächlichen Ausgangsvektor des Netzwerks und dem erwünschten Output spezifiziert wird. Eine iterative absteigende Gradiententechnik dient dabei dazu, die Gewichte  $w_i$  so einzustellen, daß das gewünschte Ergebnis erreicht wird. BP verlangt, daß die Nichtlinearität jeden Knotens monoton steigt und differenzierbar im Bereich des Arguments ist. Eine Funktion, die die Bedingungen erfüllt, ist die Sigmoid-Funktion:

$$f(y) = \frac{1}{1 + e^{-y}} \quad (5.7)$$

[74] zeigt, daß die Leistung von BP von Faktoren wie Rechengenauigkeit, Anfangswerten von  $w_i$  und  $\Theta_i$ , den benutzten Trainingsdaten u.a. abhängen. Ein anderes Manko betrifft die Möglichkeit, daß das Netzwerk zu einem lokalen statt dem globalen Extremum konvergiert. Weiterhin ist es nicht möglich, die Anzahl der Iterationen vorauszusagen, die zur Konvergenz erforderlich sind.

Die „Artificial Neural Network“ (ANN) -Technologie zur Fusion von Identitätsdaten befindet sich teilweise noch im Experimentalstadium. Ergebnisse in [7] deuten an, daß ANNs traditionellen Cluster-Methoden überlegen sind, besonders wenn die Eingangsdaten gestört sind. [7] beschreibt neben den dynamischen und Trainingsgleichungen Applikationen im Bereich Multi-sensor-ID und automatische Zielerkennung.

## 5.6 Physikalische Modelle

Eine direkte Methode zur Durchführung von Identitätsdeklarationen ist der Gebrauch von physikalischen Modellen. Zu dieser Technik gehört der Versuch, die Signatur einer Betrachtungseinheit anhand eines physikalischen Modells dieses Objektes direkt zu berechnen. Das Konzept zeigt Bild 5.8. Ein Sensor beobachtet ein Objekt bzw. Ziel. Daraus ergibt sich eine Signatur bzw. ein Bild. Der Identitätsfeststellungsprozeß vergleicht die beobachteten Daten entweder mit gespeicherten Signaturen oder mit simulierten Signaturen, die auf angenommenen Zielcharakteristika und physikalischen Modellen beruhen. Dieser Vergleich wird i.A. mit einer Korrelation vollzogen. Wenn der berechnete Korrelationskoeffizient dann einen A-Priori-Schwellwert überschreitet, gilt die Identität als festgestellt bzw. erkannt.

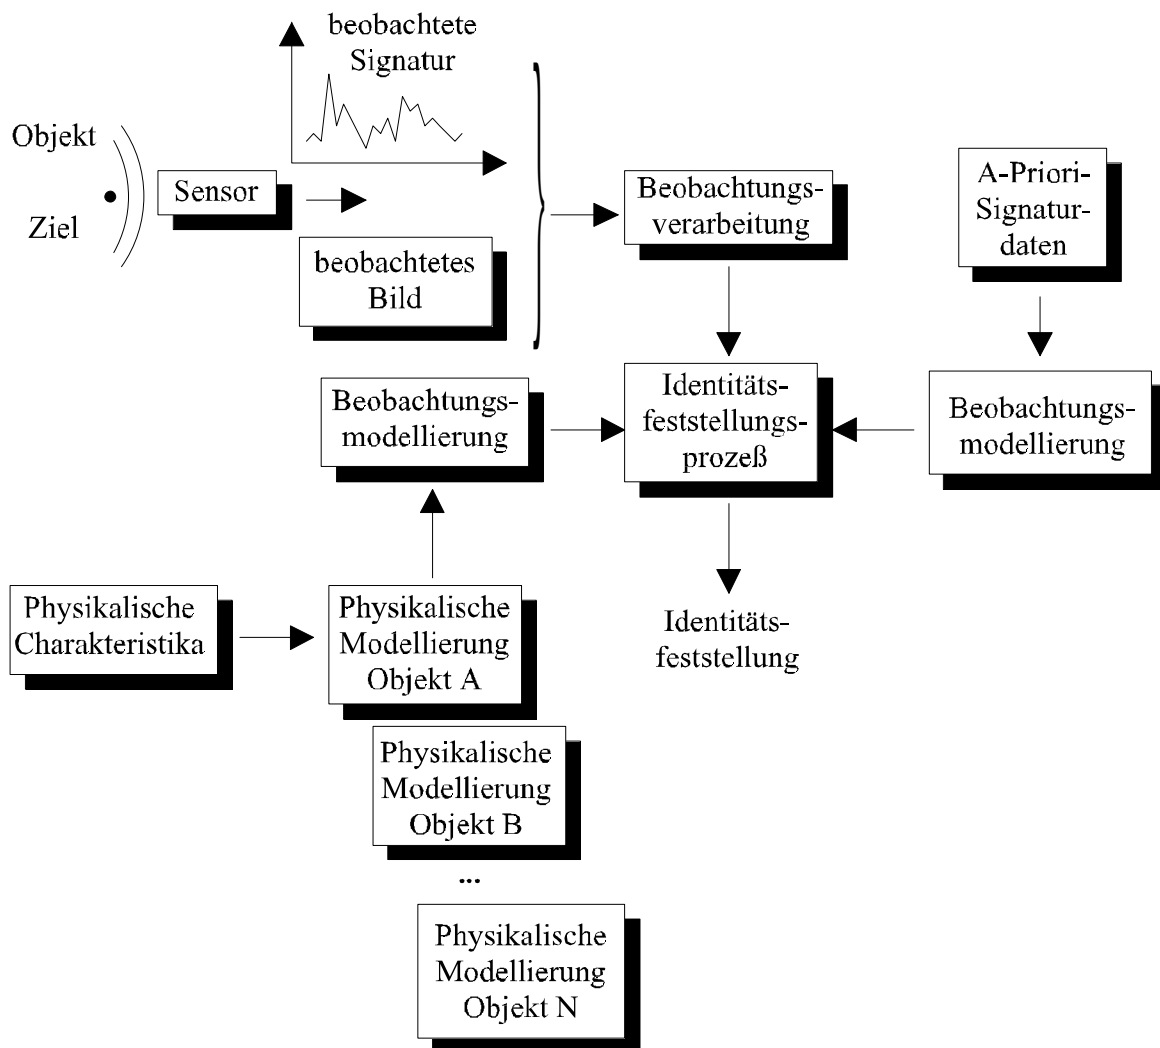


Bild 5.8: Konzept der Feststellung durch physikalische Modellierung

Die physikalische Modellierung zur Vorhersage der Signatur eines Objektes muß auf den physikalischen Charakteristika des zu beobachtenden Objekts beruhen. Ein unterschiedliches physikalisches Modell wird damit für jedes Objekt bzw. jeden Typ eines Objekts erforderlich.

Physikalische Modelle können sehr komplex werden und große Software-Programme bedingen [34, 36]. Das ist einer der Gründe, weshalb physikalische Modelle nicht so sehr verbreitet sind. Auch wenn die physikalischen Modelle relativ einfach sind oder wenn A-Priori-Signaturdaten verwendet werden können, können die Beobachtungsmodelle sowie die Vorverarbeitung sehr aufwendig werden. Angenommen sei z.B., daß ein bildgebender Sensor für die Fernerkundung genutzt werden soll, sowie, daß die Modelle einfach sind, z.B. ein zweidimensionales Geometriebild oder tatsächliche Photographien der Objekte, die durch den automatisierten Identitätsfeststellungsprozeß identifiziert werden sollen. Im Prinzip verläuft der Prozeß sehr einfach: Die beobachteten Bilder werden mit dem Modell oder der A-Priori-Photographie verglichen. Unglücklicherweise hat der Prozeß des Vergleichens seine Tücken. Es kann passieren, daß sehr viel Verarbeitungsleistung aufgewendet werden muß, um die beobachteten Daten anzupassen.

Zu den erforderlichen Bildvorverarbeitungsschritten können die folgenden gehören:

1. Geometrische Korrekturen Sensor: Komplexe Arrays und nichtlineare Optik erfordern die Lösung von Integralgleichungen, um die physikalische Geometrie des beobachteten Objekts auf seine Darstellung in einer Bildebene abzubilden.
2. Detektorkompensation: Bildgebende Arrays können fehler- oder mangelhafte Komponenten aufweisen, deren Effekte eine Bearbeitung erfordern.
3. Geometrische Korrektur Plattform: Die Plattform des Sensors kann Translations-, Attitude- und anderen kinematischen Effekten unterworfen sein. Der Einfluß dieser Effekte auf das Bild muß sorgfältig berücksichtigt werden.
4. Kompensation der Modulationstransferfunktion: Es können Modelle verwendet werden, die die optischen oder Beobachtungseffekte im Sensor emulieren. Die Kontrastverschärfung oder -erhöhung in einem Bild kann mit Hilfe einer solchen Modulationstransferfunktion geschehen, die auch zweidimensionale Faltungsoperationen beinhaltet.
5. Justierung des Dynamikbereichs: Ein Bild kann durch Schatten und Variationen der Intensität schwierig zu interpretieren sein. Eine Bearbeitung wie z.B. die Histogramm-Equalization [57-58] kann daher notwendig sein, um den Kontrast zwischen benachbarten Bildelementen anzugleichen.

6. Automatisierte Verarbeitungsfunktionen: Automatisierte Prozesse können angewendet werden, um Bildsegmente zu extrahieren, Notationen und Skalierungen durchzuführen, Liniensegmente zu identifizieren, Kanten zu erkennen usw.

Diese Liste dient dazu, die Komplexität zu veranschaulichen, die bei der physikalischen Modellierung bei der Bildverarbeitung auftreten kann.

Das Konzept der physikalischen Modellierung zur Identitätsfeststellung ist ähnlich dem für die Estimationstechniken in Kapitel 4. Sein Gebrauch ist i.A. aufgrund der notwendigen Berechnungen eingeschränkt. Die Technik ist jedoch sinnvoll bei der Untersuchung neuer Phänomene, besonders, wenn es nicht auf Realzeit ankommt, d.h., wenn der Untersuchende viel Zeit hat, einzelne Daten untersuchen zu können.

## 5.7 Wissensbasierte Methoden

Zur Identitätsfeststellung können wissensbasierte Techniken wie Expertensysteme und logische Templates verwendet werden. Diese Methoden vermeiden physikalische Modelle und versuchen stattdessen den kognitiven Ansatz zu emulieren, der beim Menschen bei der Identitätserkennung zum Einsatz kommt. Expertensysteme sind Computerprogramme, die Wissensdarstellungstechniken wie Regeln oder Inferenzprozesse verwenden, um gewisse Dinge zu bewerten und dadurch zu Schlußfolgerungen zu kommen. Logische Template-Techniken [25] erweitern das Konzept der parametrischen Templates (s. Kapitel 5.3), indem logische Bedingungen und Beziehungen zugelassen werden. Detailliertere Informationen zu diesen Techniken bietet Kapitel 7. Das Konzept der wissensbasierten Identitätsfeststellung wird hier als eine Alternative zu den vorher in diesem Kapitel beschriebenen Methoden eingeführt.

Wissensbasierte Techniken können entweder auf Sensor-Rohdaten oder auf extrahierten Charakteristika beruhen. In jedem Fall gibt es zwei gemeinsame Aspekte: 1) Techniken zur Darstellung von Wissen und 2) Inferenzmethoden zur Informationsverarbeitung, um eine Schlußfolgerung ziehen zu können. Wissensdarstellungstechniken sind z.B. die folgenden:

1. Regeln: IF-THEN Statements, die die Beziehung zwischen Tatsachen (z.B. die Existenz von Beobachtungsdaten) und resultierenden Aktionen (z.B. Identitätsfeststellung, Anforderung von zusätzlichen Daten usw.) beschreiben.
2. Frames: Komplexe Datenstrukturen, die Objektattribute, Beziehungen und Charakteristika identifizieren.
3. Scripts: Beschreibung von Zuständen und Aktionen, die reale Situationen oder Ereignisse darstellen.

Diese wissensbasierten Darstellungstechniken können dazu genutzt werden, komplexe physikalische Objekte zu definieren. Eine Sammlung von Regeln, Frames und/oder Scripts wird Wissensbasis genannt. Wissensbasierte Systeme nutzen Inferenztechniken zur Verarbeitung von Sensorbeobachtungen mit einer A-Priori-Wissensbasis, um damit Identitäten festzustellen. Zu den Techniken, die zu verwertbaren Schlußfolgerungen führen sollen, gehören Boole'sche Logik, Entscheidungsbäume, Fuzzy Logik u.a. Jede dieser Techniken kann Unsicherheiten bzgl. der Beobachtungsdaten und bzgl. der Wissensbasis verarbeiten. Wissensdarstellungs- und Schlußfolgerungstechniken, die besonders zur Identitätsfeststellung verwendet werden können, sind Methoden, die auf Objektattribute und ihre Beziehungen untereinander fokussieren. Ein Beispiel ist ein syntaktischer Ansatz, der auf der Struktur der Sprache basiert. Ein syntaktischer



Ansatz spezifiziert Elemente eines komplexen Objekts oder einer Gegebenheit und die Beziehungen zwischen den Elementen. Dies ist ähnlich den Regeln zur Erzeugung eines richtigen Satzes, d.h. Spezifizierung von Wörtern (den Grundelementen jeder Sprache) und den Regeln, mit denen diese Wörter zu sinnvollen Sätzen verbunden werden (die Syntax einer Sprache). Z.B. identifiziert die Darstellung eines Objektes wie eines Militärpanzers Elemente wie Räder, Ketten, Fahrzeug und Kanone. Die Anzahl und Plazierung dieser Elemente zur Darstellung eines Panzers wird durch syntaktische Regeln spezifiziert. Der Identifikationsprozeß geht dann weiter und sammelt Daten über elementare Komponenten einer Betrachtungseinheit und verarbeitet diese mit den Daten einer Wissensbasis, um daraus bestimmen zu können, ob die Bedingungen erfüllt sind, die Identität eines Objektes bzw. einer Gegebenheit festzustellen. Das Konzept der wissensbasierten Identitätsfeststellung ist in Bild 5.9 dargestellt.

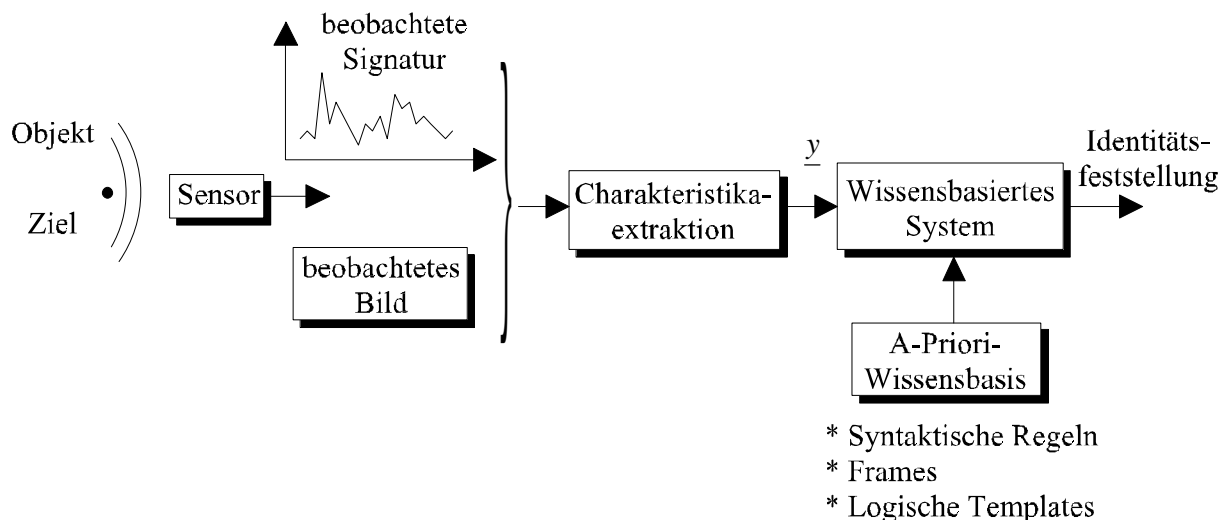


Bild 5.9: Konzept der wissensbasierten Identitätsfeststellung

In Kapitel 7 werden einige wissensbasierte Techniken beschrieben. Weitere in diesem Zusammenhang behandelte Themen sind Wissensdarstellung, Inferenz-Prozesse und Unsicherheitsdarstellung. Hier - vor der Beschreibung dieser Details - muß allerdings schon klar sein, daß der Erfolg einer solchen Technik vor allem in der Erstellung der A-Priori-Wissensbasis liegt. Knowledge Engineering ist eine dafür sehr effektive Technik, die wie das System Engineering Können erfordert und trotzdem immer noch eine Art Kunst ist, die neben dem Können ein großes Maß an Erfahrung benötigt.

## 6. Identitätsfusion auf Entscheidungsebene

### 6.1 Einleitung

Die Entscheidungsebenenfusion kombiniert Identitätsdeklarationen bzw. -feststellungen mehrerer Sensoren zu einer gemeinsamen Identitätsfeststellung. Kapitel 5 (Bild 5.2) zeigte drei mögliche Architekturen zur Identitätsfusion: 1) eine Datenebenenfusionsarchitektur, in der die Daten von entsprechenden Sensoren vor der Charakteristikaextraktion und der Identitätsfeststellung fusioniert werden, 2) eine Charakteristikaebenenarchitektur, die einen gemeinsamen multisensoriellen Charakteristikavektor mit anschließender Identitätsfeststellung entwickelt, und 3) eine Entscheidungsebenenfusionsarchitektur, bei der jeder Sensor eine Identitätsdeklaration, gefolgt von einem Prozeß, der diese Deklarationen fusioniert, um eine gemeinsame multisensorielle Identitätsfeststellung zu erhalten, durchführt.

In Kapitel 5 wurden verschiedene Techniken zur Daten- und Charakteristikaebenenfusion vorgestellt. Das folgende Kapitel fokussiert auf das Konzept und die Techniken zur Entscheidungsebenenfusion. Bild 6.1 verdeutlicht das zugrundeliegende Konzept.

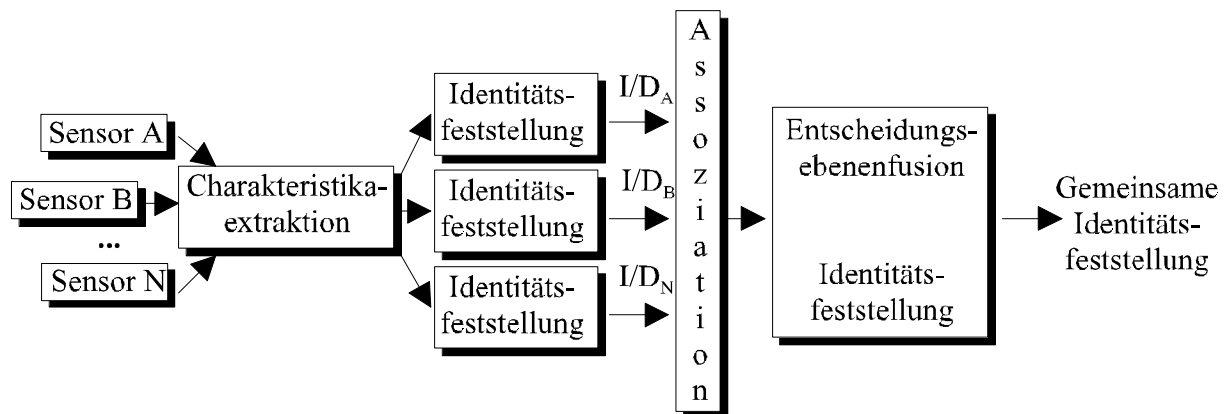


Bild 6.1: Konzept der Entscheidungsebenenidentitätsfusion

Mehrere Sensoren beobachten eine physikalische Gegebenheit, ein Objekt oder ein Ereignis. Jeder Sensor führt eine Vorverarbeitung mit Charakteristikaextraktion und Identitätsfeststellung durch, um daraus eine Identität für die beobachtete Betrachtungseinheit abzuleiten. Beispiele für Entscheidungsebenenfusion sind [44]:

1. Bedrohungswarnsysteme (TWS) an Bord taktischer Flugzeuge zur Identifizierung von Bedrohungen (z.B. Illumination durch Boden-Luft-Raketenleitsystem)
2. Mehrfachsensor-Zielentdeckung
3. Mehrfachsensor-Identifikation von Materialfehlern in einem automatisierten Fabrikationssystem [40]
4. Datenverarbeitung für Robotic-Vision [49]

Bild 6.1 zeigt einen Identitätsfusionsprozeß, bei dem Identitätsfeststellungen mehrerer Sensoren den Input für einen Entscheidungsebenenfusionsalgorithmus bilden. Die Identitätsdeklarationen jeden Sensors müssen durch einen Assoziationsprozeß vorverarbeitet werden, um die Beobachtungen zu gruppieren. Jede Beobachtungsgruppe ist mit einem Objekt oder einer Betrachtungseinheit assoziiert. Kapitel 3 beschreibt Assoziationstechniken zur Sortierung von Beobachtungen in bedeutungsvolle Gruppen. Zu den Methoden zur Fusion von Identitätsfeststellungen gehören klassische Inferenz, Bayes'sche Inferenz, die Dempster-Shafer-Methode, Thomopoulos' GEP-Theorie und verschiedene Ad-Hoc-Ansätze wie Voting-Methoden. Diese Methoden werden in diesem Abschnitt zusammengefaßt dargestellt und im Rest des Kapitels detaillierter behandelt.

Die in den Fusionsprozeß eingebrachten Einfachsensor-Identitätsfeststellungen können entweder Hard- oder Soft-Decisions sein. Hard-Decision-Sensoren liefern nur eine einzige Identitätsdeklaration. Ein Beispiel dafür ist ein Flugzeug-TWS (Threat Warning System), das eine Warnlampe zur Identifizierung einer Bedrohung steuert. Soft-Decision-Sensoren dagegen bieten mehrfache Identitätsfeststellungen mit einer zugehörigen Wahrscheinlichkeit oder einem Konfidenz-Faktor:

<b>Identitäts-Hypothese</b>	<b>Zugehörige Wahrscheinlichkeit</b>
H <sub>1</sub> Beobachtete Betrachtungseinheit ist eine F-16	P(H <sub>1</sub> ) = 0.53
H <sub>2</sub> Beobachtete Betrachtungseinheit ist ein Airbus	P(H <sub>2</sub> ) = 0.28
...	...
H <sub>n</sub> Beobachtete Betrachtungseinheit ist ein UFO	P(H <sub>n</sub> ) = 0.03

Das Ergebnis dieses Fusionsprozesses auf Entscheidungsebene ist eine Verbundidentitätsfeststellung. Idealerweise ist die Verbundidentitätsfeststellung genauer als jede der Einzelfeststellungen.

Tabelle 6.1 gibt eine Zusammenfassung der Fusionsprozesse auf Entscheidungsebene. Die Tabelle identifiziert fünf Basiskategorien. Für jede dieser Techniken wird der entscheidende Prozeß kurz erläutert sowie die Art des erforderlichen Inputs, das Ergebnis und einige Kommentare gegeben.

1. **Klassische Inferenz:** Bei der klassischen Inferenzmethode geht es darum, den Gehalt einer vorgeschlagenen Hypothese gegen eine alternative Hypothese abzuschätzen. Basis dafür sind empirisch gewonnene Wahrscheinlichkeiten. Klassische Inferenz berechnet die Verbundwahrscheinlichkeit bei gegebener Hypothese. Ein Signifikanztest bestimmt die Wahrscheinlichkeit dafür, daß reale Daten beobachtet würden, wenn die angenommene Hypothese wahr wäre. I.A. kann die klassische Inferenz nur zwei Hypothesen zeitgleich betrachten (eine Null-Hypothese  $H_0$  und die Alternative  $H_1$ ). Klassische Inferenz kann A-Priori-Information bzgl. der Wahrscheinlichkeit einer vorgeschlagenen Hypothese nicht mitberücksichtigen.
2. **Bayes'sche Inferenz:** Die Bayes'sche Inferenz aktualisiert die Wahrscheinlichkeiten alternativer Hypothesen aufgrund neuer Beobachtungserkenntnisse. Sie gibt eine Beziehung zwischen der A-Priori-Wahrscheinlichkeit einer Hypothese, der bedingten Wahrscheinlichkeit einer Beobachtung und der A-Posteriori-Wahrscheinlichkeit der Hypothese an. Analog einem wissenschaftlichen Experiment wird neue Information dazu genutzt, die A-Priori-Wahrscheinlichkeit einer Hypothese zu aktualisieren. Es können entweder empirische oder subjektive Wahrscheinlichkeiten verwendet werden. Mehrere alternative Hypothesen können simultan ausgewertet werden (obwohl ein durchgängiger und sich gegenseitig ausschließender Satz von Hypothesen definiert werden muß).
3. **Dempster-Shafer-Methode:** 1976 führten Arthur Dempster und Glen Shafer eine Verallgemeinerung der Bayes'schen Inferenzmethode ein [61]. Ähnlich der Bayes'schen Inferenz aktualisiert die Dempster-Shafer-Methode eine A-Priori-Massendichtefunktion, um damit ein A-Posteriori „Evidential Interval“ genanntes Intervall zu erhalten, das die Glaubwürdigkeit eines Vorschlags und seine Plausibilität quantifiziert. Massendichtefunktionen sind dabei das Analogon zur Bayes'schen Wahrscheinlichkeit. Die Dempster-Shafer-Methode weicht die Bayes'sche Restriktion bzgl. gegenseitig ausschließender Hypothesen auf, indem sie den Befund statt den Hypothesen den Propositionen zuordnet. Weiter bezieht diese Methode einen allgemeinen Grad von Unsicherheit in die Betrachtung mit ein, d.h. es ist nicht notwendig, einen umfassenden Satz von Hypothesen zu formulieren.

4. Verallgemeinerte Befundbearbeitungstheorie (GEP): Eine Modifikation der Dempster-Shafer-Methode wurde in [67-68] veröffentlicht. Die dabei vorgenommene Verallgemeinerung der Bayes'schen Inferenzmethode zielt darauf ab, einen optimalen Weg zu entwickeln, wie Wahrscheinlichkeitsmassen zu kombinieren sind. Hauptzweck dieser verallgemeinerten Theorie ist die Vermeidung einiger Nachteile der Dempster-Shafer-Methode.
5. Heuristische Methoden: Es gibt viele erfolgreich zur Identitätsfusion angewandte nicht-wahrscheinlichkeitstheoretische Techniken. Einige dieser Methoden emulieren die Methoden, die Menschen für Verbundinferenzen verwenden. Dazu gehören Voting-Methoden, Konsens-Techniken u.a., die die Konsequenzen berücksichtigen, die dadurch entstehen, daß eine Hypothese für wahr gehalten wird.

<b>Technik</b>	<b>Basisprozeß</b>	<b>Erforderlicher Input</b>	<b>Output</b>	<b>Kommentar</b>
Klassische Inferenz	Mit angenommener Hypothese Berechnung der Verbundwahrscheinlichkeit einer Beobachtung	Empirische oder klassische Wahrscheinlichkeit, Populationsverteilung für Statistik	Wahrscheinlichkeit für Fehler bedingt auf ausgewählte Hypothesen	Betrachtung von nur zwei Hypothesen
Bayes'sche Inferenz	Bei gegebenem Beobachtungsbefund Update der A-Posteriori-Wahrscheinlichkeit einer Hypothese	Empirische oder subjektive Wahrscheinlichkeit von Beobachtungen bei gegebener Hypothese; A-Priori-Wahrscheinlichkeit einer Hypothese	A-Posteriori-Wahrscheinlichkeit von Hypothese bei gegebenem Befund	umfassende Definition von Alternativ-Hypothesen; Hypothesen müssen gegenseitig ausschließend sein
Dempster-Shafer	Aktualisierung der A-Posteriori-Glaubwürdigkeit von Propositionen bei gegebenem Beobachtungsbefund	Wahrscheinlichkeitsmassenfunktionen zugeordnet zu Propositionen, die überlappend sein können	Glaubwürdigkeitsintervalle und Plausibilität von Propositionen; Allgemeiner Grad von Unsicherheit	Zulassung überlappender Propositionen; Zulassung allgemeinen Grads von Unsicherheit; Umfas-

				sende Definition von Hypothesen nicht notwendig
GEP	Verallgemeinerung Bayes'schen Prozesses; Kombinationsregeln zur Befundzuordnung und Optimierung resultierender Entscheidungen	wie Dempster-Shafer	wie Dempster-Shafer, aber für Hypothesen	Optimale Assoziation von Wahrscheinlichkeitsmassen; Explizite Unterscheidung zwischen Hypothesen und Entscheidungen
Heuristik	Methoden zur Kombination/Auswahl von Identitätsfeststellungen; Emulation menschlicher Gruppenentscheidungen	Identitätsfeststellungen von Einzelsensoren; Sensorgewichtungen	Verbund-/Konsens-Identitätsbestimmung	Nichtwahrscheinlichkeitstheoretische Methoden

Tabelle 6.1: Techniken zur Fusion auf Entscheidungsebene

## 6.2 Klassische Inferenz

Das Ziel statistischer Inferenztechniken ist das Ziehen von Schlußfolgerungen bzgl. eines zugrundeliegenden Mechanismus' oder einer Verteilung aufgrund einer beobachteten Datenstichprobe. Dabei wird ein wahrscheinlichkeitstheoretisches Modell angenommen, zu dem eine oder zwei Zufallsvariablen mit einer definierten - aber unbekanntem - Wahrscheinlichkeitsverteilung gehören. Dieses Wahrscheinlichkeitsmodell etabliert eine Verbindung zwischen beobachteten Daten und einer Population. Die klassische Inferenz verwendet typischerweise ein empirisches Wahrscheinlichkeitsmodell.

Empirische Wahrscheinlichkeit betrachtet Wahrscheinlichkeit als Grenzwert beobachteter Häufigkeiten. Am einfachsten kann das Konzept durch das Münzwurfexperiment verdeutlicht werden. Eine Münze mit den Seiten Kopf oder Zahl wird wiederholt geworfen. Die relative Häufigkeit des Auftretens von Kopf oder Zahl wird beobachtet. Die empirische Wahrscheinlichkeit nimmt an, daß die beobachtete Häufigkeitsverteilung die Wahrscheinlichkeit annähert, wenn die Zahl der Versuche  $k$  ohne Grenzen zunimmt, d.h.:

$$\text{Wahrscheinlichkeit(Kopf)} \approx \text{Häufigkeit(Kopf)} \text{ für } k \rightarrow \infty \quad (6.1)$$

und:

$$\text{Wahrscheinlichkeit(Zahl)} \approx \text{Häufigkeit(Zahl)} \text{ für } k \rightarrow \infty \quad (6.2)$$

I.A. nimmt die empirische Wahrscheinlichkeit an, daß:

$$P(E_j) = \lim_{k \rightarrow \infty} \left[ \frac{k\{E_j\}}{k} \right] \quad (6.3)$$

d.h., daß die empirische Wahrscheinlichkeit von Ereignissen  $E_j$  gleich der relativen Häufigkeit des Auftretens von  $E_j$  bei  $k$  Versuchen für den Grenzübergang  $k$  gegen Unendlich ist. Genau gesagt ist die empirische Wahrscheinlichkeit nur für wiederholbare Ereignisse definiert. Es ist nicht möglich, einem einzigen bzw. einem einmaligen Ereignis eine empirische Wahrschein-

lichkeit zuzuweisen. Klassische Inferenzmethoden verwenden empirische Wahrscheinlichkeiten und sind deshalb nicht eigentlich anwendbar auf singuläre Ereignisse. Der Formalismus enthält daher Beschränkungen für Datenfusionsanwendungen, bei denen auch singuläre Ereignisse auftreten. Beim klassischen Ansatz zur Identitätsdeklaration wird angenommen, daß die beobachteten Daten (z.B. RCS) auf einem von  $N$  möglichen Objekten basieren, deren Identität gesucht wird. Der Test von Hypothesen dient dazu, die Frage zu beantworten, ob die beobachteten Daten aus dem Objekt  $N$  resultiert haben könnten, wenn die Hypothese tatsächlich korrekt wäre. Es werden zwei Hypothesen definiert:

1. Eine Null-Hypothese  $H_0$ : Die beobachteten Daten sind das Ergebnis eines Objekts, dessen Identität  $N$  ist.
2. Eine alternative Hypothese  $H_1$ : Die beobachteten Daten resultieren nicht aus diesem Objekt.

Die weiteren Schritte der Testlogik sind:

1. Annahme, daß die Nullhypothese wahr ist
2. Auswertung der Konsequenzen dieser Annahme auf die Statistik der Stichprobenverteilung, d.h. Bestimmung der Wahrscheinlichkeit für die Beobachtung dieser Daten, wenn die Hypothese tatsächlich wahr wäre.
3. Ausführung eines Hypothesentests, d.h. wenn die Beobachtungen eine hohe Wahrscheinlichkeit für  $H_0$  besitzen, wird erklärt, daß die Daten der Nullhypothese nicht widersprechen.
4. Im anderen Fall wird festgestellt, daß die Daten der Hypothese  $H_0$  wahrscheinlich widersprechen.

Zwei Annahmen sind notwendig für den Test von Hypothesen. Die erste Annahme besagt, daß es möglich ist, einen erschöpfenden und sich gegenseitig ausschließenden Satz von Hypothesen aufzustellen, der die Beobachtungsdaten erklärt. Daß die Wahrscheinlichkeit einer Beobachtung bei angenommener Hypothese berechnet werden kann, ist die zweite Annahme.

Ein Beispiel für klassische Inferenz ist ein Senderidentifikationsproblem. Angenommen sei, daß zwei unterschiedliche Radartypen im Pulswiederholungsintervall (PRI) wie in Bild 6.2 arbeiten. Das Bild zeigt die Wahrscheinlichkeitsdichtefunktion über dem PRI.

Die zwei Radarklassen  $E_1$  und  $E_2$  zeigen überlappende PRI-Bereiche. Die Wahrscheinlichkeit, daß die Radarklasse  $E_2$  im PRI-Intervall  $PRI_N \leq PRI \leq PRI_{N+1}$  arbeitet, ist durch die schraffierte Fläche unter der Wahrscheinlichkeitsdichtefunktion im oberen Teil des Bildes ge-



geben. Klassische Inferenz soll eine vorgeschlagene Identitätshypothese entweder bestätigen oder ablehnen, d.h., wenn ein  $PRI_{Observed}$  beobachtet wurde, soll dadurch bestimmt werden, ob das Radar zur einen oder der anderen Klasse gehört.

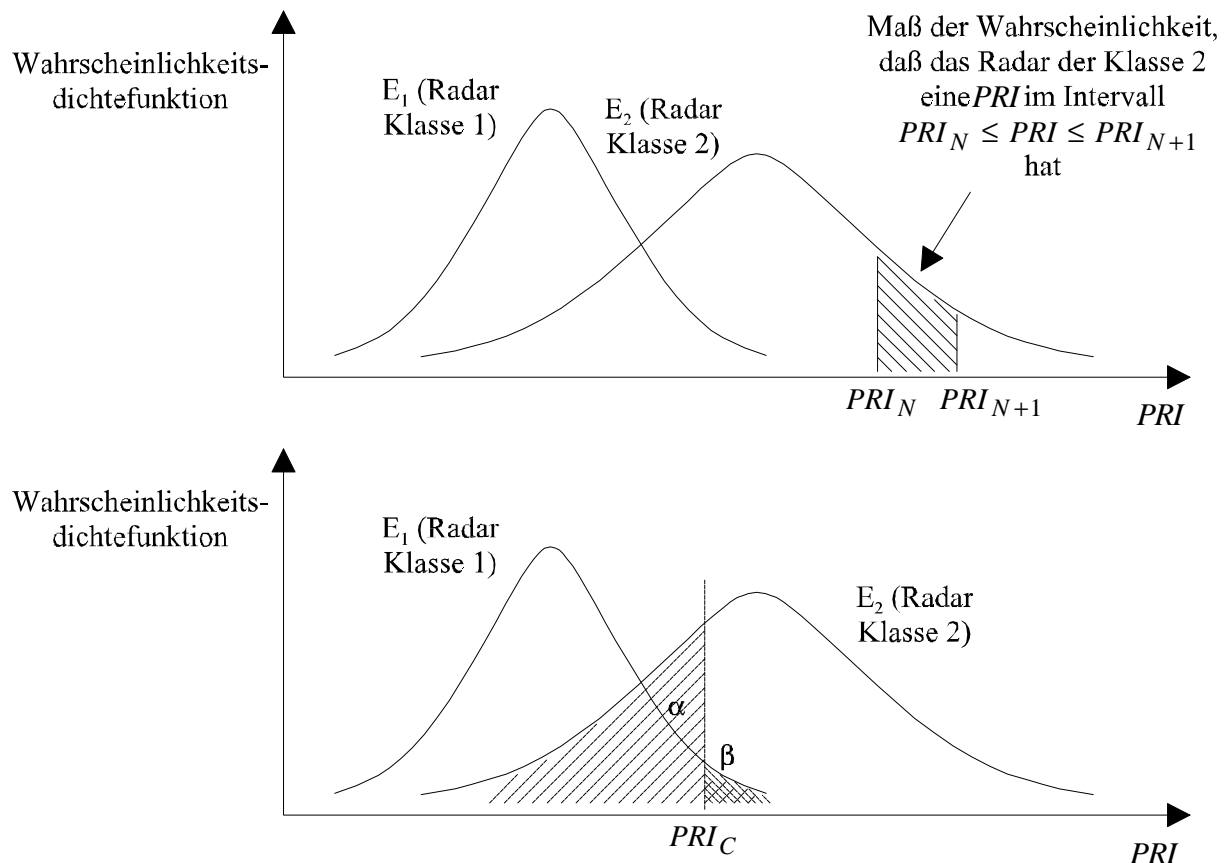


Bild 6.2: Beispiel zu klassischer Inferenz zur Identifizierung von Radarklassen

Wenn der beobachtete Wert der  $PRI$  größer als ein kritischer Wert  $PRI_C$  ist  $PRI_{Observed} > PRI_C$ , dann kann ausgesagt werden, daß der Befund die Hypothese, daß das Radar zur Klasse  $E_2$  gehört, nicht verwerfen kann. Wenn dagegen  $PRI_{Observed} < PRI_C$  gilt, kann der Befund die Hypothese, daß das Radar zur Klasse  $E_1$  gehört, nicht verwerfen.

Im Beispiel kann die Entscheidungsmetrik aufgrund des Überlappens der  $PRI$ -Beweglichkeit trotzdem zu falschen Identitätsfeststellungen führen. Der untere Teil von Bild 6.2 zeigt, daß es eine finite Wahrscheinlichkeit  $\beta$  gibt, daß die beobachtete  $PRI$  größer als  $PRI_C$  für ein Radar der Klasse  $E_1$  ist, und ebenso eine finite Wahrscheinlichkeit  $\alpha$ , daß die beobachtete  $PRI$  kleiner als  $PRI_C$  für ein Radar der Klasse  $E_2$  ist.

Der Ansatz der klassischen Inferenz kann so verallgemeinert werden, daß multidimensionale Daten von mehreren Sensoren verarbeitet werden können. Dies bedingt jedoch ein A-Priori-Wissen und die Berechnung multivariater Wahrscheinlichkeitsdichtefunktionen, was einen schwerwiegenden Nachteil für realistische Applikationen darstellt. Zu den weiteren Nachteilen der klassischen Inferenz gehören:

1. Nur zwei Hypothesen können behandelt werden ( $H_0$ ,  $H_1$ ).
2. Die Komplexität steigt enorm für multivariate Daten.
3. Keine Einbeziehung von A-Priori-Wahrscheinlichkeitsbetrachtungen.

Aus diesen Gründen wird Bayes' Modifikation der klassischen Inferenz bei der Identitätsfusion bevorzugt.

Zur Beantwortung der Frage, wie entschieden werden kann, ob Hypothese  $H_0$  gegenüber der Hypothese  $H_1$  vorzuziehen ist, können einige Regeln verwendet werden (Zusammenfassung in Tabelle 6.2):

1. Maximum A Posteriori: Akzeptanz der Hypothese  $H_0$  als wahr, wenn die Wahrscheinlichkeit von  $H_0$  bedingt auf die Beobachtung  $y$ ,  $P(H_0 / y)$ , größer als die Wahrscheinlichkeit von  $H_1$  bedingt auf  $y$ ,  $P(H_1 / y)$ , ist.
2. Maximum Likelihood: Akzeptanz der Hypothese  $H_0$  als wahr, wenn die A-Priori-Wahrscheinlichkeit von  $H_0$ ,  $P(H_0)$ , multipliziert mit  $P(y / H_0)$  größer ist als  $P(H_1) \cdot P(y / H_1)$ .
3. Neyman-Pearson [8]: Akzeptanz der Hypothese  $H_0$  als wahr, wenn das Verhältnis der Likelihood-Funktion für  $H_0$  zur Likelihood-Funktion für  $H_1$  kleiner oder gleich einer Konstanten  $C$  ist, die zur Bestimmung des gewünschten Signifikanz-Levels gewählt wird.
4. Minimax: Aufstellung einer Kostenfunktion, die das Risiko quantifiziert, eine Hypothese oder ihre Alternative auszusuchen. Der Minimax-Ansatz wählt  $H_0$  so, daß der maximal mögliche Wert der Kostenfunktion minimiert wird.
5. Bayes: Aufstellung der Kostenfunktion, die ein Maß für die Konsequenzen der Wahl von Hypothese  $H_0$  statt  $H_1$  gibt. Eine typische Kostenfunktion ist z.B.:

$$C = C_{00} \cdot P(H_0) \cdot P_a + C_{01} \cdot P(H_0) \cdot P_b + C_{10} \cdot P(H_1) \cdot P_c + C_{11} \cdot P(H_1) \cdot P_d \quad (6.4)$$

mit den A-Priori-Wahrscheinlichkeiten  $P(H_0)$  und  $P(H_1)$  der Hypothesen  $H_0$  und  $H_1$ . Die Werte  $P_a$  bis  $P_d$  entsprechen der Wahrscheinlichkeit einer Sensorzuweisung unter vier möglichen Bedingungen:

$P_a$  = Wahrscheinlichkeit, daß Sensor  $H_0$  für wahr erklärt, wenn  $H_0$  wahr ist.

$P_b$  = Wahrscheinlichkeit, daß Sensor  $H_0$  für falsch erklärt, wenn  $H_0$  wahr ist.

$P_c$  = Wahrscheinlichkeit, daß Sensor  $H_1$  für wahr erklärt, wenn  $H_1$  wahr ist.

$P_d$  = Wahrscheinlichkeit, daß Sensor  $H_1$  für falsch erklärt, wenn  $H_1$  falsch ist.

$P_a$  und  $P_c$  sind Detektionswahrscheinlichkeiten, während  $P_b$  und  $P_d$  die Wahrscheinlichkeit von Falschalarmen beschreiben. Die Konstanten  $C_{ij}$  sind willkürlich gewählt.

Diese Zusammenfassung von Entscheidungsregeln zum Hypothesentest ist nicht erschöpfend. Besonders die Minimax-Ansätze können komplexe Kostenfunktionen benutzen.

Klassische Inferenztechniken können besonders hilfreich sein bei Anwendungen wie der Identifizierung defekter Fabrikationsteile und bei der Analyse von Fehlern bei der Systemdiagnose.

Entscheidungsregel	Kriterium	Formulierung (... wähle $H_0$ , wenn ...)
Maximum A Posteriori	Basis: Beobachtungsdaten; Bestimmung der wahrscheinlichsten Hypothese	$P(H_0 / y) > P(H_1 / y)$
Maximum Likelihood	Basis: Beobachtungsdaten und A-Priori-Wahrscheinlichkeiten für Hypothesen; Bestimmung der wahrscheinlichsten Hypothese	$P(H_0) \cdot P(y / H_0) > P(H_1) \cdot P(y / H_1)$
Neyman-Pearson	Basis: Beobachtungsdaten; Konstruktion eines Tests, der die maximale Leistung zur Unterscheidung gegen Falschalarme aufweist	$\frac{L(y / H_0)}{L(y / H_1)} \leq con.$
Minimax	Wahl der A-Priori-Annahme, die die durch eine Kostenfunktion spezifizierten maximalen Kosten minimiert	Wahl von $P(H_0)$ so, daß der maximal mögliche Wert einer Kostenfunktion minimiert wird

Bayes	Wahl der Annahme, die eine Kostenfunktion, die auf Detektions- und Falschalarmwahrscheinlichkeiten basiert, minimiert	$\frac{P(y / H_0)}{P(y / H_1)} > \frac{P(H_1)}{P(H_0)} \cdot \frac{C_{01} - C_{11}}{C_{10} - C_{00}}$
-------	---	---

Tabelle 6.2: Entscheidungsregeln für Hypothesentests

### 6.3 Bayes'sche Inferenz

Die Bayes'sche Inferenz hat ihren Namen von dem englischen Reverend Thomas Bayes (1702 - 1761). Zwei Jahre nach seinem Tod wurde ein Paper veröffentlicht, das die Ungleichung enthielt, die als Bayes' Theorem bekannt geworden ist. Die Bayes'sche Inferenz löst einige der Schwierigkeiten der klassischen Inferenz. Sie aktualisiert die Wahrscheinlichkeit einer Hypothese bei gegebenem vorhergehendem Wahrscheinlichkeitsschätzwert und Zusatzinformationen in Form von Beobachtungen. Die Technik kann sich auf klassische oder subjektive Wahrscheinlichkeiten beziehen, d.h. sie benötigt nicht unbedingt Wahrscheinlichkeitsdichtefunktionen.

Subjektive Wahrscheinlichkeiten sind ein Teil der täglich gemachten Inferenzen. Menschen treffen ständig Entscheidungen und Beurteilungen, die auf subjektiven Annahmen der Wahrscheinlichkeit zukünftiger Ereignisse beruhen, z.B. kann ein Pendler einen Weg zu seiner Arbeitsstelle einem anderen vorziehen mit seiner persönlichen Einschätzung der Wahrscheinlichkeit eines Verkehrsstaus. Diese Wahrscheinlichkeitseinschätzungen sind subjektiv, nicht wiederholbar und variieren von Mensch zu Mensch. Dazu kommt noch, daß Menschen eine unterschiedliche Einschätzung vornehmen, je nachdem, ob die Wahrscheinlichkeitsannahme in positiver oder negativer Form ausgedrückt wird. Daher leiden subjektive Wahrscheinlichkeiten nicht nur ein wenig an mangelnder mathematischer Rigorosität. Trotzdem kann das Konzept subjektiver Wahrscheinlichkeit in einem Datenfusionsinferenzprozessor nützlich sein.

Der Bayes'sche Inferenzprozeß verläuft wie folgt: Angenommen sei, daß  $H_1, H_2, \dots, H_j$  sich gegenseitig ausschließende und erschöpfende Hypothesen darstellen, die ein Ereignis  $E$  (eine Beobachtung) erklären können, die gerade aufgetreten ist. Dann gilt:

$$P(H_i|E) = \frac{P(E / H_i) \cdot P(H_i)}{\sum_i P(E / H_i) \cdot P(H_i)} \quad (6.5)$$

mit:

$$\sum_i P(H_i) = 1 \quad (6.6)$$

wobei  $P(H_i / E)$  die A-Posteriori-Wahrscheinlichkeit der wahren Hypothese  $H_i$  bei eingetretenem Ereignis ist,  $P(H_i)$  die A-Priori-Wahrscheinlichkeit der wahren Hypothese  $H_i$  und  $P(E / H_i)$  die Wahrscheinlichkeit für das Auftreten des Ereignisses  $E$  unter der Bedingung, daß  $H_i$  wahr ist [21, 44].

Die Anwendung von Gl. (6.5) auf das Beispiel der Senderidentifikation aus Abschnitt 6.2 würde zu folgenden Formulierungen führen:

$$P(E_1 / PRI_{Observed}) = \frac{P(PRI_{Observed} / E_1) \cdot P(E_1)}{\sum_i P(PRI_{Observed} / Emitter_i) \cdot P(Emitter_i)} \quad (6.7)$$

und:

$$P(E_2 / PRI_{Observed}) = \frac{P(PRI_{Observed} / E_2) \cdot P(E_2)}{\sum_i P(PRI_{Observed} / Emitter_i) \cdot P(Emitter_i)} \quad (6.8)$$

In Gl. (6.7) ist  $P(E_1 / PRI_{Observed})$  die A-Posteriori-Wahrscheinlichkeit des Auftretens für einen Emitter der Klasse  $E_1$  bei einem für die  $PRI$  gegebenen Wert von  $PRI_{Observed}$ . Der Term  $P(PRI_{Observed} / E_1)$  stellt die Wahrscheinlichkeit dar, daß ein Emitter der Klasse  $E_1$  eine  $PRI$  von  $PRI_{Observed}$  aufweisen würde. Der Wert  $P(E_1)$  steht für die A-Priori-Wahrscheinlichkeit, daß ein Emitter der Klasse  $E_1$  überhaupt existiert. Analog dazu kann Gl. (6.8) interpretiert werden.

Die Bayes'sche Formulierung ist aus mehreren Gründen günstig: Zunächst liefert sie eine Bestimmung der Wahrscheinlichkeit für eine wahre Hypothese bei gegebenem Befund. Im Gegensatz dazu erbrachte die Formulierung entsprechend der klassischen Inferenz die Wahrscheinlichkeit, daß eine Beobachtung einem Objekt oder einem Ereignis bei gegebener Hypothese zugeordnet werden konnte. Weiter erlaubt die Bayes'sche Formulierung die Einbeziehung von A-Priori-Wissen bzgl. der Wahrscheinlichkeit, daß eine Hypothese überhaupt wahr ist. Die Nützlichkeit dieser Eigenschaft der Inferenz nach Bayes kann an dem folgenden Beispiel demonstriert werden:

Angenommen, ein Patient geht zum Arzt, um einen Test für eine seltene Blutkrankheit durchführen zu lassen. Der medizinische Test birgt eine Genauigkeit von 98 %, d.h. wenn der Patient die Blutkrankheit hat, wird der Test sie mit 98 %-iger Wahrscheinlichkeit anzeigen. Weiter sei angenommen, daß die seltene Blutkrankheit bei einer von 1000 Personen auftritt. Wenn der Patient darüber informiert würde, daß er krank ist, wie hoch ist dann die Wahrscheinlichkeit, daß er oder sie tatsächlich krank ist. Das eher überraschende Ergebnis entsprechend der Formulierung nach Bayes ist:

$$\begin{aligned}
 P\left(\begin{array}{l} \text{Patient krank / Information} \\ \text{über positiven Test} \end{array}\right) &= \frac{P(PT / AK) \cdot P(AK)}{P(PT / AK) \cdot P(AK) + P(PT / NK) \cdot P(NK)} \\
 &= \frac{0.98 \cdot 0.001}{0.98 \cdot 0.001 + 0.02 \cdot 0.999} \\
 &= 0.0468 (< 5 \% !!!)
 \end{aligned} \tag{6.9}$$

mit  $AK$  = Auftreten der Krankheit,  $NK$  = Nichtauftreten der Krankheit und  $PT$  = Positiver Test.

Eine weitere bemerkenswerte Eigenschaft der Bayes'schen Formulierung ist die Möglichkeit, subjektive Wahrscheinlichkeiten als A-Priori-Hypothesenwahrscheinlichkeiten zu verwenden und für die Wahrscheinlichkeit eines Befundes bei gegebener Hypothese. Diese Eigenschaft erlaubt eine zügige Implementierung eines Bayes'schen Inferenzprozessors besonders für die Multisensorfusion, da keine Wahrscheinlichkeitsdichtefunktionen notwendig sind. Das Ergebnis eines solchen Prozesses kann natürlich nur so gut sein wie es die Qualität der Eingabedaten zuläßt. Schlechte Eingabedaten, d.h. A-Priori-Wahrscheinlichkeiten, geben der berechneten Ausgangshypothese eine Tendenz, die die Berechnungen sinnlos machen.

Bild 6.3 illustriert den Gebrauch einer Bayes'schen Formulierung zur Identitätsfeststellung. Mehrere Sensoren beobachten parametrische Daten (z.B. RCS, PRI, IR-Spektrum) einer Plattform, deren Identität unbekannt ist. Jeder der Sensoren trifft eine Identitätsfeststellung oder generiert eine Hypothese bzgl. der Identität des Objekts. Für jeden Sensor liefern A-Priori-Daten einen Schätzwert für die Wahrscheinlichkeit, daß der Sensor das Objekt als zum Typ  $i$  zugehörig feststellen würde, wenn das Objekt tatsächlich vom Typ  $j$  wäre, d.h.  $P(\text{Objekt } j / \text{Feststellung des Typs } i)$ . Diese Feststellungen werden dann durch eine Verallge-

meinerung von Gl. (6.5) kombiniert. Ergebnis ist eine aktualisierte Verbundwahrscheinlichkeit für jede mögliche Plattform *Objekt*  $j$ . Damit ist:

$$P(O_j / D_1 \dots D_n), j = 1, \dots, M \quad (6.10)$$

die Wahrscheinlichkeit für das Beobachten von Objekt  $j$  bei den gegebenen Deklarationen  $D_1$  von Sensor 1,  $D_2$  von Sensor 2 usw. Damit ist die Anwendung einer Entscheidungslogik und die Auswahl einer Verbundidentitätsfeststellung durch Auswahl des Objekts, dessen Verbundwahrscheinlichkeit  $P(O_j / D_1 D_2 \dots)$  den größten Wert hat, möglich.

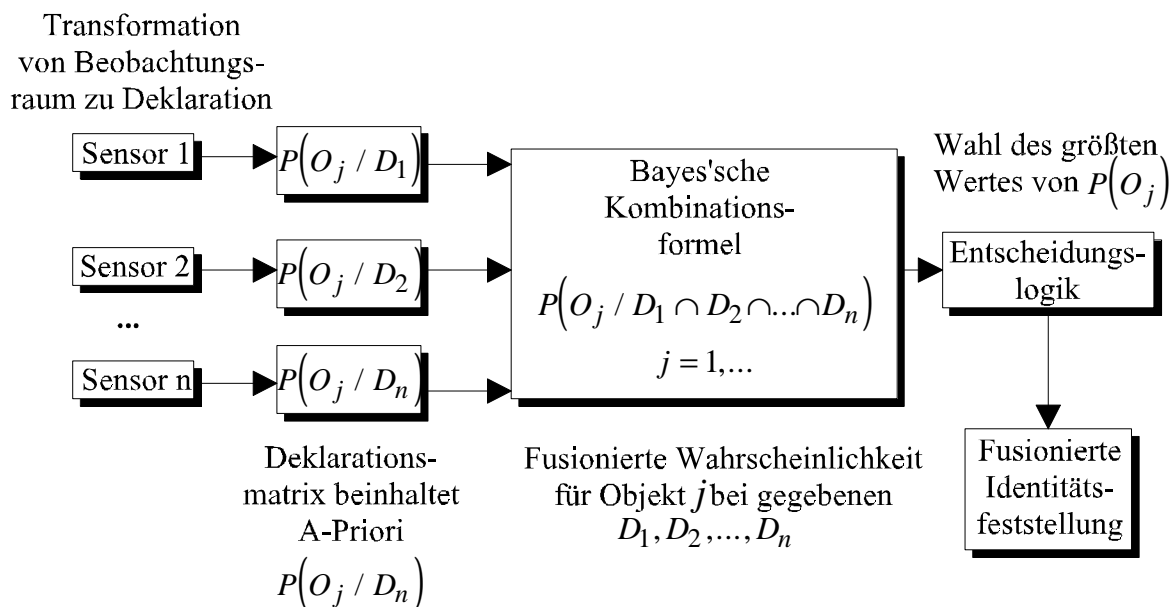


Bild 6.3: Zusammenfassung der Bayes'schen Fusion

Die Wahl des Maximalwertes von  $P(O_j / D_1 \dots D_n)$  wird als Maximum-A-Posteriori (MAP) - Entscheidungslogik bezeichnet. Die Bayes'sche Formulierung ermöglicht die Kombination von Identitätsfeststellungen mehrerer Sensoren zur Erreichung einer Verbundidentitätsfeststellung. Die nötigen Eingaben sind dabei die Fähigkeit zur Berechnung von  $P(E / H_i)$  für jeden Sensor oder jede Hypothese  $H_i$  und die A-Priori-Wahrscheinlichkeiten der wahren Hypothesen  $P(H_i)$ . Wenn keine A-Priori-Information bzgl. der relativen Wahrscheinlichkeit von  $H_i$  exi-



stiert, dann wird das Prinzip der Indifferenz angewendet, indem  $P(H_i)$  für alle  $i$  gleichgesetzt wird.

Nachteile der Bayes'schen Inferenz sind:

- Schwierigkeit der Definition vorheriger Wahrscheinlichkeiten.
- Komplexität, wenn es mehrere potentielle Hypothesen und mehrere bedingte Ereignisse gibt.
- Notwendigkeit, daß konkurrierende Hypothesen sich gegenseitig ausschließen.
- Allgemeine Unsicherheit/Unwissenheit kann nicht zugewiesen werden.

Ein einfaches Beispiel für kritisierte Unzulänglichkeiten der Bayes'schen Inferenz liefert der Versuch, die Frage zu beantworten, ob es „Leben nahe Sirius“ gibt [61]:

„Gibt es Leben nahe Sirius? Gibt es oder gibt es keine lebenden Wesen im Orbit des Sternes Sirius? Einige Wissenschaftler mögen Antworten auf diese Frage haben, aber die meisten wohl nicht.  $J_1$  beschreibe die Möglichkeit, daß es Leben gibt, und  $J_2$  die Möglichkeit, daß es eben kein Leben gibt. Der Satz der Möglichkeiten ist dann  $\Theta = \{J_1, J_2\}$ . Man könnte in diesem Kontext der Menge der Möglichkeiten auch die Frage hinzufügen, ob Sirius Planeten hat oder nicht. Der Satz von Möglichkeiten könnte dann z.B.  $\Omega = \{x_1, x_2, x_3\}$  sein, wobei  $x_1$  die Möglichkeit beschreibt, daß es Leben gibt.  $x_2$  korrespondiert zu der Möglichkeit, daß es zwar Planeten, aber kein Leben gibt, und  $x_3$  zu der Möglichkeit, daß es noch nicht einmal Planeten gibt. Der Satz  $\Omega$  ist dabei so mit dem Satz  $\Theta$  verknüpft, daß  $J_1$  zu  $x_1$  korrespondiert und  $\{x_2, x_3\}$  zu  $J_2$ . Der Anhänger der Bayes'schen Theorie könnte nun versuchen, seine Unsicherheit bzw. Unwissenheit durch  $P(\{J_1\}) = P(\{J_2\}) = \frac{1}{2}$  auszudrücken. Wenn er dann aber  $\Omega$  betrachtet, muß er  $P(\{x_1\}) + P(\{x_2\}) + P(\{x_3\}) = 1$  erfüllen. Damit besteht der beste Versuch, seine Unsicherheit bzw. Unwissenheit darzustellen, in dem Ausdruck  $P(\{x_1\}) = P(\{x_2\}) = P(\{x_3\}) = \frac{1}{3}$ . Das aber würde bedeuten, daß  $P(\{x_1\}) = \frac{1}{3}$  und  $P(\{x_2, x_3\}) = \frac{2}{3}$  ist. Da aber  $\{J_1\}$  dieselbe Bedeutung hat wie  $\{x_1\}$  und  $\{J_2\}$  wie  $\{x_2, x_3\}$ , ergibt sich eine nicht aufhebbarer Inkonsistenz.“

Dabei besteht aber der beste Versuch, die Unsicherheit bzw. Unwissenheit bzgl. der gestellten Frage, wie schon aus der angedeuteten Korrespondenz zwischen  $J_1$  und  $x_1$  bzw.  $J_2$  und so-

wohl  $\mathbf{x}_2$  als auch  $\mathbf{x}_3$  ersichtlich, in der Formulierung  $P(\{\mathbf{x}_1\}) = 0.5$ ,  $P(\{\mathbf{x}_2\}) = 0.25$  und  $P(\{\mathbf{x}_3\}) = 0.25$ . Damit ergäbe sich dann keine Inkonsistenz, allerdings wäre das Vorwissen über die Korrespondenzen genutzt worden. Das Problem besteht darin, daß für die Beantwortung der Frage nach „Leben auf Sirius“ kein Satz sich gegenseitig ausschließender und erschöpfender Hypothesen aufgestellt wurde, der aber Vorbedingung für die Anwendung der Bayes'schen Inferenz ist. Diese Vorbedingung gilt nicht für die Verallgemeinerung der Bayes'schen Inferenz durch die Methode von Dempster-Shafer, die im nächsten Abschnitt vorgestellt wird.

## 6.4 Methode von Dempster-Shafer

Shafer und Dempster [61] verallgemeinern die Bayes'sche Theorie insoweit, daß sie die Einbeziehung eines gewissen Grades von Unsicherheit bzw. Unwissenheit ermöglicht. Die Dempster-Shafer-Methode (D-S) verwendet Wahrscheinlichkeits- und Unsicherheitsintervalle zur Bestimmung der Wahrscheinlichkeit von Hypothesen basierend auf Mehrfachbefunden. Zusätzlich berechnet die D-S eine Wahrscheinlichkeit dafür, daß jede Hypothese wahr sei. Die zwei Methoden erzeugen identische Resultate, wenn alle berücksichtigten Hypothesen sich gegenseitig ausschließen (d.h.  $H_i$  überlappt  $H_j$  nicht für alle  $i = j$ ) und der Hypothesenvorrat erschöpfend ist (d.h. kein genereller Unsicherheitspegel). Die folgende Diskussion stützt sich auf die Beschreibung in [47] und [18].

Die D-S versucht, die Art, wie Menschen einen Befund zu hypothetischen Annahmen zuweisen, zu simulieren. D-S argumentiert, daß Menschen einen Befund (d.h. Wahrscheinlichkeiten) nicht einem Satz sich gegenseitig ausschließender und erschöpfender Hypothesen zuweisen. Stattdessen würden Menschen Kombinationen von Hypothesen Vertrauensmaße zuweisen, d.h. zu Annahmen statt zu Hypothesen. Im folgenden wird zwischen Annahmen und Hypothesen unterschieden. Eine Hypothese ist demnach eine fundamentale Aussage über ein Objekt (z.B. ein Objekt ist ein Airbus-Flugzeug). Eine Annahme kann entweder eine Hypothese oder eine Kombination von Hypothesen sein. Annahmen können sich überlappende oder widersprechende Hypothesen enthalten (z.B. Annahme 1: Objekt ist Airbus-Flugzeug, Annahme 2: Objekt ist ein Kampfflugzeug oder ein Airbus-Flugzeug, Annahme 3: Objekt ist ein Kampfflugzeug). Annahme 1 überschneidet sich mit Annahme 2, Annahme 2 tut dies mit Annahme 3 und Annahme 1 widerspricht Annahme 3.

Berücksichtigt werde nun ein Satz von  $n$  sich gegenseitig ausschließenden und erschöpfenden Hypothesen bzgl. einer bestimmten Betrachtungseinheit:

$$\Theta = \{A_1, A_2, \dots, A_n\} \quad (6.11)$$

Dieser Satz elementarer Annahmen wird in der D-S-Terminologie als „Frame of Discernment“ bezeichnet. Ein einfaches Beispiel eines solchen Annahmensatzes ist der Wurf eines Würfels. Elementare Annahmen sind dabei Aussagen wie:

1. Die gewürfelte Nummer ist die „1“.

2. Die gewürfelte Nummer ist die „6“.

Wenn  $\Theta$  den Satz der  $n$  Elementarannahmen bezeichnet, dann gibt es  $2^{n-1}$  allgemeine Annahmen, die aus Boole'schen Kombinationen entwickelt werden können:

$$2^{\Theta} = \{A_1 \vee A_2, A_1 \vee A_3, \dots\} \quad (6.12)$$

Für das Würfelexperiment zählen zu den allgemeinen Annahmen auch die folgenden:

1. Die gewürfelte Zahl ist gerade.
2. Die gewürfelte Zahl ist ungerade.

Eine wichtige allgemeine Annahme ist die Boole'sche Disjunktion aller elementaren Annahmen  $\bar{\Theta}$ :

$$\bar{\Theta} = A_1 \vee A_2 \vee \dots \vee A_n \quad (6.13)$$

Die D-S weist den Befund sowohl einzelnen als auch allgemeinen Annahmen zu statt der Zuweisung von Wahrscheinlichkeiten zu Hypothesen wie bei Bayes. Der D-S-Ansatz entwickelt das Konzept einer Wahrscheinlichkeitsmasse  $m(\Theta)$  zur Darstellung von zugewiesenen Befunden. Ein Beobachter (oder Sensor) kann Wahrscheinlichkeitsmassen  $m(A_1)$ ,  $m(A_2)$ ,  $m(A_1 \vee A_2)$  usw. zuweisen. Die Wahrscheinlichkeitsmassen sind so definiert, daß:

$$m(\Theta) \leq 1 \quad (6.14)$$

wobei  $m(\Theta)$  eine Wahrscheinlichkeitsmasse bezeichnet, die entweder einer elementaren Annahme oder einer allgemeinen Annahme aus dem Satz  $2^{\Theta}$  zugewiesen ist. Die Summe aller Massenfunktionen ist:

$$\sum m(\Theta) = 1 \quad (6.15)$$

Der Zusammenhang zwischen Wahrscheinlichkeitsmassen und Wahrscheinlichkeit wird durch eine Summation hergestellt. Die Wahrscheinlichkeit einer Annahme  $A_i$  ist durch die Summe der Wahrscheinlichkeitsmassen der zugehörigen Elemente in  $\Theta$  und  $2^\Theta$  gegeben:

$$\text{Wahrscheinlichkeit}(A_i) = \sum_{A_i \in \Theta_1 2^\Theta} m(\Theta, 2^\Theta) \quad (6.16)$$

d.h. die  $m(\Theta)$  werden für das Element von  $\Theta$ , das  $A_i$  exakt enthält (es gibt nur ein Element von  $\Theta$ , das  $A_i$  exakt enthält, da  $A_i$  sich von  $A_j$  im Satz der elementaren Annahmen unterscheidet) addiert und zusätzlich werden die  $m(\Theta)$  für die allgemeinen Annahmen in  $2^\Theta$  addiert, die  $A_i$  als Element enthalten.

Diese Methode (Gl. (6.16)) zur Berechnung der Wahrscheinlichkeit einer elementaren Annahme ist eine der Eigenschaften der D-S, nämlich, daß ein Befund nicht nur sich gegenseitig ausschließenden Annahmen zugeordnet werden kann, sondern auch zu allgemeinen Annahmen, bei denen es zu Überlappungen und nicht ausschließenden allgemeinen Annahmen kommen kann. Tatsächlich kann eine Wahrscheinlichkeitsmasse der allgemeinen Annahme  $\bar{\Theta}$  (Gl. (6.13)) zugewiesen werden, was darauf hinausläuft, einen allgemeinen Unsicherheitsgrad zu definieren. Da  $\bar{\Theta}$  jede elementare Annahme  $A_i$  enthält, ist  $m(\bar{\Theta})$  ein Indikator für das Maß, bis zu dem ein Beobachter (oder Sensor) unfähig ist, zwischen den Annahmen zu unterscheiden. Besonders wenn  $m(\bar{\Theta}) = 1$ , ist es für den Beobachter unmöglich, zwischen den elementaren Annahmen zu unterscheiden.

Die D-S definiert das Konzept eines evidentiellen Intervalls  $[Spt(B_i), Pls(B_i)]$ . Die Unterstützung für eine Annahme  $B_i$  ist definiert als:

$$Spt(B_i) = \sum_{B_i \in \Theta_1 2^\Theta} m(\Theta, 2^\Theta) \quad (6.17)$$

Gl. (6.17) beschreibt den Support für die Annahme  $B_i$  als Summe über die Wahrscheinlichkeitsmassen einer Annahme (beide innerhalb  $\Theta$  und  $2^\Theta$ ). Wenn  $B_i$  eine einfache Annahme ist (z.B. wenn  $B_i = A_i$ ), dann ist  $Spt(B_i)$  die Wahrscheinlichkeit von  $A_i$ . Wenn  $B_i$  eine allge-

meine Annahme ist, z.B.  $B_i = A_1 \vee A_2 \vee A_3$ , dann ist die Unterstützung für  $B_i$  die Summe der Wahrscheinlichkeitsmassen, die zu allen Elementen von  $B_i$  beitragen:

$$Spt(A_1 \vee A_2 \vee A_3) = m(A_1) + m(A_2) + m(A_3) + m(A_1 \vee A_2) + m(A_1 \vee A_3) + m(A_2 \vee A_3) + m(A_1 \vee A_2 \vee A_3) \quad (6.18)$$

Ähnlich ist die Plausibilität einer Annahme  $A_i$  definiert als der Mangel an Befund, der die Negation ( $\bar{A}_i$ ) unterstützt:

$$Pls(A_i) = 1 - Spt(\bar{A}_i) \quad (6.19)$$

Der Output eines D-S-Prozesses ist ein Satz von evidentiellen Intervallen:

$$\begin{aligned} & [Spt(A_1), Pls(A_1)] \\ & [Spt(A_2), Pls(A_2)] \\ & \dots \end{aligned} \quad (6.20)$$

Eingegeben werden Wahrscheinlichkeitsmassen  $m(A_i)$ , die von einem Beobachter oder Sensor zugewiesen werden. Es gilt die Relation:

$$Spt(A) \leq P(A) \leq Pls(A) \quad (6.21)$$

#### 6.4.1 D-S-Fusionsprozeß

Bild 6.4 veranschaulicht das Konzept für den Gebrauch eines D-S-Ansatzes zur Fusion multi-sensorieller Identitätsdaten. Analog zum Bayes'schen Ansatz sammeln dabei einzelne Sensoren parametrische Daten und weisen einen Befund für die Identität der beobachteten Betrachtungseinheit zu. Diese Identitätsfeststellungen werden über Wahrscheinlichkeitsmassenfunktionen (gegenüber Wahrscheinlichkeiten im Bayes'schen Ansatz) quantifiziert. Die Dempster'schen Kombinationsregeln liefern eine Prozedur zur Kombination der Deklarationen und resultieren

in einem evidentiellen Verbundintervall  $[Spt(H_i), Pls(H_i)]$  für jede mögliche Hypothese (d.h. mögliche Identität von beobachteten Objekten). Der Support  $Spt(H_i)$  für eine Hypothese ist hier ein Befundmaß, das einer Hypothese Glaubwürdigkeit verleiht, während die Plausibilität  $Pls(H_i)$  ein Maß für den Befund darstellt, der es nicht schafft,  $H_i$  zu widerlegen. Eine Entscheidungslogik selektiert die Hypothese mit dem „besten“ Befundintervall. Resultat ist die Feststellung der Identität eines Objektes auf Basis aller Sensoregebnisse.

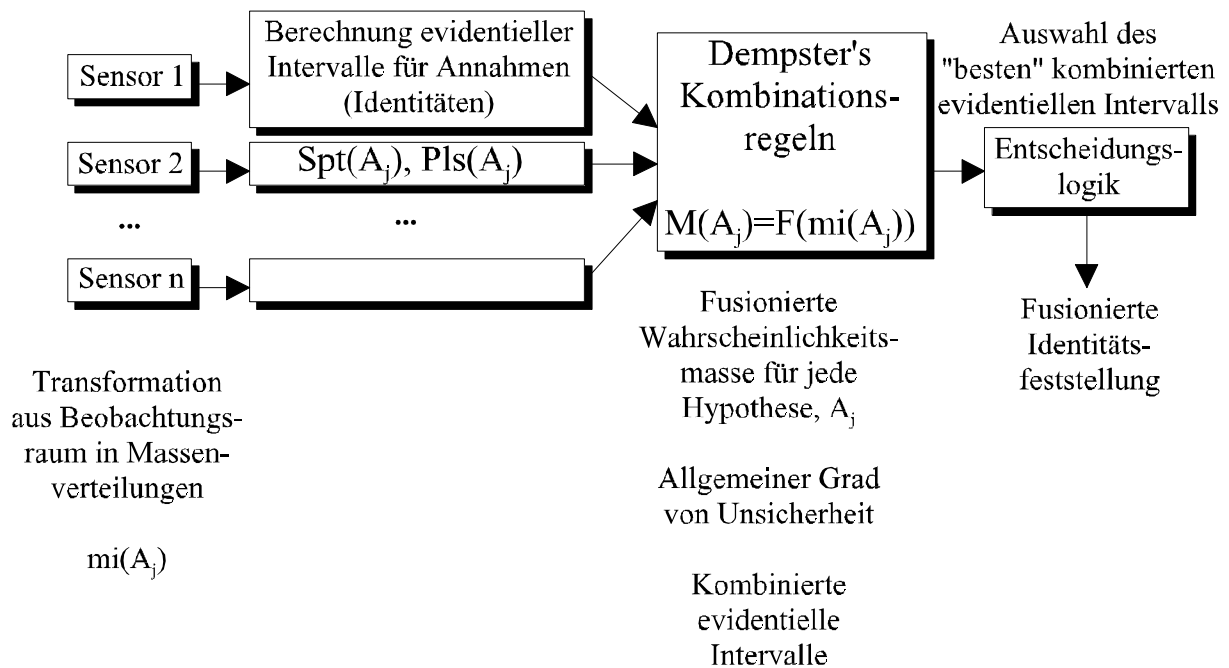


Bild 6.4: Zusammenfassung der D-S

Der Verlauf des Identitätsfusionsprozesses ist ähnlich dem in Abschnitt 6.3 beschriebenen Bayes'schen Ansatz. Statt Wahrscheinlichkeiten von alternativen Hypothesen als Input der Sensoren (Identitätsfeststellungen) weisen die D-S-Sensoren Wahrscheinlichkeitsmassen mehreren (nichtausschließenden, nichterschöpfenden) Annahmen zu. Diese Wahrscheinlichkeitsmassen werden mit bestimmten Regeln kombiniert und ein Satz von Befundintervallen berechnet. Genau wie die Bayes'sche Fusion den Weg zur Auswahl einer vorherrschenden Hypothese nicht vorschreibt, schreibt auch der D-S-Ansatz keine Entscheidungslogik zur Auswahl einer als wahr anzunehmenden Annahme vor. Trotzdem besteht die Möglichkeit für sog. schwache Entscheidungen, bei denen es nur ungenügenden Befund gibt zur Erklärung eines hypothetischen Gewinners von konkurrierenden Hypothesen.

Eine besonders nützliche Eigenschaft des D-S-Ansatzes ist die Möglichkeit, einen allgemeinen Grad von Unsicherheit einzurichten. Anders als der Bayes'sche Ansatz ermöglicht D-S die explizite Berücksichtigung unbekannter möglicher Ursachen von Beobachtungsdaten, was offensichtlich besonders wichtig in einer militärischen Umgebung ist, in der die Beobachtungen durch Gegenmaßnahmen beeinträchtigt sein können.

#### 6.4.2 Dempster'sche Kombinationsregel

Analog zur Bayes'schen Formel zur Kombination von Wahrscheinlichkeiten definiert Dempster Kombinationsregeln [13]. Diese Regeln ergeben einen Formalismus zur Kombination von Wahrscheinlichkeitsmassen von unterschiedlichen Quellen. [18] faßt eine Reihe von Regeln zur Fusion von Wahrscheinlichkeitsmassen mehrerer Quellen zusammen. Die gefundenen Methoden sind in einem regelbasierten System implementiert (ROSIE: A Rule-Oriented System for Implementing Expertise). Es werden erfolgreich durchgeführte Experimente beschrieben, die dazu dienen, das Problem der Bestimmung eines Fahrzeugtyps (z.B. Kutter, Containerschiff, Ruderboot) zu lösen. Prinzipiell ist diese Art der Problemlösung jedoch auch für andere Typisierungsaufgaben jedweder Betrachtungseinheiten anwendbar.

Die folgende Darstellung für den besonderen Fall zweier Sensoren  $S_1$  und  $S_2$ , die drei Hypothesen Befund zuweisen, orientiert sich an [67]:

$$\begin{aligned}
 u_0 &= \text{Annahme 1} = \text{Hypothese A ist wahr} \\
 u_1 &= \text{Annahme 2} = \text{Hypothese B ist wahr} \\
 u_2 &= \text{Annahme 3} = \text{Hypothese A oder B ist wahr}
 \end{aligned}
 \tag{6.22}$$

		$S_2$		
		$m_2(u_0)$	$m_2(u_1)$	$m_2(u_2)$
$S_1$	$m_1(u_0)$	$m(u_0) = m_1(u_0) \cdot m_2(u_0)$	$k_{10} = m_1(u_0) \cdot m_2(u_1)$	$m(u_0) = m_1(u_0) \cdot m_2(u_2)$
	$m_1(u_1)$	$k_{01} = m_1(u_1) \cdot m_2(u_0)$	$m(u_1) = m_1(u_1) \cdot m_2(u_1)$	$m(u_1) = m_1(u_1) \cdot m_2(u_2)$



$m_1(u_2)$	$m(u_0) = m_1(u_2) \cdot m_2(u_0)$	$m(u_1) = m_1(u_2) \cdot m_2(u_1)$	$m(u_2) = m_1(u_1) \cdot m_2(u_2)$
------------	------------------------------------	------------------------------------	------------------------------------

Tabelle 6.3: Dempster'sche Kombinationsregel

Der Sensor  $S_1$  beobachtet parametrische Daten und ordnet die Wahrscheinlichkeitsmassen  $\{m_1(u_0), m_1(u_1), m_1(u_2)\}$  den drei Annahmen zu. Analog verhält sich Sensor  $S_2$ . Tabelle 6.3 faßt die Dempster'schen Kombinationsregeln für diesen Fall zusammen [67]. Die Elemente dieser Matrix bestehen aus dem Verbundbefund der zwei Sensoren. Für identische Annahmen gilt, daß die Verbundwahrscheinlichkeitsmasse einfach das Produkt der von den jeweiligen Sensoren zugewiesenen Massen ist. Z.B. weist Sensor  $S_1$  die Wahrscheinlichkeitsmasse  $m_1(u_0)$  der Annahme  $u_0$  zu und Sensor  $S_2$  tut dies entsprechend mit der Wahrscheinlichkeitsmasse  $m_2(u_0)$ . Die Verbundwahrscheinlichkeitsmasse ist  $m(u_0) = m_1(u_0) \cdot m_2(u_0)$ . In dem Fall, in dem eine Annahme eine andere überlappt, ist die Zuweisung der Verbundwahrscheinlichkeitsmasse wieder trivial. Angenommen, Sensor  $S_2$  weist Annahme  $u_0$   $m_2(u_0)$  zu und Sensor  $S_1$  ordnet  $m_1(u_2)$  zur Annahme  $u_2$  zu, dann berechnet sich die Verbundwahrscheinlichkeitsmasse für Annahme  $u_0$  wie folgt:

$$m(u_0) = m_1(u_2) \cdot m_2(u_0) \tag{6.23}$$

Die Zuweisung eines Befundes zu gegeneinanderstehenden Annahmen ist dagegen nicht so einfach. Wenn z.B. Sensor  $S_1$  die Wahrscheinlichkeitsmasse  $m_1(u_1)$  zur Annahme  $u_1$  zuordnet und Sensor  $S_2$   $m_2(u_0)$  der Annahme  $u_0$ , dann stehen diese Befundzuweisungen zueinander in Konflikt ( $S_1$ : Hypothese B ist wahr,  $S_2$ : Hypothese A ist wahr). Hier berechnen die Dempster'schen Regeln nun einen Normalisierungsfaktor  $Q$ , der für das Beispiel aus der Summe der zu den in Konflikt stehenden Annahmen zugewiesenen Wahrscheinlichkeitsmassenprodukten besteht:

$$Q = k_{01} + k_{10} \quad (6.24)$$

Für zwei unabhängige Quellen können die Dempster'schen Regeln als:

$$m(u_l) = \frac{\sum_{A_i, B_j = u_l} m_1(A_i) \cdot m_2(B_j)}{1 - Q} \quad (6.25)$$

ausgedrückt werden [44] mit:

$$Q = \sum_{A_k, B_m = \emptyset} m_1(A_k) \cdot m_2(B_m) \quad (6.26)$$

Dabei ist  $\emptyset$  die leere Annahme (unmögliches Ereignis); die Wahrscheinlichkeitsmasse für  $\emptyset$  ist:

$$m(\emptyset) = 0 \quad (6.27)$$

$u_l$  ist eine allgemeine Annahme, die definiert ist als Boole'sche Kombination der elementaren Hypothesen  $A_i$  und  $B_j$ .

Die Gesamtverbundwahrscheinlichkeitsdichtemasse für  $u_l$  ist die Summe der Produkte aller Wahrscheinlichkeitsmassen (von jedem Sensor) über alle Annahmen, die nicht widersprüchliche Hypothesenelemente  $A_i$  und  $B_j$  enthalten.

Im Beispiel in Tabelle 6.3 tragen drei Anteile für  $u_0$  zur Gesamtmasse bei: Die Produktmasse  $m_1(u_0) \cdot m_2(u_0)$ , wenn beide Sensoren den Befund zur Annahme  $u_0$  zuordnen, die Produktmasse  $m_1(u_0) \cdot m_2(u_2)$ , wenn Sensor  $S_2$  den Befund zur nicht widersprüchlichen Annahme  $u_2$  und Sensor  $S_1$  den Befund zur Annahme  $u_0$  zuweisen und die Produktmasse  $m_1(u_2) \cdot m_2(u_0)$ , wenn die Sensoren  $S_1$  und  $S_2$  sich genau entgegengesetzt verhalten wie bei der letzten Produktmasse.

Diese drei Anteile werden summiert und dann entsprechend dem widersprüchlichen Befund korrigiert, wenn Sensor  $S_2$  den Befund zu Annahme  $u_0$  zuweist, während Sensor  $S_1$  den Befund zu Annahme  $u_1$  zuordnet ( $k_{01}$ ) bzw. wenn Sensor  $S_1$  den Befund zu Annahme  $u_0$  und Sensor  $S_2$  entsprechend den Befund zu Annahme  $u_1$  zuordnen ( $k_{10}$ ).

[18] beschreibt einen Algorithmus zur Kombination von Wahrscheinlichkeitsmassen in einer komplexeren Situation. Angenommen seien zwei Sensoren, Sensor 1 und Sensor 2. Weiterhin sei angenommen, daß das Ausgangssignal jeden Sensors entweder eine Wahrscheinlichkeitsmasse für eine Originalhypothese  $A_i$  oder eine Kombination dieser Hypothesen beschreibt:

Sensor 1	
Hypothese	Wahrscheinlichkeitsmasse
$C_1$	$m(C_1)$
$C_2$	$m(C_2)$
$C_3$	$m(C_3)$
...	...
...	...
$C_u$	$m(C_u)$
$\Theta$	$m(\Theta)$

oder

Sensor 2	
Hypothese	Wahrscheinlichkeitsmasse
$D_1$	$m(D_1)$
$D_2$	$m(D_2)$
$D_3$	$m(D_3)$
...	...
...	...
$D_v$	$m(D_v)$
$\Theta$	$m(\Theta)$

D.h. Sensor 1 weist  $u$  Hypothesen  $C_1, C_2, \dots, C_u$  Wahrscheinlichkeitsmassen zu, wobei die  $C_k$  entweder Originalhypothesen  $A_i$  oder Boole'sche Kombinationen dieser Hypothesen sind. Analoges gilt für Sensor 2. I.A. können die Hypothesen  $C_i$  und  $D_j$  überlappen, sind jedoch nicht notwendigerweise identisch. Der Algorithmus nach [18] berechnet sowohl die Verbundwahrscheinlichkeitsmasse für die Hypothesen  $B_k$  als auch den allgemeinen Unsicherheitsgrad  $m(\Theta)$ . Die Hypothesen  $B_k$  sind die Konjunktionen aller Eingangshypothesen  $C_m$  und  $D_n$ . Aus den Verbundwahrscheinlichkeitsmassen kann das evidentielle Intervall  $\{Spt(B_k), Pls(B_k)\}$  berechnet werden.

[51] erklärt, daß die Dempster'schen Kombinationsregeln sowohl kommutativ als auch assoziativ sind. Die Ordnung und Gruppierung der Kombinationen beeinflusst die resultierenden Verbundwahrscheinlichkeitsmassen nicht, d.h. Sensordaten können hierarchisch kombiniert werden, was für eine Parallelimplementierung interessant ist. Zusätzlich kann dieselbe Technik genutzt werden, um A-Priori Hypothesen zugewiesene Wahrscheinlichkeitsmassen einzubeziehen.

[63] beschreibt eine Anwendung der D-S im Bereich der Fernerkundung.

Ein einfaches Beispiel für die D-S wird in [81] gegeben, das auf Zadeh zurückgeht: Zwei Mediziner untersuchen einen Patienten und stimmen überein, daß er entweder an Meningitis ( $M$ ), Gehirnerschütterung ( $G$ ) oder einem Gehirntumor ( $T$ ) leidet. Damit ist  $\Theta = \{M, G, T\}$ . Die Mediziner sind in ihrer Diagnose uneinig und weisen den Annahmen folgende Glaubwürdigkeiten bzw. Wahrscheinlichkeitsmassen zu:

Mediziner 1:

$$\begin{aligned} m_1(\{M\}) &= 0.99 \\ m_1(\{T\}) &= 0.01 \end{aligned}$$

Mediziner 2:

$$\begin{aligned} m_2(\{G\}) &= 0.99 \\ m_2(\{T\}) &= 0.01 \end{aligned}$$

d.h. sie stimmen in ihrer geringen Erwartung eines Tumors überein, streiten aber über die sonst möglichen Ursachen. Wenn nun mit der Kombinationsregel Gl. (6.25) die Glaubwürdigkeiten kombiniert werden, ergibt sich für  $m_{1/2}(\{T\}) = 1.0$ , d.h. beide Diagnosen sind zunächst glaubwürdig, wenn nicht weitere Untersuchungen andere Befunde ergeben.

Ein anderes Beispiel [52] behandelt die Gelbsucht, die ein Symptom für Leberzirrhose ( $Z$ ), Hepatitis ( $H$ ), Gallensteine ( $G$ ) und Gallenblasenkrebs ( $K$ ) sein kann. Prinzipiell könnten auch noch andere Ursachen für die Gelbsucht gefunden werden. In der Theorie der D-S wird jedoch immer angenommen, daß die Menge der Annahmen erschöpfend sei. Wenn nun andere Ursachen bekannt würden, würde die Menge der Annahmen um diese eine erweitert.

( $Z$ ) und ( $H$ ) sind Leberprobleme, während ( $G$ ) und ( $K$ ) Gallenblasenprobleme darstellen. Ein Patient habe nun z.B. starke Schmerzen im unteren Rücken, die mit Leberproblemen assoziiert werden können. Der Arzt diagnostiziert nun  $m_1(\{Z, H\}) = 0.7$  und

$m_1(\{Z, H, G, K\}) = 0.3$ . Wenn  $m_1$  eine normale Wahrscheinlichkeitsverteilung wäre, wäre  $m_1(\{G, K\}) = 0.3$  gesetzt worden, was bedeuten würde, daß die starken Schmerzen im unteren Rückenbereich mit einer Wahrscheinlichkeit von 0.3 andeuten würden, daß der Patient kein Leberproblem hat. D-S-Glaubwürdigkeitszuweisungen verteilen die restliche Glaubwürdigkeit auf die universale Hypothese, wohingegen klassische Wahrscheinlichkeitsverteilungen diese zum Komplement der aktuellen Hypothese zuweisen würden.

Ein weiterer Befund, der die Annahme ( $H$ ) niedriger einstuft, führe nun zu  $m_2(\{Z, G, K\}) = 0.8$  und  $m_2(\{Z, H, G, K\}) = 0.2$ . Um nun den Wert  $m_{1/2}(\{Z\})$  zu erhalten, werden Gl. (6.25) und Gl. (6.26) genutzt mit dem Ergebnis:

$$m_{1/2}(\{Z\}) = \frac{m_1(\{Z, H\}) \cdot m_2(\{Z, G, K\})}{1} = 0.56$$

da keine Schnittmenge der Kombinationen der Wahrscheinlichkeitsmassen  $m_1$  und  $m_2$  die leere Annahme ergibt und damit  $Q = 0$  ist. Für den Zähler ist  $m_1(\{Z, H\}) \cdot m_2(\{Z, G, K\})$  die einzige Kombination, die in ihrer Schnittmenge die Annahme ( $Z$ ) enthält. Bemerkenswert ist hier die Tatsache, daß nicht bekannt ist, wie sich der Wert 0.7 auf die Annahmen ( $H$ ) und ( $Z$ ) verteilt bzw. wie sich der Wert 0.8 auf ( $Z$ ), ( $G$ ) und ( $K$ ) verteilt.

Wenn nun die Tatsache, daß der Patient kein schwerer Trinker ist, zur Unterstützung der Annahme herangezogen wird, daß kein Leberproblem vorliegt, könnte  $m_2(\{G, K\}) = 0.8$  und  $m_2(\{Z, H, G, K\}) = 0.2$  gesetzt werden. Unter Berücksichtigung dieser Tatsache ergibt sich nun kein Wert für  $m_{1/2}(\{Z\})$ . Gefragt werde stattdessen nach  $m_{1/2}(\{Z, H\})$ . Die relevanten Glaubwürdigkeiten für die Zählsumme in Gl. (6.25) sind nun  $m_1(\{Z, H\}) = 0.7$  und  $m_2(\{Z, H, G, K\}) = 0.2$ . In der Nennersumme ergibt sich der einzige Anteil durch die Kombination  $m_1(\{Z, H\}) = 0.7$  und  $m_2(\{G, K\}) = 0.8$ , deren Schnittmenge die leere Annahme ist. Damit berechnet sich  $m_{1/2}(\{Z, H\})$  zu:

$$m_{1/2}(\{Z, H\}) = \frac{m_1(\{Z, H\}) \cdot m_2(\{Z, H, G, K\})}{1 - m_1(\{Z, H\}) \cdot m_2(\{G, K\})} = 0.32$$

was bedeutet, daß die Befunde in diesem Szenario die Annahme, daß der Patient eine Leberkrankheit hat, mit dem Grad 0.32 unterstützen.

## 6.5 GEP

Eine andere Verallgemeinerung der Bayes'schen Theorie ist von Thomopoulos vorgeschlagen worden [67-68], woran sich die nachfolgende Darstellung orientiert. Diese Formulierung wird als „Generalized Evidence Processing“ (GEP) bezeichnet.

$H_0$  und  $H_1$  seien zwei zu testende Hypothesen. Der Wahrscheinlichkeitsraum ist entsprechend den Ereignissen  $\{\mathbf{w} = H_0\}$  und  $\{\mathbf{w} = H_1\}$  mit den assoziierten Wahrscheinlichkeiten  $P_0 \geq 0$  und  $P_1 \geq 0$  ( $P_0 + P_1 = 1$ ) in zwei Bereiche unterteilt.

Weiterhin sei angenommen, daß  $d_0$ ,  $d_1$  und  $d_{0\vee 1}$  eine Basis bezeichnen, mit der ein Entscheidungsträger den Wahrscheinlichkeitsraum entsprechend den angesammelten Befunden unterteilt, wobei die drei Entscheidungen den Behauptungen „ $H_0$  ist wahr“, „ $H_1$  ist wahr“ und „ $H_0$  oder  $H_1$  ist wahr“ entsprechen. Die Entscheidung  $d_{0\vee 1}$  steht dabei für die Unfähigkeit des Entscheidungsträgers, eine beweiskräftige Behauptung zu finden.

In der klassischen Bayes'schen Theorie ist die zu  $d_{0\vee 1}$  gehörige Wahrscheinlichkeit gleich:

$$P(d_{0\vee 1}) = P(H_0 + H_1) = P(H_0) + P(H_1) = 1 \quad (6.28)$$

da  $H_0$  und  $H_1$  eine disjunkte Zerlegung des Wahrscheinlichkeitsraumes konstituieren, über den das Befundverarbeitungsproblem definiert ist. Wie weiter oben erwähnt, führte die offensichtliche Schwäche der Bayes'schen Theorie, sich nicht gegenseitig ausschließende, d.h. redundante Behauptungen zu integrieren, zur Entwicklung der D-S, die besonders effizient ist bei der Behandlung unklarer Behauptungen.

Die GEP vereint Bayes'sche und D-S-Theorie als Spezialfälle der GEP.

Ähnlich wie die D-S sammelt bei der GEP jeder Sensor Befunde und ordnet diese durch Wahrscheinlichkeitsmassen zu. Anders als bei der D-S kombiniert GEP diese jedoch basierend auf der bedingten A-Priori-Wahrscheinlichkeit der Hypothesen  $H_0$  und  $H_1$ .

$z$  sei eine Transformation aus dem anfänglichen Ereignisraum  $\Omega$  in den Beobachtungs(daten)raum  $Z$ :

$$z: \Omega \rightarrow Z \quad (6.29)$$

und  $d$  eine Transformation aus dem Beobachtungsraum in den Entscheidungsraum  $D$ :

$$d: Z \rightarrow D \quad (6.30)$$

$\{dP(z/H_i), P(H_i); i = 0,1\}$  sei das Wahrscheinlichkeitsmaß in  $Z$  und  $C_{ij}$  die mit einer Entscheidung  $i$  verbundenen Kosten, wenn die wahre Hypothese  $H_j$  ist. Die Abbildung  $d$  ist nun so zu definieren, daß eine Kostenfunktion [67]:

$$C = \sum_i \sum_j C_{ij} \cdot P_j \cdot \int_{Z_i} dP(z/H_j); j = 0,1 \text{ und } i = 0,1,2 \quad (6.31)$$

minimiert wird, wobei  $d_2 = d_{0 \vee 1}$  die mehrdeutige Entscheidung darstellt. Dabei sind  $P_0$  und  $P_1$  die A-Priori-Wahrscheinlichkeiten der Hypothesen  $H_0$  und  $H_1$ . Die Anteile  $\int_{Z_i} dP(z/H_j)$

korrespondieren zu den Wahrscheinlichkeiten einer Sensorzuweisung unter den vier möglichen Bedingungen, s. Abschnitt 6.2. In Gl. (6.31) weisen die Bereiche  $Z_i$  auf die Unterteilung des Beobachtungsraumes entsprechend der Entscheidungsregel  $d$  hin, wobei  $Z_i$  den Bereich des Beobachtungsraumes darstellt, für den die Entscheidung  $d_i$  gilt.

Für eine geschickte Wahl der Kostenfaktoren existieren Unterteilungen  $\{Z_i\}$ , die geeignete Wahrscheinlichkeitsmaße in  $D$  definieren und somit eine verallgemeinerte Entscheidungsregel  $d$ .

Durch Ausschreiben der Gl. (6.31) als:

$$\begin{aligned} C = & \int_{Z_0} [P_0 \cdot C_{00} \cdot dP(z/H_0) + P_1 \cdot C_{01} \cdot dP(z/H_1)] \\ & + \int_{Z_1} [P_0 \cdot C_{10} \cdot dP(z/H_0) + P_1 \cdot C_{11} \cdot dP(z/H_1)] \\ & + \int_{Z_2} [P_0 \cdot C_{20} \cdot dP(z/H_0) + P_1 \cdot C_{21} \cdot dP(z/H_1)] \end{aligned} \quad (6.32)$$



wird erkenntlich, daß die Kostenfunktion  $C$  minimiert wird, wenn die Entscheidungsregel die Beobachtung  $z$  dem Bereich zuordnet, der zum kleinsten Integranden der drei Integrale in Gl. (6.32) gehört.

Damit wird die Entscheidungsregel zu:

$$\begin{array}{ccc}
 & Z_1 \text{ oder } Z_2 & \\
 P_0 \cdot C_{00} \cdot dP(z/H_0) + P_1 \cdot C_{01} \cdot dP(z/H_1) & \begin{array}{c} > \\ < \end{array} & P_0 \cdot C_{10} \cdot dP(z/H_0) + P_1 \cdot C_{11} \cdot dP(z/H_1) \\
 & Z_0 \text{ oder } Z_2 & \\
 \\
 & Z_1 \text{ oder } Z_2 & \\
 P_0 \cdot C_{00} \cdot dP(z/H_0) + P_1 \cdot C_{01} \cdot dP(z/H_1) & \begin{array}{c} > \\ < \end{array} & P_0 \cdot C_{20} \cdot dP(z/H_0) + P_1 \cdot C_{21} \cdot dP(z/H_1) \\
 & Z_0 \text{ oder } Z_1 & \\
 \\
 & Z_0 \text{ oder } Z_2 & \\
 P_0 \cdot C_{10} \cdot dP(z/H_0) + P_1 \cdot C_{11} \cdot dP(z/H_1) & \begin{array}{c} > \\ < \end{array} & P_0 \cdot C_{20} \cdot dP(z/H_0) + P_1 \cdot C_{21} \cdot dP(z/H_1) \\
 & Z_0 \text{ oder } Z_1 & \\
 \end{array} \tag{6.33}$$

Durch Division von Gl. (6.33) durch  $dP(z/H_0)$  und Definition von:

$$\Lambda(z) = \frac{dP(z/H_1)}{dP(z/H_0)} \tag{6.34}$$

erhält die Entscheidungsregel ihre endgültige Form:

$$\begin{array}{ccc}
 & d_1 \text{ oder } d_2 & \\
 P_0 \cdot C_{00} + P_1 \cdot C_{01} \cdot \Lambda(z) & \begin{array}{c} > \\ < \end{array} & P_0 \cdot C_{10} + P_1 \cdot C_{11} \cdot \Lambda(z) \\
 & d_0 \text{ oder } d_2 & \\
 \end{array}$$

$$\begin{array}{ccc} & d_1 \text{ oder } d_2 & \\ \Rightarrow \frac{P_0}{P_1} \cdot C_{00} + C_{01} \cdot \Lambda(z) & \begin{array}{c} > \\ < \end{array} & \frac{P_0}{P_1} \cdot C_{10} + C_{11} \cdot \Lambda(z) \\ & d_0 \text{ oder } d_2 & \end{array}$$

$$\begin{array}{ccc} & d_1 \text{ oder } d_2 & \\ \Rightarrow [C_{01} - C_{11}] \cdot \Lambda(z) & \begin{array}{c} > \\ < \end{array} & \frac{P_0}{P_1} \cdot [C_{10} - C_{00}] \\ & d_0 \text{ oder } d_2 & \end{array} \quad (6.35a)$$

$$\begin{array}{ccc} & d_2 \text{ oder } d_1 & \\ [C_{01} - C_{21}] \cdot \Lambda(z) & \begin{array}{c} > \\ < \end{array} & \frac{P_0}{P_1} \cdot [C_{20} - C_{00}] \\ & d_0 \text{ oder } d_1 & \end{array} \quad (6.35b)$$

$$\begin{array}{ccc} & d_1 \text{ oder } d_0 & \\ [C_{21} - C_{11}] \cdot \Lambda(z) & \begin{array}{c} > \\ < \end{array} & \frac{P_0}{P_1} \cdot [C_{10} - C_{20}] \\ & d_2 \text{ oder } d_0 & \end{array} \quad (6.35c)$$

Gl. (6.35) zeigt, daß die Entscheidungsregel von den relativen Werten der Kostenfaktoren  $C_{ij}$  abhängt, genauer, daß, wenn die Entscheidungsregel entsprechend der Minimierung einer bestimmten Entscheidungskostenfunktion gewählt wird, der unbestimmte Bereich  $(0 \vee 1)$  von der Wahl der assoziierten Kostenfaktoren abhängt.

Damit können die Wahrscheinlichkeitsmassen auf optimale Weise den verschiedenen Behauptungen (Entscheidungen) zugewiesen werden anstatt willkürlich wie in der D-S-Theorie.

Um nun zu der GEP-Kombinationsregel zu gelangen, sei  $U = \{u_1, u_2, \dots, u_n\}$  ein Satz von peripheren Sensorentscheidungen, die nun zur Fusion anstehen. Jede  $u_i$  gehört zu dem Satz  $\{d_0, d_1, d_2\}$ .  $w_{ij}$  seien die Kostenfaktoren, die zur Fusion gehören, wenn für die Behauptung  $d_i$  entschieden wird und die wahre Hypothese  $H_j$  ist. Wenn  $\underline{u} = (u_1, u_2, \dots, u_n)^T$  die Fusionsentscheidung bezeichnet, dann entstehen Gesamtkosten von:

$$C_F = \sum_i \sum_j w_{ij} \cdot P_j \cdot \int_{F_i} dP(\underline{u} / H_j) \quad (6.36)$$

Gl. (6.36) kann unter der Annahme, daß die Entscheidungen der peripheren Sensoren auf jede Hypothese unabhängig bedingt sind, als:

$$\begin{aligned}
C_F &= \sum_i \sum_j w_{ij} \cdot P_j \cdot \int \prod_{F_i, k=1}^N dP(u_k / H_j) \\
&= \sum_i \sum_j w_{ij} \cdot P_j \cdot \prod_{k=1}^N \left[ \int dP(u_k / H_j) \right] \\
C_F &= w_{00} \cdot P_0 \cdot \prod_k \left[ \int_{F_0} dP(u_k / H_0) \right] + w_{10} \cdot P_0 \cdot \prod_k \left[ \int_{F_1} dP(u_k / H_0) \right] \\
&\quad + w_{20} \cdot P_0 \cdot \prod_k \left[ \int_{F_2} dP(u_k / H_0) \right] + w_{01} \cdot P_1 \cdot \prod_k \left[ \int_{F_0} dP(u_k / H_1) \right] \\
&\quad + w_{11} \cdot P_1 \cdot \prod_k \left[ \int_{F_1} dP(u_k / H_1) \right] + w_{21} \cdot P_1 \cdot \prod_k \left[ \int_{F_2} dP(u_k / H_1) \right]
\end{aligned} \tag{6.37}$$

geschrieben werden bzw.:

$$\begin{aligned}
C_F &= \int_{F_0} [w_{00} \cdot P_0 \cdot dP(\underline{u} / H_0) + w_{01} \cdot P_1 \cdot dP(\underline{u} / H_1)] \\
&\quad + \int_{F_1} [w_{10} \cdot P_0 \cdot dP(\underline{u} / H_0) + w_{11} \cdot P_1 \cdot dP(\underline{u} / H_1)] \\
&\quad + \int_{F_2} [w_{20} \cdot P_0 \cdot dP(\underline{u} / H_0) + w_{21} \cdot P_1 \cdot dP(\underline{u} / H_1)]
\end{aligned} \tag{6.38}$$

Die Entscheidungsregel, die die Gesamtkosten minimiert, weist eine besondere Kombination peripherer Entscheidungen  $U$  dem Bereich zu, der den geringsten Integranden aufweist. Analog zu dem Vorgehen der Gl. (6.33), Gl. (6.34) und Gl. (6.35) und unter der Annahme, daß  $w_{ii} = 0$ , d.h. keine Bestrafung für eine korrekte Entscheidung (eine durchaus vernünftige Vorgehensweise in jeder Verarbeitung), und daß  $w_{ij} - w_{2j} > 0$  für jede  $j$ , d.h. daß die Kosten für Unentschlossenheit geringer sind als die für eine nicht korrekte Entscheidung, wird der Test bei der Fusion zu:

$$\Lambda(\underline{u}) \begin{array}{l} > \\ < \end{array} \begin{array}{l} d_1 \text{ oder } d_2 \\ P_0 \cdot \frac{w_{10}}{P_1 \cdot w_{01}} \end{array} \quad (6.39a)$$

$$\Lambda(\underline{u}) \begin{array}{l} > \\ < \end{array} \begin{array}{l} d_2 \text{ oder } d_1 \\ P_0 \cdot \frac{w_{20}}{P_1 \cdot w_{01} - w_{21}} \end{array} \quad (6.39b)$$

$$\Lambda(\underline{u}) \begin{array}{l} > \\ < \end{array} \begin{array}{l} d_1 \text{ oder } d_0 \\ P_0 \cdot \frac{w_{10} - w_{20}}{P_1 \cdot w_{21}} \end{array} \quad (6.39c)$$

mit:

$$\Lambda(\underline{u}) = \frac{dP(\underline{u} / H_1)}{dP(\underline{u} / H_0)} = \frac{dP(u_1 / H_1)}{dP(u_1 / H_0)} \cdot \frac{dP(u_2 / H_1)}{dP(u_2 / H_0)} \cdots \frac{dP(u_N / H_1)}{dP(u_N / H_0)} \quad (6.40)$$

Eine Separation von Gl. (6.40) nach den Teilsätzen solcher Entscheidungen aus dem Satz  $U$ , die eine bestimmte Entscheidung begünstigen, geschieht mit den folgenden Bezeichnungen:

$S_i$ : Satz der Entscheidungen aus  $U$ , die  $d_i (= H_i)$  begünstigen,  $P_{Z_i}$ : Wahrscheinlichkeitsmasse (Zähler), daß Sensor  $i$  Hypothese  $H_1$  für wahr erklärt, wenn  $H_1$  wahr ist,  $P_{N_i}$ : Wahrscheinlichkeitsmasse (Nenner), daß Sensor  $i$  Hypothese  $H_1$  für wahr erklärt, wenn  $H_0$  wahr ist,  $P_{F_i}^0$ ,  $P_{F_i}^1$ : Wahrscheinlichkeitsmassen für Sensor  $i$  assoziiert mit der unklaren (Fuzzy-) Entscheidung (bzw. Nichtentscheidung)  $d_{0 \vee 1}$  (bzw.  $d_2$ ) unter den Hypothesen  $H_0$  bzw.  $H_1$ :

$$\begin{aligned}
\Lambda(\underline{u}) &= \frac{dP(\underline{u} / H_1)}{dP(\underline{u} / H_0)} \\
&= \Lambda(u_1) \cdot \Lambda(u_2) \cdots \Lambda(u_N) \\
&= \frac{dP(u_1 / H_1)}{dP(u_1 / H_0)} \cdot \frac{dP(u_2 / H_1)}{dP(u_2 / H_0)} \cdots \frac{dP(u_N / H_1)}{dP(u_N / H_0)} \\
&= \prod_{i \in S_1} \frac{P_{Z_i}}{P_{N_i}} \cdot \prod_{j \in S_0} \frac{1 - P_{Z_j} - P_{F_j}^1}{1 - P_{N_j} - P_{F_j}^0} \cdot \prod_{k \in S_2} \frac{P_{F_k}^1}{P_{F_k}^0}
\end{aligned} \tag{6.41}$$

Aus den Gl. (6.39-6.41) ist ersichtlich, daß die optimale Entscheidungsregel bei der Fusion ein Likelihood-Ratio-Test (LRT) ist.

Durch Logarithmusbildung über Gl. (6.41):

$$\log(\Lambda(\underline{u})) = \log(\Lambda(u_1)) + \log(\Lambda(u_2)) + \dots + \log(\Lambda(u_N)) \tag{6.42}$$

wird die Berechnung der Verteilung der LR unter den beiden Hypothesen möglich.

Werden die einzelnen Summanden in Gl. (6.42) als unabhängige Zufallsvariablen betrachtet, gilt für die Verteilungsdichte der LR unter den beiden Hypothesen [66]:

$$f(\log(\Lambda(\underline{u}) / H_i)) = f(\log(\Lambda(u_1) / H_i)) * \dots * f(\log(\Lambda(u_N) / H_i)) \tag{6.43}$$

Nach [21] kann die Verteilungsdichtefunktion als Summe von mit den zugehörigen Wahrscheinlichkeiten gewichteten Delta-Funktionen geschrieben werden. Mit dieser Überlegung und:

$$\begin{aligned}
f(\log(\Lambda(u_i) / H_0)) &= f(dP(u_i / H_0)) \\
f(\log(\Lambda(u_i) / H_1)) &= f(dP(u_i / H_1))
\end{aligned} \tag{6.44}$$

wird  $f(\log(\Lambda(u_i) / H_0))$  zu:

$$\begin{aligned}
f\left(\log(\Lambda(u_i) / H_0)\right) &= \left(1 - P_{N_i} - P_{F_i}^0\right) \cdot \mathbf{d}\left(\log(\Lambda(u_i)) - \log\left(\frac{1 - P_{Z_i} - P_{F_i}^1}{1 - P_{N_i} - P_{F_i}^0}\right)\right) \\
&+ P_{F_i}^0 \cdot \mathbf{d}\left(\log(\Lambda(u_i)) - \log\left(\frac{P_{F_i}^1}{P_{F_i}^0}\right)\right) + P_{N_i} \cdot \mathbf{d}\left(\log(\Lambda(u_i)) - \log\left(\frac{P_{Z_i}}{P_{N_i}}\right)\right)
\end{aligned} \tag{6.45}$$

und entsprechend  $f\left(\log(\Lambda(u_i) / H_1)\right)$ :

$$\begin{aligned}
f\left(\log(\Lambda(u_i) / H_1)\right) &= \left(1 - P_{Z_i} - P_{F_i}^1\right) \cdot \mathbf{d}\left(\log(\Lambda(u_i)) - \log\left(\frac{1 - P_{Z_i} - P_{F_i}^1}{1 - P_{N_i} - P_{F_i}^0}\right)\right) \\
&+ P_{F_i}^1 \cdot \mathbf{d}\left(\log(\Lambda(u_i)) - \log\left(\frac{P_{F_i}^1}{P_{F_i}^0}\right)\right) + P_{Z_i} \cdot \mathbf{d}\left(\log(\Lambda(u_i)) - \log\left(\frac{P_{Z_i}}{P_{N_i}}\right)\right)
\end{aligned} \tag{6.46}$$

mit:

$$\mathbf{d}(x) = \text{Kronecker'sche Delta - Funktion} \tag{6.47}$$

D.h. die Verteilung von  $\Lambda(\underline{u})$  unter  $H_0$  ist das Produkt aller möglichen Kombinationen von  $\left[\left(1 - P_{N_i} - P_{F_i}^0\right), P_{F_i}^0, P_{N_i}\right]$  entsprechend ihrer Abszissenposition. Entsprechendes gilt für  $\Lambda(u)$  unter  $H_1$ .

Die Fusion wird ausgeführt über die Nutzung der zugehörigen Schwellwerte aus Gl. (6.39). In diesem Fall werden die mit jeder Entscheidung verbundenen Wahrscheinlichkeitsmassen entsprechend zu dem Schwellwert und ihren Abszissenpositionen kombiniert. Die Kombinationsregel beinhaltet die paarweise Multiplikation der Wahrscheinlichkeitsmassen entsprechend Tabelle 6.5, aber die Massenassoziation wird nicht willkürlich durchgeführt, indem die Masse, die einem Konflikt entspricht, zur Renormalisierung der Wahrscheinlichkeitsmassen wie in der D-S benutzt wird. In der GEP werden die Massen über Schwellwerte optimal assoziiert, entweder so, daß bestimmte Kosten (Gl. (6.38)) minimiert werden, oder so, daß die Detektionswahrscheinlichkeit für Falschalarme und Unentschiedenheitswahrscheinlichkeiten maximiert wird (verallgemeinerter Neyman-Pearson-Test [20]).

Die Wahrscheinlichkeiten in Tabelle 6.5 sind auf jede Hypothese  $H_i; i = 0,1$  bedingt. Damit ist jede  $m_j^i; j = 1,2$  in Tabelle 6.5 eine bedingte Wahrscheinlichkeit für  $i = 0,1$ . Jedes Produkt in Tabelle 6.5 ist eine Wahrscheinlichkeitsmasse auf der Koordinatenachse des LRT mit der Abszisse  $\frac{m_j^1(d)}{m_j^0(d)}$  für jede  $d = d_0, d_1, d_2$ . Befundkombination unter jeder Hypothese wird ausgeführt durch Summation der Wahrscheinlichkeiten in Tabelle 6.5, deren Abszissen in spezielle Intervalle fallen, die entweder durch ein Optimalitätskriterium oder eine bestimmte gewünschte Performanz spezifiziert werden. Für jede  $d = d_0, d_1, d_2$  wird die Befundkombination unter jeder Hypothese  $H_i; i = 0,1$  entsprechend der Schwellwertregel:

$$m_1^i(d_k) \cdot m_2^i(d_m) \Rightarrow \text{Entscheidung } d_j \text{ wenn } \frac{m_1^1(d_k) \cdot m_2^1(d_m)}{m_1^0(d_k) \cdot m_2^0(d_m)} \in F_j \quad (6.48)$$

bzw.:

$$m_1^i(d_k) \cdot m_2^i(d_m) \Rightarrow \text{Entscheidung } d_j \text{ wenn } t_j < \frac{m_1^1(d_k) \cdot m_2^1(d_m)}{m_1^0(d_k) \cdot m_2^0(d_m)} < t_{j+1} \quad (6.49)$$

für alle  $k, m$  und  $j$ , wobei  $t_j$  die Schwellwerte des LRTs bezeichnet, die mit den verschiedenen Entscheidungen verbunden sind.

			$S_2$	
		$m_2^i(d_0)$	$m_2^i(d_1)$	$m_2^i(d_2)$
	$m_1^i(d_0)$	$m_1^i(d_0) \cdot m_2^i(d_0)$	$m_1^i(d_0) \cdot m_2^i(d_1)$	$m_1^i(d_0) \cdot m_2^i(d_2)$
$S_1$	$m_1^i(d_1)$	$m_1^i(d_1) \cdot m_2^i(d_0)$	$m_1^i(d_1) \cdot m_2^i(d_1)$	$m_1^i(d_1) \cdot m_2^i(d_2)$
	$m_1^i(d_2)$	$m_1^i(d_2) \cdot m_2^i(d_0)$	$m_1^i(d_2) \cdot m_2^i(d_1)$	$m_1^i(d_2) \cdot m_2^i(d_2)$

Tabelle 6.5: GEP-Verbundkombinationsregel, [67]

[67] liefert eine Erweiterung der Kombinationsregeln auf mehrfache Hypothesen und Formulierungen für mehrere Optimierungskriterien.

## 6.6 Heuristische Methoden

Auf der Entscheidungsebene gibt es eine Reihe von alternativen Methoden, die für die Fusion von Identitätsdaten sinnvolle Ansätze liefern. Diese Alternativen basieren auf Techniken, die i.A. genutzt werden, Konsens zwischen menschlichen Entscheidungsträgern herbeizuführen.

Die Idee dabei ist recht einfach: Das Identitätsfusionsproblem wird so behandelt, als ob eine Gruppe von Menschen davon betroffen wäre, eine Entscheidung zu treffen. Jeder Mensch ist wie ein Sensor. Er sammelt Daten, wählt aus oder bewertet  $n$  alternative Entscheidungen (Hypothesen). Damit besteht der Input aus einem Satz von Beobachtungen entweder in einem Hard-Decision-Format, bei dem die Sensoren nur eine Aussage treffen (z.B. Identitätsfeststellung), oder einem Soft-Decision-Format, bei dem die Sensoren eine vielleicht mit Konfidenzfaktoren versehene gewichtete Liste liefern.

Viele Techniken zur Gruppenentscheidungsfindung können zur Identitätsfusion genutzt werden. [27] gibt einen Überblick über diese Techniken mit dem Fokus auf das Problem der Auswahl von Forschungsprojekten. Zu den für die Identitätsfusion anwendbaren Techniken gehören Voting-, Scoring- und Ordinal-Ranking-Techniken, Q-Sort-Methoden und paarweise Wertung. Im folgenden Abschnitt wird jede Methode kurz vorgestellt.

Voting-Methoden gehen das Problem mit einem demokratischen Prozeß an. Die Hard-Decisions von  $N$  Sensoren werden einfach wie Wahlstimmen behandelt und das Ergebnis entsprechend der Mehrheit der Stimmen festgelegt. Angenommen sei, daß  $M$  Sensoren ein Phänomen beobachten und daß jeder Sensor eine Identitätsfeststellung aus einer Auswahl von  $n$  Hypothesen trifft. Für jede mögliche Hypothese oder Identitätsfeststellung  $H_i$  wird die Anzahl der Sensoren, die diese Hypothese für wahr erklären, aufsummiert zu  $l_i$ . Die Verbundidentitätsfeststellung ist dann einfach die Hypothese  $H_k$ , für die  $l_k$  maximal ist. Gewichtete Votierungsschemata (z.B. Sensor  $i$  hat zwei Stimmen, während Sensor  $j$  nur eine hat), werden zur Berücksichtigung unterschiedlicher Sensorperformanz verwendet.

Scoring-Modelle [12] bieten einen anderen Mechanismus zur Bestimmung einer Verbundidentitätsfeststellung. Dabei weist jeder Sensor  $k$  allen  $n$  möglichen Hypothesen einen Wert  $g_{ik}$  zu.  $g_{ik}$  ist der Vertrauensfaktor, der der  $i$ -ten Hypothese vom  $k$ -ten Sensor zugeordnet wird. Typischerweise wird eine Skalierung  $\{0 < g < 1\}$  oder  $\{0 < g < 10\}$  benutzt, wobei ein hoher Wert bedeutet, daß der Annahme, daß die Hypothese wahr ist, großes Vertrauen entgegengebracht wird. Ein Scoring-Modell berechnet die Summe:



$$S(\mathbf{g}_i) = \frac{1}{c} \cdot \sum_{j=1}^M w_j \cdot \mathbf{g}_{ji} \quad (6.50)$$

mit  $M$  der Gesamtzahl der Sensoren,  $w_j$  einer A-Priori-Wichtung der  $j$ -ten Hypothese,  $\mathbf{g}_{ji}$  der vom  $i$ -ten Sensor der  $j$ -ten Hypothese zugewiesenen Punktezahl und  $c$  einer Normalisierungskonstante.  $S(\mathbf{g}_i)$  bezeichnet die der  $i$ -ten Hypothese durch  $M$  Sensoren zugewiesene Punktezahl. Eine Entscheidungslogik wählt dann die Hypothese mit der größten Punktezahl aus.

Scoring- wie Voting-Modelle sind i.A. rechnerisch effizient und aufgrund ihrer einfachen Formulierung leicht zu programmieren.

Andere Entscheidungsmodelle sind u.a. die „Ordinal Ranking“-Techniken [10], Q-Sort-Methoden [28, 65] und paarweise Wertung [65]. Diese Techniken modellieren Methoden zur Konsensbildung, bei denen ein iterativer Ansatz zum Tragen kommt, bei dem eine Gruppenauswertung erfolgt, die einer Reevaluierung vorausgeht, die auf der Ungleichheit zwischen den menschlichen Entscheidern basiert.

[11] gibt ein Beispiel für die Anwendung einer Scoring-Methode. Dabei geht es um die Bewertung der Sprachqualität in einer VoIP (Voice over IP) -Umgebung.

Die Sprachqualität kann auf zwei Wegen getestet werden: subjektiv und objektiv. Menschen führen subjektive Sprach-Tests durch, während Rechner, die weniger wahrscheinlich durch Kompressions-Methoden getäuscht werden können als das menschliche Ohr, objektive Sprach-Tests ausführen können.

Codecs werden auf der Basis subjektiver Messungen der Sprachqualität entwickelt und optimiert. Objektive Standard-Methoden wie „Total Harmonic Distortion“ (THD) und Signal-to-Noise-Verhältnisse korrelieren nicht gut mit der menschlichen Wahrnehmung von Sprachqualität. Dabei ist die Sprachqualität nicht nur bei VoIP ein wichtiges Kriterium zur Einsetzbarkeit einer solchen Technik.

Eine verbreitete subjektive Methode zur Quantifizierung der Performanz eines Sprach-Codecs ist der „Mean Opinion Score“ (MOS). MOS-Tests werden mit einer Gruppe von Hörern ausgeführt. Weil die Sprachqualität und Geräusche i.A. nur subjektiv von den Probanden bewertet werden können, ist es wichtig, eine größere Bandbreite von Hörern und Testmaterial zu nut-

zen. Die Hörer geben jeder Probe eine Note von 1 (schlecht) bis 5 (hervorragend). Die Noten werden dann gemittelt, um den MOS-Wert zu erhalten.

MOS-Tests werden im Umfeld von VoIP auch genutzt, das Verhalten von Codecs unter variierenden Bedingungen zu testen. Zu diesen Bedingungen gehören z.B. unterschiedliche Hintergrundgeräuschpegel, Mehrfachkodierungen und -dekodierungen.

Ein Beispiel für „Ordinal Ranking“, wie in [10] beschrieben, soll die heuristischen Methoden veranschaulichen. Das Beispiel bezieht sich auf die Auswahl von R&D-Projekten zur Förderung bei (realistischerweise) begrenztem Budget. Um die beschriebene Methode auf ein automatisiertes Sensordatenfusionsproblem anwenden zu können, wären noch manche Überlegungen notwendig. Trotzdem ist sie, wie auch die anderen erwähnten Methoden, als potentielle Methode zur Erreichung einer Verbundidentitätsfeststellung beachtenswert.

Angenommen sei ein Gesamtbudget von DM 240.000,00, welches für einen Satz von 10 vorgeschlagenen Projekten verwendet werden kann, deren Einzelkosten  $c_i / DM$  wie folgt veranschlagt werden:

$$\begin{aligned}
 c_1 &= 50.000,00, & c_2 &= 60.000,00, & c_3 &= 10.000,00 \\
 c_4 &= 70.000,00, & c_5 &= 30.000,00, & c_6 &= 30.000,00 \\
 c_7 &= 20.000,00, & c_8 &= 40.000,00, & c_9 &= 50.000,00 \\
 c_{10} &= 40.000,00
 \end{aligned}
 \tag{6.51}$$

Ein Komitee z.B. habe nun eine (relative) Ranking-Liste für jedes qualitative Kriterium (z.B. Marktfähigkeit, Unterstützung durch Geschäftsleitung, Dringlichkeit usw.) erstellt:

$$\begin{aligned}
 \textit{Kriterium 1):} & \ 10,4,9,3,5,7,|2,6,1,8 \\
 \textit{Kriterium 2):} & \ 3,4,10,8,7,2,|1,5,6,9 \\
 \textit{Kriterium 3):} & \ 1,3,5,7,2,6,10,|9,8,4 \\
 \textit{Kriterium 4):} & \ 10,6,4,3,2,5,|1,9,7,8 \\
 \textit{Kriterium 5):} & \ 1,4,9,10,3,|2,5,6,8,7
 \end{aligned}
 \tag{6.52}$$

Das Pipe-Zeichen (|) deutet an, wo die Finanzierungsgrenze bei dem gegebenen Budget liegt, d.h. z.B. für *Kriterium 1*), daß die ersten 6 Projekte - 10,4,9,3,5,7 - den förderbaren Satz von Projekten für dieses Kriterium bilden:

$$\begin{aligned}
f_1 &= \{10,4,9,3,5,7\} \\
f_2 &= \{3,4,10,8,7,2\} \\
f_3 &= \{1,3,5,7,2,6,10\} \\
f_4 &= \{10,6,4,3,2,5\} \\
f_5 &= \{1,4,9,10,3\}
\end{aligned} \tag{6.53}$$

Weiterhin sei angenommen, daß die 5 Kriterien entsprechend ihrer Wertigkeit gewichtet wurden, d.h. *Kriterium 1)* ist wichtiger als *Kriterium 2)*, *Kriterium 2)* ist wichtiger als *Kriterium 3)* usw.

In einem ersten Verarbeitungsschritt wird die Schnittmenge der Kriterien gebildet:

$$\bigcap_{i=1}^5 f_i = \{3,10\} \tag{6.54}$$

Der durch die beiden Projekte 3 und 10 verbrauchte Anteil des Gesamtbudgets beträgt  $c_3 + c_{10} = 55.000,00$ .

Der nächste Schritt ist dann die Variation bei nur 4 Kriterien.  $f_1 \cap f_2 \cap f_3 \cap f_4 = \{3,10\}$  ergibt keine Änderung genau wie  $f_1 \cap f_2 \cap f_3 \cap f_5 = \{3,10\}$ .  $f_1 \cap f_2 \cap f_4 \cap f_5 = \{3,10,4\}$  addiert Projekt 4 zur Liste der zu fördernden Projekte. Das dann verbrauchte Budget ist  $c_3 + c_{10} + c_4 = 120.000,00$ .  $f_1 \cap f_3 \cap f_4 \cap f_5 = \{3,10\}$  ändert wieder nichts, ebenso wie  $f_2 \cap f_3 \cap f_4 \cap f_5 = \{3,10\}$ .

Beim Übergang auf 3 Kriterien ergibt sich  $f_1 \cap f_2 \cap f_3 = \{3,10,4,7\}$ , wodurch Projekt 7 in die Liste kommt und sich der Budget-Betrag zu  $c_3 + c_{10} + c_4 + c_7 = 140.000,00$  ergibt.  $f_1 \cap f_2 \cap f_4 = \{3,10,4\}$  und  $f_1 \cap f_2 \cap f_5 = \{3,10,4\}$  bewirken wiederum keine Änderung. Durch  $f_1 \cap f_3 \cap f_4 = \{3,10,5\}$  gelangt Projekt 5 in die Liste und die Kosten klettern auf  $c_3 + c_{10} + c_4 + c_7 + c_5 = 170.000,00$ .  $f_1 \cap f_3 \cap f_5 = \{3,10\}$  und  $f_1 \cap f_4 \cap f_5 = \{3,10,4\}$  ergeben keine Veränderung, jedoch  $f_2 \cap f_3 \cap f_4 = \{3,10,2\}$ . Dadurch erhöht sich der Budget-Betrag auf  $c_3 + c_{10} + c_4 + c_7 + c_5 + c_2 = 230.000,00$ . Da durch den Rest-Betrag kein

weiteres Projekt vollständig gefördert werden könnte, ist die Iteration beendet und der „beste“ Satz zu fördernder Projekte nach der Cook-Seifford-Methode besteht aus  $\{2,3,4,5,7,10\}$ .

I. A. gibt es bei aller Wissenschaftlichkeit der angesprochenen Ansätze und ihrer teilweise erfolgreichen Anwendung jedoch erhebliche Probleme bei ihrer Umsetzung. Dies liegt zum Teil daran, daß die Modellansätze die reale Welt zu sehr vereinfacht sehen und tatsächlich ablaufende Entscheidungsprozesse simplifizierend darstellen. Die sog. „Management Science Models“ scheinen davon auszugehen, daß es einen einzelnen Entscheidungsträger in einer geordneten Umgebung gibt, während tatsächlich viele Entscheidungsmacher und Beeinflusser in einem dynamischen Organisationsfeld zusammenarbeiten (müssen). Es gibt auch nie perfekte und vollständige Information über die Parameter, sondern immer nur einen kleinen Ausschnitt. Auch sind die Ziele nur im Idealfall ausreichend bekannt und unveränderlich. In der realen Welt sind die sog. Experten oder auch Entscheidungsträger oft nicht in der Lage oder auch unwillig, die möglichen Konsequenzen einer Entscheidung zu artikulieren. Projekte (s. z.B. obiges Beispiel nach der Cook-Seifford-Methode) sind meist sowohl technisch als auch ökonomisch hochgradig voneinander abhängig. Diese Aufzählung einiger Unzulänglichkeiten ließe sich ohne größere Schwierigkeiten fortführen. Sie zeigt die Fehlerhaftigkeit der angesprochenen Methoden. Diese werden dadurch jedoch nicht hinfällig, da sie ihre Einsetzbarkeit erfolgreich bewiesen haben. Die Aufzählung weist darauf hin, daß bei der Anwendung das Ergebnis nur so gut sein kann wie die Modellierung.

## 7. Wissensbasierte Ansätze

### 7.1 Einführung in die künstliche Intelligenz

In den vorherigen Kapiteln wurden Techniken und Methoden zur Fusion multisensorieller Daten beschrieben, die dazu dienen, den Ort, die Kinematik, Attribute oder die Identität von Gegebenheiten wie Plattformen, Strahlern, geographischen Charakteristika, Mineralvorkommen usw. bestimmen zu helfen. Die spezifischen gesuchten Charakteristika hängen von der jeweiligen Anwendung ab, für die Fusionsalgorithmen zum Einsatz kommen. Beispiele für einige Anwendungen und die entsprechenden Inferenzen sind in Tabelle 7.1 zusammengefaßt. Dazu gehören:

1. Taktische militärische Situationseinschätzung zur Bestimmung von Ort, Identität und Verhalten militärischer Betrachtungseinheiten.
2. Militärische Bedrohungsanalyse zur Identifikation und Ortsbestimmung feindlicher Waffen und Einheiten und zur Identifikation feindlicher Aktivitäten, die eine Bedrohung der eigenen Kräfte darstellen.
3. Automatisierte Überwachung komplexer Einrichtungen und Anlagen (z.B. AKW), die den Status der eingesetzten Geräte kontrolliert.
4. Medizinische Diagnose- und Hilfssysteme, die anomale biologische Bedingungen identifizieren und versuchen, diese zu analysieren und dadurch die Ursache der Symptome zu erkennen.
5. Multisensorielle Fernerkundungssysteme, die natürliche Ressourcen wie Getreide, Wälder, Mineralvorkommen und Terraineigenschaften lokalisieren, identifizieren und überwachen.

Basisinferenzen für jede dieser Anwendungen sind in der zweiten Spalte von Tabelle 7.1 angegeben. Kapitel 2 bis 6 dieses Textes beschreiben eine Reihe von Methoden zur Durchführung dieser Inferenzen. Techniken zur Datenassoziation, Estimation und Identitätsbestimmung werden in diesen Kapiteln vorgestellt. Diese Techniken sind vor allem numerischer Art, d.h. zu ihnen gehört die Prozessierung parametrischer Daten mit numerischen Algorithmen zur Estimation von Parametern oder Identitäten.

Für jede der in Tabelle 7.1 gezeigten Applikationen gibt es höhere Inferenzebenen, die im Normalfall von menschlichen Analysten erreicht werden. Z.B. ist es die Aufgabe militärischer Situationsanalysten, die Beziehungen zwischen Objekten zu bestimmen, komplexe Betrachtungen

tungseinheiten (z.B. Zustände von Strahlern, Plattformen usw.) zu identifizieren und zu charakterisieren und die Bedeutung einer Gefechtsordnungsdatenbasis im Kontext von Zeit, Raum, Nähe zur politischen Grenze und dem natürlichen Umfeld (Wetter, Terrain usw.) zu interpretieren.

<b>Fusionsanwendungen</b>	<b>Basisinferenzen</b>	<b>Höherwertige Inferenzen</b>	<b>Schlußarten</b>
Taktische Situationseinschätzung (Level 2)	Ort, Identität von Objekten	Identität komplexer Betrachtungseinheiten/ Objekte; Beziehung zwischen Objekten (Zeit, Funktion, usw.); Kontextinterpretation	Estimation; Örtliche/zeitliche Schlußfolgerungen; Aufstellung funktionaler Beziehungen; Hierarchisch; Kontextschlußfolgerung
Bedrohungseinschätzung (Level 3)	Ort/Identifikation von Objekten; Positionsprädiktion	Identifikation von Bedrohungen; Prädiktion der Absicht; Analyse der Bedrohungsimplicationen; Abschätzung von Fähigkeiten	Mustersuche; Prädiktion; Entwicklung von Szenarien; Interpretation; Ursache/Wirkung
Komplexe Aus-rüstungsdiag-nose	Estimation von Zu-standsparemtern; Lokalisierung/Identifikation von Fehlern; Identifikation anormaler Bedingungen	Aufstellung von Ursache-Wirkung-Beziehungen; Entwicklung hierarchischer Beziehungen; Fortschrittsanalyse; Empfehlung diagnostischer Tests; Empfehlung von Reparaturmaßnahmen	Analyse von Hierarchien; Ursache-Wirkung-Analyse; Deduktion/Induktion
Medizinische Diagnose	Bestimmung entscheidender biologischer Parameter; Einschätzung von Symptomen;	Analyse von Beziehungen zwischen Symptomen; Empfehlung diagnostischer Tests; Iden-	Mustererkennung; Deduktion/Induktion; Ursache-Wirkung-Analyse

	Identifikation anormaler Parameter; Lokalisierung von Verletzungen	tifikation von Krankheiten	
Fernerkundung	Ort/Identifikation von Getreide, Mineralien, geographischen Gegebenheiten; Lokalisierung geographisch beschränkter Gegebenheiten; Identifikation von Eigenschaften und Objekten	Identität ungewöhnlicher Phänomene (z.B. krankes Getreide); Bestimmung von Beziehungen zwischen geographischen Eigenschaften; Interpretation von Daten	Mustererkennung; Räumliche/zeitliche Schlußfolgerungen; Kontextanalyse

Tabelle 7.1: Beispiele für Datenfusionsinferenzen

Ähnlich kann ein Techniker Daten über Equipmentfehler und Performanz aufnehmen, um damit Probleme zu diagnostizieren, Entwicklungs- oder Fabrikationsfehler zu identifizieren und Vorsorge- und Reparaturmaßnahmen einzuleiten. Andere Beispiele für solche höheren Inferenzebenen gehen aus der dritten Spalte von Tabelle 7.1 hervor. Diese erfordern normalerweise gewisse Formen der Erkennung und Bewertung durch Menschen. Zu den Bewertungstypen gehören:

- Mustererkennung mit unsicheren, nicht vollständigen und widersprüchlichen Daten
- Räumliche und zeitliche Bewertung
- Aufstellung von Ursache-Wirkung-Beziehungen
- Voraussage zukünftiger Ereignisse und Aktivitäten
- Planung
- Induktion (Konzipierung aufgrund von Beispielen spezifischer Fälle)
- Deduktion (Bewertung allgemeiner Prinzipien auf spezifische Schlußfolgerungen über einen besonderen Fall)
- Abduktion (Aufstellung von Parallelen oder Analogien)
- Lernen

Diese und viele andere kognitive Fähigkeiten werden von menschlichen Experten auf der Grundlage multisensorieller Daten genutzt. Die Frage ist nur, ob der Mensch auch bei diesen Aufgaben entbehrlich oder entbehrlicher, oder - positiv ausgedrückt - entlastet werden kann. Diese Grundfrage adressiert die Forschung auf dem Gebiet der artifiziellen bzw. künstlichen Intelligenz (AI). AI kann als Forschungsgebiet betrachtet werden, das sich mit der Frage beschäftigt, wie Computer bzw. Maschinen dazu gebracht werden können, Funktionen auszuführen, die normalerweise mit Menschen oder Tieren assoziiert werden.

<b>Menschliches/tierisches Verhalten</b>	<b>AI-Forschungsgebiet</b>
Absichtsvolle/unabhängige Aktion	Robotik
Erkennen/Bewerten	Experten- bzw. wissensbasierte System
Sehen	Computervision
Sprachliche Kommunikation	Sprachverarbeitung
Lernen	Computergestütztes Lernen

Für nahezu jeden Aspekt menschlichen Verhaltens gibt es ein entsprechendes AI-Forschungsgebiet [45]. Auf Probleme der AI treffen auch die Forscher und Entwickler in eher traditionellen Gebieten wie Computerwissenschaften, Psychologie, Mathematik, Biologie, Biophysik und vielen anderen. Die AI kann alternativ als Laboratorium betrachtet werden, das Einsichten darüber vermittelt, wie Menschen denken und handeln. Z.B. vergrößert der Versuch, Computern menschliche Sprache beizubringen, das Wissen darüber, wie Menschen ihre Sprache lernen bzw. wie sie sie nicht lernen.

Eine Dauerbeschwerde der AI-Forschungsgemeinschaft ist der sich ständig weiterverschiebende Horizont. In den frühen 70er Jahren war es z.B. für einen Computer ziemlich schwierig, symbolische Berechnungen durchzuführen. Der Rechner konnte zwar eine Funktion wie  $f(x) = e^x$  relativ einfach numerisch integrieren, symbolisch jedoch nicht. Heute sind solche Berechnungen schon auf Taschenrechnern implementiert. Symbolische Berechnungen stellen damit keine Herausforderung mehr für die AI dar. Trotz solcher Erfolge der AI konnten echte menschliche Fähigkeiten noch nicht erreicht werden [16].

Die Anwendbarkeit von Teilen der AI auf Problemstellungen der multisensoriellen Datenfusion wird in [27] zusammengefaßt.

Drei Gebiete sind besonders wichtig:



1. Experten-Systeme,
2. Natural Language Processing (NLP) und
3. Computer-Vision bzw. Mustererkennung.

Dieses Kapitel konzentriert sich auf Expertensysteme.

## 7.2 Expertensystemkonzept

Bild 7.1 zeigt das vereinfachte Konzept eines Computerprogramms für ein Expertensystem.

Die Struktur umfaßt vier logische Teile:

1. Wissensbasis: Fakten, Algorithmen, Darstellung von Heuristika
2. Globale Datenbasis: Dynamische Daten
3. Steuerungsstruktur („Inference Engine“)
4. Benutzerinterface

Die Steuerungsstruktur nutzt Eingabedaten und Fakten und durchsucht die Wissensbasis, um etwaige Schlußfolgerungen aufstellen zu können.

Die Wissensbasis enthält die Informationen, die die Expertise des Systems darstellen. Wissen kann dabei durch mehrere Mechanismen dargestellt werden:

1. Produktionsregeln der Art: If (Befund für X) Then Do Y, wobei Y bedeuten kann: Durchführung einer Berechnung, Aktualisierung einer Datenbasis usw.
2. Semantische Netze sind graphische Darstellungen der Beziehungen zwischen allgemeinen Objekten und spezifischeren Ausführungen eines Objekts (z.B. allgemeines Objekt „Auto“, spezifische Ausführung „BMW“, „Mercedes“ usw.)
3. Sog. Frames sind Darstellungen von Objekten und Klassen von Objekten durch strukturierte Datenrecords
4. Scripts nutzen das Konzept eines Theaterstücks (Drehbuch) zur Beschreibung von Situationen und Ereignissen

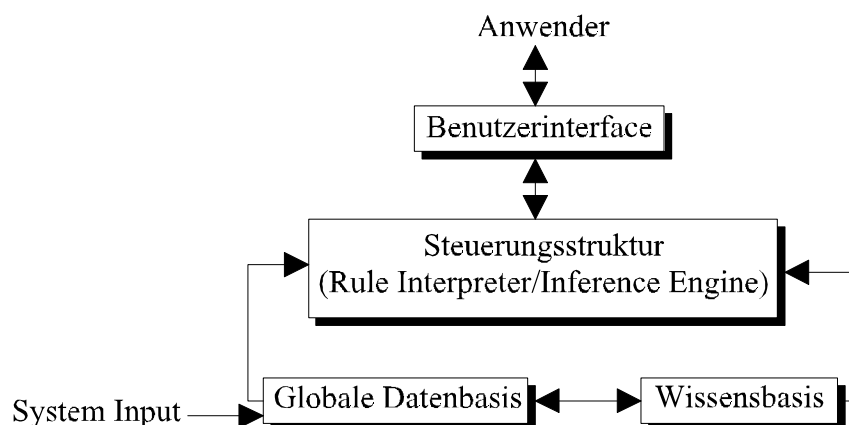


Bild 7.1: Struktur eines Expertensystems

Für den Inferenzprozeß in einem Expertensystem wird eine von zwei Grundstrategien genutzt: „Backward Chaining“ verwendet einen logischen Ansatz, der zu bestimmen versucht, ob Daten gefunden werden können, die eine angenommene Schlußfolgerung unterstützen oder sogar verifizieren. Der „Backward Chaining“-Ansatz stammt aus der Programmiersprache PROLOG. Alternativ dazu beginnt der „Forward Chaining“-Ansatz mit Daten und untersucht diese darauf, ob eine Schlußfolgerung aus diesen gezogen werden kann.

Die primären Unterschiede zwischen Expertensystemen und normalen Computerprogrammen sind zweifach. Zunächst separiert ein Expertensystem recht willkürlich zwischen Steuerprozeß und Algorithmen der Wissensbasis. Gewöhnliche Computerprogramme tendieren dazu, die Programmsteuerung (Logik) mit den problemspezifischen Algorithmen zu vermischen. Dies ist dann effizient, wenn alle logischen Pfade bekannt und feststehend sind. Der Ansatz ist jedoch dann unzureichend, wenn nicht alle Verzweigungen im voraus bekannt sind bzw. die Anzahl der möglichen Verzweigungen sehr groß ist (potentiell unbegrenzt). Ein Vorteil eines Expertensystems ist, daß die Wissensbasis relativ leicht modifiziert werden kann ohne das ganze System umzuprogrammieren. Mit der Vergrößerung der Erfahrungen wächst auch das System hin zu einer immer komplexeren Struktur.

Ein zweiter Unterschied zwischen normalem Computerprogramm und Expertensystem liegt in der dynamischen und nicht erschöpfenden Suche durch die Wissensbasis. Das Programm des Expertensystems sucht nach einer unterstützenswerten Inferenz, durchsucht die Wissensbasis jedoch nicht erschöpfend, d.h. ein Expertensystem findet eine Antwort, aber nicht notwendigerweise die einzige. Tatsächlich kann die Schlußfolgerung, abhängig von der Reihenfolge, mit der die Daten eingegeben wurden, differieren. Diese Eigenschaft von Expertensystemen macht es schwierig, sie zu bewerten.

### 7.3 Inferenzprozeß

Der von Expertensystemen verwendete Inferenzprozeß ist konzeptionell in Bild 7.2 dargestellt. Der iterative Prozeß beginnt mit einem Anfangsdatensatz (Eingangsdaten des Expertensystems) und der Regeln, Frames, Scripts und semantische Netze umfassenden Wissensbasis. Der Inferenzprozeß nutzt den A-Priori-Datensatz und durchsucht den gesamten Regelsatz (Rule Base), um anwendbare Regeln zu identifizieren. Eine Regel ist dann anwendbar, wenn ihre vorstehenden Bedingungen erfüllt sind. Der Prozeß des Auffindens anwendbarer Regeln umfaßt sowohl einen Suchprozeß als auch Mustererkennungsfähigkeiten.

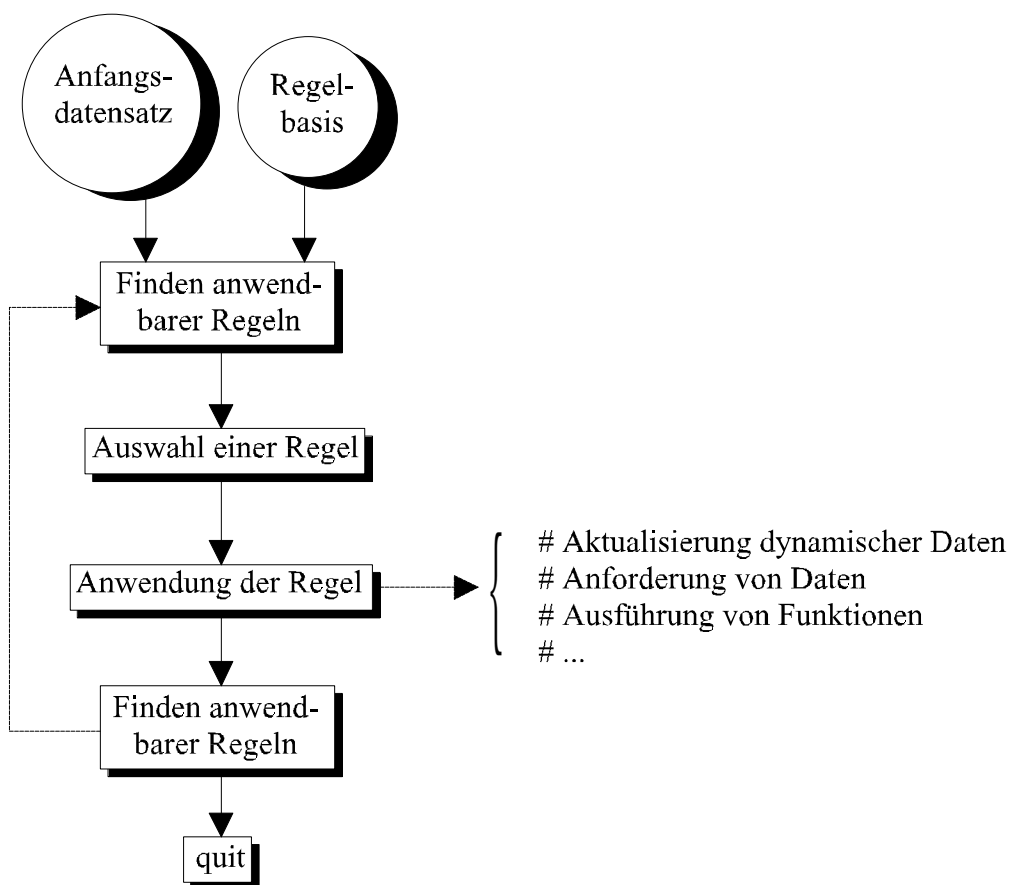


Bild 7.2: Inferenzprozeß eines Expertensystems

Nach der Identifizierung einer oder mehrerer anwendbarer Regeln muß die Steuerungsstruktur eine Regel zur Ausführung auswählen. Diese Auswahl ist kritisch, da der fortgehende Prozeß auf eine Schlußfolgerung hin davon abhängt, welche Regel ausgeführt wird. Im Gegensatz zu normalen Computerprogrammen können nicht einfach alle anwendbaren Regeln ausgeführt

werden, da, sobald nur eine Regel verarbeitet wird, die dynamische Datenbasis modifiziert wird. Als Ergebnis davon ändert sich der anwendbare Satz von Regeln. Die Steuerungsstruktur muß die originale komplette Wissensbasis durchsuchen, um einen neuen Satz anwendbarer Regeln zu finden. Der Inferenzprozeß verläuft weiterhin iterativ, bis eines von zwei Ereignissen eintritt: 1) Eine Schlußfolgerung wird erreicht, die eine letzte Regel zur Ausführung bringt und die Steuerungsstruktur dazu bringt, den Prozeß zu verlassen, oder 2) im Verlauf des Suchprozesses können keine anwendbaren Regeln gefunden werden. Ergebnis 2) führt dazu, daß das Expertensystem seine Suche aufgibt und erklärt, daß keine Schlußfolgerung gezogen werden konnte oder daß das System zusätzliche Daten anfordert.

Die Regelauswahl aus mehreren anwendbaren Regeln (Conflict Resolution) kann eine oder mehrere Vorgehensweisen verwenden. Dazu gehören Refraktion, Aktuation, Regelanordnung, Neuheit, Spezifität und Zufallswahl. Im folgenden wird jede dieser Strategien kurz zusammengefaßt.

1. Refraktion: Mehrfachverwendungen derselben Regel werden durch eine Markierung einer verwendeten Regel vermieden, so daß diese bei späteren Suchen in der Wissensbasis nicht mehr zur Ausführung kommt.
2. Aktuation: Die dynamischen Daten (z.B. im Arbeitsspeicher) werden in Übereinstimmung mit dem erkannten Wert gewichtet. Diese Wichtungen werden bei der Priorisierung konkurrierender Regeln genutzt (die Regel, die die wichtigsten Daten umfaßt, wird gewählt).
3. Regelanordnung: Die Regeln einer Wissensbasis können A-Priori gewichtet werden. Konkurrierende Regeln werden aufgrund ihrer relativen A-Priori-Gewichtung ausgewählt.
4. Neuheit: Ankommende Daten können invers proportional der Zeit, zu der sie empfangen werden, gewichtet werden. Neuere Daten bekommen damit ein stärkeres Gewicht als alte.
5. Spezifität: Regeln, die mehr Bedingungen erfüllen müssen, werden als spezifischer angesehen und daher wahrscheinlicher zu einer spezifischen Inferenz zu führen.
6. Zufallswahl: Wenn keine andere Technik zur Lösung des Konflikts zwischen konkurrierenden Regeln führt, was in einem Suchprozeß durchaus vorkommen kann, dann wird eine Regel zufällig ausgewählt.

## 7.4 Wissensdarstellung

In Tabelle 7.2 wird eine Zusammenfassung der Wissensdarstellungstechniken gegeben. Für jede dieser Techniken liefert die Tabelle eine kurze Definition oder Beschreibung, faßt die Formulierung zusammen und weist auf das Anwendungsgebiet hin.

Die vielleicht am häufigsten genutzte Darstellungsform ist die von Produktionsregeln. Regeln verwenden eine von zwei Formen: Entweder die Behauptung von Ursache-Wirkungs-Beziehungen (Produktionsregeln) oder die Schlußfolgerung von Konsequenz auf Ursache (logische Regeln). Ein eher triviales Beispiel für eine Produktionsregel ist: IF: Die Benzinanzeige steht auf null, und der Motor des Autos ist nicht zu starten; THEN: Es besteht die dringende Vermutung (z.B. mit einem Maß von 0.99), daß Benzin nachgefüllt werden muß.

Regeln können sowohl bei der Beschreibung von Ursache als auch der Wirkung Unsicherheit miteinbeziehen. Regeln können entwickelt werden, um viele verschiedene Applikationen zu beschreiben. Eine Regel-basierte Darstellung ist jedoch besonders in Bereichen anzuwenden, die durch eine lose gekoppelte Ansammlung von Fakten charakterisiert werden. Große Expertensysteme können es erforderlich machen, hunderte oder tausende Regeln aufzustellen und einzubeziehen.

Das Programm XCON [75] hat etwa 10000 Regeln und „weiß“ die Eigenschaften von mehreren hundert Komponententypen für VAX-Computer. Das von der Digital Equipment Corporation (DEC) und der Carnegie-Mellon-Universität entwickelte Programm „handelt“ routinemäßig Aufträge, die 100 bis 200 Komponenten umfassen, ab. Es ist repräsentativ für viele ähnliche Systeme, deren Einsatzgebiet vor allem in Fabrikationsprozessen liegt. XCON's Hauptgebiet sind Systemkomponenten für Computer. Wenn eine Firma z.B. einen großen Rechner kauft, kauft sie damit CPU(en), Memory, Terminals, Festplatten, Bandlaufwerke, verschiedene Peripheriecontroller und vieles mehr. Alle diese Komponenten müssen so eingebaut werden, daß sie zueinander passen und funktionieren. Diese Aufgabe wird Systemkonfiguration genannt und ist häufig sehr mühsam. XCON kann diese Aufgabe für den Fall von VAX-Computern erledigen. Das Nachfolgeprogramm heißt R1.

Eine zweite Methode zur Wissensdarstellung sind Netzwerke (Semantische Netzwerke, Transitionsnetzwerke und prozedurale Netzwerke). Semantische Netzwerke sind besonders dort anwendbar, wo es auf die Darstellung von Hierarchien von Stereotypen ankommt. Ein Beispiel dafür ist ein Familienstammbaum. Allgemeine „Objekte“ wie Vater, Mutter, Großvater, Geschwister, Tanten und Onkel können identifiziert werden. Jedes dieser Objekte besitzt Cha-

rakteristika, die zusammen mit den Beziehungen zu anderen Objekten spezifiziert werden können. Z.B. hat das allgemeine Objekt „Vater“ die Eigenschaften, ein männliches Wesen mit einem oder mehreren Kindern zu sein. Ein semantisches Netzwerk kann daher die allgemeinen Charakteristika familiärer Beziehungen und einer dazugehörigen Hierarchie beschreiben. Zusätzlich können spezifische Erscheinungsformen dieser Objekte identifiziert werden. Semantische Netzwerke werden zur Beschreibung eines Netzwerks von Objekten und ihrer Beziehungen formuliert. Ein formales graphisches Schema kann verwendet werden, in dem die Objekte z.B. als Kreise dargestellt werden, die Beziehungen als bezeichnete Pfeile und die Eigenschaften als Rechtecke. Eine wichtige Eigenschaft von Netzwerken ist das Konzept der Vererbung, d.h., daß die Identität eines Objektes als Mitglied einer allgemeinen Klasse es erlaubt, Informationen bzgl. der Zugehörigkeit zur Klasse als gegeben anzunehmen. In einem Inferenzprozeß werden bestimmte Prozeduren verwendet, alle Fälle oder Beispiele eines Objektes zu durchsuchen und unbekannte Eigenschaften aus der zugehörigen Klasse zu übernehmen.

<b>Darstellungstechnik</b>	<b>Beschreibung</b>	<b>Formulierung</b>	<b>Anwendungsbereich</b>
Produktionsregeln	Ursache-Wirkung-Paar	Syntaktische Darstellung: IF (Befund für X) THEN (führe Y aus)	Locker verbundene Faktenansammlung
Netzwerke	Hierarchische Beziehungen zwischen allgemeinen Objekten und deren spezifischen Erscheinungsformen	Allgemein graphische Formulierung	Hierarchien von Stereotypen; Muster
Frames	Entwickelt zur Einbeziehung mehrerer Attribute eines Objekts	Kombinierte graphische und komplexe Datenrecords-Darstellung; erlaubt Spezifikation von Hierarchien und Attributen	Hierarchien von Stereotypen; Muster
Scripts	Ähnlich Drehbuch; Spe-	Formulierung spezifi-	Von Rollen, Kontexten

	zifikation von aktiven Betrachtungseinheiten, allgemeinen Bedingungen und Aktionsfolgen	ziert: aktive Agenten/Objekte, Kontext, Aktionsfolge, Interaktion	und Aktionsfolgen geprägte Bereiche
Direkt (analog)	Klasse von Darstellungsschemata zur Wissensdarstellung bzgl. bestimmter Aspekte eines Bereichs	Karten, Modelle, Diagramme, Symbole usw.	Bei Vorhandensein spezialisierter Wissens bzgl. eines bestimmten Bereichs

Tabelle 7.2: Techniken zur Wissensdarstellung

Wissensdarstellung durch semantische Netzwerke wird i.A. in der Form von Frames implementiert. Ein Frame ist eine Ansammlung semantischer Netzknoten nebst zugehörigen Eigenschaften, die zusammen ein typisiertes Objekt oder Ereignis beschreiben. Frames ermöglichen strukturierte Darstellungen von Objekten oder Klassen von Objekten. Sie eignen sich besonders zur Darstellung von Hierarchien von Stereotypen oder Datenmustern.

Das Konzept der Scripts zur Wissensdarstellung ist vergleichbar mit den Anweisungen eines Regisseurs an einen Schauspieler. Ein Script beschreibt Szenarien mit aktiven Parteien, ein allgemeines Umgebungssetting, eine Abfolge von Aktionen und Interaktionen zwischen den handelnden Parteien. Dieser Darstellungstyp ist besonders geeignet zur Beschreibung von Rollen, Kontexten und einer Gruppe von Aktionen, die auf ein Ziel zulaufen. Scripts sind in kommerziellen Expertensystemen nicht häufig anzutreffen. Trotzdem bieten sie einen tragfähigen Kontext zur Beschreibung komplexer Ereignisse. Eine spezielle Eigenschaft von Scripts ist, daß bei ihrer Verwendung die Möglichkeit besteht, die Menge realer Information, die beschrieben werden muß, zu reduzieren. Z.B. kann durch die Spezifikation bestimmter Szenarien und Settings die benötigte Menge an Information reduziert werden.

Eine letzte alle Anforderungen erfüllende Kategorie der Wissensdarstellung ist der direkte Gebrauch von Analogien. Dies bezieht sich auf alle Techniken, die genutzt werden, Informationen zu einem besonderen Gebiet darzustellen. Beispiele dazu sind Karten, Diagramme, mathemati-



sche oder chemische Symbole usw. Direkte Methoden sind auf einen bestimmten Wissenstypus angepaßt und als solche effizient und effektiv.

Der tatsächliche Prozeß der Füllung einer Wissensbasis (Entwicklung von Regeln, Frames oder Scripts) wird „Knowledge Engineering“ genannt und basiert weitestgehend auf Trial-and-Error, da zur Wissensdarstellung zwar Techniken entwickelt worden sind, diese jedoch keineswegs ein eindeutiges Schema etablieren, anhand dessen vorgegangen werden könnte.

## 7.5 Unsicherheitsdarstellung

Jede der zur Wissensdarstellung beschriebenen Methoden erlaubt die Einbeziehung von Unsicherheit. Unsicherheit kann auf zwei Arten betrachtet werden: Zunächst als ein Weg, beobachteten Daten Unsicherheit zuzuweisen und zum anderen durch die Spezifikation der Unsicherheit logischer Beziehungen. Z.B. könnte eine Regel, die die biologische Kategorie „Muttertier“ beschreibt, die folgende Form haben:

```
IF Großmutter ist plötzlich sehr behaart
AND Großmutter hat große Zähne
THEN Großmutter ist ein Wolf und will Rotkäppchen nichts Gutes
```

Den Beobachtungen kann eine gewisse Unsicherheit zugewiesen werden. Basierend auf z.B. Infrarotdaten kann eine Wahrscheinlichkeit oder ein Konfidenzfaktor ausgewiesen werden, daß Großmutter große Zähne hat. Unsicherheit kann auch der Schlußfolgerung zugewiesen werden, d.h. selbst wenn mit 100%iger Sicherheit klar ist, daß Großmutter urplötzlich eine enorme Körperbehaarung hat und ziemlich große Zähne hat, kann trotzdem ein gewisses Maß an Unsicherheit bestehen, daß Großmutter Rotkäppchen etwas Böses antun will.

Es gibt eine Reihe von Methoden zur Behandlung von Unsicherheiten. In den vorherigen Kapiteln wurden die Konzepte von Wahrscheinlichkeit und evidentiellen Intervallen eingeführt. Im folgenden werden fünf Techniken exemplarisch kurz vorgestellt:

### 1. Wahrscheinlichkeit

Wahrscheinlichkeitskonzepte und ihr Einsatz zur Vorbestimmung von Glücksspielergebnissen kamen im 17-ten Jahrhundert auf. In Kapitel 6 führte eine Diskussion der klassischen Inferenz in die Konzepte der klassischen, empirischen und subjektiven Wahrscheinlichkeiten ein. Wahrscheinlichkeit kann sowohl Beobachtungen als auch logischen Beziehungen zugewiesen werden. Die klassischen Gesetzmäßigkeiten der Wahrscheinlichkeit (bedingte Wahrscheinlichkeitsregeln) wie auch die Bayes'sche Ungleichung legen eine Basis für die Arbeit mit Wahrscheinlichkeiten. Wahrscheinlichkeit scheint intuitiv ansprechend, da die meisten Menschen ein formales Training der Wahrscheinlichkeitsmathematik erhalten haben und die verwendete Terminologie weit verbreitet ist. Unglücklicherweise ist Intuition nicht immer geeignet beim Umgang mit Wahrscheinlichkeit. Der Gebrauch klassischer und Bayes'scher

Inferenz verlangt eine gründliche Betrachtung der zugrundeliegenden Einschränkungen (z.B. die Notwendigkeit zur Definition sich gegenseitig ausschließender Hypothesen).

## 2. Evidentielle Intervalle

Die in Kapitel 6 eingeführte Dempster-Shafer-Theorie [62] stellt Unsicherheiten durch ein evidentielles Intervall dar: die Unterstützung für einen Vorschlag - basierend auf den aufsummierten Massenfunktionen - und die Plausibilität eines Vorschlages, d.h. den Mangel an Beweiskraft, die den Vorschlag direkt verwirft. Die Dempster'schen Kombinationsregeln erlauben es, die evidentiellen Intervalle zur Darstellung und Verarbeitung von Unsicherheit in einem Inferenzprozeß zu nutzen. Ebenso wie die Wahrscheinlichkeitskonzepte und (1) verfügen die evidentiellen Intervalle der D-S über einen fundierten theoretischen Hintergrund. Dieser modifiziert einige der Bedingungen der Bayes'schen Inferenz. Der Rechenaufwand dieser Methode ist jedoch größer als der bei der Bayes'schen Inferenz.

## 3. Verallgemeinerte Beweisverarbeitungstheorie (GEP)

[68] führt eine Verallgemeinerung der Bayes'schen Inferenz als eine Variante des D-S-Ansatzes ein. Evidentielle Intervalle werden analog zu den D-S-Intervallen mit einem optimierten Entscheidungsansatz entwickelt. Kapitel 6 bietet zu diesem Thema einen Überblick. Während die theoretische Basis dieses Ansatzes gut definiert ist, birgt der Gebrauch dieser Technik die Notwendigkeit ausgiebigen Trainings für den Anwender und erfordert eine erhöhte Berechnungskomplexität.

## 4. Vertrauens- bzw. Konfidenzfaktoren

Der Gebrauch von Konfidenzfaktoren wurde durch die Entwicklung des medizinischen Expertensystems MYCIN [75] eingeführt. Vertrauensfaktoren sind numerische Schätzwerte menschlicher Analysten der Sicherheit eines Faktums, einer Assoziation oder Regel. Der Konfidenzfaktor für eine Regel oder logische Beziehung beschreibt den Grad des Glaubens bzw. der Sicherheit, der auf die durch die Regel definierten Beziehungen gesetzt wird. Wenn der Konfidenzfaktor durch einen Sensor einem Faktum oder einer Assoziation zugewiesen wird, beschreibt er das Maß, mit dem der Anwender meint, daß dieses Faktum bekannt sei. Oft wird eine Konfidenzschwelle definiert zur Etablierung eines Konfidenzgrades, der für die bekannten Fakten und Assoziationen erreicht sein muß, bevor eine Schlußfolgerung aus der Regel gezogen werden kann. Ein Regelsatz für die Ausbreitung der Konfidenzfaktoren in Boole'schen Beziehungen existiert. Wenn eine Regel z.B. einen Vorgänger mit unsicheren Daten hat, d.h.  $CF(Daten)$ , und eine Schlußfolgerung, deren Konfidenz

$CF(\text{Beziehung})$  ist (bei 100%ig sicheren Daten), dann ist die Konfidenz der Schlußfolgerung:

$$CF(\text{Schlußfolgerung}) = CF(\text{Daten}) \cdot CF(\text{Beziehung}) \quad (7.1)$$

Der Gebrauch von Konfidenzfaktoren erscheint auf den ersten Blick recht sinnig. Die theoretische Basis ist jedoch nicht sehr gut definiert und die Interpretation von Ergebnissen kann mehrdeutig sein.

## 5. Fuzzy-Sets

Das Konzept der Fuzzy-Sets wurde 1968 durch Zadeh [44, 79-82] vorgestellt. Das Basis-konzept versucht Probleme anzugehen, bei denen Ungenauigkeit ein inhärenter Aspekt des Schlußfolgerungsprozesses ist. Z.B. sind einige Attribute und Konzepte, die verwendet werden, inhärent ungenau: Groß, kurz, attraktiv, liebenswürdig usw. Man kann die Höhe eines Menschen in Zentimetern quantifizieren, aber trotzdem nicht in der Lage sein, absolut zu sagen, ob dieser Mensch nun groß oder klein ist, z.B. im Vergleich mit einem Basketballspieler oder einem Pygmäen.

Zadeh entwickelte das Konzept der Fuzzy-Sets und später der Formulierung der Fuzzy-Logik [79] zur Behandlung solcher Probleme. Er ging davon aus, daß Ungenauigkeit in vielen täglichen Situationen eine große Rolle spielt. Statt diese Ungenauigkeit zu ignorieren, eröffnen die Fuzzy-Betrachtungen einen Weg, sich formal mit dieser Ungenauigkeit auseinanderzusetzen.

Fuzzy-Sets sind Sätze geordneter Paare  $[x, \mathbf{m}_A(x)]$ , wobei  $x$  ein in der Menge  $A$  definiertes Element repräsentiert und  $\mathbf{m}_A(x)$  die sog. Membership-Funktion ist, deren Wert zwischen 0 und 1 liegt:

$$0 \leq \mathbf{m}_A(x) \leq 1 \quad (7.2)$$

Die Membership-Funktion  $\mathbf{m}_A(x)$  quantifiziert, inwieweit das Element  $x$  zur Menge  $A$  gehört. In der Boole'schen Theorie werden Sätze durch die Spezifikation der Elemente definiert. Zwei Mengen  $A$  und  $B$  können z.B. definiert sein durch:

$$A = (x_1, x_2, x_3), B = (x_2, x_3, x_4) \quad (7.3)$$

In diesem Beispiel hat die Menge  $A$  die Elemente  $x_1$ ,  $x_2$  und  $x_3$ , während Menge  $B$  aus den Elementen  $x_2$ ,  $x_3$  und  $x_4$  besteht. In Boole'scher Theorie ist ein Element  $x_i$  entweder zu einer definierten Menge gehörig oder nicht. Hierbei sind klassische Mengenoperationen wie Vereinigung, Durchschnitt und Unterschied definiert. Demgegenüber definiert die Fuzzy-Theorie Mengen durch geordnete Paare:

$$A = \{[x_1, \mathbf{m}_A(x_1)], [x_2, \mathbf{m}_A(x_2)], [x_3, \mathbf{m}_A(x_3)]\} \quad (7.4a)$$

$$B = \{[x_2, \mathbf{m}_B(x_2)], [x_3, \mathbf{m}_B(x_3)], [x_4, \mathbf{m}_B(x_4)]\} \quad (7.4b)$$

In diesem Fall schreibt die assoziierte Membership-Funktion für jedes Element der Menge den Grad vor, mit dem ein Element zu einer bestimmten Menge zugehörig ist, z.B. definiert  $\mathbf{m}_A(x_1)$  das Maß, mit dem das Element  $x_1$  zur Menge  $A$  gehört. In der Fuzzy-Theorie sind dieselben Operationen (Inklusion, Gleichheit, Komplement, Vereinigung, Durchschnitt, Unterschied) definiert wie in der Boole'schen Theorie. Es sind jedoch zusätzlich Regeln definiert zur Beschreibung der entsprechenden Membership-Funktionen. Im besonderen sind die folgenden Regeln für Mengenoperationen definiert [6]:

$$A \subset B \Rightarrow \mathbf{m}_A(x) \leq \mathbf{m}_B(x) \quad (\text{Inklusion}) \quad (7.5)$$

$$A = B \Rightarrow \mathbf{m}_A(x) = \mathbf{m}_B(x) \quad (\text{Gleichheit}) \quad (7.6)$$

$$\mathbf{m}_{\bar{A}}(x) = 1 - \mathbf{m}_A(x) \quad (\text{Komplement}) \quad (7.7)$$

$$\mathbf{m}_{A \cup B}(x) = \text{Maximum}[\mathbf{m}_A(x), \mathbf{m}_B(x)] \quad (\text{Vereinigung}) \quad (7.8)$$

$$\mathbf{m}_{A \cap B}(x) = \text{Minimum}[\mathbf{m}_A(x), \mathbf{m}_B(x)] \quad (\text{Durchschnitt}) \quad (7.9)$$

$$\mathbf{m}_{A \cup \bar{B}}(x) = \text{Minimum}[\mathbf{m}_A(x), \mathbf{m}_{\bar{B}}(x)] \quad (\text{Unterschied}) \quad (7.10)$$

Diese Regeln zur Definition der Membership-Funktionen für Verbundmengenoperationen sind einfach zu interpretieren. Wenn der Durchschnitt zweier Mengen  $A$  und  $B$  z.B. gemeinsame Elemente  $x_i$  enthält, dann liegen diese Elemente zum Teil in Menge  $A$  und zum

Teil in Menge  $B$ . Es kann nicht wahrer sein, daß ein Element zum Durchschnitt  $A \cap B$  gehört als daß ein Element zu einer der beiden Mengen gehört. Die Regel für diesen Fall, Gl. (7.9), besagt, daß die Membership-Funktion für das Element  $x$  im Schnitt der Mengen  $A$  und  $B$  das Minimum der Zugehörigkeitsfunktionen zu den Mengen  $A$  und  $B$  ist. Ähnliche Interpretationen können für alle Regeln der Gl. (7.5) bis (7.10) entwickelt werden. In [79] wird zusammengefaßt, wie Fuzzy-Sets zur Erweiterung dieser Konzepte zu einer Fuzzy-Logik verwendet werden können. Zadeh definiert die Basisregeln der Fuzzy-Logik, u.a. Standardlogikbeziehungen wie konjunktive Regeln, kartesische Produkte, Projektion, Kompositionsregeln usw. Details dieser Formalismen können in [80-82] gefunden werden.

## 7.6 Suchtechniken

Zusätzlich zur Auf- und Bereitstellung von Techniken zur Darstellung von Wissen und Schlußfolgerungen unter Einbeziehung von Unsicherheit gehören Suchtechniken und -verfahren zu den Schlüsselementen eines Expertensysteminferenzprozesses. Der in Bild 7.2 skizzierte Inferenzprozeß stellt einen zyklischen Prozeß dar, dessen wesentliche Schritte aus Mustererkennungen, Suchen in einer Wissensbasis und der Ausführung von Regeln oder deren Äquivalent bestehen. Welche Methode auch immer zur Wissensdarstellung angewendet wird, es muß immer ein Verfahren geben, mit dem eine Wissensbasis zur Auffindung anwendbarer Regeln, Frames, Knoten innerhalb eines Netzwerks oder Daten durchsucht werden kann.

Der Suchprozeß wird oft mit der Suche eines bestimmten Blatts an einem großen Baum verglichen. Durch das Treffen fundierter Entscheidungen an jedem Verzweigungspunkt geht die Suche vom Baumstamm über die großen und kleinen Äste bis hin zu dem gesuchten Blatt.

Ein verbreitetes Beispiel eines Suchproblems ist das Problem des Handlungsreisenden (Traveling Salesman Problem), wie es in Bild 7.3 illustriert ist. Ein Handlungsreisender beginnt am Start-Knoten „Siegen“ und arbeitet sich über verschiedene andere Knoten (Städte) bis zum Ziel-Knoten „Regensburg“ vor. Die möglichen Pfade oder Straßen sind durch die Verbindungslinien zwischen den Knoten gegeben. Die dazugehörigen Distanzen werden durch die Zahlen an den Verbindungslinien angegeben (nicht maßstäblich). Das Problem kann wie folgt formuliert werden:

1. Finde einen Pfad, der bei „Siegen“ beginnt und bei „Regensburg“ endet und der mindestens einen Stop an jedem dazwischen liegenden Knoten enthält.
2. Finde den besten (kürzesten) Pfad zwischen Start- und Ziel-Knoten.
3. Finde irgendeinen zufriedenstellenden Pfad zwischen Start- und Ziel-Knoten.

Die beiden letzten Formulierungen sind Vereinfachungen des allgemeinen Problems und können mit wesentlich weniger Aufwand gelöst werden. Mögliche Pfade vom Start- zum Ziel-Knoten sind in dem Entscheidungsbaum in Bild 7.3 dargestellt. Beginnend bei „Siegen“ kann ein Pfad gewählt werden (entweder nach „Aschaffenburg“ oder nach „Dresden“). An jedem weiteren Kreuzungspunkt muß wieder eine Entscheidung getroffen werden (von „Aschaffenburg“ nach „Berlin“ oder nach „Dresden“), bis entweder eine Sackgasse oder der Endpunkt erreicht wird.

In Bild 7.3 zeigt die Doppellinie drei mögliche Routen von „Siegen“ nach „Regensburg“:

1. „Siegen“ => „Aschaffenburg“ => „Berlin“ => „Essen“ => „Friedrichshafen“ => „Regensburg“
2. „Siegen“ => „Aschaffenburg“ => „Dresden“ => „Essen“ => „Friedrichshafen“ => „Regensburg“
3. „Siegen“ => „Dresden“ => „Essen“ => „Friedrichshafen“ => „Regensburg“

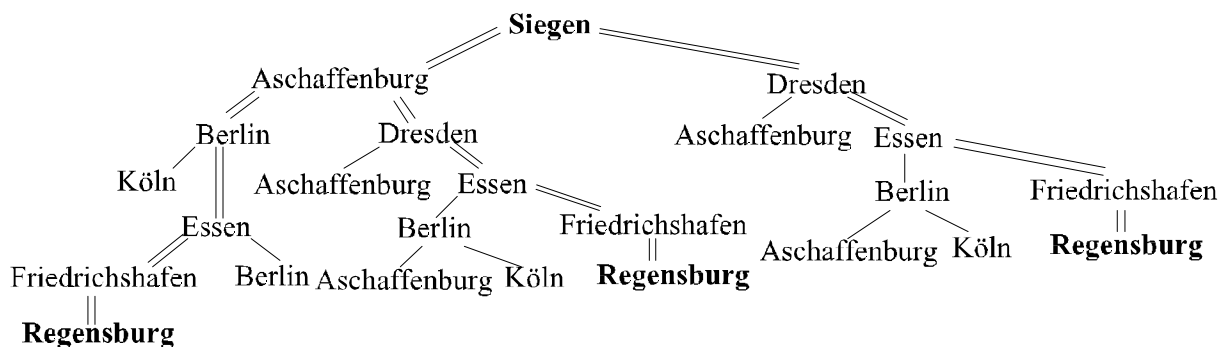
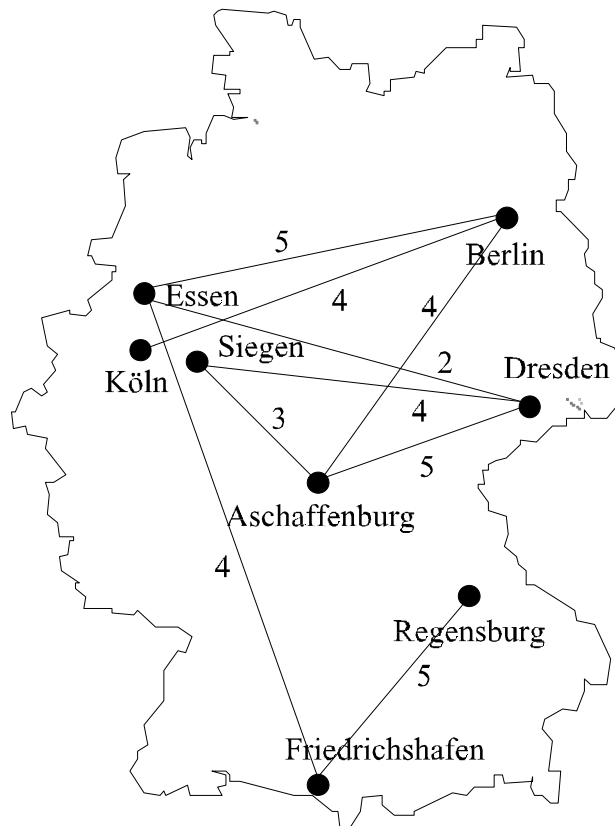


Bild 7.3: Beispiel für das Problem des Handlungsreisenden



In diesem Beispiel ist der kürzeste Pfad definiert durch die dritte Route, die eine Länge von 13 Einheiten hat im Vergleich zu der Distanz von 19 Einheiten für Pfad (1) und 17 Einheiten für Pfad (2). Während es relativ einfach ist, sich mögliche erfolgreiche Routen vorzustellen, erfordert die tatsächliche Suche von Knoten zu Knoten eine Suchstrategie.

In Bild 7.4 wird ein Überblick über einige Strategien, die für diese Art von Problemen entworfen wurden, gegeben. Eine umfassende Diskussion gibt [75].

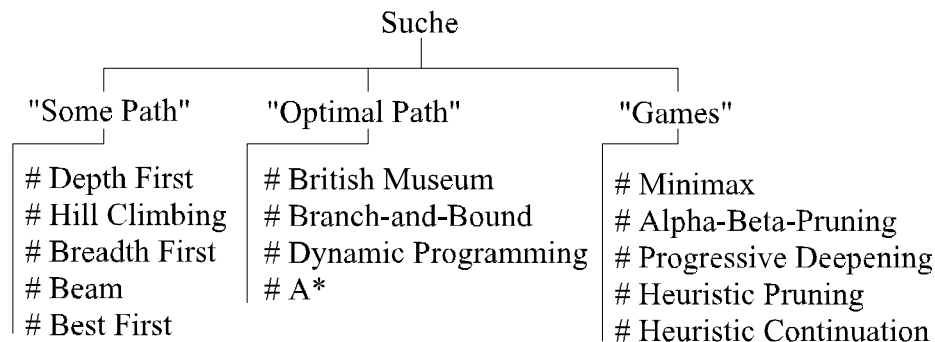


Bild 7.4: Überblick über Suchstrategien (nach [75])

„Some Path“-Strategien sind Methoden zur Auffindung irgendeines akzeptablen Weges zum Ziel. Z.B. wählt der „Depth First“-Algorithmus willkürlich einen alternativen Knoten und fährt auf diese Weise bei jedem weiteren Knoten fort, bis entweder eine Sackgasse oder das Ziel erreicht wird. Wenn eine Sackgasse erreicht worden ist, wird die Suche am nächsten Vorgängerknoten mit noch nicht durchlaufenem Pfad wieder aufgenommen, d.h. für das „Traveling Salesman Problem“ in Bild 7.3, daß eine „Depth First“-Vorgehensweise wie folgt aussehen würde, wenn die linke Seite die willkürliche erste Wahl an jedem Knoten wäre:

„Siegen“ => „Aschaffenburg“ => „Berlin“ => „Köln“ => „Berlin“ => „Essen“ => „Friedrichshafen“ => „Regensburg“

„Depth First“-Suchen sind dann effizient, wenn an jedem Knoten nur wenige Alternativen gegeben sind. Demgegenüber sucht ein „Breadth First“-Algorithmus alle alternativen Knoten Ebene für Ebene ab, bis das Ziel erreicht wird.

Die zweite in Bild 7.4 gezeigte Kategorie von Suchtechniken wird „Optimal Path“ genannt. Die unter diesem Begriff gesammelten Techniken suchen - wie der Name sagt - nicht nur irgendei-

nen Weg vom Start zum Ziel, sondern den besten Weg. I.A. dauert die Wegfindung mit „Optimal Path“ länger als „Some Path“.

Eine besonders ineffektive Methode - jedoch mit Garantie zur Auffindung des optimalen Weges - ist der „British Museum“-Ansatz. Dieser findet durch „Depth First“ oder „Breadth First“ alle möglichen Wege und wählt dann den besten Pfad aus.

„A\*“ ist relativ effizient und wird verbreitet in wissensbasierten Systemen genutzt.

Die Techniken der dritten Kategorie werden für Suchen in Situationen wie Spielen verwendet, bei denen ein Opponent auf eine gewählte Alternative mit einem Gegenzug antwortet. Diese Gegenzugstechniken versuchen ihre Züge mit dem Wissen, daß ein aktiver Opponent auf den Zug reagieren wird.

Die Auswahl von Suchtechniken hängt von dem spezifischen Problem ab, der Art des Suchproblems, den verfügbaren Rechnerressourcen und den Zielen des Entwicklers.

## 7.7 Logische Templates (Schablonen)

In der multisensoriellen Datenfusion werden zur Ereignisdetektion oder Situationseinschätzung logikbasierende Mustererkennungstechniken eingesetzt. Der Name in der Literatur dafür ist Templating [44]. Diese Klassen von Techniken sind seit der Mitte der 70er Jahre des 20ten Jahrhunderts erfolgreich bei der Konzeptionierung und Implementierung von Systemen zur Datenfusion eingesetzt worden. Der Begriff „Templating“ stammt von dem Konzept des Erkennens eines vorbestimmten Musters aus beobachteten Daten zur Bestimmung, ob bestimmte Bedingungen erfüllt wurden, um daraus die Ableitung einer Inferenz zu erlauben. Ein schulisches Beispiel eines solchen Musters ist der Gebrauch einer Test-Schablone durch einen Lehrer. Bei diesem simplen Beispiel wird ein Stück Papier mit einem Lochmuster über den ausgefüllten Antwortbogen des Schülers gelegt. Diese Art der Bewertung erlaubt dem Lehrer eine rasche Bewertung der Antworten. Das Muster ist sehr einfach und die Möglichkeiten sind binär: falsch oder richtig.

Dieses Mustererkennungskonzept kann für komplexe Muster wie logische Bedingungen, Fuzzy-Konzepte und Unsicherheit sowohl bei den Beobachtungsdaten als auch den logischen Beziehungen zur Definition eines Musters verallgemeinert werden. Das Muster, das durch ein Template definiert wird, kann z.B. ein taktisches Ereignis wie einen Raketenstart darstellen. Zur Abbildung zunehmend komplexer Gegebenheiten, Ereignisse oder Aktivitäten können Template-Hierarchien entwickelt werden.

Der Templating-Algorithmus vergleicht Beobachtungsdaten mit festgelegten Spezifikationen. Das Ergebnis bestimmt, ob die Beobachtungen genügend Beweiskraft besitzen, um eine Betrachtungseinheit, ein Ereignis oder eine Aktivität zu bestimmen. Input für den Templating-Prozeß sind eine oder mehrere Beobachtungen über einen Zeitraum, die sowohl parametrische als auch nichtparametrische Datensätze enthalten können. Der Output des Prozesses besteht aus einer Aussage, ob die Beobachtungen einem festgelegten Profil entsprechen oder nicht. Dieser Aussage kann eine Wahrscheinlichkeit bzgl. des durch das Template spezifizierten Ereignisses zugeordnet sein. Jede Anwendung braucht anwendungsspezifische Informationen. Einige Informationen sind jedoch gleich für alle Templates. Zu den anwendungsabhängigen Informationen gehören Identifikation, Annahme- und Abweisungsschwellen, notwendige und hinreichende Bedingungen und die Komponenten, die die Aktivität beschreiben.

Bild 7.5 zeigt das allgemeine Ablaufdiagramm eines Basistemplates.

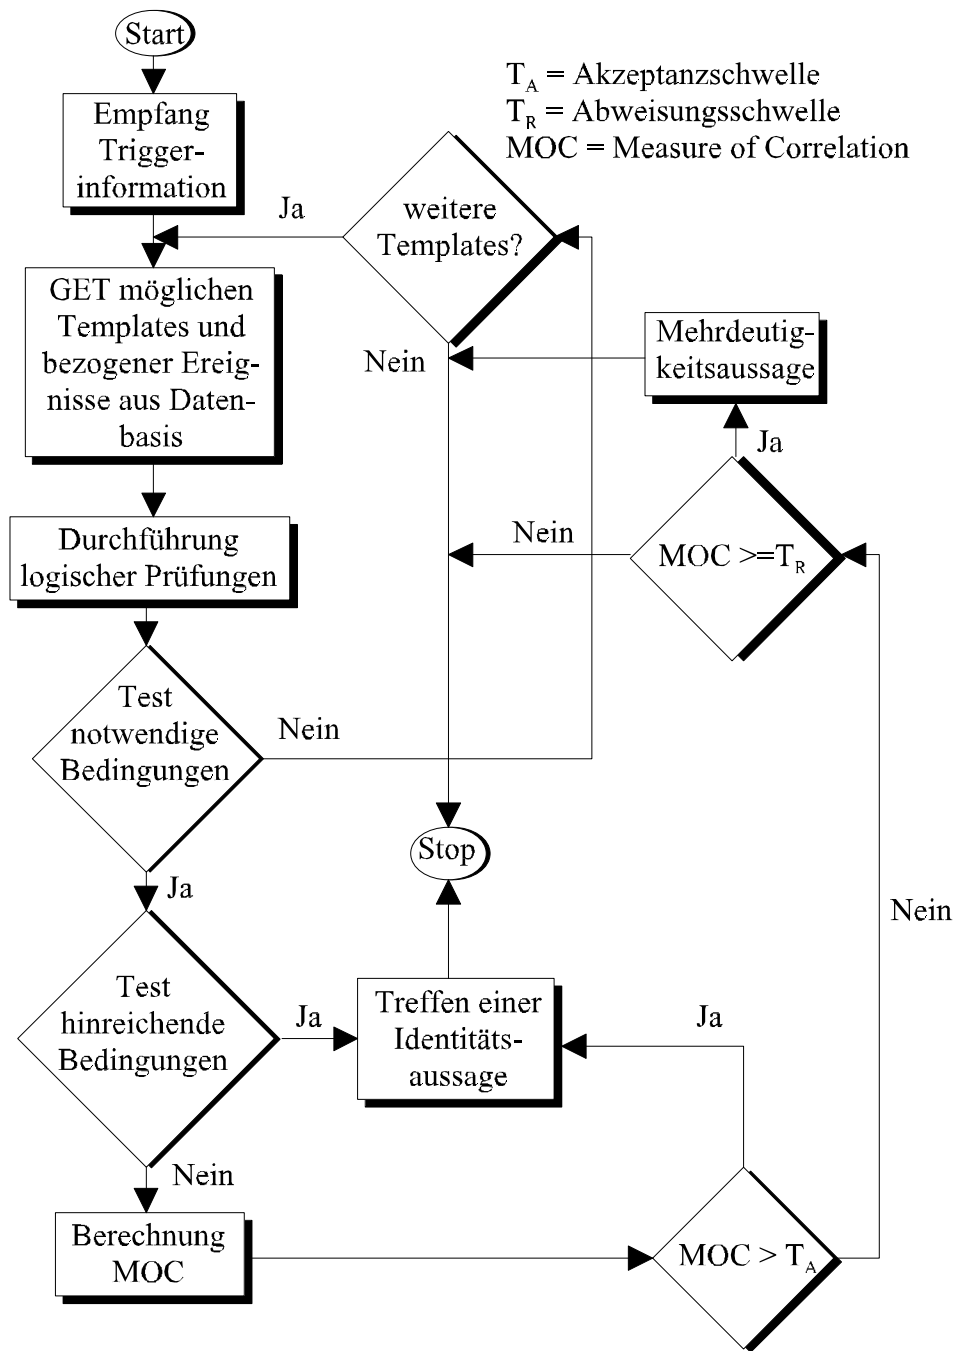


Bild 7.5: Grundlegendes Ablaufdiagramm für Templates

Es handelt sich dabei um einen datenverarbeitenden Prozeß, bei dem neue Daten einen Prozessor zu der Bestimmung bewegen, welche (wenn überhaupt) Templates durch die neuen Daten bedient bzw. welche Templates durch sie gefüllt werden. Der Prozeß kann genauso gut in einer zielgerichteten Art formuliert werden, bei dem eine existierende Datenbasis auf einzelne Templates durchsucht wird. Initiiert wird der Prozeß durch Triggerinformation (neue Beobach-

tungsdaten). Sobald eine Liste von anwendbaren Templates gefunden ist, kann diese Liste noch durch weitere Filterung gekürzt werden. Jedes der möglichen Templates wird auf der Basis von notwendigen und hinreichenden Bedingungen ausgewertet. Ein Korrelationsmaß (MOC) wird berechnet und mit den Akzeptanz- und Abweisungsschwellen des Templates verglichen. Der MOC-Wert (Measure of Correlation) bestimmt, ob die in der Datenbasis akkumulierten Ereignisse die Identifikation, die durch das Template repräsentiert wird, unterstützen oder nicht.

Wenn notwendige Komponentensätze in dem Template spezifiziert sind, dann werden die Daten auf diese Komponenten hin kontrolliert. Wenn sie nicht vorhanden sind, wird das Template verworfen. Werden die notwendigen Bedingungen erfüllt, werden die Daten auf die hinreichenden Bedingungen hin untersucht. Treffen diese Bedingungen nicht zu, wird der MOC berechnet und mit den Akzeptanz- bzw. Annahme- und Abweisungsschwellen verglichen, um dann einen flexibleren Test durchführen zu können. Wenn der MOC-Wert über der Akzeptanzschwelle liegt, wird eine Identitätsaussage auf Basis des Templates getroffen. Liegt dieser Wert zwischen den festgesetzten Schwellen, kommt es zu einer Mehrdeutigkeitsaussage. Ist der MOC-Wert kleiner als die Abweisungsschwelle, wird keine Identitätsaussage getroffen.

Der Template-Algorithmus führt auf diese Weise einen iterativen Mustererkennungsprozeß durch, der sowohl parametrische als auch nichtparametrische Daten wie auch logische Beziehungen beinhaltet. Der Prozeß endet dann, wenn entweder ein oder mehrere Templates als die Aussage unterstützend erkannt wurden oder wenn keines gefunden werden konnte. Im Fall, daß mehrere Templates als tragbar erkannt wurden, wird eine Mehrdeutigkeitsaussage getroffen, die durch menschliche Entscheidungen oder eine vorbestimmte Wichtung der Templates aufgelöst werden kann.

## 7.8 Figures of Merit

Im Template-Inferenzprozeß werden Beobachtungen mit jedem Template assoziiert und Beobachtungen mit anderen Beobachtungen. Weil die Beobachtungen i.A. sowohl parametrische Daten (Ort, Frequenz, Zeit, usw.) als auch nichtparametrische Daten (Identitätsaussagen von Sensoren) enthalten, wird ein MOC dazu genutzt, den Grad der Assoziation zu definieren. Wären bei diesen Prozessen nur parametrische Daten involviert, könnten statistische Maße wie die Mahalanobis-Metrik zur Bestimmung der Assoziation genutzt werden.

Der MOC-Wert ist ein numerisches Maß für das Vertrauen, daß zwei Beobachtungen dasselbe Objekt darstellen. Ein Objekt wird durch bestimmte Attribute beschrieben und der MOC-Wert für zwei Objekte hängt von den Ähnlichkeitsgraden zwischen den einzelnen Attributen der Objekte ab. Das Assoziationsproblem hat zwei Facetten: das Finden von Maßen zum Vergleich der einzelnen Attribute und das Erdenken einer Methode zur Kombination dieser Maße zur Bildung des MOC. Die Vergleichsmaße werden „Figures of Merit“ (FOM) genannt [76].

Die FOMs müssen den Attributen der einzelnen Objekte angepaßt werden. Es ist möglich, statistische Maße als FOMs für numerische Attribute zu verwenden, für die die Wahrscheinlichkeitsdichtebeschreibungen vorliegen. Z.B. ist die normalisierte Verteilung für den Ortsveränderungsvektor eine geeignete FOM für durch Gauß'sche Vektorprozesse beschriebene Orte. Für skalare numerische Attribute mit Gauß'schen Verteilungen kann die normalisierte Chi<sup>2</sup>-Verteilung, die ein Differenzmaß ist, als FOM geeignet sein [60].

Es gibt eine Klasse numerischer Attribute, bei denen die Unsicherheit beschrieben wird als ein für diese Attribute in Frage kommender Bereich von Werten. Eine für diese Klasse geeignete FOM ist das Cross-Korrelogramm der zwei Intervalle, die die beiden zu vergleichenden Attribute beschreiben. Dieser Prozeß ergibt einen FOM-Wert von 1, wenn die Intervalle deckungsgleich sind und gehen auf 0 zu, je verschiedener die Intervalle sind. Alphanumerische Attribute wie Gerätebezeichnungen erfordern einen anderen Ansatz. Auf der einen Seite kann der Vergleich als einfacher Boole'scher Test durchgeführt werden, für den der FOM-Wert entweder 1 oder 0 annimmt, und auf der anderen Seite wird der Vergleich für den einzelnen Buchstaben ausgeführt, was eine kontinuierliche FOM-Funktion ergibt. Die spezifische FOM-Funktion wird oft eher heuristisch begründet als durch rigorose mathematische Grundlagen.

Die Methode zur Kombination von FOMs zu einem MOC-Wert wird empirisch entwickelt. Ein solcher Ansatz kann sein, einfach den Mittelwert der gewichteten FOMs zu ermitteln. Eine andere Möglichkeit besteht darin, die gewichteten FOMs zu multiplizieren. Das grundlegende

Problem dieser Methode ist, daß die inkrementelle Sensitivität des MOC-Wertes bzgl. einzelner FOMs eine Funktion der Werte und Gewichte der anderen FOMs ist. Multiplikative FOMs sind i.A. nicht sehr hilfreich in entscheidungstheoretischen Studien. Die allgemeine Form der MOC-Gleichung ist:

$$MOC = \sum_{i=1}^n W_i \cdot FOM_i \quad (7.11)$$

Der berechnete MOC-Wert wird mit einem vorbestimmten Schwellwert verglichen. Wenn der MOC-Wert den Schwellwert übersteigt, werden die beiden individuellen Betrachtungseinheiten als dieselben Gegebenheiten darstellend beurteilt. Wenn der Schwellwert nicht überschritten wird, stellen sie verschiedene Gegebenheiten dar.

Dieser Prozeß kann durch den Gebrauch mehrerer Schwellen verkompliziert werden. Die Beurteilungen zweier Schwellwerte z.B. können identisch, unterschiedlich und mehrdeutig sein. Solche Mehrdeutigkeiten erfordern die Auflösung durch ähnliche Techniken, wie sie bei Expertensystemen zur Konfliktlösung Verwendung finden.

Template-Techniken sind besonders nützlich bei der Entwicklung von abstrakten Techniken mit Bezug auf Situations- oder Bedrohungseinschätzungen. Sie sind eine Alternative zum Ansatz des Expertensystems.

## 8. Schlußbemerkungen und Perspektive

Multisensor-Datenfusion ist eine sich vehement entwickelnde Technologie, die eine Anhäufung verfügbarer Techniken zur Lösung sehr unterschiedlicher Problemkreise darstellt. Ziel der vorliegenden Abhandlung ist, eine Einführung in die Datenfusion zu geben und einen Überblick über spezifische Techniken.

Die Datenfusion selbst ist noch keine so ausgereifte Technologie wie die von ihr verwendeten Disziplinen wie z.B. Signalverarbeitung. Die Perspektive der Abhandlung ist zweifach:

Erstens, die individuellen Techniken zur Datenfusion sind relativ ausgereift, während ihre Nutzung im Zusammenspiel mit anderen Techniken dies noch nicht hergibt, und zweitens, daß im Gebiet der Implementierung einsetzbarer Systeme noch eine Menge Arbeit zu leisten ist.

Die erste Perspektive ist, daß viele der behandelten Techniken von einem mathematischen Standpunkt aus betrachtet beherrschbar sind bzw. beherrscht werden. Sie decken einen weiten Bereich ab, von numerischen Techniken bis zu heuristischen Ansätzen. Viele dieser Techniken wie Least-Squares-Estimation, klassische Inferenz oder Bayes'sche Inferenz haben eine lange Tradition, die bis ins 17te Jahrhundert zurückgeht. Die Zusammenführung diverser Methoden zur Lösung von Datenfusionsproblemen ist dagegen relativ neu. Die Auswahl von Techniken und die Bereitstellung von A-Priori-Daten bereiten nach wie vor eine Herausforderung. Die weitere Forschung auf dem Gebiet der Datenfusion soll genau hier Fortschritte erbringen. Arbeit ist besonders notwendig zum Vergleich der relativen Leistungsfähigkeit von Techniken.

Eine zweite Perspektive beinhaltet das Implementierungsproblem. Probleme hier bestehen in den Gebieten Test und Evaluation, Architekturauswahl, Technikauswahl und Mensch-Maschine-Interfaces. Alle diese Fragen betreffen weitgehend System-Engineering-Probleme.



## A.1 Herleitung Gl. (1.1)

Ein Versuch werde  $n$  mal wiederholt. Dabei sind die einzelnen Versuche voneinander unabhängig. In jedem der Versuche trete ein bestimmtes Ereignis  $A$  ein oder nicht. Die Wahrscheinlichkeit für das Eintreten von  $A$  im Einzelversuch sei unabhängig von der Nummer des Versuchs gleich  $p$ .  $X^{(n)}$  sei die Anzahl des Eintretens von  $A$  in einer solchen Serie von  $n$  Versuchen. Die möglichen Werte der Zufallsgröße  $X^{(n)}$  sind damit die Zahlen  $0, 1, 2, \dots, n$ . Für die Wahrscheinlichkeit  $p_k^{(n)} = P(X^{(n)} = k)$  gilt:

$$p_k^{(n)} = \binom{n}{k} p^k \cdot q^{n-k} \text{ mit } q = 1 - p, k = 0, 1, \dots, n \quad (\text{A.1.1})$$

mit:

$$\binom{n}{k} = \frac{n!}{(n-k)! k!} \quad (\text{A.1.2})$$

Sind  $A_1, A_2, A_3, \dots$  zufällige Ereignisse, die paarweise unvereinbar sind, d.h.  $A_i \cap A_j = \emptyset$  für  $i \neq j$ , so gilt:

$$P\left(\bigcup_i A_i\right) = \sum_i P(A_i) \quad (\text{A.1.3})$$

Für die „Majority Rule“ gilt dann bei  $N$  ( $N$  ungerade) symmetrisch eingestellten Sensoren, wenn die Wahrscheinlichkeit gesucht wird, daß die  $N$  Sensoren (mehr als die Hälfte müssen korrekt klassifizieren  $\Rightarrow$  Summe von  $k = \frac{N+1}{2}$  bis  $N$ ) das Ziel korrekt klassifizieren:

$$P_{MR,N}(A) = \sum_{k=\frac{N+1}{2}}^N \binom{N}{k} P^k(A) \cdot (1 - P(A))^{N-k} \quad (\text{A.1.4})$$

Daraus folgt unmittelbar:

$$P_{MR,N+2}(A) = \sum_{k=\frac{N+3}{2}}^{N+2} \binom{N+2}{k} P^k(A) \cdot (1-P(A))^{N+2-k} \quad (\text{A.1.5})$$

Die „Network Performance“ sei definiert als:

$$\Delta P_{MR}(A) = P_{MR,N+2}(A) - P_{MR,N}(A) \quad (\text{A.1.6})$$

Dann ergibt sich für (A.1.6) mit (A.1.4) und (A.1.5):

$$\begin{aligned} \Delta P_{MR}(A) &= \sum_{k=\frac{N+3}{2}}^{N+2} \binom{N+2}{k} P^k(A) \cdot (1-P(A))^{N+2-k} \\ &\quad - \sum_{k=\frac{N+1}{2}}^N \binom{N}{k} P^k(A) \cdot (1-P(A))^{N-k} \end{aligned} \quad (\text{A.1.7})$$

Anwendung der Pascal'schen Identität:

$$\binom{N+1}{k} = \binom{N}{k} + \binom{N}{k-1} \quad (\text{A.1.8})$$

bzw.:

$$\binom{N+2}{k} = \binom{N}{k} + 2 \cdot \binom{N}{k-1} + \binom{N}{k-2} \quad (\text{A.1.9})$$

auf (A.1.7) ergibt:

$$\begin{aligned}
P_{MR,N+2}(A) &= \sum_{k=\frac{N+3}{2}}^{N+2} \binom{N}{k} P^k(A) \cdot (1-P(A))^{N-k+2} \\
&+ 2 \cdot \sum_{k=\frac{N+3}{2}}^{N+2} \binom{N}{k-1} P^k(A) \cdot (1-P(A))^{N+2-k} \\
&+ \sum_{k=\frac{N+3}{2}}^{N+2} \binom{N}{k-2} P^k(A) \cdot (1-P(A))^{N+2-k}
\end{aligned} \tag{A.1.10}$$

$$\begin{aligned}
P_{MR,N+2}(A) &= \sum_{k=\frac{N+3}{2}}^{N+2} \binom{N}{k} P^k(A) \cdot (1-P(A))^{N+2-k} \\
&+ 2 \cdot \sum_{j=\frac{N+1}{2}}^{N+1} \binom{N}{j} P^{j+1}(A) \cdot (1-P(A))^{N+2-(j+1)} \\
&+ \sum_{j=\frac{N-1}{2}}^N \binom{N}{j} P^{j+2}(A) \cdot (1-P(A))^{N+2-(j+2)} \\
&= (1-P(A))^2 \cdot \sum_{k=\frac{N+3}{2}}^{N+2} \binom{N}{k} P^k(A) \cdot (1-P(A))^{N-k} \\
&+ 2 \cdot P(A) \cdot (1-P(A)) \cdot \sum_{k=\frac{N+1}{2}}^{N+1} \binom{N}{k} P^k(A) \cdot (1-P(A))^{N-k} \\
&+ P^2(A) \cdot \sum_{k=\frac{N-1}{2}}^N \binom{N}{k} P^k(A) \cdot (1-P(A))^{N-k}
\end{aligned}$$

Mit einer Zerlegung in Einzelsummen, z.B.  $\sum_{k=\frac{N+3}{2}}^{N+2} \dots = \sum_{k=\frac{N+1}{2}}^N \dots + \dots$  folgt:

$$\begin{aligned}
P_{MR,N+2}(A) &= (1-P(A))^2 \cdot \sum_{k=\frac{N+1}{2}}^N \binom{N}{k} P^k(A) \cdot (1-P(A))^{N-k} \\
&\quad + (1-P(A))^2 \cdot \binom{N}{N+1} \cdot P^{N+1}(A) \cdot (1-P(A))^{N-(N+1)} \\
&\quad + (1-P(A))^2 \cdot \binom{N}{N+2} \cdot P^{N+2}(A) \cdot (1-P(A))^{N-(N+2)} \\
&\quad - (1-P(A))^2 \cdot \left( \binom{N}{\frac{N+1}{2}} \right) \cdot P^{\frac{N+1}{2}}(A) \cdot (1-P(A))^{N-\left(\frac{N+1}{2}\right)} \\
&\quad + 2 \cdot P(A) \cdot (1-P(A)) \cdot \sum_{k=\frac{N+1}{2}}^N \binom{N}{k} P^k(A) \cdot (1-P(A))^{N-k} \\
&\quad + 2 \cdot P(A) \cdot (1-P(A)) \cdot \binom{N}{N+1} P^{N+1}(A) \cdot (1-P(A))^{N-(N+1)} \\
&\quad + P^2(A) \cdot \sum_{k=\frac{N+1}{2}}^N \binom{N}{k} P^k(A) \cdot (1-P(A))^{N-k} \\
&\quad + P^2(A) \cdot \left( \binom{N}{\frac{N-1}{2}} \right) \cdot P^{\frac{N-1}{2}}(A) \cdot (1-P(A))^{N-\frac{N-1}{2}}
\end{aligned}$$

Mit  $\binom{N}{k} = 0$  für  $k > N$ :

$$\begin{aligned}
P_{MR,N+2}(A) &= (1-P(A))^2 \cdot P_{MR,N}(A) \\
&\quad - \left( \binom{N}{\frac{N+1}{2}} \right) P^{\frac{N+1}{2}}(A) \cdot (1-P(A))^{\frac{N+3}{2}} \\
&\quad + 2 \cdot P(A) \cdot (1-P(A)) \cdot P_{MR,N}(A) \\
&\quad + P^2(A) \cdot P_{MR,N}(A) \\
&\quad + \left( \binom{N}{\frac{N-1}{2}} \right) P^{\frac{N+3}{2}}(A) \cdot (1-P(A))^{\frac{N+1}{2}}
\end{aligned} \tag{A.1.11}$$

Die Identität  $\left( \binom{N}{\frac{N-1}{2}} \right) = \left( \binom{N}{\frac{N+1}{2}} \right)$  ergibt:

$$\begin{aligned}
P_{MR,N+2}(A) &= (1-P(A))^2 \cdot P_{MR,N}(A) \\
&\quad - \left( \binom{N}{\frac{N+1}{2}} \right) P^{\frac{N+1}{2}}(A) \cdot (1-P(A))^{\frac{N+3}{2}} \\
&\quad + 2 \cdot P_{MR,N}(A) \cdot P(A) \cdot (1-P(A)) \\
&\quad + P^2(A) \cdot P_{MR,N}(A) \\
&\quad + \left( \binom{N}{\frac{N+1}{2}} \right) P^{\frac{N+3}{2}}(A) \cdot (1-P(A))^{\frac{N+1}{2}} \\
&= P_{MR,N}(A) \cdot \left[ (1-P(A))^2 + 2 \cdot P(A) \cdot (1-P(A)) + P^2(A) \right] \\
&\quad + \left( \binom{N}{\frac{N+1}{2}} \right) \cdot \left[ P^{\frac{N+3}{2}}(A) \cdot (1-P(A))^{\frac{N+1}{2}} - P^{\frac{N+1}{2}}(A) \cdot (1-P(A))^{\frac{N+3}{2}} \right] \\
&= P_{MR,N}(A) + \left( \binom{N}{\frac{N+1}{2}} \right) \cdot \left[ \begin{aligned} &P(A) \cdot P^{\frac{N+1}{2}}(A) \cdot (1-P(A))^{\frac{N+1}{2}} \\ &- P^{\frac{N-1}{2}}(A) \cdot P(A) \cdot (1-P(A)) \cdot (1-P(A))^{\frac{N+1}{2}} \end{aligned} \right]
\end{aligned}$$

$$\begin{aligned}
P_{MR,N+2}(A) &= P_{MR,N}(A) \\
&\quad + \left( \binom{N}{\frac{N+1}{2}} \right) P(A) \cdot (1-P(A))^{\frac{N+1}{2}} \cdot \left[ P^{\frac{N+1}{2}}(A) - (1-P(A)) \cdot P^{\frac{N-1}{2}}(A) \right] \\
&= P_{MR,N}(A) \\
&\quad + \left( \binom{N}{\frac{N+1}{2}} \right) P(A) \cdot (1-P(A))^{\frac{N+1}{2}} \cdot \left[ P^{\frac{N+1}{2}}(A) - P^{\frac{N-1}{2}}(A) + P^{\frac{N+1}{2}}(A) \right] \\
&= P_{MR,N}(A) \\
&\quad + \left( \binom{N}{\frac{N+1}{2}} \right) P(A) \cdot (1-P(A))^{\frac{N+1}{2}} \cdot \left[ 2 \cdot P^{\frac{N+1}{2}}(A) - P^{\frac{N-1}{2}}(A) \right] \\
&= P_{MR,N}(A) \\
&\quad + \left( \binom{N}{\frac{N+1}{2}} \right) P(A) \cdot (1-P(A))^{\frac{N+1}{2}} \cdot P^{\frac{N}{2}} \cdot \left[ 2 \cdot P^{\frac{1}{2}}(A) - P^{-\frac{1}{2}}(A) \right]
\end{aligned}$$

$$\begin{aligned}
P_{MR,N+2}(A) &= P_{MR,N}(A) \\
&+ \left( \binom{N}{\frac{N+1}{2}} \right) P(A) \cdot (1-P(A))^{\frac{N+1}{2}} \cdot P^{\frac{N}{2}}(A) \cdot P^{-\frac{1}{2}}(A) \cdot [2 \cdot P(A) - 1] \quad (\text{A.1.12}) \\
&= P_{MR,N}(A) + \left( \binom{N}{\frac{N+1}{2}} \right) \cdot [P(A) \cdot (1-P(A))]^{\frac{N+1}{2}} \cdot [2 \cdot P(A) - 1]
\end{aligned}$$

Damit folgt mit (A.1.12) sowie (A.1.4) und (A.1.6):

$$\begin{aligned}
\frac{\Delta P_{MR}(A)}{P_{MR,N}(A)} &= \frac{P_{MR,N+2}(A) - P_{MR,N}(A)}{P_{MR,N}(A)} \\
&= \frac{\left( \binom{N}{\frac{N+1}{2}} \right) \cdot [P(A) \cdot (1-P(A))]^{\frac{N+1}{2}} \cdot (2 \cdot P(A) - 1)}{\sum_{k=\frac{N+1}{2}}^N \binom{N}{k} P^k(A) \cdot (1-P(A))^{N-k}} \quad (\text{A.1.13})
\end{aligned}$$

## A.2 Berechnung eines Schätzwerts des Korrelationskoeffizienten für zwei Vektoren $\underline{y}$

und  $\underline{z}$  mit  $\dim[\underline{y}] = \dim[\underline{z}] = n$

Empirisches Mittel:

$$m_y = \frac{1}{n} \sum_{i=1}^n y_i \quad (\text{A.2.1})$$

Empirische Varianz:

$$s_y^2 = \frac{1}{n-1} \sum_{i=1}^n \left[ y_i - \frac{1}{n} \sum_{i=1}^n y_i \right]^2 \quad (\text{A.2.2})$$

Empirische Kovarianz:

$$s(y, z) = \frac{1}{n-1} \sum_{i=1}^n \left[ \left( y_i - \frac{1}{n} \sum_{i=1}^n y_i \right) \cdot \left( z_i - \frac{1}{n} \sum_{i=1}^n z_i \right) \right] \quad (\text{A.2.3})$$

$\Rightarrow$

$$\begin{aligned} r_{zy} &= \frac{s(y, z)}{s_y \cdot s_z} \\ &= \frac{\frac{1}{n-1} \sum_{i=1}^n \left[ \left( y_i - \frac{1}{n} \sum_{i=1}^n y_i \right) \cdot \left( z_i - \frac{1}{n} \sum_{i=1}^n z_i \right) \right]}{\sqrt{\frac{1}{n-1} \sum_{i=1}^n \left( y_i - \frac{1}{n} \sum_{i=1}^n y_i \right)^2 \cdot \frac{1}{n-1} \sum_{i=1}^n \left( z_i - \frac{1}{n} \sum_{i=1}^n z_i \right)^2}} \end{aligned}$$

$$\begin{aligned}
r_{zy} &= \frac{\mathbf{s}(y,z)}{\mathbf{s}_y \cdot \mathbf{s}_z} \\
&= \frac{\sum_{i=1}^n y_i \cdot z_i - \sum_{i=1}^n y_i \cdot \frac{1}{n} \sum_{i=1}^n z_i - \sum_{i=1}^n z_i \cdot \frac{1}{n} \sum_{i=1}^n y_i + \sum_{i=1}^n \frac{1}{n} \sum_{i=1}^n y_i \cdot \frac{1}{n} \sum_{i=1}^n z_i}{\sqrt{\left[ \sum_{i=1}^n y_i^2 - \sum_{i=1}^n 2 \cdot y_i \cdot \frac{1}{n} \sum_{i=1}^n y_i + \sum_{i=1}^n \left( \frac{1}{n} \sum_{i=1}^n y_i \right)^2 \right] \cdot \left[ \sum_{i=1}^n z_i^2 - \sum_{i=1}^n 2 \cdot z_i \cdot \frac{1}{n} \sum_{i=1}^n z_i + \sum_{i=1}^n \left( \frac{1}{n} \sum_{i=1}^n z_i \right)^2 \right]}} \\
&= \frac{\sum_{i=1}^n y_i \cdot z_i - \sum_{i=1}^n y_i \cdot \frac{1}{n} \sum_{i=1}^n z_i - \sum_{i=1}^n z_i \cdot \frac{1}{n} \sum_{i=1}^n y_i + n \cdot \frac{1}{n} \sum_{i=1}^n y_i \cdot \frac{1}{n} \sum_{i=1}^n z_i}{\sqrt{\left[ \sum_{i=1}^n y_i^2 - 2 \cdot n \cdot \frac{1}{n} \sum_{i=1}^n y_i \cdot \frac{1}{n} \sum_{i=1}^n y_i + n \cdot \left( \frac{1}{n} \sum_{i=1}^n y_i \right)^2 \right] \cdot \left[ \sum_{i=1}^n z_i^2 - 2 \cdot n \cdot \frac{1}{n} \sum_{i=1}^n z_i \cdot \frac{1}{n} \sum_{i=1}^n z_i + n \cdot \left( \frac{1}{n} \sum_{i=1}^n z_i \right)^2 \right]}} \\
&= \frac{\sum_{i=1}^n y_i \cdot z_i - n \cdot \frac{1}{n} \sum_{i=1}^n y_i \cdot \frac{1}{n} \sum_{i=1}^n z_i - n \cdot \frac{1}{n} \sum_{i=1}^n z_i \cdot \frac{1}{n} \sum_{i=1}^n y_i + n \cdot \frac{1}{n} \sum_{i=1}^n y_i \cdot \frac{1}{n} \sum_{i=1}^n z_i}{\sqrt{\left[ \sum_{i=1}^n y_i^2 - 2 \cdot n \cdot \left( \frac{1}{n} \sum_{i=1}^n y_i \right)^2 + n \cdot \left( \frac{1}{n} \sum_{i=1}^n y_i \right)^2 \right] \cdot \left[ \sum_{i=1}^n z_i^2 - 2 \cdot n \cdot \left( \frac{1}{n} \sum_{i=1}^n z_i \right)^2 + n \cdot \left( \frac{1}{n} \sum_{i=1}^n z_i \right)^2 \right]}} \\
&= \frac{\sum_{i=1}^n y_i \cdot z_i - \frac{1}{n} \sum_{i=1}^n y_i \cdot \sum_{i=1}^n z_i}{\sqrt{\left[ \sum_{i=1}^n y_i^2 - \frac{1}{n} \left( \sum_{i=1}^n y_i \right)^2 \right] \cdot \left[ \sum_{i=1}^n z_i^2 - \frac{1}{n} \left( \sum_{i=1}^n z_i \right)^2 \right]}}
\end{aligned}$$



### A.3 Listing „IDL 3.6.1b“-Programm zum Vergleich Alpha- und Kalman-Filter

```
;
;   Alpha filter, Paul Kalata
;   Kalman filter, R. E. Kalman
;

Pro Alpha_Long

;
;   argument for call to systime
;

arg=4.15

;
;   measurement noise, white gaussian
;

v=randomn(seed,1024)/2.0

;
;   unknown target maneuvers, white gaussian noise
;

w=randomn(seed,1024)/2.0

;
;   some statistical properties of these noises
;   to calculate the (optimal) Alpha value, see Kalata
;

meanv=Total(v)/N_Elements(v)
stdevv=Sqrt(Total((v-meanv)^2/(N_Elements(v)-1)))
meanw=Total(w)/N_Elements(w)
stdevw=Sqrt(Total((w-meanw)^2/(N_Elements(w)-1)))
alpha=stdevw/stdevv

;
;   simulated real state values (xval) and measurement values (yval)
;

xval=fltarr(1024)
yval=fltarr(1024)
xval(0)=1.0
for i=1,1023 do begin
    xval(i)=xval(i-1)+w(i-1)/2.0
    yval(i-1)=xval(i-1)+v(i-1)
endfor
```

```

;
;   Alpha filter
;

alphatime1=systime(arg)
xs=fltarr(1024)
xs(0)=yval(0)
for i=1,1022 do begin
    xs(i)=xs(i-1)+alpha*(yval(i)-xs(i-1))
endfor
alphatime2=systime(arg)

;
;   Kalman filter:
;   xskm=predicted state before new measurement
;   xskp=predicted state after new measurement
;   pm=predicted covariance matrix before ...
;   pp=predicted covariance matrix after ...
;   yt=innovation sequence
;   kk=kalman gain
;

kalmantime1=systime(arg)
xskm=fltarr(1024)
xskp=fltarr(1024)
pm=fltarr(1024)
pp=fltarr(1024)
yt=fltarr(1024)
kk=fltarr(1024)
q=0.6
r=0.4
xskp(0)=yval(0)
pp(0)=1.0
for i=1,1022 do begin
    xskm(i)=xskp(i-1)
    pm(i)=pp(i-1)+q
    yt(i)=yval(i)-xskm(i)
    kk(i)=pm(i)/(pm(i)+r)
    xskp(i)=xskm(i)+kk(i)*yt(i)
    pp(i)=(1.0-kk(i))*pm(i)
endfor
kalmantime2=systime(arg)

;
;   print delta times
;

print,"Time for Alpha [s] =" +string(alphatime2-alphatime1)
print,"Time for Kalman [s] =" +string(kalmantime2-kalmantime1)

```

```

print,(kalmantime2-kalmantime1)/(alphatime2-alphatime1)

;
;   prepare some results
;

alphaf=xs-xval
meanalphaf=Total(alphaf)/N_Elements(alphaf)
stdevalphaf=Sqrt(Total((alphaf-meanalphaf)^2/(N_Elements(alphaf)-1)))
kalmanf=xskp-xval
meankalmanf=Total(kalmanf)/N_Elements(kalmanf)
stdevkalman=Sqrt(Total((kalmanf-meankalmanf)^2/(N_Elements(kalmanf)-1)))

;
;   show some results
;

SET_PLOT,'HP'
DEVICE,FILENAME='C:\FERDI\PRIVAT\HABIL\CHAP4\Real.HPG'
;window,0,title="xval",xsize=512,ysize=256
plot,xval,xrange=[0,511],title="Real"
device,/close

;window,1,title="xs",xsize=512,ysize=256
DEVICE,FILENAME='C:\FERDI\PRIVAT\HABIL\CHAP4\Alpha.HPG'
plot,xs,xrange=[0,511],title="Ergebnisse Alpha-Filter"
device,/close

;window,2,title="xskp",xsize=512,ysize=256
DEVICE,FILENAME='C:\FERDI\PRIVAT\HABIL\CHAP4\Kalman.HPG'
plot,xskp,xrange=[0,511],title="Ergebnisse Kalman-Filter"
device,/close

;window,3,title="ERROR: Alpha - Real",xsize=512,ysize=256
DEVICE,FILENAME='C:\FERDI\PRIVAT\HABIL\CHAP4\AError.HPG'
plot,alphaf,xrange=[0,511],title="Mean =" + string(meanalphaf) + ", Stdev =" + string(stdevalphaf)

;window,4,title="ERROR: Kalman - Real",xsize=512,ysize=256
DEVICE,FILENAME='C:\FERDI\PRIVAT\HABIL\CHAP4\KError.HPG'
plot,kalmanf,xrange=[0,511],title="Mean =" + string(meankalmanf) + ", Stdev =" + string(stdevkalman)
device,/close

;
; Bye
;

End

```

Die Aufrufe von SYSTIME und anschließende Differenzenbildung zeigen für das einfache Beispiel einen für das Kalman-Filter gegenüber dem Alpha-Filter erhöhten Zeitbedarf im Bereich 1.6 bis 1.8.

## A.4 Wavelet-Transformation

Der folgende Abschnitt stellt eine kurze Einleitung zum Thema Wavelets dar. Für detailliertere und weitergehende Darstellungen sei auf die Literatur verwiesen [23, 58, 68].

### Einleitung

Mathematische Transformationen werden auf Signale angewandt, um sie besser weiterverarbeiten zu können, aber auch um Informationen aus diesen gewinnen zu können, die so zunächst nicht erkennbar sind.

Ein erfahrener Kardiologe z.B. kann aus der Form des EKG-Signals schließen, ob eine Abweichung von der typischen Signalform ein Symptom für eine Krankheit ist oder nicht. Neuere EKG-Analysatoren verwenden auch Informationen im Frequenzbereich, die z.B. mit der FFT (Fast Fourier Transformation) gewonnen werden, zu diesen Schlußfolgerungen.

Die Fourier-Transformation gibt - einfach gesagt - Aufschluß darüber, wieviel von jeder Frequenz in einem Zeitsignal enthalten ist, aber sie kann nichts darüber aussagen, wann auf der Zeitachse diese Frequenzkomponenten existieren. Diese Information ist irrelevant, wenn das Signal stationär ist.

Signale, deren Frequenzgehalt über der Zeit konstant ist, werden als stationäre Signale bezeichnet. Für solche Signale gilt die Irrelevanz der Informationen, zu welchen Zeiten Frequenzkomponenten existieren, da alle Frequenzkomponenten zu jeder Zeit existieren.

Angenommen sei das folgende stationäre Signal:

$$x(t) = \cos(2 \cdot \mathbf{p} \cdot 10 \cdot t) + \cos(2 \cdot \mathbf{p} \cdot 25 \cdot t) + \cos(2 \cdot \mathbf{p} \cdot 50 \cdot t) + \cos(2 \cdot \mathbf{p} \cdot 100 \cdot t) \quad (\text{A.4.1})$$

Bild A.4.1 zeigt dieses Signal.

Bild A.4.2 zeigt die Hälfte des symmetrischen Frequenzspektrums des FFT-transformierten Signals.

Im Gegensatz zu Bild A.4.1 zeigt Bild A.4.3 ein Signal mit vier unterschiedlichen Frequenzen zu vier unterschiedlichen Zeitintervallen, d.h. ein nicht-stationäres Signal, und Bild A.4.4 das zu Bild A.4.2 entsprechende.




Bild A.4.1: Signal Gl. (A.4.1)




Bild A.4.2: FFT Signal Gl. (A.4.1)




Bild A.4.3: Signal mit unterschiedlichen Frequenzen zu unterschiedlichen Zeiten




Bild A.4.4: FFT des Signals aus Bild A.4.3

Abgesehen von den Unregelmäßigkeiten in Bild A.4.4 und den unterschiedlichen Amplituden sind die beiden Amplitudenspektren recht ähnlich, obwohl die Ursprungssignale sehr unterschiedlich sind.

Das Beispiel zeigt, daß die Fouriertransformation nicht besonders gut geeignet ist für nicht-stationäre Signale.

Wenn die zeitliche Lokalisierung der Spektralkomponenten von Bedeutung ist, wird eine Transformation zu einer Zeit-Frequenz-Darstellung benötigt.

Prinzipiell wäre für diese Aufgabe auch die Kurzzeitfouriertransformation mit Fensterfunktionen [56] denkbar, jedoch zeigt diese einige auflösungsbezogene Probleme.

Diese können auch durch die Wavelet-Transformation nicht überwunden werden, da sie auf einem physikalischen Phänomen beruhen (Heisenberg'sche Unsicherheit).

Die MRA (Multiresolution Analysis) analysiert ein Signal zu unterschiedlichen Frequenzen mit unterschiedlichen Auflösungen; bei der Kurzzeitfouriertransformation wird jede spektrale Komponente gleich aufgelöst. MRA gibt eine gute Zeit- und eine relativ schlechte Frequenzauflösung bei hohen Frequenzen und eine gute Frequenz- und relativ schlechte Zeitauflösung bei niedrigen Frequenzen. Der Ansatz der MRA macht besonders Sinn für Signale mit kurzzeitigen hochfrequenten Anteilen.

Die kontinuierliche Wavelet-Transformation wurde als Alternative zur Kurzzeitfouriertransformation entwickelt. Das Signal wird mit einer Funktion (das Wavelet) multipliziert, und die Transformation wird separat berechnet für unterschiedliche Segmente des Zeitsignals.

Die kontinuierliche Wavelet-Transformation ist definiert als:

$$CWT_x^y(\mathbf{t}, s) = \Psi_x^y(\mathbf{t}, s) = \frac{1}{\sqrt{s}} \int_{-\infty}^{\infty} x(t) \cdot \mathbf{y}^* \left( \frac{t - \mathbf{t}}{s} \right) dt \quad (\text{A.4.2})$$

wobei  $(^*)$  das konjugiert komplexe Signal andeutet.

Das transformierte Signal ist eine Funktion der zwei Variablen  $\mathbf{t}$  und  $s$ , die Translation und Skalierung (Scale) bezeichnen.  $\mathbf{y}(t)$  ist die transformierende Funktion, das sog. Mother-Wavelet.

Der Ausdruck Wavelet beschreibt eine kleine Welle. Diese Eigenschaft der Welle bezieht sich auf die Bedingung, daß die Funktion von begrenzter Länge ist (Compact Support). Die Welle



selbst zeigt an, daß die Funktion oszilliert. Der Ausdruck Mother-Wavelet beschreibt, daß die Funktionen mit unterschiedlichen Support-Regionen, die in der Transformation genutzt werden, von einer Hauptfunktion abgeleitet sind, dem Mother-Wavelet, das damit eine prototyp-artige Funktion darstellt.

Die Translation bezieht sich auf den Ort der über das Signal geschobenen Funktion. Der Skalierungsparameter der Wavelet-Analyse ist der Skalierung von Landkarten ähnlich. Eine Grobskalierung entspricht einem wenig detaillierten Überblick und eine Feinskalierung einer detaillierten Ansicht. Die Skalierung als mathematische Operation komprimiert das Signal oder zieht es auseinander. In der Wavelet-Transformation steht der Skalierungsfaktor im Nenner der Wavelet-Funktion, d.h., daß Werte von  $s < 1$  das Signal komprimieren und  $s > 1$  expandieren. Wenn das Mother-Wavelet ausgewählt worden ist, beginnt die Berechnung mit  $s = 1$ . Die CWT wird dann für alle Werte von  $s$ , kleiner und größer als 1 durchgeführt. Das Wavelet wird an den Beginn des Signals plziert, der  $t = 0$  entspricht. Die Wavelet-Funktion mit  $s = 1$  wird dann mit dem Signal  $x(t)$  multipliziert. Das multiplizierte Signal wird anschließend über alle Zeiten integriert. Der letzte Schritt der Multiplikation mit  $\sqrt{s}^{-1}$  ist eine Normalisierung, die dafür sorgt, daß das transformierte Signal für jede Skalierung  $s$  dieselbe Energie aufweist. Damit besteht das Ergebnis in dem Punkt des transformierten Signals, der  $t = 0$  und  $s = 1$  in einer Zeit-Skalierung-Ebene entspricht.

Bild A.4.5 zeigt ein beispielhaftes nicht-stationäres Signal und Bild A.4.6 dessen CWT, die mit einem Sombrero-Wavelet berechnet wurde.

Die Sombrero- oder „Mexican Hat“-Funktion ist die zweite Ableitung der Gauß-Funktion:

$$f(t) = \frac{1}{\sqrt{2 \cdot p \cdot s}} \cdot \exp\left\{-\frac{t^2}{2 \cdot s^2}\right\} \quad (\text{A.4.3})$$

nach der Zeit:

$$y(t) = \frac{d^2 f(t)}{dt^2} = \frac{1}{\sqrt{2 \cdot p \cdot s^3}} \cdot \left[ \exp\left\{-\frac{t^2}{2 \cdot s^2}\right\} \cdot \left(\frac{t^2}{s^2} - 1\right) \right] \quad (\text{A.4.4})$$




Bild A.4.5: Nicht-stationäres Signal




Bild A.4.6: CWT des nicht-stationären Signals in Bild A.4.5

## Basisvektoren

Nachdem die CWT nun einleitend beschrieben worden ist, soll die Mathematik der Wavelet-Transformation etwas näher betrachtet werden. Eine ausführlichere Darstellung findet sich z.B. in [68].

Die Fourier-Transformation verwendet zur Analyse und Synthese (Rekonstruktion) von Signalen sog. Basisfunktionen. Jeder Vektor in einem Vektorraum kann als lineare Kombination der Basisvektoren in diesem Vektorraum geschrieben werden, d.h. durch Multiplikation der Vektoren mit bestimmten Koeffizienten und anschließende Summation der Produkte. Die Analyse des Signals beschäftigt sich mit der Bestimmung der Koeffizienten, während die Synthese der Berechnung der Linearkombination entspricht.

Eine Basis eines Vektorraums ist ein Satz von unabhängigen Vektoren so, daß jeder Vektor  $\underline{v}$  als lineare Kombination dieser Basisvektoren geschrieben werden kann. Es kann mehr als eine Basis für einen Vektorraum geben. Alle diese Basen weisen jedoch dieselbe Anzahl von Vektoren auf. Diese Anzahl bezeichnet die Dimension des Vektorraums.

$$\underline{v} = \sum_k v_k \cdot \underline{b}_k \quad (\text{A.4.5})$$

Gl. (A.4.5) beschreibt den Zusammenhang zwischen dem Vektor  $\underline{v}$  und der linearen Kombination aus Basisvektoren  $\underline{b}_k$  und entsprechenden Koeffizienten  $v_k$ .

Dieses Konzept kann recht einfach auf Funktionen verallgemeinert werden, indem die Basisvektoren  $\underline{b}_k$  durch Basisfunktionen  $\mathbf{f}_k(t)$  und der Vektor  $\underline{v}$  durch eine Funktion  $f(t)$  ersetzt wird:

$$f(t) = \sum_k \mathbf{m}_k \cdot \mathbf{f}_k(t) \quad (\text{A.4.6})$$

Angenommen seien zwei Funktionen  $f(t)$  und  $g(t)$ . Das innere Produkt dieser beiden Funktionen ist:

$$\langle f(t), g(t) \rangle = \int_a^b f(t) \cdot g^*(t) dt \quad (\text{A.4.7})$$

wobei  $a$  und  $b$  das Intervall bezeichnen, in dem die Funktionen integrierbar sind.

Entsprechend dieser Definition kann die CWT als inneres Produkt des Signals  $x(t)$  und der Basisfunktionen  $\mathbf{y}_{t,s}(t)$  beschrieben werden:

$$CWT_x^{\mathbf{y}}(t, s) = \Psi_x^{\mathbf{y}}(t, s) = \int_{-\infty}^{\infty} x(t) \cdot \mathbf{y}_{t,s}^*(t) dt \quad (\text{A.4.8})$$

mit:

$$\mathbf{y}_{t,s} = \frac{1}{\sqrt{s}} \cdot \mathbf{y}\left(\frac{t-t}{s}\right) \quad (\text{A.4.9})$$

Diese Definition der CWT zeigt, daß die Wavelet-Analyse ein Ähnlichkeitsmaß zwischen den Basisfunktionen (Wavelets) und dem Signal berechnet. Die berechneten CWT-Koeffizienten beziehen sich auf die Ähnlichkeit des Signals zum Wavelet der gewählten Skalierung.

### **Inneres Produkt, Orthogonalität und Orthonormalität**

Zwei Vektoren  $\underline{v}$  und  $\underline{w}$  mit  $\dim[\underline{v}] = \dim[\underline{w}] = n$  sind dann orthogonal, wenn ihr inneres Produkt (bzw. wenn ihre Korrelationsmatrix) Null ist:

$$\langle \underline{v}, \underline{w} \rangle = \sum_n v_n \cdot w_n^* = 0 \quad (\text{A.4.10})$$

Ähnlich sind zwei Funktionen  $f(t)$  und  $g(t)$  dann orthogonal, wenn ihr inneres Produkt Null ist:

$$\langle f(t), g(t) \rangle = \int_{-\infty}^{\infty} f(t) \cdot g^*(t) dt = 0 \quad (\text{A.4.11})$$

Ein Satz von Vektoren  $\{\underline{v}_1, \underline{v}_2, \dots, \underline{v}_n\}$  wird als orthonormal bezeichnet, wenn die Vektoren paarweise orthogonal zueinander sind und alle die Länge 1 haben. Dies kann wie folgt ausgedrückt werden:

$$\langle \underline{v}_m, \underline{v}_n \rangle = \mathbf{d}_{mn} \quad (\text{A.4.12})$$

Ähnlich wird ein Satz von Funktionen  $\{\mathbf{f}_k(t)\}$ ,  $k = 1, 2, \dots$  als orthonormal bezeichnet, wenn gilt:

$$\int_a^b \mathbf{f}_k(t) \cdot \mathbf{f}_l^*(t) dt = 0, \quad k \neq l \quad (\text{Orthogonalitätsbedingung}) \quad (\text{A.4.13})$$

und:

$$\int_a^b |\mathbf{f}_k(t)|^2 dt = 1 \quad (\text{A.4.14})$$

oder gleichwertig:

$$\int_a^b \mathbf{f}_k(t) \cdot \mathbf{f}_l^*(t) dt = \mathbf{d}_{kl} \quad (\text{A.4.15})$$

mit der Kronecker-Delta-Funktion:

$$\mathbf{d}_{kl} = \begin{cases} 1 & \text{für } k = l \\ 0 & \text{für } k \neq l \end{cases} \quad (\text{A.4.16})$$

Für orthonormale Basen können die Koeffizienten  $\mathbf{m}_k$  berechnet werden durch:

$$\mathbf{m}_k = \langle f(t), \mathbf{f}_k(t) \rangle = \int f(t) \cdot \mathbf{f}_k^*(t) dt \quad (\text{A.4.17})$$

Die Funktion  $f(t)$  kann durch Einsetzen von Gl. (A.4.17) in Gl. (A.4.4) berechnet werden:

$$\begin{aligned} f(t) &= \sum_k \mathbf{m}_k \cdot \mathbf{f}_k(t) \\ &= \sum_k \langle f(t), \mathbf{f}_k(t) \rangle \cdot \mathbf{f}_k(t) \end{aligned} \quad (\text{A.4.18})$$

### Wavelet-Synthese

Die Wavelet-Analyse ist unter bestimmten Bedingungen reversibel. Sind diese erfüllt, kann folgende Rekonstruktionsgleichung angewendet werden:

$$x(t) = \frac{1}{C_y} \int \int \Psi_x^y(\mathbf{t}, s) \cdot \frac{1}{s^2} \cdot \mathbf{y}\left(\frac{t-\mathbf{t}}{s}\right) d\mathbf{t} \cdot ds \quad (\text{A.4.19})$$

wobei  $C_y$  eine Konstante ist, die von dem benutzten Wavelet abhängt:

$$C_y = \left\{ 2 \cdot p \int_{-\infty}^{\infty} \frac{|F\{\mathbf{y}(t)\}|^2}{|\mathbf{x}|} d\mathbf{x} \right\}^{\frac{1}{2}} < \infty \quad (\text{A.4.20})$$

wobei  $F\{\mathbf{y}(t)\}$  die Fouriertransformierte von  $\mathbf{y}(t)$  darstellt.

### Diskretisierung der CWT: Wavelet-Reihe

Bei der Abtastung der Zeit-Skalierung-Ebene kann bei der Wavelet-Transformation die Variation des Skalierungsfaktors  $s$  ausgenutzt werden.

Bei höheren Skalierungen (tieferen Frequenzen) kann die Abtastrate entsprechend Nyquist abgesenkt werden. Wenn die Zeit-Skalierung-Ebene mit einer Abtastrate  $N_1$  bei  $s_1$  abgetastet wird, kann dieselbe Ebene bei  $s_2$  mit einer veränderten Abtastrate  $N_2$  abgetastet werden:

$$N_2 = \frac{s_1}{s_2} N_1 \text{ bzw. } N_2 = \frac{f_2}{f_1} N_1 \quad (\text{A.4.21})$$

Die Diskretisierung unterliegt bzgl. der Analyse des Signals zunächst keinerlei Beschränkung bei der Wahl der Abtastrate. Wenn eine Synthese nicht notwendig ist, muß auch das Nyquist-Kriterium nicht erfüllt sein. Beschränkungen der Diskretisierung und der Abtastrate werden nur dann wichtig, wenn eine Signalsynthese erwünscht bzw. erforderlich ist, da die Abtastrate nach Nyquist die minimal notwendige Abtastrate darstellt, die es erlaubt, das zeitkontinuierliche Signal aus den diskreten Abtastwerten zu rekonstruieren.

Mit den Substitutionen für die Skalierung:

$$s = s_0^j \quad (\text{A.4.22})$$

und für die Translation:

$$t = k \cdot s_0^j \cdot t_0 \quad (\text{A.4.23})$$

wird Gl. (A.4.9) zu:

$$\mathbf{y}_{j,k}(t) = s_0^{-\frac{j}{2}} \cdot \mathbf{y}\left(s_0^{-j} \cdot t - k \cdot t_0\right) \quad (\text{A.4.24})$$

Wenn  $\{\mathbf{y}_{j,k}\}$  eine orthonormale Basis konstituiert, ist die Wavelet-Reihendarstellung:

$$\Psi_x^{\mathbf{y}_{j,k}} = \int x(t) \cdot \mathbf{y}_{j,k}^*(t) dt \quad (\text{A.4.25})$$

bzw.:

$$x(t) = C_{\mathbf{y}} \cdot \sum_j \sum_k \Psi_x^{\mathbf{y}}{}^{j,k} \cdot \mathbf{y}_{j,k}(t) \quad (\text{A.4.26})$$

## Diskrete Wavelet-Transformation

Die Hauptidee bei der DWT (Discrete Wavelet Transform) ist ähnlich wie bei der CWT. Eine Zeit-Skalierung-Darstellung eines digitalen Signals wird durch digitale Filtertechniken erreicht. Die CWT stellt eine Korrelation zwischen einem Wavelet bei unterschiedlichen Skalierungsstufen und einem Signal dar mit der Skalierung bzw. der Frequenz als Ähnlichkeitsmaß. Sie wird berechnet, indem die Skalierung des Analysefensters variiert wird, das Fenster bzgl. der Zeit verschoben wird, eine Multiplikation mit dem Signal durchgeführt und anschließend über alle Zeiten integriert wird. Im diskreten Fall werden Filter mit unterschiedlichen Grenzfrequenzen verwendet, um das Signal bei unterschiedlichen Skalierungsstufen zu analysieren. Das Signal wird durch eine Reihe von Hochpaßfiltern geschickt, um die hohen Frequenzen zu untersuchen, und durch eine Reihe von Tiefpaßfiltern, um die tieferen Frequenzen zu analysieren.

Die Auflösung des Signals, die ein Maß für die Detailinformation in dem Signal darstellt, wird durch die Filteroperationen verändert, während die Skalierung durch Up- und Downsampling variiert wird. Das Sub- oder Downsampling eines Signals entspricht einer Verringerung der Abtastrate und geschieht durch das Entfernen von Abtastwerten des Signals. Z.B. bedeutet ein Subsampling mit Faktor 2 das Entfernen jedes zweiten Abtastwerts. Upsampling entspricht dem umgekehrten Vorgang.

Obwohl es nicht die einzige Möglichkeit ist, werden DWT-Koeffizienten üblicherweise entsprechend Gl. (A.4.22) und Gl. (A.4.23) mit  $s_0 = 2$  und  $t_0 = 1$  abgetastet:

$$\begin{aligned} s &= 2^j \\ \mathbf{t} &= k \cdot 2^j \end{aligned} \quad (\text{A.4.27})$$

Die Verarbeitung beginnt mit einem Halbband-Tiefpaßfilter der Impulsantwort  $h_{TP}(n)$ . Die Faltung entfernt mit dem die halbe Bandbreite der Signalsequenz  $x(n)$  abdeckenden Filter alle Frequenzen, die über der Hälfte des höchsten Frequenzanteils der Signalsequenz liegen.



Die anschließende Subsampling-Operation mit Faktor 2 ergibt dann eine neue Sequenz  $y_{TP}(n)$  mit einer Anzahl, die der Hälfte der Ursprungssequenz entspricht. Die Skalierung ist damit verdoppelt, während die Auflösung um die Hälfte verringert wird.

Diese beiden Schritte können ausgedrückt werden als:

$$y_{TP}(n) = \sum_{k=-\infty}^{\infty} h_{TP}(2 \cdot n - k) \cdot x(k) \quad (\text{A.4.28})$$

Entsprechend wird in einem zweiten Schritt die Ursprungssequenz durch ein Halbband-Hochpaßfilter der Impulsantwort  $h_{HP}(n)$  geleitet. Ein folgendes Subsampling mit Faktor 2 ergibt dann:

$$y_{HP}(n) = \sum_{k=-\infty}^{\infty} h_{HP}(2 \cdot n - k) \cdot x(k) \quad (\text{A.4.29})$$

Die beschriebene Verarbeitung (Subband Coding) kann dann für weitere Dekompositionsschritte weitergeführt werden. Auf jedem Level resultieren Filterung und Subsampling in der Hälfte der Anzahl der Abtastwerte (halbe Auflösung) und der Halbierung des überdeckten Frequenzbandes (Verdopplung der Frequenzauflösung).

Bild A.4.7 illustriert die Verarbeitung.

Die Dekomposition läuft ab, bis nur noch 2 Abtastwerte übrig sind, d.h. für eine vollständige Dekomposition sind  $\log_2(N)$  Schritte notwendig ( $N$  Potenz von 2). Die DWT des Ursprungssignals wird dann erhalten durch Aneinanderreihung aller Koeffizienten, beginnend vom letzten Level der Dekomposition.

Eine wichtige Eigenschaft der DWT ist die Beziehung zwischen den Stoßantworten der Hoch- und Tiefpaßfilter. Die Hoch- und Tiefpaßfilter sind nicht unabhängig voneinander. Sie sind verknüpft durch:

$$h_{HP}(L - 1 - n) = (-1)^n \cdot h_{TP}(n) \quad (\text{A.4.30})$$

mit  $L$  der Filterlänge.

Filter, die diese Bedingung erfüllen, werden als „Quadrature Mirror“-Filter (QMF) bezeichnet.

Zur Rekonstruktion wird der oben beschriebene Prozeß umgekehrt. Die Signale jedes Levels werden mit dem Faktor 2 upgesampled, durch die Synthesefilter geleitet und anschließend addiert.

Ein Beispiel soll die einzelnen Schritte verdeutlichen. Gegeben sei eine Signalsequenz:

$$x(n) = (\dots, x(-1), x(0), x(1), x(2), x(3), \dots) \quad (\text{A.4.31})$$

Faltung mit dem Tiefpaß-Analysefilter (Haar [68]):

$$h_{TP/A}(n) = \frac{1}{\sqrt{2}} \cdot (\mathbf{d}(n) + \mathbf{d}(n-1)) \quad (\text{A.4.32})$$

mit:

$$\mathbf{d}(n) = \begin{cases} 1 & \text{für } n = 0 \\ 0 & \text{für } n \neq 0 \end{cases} \quad (\text{A.4.33})$$

und dem Hochpaß-Analysefilter (Haar [68]):

$$h_{HP/A}(n) = \frac{1}{\sqrt{2}} \cdot (\mathbf{d}(n) - \mathbf{d}(n-1)) \quad (\text{A.4.34})$$

ergibt:

$$\begin{aligned} x_{TP}(k) &= \sum_{n=-\infty}^{\infty} x(n) \cdot h_{TP/A}(k-n) \\ &= \frac{1}{\sqrt{2}} \cdot (\dots, x(-1) + x(0), x(0) + x(1), x(1) + x(2), x(2) + x(3), \dots) \end{aligned} \quad (\text{A.4.35})$$

und:

$$\begin{aligned}
x_{HP}(k) &= \sum_{n=-\infty}^{\infty} x(n) \cdot h_{HP/A}(k-n) \\
&= \frac{1}{\sqrt{2}} (\dots, -x(-1) + x(0), -x(0) + x(1), -x(1) + x(2), -x(2) + x(3), \dots)
\end{aligned} \tag{A.4.36}$$

Downsampling beendet den ersten Zyklus. Die Dezimation entfernt jeden zweiten Wert:

$$\begin{aligned}
y_{TP}(k) &= (\downarrow 2)x_{TP}(k) \\
&= \frac{1}{\sqrt{2}} (\dots, x(-1) + x(0), x(1) + x(2), x(3) + x(4), \dots)
\end{aligned} \tag{A.4.37}$$

$$\begin{aligned}
y_{HP}(k) &= (\downarrow 2)x_{HP}(k) \\
&= \frac{1}{\sqrt{2}} (\dots, -x(-1) + x(0), -x(1) + x(2), -x(3) + x(4), \dots)
\end{aligned} \tag{A.4.38}$$

Der Rekonstruktionsprozeß verläuft wie oben beschrieben. Upsampling von Gl. (A.4.37) und Gl. (A.4.38) fügt 0 zwischen die Komponenten ein:

$$\begin{aligned}
\hat{x}_{TP}(k) &= (\uparrow 2)y_{TP}(k) \\
&= \frac{1}{\sqrt{2}} (\dots, x(-1) + x(0), 0, x(1) + x(2), 0, x(3) + x(4), 0, \dots)
\end{aligned} \tag{A.4.39}$$

$$\begin{aligned}
\hat{x}_{HP}(k) &= (\uparrow 2)y_{HP}(k) \\
&= \frac{1}{\sqrt{2}} (\dots, -x(-1) + x(0), 0, -x(1) + x(2), 0, -x(3) + x(4), 0, \dots)
\end{aligned} \tag{A.4.40}$$

Die Synthese-Filter sind entsprechend den Regeln für „Perfect Reconstruction“ [68]:

$$h_{TP/S}(k) = \frac{1}{\sqrt{2}} \cdot (\mathbf{d}(k) + \mathbf{d}(k-1)) \tag{A.4.41}$$

$$h_{HP/S}(k) = \frac{-1}{\sqrt{2}} \cdot (\mathbf{d}(k) - \mathbf{d}(k-1)) \tag{A.4.42}$$

Faltung von Gl. (A.4.39) mit Gl. (A.4.41) und Gl. (A.4.40) mit Gl. (A.4.42) ergibt:

$$\begin{aligned}\tilde{x}_{TP}(k) &= \sum_{n=-\infty}^{\infty} \hat{x}_{TP}(n) \cdot h_{TP/S}(k-n) \\ &= \frac{1}{2} \cdot (\dots, x(-1) + x(0), x(-1) + x(0), x(1) + x(2), x(1) + x(2), \dots)\end{aligned}\tag{A.4.43}$$

$$\begin{aligned}\tilde{x}_{HP}(k) &= \sum_{n=-\infty}^{\infty} \hat{x}_{HP}(n) \cdot h_{HP/S}(k-n) \\ &= \frac{1}{2} \cdot (\dots, x(-1) - x(0), -x(-1) + x(0), x(1) - x(2), -x(1) + x(2), \dots)\end{aligned}\tag{A.4.44}$$

Durch Addition der Gl. (A.4.43) und Gl. (A.4.44) entsteht die zeitverzögerte Ursprungssequenz.

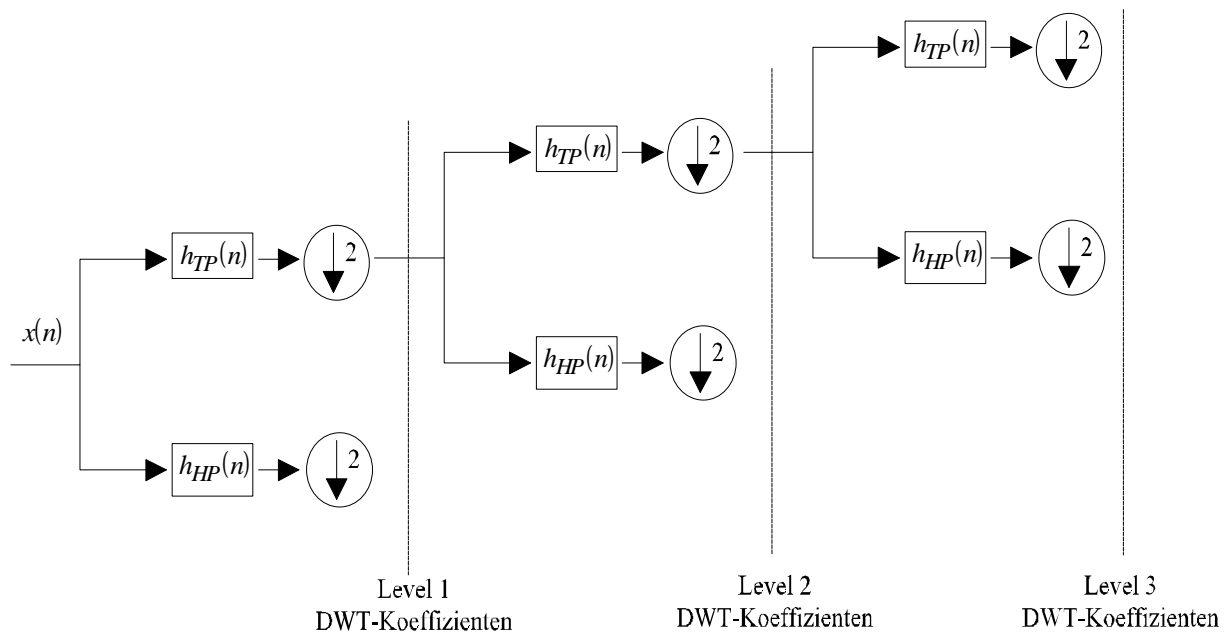


Bild A.4.7

### Herleitung Koeffizienten Daubechies-Filter D4 [58, 68]

Das Leistungsdichtespektrum eines „Halband“-Tiefpaßfilters sei gegeben mit:

$$\begin{aligned}
 P(\Omega) &= |C(\Omega)|^2 \\
 &= (1 + \cos(\Omega))^2 \cdot \left(1 - \frac{1}{2} \cdot \cos(\Omega)\right)
 \end{aligned}
 \tag{A.4.45}$$




Bild A.4.8: Plot Gl. (A.4.45)

Dieses kann in zwei Schritten faktorisiert werden:

Mit  $z = \exp\{j \cdot \Omega\} = \exp\{j \cdot \omega \cdot T\} = \exp\{j \cdot 2 \cdot \mathbf{p} \cdot f \cdot T\}$ :

$$\begin{aligned}
 1 + \cos(\Omega) &= \frac{(1 + \exp\{j \cdot \Omega\}) \cdot (1 + \exp\{-j \cdot \Omega\})}{2} \\
 &= \frac{(1 + z) \cdot (1 + z^{-1})}{2} \\
 &= \frac{1}{2} \cdot (1 + z^{-1} + z + 1) \\
 &= 1 + \frac{z^{-1} + z}{2}
 \end{aligned}
 \tag{A.4.46}$$

$$1 - \frac{1}{2} \cdot \cos(\Omega) = 1 - \frac{1}{4} \cdot (z^{-1} + z) \quad (\text{A.4.47})$$

Dann ist:

$$\begin{aligned} P(\Omega) &= (1 + \cos(\Omega))^2 \cdot \left(1 - \frac{1}{2} \cdot \cos(\Omega)\right) \\ &= 1 + \frac{3}{2} \cdot \cos(\Omega) - \frac{1}{2} \cdot \cos^3(\Omega) \end{aligned} \quad (\text{A.4.48})$$

Die Darstellung in der  $z$ -Ebene ist:

$$\begin{aligned} P(z) &= 1 + \frac{3}{2} \cdot \left(\frac{z^{-1} + z}{2}\right) - \frac{1}{2} \cdot \left(\frac{z^{-1} + z}{2}\right)^3 \\ &= 1 + \frac{3}{4} \cdot (z^{-1} + z) - \frac{1}{16} \cdot (z^{-2} + 2 + z^2) \cdot (z^{-1} + z) \\ &= 1 + \frac{3}{4} \cdot (z^{-1} + z) - \frac{1}{16} \cdot (z^{-3} + z^{-1} + 2 \cdot z^{-1} + 2 \cdot z + z + z^3) \\ &= -\frac{1}{16} \cdot z^3 + \frac{9}{16} \cdot z + 1 + \frac{9}{16} \cdot z^{-1} - \frac{1}{16} \cdot z^{-3} \end{aligned} \quad (\text{A.4.49})$$

Die Zerlegung der beiden Anteile in Gl. (A.4.45) geschieht unter Berücksichtigung von  $|C(\Omega)|^2 = C^*(\Omega) \cdot C(\Omega)$ . Mit Gl. (A.4.46) gilt:

$$|C_1(\Omega)|^2 = (1 + \cos(\Omega))^2 = \left[ \frac{(1 + \exp\{-j \cdot \Omega\}) \cdot (1 + \exp\{j \cdot \Omega\})}{2} \right]^2 \quad (\text{A.4.50})$$

Damit ist:

$$C_1(\Omega) = \left[ \frac{1 + \exp\{-j \cdot \Omega\}}{\sqrt{2}} \right]^2 \quad (\text{A.4.51})$$

Für den Anteil:

$$|C_2(\Omega)|^2 = 1 - \frac{1}{2} \cdot \cos(\Omega) \quad (\text{A.4.52})$$

findet der Ansatz:

$$\begin{aligned} 1 - \frac{1}{2} \cdot \cos(\Omega) &= 1 - \frac{1}{4} \cdot (z^{-1} + z) \\ &= (z_0 + z_1 \cdot z^{-1}) \cdot (z_0 + z_1 \cdot z) \\ &= z_0^2 + z_0 \cdot z_1 \cdot z^{-1} + z_0 \cdot z_1 \cdot z + z_1^2 \end{aligned} \quad (\text{A.4.53})$$

Verwendung. Gl. (A.4.53) ergibt zwei Gleichungen zur Bestimmung von  $z_0$  und  $z_1$ :

$$1 = z_0^2 + z_1^2 \quad (\text{A.4.54})$$

$$-\frac{1}{4} = z_0 \cdot z_1 \quad (\text{A.4.55})$$

Gl. (A.4.55) eingesetzt in Gl. (A.4.54):

$$1 = \frac{1}{16 \cdot z_1^2} + z_1^2 \quad (\text{A.4.56})$$

$$16 \cdot z_1^4 - 16 \cdot z_1^2 + 1 = 0 \quad (\text{A.4.57})$$

Einsetzen der Substitution  $x = z_1^2$  in Gl. (A.4.57) führt auf:

$$\begin{aligned} 16 \cdot x^2 - 16 \cdot x + 1 &= 0 \\ x^2 - x + \frac{1}{16} &= 0 \end{aligned} \quad (\text{A.4.58})$$

Quadratische Ergänzung von Gl. (A.4.58) ergibt:

$$x^2 - x + \left(\frac{1}{2}\right)^2 + \frac{1}{16} - \frac{1}{4} = \left(x - \frac{1}{2}\right)^2 - \frac{3}{16} = 0 \quad (\text{A.4.59})$$

Mit dem Zwischenschritt:

$$\left(x - \frac{1}{2}\right)^2 = \frac{3}{16}$$

wird die Lösung für  $x$  gefunden:

$$x = \frac{1}{4} \cdot (2 \pm \sqrt{3})$$

Auflösen der Substitution  $x = z_1^2$  ergibt:

$$\begin{aligned} z_1 &= \pm \frac{1}{2} \cdot \sqrt{2 \pm \sqrt{3}} = \pm \sqrt{\frac{2 \pm \sqrt{3}}{4}} = \pm \sqrt{\frac{4 \pm 2 \cdot \sqrt{3}}{8}} = \pm \sqrt{\frac{1 \pm 2 \cdot \sqrt{3} + 3}{8}} \\ &= \pm \sqrt{\frac{(1 \pm \sqrt{3})^2}{8}} \\ &= \pm \frac{1 \pm \sqrt{3}}{\sqrt{8}} \end{aligned} \tag{A.4.60}$$

Mit Gl. (A.4.54) resultiert für die zweite Variable der Ansatzgleichung Gl. (A.4.53):

$$\begin{aligned} z_0^2 &= 1 - z_1^2 = 1 - \left(\pm \frac{1 \pm \sqrt{3}}{\sqrt{8}}\right)^2 = 1 - \frac{1}{8} \cdot (1 \pm \sqrt{3})^2 = 1 - \frac{1}{8} \cdot (1 \pm 2 \cdot \sqrt{3} + 3) \\ &= \frac{7 \mp 2 \cdot \sqrt{3} - 3}{8} = \frac{1 \mp 2 \cdot \sqrt{3} + 3}{8} \\ &= \frac{(1 \mp \sqrt{3})^2}{8} \\ z_0 &= \pm \frac{1 \mp \sqrt{3}}{\sqrt{8}} \end{aligned} \tag{A.4.61}$$

Das Ergebnis für den zweiten Anteil in Gl. (A.4.45) ist:



$$C_2(\Omega) = \frac{1+\sqrt{3}}{\sqrt{8}} + \frac{1-\sqrt{3}}{\sqrt{8}} \cdot \exp\{-j \cdot \Omega\} \quad (\text{A.4.62})$$

Multiplikation von  $C_1(z)$  und  $C_2(z)$  führt auf:

$$\begin{aligned} C(z) &= \frac{(1+z^{-1})^2}{2} \cdot \left[ \frac{1+\sqrt{3}}{\sqrt{8}} + \frac{1-\sqrt{3}}{\sqrt{8}} \cdot z^{-1} \right] \\ &= \frac{1}{4 \cdot \sqrt{2}} \cdot \left[ (1+z^{-1})^2 \cdot \left( (1+\sqrt{3}) + (1-\sqrt{3}) \cdot z^{-1} \right) \right] \\ &= \frac{1}{4 \cdot \sqrt{2}} \cdot \left[ \begin{aligned} &(1+\sqrt{3}) + 2 \cdot (1+\sqrt{3}) \cdot z^{-1} + (1+\sqrt{3}) \cdot z^{-2} \\ &+ (1-\sqrt{3}) \cdot z^{-1} + 2 \cdot (1-\sqrt{3}) \cdot z^{-2} + (1-\sqrt{3}) \cdot z^{-3} \end{aligned} \right] \\ &= \frac{1}{4 \cdot \sqrt{2}} \cdot \left[ (1+\sqrt{3}) + (3+\sqrt{3}) \cdot z^{-1} + (3-\sqrt{3}) \cdot z^{-2} + (1-\sqrt{3}) \cdot z^{-3} \right] \end{aligned} \quad (\text{A.4.63})$$

Damit ergeben sich die Koeffizienten des Daubechies-Filter D4 zu:

$$c(0) = \frac{1+\sqrt{3}}{4 \cdot \sqrt{2}}, c(1) = \frac{3+\sqrt{3}}{4 \cdot \sqrt{2}}, c(2) = \frac{3-\sqrt{3}}{4 \cdot \sqrt{2}}, c(3) = \frac{1-\sqrt{3}}{4 \cdot \sqrt{2}} \quad (\text{A.4.64})$$




Bild A.4.9: Darstellung Gl. (A.4.64)

Mit dem „Alternating Flip“ ( $d(k) = (-1)^k c(N - k)$ ;  $N$  ungerade) ergeben sich die Koeffizienten des entsprechenden Hochpaßfilters:

$$d(0) = c(3), d(1) = -c(2), d(2) = c(1), d(3) = -c(0) \quad (\text{A.4.65})$$




Bild A.4.10: Darstellung Gl. (A.4.65)

### Listing IDL 3.6.1b zur Erzeugung Abbildungen 5.3a-5.3i

; "On Multi-Scale Feature Detection Using Filter Banks"

Pro Mscale

; simulated original signal without noise

```
orgsig=dblarr(512)
orgsig(0:255)=0.0
orgsig(130:250)=1.0
orgsig(251:350)=2.0
orgsig(351:400)=3.0
orgsig(401:511)=4.0
```

; simulated original signal with noise

```
r=randomn(seed,512)
noisesig=orgsig+r/5.0
```

; application of Haar wavelet (level 1) to original signal

```
a1kwon=dblarr(512)
b1kwon=dblarr(512)
scc=1.0/sqrt(2.0)
for i=0,510 do begin
    b1kwon(i)=scc*(orgsig(i)-orgsig(i+1))
    a1kwon(i)=scc*(orgsig(i)+orgsig(i+1))
endfor
b1kwon(511)=b1kwon(510)
a1kwon(511)=a1kwon(510)
```

; application of Haar wavelet (level 1) to noisy signal

```
a1kwn=dblarr(512)
b1kwn=dblarr(512)
for i=0,510 do begin
    b1kwn(i)=scc*(noisesig(i)-noisesig(i+1))
    a1kwn(i)=scc*(noisesig(i)+noisesig(i+1))
endfor
b1kwn(511)=b1kwn(510)
a1kwn(511)=a1kwn(510)
```

; scale 1 to signal

```
a2kwon=dblarr(256)
b2kwon=dblarr(256)
```

```

for i=0,255 do begin
    b2kwon(i)=scc*(a1kwon(2*i)-a1kwon(2*i+1))
    a2kwon(i)=scc*(a1kwon(2*i)+a1kwon(2*i+1))
endfor

; scale 2 to signal

a3kwon=dblarr(128)
b3kwon=dblarr(128)
for i=0,127 do begin
    b3kwon(i)=scc*(a2kwon(2*i)-a2kwon(2*i+1))
    a3kwon(i)=scc*(a2kwon(2*i)+a2kwon(2*i+1))
endfor

; scale 3 to signal

a4kwon=dblarr(64)
b4kwon=dblarr(64)
for i=0,63 do begin
    b4kwon(i)=scc*(a3kwon(2*i)-a3kwon(2*i+1))
    a4kwon(i)=scc*(a3kwon(2*i)+a3kwon(2*i+1))
endfor

; scale 4 to signal

a5kwon=dblarr(32)
b5kwon=dblarr(32)
for i=0,31 do begin
    b5kwon(i)=scc*(a4kwon(2*i)-a4kwon(2*i+1))
    a5kwon(i)=scc*(a4kwon(2*i)+a4kwon(2*i+1))
endfor

; scale 5 to signal

a6kwon=dblarr(16)
b6kwon=dblarr(16)
for i=0,15 do begin
    b6kwon(i)=scc*(a5kwon(2*i)-a5kwon(2*i+1))
    a6kwon(i)=scc*(a5kwon(2*i)+a5kwon(2*i+1))
endfor

; scale 1 to noisy signal

a2kwn=dblarr(256)
b2kwn=dblarr(256)
for i=0,255 do begin
    b2kwn(i)=scc*(a1kwn(2*i)-a1kwn(2*i+1))
    a2kwn(i)=scc*(a1kwn(2*i)+a1kwn(2*i+1))
endfor

```

```
; scale 2 to noisy signal
```

```
    a3kwn=dblarr(128)
    b3kwn=dblarr(128)
    for i=0,127 do begin
        b3kwn(i)=scc*(a2kwn(2*i)-a2kwn(2*i+1))
        a3kwn(i)=scc*(a2kwn(2*i)+a2kwn(2*i+1))
    endfor
```

```
; scale 3 to noisy signal
```

```
    a4kwn=dblarr(64)
    b4kwn=dblarr(64)
    for i=0,63 do begin
        b4kwn(i)=scc*(a3kwn(2*i)-a3kwn(2*i+1))
        a4kwn(i)=scc*(a3kwn(2*i)+a3kwn(2*i+1))
    endfor
```

```
; scale 4 to noisy signal
```

```
    a5kwn=dblarr(32)
    b5kwn=dblarr(32)
    for i=0,31 do begin
        b5kwn(i)=scc*(a4kwn(2*i)-a4kwn(2*i+1))
        a5kwn(i)=scc*(a4kwn(2*i)+a4kwn(2*i+1))
    endfor
```

```
; scale 5 to noisy signal
```

```
    a6kwn=dblarr(16)
    b6kwn=dblarr(16)
    for i=0,15 do begin
        b6kwn(i)=scc*(a5kwn(2*i)-a5kwn(2*i+1))
        a6kwn(i)=scc*(a5kwn(2*i)+a5kwn(2*i+1))
    endfor
```

```
ts=dindgen(512)
```

```
for i=0,511 do ts(i)=double(i)
```

```
window,0,xsize=512,ysize=256
```

```
plot,orgsig
```

```
;window,1,xsize=512,ysize=256
```

```
set_plot,'HP'
```

```
device,filename='C:\Ferdinand\Privat\Habil\Zusatz\org.hpg'
```

```
plots,ts,orgsig
```

```
device,/close
```

```
set_plot,'WIN'
```

```
window,2,xsize=512,ysize=256
```

```
plot,abs(b1kwon)
```

```
;window,3,xsize=512,ysize=256
```

```

set_plot,'HP'
device,filename='C:\Ferdì\Privat\Habil\Zusatz\b1kwon.hpg'
plots,ts,abs(b1kwon)
device,/close
set_plot,'WIN'
window,4,xsize=512,ysize=256
plot,noisesig
;window,5,xsize=512,ysize=256
set_plot,'HP'
device,filename='C:\Ferdì\Privat\Habil\Zusatz\noise.hpg'
plots,ts,noisesig
device,/close
set_plot,'WIN'
window,6,xsize=512,ysize=256
plot,abs(b1kwn)
;window,7,xsize=512,ysize=256
set_plot,'HP'
device,filename='C:\Ferdì\Privat\Habil\Zusatz\b1kwn.hpg'
plots,ts,abs(b1kwn)
device,/close
set_plot,'WIN'

```

End

**; "On Multi-Scale Feature Detection Using Filter Banks"**

;

**; Wavelets for Feature Detection**

;

**; NScale.pro**

;

**Pro NScale**

;

; coefficients of D4 filter (Daubechies)

;

    c0=(1.0+sqrt(3.0))/4.0/sqrt(2.0)

    c1=(3.0+sqrt(3.0))/4.0/sqrt(2.0)

    c2=(3.0-sqrt(3.0))/4.0/sqrt(2.0)

    c3=(1.0-sqrt(3.0))/4.0/sqrt(2.0)

;

; number of data points

;

    n=1024

;

; data without noise

;

    xi=dblarr(n)

    for i=0,300 do begin

        xi(i)=0.0

    endfor

```

    for i=301,600 do begin
        xi(i)=1.0
    endfor
    for i=601,800 do begin
        xi(i)=2.0
    endfor
    for i=801,900 do begin
        xi(i)=3.0
    endfor
    for i=901,1023 do begin
        xi(i)=4.0
    endfor
;
; adding white Gaussian noise
;
    r=randomn(seed,1024)
    xi=xi+r/5.0
;
; save data points in xires for later use, xi will be used and changed in calculations
;
    xires=xi

    nmax=n/2-1
    kmax=fix(alog(float(n))/alog(2.0)-1.0)
;
; smooth scales of signal
;
    s=dblarr(kmax,n)
;
; detailed wavelet coefficients
;
    d=dblarr(kmax,n)

    nt=2

;
; it needs kmax "rounds" to calculate all scales, to multiresolve the signal
;
    for k=0,kmax-1 do begin
;
; each "round" has nmax smooth and detail elements
;
        for i=0,nmax do begin
            indmax=2*nmax+1
            index1=2*i
            if index1 gt indmax then begin
                index1=index1-(indmax+1)
            endif
            index2=index1+1
            if index2 gt indmax then begin

```

```

        index2=index2-(indmax+1)
    endif
    index3=index2+1
    if index3 gt indmax then begin
        index3=index3-(indmax+1)
    endif
    index4=index3+1
    if index4 gt indmax then begin
        index4=index4-(indmax+1)
    endif
    s(k,i*nt)=c0*xi(index1)+c1*xi(index2)+c2*xi(index3)+c3*xi(index4)
    d(k,i*nt)=c3*xi(index1)-c2*xi(index2)+c1*xi(index3)-c0*xi(index4)
endfor
;
; preparing for next "round", shifting data points to xi
;
        for i=0,nmax do begin
            xi(i)=s(k,i*nt)
        endfor
;
; only half as many elements in next "round"
;
        nmax=(nmax+1)/2-1
        nt=nt*2
    endfor
;
; show something
;

ts=dindgen(1024)
for i=0,1023 do ts(i)=double(i)
window,0,xsize=512,ysize=256
plot,xires(0:980)
set_plot,'HP'
device,filename='C:\Ferd\Privat\Habil\Zusatz\d4noi.hpg'
plots,ts(0:980),xires(0:980)
device,/close
set_plot,'WIN'
window,1,xsize=512,ysize=256
plot,abs(d(0,0:980))
set_plot,'HP'
device,filename='C:\Ferd\Privat\Habil\Zusatz\d4l1.hpg'
plots,ts(0:980),abs(d(0,0:980))
device,/close
set_plot,'WIN'
window,2,xsize=512,ysize=256
plot,abs(d(1,0:980))
set_plot,'HP'
device,filename='C:\Ferd\Privat\Habil\Zusatz\d4l2.hpg'
plots,ts(0:980),abs(d(1,0:980))

```



```

device,/close
set_plot,'WIN'
window,3,xsize=512,yysize=256
plot,abs(d(2,0:980))
set_plot,'HP'
device,filename='C:\Ferdi\Privat\Habil\Zusatz\d413.hpg'
plots,ts(0:980),abs(d(2,0:980))
device,/close
set_plot,'WIN'
window,4,xsize=512,yysize=256
plot,abs(d(3,0:980))
set_plot,'HP'
device,filename='C:\Ferdi\Privat\Habil\Zusatz\d414.hpg'
plots,ts(0:980),abs(d(3,0:980))
device,/close
set_plot,'WIN'

end

```

**Listing „IDL 3.6.1b“ zur Erzeugung von Bild A.4.6**

**Pro CoWaTr**

```

;
;   Example Continuous Wavelet Transform
;

zp=2.0*!PI

;
;   sigma: Sigma Sombrero function
;

sigma=3.0

f1=1.0
f2=2.0
f3=5.0
f4=10.0

;
;   d_s: delta scale
;   d_tau: delta translation
;   d_t: delta time
;

d_s=0.025
d_tau=0.005

```

```

d_t=4.0*zp/63.0

;
;   function to be CWTed =
;   cos(2Pi f1*t) for 0<arg<2Pi
;   cos(2Pi f2*t) for 2Pi<arg<4Pi
;   cos(2Pi f3*t) for 4Pi<arg<6Pi
;   cos(2Pi f4*t) for 6Pi<arg<8Pi
;   else 0.0
;
;

xf=findgen(64)
for k=0,15 do begin
    xf(k)=cos(zp*f1*k*d_t)
endfor
for k=16,31 do begin
    xf(k)=cos(zp*f2*k*d_t)
endfor
for k=32,47 do begin
    xf(k)=cos(zp*f3*k*d_t)
endfor
for k=48,63 do begin
    xf(k)=cos(zp*f4*k*d_t)
endfor

input_x_int=findgen(64)
input_y_int=findgen(64)
res_int=findgen(64,64)

;
;   i: Scale loop
;
;

for i=0,63 do begin

;
;   j: Translation loop
;
;

    for j=0,63 do begin
        for k=0,63 do begin
            input_x_int(k)=(k*d_t-j*d_tau)/((i+1)*d_s)
            ttau_s=input_x_int(k)
            input_y_int(k)=xf(k)/sqrt(zp)/sigma^3*exp(ttau_s^2/2.0/sigma^2
            )*(ttau_s^2/sigma^2-1.0)
        endfor
        restmp=int_tabulated(input_x_int,input_y_int)
        res_int(i,j)=1.0/sqrt((i+1)*d_s)*restmp
    endfor
endfor

```

```
;
;   show result
;

tax=findgen(64)
xax=findgen(64)
zax=findgen(64)
for i=0,63 do begin
    xax(i)=(i+1)*d_s
    zax(i)=i*d_tau
    tax(i)=i*d_t
endfor

;window,1
device,filename='c:\ferdi\privat\habil\anhang\a46_1.hp'
surface,abs(res_int),xax,zax,az=-50,xtitle='Scale',ytitle='Translation',charsize=2.0
device,/close

End
```

## A.5 Herleitung Gl. (4.77)

Weiterführende Betrachtungen zu der folgenden Herleitung können in „Capellari, J.O.; Velez, C.E.; Fuchs, A.J.: Mathematical Theory of the Goddard Trajectory Determination System, NASA-TM-X-71106, Goddaard Space Flight Center, Greenbelt, Maryland, April 1976“ gefunden werden.

### Problembeschreibung

Es sei ein  $m$ -dimensionaler Vektor  $\underline{y}$  gegeben, der einen Satz von  $m$  Beobachtungen beschreibt. Diese Beobachtungen seien gleich einer bekannten Funktion eines Satzes von  $p$  Parametern, die durch einen  $p$ -dimensionalen Vektor  $\underline{x}$  beschrieben werden, plus additivem Zufallsrauschen  $\underline{n}$ :

$$\underline{y} = f(\underline{x}) + \underline{n} \quad (\text{A.5.1})$$

Das Problem bestehe nun darin, bei gegebenem  $\underline{y}$  den Parametervektor  $\underline{x}$ , die Form von  $f(\cdot)$  und die statistischen Eigenschaften von  $\underline{n}$  zu schätzen. Der Estimationsprozeß versucht, einen Wert für  $\underline{x}$  zu finden, der die gewichtete Summe der Quadrate der Beobachtungsresiduen  $[\underline{y} - f(\underline{x})]$  zwischen den tatsächlichen Beobachtungen und den aus dem mathematischen Modell berechneten Beobachtungen minimiert:

$$l(\underline{x}) = [\underline{y} - f(\underline{x})]^T \cdot W \cdot [\underline{y} - f(\underline{x})] \quad (\text{A.5.2})$$

wobei  $W$  die  $m \times m$ -Gewichtungsmatrix darstellt. Die skalare Funktion  $l(\underline{x})$  bezeichnet die Verlustfunktion. Ein A-Priori-Schätzwert des Zustands  $\underline{x}_0$  sei als verfügbar angenommen. Die Abweichung von  $\underline{x}_0$  von dem wahren Wert des Zustands habe einen Mittelwert von 0 und eine Kovarianz  $P_{\Delta x_0}$ . Der Wert von  $\underline{x}$ , der  $l(\underline{x})$  minimiert, kann durch Lösung von:

$$\frac{\partial l(\underline{x})}{\partial \underline{x}} = -2 \cdot [\underline{y} - f(\underline{x})]^T \cdot W \cdot \frac{\partial f}{\partial \underline{x}} = \underline{0}^T \quad (\text{A.5.3})$$

gefunden werden.

$f(\underline{x})$  kann in eine abgeschnittene Taylor-Reihe um den A-Priori-Schätzwert  $\underline{x}_0$  entwickelt werden:

$$f(\underline{x}) = f(\underline{x}_0) + F \cdot \Delta \underline{x} \quad (\text{A.5.4})$$

mit:

$$\Delta \underline{x} = \underline{x} - \underline{x}_0 \quad (\text{A.5.5})$$

und:

$$F = \left( \frac{\partial f}{\partial \underline{x}} \right)_{\underline{x}=\underline{x}_0} \quad (\text{A.5.6})$$

Der linearisierte Beobachtungsvektor ergibt sich damit zu:

$$\Delta \underline{y} = F \cdot \Delta \underline{x} + \underline{n} \quad (\text{A.5.7})$$

mit:

$$\Delta \underline{y} = \underline{y} - f(\underline{x}_0) \quad (\text{A.5.8})$$

Durch Einsetzen der Gl. (A.5.4) und Gl. (A.5.7) wird Gl. (A.5.3) zu:

$$-2 \cdot [\Delta \underline{y} - F \cdot \Delta \underline{x}]^T \cdot W \cdot F = \underline{0}^T \quad (\text{A.5.9})$$

und kann nach  $\Delta \underline{x}$  aufgelöst werden:

$$\Delta \hat{\underline{x}} = \left( \underline{F}^T \cdot \underline{W} \cdot \underline{F} \right)^{-1} \cdot \underline{F}^T \cdot \underline{W} \cdot \Delta \underline{y} \quad (\text{A.5.10})$$

wobei  $\Delta \hat{\underline{x}}$  einen Schätzwert für  $\Delta \underline{x}$  darstellt. Der aus dem linearisierten System abgeleitete Schätzwert  $\hat{\underline{x}}$  ist dann:

$$\hat{\underline{x}} = \underline{x}_0 + \Delta \hat{\underline{x}} \quad (\text{A.5.11})$$

### **Batch-Estimator-Algorithmus**

Um die Ableitung einer iterativen WLS-Lösung zu vereinfachen, werden die Terme, die abhängig von dieser Iteration sind, im Folgenden mit dem Index „i“ gekennzeichnet.

Damit wird  $\Delta \underline{x}$  in Gl. (A.5.5) zu:

$$\Delta \underline{x}_i = \underline{x} - \hat{\underline{x}}_i \quad (\text{A.5.12})$$

wobei  $\hat{\underline{x}}_i$  den besten Schätzwert im Sinne des WLS-Kriteriums bezeichnet, der aus der i-ten Iteration folgt.

Zu Beginn des Prozesses (0-te Iteration) ist:

$$\hat{\underline{x}}_0 = \underline{x}_0 \quad (\text{A.5.13})$$

der A-Priori-Wert für  $\underline{x}$ . Die Aufgabe besteht darin,  $\hat{\underline{x}}_{i+1}$  aus  $\hat{\underline{x}}_i$  abzuleiten. Die Anfangsannahme, daß der Meßvektor  $\underline{y}$  mit den Zustands- und Modellparametern in Beziehung steht, wird als:

$$\underline{y} = f(\underline{x}, \underline{z}) + \underline{n} \quad (\text{A.5.14})$$

formuliert. Gl. (A.5.14) bezieht sich auf zwei Klassen von Variablen: Der  $p$ -dimensionale Vektor  $\underline{x}$  umfaßt die Zustands- und Modellparameter, deren Werte mit begrenzter Sicherheit

bekannt sind und die geschätzt werden sollen. Der  $q$ -dimensionale Vektor  $\underline{z}$  beschreibt alle Modellparameter, deren Werte mit begrenzter Sicherheit bekannt sind, die aber nicht geschätzt werden sollen. Trotzdem ist die Unsicherheit bzgl.  $\underline{z}$  in den Prozeß einzubeziehen. Die A-Priori-Werte von  $\underline{x}$  und  $\underline{z}$  werden mit  $\underline{x}_0$  und  $\underline{z}_0$  sowie den jeweiligen Kovarianzmatrizen  $P_{\Delta x_0}$  und  $P_{\Delta z_0}$  beschrieben:

$$E\{\underline{x}_0\} = \underline{x}; \quad \text{cov}\{\underline{x}_0 - \underline{x}\} = P_{\Delta x_0} \quad (\text{A.5.15})$$

$$E\{\underline{z}_0\} = \underline{z}; \quad \text{cov}\{\underline{z}_0 - \underline{z}\} = P_{\Delta z_0} \quad (\text{A.5.16})$$

Die Verlustfunktion wird definiert als:

$$l(\underline{x}) = \left[ \underline{y} - f(\underline{x}, \underline{z}_0) \right]^T \cdot W \cdot \left[ \underline{y} - f(\underline{x}, \underline{z}_0) \right] + (\underline{x} - \underline{x}_0)^T \cdot P_{\Delta x_0}^{-1} \cdot (\underline{x} - \underline{x}_0) \quad (\text{A.5.17})$$

Der zweite Term auf der rechten Seite wird addiert, um den besten Schätzwert auf den A-Priori-Wert  $\underline{x}_0$  einzuschränken, wobei der Grad der Beschränkung von der Unsicherheit  $P_{\Delta x_0}$  abhängig ist. Dieser Term zeigt an, daß  $\underline{x}_0$  entsprechend einem durch  $P_{\Delta x_0}$  gegebenen Vertrauensgrad bekannt ist.

Die Linearisierung der Funktion  $f(\cdot)$  in Gl. (A.5.14) ergibt:

$$f(\underline{x}, \underline{z}) = f(\hat{\underline{x}}_i, \underline{z}_0) + F_i \cdot \Delta \underline{x}_i + E_i \cdot \Delta \underline{z}_i \quad (\text{A.5.18})$$

mit:

$$\Delta \underline{x}_i = \underline{x} - \hat{\underline{x}}_i \quad (\text{A.5.19})$$

$$\Delta \underline{z}_i = \underline{z} - \underline{z}_0 \quad (\text{A.5.20})$$

und:

$$F_i = \left( \frac{\mathcal{J}f}{\mathcal{J}\underline{x}} \right)_{\underline{x}=\hat{\underline{x}}_i; \underline{z}=\underline{z}_0} \quad (\text{A.5.21a})$$

$$E_i = \left( \frac{\mathcal{J}f}{\mathcal{J}\underline{z}} \right)_{\underline{x}=\hat{\underline{x}}_i; \underline{z}=\underline{z}_0} \quad (\text{A.5.21b})$$

Da  $\underline{z}$  nicht geschätzt wird, bleiben die Werte dieser Variablen gleich  $\underline{z}_0$ .

Einsetzen der Terme mit nicht verschwindendem Mittelwert aus Gl. (A.5.18) in Gl. (A.5.17) ergibt die linearisierte Verlustfunktion:

$$l(\Delta\underline{x}_i) = \left[ \Delta\underline{y}_i - F_i \cdot \Delta\underline{x}_i \right]^T \cdot W \cdot \left[ \Delta\underline{y}_i - F_i \cdot \Delta\underline{x}_i \right] + \left( \Delta\underline{x}_i - \Delta\underline{\tilde{x}}_i \right)^T \cdot P_{\Delta x_0}^{-1} \cdot \left( \Delta\underline{x}_i - \Delta\underline{\tilde{x}}_i \right) \quad (\text{A.5.22})$$

mit den Meßwertresiduen:

$$\Delta\underline{y}_i = \underline{y} - f(\hat{\underline{x}}_i, \underline{z}_0) \quad (\text{A.5.23})$$

und der Abweichung des A-Priori-Schätzwerts von dem i-ten Schätzwert:

$$\Delta\underline{\tilde{x}}_i = \underline{x}_0 - \hat{\underline{x}}_i \quad (\text{A.5.24})$$

Der Wert von  $\Delta\underline{x}_i$ , der die Verlustfunktion minimiert, ist damit:

$$\Delta\underline{\hat{x}}_{i+1} = \left( F_i^T \cdot W \cdot F_i + P_{\Delta x_0}^{-1} \right)^{-1} \cdot \left[ F_i^T \cdot W \cdot \Delta\underline{y}_i + P_{\Delta x_0}^{-1} \cdot \Delta\underline{\tilde{x}}_i \right] \quad (\text{A.5.25})$$

und der beste Schätzwert:

$$\hat{\underline{x}}_{i+1} = \underline{x}_0 + \sum_{k=1}^{i+1} \Delta\underline{\hat{x}}_k = \hat{\underline{x}}_i + \Delta\underline{\hat{x}}_{i+1} \quad (\text{A.5.26})$$



## Mittelwert und Kovarianz des Schätzwerts

Der beste Schätzwert  $\hat{x}$ , der aus der Konvergenz des Estimationsalgorithmus' resultiert, wird im Folgenden auf seine statistischen Eigenschaften hin untersucht, d.h. auf den Erwartungswert (Mittelwert) und die Kovarianz. Der Erwartungswert der Abweichung  $\Delta\hat{x}$  beschreibt den Bias des Schätzwerts, während die Kovarianz die Unsicherheit aufzeigt. Offensichtlich sind verschwindender Bias und minimale Unsicherheit die gesuchten Qualitäten.

In der folgenden Ableitung wird angenommen, daß die Iteration konvergiert ist, und die nicht indizierten Variablen  $\underline{x}$ ,  $\Delta\underline{x}$ ,  $\Delta\underline{y}$  usw. der konvergierten Lösung entsprechen.

Erwartungswert und Kovarianz des Vektors des Meßrauschens seien:

$$E\{\underline{n}\} = 0 \quad (\text{A.5.27a})$$

$$\text{cov}\{\underline{n}\} = W^{-1} \quad (\text{A.5.27b})$$

und der linearisierte Vektor der Beobachtungsresiduen kann als:

$$\Delta\underline{y} = F \cdot \Delta\underline{x} + E \cdot \Delta\underline{z} + \underline{n} \quad (\text{A.5.28})$$

geschrieben werden.

Daher berechnet sich der Erwartungswert von  $\Delta\underline{y}$ :

$$E\{\Delta\underline{y}\} = E\{F \cdot \Delta\underline{x}\} = F \cdot E\{\Delta\underline{x}\} \quad (\text{A.5.29})$$

mit  $E\{\underline{n}\} = E\{\Delta\underline{z}\} = 0$ .

Die Kovarianz von  $\Delta\underline{y}$  ist:

$$\begin{aligned}
\text{cov}\{\Delta \underline{y}\} &= E\left\{\left[\Delta \underline{y} - E\{\Delta \underline{y}\}\right] \cdot \left[\Delta \underline{y} - E\{\Delta \underline{y}\}\right]^T\right\} \\
&= E \cdot E\{\Delta \underline{z} \cdot \Delta \underline{z}^T\} \cdot E^T + E \cdot E\{\Delta \underline{z} \cdot \underline{n}^T\} + E\{\underline{n} \cdot \Delta \underline{z}^T\} \cdot E^T \\
&\quad + E\{\underline{n} \cdot \underline{n}^T\} \\
&= E \cdot P_{\Delta z_0} \cdot E^T + W^{-1}
\end{aligned} \tag{A.5.30}$$

wobei die Korrelation zwischen  $\Delta \underline{z}$  und dem Meßrauschen zu Null angenommen ist:

$$E\{\Delta \underline{z} \cdot \underline{n}^T\} = 0 \tag{A.5.31}$$

Der Mittelwert des besten Schätzwerts  $\hat{x}_{i+1}$  bestimmt sich mit:

$$\Psi = \left(F^T \cdot W \cdot F + P_{\Delta x_0}^{-1}\right)^{-1} \tag{A.5.32}$$

zu:

$$\begin{aligned}
E\{\hat{x}_{i+1} - \underline{x}\} &= E\{\Delta \hat{x}_{i+1} - \Delta \underline{x}_i\} \\
&= \Psi \cdot \left[F^T \cdot W \cdot E\{\Delta \underline{y}\} + P_{\Delta x_0}^{-1} \cdot E\{\Delta \tilde{x}\} - \Psi^{-1} \cdot E\{\Delta \underline{x}\}\right] \\
&= \Psi \cdot \left[\begin{array}{l} F^T \cdot W \cdot E\{F \cdot \Delta \underline{x} + E \cdot \Delta \underline{z} + \underline{n}\} \\ + P_{\Delta x_0}^{-1} \cdot E\{\Delta \tilde{x}\} - \Psi^{-1} \cdot E\{\Delta \underline{x}\} \end{array}\right] \\
&= \Psi \cdot \left[\begin{array}{l} F^T \cdot W \cdot F \cdot E\{\Delta \underline{x}\} + F^T \cdot W \cdot E \cdot E\{\Delta \underline{z}\} \\ + F^T \cdot W \cdot E\{\underline{n}\} + P_{\Delta x_0}^{-1} \cdot E\{\Delta \tilde{x}\} - \Psi^{-1} \cdot E\{\Delta \underline{x}\} \end{array}\right] \\
&= \Psi \cdot \left[\begin{array}{l} \left(F^T \cdot W \cdot F - F^T \cdot W \cdot F - P_{\Delta x_0}^{-1}\right) \cdot E\{\Delta \underline{x}\} \\ + P_{\Delta x_0}^{-1} \cdot E\{\Delta \tilde{x}\} \end{array}\right] \\
&= \Psi \cdot P_{\Delta x_0}^{-1} \cdot \left[E\{\Delta \tilde{x}\} - E\{\Delta \underline{x}\}\right] \\
&= \Psi \cdot P_{\Delta x_0}^{-1} \cdot E\{\underline{x}_0 - \hat{x}\}
\end{aligned} \tag{A.5.33}$$

Die Kovarianz des Schätzfehlers ist:

$$\begin{aligned}
E \left\{ \begin{array}{l} \left[ \hat{\underline{x}}_{i+1} - \underline{x} \right] \cdot \\ \left[ \hat{\underline{x}}_{i+1} - \underline{x} \right]^T \end{array} \right\} &= E \left\{ \left[ \Delta \hat{\underline{x}}_{i+1} - \Delta \underline{x}_i \right] \cdot \left[ \Delta \hat{\underline{x}}_{i+1} - \Delta \underline{x}_i \right]^T \right\} \\
&= E \left\{ \begin{array}{l} \Psi \cdot \left[ F^T \cdot W \cdot \Delta \underline{y} + P_{\Delta x_0}^{-1} \cdot \Delta \tilde{\underline{x}} - \Psi^{-1} \cdot \Delta \underline{x} \right] \cdot \\ \left[ F^T \cdot W \cdot \Delta \underline{y} + P_{\Delta x_0}^{-1} \cdot \Delta \tilde{\underline{x}} - \Psi^{-1} \cdot \Delta \underline{x} \right]^T \cdot \Psi^T \end{array} \right\} \\
&= E \left\{ \begin{array}{l} \Psi \cdot \left[ \begin{array}{l} F^T \cdot W \cdot (F \cdot \Delta \underline{x} + E \cdot \Delta \underline{z} + \underline{n}) \\ + P_{\Delta x_0}^{-1} \cdot \Delta \tilde{\underline{x}} - \Psi^{-1} \cdot \Delta \underline{x} \end{array} \right] \cdot \\ \left[ \begin{array}{l} F^T \cdot W \cdot (F \cdot \Delta \underline{x} + E \cdot \Delta \underline{z} + \underline{n}) \\ + P_{\Delta x_0}^{-1} \cdot \Delta \tilde{\underline{x}} - \Psi^{-1} \cdot \Delta \underline{x} \end{array} \right]^T \cdot \Psi^T \end{array} \right\} \\
&= E \left\{ \begin{array}{l} \Psi \cdot \left[ \begin{array}{l} (F^T \cdot W \cdot F - \Psi^{-1}) \cdot \Delta \underline{x} \\ + F^T \cdot W \cdot E \cdot \Delta \underline{z} + F^T \cdot W \cdot \underline{n} \\ + P_{\Delta x_0}^{-1} \cdot \Delta \tilde{\underline{x}} \end{array} \right] \cdot \\ \left[ \begin{array}{l} (F^T \cdot W \cdot F - \Psi^{-1}) \cdot \Delta \underline{x} \\ + F^T \cdot W \cdot E \cdot \Delta \underline{z} + F^T \cdot W \cdot \underline{n} \\ + P_{\Delta x_0}^{-1} \cdot \Delta \tilde{\underline{x}} \end{array} \right]^T \cdot \Psi^T \end{array} \right\} \\
&= E \left\{ \begin{array}{l} \Psi \cdot \left[ \begin{array}{l} -P_{\Delta x_0}^{-1} \cdot \Delta \underline{x} + F^T \cdot W \cdot E \cdot \Delta \underline{z} \\ + F^T \cdot W \cdot \underline{n} + P_{\Delta x_0}^{-1} \cdot \Delta \tilde{\underline{x}} \end{array} \right] \cdot \\ \left[ \begin{array}{l} -P_{\Delta x_0}^{-1} \cdot \Delta \underline{x} + F^T \cdot W \cdot E \cdot \Delta \underline{z} \\ + F^T \cdot W \cdot \underline{n} + P_{\Delta x_0}^{-1} \cdot \Delta \tilde{\underline{x}} \end{array} \right]^T \cdot \Psi^T \end{array} \right\} \\
&= \Psi \cdot E \left\{ \begin{array}{l} \left[ \begin{array}{l} P_{\Delta x_0}^{-1} \cdot (\underline{x}_0 - \underline{x}) + F^T \cdot W \cdot E \cdot \Delta \underline{z} \\ + F^T \cdot W \cdot \underline{n} \end{array} \right] \cdot \\ \left[ \begin{array}{l} P_{\Delta x_0}^{-1} \cdot (\underline{x}_0 - \underline{x}) + F^T \cdot W \cdot E \cdot \Delta \underline{z} \\ + F^T \cdot W \cdot \underline{n} \end{array} \right] \end{array} \right\} \cdot \Psi^T
\end{aligned}$$

$$E \begin{Bmatrix} [\hat{x}_{i+1} - \underline{x}] \cdot \\ [\hat{x}_{i+1} - \underline{x}]^T \end{Bmatrix} = \Psi \cdot \left[ \begin{array}{l} P_{\Delta x_0}^{-1} \cdot E \left\{ (\underline{x}_0 - \underline{x}) \cdot (\underline{x}_0 - \underline{x})^T \right\} \cdot P_{\Delta x_0}^{-1} \\ + P_{\Delta x_0}^{-1} \cdot E \left\{ (\underline{x}_0 - \underline{x}) \cdot \Delta \underline{z}^T \right\} \cdot E^T \cdot W \cdot F \\ + P_{\Delta x_0}^{-1} \cdot E \left\{ (\underline{x}_0 - \underline{x}) \cdot \underline{n}^T \right\} \cdot W^T \cdot F \\ + F^T \cdot W \cdot E \cdot E \left\{ \Delta \underline{z} \cdot (\underline{x}_0 - \underline{x})^T \right\} \cdot P_{\Delta x_0}^{-1} \\ + F^T \cdot W \cdot E \cdot E \left\{ \Delta \underline{z} \cdot \Delta \underline{z}^T \right\} \cdot E^T \cdot W \cdot F \\ + F^T \cdot W \cdot E \cdot E \left\{ \Delta \underline{z} \cdot \underline{n}^T \right\} \cdot W \cdot F \\ + F^T \cdot W \cdot E \left\{ \underline{n} \cdot (\underline{x}_0 - \underline{x})^T \right\} \cdot P_{\Delta x_0}^{-1} \\ + F^T \cdot W \cdot E \left\{ \underline{n} \cdot \Delta \underline{z}^T \right\} \cdot E \cdot W \cdot F \\ + F^T \cdot W \cdot E \left\{ \underline{n} \cdot \underline{n}^T \right\} \cdot W \cdot F \end{array} \right] \cdot \Psi^T \quad (\text{A.5.33})$$

Mit den Definitionen:

$$\begin{aligned}
C_{\Delta x_0 \Delta z} &= E \left\{ (\Delta \underline{x} - \Delta \tilde{\underline{x}}) \cdot \Delta \underline{z}^T \right\} \\
&= E \left\{ (\underline{x} - \underline{x}_0) \cdot (\underline{z} - \underline{z}_0)^T \right\} \\
&= E \left\{ (\underline{x}_0 - \underline{x}) \cdot (\underline{z}_0 - \underline{z})^T \right\}
\end{aligned} \quad (\text{A.5.34})$$

$$\begin{aligned}
C_{\Delta x_0 \Delta z}^T &= E \left\{ \Delta \underline{z} \cdot (\Delta \underline{x} - \Delta \tilde{\underline{x}})^T \right\} \\
&= E \left\{ (\underline{z} - \underline{z}_0) \cdot (\underline{x} - \underline{x}_0)^T \right\} \\
&= E \left\{ (\underline{z}_0 - \underline{z}) \cdot (\underline{x}_0 - \underline{x})^T \right\}
\end{aligned} \quad (\text{A.5.35})$$

$$\begin{aligned}
C_{\Delta z n} &= E \left\{ \Delta \underline{z} \cdot \underline{n}^T \right\} \\
&= E \left\{ (\underline{z} - \underline{z}_0) \cdot \underline{n}^T \right\} \\
&= 0
\end{aligned} \quad (\text{A.5.36})$$

$$\begin{aligned}
C_{\Delta z n}^T &= E \left\{ \underline{n} \cdot \Delta \underline{z}^T \right\} \\
&= E \left\{ \underline{n} \cdot (\underline{z} - \underline{z}_0)^T \right\} \\
&= 0
\end{aligned} \quad (\text{A.5.37})$$

$$\begin{aligned}
C_{\Delta x_0 n} &= E\left\{(\Delta \underline{x} - \Delta \tilde{\underline{x}}) \cdot \underline{n}^T\right\} \\
&= E\left\{(\underline{x} - \underline{x}_0) \cdot \underline{n}^T\right\} \\
&= 0
\end{aligned} \tag{A.5.38}$$

$$\begin{aligned}
C_{\Delta x_0 n}^T &= E\left\{\underline{n} \cdot (\Delta \underline{x} - \Delta \tilde{\underline{x}})^T\right\} \\
&= E\left\{\underline{n} \cdot (\underline{x} - \underline{x}_0)^T\right\} \\
&= 0
\end{aligned} \tag{A.5.39}$$

wird Gl. (A.5.33) umformuliert zu:

$$\begin{aligned}
P_{\Delta x} &= E\left\{\left[\Delta \hat{\underline{x}}_{i+1} - \Delta \underline{x}_i\right] \cdot \left[\Delta \hat{\underline{x}}_{i+1} - \Delta \underline{x}_i\right]^T\right\} \\
&= \Psi \cdot \begin{bmatrix} F^T \cdot W \cdot E \cdot P_{\Delta z_0} \cdot E^T \cdot W \cdot F + \Psi^{-1} \\ + F^T \cdot W \cdot E \cdot C_{\Delta x_0 \Delta z}^T \cdot P_{\Delta x_0}^{-1} \\ + P_{\Delta x_0}^{-1} \cdot C_{\Delta x_0 \Delta z} \cdot E^T \cdot W \cdot F \end{bmatrix} \cdot \Psi^T
\end{aligned} \tag{A.5.40}$$

## Literaturverzeichnis

- [1] Aldenderfer, Mark S.; Blashfield, Roger K.: „Cluster Analysis“, in „Quantitative Applications in the Social Sciences“, Sage University Paper 07-044, Sage Publications Ltd., London, 1984, ISBN 0-8039-2376-7
- [2] Arndt, Christoph: „Informationsgewinnung und -verarbeitung in nichtlinearen dynamischen Systemen“, Dissertation, Universität-GH-Siegen, ZESS-Forschungsberichte, Band 2, Shaker-Verlag, Aachen, 1997, ISBN 3-8265-2304-0
- [3] „backscatter“, Newsletter of the Alliance for Marine Remote Sensing, February 1996, „Merging Over-the-Horizon Radar with Satellite Oceanographic Data“, pp. 19-21
- [4] „backscatter“, Newsletter of the Alliance for Marine Remote Sensing, May 1999, San Diego HF Radar User Workshop '99, pp 15, 16 and 25
- [5] Bar-Shalom, Yaakov; Tse, Edison: „Tracking in a Cluttered Environment with Probabilistic Data Association“, Automatica, Volume 11, September 1975, pp. 451-460
- [6] Bessai, Horst: „Sonderprobleme der Nachrichtentechnik“, Vorlesung an der Universität-GH Siegen, SS 1996
- [7] Bowman, Cristopher: „Artificial Neural Network Adaptive Systems Applied to Multisensor ID“, 1988 Proceedings of U.S. Department of Defense Tri-Service Data Fusion Symposium, Johns Hopkins University, Baltimore, Maryland, May 1988, Naval Air Development Center, Warminster, Pennsylvania, pp. 161-172
- [8] Brandt, Siegmund: „Datenanalyse“, Spektrum Akademischer Verlag GmbH Heidelberg - Berlin, 1999, ISBN 3-8274-0158-5
- [9] Bronstejn, Ilja Nikolaevic; Semendjaev, Konstantin Adolfovic: „Taschenbuch der Mathematik“, Verlag Harri Deutsch, Thun, 1984, ISBN 3-87 144-492-8

- [10] Cook, Wade D.; Seiford, Lawrence M.: „R&D Project Selection in a Multidimensional Environment: A Practical Approach“, The Journal of the Operational Research Society, Volume 33, Number 5, May 1982, pp. 397-405, Pergamon Press
- [11] Davidson, Jonathan; Peters, James: „Voice over IP Fundamentals“, Cisco Press, 1999, ISBN: 1-57870-168-6
- [12] Dean, Burton. V.; Nishry, Meir J.: „Scoring and Profitability Models for Evaluating and Selecting Engineering Projects“, J. Oper. Res., Volume 13, Number 4, 1965, pp. 550-569
- [13] Dempster, A. P.: „A Generalization of Bayesian Inference“, Journal of the Royal Statistical Society, Series B (Methodological), Volume 30, 1968, pp. 205-247
- [14] DER SPIEGEL, Nr. 36/2.9.1996, „Lauscher im Datenreich“, pp. 194-211
- [15] DER SPIEGEL, Nr. 34/17.8.1998, „Falsche Werte - falscher Trend“, pp. 145
- [16] DER SPIEGEL, Nr. 34/17.8.1998, „Ins Stocken geraten“, pp. 145
- [17] DER SPIEGEL, Nr.18/3.5.1999, „Schneller Automat“, pp. 222
- [18] Dillard, Robin A.: „Tactical Inferencing with the Dempster-Shafer Theory of Evidence“, 17th Asilomar Conference on Circuits, Systems & Computers, 1983, Pacific Grove, California, ISBN 0-8186-0507-3, IEEE Catalog Number 83CH1939-8, Library of Congress Number 83-81639, IEEE Computer Society Order Number 507, pp. 312-316
- [19] Fortmann, Thomas E.; Bar-Shalom, Yaakov; Scheffe, Molly: „Multi-Target Tracking Using Joint Probabilistic Data Association“, Proceedings 1980 IEEE Conference on Decision and Control, December 1980, pp. 806-812
- [20] Fukunaga, Keinosuke: „Introduction to Statistical Pattern Recognition“, Academic Press, 1990; ISBN 0-12-269851-7

- [21] Gelb, A.: „Applied Optimal Estimation“, THE M.I.T. PRESS, Massachusetts Institute of Technology, Cambridge, Massachusetts, and London, England, 1974, ISBN 0-262-20027-9
- [22] Gower, J. C.: „A General Coefficient of Similarity and Some of its Properties“, Biometrics, Volume 27, 1971, pp. 857-872
- [23] Graps, Amara: „An Introduction to Wavelets“, IEEE Computational Science and Engineering Volume 2, Number 2, 1995
- [24] Hajj, Hazem M.; Nguyen, Truong Q.; Chin, Roland T.: „On Multi-Scale Feature Detection Using Filter Banks“, Proceedings of Asilomar Conference on Signals, Systems & Computers, Los Alamitos, California, 1996
- [25] Hall, David L.: „Mathematical Techniques in Multisensor Data Fusion“, Artech House, Inc., Norwood, Massachusetts, 1992, ISBN: 0-89006-558-6
- [26] Hall, David L.; Llinas, James: „A Survey of Techniques for CIS Data Fusion“, Proceedings of the Second International Conference on Command, Control and Communications Management Information Systems, Bournemouth, UK, IEEE, London, April 1987, pp. 77-84
- [27] Hall, David L.; Nauda, Alexander: „An Interactive Approach for Selecting IR&D Projects“, IEEE Transactions on Engineering Management Volume 37, Number 2, May 1990, pp. 126-133
- [28] Helin, Arthur F.; Souder, William E.: „Experimental Test of a Q-Sort Procedure for Prioritizing R&D Projects“, IEEE Transactions on Engineering Management, Volume EM-21, Number 1, February 1974, pp. 159-164
- [29] Jonuscheit, Horst: „Neuronale Netze in der Produktion“, „Design & Elektronik“ Nr. 19/1996, pp. 22-28, MagnaMedia Verlag AG, München, 1996



- [30] Kalata, Paul R.: „The Tracking Index: A Generalized Parameter for  $\alpha$ - $\beta$  and  $\alpha$ - $\beta$ - $\gamma$  Target Trackers“, IEEE Transactions on Aerospace and Electronic Systems, Volume 20, Number 2, March 1984, pp. 174-182
- [31] Kalman, R. E.: „A New Approach to Linear Filtering and Prediction Problems“, The American Society of Mechanical Engineers, Transactions of the ASME, Series D, Journal of Basic Engineering, Volume 82, Number 1, March 1960, pp. 35-46
- [32] Kalman, R. E.; Bucy, R. S.: „New Results in Linear Filtering and Prediction Theory“, The American Society of Mechanical Engineers, Transactions of the ASME, Series D, Journal of Basic Engineering, Volume 83, Number 1, March 1961, pp. 95-108
- [33] Karnofsky, Ken: „Neural Networks And Character Recognition“, Dr. Dobb's Journal, June 1993, Volume 18, Issue 6, Miller Freeman Inc., 1993
- [34] King-Hele, Desmond: „Theory of Satellite Orbits in an Atmosphere“, Butterworths, London, 1964
- [35] Klaus, Ferdinand: „Entwicklung, Adaption und Analyse von Fixed Interval Kalman Smoothen für die Doppler Centroidestimation beim SAR“, Diplomarbeit am Institut für Nachrichtenverarbeitung der Universität-GH-Siegen, 1990
- [36] Klaus, Ferdinand: „Simulation von Radar-Sensoren mit synthetischer Apertur“, Dissertation, Universität-GH-Siegen, Fortschrittberichte VDI Reihe 8 Nr. 447, VDI-Verlag GmbH, Düsseldorf 1995, ISBN 3-18-344708-8
- [37] Klaus, Ferdinand; Blewonska, Ute F.; Bundschuh, Bernhard: „Flexible, Runtime Efficient Vector-Radix Algorithms For Multidimensional Fast Fourier Transform“, Proceedings of European Symposium on Optics for Productivity in Manufacturing, Frankfurt/Main, Deutschland, 1994
- [38] Klinkrad, Hans-Heinrich: „Analytische Berechnung erdnaheer Satellitenbahnen unter Verwendung eines realistischen Luftwiderstandsmodells“, Dissertation, Braunschweig, 1985

- [39] Knuefermann, Ralf: „Simulation gestörter erdnaheer Satellitenbahnen unter Verwendung realistischer Gravitations- und Luftwiderstandsmodelle sowie stochastischer Störungen“, Diplomarbeit am Institut für Nachrichtenverarbeitung der Universität-GH Siegen, 1992
- [40] Koelsch, James R.: „Sensors - The Missing Link“, Manufacturing Engineering, Volume 105, Number 4, October 1990, pp. 53-56
- [41] Lefferts, Robert E.: „Adaptive Correlation Regions for Alpha-Beta Tracking Filters“, IEEE Transactions on Aerospace and Electronic Systems, Volume 17, Number 6, November 1981, pp. 738-747
- [42] Liebetrau, Albert M.: „Measures of Association“, in the series „Quantitative Applications in the Social Sciences“, Sage University Paper 32, Sage Publications, London, 1983
- [43] Lippman, Richard P.: „An Introduction to Computing Neural Nets“, IEEE Acoustics, Speech, and Signal Processing Magazine, Volume 3, Number 4, 1987, pp. 4-22
- [44] Llinas, James; Waltz, Edward L.: „Multisensor Data Fusion“, Artech House, Inc., Norwood, Massachusetts, 1990, ISBN: 0-89006-277-3
- [45] Loffeld, Otmar: „Estimationstheorie I, Grundlagen und stochastische Konzepte“, „Estimationstheorie II, Anwendungen - Kalman-Filter“, R. Oldenbourg Verlag GmbH, München, 1990, ISBN 3-486-21616-3 und ISBN 3-486-21627-9
- [46] Loffeld, Otmar; Klaus, Ferdinand: „Fixed Interval Kalman Smoothers For The Doppler Centroid Estimation For X-SAR“, pp. 216-221, Modellgestützte Signalverarbeitung: Aachen, 12.-14. September 1990, Proceedings/ASST'90, 7. Aachener Symposium für Signaltheorie, Springer-Verlag Berlin Heidelberg 1990, ISBN 3-540-53124-6
- [47] Lowrance, John D.; Garvey, Thomas D.: „Evidential Reasoning: A Developing Concept“, Proceedings of the International Conference on Cybernetics and Society, October 1982, IEEE, pp. 6-9

- [48] Lüke, Hans Dieter: Signalübertragung: Grundlagen der digitalen und analogen Nachrichtenübertragungssysteme, Springer-Verlag Berlin Heidelberg 1985, ISBN 3-540-15526-0
- [49] Luo, Ren C.; Lin, Ming-Hsiung: „Robot Multi-Sensor Fusion and Integration: Optimum Estimation of Fused Sensor Data“, Proceedings of the 1988 IEEE International Conference on Robotics and Automation, Philadelphia, Pennsylvania, IEEE Computer Society Press, Volume 2, pp. 1076-1081, ISBN 0-8186-0852-8
- [50] Maybeck, Peter S.: „Stochastic Models, Estimation and Control“, Academic Press, Inc., 1979, ISBN 0-12-480701-1
- [51] McGee, Leonard A.; Schmidt, Stanley F.: „Discovery of the Kalman Filter as a Practical Tool for Aerospace and Industry“, NASA Technical Memo 86847, Ames Research Center, California, NTIC, N86-13311, November 1985
- [52] [mull.ccl.umist.ac.uk/teaching/material/5005/node30.html](http://mull.ccl.umist.ac.uk/teaching/material/5005/node30.html)
- [53] Nahin, Paul J.; Pokoski, John L.: „NCTR Plus Sensor Fusion Equals IFFN or Can Two Plus Two Equal Five?“, IEEE Transactions on Aerospace and Electronic Systems, Volume 16, Number 3, May 1980, pp. 320-327
- [54] Nguyen, Truong Q.; Soman, A. K.; Vaidyanathan, P. P.: „A Quadratic-Constrained Least-Squares Approach to Linear-Phase Orthonormal Filter Bank Design“, Proceedings IEEE International Symposium on Circuits and Systems, 1993, pp. 383-386
- [55] Nguyen, Truong Q.: „Digital Filter Bank Design - Quadratic-Constrained Formulation“, IEEE Transactions on Signal Processing, Volume 43, Number 9, September 1995, pp. 2103-2108
- [56] Oppenheim, Alan V.; Schaffer, Ronald W.: „Digital Signal Processing“, Prentice-Hall, Inc., Englewood Cliffs, New Jersey, 1975, ISBN 0-13-214635-5

- [57] Painter, John H.; Kerstetter, David; Jowers, Steve: „Reconciling Steady-State Kalman and Alpha-Beta Filter Design“, IEEE Transactions on Aerospace and Electronic Systems, Vol. 26, No. 6, November 1990, pp. 986-991
- [58] Press, William H.; Teukolsky, Saul A.; Vetterling, William T.; Flannery, Brian P.: „Numerical Recipes in C - The Art of Scientific Computing“, Cambridge University Press, 1992, ISBN 0-521-43108-5
- [59] PV-WAVE User's Guide, Reference Volume 1/2, Programmer's Guide, Unterlagen der Firma Visual Numerics
- [60] Rabiner, Lawrence R.: „A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition“, Proceedings of the IEEE, Vol. 77, No. 2, February 1989, pp. 257-286
- [61] Schrüfer, Elmar: „Signalverarbeitung: Numerische Verarbeitung digitaler Signale“, Carl Hanser Verlag München Wien, 1992, ISBN 3-446-16563-0
- [62] Shafer, Glenn: „A Mathematical Theory of Evidence“, Princeton University Press, Princeton, New Jersey, 1976, ISBN 0-691-08175-1
- [63] Shenoy, Prakash P., Shafer, Glenn: „Propagating Belief Functions with Local Computations“, IEEE Expert, Fall 1986, pp. 43-52
- [64] Shimoda, Haruhisa; Houg, Sun-Pyo; Fukue, Kiyonari; Sakata, Toshibumi: „A Multi-Temporal Classification method using Dempster-Shafer Model“, Proceedings of IGARSS'91 „Remote Sensing: Global Monitoring for Earth Management“, Volume 3, pp. 1831-1833, Espoo, Finland, IEEE Catalog Number 91CH2971-0
- [65] Simon, Wieland: „Neuronale Netze optimieren Produktion und Produkte“, Handelsblatt, 25.05.1999

- [66] Sorensen, Harold W.: „Least-Squares Estimation: From Gauss to Kalman“, IEEE Spectrum, July 1970, pp. 63-68
- [67] Souder, William E.: „A System for Using R&D Project Evaluation Methods“, Research Management, Volume 21, 1978, pp. 29-37
- [68] Strang, Gilbert; Nguyen, Truong Q.: „Wavelets and Filter Banks“, Wellesley-Cambridge Press, Wellesley, Massachusetts, 1996, ISBN 0-9614088-7-1
- [69] Thomopoulos, Stelios C. A.: „Sensor Integration and Data Fusion“, Journal of Robotic Systems, Volume 7, Number 3, June 1990, pp. 337-372
- [70] Thomopoulos, Stelios C. A.: „Theories in Distributed Decision Fusion: Comparison and Generalization“, Proceedings SPIE 1990 on Sensor Fusion III: 3-D Perception and Recognition, Boston, Massachusetts, November 5-9, 1990, pp. 623-634
- [71] Van Brussel, Hendrik; Vandorpe, Jurgen: „An Integrated Control System for Enhanced Autonomous Navigation of Mobile Robots“, Proceedings Second Conference on Mechatronics and Robotics, Duisburg/Moers, September 1993, pp. 297-318
- [72] Vandorpe, Jurgen; Van Brussel, Hendrik; Xu, Hong: „LiAS: A Navigation Architecture for an Intelligent Mobile Robot System“, Special Issue of IEEE Multisensor Fusion and Integration for Intelligent Systems in the Transactions on Industrial Electronics, Volume 43, Number 3, pp. 432-440, 1996
- [73] Vandorpe, Jurgen; Van Brussel, Hendrik: „A Reflexive Navigation Algorithm for an Autonomous Mobile Robot“, Proceedings International Conference on Multisensor Fusion and Integration for Intelligent Systems, October 2-5, 1994, Las Vegas, Nevada, USA, pp. 251-259
- [74] Vandorpe, Jurgen; Van Brussel, Hendrik; Xu, Hong; Aertbelien, E.: „Positioning of the Mobile Robot LiAS using Natural Landmarks and a 2D Range Finder“, Proceedings of the

IEEE/SICE/RSJ International Conference on Multisensor Fusion and Integration for Intelligent Systems, December 8-11, 1996, Washington, D.C., USA, pp. 257-264

- [75] Widrow, Bernard; Winter, Rodney: „Neural Nets for Adaptive Filtering and Adaptive Pattern Recognition“, IEEE Computer, Vol. 21, No. 3, March 1988, pp. 25-40
- [76] Willson, Gregory B.: „Radar classification using a neural network“, Proceedings of SPIE, Applications of Artificial Neural Networks, Volume 1294, April 1990, pp. 200-210, ISBN 0-8194-0345-8
- [77] Winston, Patrick Henry: „Artificial Intelligence“, Addison-Wesley Publishing Company, 1992, ISBN 0-201-53377-4
- [78] Wright, Fred L.: „The Fusion of Multisensor Data“, Signal, October 1980, pp. 39-43
- [79] Xu, H.; Van Brussel, H.; De Schutter, J.; Vandorpe, J.: „Sensor Fusion and Positioning of the Mobile Robot LiAS“, Proceedings of the International Conference on Intelligent Autonomous Systems 4, IAS4, March 27-30, 1995, Karlsruhe, pp. 246-253
- [80] Xu, H.; Vandorpe, J.: „Perception Panning in Mobile Robot Navigation“, Proceedings International Conference on Multisensor Fusion and Integration for Intelligent Systems, October 2-5, 1994, Las Vegas, Nevada, USA, pp. 723-731
- [81] [yoda.cis.temple.edu:8080/UGAIWWW/lectures/dempster.html](http://yoda.cis.temple.edu:8080/UGAIWWW/lectures/dempster.html)
- [82] Zadeh, Lofti A.: „Fuzzy Logic“, Computer by the Computer Society of the IEEE, Volume 21, Number 4, April 1988, pp. 83-92, ISSN 0018-9162
- [83] Zadeh, Lofti A.: „Fuzzy Logic and Approximate Reasoning“, Synthese, Vol. 30, 1975, D. Reidel Publishing Company, Dordrecht-Holland, pp. 407-428

- [84] Zadeh, Lofti A.: „Syllogistic Reasoning in Fuzzy Logic and its Application to Usuality and Reasoning with Dispositions“, IEEE Transactions On Systems Man, And Cybernetics, Volume SMC-15, Number 6, 1985, pp. 754-763
- [85] Zadeh, Lofti A.: „The Role of Fuzzy Logic in the Management of Uncertainty in Expert Systems“, Fuzzy Sets and Systems: An International Journal/International Fuzzy Systems Association, Volume 11, 1983, North-Holland, pp. 199-227