

Informationsfusion zur Umgebungsexploration

Michael Heizmann¹, Ioana Gheța², Fernando Puente León³
und Jürgen Beyerer^{1,2}

¹ Fraunhofer-Institut für Optronik, Systemtechnik und Bildauswertung

IOSB, Fraunhoferstr. 1, D-76131 Karlsruhe

² Karlsruher Institut für Technologie, Institut für Anthropomatik, Lehrstuhl
für Interaktive Echtzeitsysteme, Adenauerring 4, D-76131 Karlsruhe

³ Karlsruher Institut für Technologie, Institut für Industrielle
Informationstechnik, Hertzstr. 16, D-76187 Karlsruhe

Zusammenfassung Die Wahrnehmung und aufgabengerechte Interpretation einer dynamischen Umwelt stellen Schlüsselkomponenten künftiger intelligenter Systeme dar. Die Beherrschung dieser Fähigkeiten erfordert Methoden, die in der Lage sind, aus Messsignalen relevante Informationen zu extrahieren und diese adäquat miteinander zu verknüpfen, um daraus ein semantisch angereichertes Modell der interessierenden Szene zu konstruieren. Der Beitrag widmet sich zwei wichtigen Teilaspekten dieser Aufgabenstellung. Einerseits wird eine Methodik vorgestellt, um aus den verfügbaren Eingangsdaten eine optimale Auswahl zu treffen. Andererseits wird ein objektorientiertes Umweltmodell vorgeschlagen, welches eine laufende Fusion vorhandenen Wissens mit neuen Sensorinformationen gestattet und dies mit einem Gedächtnismodell verknüpft. Sämtliche Verfahren basieren auf der Bayes'schen Statistik in einer objektiven „*Degree of Belief*“-Interpretation. Die Einsatzgebiete der Ansätze werden am Beispiel humanoider Roboter und autonomer Fahrzeuge demonstriert.

1 Einleitung

Autonome technische Systeme haben in den letzten Jahren viele Domänen unseres Alltags erschlossen: Sie sind nicht mehr auf spezielle Umgebungen angewiesen, wie etwa bei Überwachungsaufgaben, in der Produk-

tion oder in der Fernerkundung, sondern übernehmen zunehmend Aufgaben in den Bereichen der Personenassistentz und -pflege, der Reinigung, der Bau- und Landwirtschaft, des Transportes und Individualverkehrs, in Rettungs- und Katastrophenszenarien sowie in der Unterhaltung. Zahlreiche weitere Applikationen befinden sich in der Entwicklung.

Vielen Einsatzgebieten gemeinsam sind eine veränderliche und a priori nur unzureichend bekannte Umgebung sowie die Notwendigkeit, diese Umgebung zu erfassen und zu „verstehen“, um mit ihr interagieren zu können oder um sich innerhalb der Szene sicher zu bewegen.

Man kann erahnen, dass die Umfeldwahrnehmung und -interpretation eine der größten Herausforderungen bei der Lösung derartiger Aufgabenstellungen darstellt. Um eine Inferenz über die dreidimensional ausgeprägte Umwelt zu gestatten, werden gewöhnlich mehrere heterogene Sensoren eingesetzt, die Informationen u. a. in Form von Bildern, akustischen Signalen oder geometrischen Messergebnissen liefern. Es sind daher Mechanismen erforderlich, um aus den Signalen relevante Merkmale zu extrahieren und diese zuverlässig zu klassifizieren. Darüber hinaus müssen Relationen zwischen den erkannten Objekten⁴ erfasst werden und zu einem Lagebild verschmolzen werden. Im Allgemeinen ist die Umwelt dynamisch, weshalb erst die Schätzung der Zustände von Entitäten eine zuverlässige Prognose der Intention der beteiligten Akteure ermöglichen kann.

Der vorliegende Beitrag befasst sich mit Methoden zur multisensoriellen Wahrnehmung und Beschreibung einer dynamischen Umwelt für technische autonome Systeme. Dabei erfolgt eine Fokussierung auf zwei wichtige Komponenten der Informationsverarbeitungskette:

- Im folgenden Abschnitt wird davon ausgegangen, dass ein ausreichender Vorrat an Sensoren und Auswerteverfahren verfügbar ist, aus dem eine Selektion vorgenommen werden muss, um die Eingangsdaten bei den verfügbaren Ressourcen optimal auszuwählen.
- Abschnitt 3 präsentiert ein szenengerechtes objektorientiertes Umweltmodell. Dazu gehören nicht nur Methoden, um Entitäten in der Umwelt samt ihren Attributen und ihren gegenseitigen Relationen zu beschreiben, sondern ebenfalls Mechanismen, um die Qualität

⁴ Um eine Unterscheidbarkeit von realen Objekten und Objekten einer objektorientierten Modellierung zu gewährleisten, werden reale Objekte im Folgenden als „Entitäten“ bezeichnet.

dieser Beschreibung mit zunehmend verfügbaren Sensorinformationen graduell zu verfeinern, sowie ein einfaches Gedächtnismodell für das Lagebild.

Als gemeinsamer theoretischer Unterbau dieser beiden Komponenten fungiert die Bayes'sche Statistik, mit welcher der Wissensstand über die beteiligten Größen in einer objektiven „*Degree of Belief*“-Interpretation modelliert wird. In Abschnitt 4 werden exemplarisch zwei Anwendungsszenarien der vorgestellten Methodik diskutiert. Für andere Aspekte der technischen Kognition, die dieser Beitrag nicht abdecken kann, sei z. B. an die Forschungsaktivitäten im Rahmen der DFG-Exzellenzcluster „Cognition for Technical Systems“ in München [1] sowie „Cognitive Interaction Technology“ in Bielefeld [2] verwiesen.

2 Bayes'sche Auswahlmethodik für Sensorsysteme

Bei der Lösung einer Aufgabe der Informationsgewinnung steht man oft vor der Problematik, dass aus einer Menge von unterschiedlichen Sensorsystemen und Auswertestrategien (im Folgenden zusammengefasst als Informationskanäle bezeichnet) die am besten geeigneten gewählt werden müssen oder eine Kombination erzielt werden muss, um die Fähigkeiten der einzelnen Informationskanäle und verfügbare Ressourcen optimal auszuschöpfen. Um diese Aufgabenstellung zu lösen, wird im Folgenden eine Auswahlmethodik dargestellt, die ein Bayes'sches Kalkül in einer Degree-of-Belief-(DoB-)Interpretation verwendet.

Zunächst werden die für die Aufgabe relevanten Zielgrößen zu einem Zielgrößenvektor \mathbf{z} , $\dim(\mathbf{z}) := \mathcal{Z}$ zusammengefasst. Das aufgabenbezogene Wissen kann probabilistisch in Form von Wahrscheinlichkeitsverteilungen⁵ $\mathbf{p}(\mathbf{z}) := (p(z_1), \dots, p(z_{\mathcal{Z}}))^T$ über den Zielgrößenräumen \mathbf{Z}_i , $i = 1, \dots, \mathcal{Z}$, verkörpert werden.

Das aufgabenbezogene Interesse an den Zielgrößen \mathbf{z} wird mit Hilfe eines Interessensvektors \mathbf{w} , $\dim(\mathbf{w}) = \dim(\mathbf{z})$, $w_i \in \{0, 1\}$ modelliert. Das Interesse an den Zielgrößen lässt sich nun mittels Verteilungen $\mathbf{p}(\mathbf{w}) := (p(w_1), \dots, p(w_{\mathcal{Z}}))^T$ verkörpern. Sie bilden den Wissensbedarf oder Aufklärungsbedarf für die Zielgrößen z_i ab. Der Wert

⁵ Das im Folgenden verwendete Symbol $p(\cdot)$ bezeichnet sowohl Wahrscheinlichkeitsdichtefunktionen für den Fall, dass das Argument kontinuierlich ist, als auch Wahrscheinlichkeitsfunktionen für den Fall, dass das Argument diskret ist.

$p(w_i = 1) = 1 - p(w_i = 0)$ repräsentiert dabei als DoB das Interesse an der entsprechenden Zielgröße z_i .

Als nächstes werden die Informationskanäle definiert und ihr Beitrag zur Bestimmung der Zielgrößen modelliert. Dazu dient der Vektor der Informationskanäle \mathbf{m} , $\dim(\mathbf{m}) := \mathcal{M}$. Diese Modellierung umfasst die Gewinnung der Sensordaten bis zur Auswertung, die eine oder mehrere Zielgrößen zum Ergebnis besitzt. Der Einsatz eines Informationskanals wird mittels der Verteilungen $\mathbf{p}(\mathbf{m}) := (p(m_1), \dots, p(m_{\mathcal{M}}))^T$, $m_i \in \{0, 1\}$, modelliert. Hierbei bezeichnet der Wert $p(m_i = 1) = 1 - p(m_i = 0)$ den Beitrag dieses Informationskanals zur Lösung der Aufgabe, wobei $\sum_{i=1}^{\mathcal{M}} p(m_i = 1) = 1$. Zuletzt werden nun die Sensordaten als \mathbf{d} , $\dim(\mathbf{d}) = \dim(\mathbf{m})$ definiert.

Auf der Grundlage dieser Modellierung lassen sich folgende Fragestellungen beantworten: (1) Welche optimale Kombination der Informationskanäle $\mathbf{p}_{\text{opt}}(\mathbf{m})$ muss gewählt werden, um das bestehende Interesse \mathbf{w} an den Zielgrößen \mathbf{z} zu stillen? (2) Welche Schätzung der Zielgrößen liegt vor, wenn diese optimale oder eine daraus abgeleitete Kombination von Informationskanälen $\mathbf{p}_{\text{beob}}(\mathbf{m})$ gewählt worden ist? (3) Wie lässt sich die Auswahlmethodik für den Fall, dass die Zielgrößen iterativ bestimmt werden müssen (z. B. bei geändertem Interesse oder bei zeitveränderlichen Zielgrößen), erweitern?

Auswahl optimaler Informationskanäle Gesucht wird die optimale Kombination der Informationskanäle $\mathbf{p}_{\text{opt}}(\mathbf{m})$, wobei Vorwissen über die Zielgrößen in Gestalt von A-priori-Verteilungen $p(z_{i,0})$ genutzt werden soll und Wissensbedarf an den Zielgrößen $p(w_i)$ besteht. In einer Bayes'schen Formulierung lässt sich dieses Problem als Aufgabe der Bestimmung der A-posteriori-Verteilungen:

$$p(m_j | w_i, z_{i,0}) = \frac{p(w_i, z_{i,0} | m_j) \cdot p(m_j)}{p(w_i, z_{i,0})} = \frac{p(w_i | z_{i,0}, m_j) \cdot p(z_{i,0} | m_j) \cdot p(m_j)}{p(w_i, z_{i,0})} \quad (12.1)$$

mit $i = 1, \dots, \mathcal{Z}$, $j = 1, \dots, \mathcal{M}$ auffassen.

Dabei modelliert die Verteilung $p(w_i | z_{i,0}, m_j)$ die Aussage, welcher Wissensbedarf (w_i) besteht, wenn Vorwissen ($z_{i,0}$) vorhanden ist und die Informationskanäle (m_j) zum Einsatz kommen. Da der Wissensbedarf unabhängig von den genutzten Informationskanälen ist, kann diese

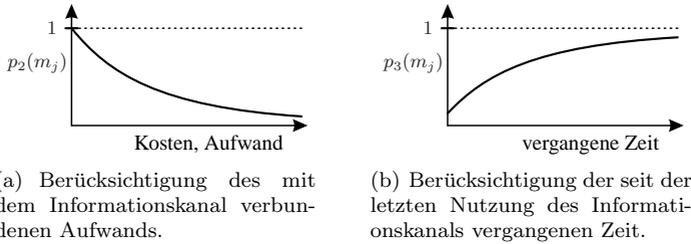


Abbildung 12.1: Modellierung der Einsatzbarkeit eines Informationskanals.

Verteilung zu $p(w_i|z_{i,0}, m_j) = p(w_i|z_{i,0})$ vereinfacht werden. Der Wissensbedarf in Abhängigkeit vom vorhandenen Vorwissen kann nun beispielsweise festgelegt werden durch:

$$p(w_i|z_{i,0}) \propto H(z_{i,0}) \cdot p_1(w_i), \tag{12.2}$$

wobei $H(z_{i,0})$ die Entropie der Verteilung $p(z_{i,0})$ ist und somit die vorhandene Unwissenheit über z_i beschreibt und $p_1(w_i)$ zur Spezifikation des a priori vorhandenen Wissensbedarfs an z_i dient.

Die Verteilung $p(z_{i,0}|m_j)$ verkörpert die Information, was ein Informationskanal (m_j) über eine Zielgröße (z_i) aussagt. Da dies eine Eigenschaft des Informationskanals und nicht des a priori gegebenen Wissensstands ist, gilt:

$$p(z_{i,0}|m_j) = p(z_i|m_j). \tag{12.3}$$

In dieser Verteilung lässt sich modellieren, welche Qualität der Aussage ein Informationskanal über eine Zielgröße erzielen kann.

Die Verteilung $p(m_j)$ beschreibt Eigenschaften des Informationskanals m_j , die nicht mit der konkreten Aufgabe zusammenhängen, und kann im Bayes'schen Sinne als A-priori-Verteilung interpretiert werden. Hier lässt sich etwa modellieren, welche Kosten mit dem Einsatz eines Informationskanals verbunden sind. Eine Modellierung dieser Verteilung wird etwa durch:

$$p(m_j) \propto p_2(m_j) \cdot p_3(m_j) \tag{12.4}$$

erzielt, wobei $p_2(m_j)$ den mit dem Informationskanal verbundenen Aufwand und $p_3(m_j)$ die seit dem letzten Einsatz des Kanals vergangene

Zeit bewertet. Eine mögliche Wahl beider Verteilungen ist in Abb. 12.1 dargestellt. Dabei verringert der abfallende Verlauf von $p_2(m_j)$ das Gewicht eines Informationskanals mit steigendem Aufwand für die Informationsgewinnung. Der auf niedrigem Wert beginnende und mit der Zeit anwachsende Verlauf von $p_3(m_j)$ stellt sicher, dass unterschiedliche Informationskanäle in zeitlicher Abfolge zum Zuge kommen.

Die Auswahl der optimalen Informationskanäle kann nun durch Summation über die Dimension der Zielgröße \mathcal{Z} erfolgen:

$$\mathbf{p}_{\text{opt}}(\mathbf{m}) = (p_{\text{opt}}(m_1), \dots, p_{\text{opt}}(m_{\mathcal{M}}))^T \quad \text{mit} \quad (12.5)$$

$$p_{\text{opt}}(m_j) := \lambda \sum_{i=1}^{\mathcal{Z}} p(m_j | w_i, z_{i,0}), \quad (12.6)$$

wobei unter Vernachlässigung des Nenners von Gl. (12.1) die Wahl einer geeigneten Konstanten λ sicherstellt, dass die Normierungsbedingung $\sum_{j=1}^{\mathcal{M}} p_{\text{opt}}(m_j = 1) = 1$ eingehalten wird.

Können z. B. aufgrund begrenzter Ressourcen oder Zeitbeschränkungen nicht alle möglichen Informationskanäle genutzt werden, lässt sich der Einsatz der Informationskanäle entsprechend ihrer DoB $p_{\text{opt}}(m_j = 1)$ priorisieren. Auf diese Weise ist sichergestellt, dass die in Bezug auf die Aufgabe und das zur Verfügung stehende Vorwissen optimale Auswahl getroffen wird. Aus der nach abfallendem Wert für $p_{\text{opt}}(m_{(k)} = 1)$ sortierten Liste können z. B. die ersten $N < \mathcal{M}$ Informationskanäle verwendet werden. Man erhält dann die Beiträge der zur Beobachtung genutzten Informationskanäle zu:

$$p_{\text{beob}}(m_{(k)}) := \kappa \cdot p_{\text{opt}}(m_{(k)}), \quad k = 1, \dots, N, \quad (12.7)$$

wobei die Konstante κ wiederum die Erfüllung der Normierungsbedingung $\sum_{k=1}^N p_{\text{beob}}(m_{(k)} = 1) = 1$ gewährleistet.

Schätzung der Zielgrößen Die interessierenden Zielgrößen lassen sich nach erfolgter Nutzung der Informationskanäle durch gewichtete Überlagerung der jeweiligen kanal- und zielgrößenspezifischen A-posteriori-Verteilungen $p(z_i | d_j)$ gewinnen:

$$p(z_i) := \sum_{k=1}^N p_{\text{beob}}(m_{(k)} = 1) \cdot p(z_i | d_{(k)}). \quad (12.8)$$

Iterative Vorgehensweise Die dargestellte Methodik zur Auswahl von Informationskanälen und zur Bestimmung der Zielgrößen lässt sich iterativ umsetzen. Dazu werden die beiden Schritte abwechselnd ausgeführt. Im ersten Schritt wird die optimale Kombination von Informationskanälen nach Gl. (12.1) zu:

$$p(m_j^t | w_i^t, z_i^{t-1}) = \frac{p(w_i^t | z_i^{t-1}, m_j^t) \cdot p(z_i^{t-1} | m_j^t) \cdot p(m_j^t)}{p(w_i^t, z_i^{t-1})} \quad (12.9)$$

bestimmt, wobei der Index $t \in \mathbb{N}$ den Iterationsschritt angibt und z_i^{t-1} das zum vorherigen Zeitschritt erzielte Wissen repräsentiert. Nach der oben dargestellten Vorgehensweise werden daraus die Beiträge der Informationskanäle mittels $p_{\text{beob}}(m_{(k)}^t)$ modelliert. Im zweiten Schritt lassen sich nach Gl. (12.8) die gesuchten Zielgrößen bestimmen:

$$p(z_i^t) := \sum_{k=1}^N p_{\text{beob}}(m_{(k)}^t = 1) \cdot p(z_i^t | d_{(k)}^t). \quad (12.10)$$

3 Umweltmodellierung

Viele Systeme, die zur Umweltinteraktion Information akquirieren, benötigen zusätzlich zu den eigentlichen Sensoren und Informationskanälen auch einen Speicher, in dem die gewonnenen Informationen abgelegt und bei Bedarf wieder abgerufen werden können. Bei solchen Systemen – wie z. B. autonomen humanoiden Robotern zur Unterstützung des Menschen (siehe Abschnitt 4.1) – stellt dieser Speicher ein Gedächtnis dar, in dem ein zeitbezogenes Modell der Umgebung enthalten ist. Damit wird dem autonomen System die Möglichkeit geboten, zu jeder Zeit einen aufgabenbezogenen Überblick über das aktuelle Geschehen in seiner relevanten Umgebung zu gewinnen.

Ein derartiger Speicher kann mittels einer dynamischen objektorientierten Umweltmodellierung erstellt werden. Der Speicher wird dann zu einer Art *digitalem Sandkasten*, der virtuelle Stellvertreter realer Objekte („Entitäten“) der Umwelt enthält. In dieser virtuellen Welt modellieren Instanzen von Klassen die realen Entitäten, die bestimmten Objektarten zugeordnet werden können, siehe Abb. 12.2.

Attribute und Relationen von Entitäten in der realen Welt werden mittels Sensoren erfasst. Die im Umweltmodell als Eigenschaften von Instan-

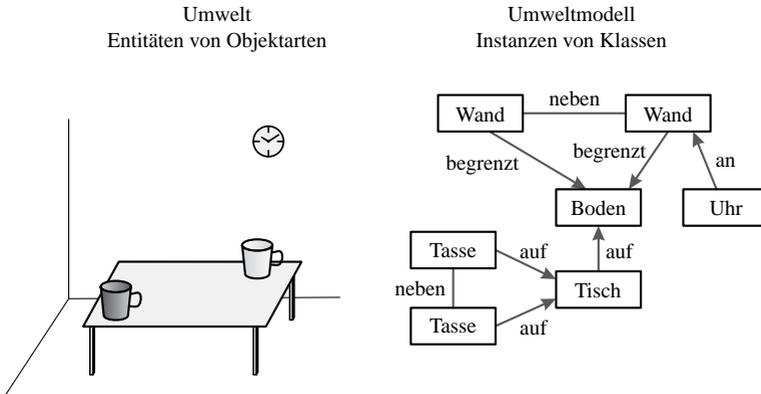


Abbildung 12.2: Zusammenhang zwischen realer Welt und Umweltmodell.

zen abgelegten Attribute und Relationen werden im Folgenden zur Vereinfachung Informationen genannt und entsprechen den in Abschnitt 2 eingeführten Zielgrößen.

Das in Abschnitt 3.1 dargestellte Umweltmodell ist der zentrale Kern der Umweltmodellierung. Zusätzlich werden Mechanismen auf Basis von Methoden der Bayes'schen Fusion eingeführt, welche die im Umweltmodell abgelegten Informationen auf der Grundlage sensorischer und anderer Information verändern, siehe Abschnitte 3.3 und 3.4.

3.1 Objektorientiertes Umweltmodell

Für die Umweltmodellierung wird ein objektorientierter Ansatz verfolgt, bei dem alle im Modell gespeicherten Informationen mit Unsicherheiten versehen sind. Die gespeicherten Informationen weisen einen Zeitbezug auf, so dass das Umweltmodell die Umgebung des Systems zu einem bestimmten Zeitpunkt repräsentiert.

Objekte besitzen klassenbezogene Eigenschaften, z. B. Position, Größe, Farbe oder andere relevante Größen. Klassen, die im Umweltmodell eingesetzt werden, sind kontextabhängig und können entsprechend der aktuellen Aufgabe definiert werden.

Als Basiselement für das Umweltmodell dient die schlank gehaltene Klasse der Blanko-Objekte, die zumindest das Attribut *Existenz* besit-

zen. Instanzen dieser Klasse dienen als Platzhalter für Informationen: Beispielsweise können räumliche Bereiche als belegt gekennzeichnet werden, um Kollisionen zu vermeiden. Dafür ist nur das Attribut *Position* zusätzlich zur *Existenz* notwendig. Instanzen von Blanko-Objekte können bei Bedarf durch Instanzen anderer Klassen ersetzt werden: Findet eine Klassifikation statt, wird zusätzlich das Attribut *Typ* spezifiziert und die Instanz der entsprechenden Klasse zugeordnet, was wiederum die Spezifizierung klassenspezifischer Attribute bewirkt. Zusätzlich können mittels Blanko-Objekten abstrakte Informationen modelliert werden, z. B. Geräusche, deren Quelle nicht identifiziert werden konnte.

Relationen zwischen Entitäten sind wie Attribute unsicherheitsbehaltet und werden im Umweltmodell in ähnlicher Weise behandelt.

3.2 Modellierung von Unsicherheiten

Jede Information wird im Umweltmodell zusammen mit einer Unsicherheit abgelegt, welche die Qualität der Information quantifiziert. Zwei Arten von Informationen fließen in das Umweltmodell ein: Sensorielle Information, die vom System dynamisch akquiriert wird (z. B. durch Exploration), und A-priori-Information, die dem System als Vorwissen zur Verfügung steht (z. B. als Plan der Umgebung). Sensorielle Information wird i. d. R. mittels einer Beobachtungsunsicherheit charakterisiert. A-priori-Information wird meist mittels externer Sensoren gewonnen oder kann als Zusatzwissen (z. B. Klassenwissen) eingespeist werden.

Unsicherheiten können auf unterschiedliche Arten angegeben werden:

- Zunächst kann die Information über eine einzige Größe (Attribut oder Relation) parametrisch als wahrscheinlichster Wert mit einem zugeordneten Streuparameter angegeben werden. Eine derartige Aussage ist etwa: „Die Entität A hat die wahrscheinlichste Höhe z_0 mit einer Varianz von σ_z^2 .“ Der Vorteil einer derartigen Modellierung liegt in der Sparsamkeit der zu spezifizierenden Parameter.
- Soll die Unsicherheit einer einzigen Größe umfassend angegeben werden, kann dies durch Angabe einer Wahrscheinlichkeitsverteilung über den Bereich möglicher Werte der jeweiligen Größe erfolgen, z. B. für das Beispiel der Höhenangabe $p(z)$. Aus einer parametrischen Angabe von erwartetem Wert und Streuparameter lässt

sich die zugehörige Wahrscheinlichkeitsverteilung mittels des Prinzips der maximalen Entropie eindeutig ermitteln [3, 4]. Im obigen Beispiel erhält man z. B. die Normalverteilung $\mathcal{N}(z_0; \sigma_z)$.

- Werden mehrere Größen (Attribute oder Relationen) gemeinsam betrachtet, kann die Spezifikation ihrer Unsicherheit zunächst unabhängig voneinander mittels parametrischer Modellierung (z. B. bei zwei Positionsattributen $\mathcal{N}((x_0, y_0), (\sigma_x, \sigma_y))$) oder zweier (unabhängig angenommener) Marginalverteilungen ($p(x, y) = p(x) \cdot p(y)$) erfolgen.
- Die Unsicherheit mehrerer Größen lässt sich umfassend mittels Verbundverteilungen (im Beispiel $p(x, y)$) angeben. Diese explizite Angabe hat den Nachteil, dass sie sehr aufwändig ist: Für alle Wertekombinationen der beteiligten Größen muss die Wahrscheinlichkeit ermittelt und gespeichert werden.

Die probabilistische Modellierung der Unsicherheit ermöglicht neben der frequentistischen Interpretation in der Statistik die Interpretation von Wahrscheinlichkeiten als Degree-of-Belief (DoB, Grad des Dafürhaltens) im Bayes'schen Sinne [5–7]. Der DoB-Formalismus besitzt folgende wesentliche Vorteile:

- Unsicherheiten lassen sich einheitlich beschreiben: Alle Möglichkeiten zum Ausdruck einer Unsicherheit können mittels des Prinzips der maximalen Entropie in eine entsprechende DoB-Repräsentation umgewandelt werden.
- Attribute und Relationen, die unterschiedlichen Skalen angehören, lassen sich gleichwertig behandeln: Über Attribute und Relationen aller möglichen Skalen – Nominal-, Ordinal-, Interval-, Verhältnis- und Absolutskala – können entsprechende Wahrscheinlichkeitsverteilungen modelliert werden [6].
- Sowohl objektive als auch subjektive Information lassen sich in gleicher Weise quantifizieren [8].
- Bewährte Bayes'sche Fusionsmechanismen können angewendet werden [7].
- Inkonsistenzen lassen sich innerhalb des Bayes'schen Formalismus behandeln. Sich widersprechende Informationen können durch Angabe von Unsicherheiten mittels DoB-Verteilungen im Gegensatz zu anderen strengen Formalismen fusioniert werden.

Als Beispiel dienen zwei Beobachtungen von zylindrischen Objekten, die sich in einem Abstand von 1 mm befinden und deren Durchmesser jeweils 10 cm beträgt. Ein strenger Formalismus ohne Berücksichtigung von Unsicherheiten müsste die Informationen als widersprüchlich einstufen, da sich zwei Objekte nicht durchdringen können. Beim Einsatz von DoBs könnte eine Beobachtungsunsicherheit beispielsweise mittels einer Varianz $(\sigma_x, \sigma_y) = (1 \text{ cm}, 1 \text{ cm})$ angegeben werden. Somit wird die Interpretation ermöglicht, dass beide Instanzen durch Beobachtungen derselben Entität entstanden sind.

3.3 Bayes'sche Propagation

Das Umweltmodell gibt die Umgebung des Systems zu einem bestimmten Zeitpunkt wieder. Für die Berücksichtigung von Änderungen der Umgebung und neu hinzugekommener Information wird das Umweltmodell über die Zeit entwickelt. Dafür werden Methoden der Bayes'schen Informationsfusion eingesetzt, welche die DoB-Verteilungen von einem Zeitpunkt t_{i-1} zum nächsten Zeitpunkt t_i propagieren. Zwei Einflussfaktoren können dazu das Umweltmodell ändern: Neue Information wird akquiriert und in das Modell eingebracht, und schon vorhandene Information altert. Zur Erläuterung werden diese Propagationsmechanismen im Weiteren am Beispiel des Attributs *Existenz* dargestellt. Die Vorgehensweise ist für andere Attribute und Relationen analog.

Instanziierung Falls neue Information über Entitäten und deren Attribute und Relationen beobachtet wird, die keine Entsprechung im Umweltmodell besitzt (d. h. es existiert keine Instanz der beobachteten Entität), wird eine Instanz der entsprechenden Klasse in das Umweltmodell eingefügt. Die Entscheidung über die Instanziierung wird anhand einer A-posteriori-DoB für die jeweilige Information getroffen. Im Fall des Attributs *Existenz* wird eine Instanz erzeugt. Bei anderen Attributen und Relationen werden diese bereits bestehenden Instanzen zugeordnet.

Ausgehend von der Existenzwahrscheinlichkeit $p(O = o)$, dass eine Entität in der realen Welt existiert, und der Wahrscheinlichkeit $p(O = \bar{o}) = 1 - p(O = o)$, dass die Entität nicht existiert, können folgende bedingte DoBs definiert werden [9]:

- Die bedingte Wahrscheinlichkeit $p(D = o|O = o) = p_E$ beschreibt die Wahrscheinlichkeit für einen *Treffer*, d. h. die Entität existiert und wird beobachtet.
- Die bedingte Wahrscheinlichkeit $p(D = \bar{o}|O = o) = 1 - p_E$ beschreibt die Wahrscheinlichkeit für einen *Fehlschlag*, d. h. die Entität existiert, wird aber nicht beobachtet.
- Die bedingte Wahrscheinlichkeit $p(D = o|O = \bar{o}) = p_F$ gibt die Wahrscheinlichkeit für einen *falschen Alarm* an, d. h. eine Entität existiert nicht, es findet aber eine Beobachtung statt.
- Die bedingte Wahrscheinlichkeit $p(D = \bar{o}|O = \bar{o}) = 1 - p_F$ beschreibt die Wahrscheinlichkeit für eine *korrekte Rückweisung*, d. h. eine Entität existiert nicht und wird auch nicht beobachtet.

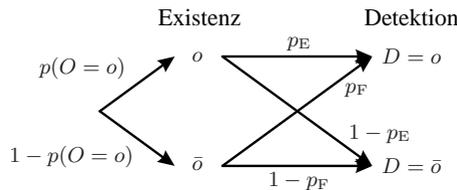


Abbildung 12.3: Schematischer Zusammenhang zwischen Existenz und Detektion von Entitäten.

Die Kombination aus den Wahrscheinlichkeiten der Existenz und der Beobachtung ergibt vier Möglichkeiten, siehe Abb. 12.3. Falls der A-posteriori-DoB der Existenz einer Entität einen festgelegten Schwellwert der Initialisierung γ_i überschreitet, wird eine Instanz bzw. ein Attribut oder eine Relation entsprechend der Beobachtung erzeugt:

$$\begin{aligned}
 p(O = o|D = o) &= \frac{p(D = o|O = o) \cdot p(O = o)}{p(D = o)} \\
 &= \frac{1}{1 + \frac{1-p(o)}{p(o)} \frac{p_F}{p_E}} > \gamma_i.
 \end{aligned}
 \tag{12.11}$$

Propagation durch Alterung Beim Übergang von einem Zeitpunkt t_{i-1} zum nachfolgenden Zeitpunkt t_i (mit $t_i - t_{i-1} = \Delta t = \text{const.}$) wird die

im Umweltmodell enthaltene Information einem Alterungsprozess unterzogen. Da durch die Alterung das Wissen über die Umwelt abnimmt und somit die vorhandene Unsicherheit erhöht wird, muss die Propagation so definiert werden, dass die Existenzwahrscheinlichkeit über die Zeit abnimmt und die Entropie der DoB-Verteilungen von Attributen und Relationen über die Zeit erhöht wird. Ein konkreter Alterungsmechanismus für die *Existenz* kann etwa mittels einer exponentiell abnehmenden Funktion dargestellt werden:

$$p_{t_i}^-(O = o) := \beta \cdot p_{t_{i-1}}(O = o), \quad (12.12)$$

wobei $0 < \beta \leq 1$ eine klassenspezifische Konstante ist und $p_{t_i}^-(O = o)$ die Existenzwahrscheinlichkeit nach dem Alterungsschritt bezeichnet. Schnell veränderliche Information (z. B. die Existenz eines Apfels) wird durch einen kleinen Wert für β charakterisiert, so dass diese Information in kurzer Zeit unsicherer wird. Im Gegensatz dazu wird beständige Information (z. B. die Existenz eines Schanks) mit einem höheren Wert für β versehen, so dass deren Unsicherheit langsamer ansteigt.

Propagation bei neu akquirierter Information Falls mittels Sensoren neu akquirierte Information eine Entsprechung im Umweltmodell besitzt, wird die neue Information zur alten Information unter Berücksichtigung der jeweiligen Unsicherheiten fusioniert.

Grundlage ist die rekursive Bayes'sche Fusion, bei der eine auf Basis der $i-1$ vorhergehenden Beobachtungen D_{i-1}, \dots, D_0 erzeugte A-priori-DoB-Verteilung $p(O|D_{i-1}, \dots, D_0)$ mit neu hinzukommender Information in Form einer Likelihood-Funktion $p(D_i|O)$ aktualisiert wird [10, 11]:

$$\begin{aligned} p(O|D_i, \dots, D_0) &= \frac{p(D_i, \dots, D_0|O) \cdot p(O)}{p(D_i, \dots, D_0)} \\ &= \frac{p(D_i|O) \cdot p(O|D_{i-1}, \dots, D_0)}{p(D_i|D_{i-1}, \dots, D_0)}. \end{aligned} \quad (12.13)$$

Dabei repräsentiert $p(O)$ das Vorwissen, bevor eine Beobachtung erfolgt ist. $p(D_i|D_{i-1}, \dots, D_0)$ ist die Wahrscheinlichkeit, dass die i -te Beobachtung gemacht wird und hat die Rolle eines Normalisierungsfaktors.

Zur Propagation wird als A-priori-DoB-Verteilung das Ergebnis des Alterungsschritts verwendet. Die Beobachtungen D_{i-1}, \dots, D_0 erhalten

einen Zeitbezug zu den Zeitpunkten t_{i-1}, \dots, t_0 . Die Aktualisierung der DoB-Verteilung wird somit zu:

$$p_{t_i}(O) := p_{t_i}(O|D) = \frac{p(D_i|O) \cdot p_{t_i}^-(O)}{p(D_i|D_{i-1}, \dots, D_0)}. \quad (12.14)$$

Dabei ist $p_{t_i}(O)$ die gesuchte A-posteriori-DoB-Verteilung, $p(D_i|O)$ beschreibt die Beobachtung für den Zeitpunkt t_i und $p_{t_i}^-(O)$ ist das Ergebnis des Alterungsprozesses der DoB-Verteilung nach Gl. (12.12), das die Rolle einer A-priori-Verteilung bei der Bayes'schen Fusion einnimmt. Mit $D = \{D_0, \dots, D_i\}$ werden die Beobachtungen bis zum Zeitpunkt t_i zusammengefasst.

Findet zum Zeitpunkt t_i keine neue Beobachtung statt, wird das Ergebnis des Alterungsschrittes unverändert übernommen:

$$p_{t_i}(O) := p_{t_i}^-(O). \quad (12.15)$$

Löschen von Informationen Um das Umweltmodell schlank zu halten, ist es notwendig, veraltete oder zu unsichere Informationen zu löschen. Für die Entscheidung, ob die Löschung einer Instanz erfolgen soll, wird die DoB-Verteilung der *Existenz* herangezogen. Falls der DoB der *Existenz* kleiner ist als ein gegebener Schwellwert, wird die Instanz aus dem Umweltmodell gelöscht:

$$p_{t_i}(O) < \gamma_e, \quad (12.16)$$

wobei γ_e der Schwellwert für das Löschen ist und $\gamma_e < \gamma_i$. Der Wert des DoBs der *Existenz* kann unter den Schwellwert γ_e durch Alterung nach Gl. (12.12) oder durch Fusion mit neu akquirierter Information, welche die Existenz der zugehörigen Entität nicht bestätigt, nach Gl. (12.14) sinken.

Die Differenz zwischen γ_i und γ_e ist notwendig, um eine Hysterese sicherzustellen, siehe Abb. 12.4. Eine Instanz soll nicht unmittelbar nach deren Erzeugung wieder gelöscht werden.

Ein weiterer Schwellwert γ_r mit $\gamma_e < \gamma_r < \gamma_i$ kann als Auslöser für die Wiederbestätigung der Existenz einer Entität eingefügt werden. Wird eine Entität nicht zufällig erneut beobachtet, kann damit eine Wiederbestätigung seiner Existenz explizit ausgelöst werden. Die Differenz zwischen

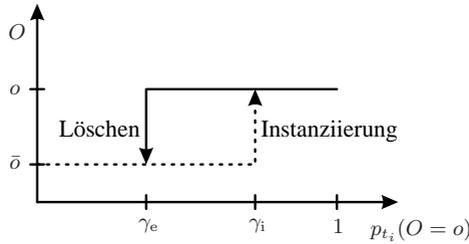


Abbildung 12.4: Hysterese für die Instanziierung und das Löschen von Instanzen.

γ_r und γ_i erzeugt einen Zeitpuffer, in dem eine Entität auch ohne erneute Beobachtung als existierend angenommen wird. Der Zeitpuffer ist vor allem bei schnell veränderlichen Informationen von Vorteil, um ständige Wiederbestätigungsanforderungen an die Sensorik zu vermeiden.

Abbildung 12.5 zeigt das Beispiel eines Lebenszyklus der Instanz einer schnell veränderlichen Entität anhand des DoBs seines Attributs *Existenz*. Die Strichlinie beschreibt die Propagation des DoBs mittels des Alterungsmechanismus nach Gl. (12.12), falls keine erneute Beobachtung erfolgt. Die durchgezogene Linie stellt den Verlauf des DoBs dar, falls zu den Zeitpunkten t_j und t_k die Existenz der Entität durch erneute Beobachtungen wiederbestätigt wird. Zuletzt findet keine Wiederbestätigung der Existenz statt, so dass der DoB zum Zeitpunkt t_l den Schwellwert γ_e für das Löschen erreicht. Die Instanz wird dann aus dem Umweltmodell entfernt.

3.4 Abstraktionsniveaus

Die im Umweltmodell enthaltenen Informationen werden unterschiedlichen Abstraktionsniveaus zugeordnet: Eine Instanz, die sehr detailliert durch ihre Klasse und die jeweiligen Attribute und Relationen beschrieben ist, befindet sich auf einem niedrigen Abstraktionsniveau. Im Gegensatz dazu befinden sich Instanzen, für die eine geringe Anzahl von Attributen und Relationen bekannt sind, auf höheren Abstraktionsniveaus. Die abstrakteste Information im Umweltmodell wird durch Blanko-Objekte dargestellt, die nur das Attribut *Existenz* besitzen.

Das Abstraktionsniveau einer Instanz kann sich mit zunehmender

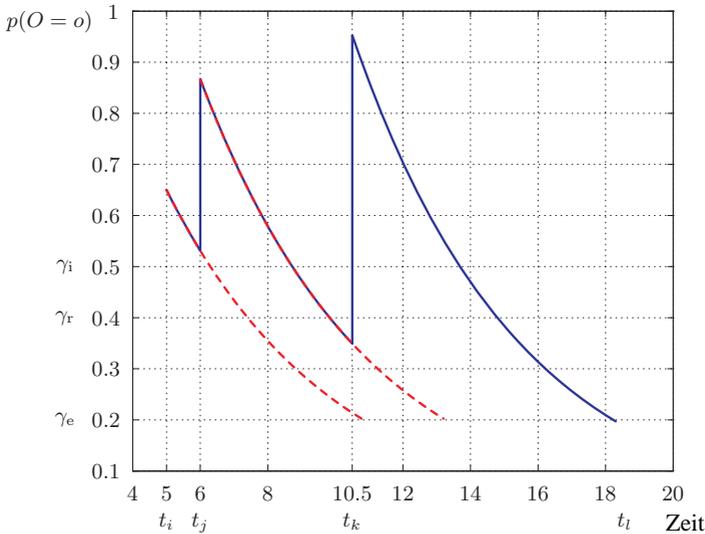


Abbildung 12.5: Beispielhafter Lebenszyklus der Instanz einer schnell veränderlichen Entität.

Information ändern: Je mehr Attribute und Relationen über eine Instanz bekannt sind, desto niedriger wird ihr Abstraktionsniveau. Abbildung 12.6 stellt die Abstraktionsniveaus als Pyramide dar. An der Spitze der Pyramide liegt mit den Blanko-Objekten die abstrakteste Information. Das unterste Niveau ist mit Instanzen unterschiedlicher Klassen belegt, deren Attribute und Relationen vollständig spezifiziert sind.

Abstraktionsniveaus erfüllen für die Anwendbarkeit des Umweltmodells eine wichtige Voraussetzung: Sie definieren einen Detailliertheitsgrad der Information, der je nach Aufgabe des Systems verwendet werden kann. Für die Bahnplanung ist beispielsweise nur Information bezüglich des freien Raums notwendig. Diese Information entspricht einem hohen Abstraktionsniveau, da für die Aufgabe nur die Attribute *Position* und *Ausdehnung* relevant sind. Im Gegensatz dazu sind für eine Greifaufgabe detaillierte Attribute (z. B. *3D-Gestalt* oder *Greifmöglichkeit*) und Relationen (z. B. *steht auf*) der entsprechenden Instanz erforderlich. Solche Informationen entsprechen einem niedrigeren Abstraktionsniveau.

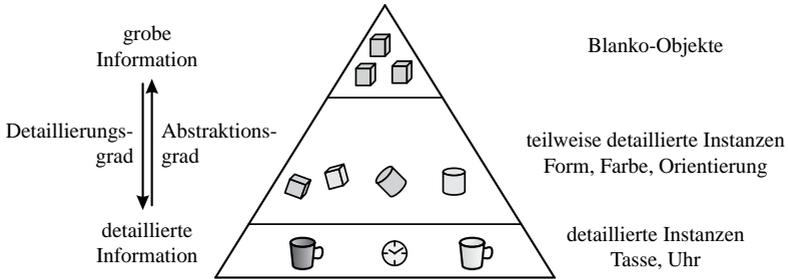


Abbildung 12.6: Abstraktionsniveaus im Umweltmodell.

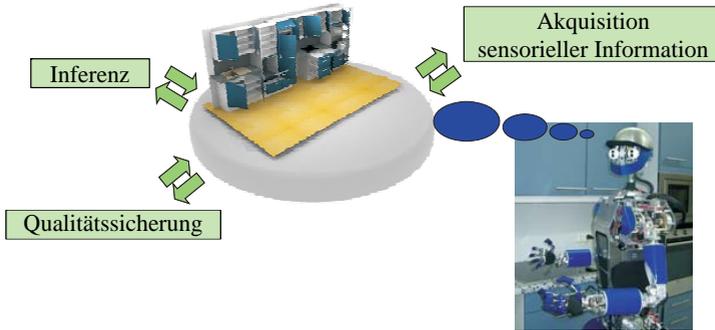


Abbildung 12.7: Anwendungsbeispiel des Umweltmodells im SFB 588.

4 Anwendungen

4.1 Humanoide Roboter

Ein Beispiel für Systeme, die eine ständige Informationsakquisition zur Interaktion mit ihrer Umgebung benötigen, sind autonom agierende Roboter. Der SFB 588 „Humanoide Roboter – Lernende und kooperierende multimodale Roboter“ [12] hat sich als Ziel die Entwicklung eines humanoiden Roboters gesetzt, der dem Menschen z. B. im Haushalt zur Hilfe kommen kann. Für die Erfüllung dieser Aufgabe benötigt der Roboter einen umfassenden Überblick über das Geschehen in seiner Umgebung. Um dies zu gewährleisten, wurden die Bayes’sche Auswahlmethodik für Sensorsysteme aus Abschnitt 2 und das in Abschnitt 3 beschriebene Um-

weltmodell eingesetzt. Details bezüglich der Implementierung der Konzepte zur Umweltmodellierung im Kontext der humanoiden Roboter werden in [13] ausführlich erklärt.

Das entwickelte Umweltmodell mit seinen Eigenschaften bildet die zentrale kognitive Komponente des humanoiden Roboters. Es fungiert als Informationsdrehzscheibe, in welche die von den Sensoren des Roboters akquirierten Informationen eingebracht, propagiert und gleichzeitig anderen kognitiven Prozessen zur Verfügung gestellt werden. Beispielsweise greifen Inferenzprozesse zur Bahnplanung für die Exploration oder zur Entscheidungsfindung auf diese Informationen zurück, siehe Abb. 12.7.

4.2 Autonome Fahrzeuge

Im Bereich der autonomen Fahrzeuge befasst sich mit dem SFB/Transregio 28 „Kognitive Automobile“ [14] ein weiterer DFG-Sonderforschungsbereich mit Fragestellungen der Umfeldwahrnehmung und Situationsinterpretation. Ein wesentliches Ziel des interdisziplinär ausgelegten Vorhabens ist die Erforschung der maschinellen Kognition für mobile Systeme als Grundlage „intelligenten“ Handelns. Abbildung 12.8 zeigt den dafür vom Institut für Mess- und Regelungstechnik des Karlsruher Instituts für Technologie entwickelten Versuchsträger „AnnieWAY“ [15].

Als Informationsdrehzscheibe fungiert in diesem Fall die echtzeitfähige Datenbank KogMo-RTDB [16]. Diese gewährleistet sämtlichen Softwareprozessen – Sensordatenerfassung, Signalverarbeitung und Umfeldwahrnehmung, Situationsbewertung sowie Verhaltensgenerierung – einen schnellen Zugriff auf die benötigten Eingangsdaten, die allesamt mit Zeitstempeln versehen sind, und nimmt anschließend die verarbeiteten Ergebnisobjekte entgegen. Aus Performancegründen ist die Datenbank rein Hauptspeicherbasiert.

Zur Bahnplanung bedarf es einer Unterscheidung zwischen Straßen und unstrukturierten Bereichen. Zur kollisionsfreien Navigation ist darüber hinaus eine Kenntnis des freien befahrbaren Raums erforderlich, wofür die Dynamik potentieller Hindernisse zu berücksichtigen ist. Aus diesem Grund wird für die verkehrsrelevanten Entitäten das Attribut *Beweglichkeit* ergänzt, um statische und dynamische Entitäten zu unterscheiden. Eine höherer Detaillierungsgrad wird benötigt, um etwa im Falle einer unvermeidlichen Kollision eine Handlungsentscheidung im Sinne einer Risiko- oder Schadensminimierung treffen zu können.

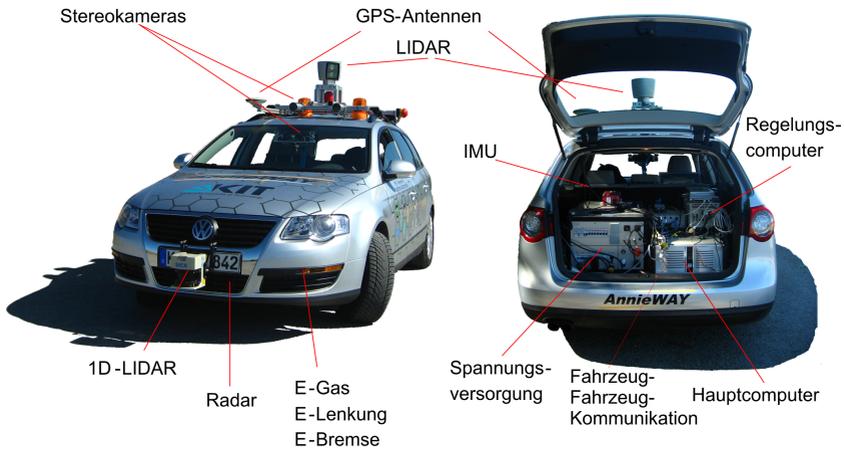


Abbildung 12.8: Versuchsträger AnnieWAY (Quelle: Team AnnieWay [15]).

5 Zusammenfassung

Im Beitrag wurden zwei wichtige Komponenten im Kontext der Wahrnehmung und aufgabengerechten Interpretation einer dynamischen Umwelt vorgestellt. Mittels eines Bayes'schen Ansatzes werden die für eine bestimmte Applikation am besten geeigneten Informationskanäle ausgewählt. Andererseits dient ein objektorientiertes Umweltmodell als Informationsdrehscheibe, mit deren Hilfe sämtliche informationsverarbeitenden Prozesse das Wissen bezüglich der aufgabenrelevanten Entitäten sowie ihrer Relationen adäquat repräsentieren, teilen und ergänzen können. Sämtliche Informationen werden in einer Interpretation als Grad des Dafürhaltens spezifiziert, was den Einsatz Bayes'scher Fusions- und Inferenzmethoden ermöglicht. Weitere Mechanismen der Datenkonsistenz und der Qualitätssicherung sorgen für die gute Eignung des Modells zur Wissensrepräsentation in intelligenten autonomen Systemen.

Literatur

1. „Cognition for Technical Systems“, <http://www.cotesys.org/>, Verfügbar am 10.02.2010.

2. „Cognitive Interaction Technology“, <http://www.cit-ec.de/>, Verfügbar am 10.02.2010.
3. E. T. Jaynes, „Prior probabilities“, *IEEE Transactions on Systems, Science, and Cybernetics*, Vol. 4, Nr. 3, S. 227–241, 1968.
4. J. N. Kapur, *Maximum entropy models in science and engineering*, 1. Aufl. New York (NY): John Wiley & Sons, 1989.
5. F. Puente León und J. Beyerer, „Datenfusion zur Gewinnung hochwertiger Bilder in der automatischen Sichtprüfung“, *Automatisierungstechnik*, Vol. 45, Nr. 10, S. 480–489, 1997.
6. J. Beyerer, *Verfahren zur quantitativen statistischen Bewertung von Zusatzwissen in der Meßtechnik*. Düsseldorf: VDI Verlag, 1999.
7. J. Beyerer, M. Heizmann, J. Sander und I. Gheța, *Image Fusion – Algorithms and Applications*. Academic Press, 2008, Kap. Bayesian Methods for Image Fusion, S. 157–192.
8. J. Sander, M. Heizmann, I. Goussev und J. Beyerer, „A local approach for focussed Bayesian fusion“, in *Multisensor, Multisource Information Fusion: Architectures, Algorithms, and Applications, Proceedings of SPIE Vol. 7345*, 2009.
9. R. O. Duda, P. E. Hart und D. G. Stork, *Pattern Classification*, 2. Aufl. New York: John Wiley & Sons Inc, 2001.
10. J. M. Bernardo, *Encyclopedia of Life Support Systems (EOLSS). Probability and Statistics*. Oxford: UNESCO, 2003, Kap. Bayesian Statistics.
11. J. Sander und J. Beyerer, „Fusion agents – realizing Bayesian fusion via a local approach“, *2006 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems*, S. 249–254, 2006.
12. „Humanoide Roboter“, <http://www.sfb588.uni-karlsruhe.de/>, Verfügbar am 10.02.2010.
13. B. Kühn, A. Belkin, A. Swerdlow, T. Machmer, J. Beyerer und K. Kroschel, „Knowledge-driven opto-acoustic scene analysis based on an object-oriented world modelling approach for humanoid robots“, in *Proceedings of the 41st International Symposium on Robotics and the 6th German Conference on Robotics*. VDE-Verlag, 2010.
14. „Kognitive Automobile“, <http://www.kognimobil.de/>, Verfügbar am 10.02.2010.
15. „Team AnnieWay“, <http://annieway.mrt.uni-karlsruhe.de/>, Verfügbar am 10.02.2010.
16. M. Goebel, „KogMo-RTDB – Real-time database for cognitive automobiles“, <http://www.kogmo-rtdb.de/>, Verfügbar am 10.02.2010.