

Karlsruher Schriften  
zur Anthropomatik

Band 23



Yvonne Fischer

**Wissensbasierte probabilistische  
Modellierung für die Situationsanalyse  
am Beispiel der maritimen Überwachung**



Yvonne Fischer

**Wissensbasierte probabilistische  
Modellierung für die Situationsanalyse am  
Beispiel der maritimen Überwachung**

Karlsruher Schriften zur Anthropomatik

Band 23

Herausgeber: Prof. Dr.-Ing. Jürgen Beyerer

Eine Übersicht aller bisher in dieser Schriftenreihe  
erschienenen Bände finden Sie am Ende des Buchs.

# **Wissensbasierte probabilistische Modellierung für die Situationsanalyse am Beispiel der maritimen Überwachung**

von  
Yvonne Fischer

Dissertation, Karlsruher Institut für Technologie (KIT)  
Fakultät für Informatik, 2015

#### Impressum



Karlsruher Institut für Technologie (KIT)  
KIT Scientific Publishing  
Straße am Forum 2  
D-76131 Karlsruhe

KIT Scientific Publishing is a registered trademark of Karlsruhe  
Institute of Technology. Reprint using the book cover is not allowed.

[www.ksp.kit.edu](http://www.ksp.kit.edu)



*This document – excluding the cover, pictures and graphs – is licensed  
under the Creative Commons Attribution-Share Alike 3.0 DE License  
(CC BY-SA 3.0 DE): <http://creativecommons.org/licenses/by-sa/3.0/de/>*



*The cover page is licensed under the Creative Commons  
Attribution-No Derivatives 3.0 DE License (CC BY-ND 3.0 DE):  
<http://creativecommons.org/licenses/by-nd/3.0/de/>*

Print on Demand 2016

ISSN 1863-6489

ISBN 978-3-7315-0460-3

DOI 10.5445/KSP/1000051065







# **Wissensbasierte probabilistische Modellierung für die Situations- analyse am Beispiel der maritimen Überwachung**

zur Erlangung des akademischen Grades eines  
Doktors der Ingenieurwissenschaften

von der Fakultät für Informatik  
des Karlsruher Instituts für Technologie (KIT)

**genehmigte**

Dissertation

von

**Yvonne Fischer**

aus Stühlingen

Tag der mündlichen Prüfung:	16. Juli 2015
Erster Gutachter:	Prof. Dr.-Ing. Jürgen Beyerer
Zweiter Gutachter:	Prof. Dr.-Ing. Johann Marius Zöllner



---

# Danksagung

---

Die vorliegende Arbeit entstand während meiner Tätigkeit am »Lehrstuhl für Interaktive Echtzeitsysteme« (IES) des »Karlsruher Instituts für Technologie« (KIT) in enger Kooperation mit dem »Fraunhofer Institut für Optronik, Systemtechnik und Bildauswertung« (IOSB). In erster Linie möchte ich mich hiermit bei Herrn Prof. Dr.-Ing. Jürgen Beyerer für die vielen zielführenden Diskussionen und die exzellente Betreuung der Arbeit bedanken. Ohne die regelmäßigen Freitagsrunden am IES und der Teilnahme an vielen Sommerseminaren hätte die Arbeit bei Weitem nicht die jetzige Qualität erreicht. Des Weiteren möchte ich mich herzlich bei Herrn Prof. Dr.-Ing. Johann Marius Zöllner für die Übernahme des Korreferats bedanken.

Am Fraunhofer IOSB gilt mein Dank ganz besonders Frau Dr. Elisabeth Peinsipp-Byma, welche mir die Promotionsstelle ermöglicht hat und stets an meine Fähigkeiten geglaubt hat. Herrn Dr. Jürgen Geisler danke ich für die vielen interessanten Diskussionen zum Thema der Situationsanalyse. Des Weiteren möchte ich mich bei allen Kollegen der Abteilung »Interaktive Analyse und Diagnose« (IAD) für die stets angenehme Arbeitsatmosphäre bedanken. Meinen Studenten danke ich für die Unterstützung bei der Aufarbeitung konkreter Themenstellungen.

Weiter gilt mein Dank dem »Karlsruhe House of Young Scientists« (KHYS), welche meinen dreimonatigen Auslandsaufenthalt an der Ningbo University in China mit einem Stipendium unterstützten, sowie meinem dortigen Betreuer Herrn Prof. Jieyu Zhao.

Herrn Josef Traxl von der »Wehrtechnischen Dienststelle für Schiffe und Marinewaffen, Maritime Technologie und Forschung« (WTD 71) verdanke ich den aufgezeichneten Datensatz, welcher in dieser Arbeit für die Evaluierung

eingesetzt wurde sowie den Anomaliekatalog, auf welchem die in dieser Arbeit modellierten Situationen beruhen. Herrn Peter Piankowski von der Firma »Schönhöfer Sales and Engineering GmbH« verdanke ich die Bereitstellung von konkreten Situationsbeschreibungen, welche den Anomaliekatalog von der WTD 71 sinnvoll ergänzten.

Ein ganz besonderer Dank gilt meinen Korrekturlesern Jutta Hild, Dr. Elisabeth Peinsipp-Byma und Mathias Anneken sowie Philipp Woock für die zeitintensive  $\LaTeX$ -Betreuung. Ohne eure Unterstützung würde die Arbeit ganz bestimmt nicht in dieser Form existieren.

Den Kollegen am Lehrstuhl danke ich für die vielen Anregungen und kritischen Diskussionen in den Freitagsrunden und auf den Sommerseminaren. Besonders Miriam Schleipen, Thomas Bader und Hauke Vagts verdanke ich unvergessliche gemeinsame Abende - vielen Dank für die tolle Zeit.

Abschließend danke ich meiner Familie und meinen engsten Freunden, welche mich während dieser Zeit stets unterstützt und motiviert haben - ohne euch hätte ich das nie geschafft.

Karlsruhe, im November 2015

*Yvonne Fischer*

---

# Kurzfassung

---

In heutigen Überwachungssystemen wird eine Vielzahl heterogener Sensorik in einem Systemverbund eingesetzt. Mit dem verstärkten Einsatz von Sensorik wächst auch das zu verarbeitende Datenvolumen deutlich an. Daraus resultiert wiederum der Bedarf, den menschlichen Entscheider zu entlasten, indem diese Daten intelligent verarbeitet und ihm die Ergebnisse aufgabenabhängig präsentiert werden. Auf kognitiver Ebene wird dabei das Situationsbewusstsein als der mentale Zustand bezeichnet, welcher die Basis für menschliche Entscheidungen ist. Auf maschineller Ebene behandelt die Datenfusion die intelligente Verarbeitung der Daten auf unterschiedlichen Ebenen mit dem Ziel, das Situationsbewusstsein zu unterstützen.

Die vorliegende Arbeit leistet einen Beitrag zur Situationsanalyse, einem Teilbereich der Datenfusion auf höherer Ebene. Dazu wird eine Situation mathematisch definiert und die wissensbasierte Modellierung von Situationen in einem Situationsnetzwerk vorgestellt. Der Vorteil der wissensbasierten Modellierung besteht darin, dass diese für den Menschen nachvollziehbar und verständlich ist. Die Erstellung des Situationsnetzwerkes ist als ein Teilprozess der Situationsanalyse zu interpretieren. Das hier entwickelte Gesamtkonzept der Situationsanalyse behandelt des Weiteren den Prozess, welcher Echtzeitdaten hinsichtlich modellierter Situationen von Interesse auswertet und dem Entscheider die erkannten Situationen entsprechend präsentiert. Um dies zu ermöglichen, wird aus dem Situationsnetzwerk ein probabilistisches graphisches Modell, ein situationsspezifisches dynamisches Bayes'sches Netz (SSDBN), generiert. Ein entscheidender Faktor hinsichtlich der Funktionalität des SSDBN ist die Wahl der Parameter, also der Einträge der bedingten Wahrscheinlichkeitstabellen. Die Wahl dieser Parameter kann für den Menschen

dabei äußerst komplex sein. Ein wesentlicher Beitrag der Arbeit ist daher die Generierung dieser Parameter, wobei der Benutzer nur wenige, ihm verständliche Eingabewerte vorgeben muss. Das resultierende SSDBN ist insbesondere in der Lage, Vorwissen abzubilden und verrauschte Sensorbeobachtungen zu kompensieren.

Um die Funktionalität des in dieser Arbeit entwickelten Beitrags zur Situationsanalyse zu demonstrieren, werden mehrere Situationen von Interesse in der maritimen Domäne modelliert und bezüglich ihrer Erkennungsqualität evaluiert. Die Evaluierung wird dabei sowohl mittels simulierter Daten als auch mittels Realdaten durchgeführt. Zudem wird in einer Benutzerstudie der Einfluss eines Situationsanalysedienstes auf die Arbeitsbeanspruchung und die Akzeptanz von Nutzern untersucht.

---

# Inhaltsverzeichnis

---

<b>Symbolverzeichnis</b> . . . . .	<b>ix</b>
<b>Abkürzungsverzeichnis</b> . . . . .	<b>xiii</b>
<b>1. Einleitung</b> . . . . .	<b>1</b>
1.1. Motivation . . . . .	1
1.2. Zielsetzung . . . . .	5
1.3. Eigene Beiträge . . . . .	6
1.4. Gliederung der Arbeit . . . . .	8
<b>2. Stand von Forschung und Technik</b> . . . . .	<b>11</b>
2.1. Situationsbewusstsein . . . . .	11
2.1.1. Definition von Situationsbewusstsein . . . . .	12
2.1.2. Messung des Situationsbewusstseins . . . . .	14
2.1.3. OODA-Entscheidungszyklus . . . . .	19
2.2. Datenfusionsmodelle . . . . .	21
2.2.1. Terminologie der Datenfusion . . . . .	23
2.2.2. Omnibus-Modell . . . . .	25
2.2.3. JDL-Datenfusionsmodell . . . . .	26
2.2.4. Datenfusion und Situationsbewusstsein . . . . .	29
2.3. Maritime Überwachungssysteme . . . . .	31
2.3.1. Maritimes Situationsbewusstsein . . . . .	31
2.3.2. Eingesetzte Sensorik . . . . .	32
2.3.3. Eingesetzte Systeme . . . . .	38

2.4.	Umweltmodellierung . . . . .	42
2.4.1.	Anwendungsbereich Robotik . . . . .	42
2.4.2.	Anwendungsbereich Fahrzeugführung . . . . .	45
2.4.3.	Anwendungsbereich Videoüberwachung . . . . .	48
2.5.	Wissensmodellierung und Situationserkennung . . . . .	51
2.5.1.	Methoden zur Anomaliedetektion . . . . .	52
2.5.2.	Regelbasierte Methoden zur Situationserkennung . . . . .	58
2.5.3.	Probabilistische Methoden zur Situationserkennung . . . . .	62
2.6.	Zusammenfassung . . . . .	71
<b>3.</b>	<b>Umweltmodellierung . . . . .</b>	<b>75</b>
3.1.	Informationsfluss in Überwachungssystemen . . . . .	75
3.1.1.	Beobachten . . . . .	76
3.1.2.	Auswerten . . . . .	77
3.1.3.	Inferenz und Lernen . . . . .	78
3.1.4.	Handeln . . . . .	79
3.2.	Modellierung von Objekten . . . . .	80
3.3.	Modellierung von Situationen . . . . .	82
3.3.1.	Eingrenzung des Situationsbegriffs . . . . .	82
3.3.2.	Formale Definition einer Situation . . . . .	86
3.3.3.	Existenzwahrscheinlichkeit einer Situation . . . . .	89
3.4.	Modellierung weiterer Konzepte . . . . .	90
3.5.	Das objektorientierte Weltmodell . . . . .	90
3.5.1.	Funktionalitäten des OOWM . . . . .	91
3.5.2.	Architektur des OOWM . . . . .	92
3.6.	Zusammenfassung . . . . .	94
<b>4.</b>	<b>Wissensbasierte Modellierung von Situationen . . . . .</b>	<b>95</b>
4.1.	Die semantische Aussage . . . . .	95
4.1.1.	Deduktion und Abduktion . . . . .	95
4.1.2.	Formalisierung der semantischen Aussage . . . . .	96
4.2.	Wissensbasis einer Situation . . . . .	97
4.2.1.	Abstraktion von Situationen . . . . .	97
4.2.2.	Elementare und abstrakte Situationen . . . . .	98
4.2.3.	Die formalisierte semantische Aussage einer Situation . . . . .	99
4.2.4.	Wissensbasis einer Situation . . . . .	100



---

4.3.	Abhängigkeiten zwischen Situationen . . . . .	101
4.3.1.	Notwendige und hinreichende Bedingungen . . . . .	101
4.3.2.	Bedeutung für die formalisierte semantische Aussage . . . . .	102
4.4.	Situationsnetzwerk als Wissensmodellierung . . . . .	103
4.4.1.	Gemeinsame Wissensbasis mehrerer Situationen . . . . .	103
4.4.2.	Situationsnetzwerk . . . . .	104
4.4.3.	Abstraktionslevel von Situationen . . . . .	104
4.5.	Zusammenfassung . . . . .	106
<b>5.</b>	<b>Situationsanalyse . . . . .</b>	<b>109</b>
5.1.	Gesamtkonzept der Situationsanalyse . . . . .	109
5.1.1.	Objekterkennung . . . . .	111
5.1.2.	Situationscharakterisierung . . . . .	111
5.1.3.	Situationserkennung . . . . .	114
5.1.4.	Visualisierung . . . . .	115
5.1.5.	Rückkopplung . . . . .	116
5.2.	Das situationspezifische DBN . . . . .	116
5.2.1.	Motivation zur Nutzung eines SSDBN . . . . .	116
5.2.2.	Möglichkeiten der Inferenz im SSDBN . . . . .	118
5.2.3.	Algorithmen zur Inferenzberechnung . . . . .	121
5.3.	Generierung der SSDBN Struktur . . . . .	124
5.4.	Methoden zur Spezifizierung der Parameter . . . . .	127
5.4.1.	Anzahl der zu bestimmenden Parameter . . . . .	127
5.4.2.	Expertenbefragungen . . . . .	127
5.4.3.	Gewichtete CPT-Berechnung . . . . .	128
5.4.4.	Noisy-Or-Modell . . . . .	129
5.4.5.	Generalisiertes lineares Modell . . . . .	129
5.5.	Generierung der SSDBN Parameter . . . . .	131
5.5.1.	Erwartungen an das SSDBN-Verhalten . . . . .	131
5.5.2.	Nutzung von Vorwissen . . . . .	132
5.5.3.	Stationaritäts-Bedingung . . . . .	133
5.5.4.	Sprungverhalten . . . . .	133
5.5.5.	Robustheit . . . . .	133
5.5.6.	Asymptotisches Verhalten . . . . .	134
5.5.7.	Berechnung der CPT . . . . .	134
5.5.8.	Bestimmung der Kantengewichte . . . . .	136
5.6.	Beispielberechnung für ein HMM . . . . .	138
5.7.	Zusammenfassung . . . . .	144

---

<b>6. Ergebnisse am Beispiel der maritimen Überwachung . . . . .</b>	<b>145</b>
6.1. Evaluation mit simulierten Daten . . . . .	145
6.1.1. Maritime Situation von Interesse . . . . .	145
6.1.2. Robustheit . . . . .	148
6.1.3. Sprungverhalten . . . . .	150
6.2. Evaluation mit Realdaten . . . . .	152
6.2.1. Datengrundlage . . . . .	152
6.2.2. Maritime Situationen von Interesse . . . . .	155
6.2.3. Berechnung der Evidenzen . . . . .	159
6.2.4. Ergebnisse . . . . .	161
6.3. Benutzerstudie . . . . .	172
6.3.1. Aufgabenstellung . . . . .	172
6.3.2. Arbeitsbeanspruchung . . . . .	174
6.3.3. Akzeptanz . . . . .	176
6.4. Zusammenfassung . . . . .	178
<b>7. Schlussbetrachtungen . . . . .</b>	<b>179</b>
7.1. Zusammenfassung . . . . .	179
7.2. Ausblick . . . . .	181
<b>Literaturverzeichnis . . . . .</b>	<b>183</b>
<b>Eigene Veröffentlichungen . . . . .</b>	<b>209</b>
<b>Betreute studentische Arbeiten . . . . .</b>	<b>213</b>
<b>A. Situationsnetzwerke . . . . .</b>	<b>215</b>

---

# Symbolverzeichnis

---

## Generelle Notationen

$\mathcal{A}, \mathcal{B}, \dots$	Mengen (Großbuchstaben, kalligraphisch)
$i, j, k, \ell, \dots$	Ganzzahlige Indexvariablen (Kleinbuchstaben, kursiv)
$\mathbb{N}$	Menge der natürlichen Zahlen inklusive Null
$\mathbb{R}$	Menge der reellen Zahlen
$\mathbb{R}_0^+$	Menge der positiven reellen Zahlen inklusive Null
$X, Y, \dots$	Variablen (Großbuchstaben, kursiv)
$x, y, \dots$	Ausprägungen von Variablen (Kleinbuchstaben, kursiv)

## Bezeichnungen

$\mathcal{A}$	Menge von abstrakten Situationen
$A^i$	Allgemeiner Bezeichner für eine abstrakte Situation mit Index $i$
$A_t^i$	Allgemeiner Bezeichner für eine abstrakte Situation mit Index $i$ zum Zeitpunkt $t$
$\delta$	Zeitintervall
$d$	Zeitintervall
$e$	Menge der beobachteten Evidenzen

---

$\mathcal{E}$	Menge von elementaren Situationen
$E$	Allgemeiner Bezeichner für eine elementare Situation
$E^i$	Allgemeiner Bezeichner für eine elementare Situation mit Index $i$
$E_t^i$	Allgemeiner Bezeichner für eine elementare Situation mit Index $i$ zum Zeitpunkt $t$
$F$	F-Maß: harmonisches Mittel aus Genauigkeit und Trefferquote
$F(S)$	Formalisierte semantische Aussage einer Situation $S$
$g_{asym}$	Anzahl Zeitschritte bei ausbleibenden Evidenzen, bis A-priori-Wahrscheinlichkeit ausgehend von der Maximalwahrscheinlichkeit erreicht wird
$g_{neg}$	Anzahl Zeitschritte bei negativen Evidenzen, bis A-priori-Wahrscheinlichkeit ausgehend von der Maximalwahrscheinlichkeit erreicht wird
$g_{pos}$	Anzahl Zeitschritte bei positiven Evidenzen, bis maximale Wahrscheinlichkeit ausgehend von der A-priori-Wahrscheinlichkeit erreicht wird
$H$	Entropie
$L(S)$	Abstraktionslevel einer Situation $S$
$\max(S)$	Maximale Wahrscheinlichkeit von $S$
$\min(S)$	Minimale Wahrscheinlichkeit von $S$
$n_t$	Anzahl aller Knoten in Zeitscheibe $t$
$n_t^a$	Anzahl aller abstrakten Situationen in Zeitscheibe $t$
$[O]$	Äquivalenzklasse eines Objektes
$\mathcal{O}$	Menge von Objekten
$\omega$	Zustandsausprägung einer Situation

---

$\Omega_S$	Zustandsraum der Situation $S$
$\omega_t$	Zustandsausprägung einer Situation zum Zeitpunkt $t$
$\tilde{\Omega}_S$	Träger der Situation $S$
$O$	Allgemeiner Bezeichner für ein Objekt
$O^i$	Allgemeiner Bezeichner für ein Objekt mit Index $i$
$Pa(X)$	Elternknoten des Knotens $X$
$\text{prior}(S)$	A-priori-Wahrscheinlichkeit von $S$
$R$	Allgemeiner Bezeichner für eine Relation
$S$	Menge von Situationen
$\text{sig}(\cdot)$	Sigmoidfunktion
$\sigma$	Infon: Informationseinheit in der Situationstheorie
$\Sigma_S$	Sigma-Algebra über $\Omega_S$
$ S $	Anzahl der Zustände der Zufallsvariablen $S$
$S$	Allgemeiner Bezeichner für eine Situation
$S^i$	Allgemeiner Bezeichner für eine Situation mit Index $i$
$S^i \xrightarrow{N} S^j$	Notwendige Bedingung: $S^j$ ist notwendige Situation für $S^i$ , es gilt $S^i \Rightarrow S^j$
$S^i \xrightarrow{S} S^j$	Hinreichende Bedingung: $S^i$ ist hinreichende Situation für $S^j$ , es gilt $S^i \Rightarrow S^j$
$S_t$	Situation $S$ zum Zeitpunkt $t$
$S_t^i$	Allgemeiner Bezeichner für eine Situation mit Index $i$ zum Zeitpunkt $t$
$\mathbb{T}$	Zeitdimension mit $\mathbb{T} = \mathbb{N}$ oder $\mathbb{T} = \mathbb{R}_0^+$
$t$	Zeitpunkt

$WB(S)$	Wissensbasis einer Situation $S$ : Menge von formalisierten semantischen Aussagen
$WB(S^1, \dots, S^n)$	Gemeinsame Wissensbasis der Situationen $S^1, \dots, S^n$ : Vereinigung einzelner Wissensbasen
$w_{obs}$	Gewicht für Kanten innerhalb einer Zeitscheibe
$w_{temp}$	Gewicht für Kanten zwischen zwei Zeitscheiben
$z_{asym}$	Zielzahl von $g_{asym}$
$z_{neg}$	Zielzahl von $g_{neg}$
$z_{pos}$	Zielzahl von $g_{pos}$

---

# Abkürzungsverzeichnis

---

2TBN	2-Time-Slice Bayesian Network
AIS	Automatic Identification System
ARPA	Automatic Radar Plotting Aid
BN	Bayes'sches Netz
CISE	Common Information Sharing Environment
COG	Course over Ground
COP	Common Operational Picture
CPD	Conditional Probability Distribution
CPT	Conditional Probability Table
CSS	Coastal Surveillance System
DBN	Dynamische Bayes'sches Netz
DL	Description Logic
DNBC	Dynamic Naive Bayes Classifier
DoB	Degree of Belief
ECDIS	Electronic Chart Display and Information System
EEZ	Exclusive Economic Zone

EM	Expectation Maximization
ENC	Electronic Navigational Charts
ESA	European Space Agency
GLM	Generalisiertes lineares Modell
GMDSS	Global Maritime Distress and Safety System
GMM	Gaussian Mixture Model
GPS	Global Positioning System
HMM	Hidden-Markov-Modell
ICI	Independence of Causal Influence
ID	Identifikator
IMO	International Maritime Organization
IOSB	(Fraunhofer) Institut für Optronik, Systemtechnik und Bildauswertung
IR	Infrarot
ISIF	International Society of Information Fusion
ITU	International Telecommunication Union
JDL	Joint Directors of Laboratories
KDE	Kernel Density Estimation
LOF	Local Outlier Factor
LRIT	Long Range Identification and Tracking
MAP	Maximum-A-posteriori-Schätzer
MCMC	Markov-Ketten-Monte-Carlo
MDA	Maritime Domain Awareness



---

MEBN	Multi-Entity Bayesian Network
MLN	Markov Logik Netzwerk
MMSI	Maritime Mobile Service Identity
NASA	National Aeronautics and Space Administration
NASA TLX	NASA Task Load Index
NEST	Network Enabled Surveillance and Tracking
NMEA	National Marine Electronics Association
NN	Nearest Neighbor
OOBN	Objektorientiertes Bayes'sches Netz
OODA	Observe - Orient - Decide - Act
OOWM	Objektorientiertes Weltmodell
OPRM	Objektorientiertes Probabilistisches Relationales Modell
OWL	Web Ontology Language
PR-OWL	Probabilistic Web Ontology Language
RCS	Radar Cross Section
RCS	Real-Time Control System
RDF	Radio Direction Finder
RMP	Recognized Maritime Picture
ROT	Rate of Turn
SA	Situation Awareness/Situationsbewusstsein
SAGAT	Situation Awareness Global Assessment Technique
SAR	Search and Rescue
SART	Situational Awareness Rating Technique

SAT-AIS	Satellitengestütztes AIS
SN	Situationsnetzwerk
SOG	Speed over Ground
SSBN	Situationspezifisches Bayes'sches Netz
SSDBN	Situationspezifisches dynamisches Bayes'sches Netz
SWIR	Short Wavelength IR
UKW	Ultrakurzwellen
UML	Unified Modeling Language
UTC	Universal Time, coordinated
VMS	Vessel Monitoring System
VTs	Vessel Traffic Service
W3C	World Wide Web Consortium
WTD 71	Wehrtechnische Dienststelle für Schiffe und Marinewaffen, Maritime Technologie und Forschung
WWW	World Wide Web

# 1

---

## Einleitung

---

### 1.1. Motivation

Im Jahr 2012 wurden 80 % der Güter weltweit über den Seeweg transportiert [Uni13]. Dies entspricht ca. 9,2 Milliarden Tonnen. Im Vergleich zum Vorjahr 2011 war für das Jahr 2012 ein Wachstum von 4,3 % zu verzeichnen. Dieses Wachstum, das über die letzten Jahrzehnte stetig stieg, zeigt sich einerseits an der steigenden Anzahl von Handelsschiffen, von denen im Jahr 2012 ca. 87.000 mit einer Bruttoreaumzahl<sup>1</sup> größer als 100 registriert waren. Andererseits werden auch immer größere Schiffe gebaut, wie beispielsweise Frachtschiffe mit Tragfähigkeiten von mehr als 400.000 dwt (engl.: »deadweight tonnage«) [Uni13].

Aufgrund der hohen wirtschaftlichen Bedeutsamkeit des maritimen Handels wurde bereits 1948 die »International Maritime Organization« (IMO)<sup>2</sup> als Sonderorganisation der Vereinten Nationen gegründet. Zu Beginn befasste diese sich hauptsächlich mit der Verbesserung der Betriebssicherheit (engl.: »Safety«) und dem Schutz vor maritimer Umweltverschmutzung. Seit den

---

<sup>1</sup> Maßzahl zur Schiffsgröße, in Deutschland offiziell im Schiffsmessbrief festgehalten, ausgestellt durch das Bundesamt für Seeschifffahrt und Hydrographie (BSH), siehe <http://www.bsh.de/de/Schifffahrt/Berufsschifffahrt/Schiffsvermessung/index.jsp>, letzter Abruf am 16.04.2015

<sup>2</sup> <http://www.imo.org/>, letzter Abruf am 16.04.2015

frühen 2000ern rückt jedoch auch die Angriffssicherheit (engl.: »Security«) immer mehr in den Fokus der Organisation [IMO13b]. Die IMO hat heute die Zielsetzung, Strategien für eine sichere, geschützte und effiziente Schifffahrt auf sauberen Meeren zu entwickeln [IMO13b].

Des Weiteren gibt es seitens der Europäischen Kommission die Generaldirektion »Maritime Angelegenheiten und Fischerei<sup>3</sup>«, welche sich für die Entwicklung des Potenzials der maritimen Wirtschaft in Europa einsetzt. Unter die maritimen Angelegenheiten der Europäischen Kommission fällt auch die integrierte Meeresüberwachung, welche die Interoperabilität maritimer Überwachungssysteme zum Ziel hat. Dies wird in einer gemeinsamen Informationsanwendung CISE<sup>4</sup> (engl.: »Common Information Sharing Environment«) umgesetzt. CISE gibt Behörden die Möglichkeit, Informationen und Daten auszutauschen, um die Meeresüberwachung kostengünstiger und effektiver zu gestalten [Eur10].

Die Europäische Kommission hat in diesem Zusammenhang eine Definition der maritimen Überwachung veröffentlicht [Eur10]:

»Die maritime Überwachung ist das tatsächliche Verstehen aller auf See stattfindenden Tätigkeiten, die die Sicherheit, die Wirtschaft oder die Umwelt der Europäischen Union und ihrer Mitgliedsstaaten beeinflussen können<sup>5</sup>.«

Um in heutigen maritimen Überwachungssystemen dieses tatsächliche Verstehen bestmöglich zu unterstützen, wird eine Vielzahl heterogener Sensoren in einem Systemverbund eingesetzt, wie beispielsweise das auf Funk basierende automatische Identifikationssystem AIS in Kombination mit Radarsensorik. Durch die Vielzahl von Sensoren wächst jedoch auch das zu verarbeitende Datenvolumen stark an. Daraus resultiert wiederum der Bedarf, diese Daten intelligent zu verarbeiten und zu interpretieren sowie die Ergebnisse aufgabenabhängig zu präsentieren [Abi13].

---

<sup>3</sup> [http://ec.europa.eu/dgs/maritimeaffairs\\_fisheries/about\\_us/index\\_de.htm](http://ec.europa.eu/dgs/maritimeaffairs_fisheries/about_us/index_de.htm), letzter Abruf am 16.04.2015

<sup>4</sup> [http://ec.europa.eu/maritimeaffairs/policy/integrated\\_maritime\\_surveillance](http://ec.europa.eu/maritimeaffairs/policy/integrated_maritime_surveillance), letzter Abruf am 16.04.2015

<sup>5</sup> Eigene Übersetzung. Original: »Maritime Surveillance is the effective understanding of all activities carried out at sea that could impact the security, safety, economy, or environment of the European Union and its Member States.«

Mit der wissenschaftlichen Herangehensweise an diese Problemstellungen beschäftigen sich die Forschungsarbeiten in den Bereichen Situationsbewusstsein und Datenfusion [End11; Mit12]. Situationsbewusstsein ist auf den menschlichen Entscheider bezogen und wird dabei als der mentale Zustand interpretiert, welcher die Basis für die menschlichen Entscheidungen ist. Situationsbewusstsein wird von unterschiedlichen Faktoren beeinflusst, unter anderem von der Arbeitsbelastung, welcher ein Entscheider ausgesetzt ist, bzw. der resultierenden individuellen Arbeitsbeanspruchung. Die Datenfusion behandelt die maschinelle Ebene und untersucht die Automatisierung oder auch die Teilautomatisierung einzelner datenverarbeitender Prozesse auf unterschiedlichen Ebenen. Die Datenfusion hat im hier betrachteten Kontext das Ziel, das Situationsbewusstsein eines Entscheiders zu unterstützen.

Die Domäne der Datenfusion lässt sich in zwei wesentliche Ebenen unterteilen: die »Low-Level-Datenfusion« und die »High-Level-Datenfusion«. Die Methoden der »Low-Level-Datenfusion« beschäftigen sich beispielsweise mit der Positionsschätzung eines Objektes über die Zeit hinweg [Koc14]. Solche Methoden sind bereits vielseitig erforscht und befinden sich auch schon im Einsatz. So sind beispielsweise maritime Überwachungssysteme bereits heute in der Lage, Schiffe und andere Objekte robust über die Zeit hinweg zu verfolgen. In den letzten Jahren kristallisierte sich jedoch der Bedarf heraus, Konzepte und Methoden zur »High-Level-Datenfusion« zu entwickeln, also nicht nur die einzelnen Objektzustände zu schätzen, sondern auch die Beziehungen zwischen den erfassten Objekten zu analysieren und die Erkennung spezifischer Situationen von Interesse zu unterstützen [Bla12a; Bla12b; Foo13]. Mit genau dieser Thematik befasst sich die Situationsanalyse, welche in dieser Arbeit behandelt wird.

Bei den Methoden zur Situationsanalyse ist das logische Schlussfolgern weit verbreitet. Dabei wird das Wissen über gewisse Fakten in Form von Wenn-Dann-Regeln modelliert und in einer Wissensbasis abgelegt. In der Anwendung, also beispielsweise bei der Erkennung bestimmter Objektbeziehungen, wird deduktives logisches Schließen angewendet [Bib93; Rus10]. Zur Modellierung der Wissensbasis werden üblicherweise Ontologien verwendet. Ein wesentlicher Vorteil dieser Methode ist, dass die Regeln von Experten formuliert werden und dadurch für den Menschen verständlich sind. Ein wesentlicher Nachteil ist, dass Unsicherheiten in den Objektbeobachtungen nicht behandelt werden können. Als mächtiges Werkzeug im Umgang mit unsicherer Information hat sich die Bayes'sche Statistik etabliert [Rob07].

Für die Anwendung in der Situationsanalyse werden solche Bayes'schen Verfahren meist mit maschinellen Lernverfahren kombiniert [Bis06; Mur12]. Die Lernverfahren werden dazu verwendet, um die Parameter der verwendeten Modelle zu lernen. Ein wesentlicher Nachteil dieser Lernverfahren ist jedoch die Erforderlichkeit von Trainingsdaten. Um eine optimale Lösung zu gewährleisten, müssen die Trainingsdaten unbedingt umfangreich genug sein, bzw. bei überwachten Lernverfahren müssen sie darüber hinaus mit der Grundwahrheit annotiert sein. Dieser Prozess der Datenerhebung und -annotation kann sehr aufwändig sein. Dies wird vor allem dann zum Problem, wenn sich die Situationen von Interesse für den Benutzer ändern, da in diesem Fall die Trainingsphase und damit die Datenerhebung und -annotation erneut durchgeführt werden muss. Eine weitere Problematik besteht darin, dass eine solche Datenerhebung nicht immer gewährleistet werden kann. In gewissen Anwendungsdomänen treten die Situationen von Interesse sehr selten auf, so dass kein Trainingsdatensatz erstellt werden kann. Ein weiterer Nachteil der maschinellen Lernverfahren ist, dass diese wie eine Black-Box agieren. Dies kann dazu führen, dass die Verfahrensergebnisse in der Anwendung für den Menschen nicht nachvollziehbar sind. Speziell für sicherheitskritische Anwendungen, in denen der Mensch auch folgenschwere Entscheidungen treffen muss, sind solche Black-Box-Verfahren für den praktischen Einsatz ungeeignet.

Aus diesen Gründen gibt es bereits Verfahren, welche die jeweiligen Stärken des logikbasierten und des probabilistischen Ansatzes kombinieren [Ric06; Las08]. Diese verwenden als Repräsentation ein graphisches Modell, also entweder einen gerichteten oder einen ungerichteten Graphen, und wenden Methoden der probabilistischen Inferenz darauf an, um gewisse Schlussfolgerungen zu ziehen, d.h. die A-posteriori-Wahrscheinlichkeit eines Knotens bei gesetzten Evidenzwerten zu berechnen. Die wesentliche Problematik bei den bestehenden Verfahren ist aber, dass die Parameter der verwendeten Modelle manuell zu setzen sind. Die Anzahl der Parameter wächst jedoch mit der Anzahl der Abhängigkeiten an, so dass die Verfahren im praktischen Einsatz schnell an ihre Grenzen stoßen.

## 1.2. Zielsetzung

Die Zielsetzung dieser Arbeit besteht darin, ein Konzept dafür zu entwickeln und zu evaluieren, wie eine Situationsanalyse probabilistisch umgesetzt werden kann, und zwar ohne Zuhilfenahme von Trainingsdaten. Dies bedeutet insbesondere, dass die Modellierung einer Situation von Interesse wissenschaftlich umgesetzt werden muss. Dazu ist es zunächst notwendig, den Begriff der Situation formal zu definieren. Basierend auf dieser Definition soll die Modellierung einer Wissensbasis für eine Menge von Situationen von Interesse durchgeführt werden.

Da die Inferenz probabilistisch umgesetzt wird, muss für die Repräsentation einer Situation ein geeignetes Modell gewählt werden. Als Repräsentationsform wird in dieser Arbeit ein graphisches Modell verwendet, da sich diese Modellierung bereits seit Jahrzehnten in vielen Anwendungen bewährt hat und dafür bereits sehr mächtige Inferenzalgorithmen existieren.

Eine weitere Zielsetzung behandelt die Problematik, wie aus der Wissensbasis ein solches, graphisches Modell generiert werden kann. Eine besondere Herausforderung ist dabei die Wahl der Parameter. Die Anzahl der auszuwählenden Parameter muss einerseits überschaubar sein, andererseits müssen diese in der Lage sein, gewisse Zielkriterien zu erfüllen. Eine Evaluation soll die Funktionalität der entwickelten Methodik aufzeigen. Für die Evaluation werden für den Anwendungsfall der maritimen Überwachung mehrere Situationen von Interesse definiert. Diese werden mittels der vorgestellten Methodik in ein probabilistisches graphisches Modell überführt. Die Ergebnisse werden anhand simulierter und realer Schiffsverkehrsdaten dargestellt. Um nachzuweisen, dass die Methodik dafür geeignet ist, das Situationsbewusstsein zu unterstützen, wird eine Benutzerstudie vorgestellt, welche den Einfluss eines Situationsanalysedienstes auf die Arbeitsbeanspruchung und die Akzeptanz der Nutzer untersucht.

### 1.3. Eigene Beiträge

Basierend auf der Zielsetzung liefert die Arbeit in vier Bereichen einen wesentlichen Beitrag.

#### Mathematische Definition einer Situation

In der Literatur fehlt bislang die mathematische Definition einer Situation. In dieser Arbeit wird eine Situation zum Zeitpunkt  $t$  als eine binäre Zufallsvariable definiert, also als eine Abbildung  $S_t : \Omega_S \rightarrow \{0,1\}$ . Der Grundraum  $\Omega_S$  wird dabei aufgespannt aus der Zeitdimension und dem Konfigurationsraum aller relevanten Objektattribute. Die Relevanz von Objektattributen ist dabei abhängig von der Semantik der Situation. So ist beispielsweise die Situation, dass ein Boot schnell ist, von seiner Geschwindigkeit und dem Schiffstyp abhängig, nicht jedoch von seiner Kursrichtung. Durch die Wahl einer Sigma-Algebra  $\Sigma_S$  und eines Wahrscheinlichkeitsmaßes  $P$  kann die Existenzwahrscheinlichkeit einer Situation als  $P(S_t(\omega) = 1)$  definiert werden. Weiter sei  $\tilde{\Omega}_S \subseteq \Omega_S$  der Träger der Situation  $S_t$ , d.h. es gilt  $S_t(\omega) = 1 \Leftrightarrow \omega \in \tilde{\Omega}_S$ .

#### Wissensbasierte Modellierung von Situationen in einem Situationsnetzwerk

Aufgrund der unterschiedlichen Semantik einzelner Situationen lassen sich diese verschiedenen Abstraktionsebenen zuordnen. Grundsätzlich lassen sich Situationen in elementare Situationen und abstrakte Situationen unterteilen. Elementare Situationen befinden sich auf der niedrigsten Abstraktionsebene und ihre Träger lassen sich explizit aus den relevanten Objektattributen als deterministische Abbildung modellieren. So kann beispielsweise die Existenz der Situation, dass ein Schiff ein Tanker ist, direkt aus dem Attribut des Schiffstyps inferiert werden. Situationen, deren Träger sich nicht explizit modellieren lassen, werden als abstrakte Situationen bezeichnet, wie z.B., dass ein Schiff ein Schmuggelboot ist. Die Existenz von abstrakten Situationen ist also abhängig von der Existenz anderer (elementarer oder abstrakter) Situationen. Diese Abhängigkeiten werden mittels notwendiger und hinreichender Bedingungen vom menschlichen Experten modelliert. Diese Modellierung wird als vollständige Wissensbasis einer Situation bezeichnet und kann graphisch als Situationsnetzwerk dargestellt werden. Die Abstraktionsebene einer Situation kann dann anhand der Struktur des Situationsnetzwerkes berechnet werden.



### **Konzept zur Situationsanalyse**

Es wurde ein Konzept zur wissensbasierten Situationsanalyse entwickelt. Der Prozess der Situationsanalyse wird dabei in einzelne Teilprozesse unterteilt. Im Teilprozess der Charakterisierung werden Situationen von Interesse von einem (maritimen) Experten identifiziert und charakterisiert. Dabei werden Abhängigkeiten zu anderen Situationen berücksichtigt und diese als notwendige und hinreichende Bedingungen abgebildet. Das Ergebnis des Charakterisierungsprozesses ist ein Situationsnetzwerk. Im Teilprozess der Situationserkennung wird aus dem zugrundeliegenden Situationsnetzwerk ein probabilistisches Modell generiert und auf Beobachtungsdaten angewendet. Das Resultat der Situationserkennung sind Existenzwahrscheinlichkeiten der ausgewählten Situationen von Interesse.

### **Generierung eines probabilistischen Modells für die Situationsanalyse**

Auf Basis des modellierten Situationsnetzwerkes wird ein probabilistisches Modell generiert, ein sogenanntes situationsspezifisches dynamisches Bayes'sches Netz (SSDBN). Dazu wird vom Anwender eine Situation von Interesse ausgewählt. Die Struktur des SSDBN wird dabei aus dem Situationsnetzwerk übernommen. Es werden jedoch nur die Knoten übernommen, welche für die Berechnung der Existenzwahrscheinlichkeit notwendig sind. Dies sind genau diejenigen Knoten, welche eine niedrigere Abstraktionsebene besitzen und mit der Situation durch eine Abhängigkeit verbunden sind. Eine wissenschaftliche Herausforderung stellt die Spezifizierung der Parameter dar, also die Berechnung der Einträge der bedingten Wahrscheinlichkeitstabellen (CPT). Dazu ist es notwendig, jeder Abhängigkeit eine Gewichtung zuzuordnen. Insgesamt können die Einträge der CPTs dann mittels eines Ansatzes, welcher auf generalisierten linearen Modellen basiert, berechnet werden. Dieses Modell wurde so adaptiert, dass es zwei wesentlichen Anforderungen genügt: zum einen der Verwendung von A-priori-Wahrscheinlichkeiten, also bekannten Häufigkeiten des Auftretens einer Situation, zum anderen der Erfüllung der Stationaritäts-Bedingung, also dass die A-priori-Verteilung gerade die stationäre Verteilung des dynamischen Bayes'schen Netzes ist. Die Stationaritäts-Bedingung gewährleistet außerdem ein asymptotisches Verhalten, also die Konvergenz der A-posteriori-Wahrscheinlichkeit hin zur A-priori-Verteilung, wenn keine Beobachtungen mehr gemacht werden. Insgesamt wurde ein Al-

gorithmus zur Generierung eines SSDBNs entwickelt, welcher als Eingabe das Situationsnetzwerk verwendet und als Ergebnis ein probabilistisches Modell liefert, das in der Lage ist, aktuelle Beobachtungen in Echtzeit auszuwerten, und zwar hinsichtlich ausgewählter Situationen von Interesse.

## 1.4. Gliederung der Arbeit

Die Arbeit umfasst fünf inhaltliche Kapitel. In Kapitel 2 wird der Stand von Forschung und Technik erörtert. Dieser beinhaltet Forschungsarbeiten zu den Themen Situationsbewusstsein und Datenfusionsmodelle. Weiter werden aktuell eingesetzte Techniken von maritimen Überwachungssystemen vorgestellt. Bezüglich des Themas Umweltmodellierung werden aktuelle Methoden aus den verwandten Gebieten der Robotik, der Fahrzeugführung und der Videoüberwachung behandelt. Das abschließende Unterkapitel stellt den Stand der Forschung zur Wissensmodellierung und zur Situationserkennung vor. Dabei werden Verfahren zur Anomaliedetektion sowie zur regelbasierten und probabilistischen Situationserkennung vorgestellt.

Kapitel 3 behandelt die in dieser Arbeit verwendete Umweltmodellierung. Dazu wird im ersten Schritt der Informationsfluss in Überwachungssystemen analysiert. Anschließend wird das hier verwendete Objekt-konzept vorgestellt und eine formale Definition einer Situation erarbeitet. Das Kapitel schließt mit der Präsentation davon, wie eine objektorientierte Umweltmodellierung auf die maritime Domäne angewendet werden kann.

In Kapitel 4 wird die wissensbasierte Modellierung von Situationen vorgestellt. Dabei wird zunächst definiert, was unter einer formalisierten semantischen Aussage zu verstehen ist. Weiter wird auf die Abstraktion von Situationen eingegangen und es werden die Begriffe der elementaren und abstrakten Situation vorgestellt. Mit diesen Definitionen kann dann die Wissensbasis einer Situation definiert werden. Im weiteren Verlauf des Kapitels werden notwendige und hinreichende Bedingungen als Abhängigkeiten zwischen Situationen eingeführt. Abschließend wird das Situationsnetzwerk als graphische Repräsentationsform einer Wissensbasis vorgestellt.

Kapitel 5 beschreibt die Situationsanalyse. Dabei wird im ersten Schritt das Gesamtkonzept der Situationsanalyse vorgestellt. Die Notation des situationspezifischen dynamischen Bayes'schen Netzes (SSDBN) wird eingeführt und ein Algorithmus zur Generierung der Struktur eines SSDBN aus einem Situationsnetzwerk vorgestellt. Für die Generierung der Parameter werden

Erwartungen an das Verhalten des SSDBN formuliert, welche die Robustheit und das Sprungverhalten betreffen. Weiter wird noch die Nutzung von Vorwissen berücksichtigt sowie eine Stationaritäts-Bedingung formuliert. Zur Berechnung der Parameter wird ein generalisiertes lineares Modell verwendet, wobei die jeweiligen Gewichte aus einem Optimierungsschritt heraus berechnet werden. Das Vorgehen wird anhand eines Hidden-Markov-Modells aufgezeigt.

In Kapitel 6 wird das in den Kapiteln 3 bis 5 vorgestellte Vorgehen auf die maritime Domäne angewandt. Dazu werden Situationen von Interesse formuliert und als Situationsnetzwerk modelliert. Diese werden dann mit dem vorgestellten Verfahren in ein SSDBN überführt. Zur Evaluierung werden einerseits simulierte Daten verwendet, andererseits auch reale Daten. Insbesondere wird hier aufgezeigt, dass das so generierte SSDBN den in Kapitel 5 formulierten Anforderungen an das Verhalten standhält. Das Kapitel schließt mit der Beschreibung einer Nutzerstudie, welche den Einfluss eines Situationsanalyzedienstes auf die Arbeitsbeanspruchung und die Akzeptanz von Nutzern untersucht. Die Arbeit schließt in Kapitel 7 mit einer Zusammenfassung und einem Ausblick.



# 2

---

## Stand von Forschung und Technik

---

In diesem Kapitel wird der Stand von Wissenschaft und Technik dargestellt. Zunächst werden Modelle für Situationsbewusstsein und Datenfusion erläutert und miteinander in Beziehung gesetzt. Im Anschluss werden die Fähigkeiten aktueller Überwachungssysteme vorgestellt, wobei der Schwerpunkt auf maritimen Systemen liegt. Im darauffolgenden Abschnitt wird der Stand der Forschung im Bereich der Umweltmodellierung dargestellt. Abschließend wird auf Verfahren zur Wissensmodellierung und zur Situationserkennung eingegangen und es werden deren Vor- und Nachteile erläutert. Das Kapitel schließt mit einer Zusammenfassung.

### 2.1. Situationsbewusstsein

Als Teilgebiet der Arbeitswissenschaften beschäftigt sich die Ergonomie mit der »Anpassung der Technik an den Menschen zur Erleichterung der Arbeit« [Bul13]. Bei der Bearbeitung komplexer Aufgaben soll die Belastung des arbeitenden Menschen so ausgewogen wie möglich sein, und zwar in technischer, medizinischer, psychologischer, sozialer und ökonomischer Hinsicht. Der Grad der Ergonomie kann beispielsweise anhand der Leistung, der Zuverlässigkeit, der Gebrauchstauglichkeit und der Wirtschaftlichkeit gemessen werden [Syr07].

Für die Gestaltung von Mensch-Computer-Systemen ist neben der physikalischen Ergonomie, wie beispielsweise der optimalen Sitzhaltung, die kognitive Ergonomie (engl.: »Human Factors«) von entscheidender Bedeutung. Diese beschäftigt sich mit den mentalen Prozessen bei der Interaktion des Menschen mit dem Computer. Speziell bei der Bedienung komplexer dynamischer Systeme, welche zwar Prozesse teilautomatisiert ausführen, der Benutzer jedoch trotzdem noch eigene Entscheidungen treffen muss, hat sich der Begriff des *Situationsbewusstseins* (SA, engl.: »Situation Awareness«) als Bezeichnung für den mentalen Zustand ausgeprägt.

Das Konzept des Situationsbewusstseins fand bisher Anwendung bei Piloten in der Luftfahrt [Sel91; End98], bei Fluglotsen in der Luftraumüberwachung [Dur98], bei Kapitänen in der Schifffahrt [Oka09], bei Anwendern von Systemen zur Seeüberwachung und Schiffsnavigation [Riv08a; Lav11; Fio12], bei Entscheidungsträgern im Krisenmanagement [Har07b] und in militärischen Operationen [Sal09], bei Bedienern von Fahrzeugen [Wul13], bei Nutzern von Leitwarten zur Energieübertragung und -verteilung [End08] sowie bei Medizinern und Ärzten [Sch13]. Die breit gefächerten Anwendungsgebiete unterstreichen, dass Situationsbewusstsein genau dann von Bedeutung ist, wenn der Mensch Entscheidungen treffen muss.

### 2.1.1. Definition von Situationsbewusstsein

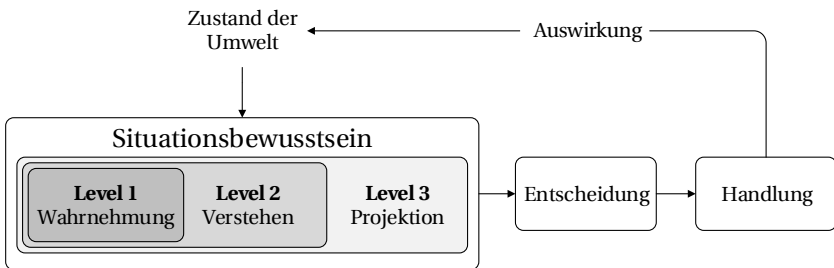
Die heute am weitesten akzeptierte Definition für Situationsbewusstsein wurde von Endsley in [End95b] veröffentlicht, wobei diese Arbeit auf einer früheren Veröffentlichung beruht [End88]. Sie definiert Situationsbewusstsein mit Hilfe von drei hierarchischen Ebenen, bei Endsley Levels genannt:

»Situationsbewusstsein ist die Wahrnehmung der Elemente in der Umwelt innerhalb eines räumlich-zeitlichen Abschnitts, das Verstehen ihrer Bedeutung und die Projektion ihrer Zustände in die nahe Zukunft<sup>6</sup>.«

---

<sup>6</sup> Eigene Übersetzung. Original: »Situation awareness is the perception of the elements in the environment within a volume of time and space, the comprehension of their meaning, and the projection of their status in the near future.«

Situationsbewusstsein ist also definiert als ein mentaler Zustand und ist eine wichtige Basis für menschliche Entscheidungen. Die Prozesse des Wahrnehmens, des Verstehens und der Projektion dienen dem Erreichen oder dem Aufrechterhalten dieses Zustandes. Dieser menschliche Entscheidungszyklus ist in Abbildung 2.1 dargestellt.



**Abbildung 2.1.:** Das Situationsbewusstsein nach Endsley [End95b].

Im ersten Prozess, dem Wahrnehmen, werden der Zustand, die Attribute und das dynamische Verhalten von relevanten Elementen der Umgebung wahrgenommen. Bei einem maritimen Überwachungssystem beinhaltet dies beispielsweise die Schiffe, welche sich aktuell im überwachten Gebiet aufhalten und bewegen, sowie deren aktueller Zustand wie beispielsweise Position oder Geschwindigkeit.

Im Prozess des Verstehens werden die wahrgenommenen Elemente hinsichtlich der Aufgabenstellung analysiert und ihre Relevanz festgestellt. Dadurch erlangt der Entscheider ein ganzheitliches Verständnis der aktuellen Lage. In diesem Prozess werden also sowohl zeitliche, räumliche und attributive Beziehungen zwischen den wahrgenommenen Elementen mit bekannten Mustern verglichen. In maritimen Überwachungssystemen beinhaltet dies beispielsweise das Erkennen, dass ein Schiff von seiner Route abweicht oder sich bezüglich seines Schiffstyps anormal verhält.

Das höchste Situationsbewusstsein wird erlangt, wenn der Entscheider zusätzlich in der Lage ist, das Verhalten der Elemente vorherzusagen. Basierend auf seinem aktuellen Verständnis der Lage projiziert er also die Zustände der Elemente in die nahe Zukunft. In maritimen Überwachungssystemen beinhaltet

tet dies beispielsweise die Vorhersage der Position eines Schiffes, basierend auf seinem Kurs und seiner Geschwindigkeit, oder sogar die Vorhersage des wahrscheinlichsten Zielhafens.

Basierend auf den drei Ebenen des Situationsbewusstseins können nun im Folgeprozess die Entscheidungen getroffen werden. Ein wesentlicher Beitrag von Endsleys Modell ist die Entkopplung des Situationsbewusstseins von der Entscheidung selbst. Beispielsweise kann eine Person sehr gut auf eine bestimmte Aufgabe hin trainiert werden und aufgrund dessen grundsätzlich optimale Entscheidungen treffen. Ist jedoch das Situationsbewusstsein fehlerbehaftet oder unvollständig, so kann die Person trotz des guten Trainings falsche Entscheidungen treffen. Im umgekehrten Fall kann trotz eines idealen Situationsbewusstseins die Leistung des Menschen sehr niedrig sein, wenn dieser nicht genügend Training für die Aufgabe erfahren hat. Folglich ist es sinnvoll, diese beiden kognitiven Prozesse voneinander zu trennen. Nach [End95b] ist jedoch generell eine schlechte menschliche Leistung zu erwarten, wenn ein geringes Situationsbewusstsein vorliegt. Andererseits ist ein hohes Maß an Situationsbewusstsein ein wesentlicher Faktor, um die Wahrscheinlichkeit für eine gute Leistung zu erhöhen, wobei diese wiederum nicht garantiert werden kann.

Des Weiteren analysiert Endsley die Faktoren, welche das Situationsbewusstsein beeinflussen [End95b]. Dies sind Mechanismen der menschlichen Informationsverarbeitung wie die eigenen Fähigkeiten, Erfahrungen und durchlaufene Trainings. Weiter gibt es individuelle Einflussfaktoren wie die eigene Zielsetzung, vorgefasste Meinungen und Erwartungshaltungen. Ein wesentlicher Faktor ist das Systemdesign. Dazu zählen die Fähigkeiten des Systems selbst, das Design der Benutzerschnittelle, die Komplexität des Systems, der Grad der Automatisierung und die aufgabenabhängige Arbeitsbelastung, welcher der Benutzer ausgesetzt wird.

### 2.1.2. Messung des Situationsbewusstseins

Durch die Entkopplung des Entscheidungsprozesses vom Prozess zur Erlangung eines hohen Situationsbewusstseins stellt sich nun die Frage, wie das Situationsbewusstsein gemessen werden kann. Grundsätzlich lassen sich die Techniken zur Messung des Situationsbewusstseins in drei Kategorien einteilen [End95a; Jun12]:



- subjektive Messmethoden,
- objektive oder auch explizite Messmethoden,
- leistungsbezogene oder auch implizite Messmethoden.

### Subjektive Messmethoden

Unter den subjektiven Messmethoden versteht man die Bestimmung des Situationsbewusstseins durch Fragebögen. Bei der Selbsteinschätzung beantwortet der Anwender den Fragebogen, bei der Fremdeinschätzung vollzieht dies eine beobachtende Person. Der Fragebogen kann entweder während oder nach der Systembenutzung beantwortet werden. Die Einschätzungen zu den einzelnen Bewertungskriterien werden dabei meist auf einer numerischen Skala eingetragen und im Anschluss kann ein Gesamtwert berechnet werden.

Eine der bekanntesten subjektiven Methode ist die »Situational Awareness Rating Technique« (SART) nach Taylor [Tay90]. Dort werden mehrere Fragen in jeweils drei Kategorien gestellt:

- Anforderungen an die Aufmerksamkeitsressourcen ( $A$ ),
- Bereitstellung von Aufmerksamkeitsressourcen ( $B$ ),
- Verstehen der Situation ( $V$ ).

Die einzelnen Fragen werden mit einem numerischen Wert zwischen 1 und 7 bewertet und zu einem Gesamtwert kombiniert, um einen einzelnen Wert ( $SA$ ) für das Situationsbewusstsein zu ermitteln [Tay95]:

$$SA = V - (A - B). \quad (2.1)$$

Eine speziell zur Messung der Arbeitsbeanspruchung entworfene subjektive Methode ist der »NASA Task Load Index« (NASA TLX)<sup>7</sup>. Dieser wurde bereits in den 80er Jahren entwickelt [Har88] und schon in mehreren hundert Studien weltweit verwendet [Har06]. In diesem Fragebogen hat der Nutzer jeweils eine Frage zu jeder der folgenden sechs Kategorien zu beantworten:

---

<sup>7</sup> Die »National Aeronautics and Space Administration« (NASA) ist die amerikanische Bundesbehörde für Raumfahrt und Flugwissenschaft, <http://www.nasa.gov/>, letzter Abruf am 16.04.2015

- mentale Beanspruchung ( $M$ ),
- physische Beanspruchung ( $P$ ),
- zeitliche Beanspruchung ( $Z$ ),
- Leistung ( $L$ ),
- Anstrengung ( $A$ ),
- Frustration ( $F$ ).

Die Skalen können dabei frei gewählt werden. Ursprünglich wurde für jede Fragestellung eine Skala von 1-100 vorgeschlagen, wobei jedoch eine 10er-Schrittweite empfohlen wird. Die resultierenden Werte werden schließlich gemittelt, um einen numerischen Wert für die Arbeitsbeanspruchung ( $B$ ) zu erlangen. Zur Anpassung an die Aufgabe können die einzelnen Faktoren noch zusätzlich mit den Gewichten  $w_M, w_P, w_Z, w_L, w_A$  und  $w_F$  gewichtet werden:

$$B = \frac{w_M M + w_P P + w_Z Z + w_L L + w_A A + w_F F}{w_M + w_P + w_Z + w_L + w_A + w_F}. \quad (2.2)$$

Ein wesentlicher Vorteil der subjektiven Messmethoden ist ihre einfache Umsetzbarkeit für die unterschiedlichsten Systeme. Da die Fragen oft erst nach der Systemsimulation zu beantworten sind, wird der Arbeitsablauf während der Bearbeitung der Aufgabe nicht unterbrochen. Nachteil ist jedoch, dass keine objektive Messung vorliegt. Des Weiteren ist sich der Nutzer seines fehlendes Situationsbewusstseins nicht bewusst [End98].

### Objektive Messmethoden

Unter den objektiven Messmethoden versteht man die Bestimmung des Situationsbewusstseins durch das Prüfen von Gedächtnisleistungen [Jun12]. Dabei werden meist während einer Simulation des zu prüfenden Systems bestimmte Informationen ausgeblendet, welche der Anwender dann wiedergeben muss. Dies geschieht entweder computerbasiert, durch verbalen Austausch oder durch Fragebögen.

Eine der bekanntesten objektiven Methoden ist die »Situation Awareness Global Assessment Technique« (SAGAT) nach Endsley [End88]. SAGAT wurde speziell für die Messung des Situationsbewusstseins von Piloten entwickelt, ist

jedoch auf andere Anwendungsbereiche übertragbar. Dafür ist es notwendig, eine Aufgabenanalyse durchzuführen, um die richtigen Fragestellungen zu identifizieren [End95a]. Das Vorgehen bei SAGAT ist wie folgt: Zunächst wird die Systemsimulation abgespielt, bis sie an einem zufälligen Zeitpunkt angehalten wird und gleichzeitig alle Informationsquellen ausgeblendet werden. Der Nutzer beantwortet nun Fragen nach konkreten Informationen, beispielsweise nach der Position des Flugzeugs auf der Karte. Die Fragen werden den einzelnen Levels des Situationsbewusstseins zugeordnet, wobei sie meist das erste Level, also die Wahrnehmung betreffen. Da es aufgrund zeitlicher Randbedingungen oft nicht möglich ist, bei jedem Simulationsstopp alle Fragen zu beantworten, können diese zufällig ausgewählt werden. Bis zum Ende der Systemsimulation werden mehrere Stopps eingelegt. Zusätzlich zu den Fragen werden Toleranzbereiche für die Antworten festgelegt. Liegt die Antwort innerhalb des Toleranzbereiches, wird sie als korrekt bewertet, ansonsten als nicht korrekt. Die Simulation wird für jeden Nutzer mehrmals durchlaufen, um eine ausreichende Datenmenge zu erhalten. Der Grad des Situationsbewusstseins ( $SA$ ) kann dann berechnet werden als

$$SA = \frac{1}{n} \sum_{i=1}^n \delta(i), \quad (2.3)$$

wobei

$$\delta(i) = \begin{cases} 1, & \text{wenn Frage } i \text{ korrekt beantwortet wurde,} \\ 0, & \text{wenn Frage } i \text{ nicht korrekt beantwortet wurde,} \end{cases} \quad (2.4)$$

und  $n$  die Anzahl der Fragen ist. Dabei kann beispielsweise über alle Fragen eines Levels, einer Versuchsperson, eines Versuchsaufbaus oder über alle Fragen summiert werden. Dies ist abhängig davon, welche Aussage untersucht werden soll. Dadurch, dass über unterschiedlichen Fragen summiert werden kann, hat SAGAT die Fähigkeit, unterschiedliche Kriterien zu evaluieren, wie zum Beispiel unterschiedliche Variationen in der Informationsdarstellung.

Vorteil dieser Methode ist, dass Wissen des Nutzers über die aktuelle Situation direkt gemessen wird und somit eine objektive Bewertung durchgeführt werden kann. Ein Nachteil ist die Unterbrechung des Arbeitsablaufes durch die erzwungenen Simulationsstopps, was in einer höheren Arbeitsbeanspruchung resultieren kann [End95a]. Des Weiteren werden in SAGAT alle Fragen gleich gewichtet. Für den Anwendungsbereich der Flugsicherung haben Hauss und Eyferth in [Hau03] die SAGAT-Methode erweitert, indem

sie die einzelnen Fragen unterschiedlich gewichten. Die Gewichtungen wurden vorab mit Experten bestimmt. Insgesamt ist die SAGAT-Methode sehr aufwändig umzusetzen, da keine Standard-Fragen gestellt werden können und die Systemsimulation angepasst werden muss, um die Stopps und die Ausblendungen der Information umzusetzen.

### **Leistungsbezogene Messmethoden**

Leistungsbezogene Messmethoden verwenden die Qualität des Arbeitsergebnisses, um auf das Situationsbewusstsein zu schließen. Dazu verwendet werden können beispielsweise Reaktionszeiten auf bestimmte Ereignisse in der Systemsimulation oder auch die Korrektheit der Entscheidungen, die der Nutzer während der Simulation treffen muss.

Vorteile solcher Messungen sind ihre Objektivität und ihre einfache Handhabung und Umsetzbarkeit. Außerdem wird der eigentliche Arbeitsablauf nicht durch Unterbrechungen gestört. Der wesentliche Nachteil dieser Methodik besteht darin, dass von der Leistung des Nutzers nicht direkt auf das Situationsbewusstsein geschlossen werden kann. Dies liegt an der Tatsache, dass die kognitiven Prozesse zum Erreichen des Situationsbewusstseins und das Entscheiden selbst voneinander getrennt zu betrachten sind, wie oben erläutert wurde. Dadurch kann insbesondere bei einer schlechten Leistung nicht auf die konkrete Ursache geschlossen werden [End95a]. Dennoch werden leistungsbezogene Methoden häufig mit betrachtet, da deren Ergebnis zumindest als Indikator für das Situationsbewusstsein gelten kann.

### **Vergleich der Methodiken**

In [Sel91] werden in einer Flugsimulation die Ergebnisse der NASA TLX-Methode zur Messung der Arbeitsbeanspruchung und die SART-Methode zur Messung des Situationsbewusstseins miteinander verglichen. Teilnehmer der Studie waren zwölf Piloten der Luftstreitkräfte der USA, denen verschiedene Videos gezeigt wurden. Es zeigte sich eine Korrelation zwischen der subjektiven Einschätzung der eigenen Leistung und der subjektiven Einschätzung des Situationsbewusstseins (SART). Des Weiteren korrelierten die Ergebnisse von NASA TLX und SART bezüglich der Fragen nach der subjektiven Beanspruchung. Hieraus kann geschlossen werden, dass beide Methoden denselben Sachverhalt messen [Sel91].

In [End98] vergleicht Endsley die Methoden SAGAT und SART. In der Studie gaben die Teilnehmer zusätzlich noch ihre subjektive Bewertung zu ihrer Leistung ab. Bei den Teilnehmern handelte es sich um zwölf Kampfpiloten. Evaluiert wurden zwei unterschiedliche Arten der Informationsdarstellung im Cockpit. Endsley stellte fest, dass die beiden Maße SAGAT und SART nicht korrelieren, dafür jedoch das Ergebnis der subjektiven Leistungsbewertung mit dem berechneten SART-Wert eine starke Korrelation aufweist. Dies deckt sich mit den Ergebnissen aus [Sel91]. Durch die an die Aufgabe angepassten Fragestellungen ist SAGAT geeigneter, um die Darstellungsarten differenzierter bewerten zu können, also nicht nur eine Aussage zu treffen, welche Darstellung die geeignetste ist, sondern welche Teilelemente das Situationsbewusstsein fördern und welche nicht [End98].

In einer aktuelleren Veröffentlichung von Salmon et al. [Sal09] mussten zwanzig Teilnehmer eine militärische Planungsaufgabe lösen. Zur Messung des Situationsbewusstseins wurden hier die SART und die SAGAT-Methode angewendet, sowie die Leistung gemessen und nach dem NASA TLX die Arbeitsbeanspruchung bewertet. Salmon et al. fanden eine signifikante Korrelation zwischen dem SAGAT-Ergebnis und der tatsächlichen Leistung [Sal09]. Differenzierter betrachtet korrelierte das gemessene Level 2-Situationsbewusstsein (Verstehen) mit der Leistung, nicht jedoch die beiden anderen Levels 1 und 3 (Wahrnehmung und Projektion). Auch Salmon et al. konnten keine Korrelation zwischen SAGAT und SART nachweisen. Auch eine Korrelation zwischen SART und NASA TLX wie in [Sel91] konnte nicht bestätigt werden.


Zusammenfassend ist festzuhalten, dass die objektiven und die subjektiven Messmethoden keine Korrelation zur Bestimmung des Situationsbewusstseins zeigen. Diese Tatsache könnte ein Indikator dafür sein, dass das subjektive Situationsbewusstsein nicht mit dem tatsächlichen Situationsbewusstsein übereinstimmt, und dass die subjektiven und die objektiven Messmethoden unterschiedliche Aspekte des Situationsbewusstseins messen [Sal09].

### 2.1.3. OODA-Entscheidungszyklus

Aus dem Bereich der militärischen Kriegsführung ist ein dem Situationsbewusstsein ähnliches Modell des menschlichen Entscheidungszyklus bekannt, der sogenannte OODA-Loop. Dabei steht OODA für »Observe - Orient - Decide - Act«, also die Prozesse Beobachten, Orientieren, Entscheiden und Handeln. Dieser OODA-Loop geht zurück auf John Boyd, einen amerikanischen Kampfpiloten, der seine Theorien jedoch nie wissenschaftlich veröffentlicht hat.

Eine umfassende Beschreibung des OODA-Loops und seiner historischen Entwicklung findet sich bei Osinga [Osi07].

Nach Osinga ist die einzige Skizze von Boyds OODA-Loop in einer Folie aus dem Jahre 1995 zu finden, wenngleich er seine Theorien schon ab 1976 aufzuschreiben begann. Eine vereinfachte bildliche Darstellung des OODA-Loops ist beispielsweise in [Roy01] zu finden. Diese Skizze ist in Abbildung 2.2 veranschaulicht.



**Abbildung 2.2.:** Der vereinfachte OODA-Loop nach Roy [Roy01].

Grundsätzlich ist der OODA-Loop als Entscheidungszyklus zu interpretieren [Osi07]. Dabei ist anzunehmen, dass der Gesamtprozess einem Agenten zugeordnet ist und dieser konkurrierend mit anderen Agenten in der Umwelt interagiert, das heißt, es wird angenommen, dass die anderen Agenten auch dem Prinzip eines OODA-Loops folgen [Gra05]. Nach [Gra05] sind die Einzelprozesse des OODA-Loops wie folgt zu interpretieren.

Der Prozess des Beobachtens umfasst die Gewinnung von Informationen über die Umwelt, in Abbildung 2.2 als reale Welt bezeichnet. Dies geschieht durch Interaktion, durch aktive Beobachtung mittels Sensoren oder durch den Erhalt von Nachrichten über den Zustand der Umwelt. Der Beobachtungsprozess wird einerseits durch die Erwartungen des Orientierungsprozesses initiiert und andererseits durch die Entscheidungs- und Handlungsprozesse gesteuert.

Der Orientierungsprozess stellt das zentrale Element des OODA-Loops dar, da er bestimmt, in welcher Weise die Umwelt beobachtet wird, welche Entscheidungen getroffen werden und welche Handlungen vollzogen werden sollen. Die Orientierung ist ein interaktiver Prozess, welcher durch die unter-

schiedlichsten Aspekte wie Erfahrungen, kulturelle Traditionen und gegebene Umstände geprägt ist. Das Ergebnis des Orientierungsprozesses sind Bilder, Ansichten und Eindrücke über die reale Welt.

Im Entscheidungsprozess wird aus unterschiedlichen Hypothesen über mögliche Reaktionen auf den aktuellen Zustand der Umwelt eine Hypothese ausgewählt. Dabei wird die Entscheidung auf die Erkenntnisse des Orientierungsprozesses gestützt. Das Handeln ist schließlich die Ausführung der getroffenen Wahl. Der Zyklus schließt sich, da das Handeln die reale Welt beeinflusst und somit neue Beobachtungen initiiert werden. Agieren viele Agenten nach dem OODA-Loop in der selben Umwelt, so gewinnt nach [Gra05] derjenige, der schneller als der Gegner den Zyklus durchläuft oder im Idealfall den Zyklus des Gegners durchschaut.

Um den OODA-Loop als menschlichen Entscheidungszyklus zu interpretieren, fehlen den Ansätzen nach Boyd jedoch wesentliche kognitive Aspekte [Gra05]. Konzepte wie Aufmerksamkeit, Gedächtnisleistung oder Arbeitsbelastung sind im OODA-Loop nicht berücksichtigt. Dennoch gibt es viele Parallelen zum Konzept des Situationsbewusstseins nach Endsley. Nach [End97] decken sich die beiden Prozesse Beobachten und Orientieren mit den drei Ebenen des Situationsbewusstseins (Wahrnehmung, Verstehen, Projektion). Dies deckt sich auch mit dem Verständnis von [Roy01]. Wie in Abbildung 2.2 veranschaulicht, ist das Situationsbewusstsein ein mentaler Zustand, welcher aus den Prozessen Beobachten und Orientieren resultiert. Im direkten Vergleich entspricht der Beobachtungsprozess der Wahrnehmung (Level 1) und der Orientierungsprozess dem Verstehen (Level 2). Die Projektion nach Endsley hat jedoch kein direktes Äquivalent [Gra05]. Eine Möglichkeit wäre, die Projektion noch dem Orientierungsprozess zuzuordnen. Nach [Gra05] müsste jedoch der OODA-Loop um eine Planungskomponente erweitert werden.

## 2.2. Datenfusionsmodelle

Analog zum Situationsbewusstsein, welches sich mit dem kognitiven Entscheidungsprozess des Menschen beschäftigt, gibt es auf maschineller Ebene das Konzept der Daten- und Informationsfusion [Hal04]. Dieses beschäftigt sich damit, welche Prozesse automatisiert oder auch teilautomatisiert umgesetzt werden können, mit dem Ziel, das Situationsbewusstsein interaktiv zu unterstützen.

Die Daten- und Informationsfusion adressiert interdisziplinäre Ansätze sowohl in der theoretischen als auch in der angewandten Forschung. Die Datenfusion wird hauptsächlich in Multi-Sensor-Systemen angewendet. Ziel ist, Daten unterschiedlicher Sensoren zu kombinieren und aus den fusionierten Daten Schlussfolgerungen zu ziehen, die aus einem einzelnen Sensor nicht ableitbar wären [Hal04].

Das Prinzip der Daten- und Informationsfusion findet beispielsweise Anwendung in den Gebieten der multisensoriellen Überwachung wie der Videoüberwachung [Sni04; Sni11; Fis14a] oder der maritimen Überwachung [Gad02; Car07; Gue08; Gar10; Fis10b; Gab12], in der Robotik [Abi92; Str01; Bau10b; Bel12a], in der Forschung für autonome Fahrzeuge [Bec00; Dar08; Hos12], im Krisenmanagement [Lli02; Jot09; Flo09] oder in der medizinische Diagnostik [Sol99; Azu99; Pol08].

Die Forschung im Bereich der Daten- und Informationsfusion beschäftigt sich einerseits mit der Definition von Softwarearchitekturen, welche entweder zentralisiert oder verteilt umgesetzt werden können [Mit12]. Andererseits beschäftigt sie sich mit Methoden zur Fusion von Sensor-Rohdaten wie beispielsweise Bilddaten, mit der Objektverfolgung (engl.: »Target Tracking«), also der Positionsschätzung von Objekten über die Zeit hinweg, mit der Klassifikation von beobachteten Objekten, mit Verhaltensanalysen von Objekten sowie mit Methoden der Entscheidungsunterstützung.

Generelle Ansätze zu den hier aufgelisteten Problemstellungen werden in einem Übersichtsartikel von Khaleghi [Kha13], sowie in den Büchern von Hall und McMullen [Hal04], Klein [Kle04] und Mitchell [Mit12] erläutert. Spezifische, für diese Arbeit relevante Publikationen werden in den Abschnitten 2.3, 2.4 und 2.5 adressiert.

Trotz der breiten Anwendungsfelder und Problemstellungen haben sich nur wenige Publikationsreihen auf die Daten- und Informationsfusion spezialisiert. Erwähnenswert ist zum einen die unabhängige, gemeinnützige Organisation »International Society of Information Fusion« (ISIF)<sup>8</sup>. Diese hat den Anspruch, eine weltweite Gemeinschaft im Bereich der Daten- und Informationsfusion zu bilden und hat sich über die letzten 15 Jahre auch etabliert. So organisiert die ISIF beispielsweise die seit 1998 durchgeführte »International Conference on Information Fusion« (FUSION)<sup>9</sup>. Zum anderen

---

<sup>8</sup> <http://www.isif.org>, letzter Abruf am 16.04.2015

<sup>9</sup> <http://www.isif.org/conferences>, letzter Abruf am 16.04.2015



hat sich neben der ISIF das seit 2000 vom Elsevier-Verlag herausgegebene Journal »Information Fusion - An International Journal on Multi-Sensor, Multi-Source Information Fusion«<sup>10</sup> als das bedeutendste Journal in diesem Bereich etabliert.

### 2.2.1. Terminologie der Datenfusion

Die Terminologie im Bereich der Daten- und Informationsfusion wird in der Literatur nicht einheitlich verwendet. Dies zeigt sich etwa dadurch, dass die Begriffe Sensorfusion, Datenfusion, Informationsfusion und Multisensor-Datenfusion für unterschiedliche Sachverhalte verwendet werden [Ste01; Sni11].

Dasarathy verwendet den Begriff der Informationsfusion als übergeordnete Bezeichnung [Das01]. Nach Dasarathy umfasst die Informationsfusion »Theorien, Techniken und Werkzeuge, welche Synergieeffekte in Informationen aus unterschiedlichen Quellen ausnutzen. Die aus der Informationsfusion resultierende Entscheidung oder Aktion ist in qualitativer oder quantitativer Weise besser als jegliche Entscheidung, welche auf Basis einer einzigen Informationsquelle getroffen worden wäre<sup>11</sup>.«

Im Gegensatz dazu definiert White [Whi91] den Begriff der Datenfusion als übergeordneten Begriff:

»Datenfusion ist ein Prozess, welcher sich mit der Assoziation, der Korrelation und der Kombination von Daten und Information aus einer oder mehrerer Quellen beschäftigt, um verfeinerte Positions- und Identitätsschätzungen und um vollständige und zeitnahe Analysen von Situationen und Bedrohungen wie auch deren Signifikanz zu erreichen<sup>12</sup>.«

---

<sup>10</sup> <http://www.journals.elsevier.com/information-fusion>, letzter Abruf am 16.04.2015

<sup>11</sup> Eigene Übersetzung. Original: »Information Fusion encompasses theory, techniques and tools conceived and employed for exploiting the synergy in the information acquired from multiple sources (sensor, databases, information gathered by human, etc.) such that the resulting decision or action is in some sense better (qualitatively or quantitatively, in terms of accuracy, robustness, etc.) than would be possible, if any of these sources were used individually without such synergy exploitation.«

<sup>12</sup> Eigene Übersetzung. Original: »Data Fusion is a process dealing with the association, correlation, and combination of data and information from single and multiple sources to achieve refined position and identity estimates, and complete and timely assessments of situations and threats as well as their significance.«

Steinberg und Bowman [Ste01] vereinfachen diese Definition zu folgender, welche sich weitestgehend durchgesetzt hat:

»Datenfusion ist der Prozess, welcher Daten kombiniert, um Zustandsschätzungen und -vorhersagen zu verfeinern<sup>13</sup>.«

Auch Lambert interpretiert den Begriff der Datenfusion als übergeordnete Bezeichnung und adaptiert die Definition von Steinberg und Bowman wie folgt [Lam01]:

»Datenfusion ist der Prozess, welcher eine oder mehrere Datenquellen über die Zeit hinweg verwendet, um eine Repräsentation von interessanten Aspekten der Umwelt zusammensetzen<sup>14</sup>.«

Die Informationsfusion ist nach [Whi91; Ste01; Lam03], im Gegensatz zu Dasarathy [Das01], eine Teilmenge der Datenfusion. Dies deckt sich auch mit der sogenannten Wissenspyramide, welche aus den vier Ebenen Daten, Information, Wissen und Weisheit besteht [Row07]. Auf unterster Ebene sind die Daten angesiedelt. Aus den Daten kann Information generiert werden, das heißt, die Information ist implizit in den Daten enthalten.

Auch der Begriff der Sensorfusion wird nicht einheitlich für den gleichen Sachverhalt verwendet. Klein [Kle04] beschreibt die Sensorfusion wie folgt:

»Die Sensorfusion beschreibt die Verwendung von mehr als einem Sensor in einem Multisensorsystem, um präzisere oder zusätzliche Daten über Ereignisse oder Objekte zu sammeln, welche im Beobachtungsraum der Sensoren liegen<sup>15</sup>.«

Lambert hingegen identifiziert die Sensorfusion nur mit der Schätzung von Objektzuständen und nicht mit der Schätzung von Ereignissen [Lam03]. Die Sensorfusion ist nach Lambert also als eine Teilmenge der Datenfusion zu interpretieren.

---

<sup>13</sup> Eigene Übersetzung. Original: »Data fusion is the process of combining data to refine state estimates and predictions.«

<sup>14</sup> Eigene Übersetzung. Original: »Data fusion is the process of utilizing one or more data sources over time to assemble a representation of aspects of interest in an environment.«

<sup>15</sup> Eigene Übersetzung. Original: »Sensor fusion describes the use of more than one sensor in a multisensor system to enable more accurate or additional data to be gathered about events or objects present in the observation space of the sensors.«

Der Begriff der Multisensor-Datenfusion hebt generell die Verwendung von mehreren Sensoren hervor, welche entweder gleichartig oder heterogen sein können. Ein wesentlicher Aspekt der Multisensor-Datenfusion ist, dass die aus mehreren Sensordaten generierte Information in einer gewissen Weise als besser bewertet werden kann als Information, welche aus nur einem Sensor generiert werden kann [Hal97; Sni11; Mit12].

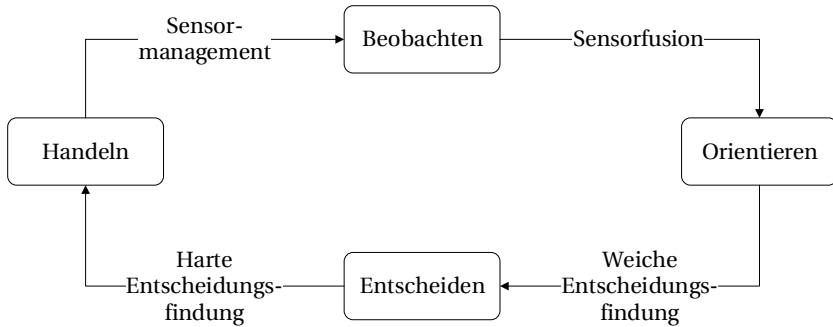
In dieser Arbeit wird der Begriff der Datenfusion als übergeordneter Begriff verwendet. Die Sensorfusion und die Informationsfusion werden als Teilmengen der Datenfusion betrachtet [Lam03]. Der Begriff der Multisensor-Datenfusion wird analog zur Datenfusion genutzt, wobei der Aspekt der Verwendung von mehr als einem Sensor betont wird.

Die prinzipielle Motivation der Datenfusion ist also die Qualität der resultierenden Information zu verbessern. Dies geschieht durch Synergieeffekte, welche entweder aus einer zeitlichen Abfolge von Daten eines Sensors, aus Daten mehrerer Sensoren oder sogar aus einer zeitlichen Abfolge von Daten mehrerer Sensoren entstehen. Die verbesserte Qualität kann aus einer erhöhten räumlichen oder zeitlichen Abdeckung der eingesetzten Sensoren, aus einer höheren Robustheit, einer besseren Rauschunterdrückung oder einer besseren Schätzgenauigkeit der eingesetzten Verfahren entstehen [Mit12].

### 2.2.2. Omnibus-Modell

Das Omnibus-Modell ist ein Prozessmodell, welches auf dem OODA-Loop basiert und den kognitiven Entscheidungsprozess auf die maschinelle Ebene überträgt. Das Omnibus-Modell wurde von Bedworth und O'Brian in [Bed99] vorgestellt und ist in Abbildung 2.3 dargestellt. Im Vergleich zum OODA-Loop werden in diesem Zyklus explizit die Stellen, an denen unterschiedliche Arten von Fusion stattfindet, deutlich gemacht [Bed99]. Des Weiteren ordnet das Omnibus-Modell den einzelnen Prozessschritten des OODA-Loops maschinelle Funktionalitäten zu [Bed99; Bar07]:

- **Beobachten:** Messen und Signalverarbeitung,
- **Orientieren:** Merkmalsfusion basierend auf Merkmalsextraktion und Mustererkennung,
- **Entscheiden:** Kontextverarbeitung und Entscheidungsfindung,
- **Handeln:** Steuern/Regeln und Ressourceneinsatz.



**Abbildung 2.3.:** Das Omnibus-Prozessmodell nach Bedworth und O'Brian [Bed99].

Im Omnibus-Prozessmodell bauen die weiteren Verarbeitungsschritte auf den Ergebnissen des vorherigen Prozessschrittes auf. Nach dem Beobachtungsprozess werden die Sensordaten fusioniert (Sensorfusion) und im Orientierungsschritt weiter verarbeitet. Basierend auf der Merkmalsfusion und der Mustererkennung werden weiche Entscheidungsfindungen generiert, also eine Reihe von Hypothesen aufgestellt. Basierend auf dem Entscheidungsprozess werden harte Entscheidungen zum weiteren Handeln getroffen. Dies beinhaltet im Wesentlichen das Sensormanagement, also die Planung des weiteren Sensoreinsatzes.

### 2.2.3. JDL-Datenfusionsmodell

Das JDL-Datenfusionsmodell wurde in den 80er Jahren von der Datenfusionsgruppe des Joint Directors of Laboratories (JDL) entwickelt und ist bis heute das am meisten verwendete Modell der Datenfusion [Ste01]. Das Modell unterscheidet zwischen einzelnen Fusions Ebenen, wobei diese jeweils definiert sind durch den Entitätstyp, dessen Eigenschaften geschätzt werden [Roy01]. Der Begriff der Entität wird in diesem Zusammenhang nicht nur für physikalische Objekte in der Umwelt verwendet, sondern für jegliche Gegebenheiten, über welche Informationen gesammelt werden, also beispielsweise auch für Situationen oder Ereignisse. Das JDL-Datenfusionsmodell ist folglich kein Prozessmodell, sondern ein funktionales Modell. Es dient somit zur Kategorisierung einzelner Fusionsprozesse und hat nicht den Anspruch, die Prozessabfolge abzubilden wie das Omnibus-Modell. Das JDL-Datenfusionsmodell

nach [Ste01] ist in Abbildung 2.4 abgebildet. Das JDL-Datenfusionsmodell bildet sowohl die Datenquellen als auch die Mensch-Maschine-Schnittstelle mit ab. Datenquellen sind beispielsweise Sensoren, Dokumente oder Personen. Die Mensch-Maschine-Schnittstelle dient sowohl zur Visualisierung der Fusionsergebnisse, als auch zur Eingabe für Befehle oder Systemanfragen.

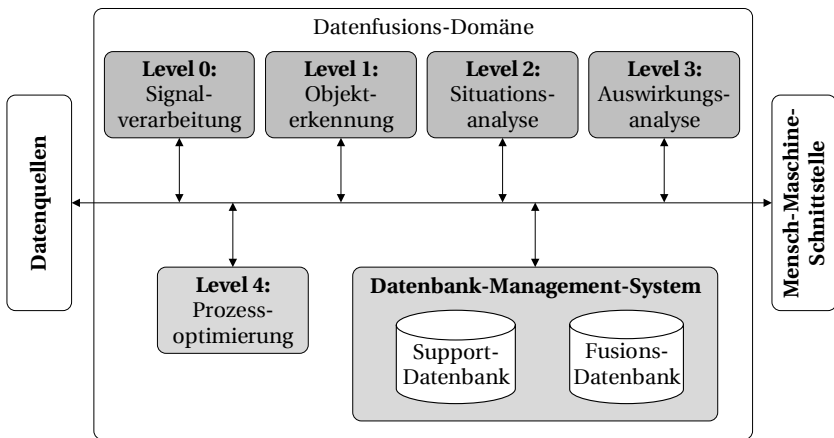


Abbildung 2.4.: Das JDL-Datenfusionsmodell nach [Ste01].

Eingebettet zwischen Datenquellen und Mensch-Maschine-Schnittstelle befinden sich die Prozesse der Datenfusion. Die Kategorisierung der einzelnen Prozesse wird mittels unterschiedlicher Levels vorgenommen, welche wie folgt interpretiert werden [Ste01]:

- **Level 0 - Signalverarbeitung:** Schätzung und Vorhersage von beobachtbaren Signal- oder Objektzuständen, basierend auf einer Datenassoziation oder Korrelation auf Pixel- oder Signalebene,
- **Level 1 - Objekterkennung:** Schätzung und Vorhersage von Entitätszuständen, basierend auf Inferenzergebnissen aus Beobachtungen,
- **Level 2 - Situationsanalyse:** Schätzung und Vorhersage von Entitätszuständen, basierend auf inferierten Relationen zwischen Entitäten,

- **Level 3 - Auswirkungsanalyse:** Schätzung und Vorhersage von Effekten auf Situationen, basierend auf geplanten oder geschätzten beziehungsweise vorhergesagten Handlungen der teilnehmenden Akteure,
- **Level 4 - Prozessoptimierung:** adaptive Datenakquisition und Verarbeitung im Hinblick auf die optimale Erfüllung von Missionszielen.

Zusätzlich zur Kategorisierung der einzelnen Fusionsebenen ist im JDL-Datenfusionsmodell das Datenbank-Management-System explizit adressiert. Dieses beinhaltet beispielsweise für die Fusion notwendige Wissensdatenbanken oder die Zwischenspeicherung von Fusionsergebnissen [Hal04].

**Tabelle 2.1.:** Einordnung von Funktionalitäten in die JDL Datenfusionsebenen.

Level 0	Synchronisation Rauschunterdrückung Digitalisierung Bildverarbeitung Merkmalsextraktion
Level 1	Datenassoziation und -korrelation Objektdetektion Schätzung von kinematischen Objekteigenschaften Schätzung von Objektattributen Objektklassifikation Objektverfolgung (Tracking)
Level 2	Schätzung von Objektgregationen Situationserkennung Ereigniserkennung Aktivitätserkennung
Level 3	Intentionsschätzung Entscheidungsunterstützung Kosten-Nutzen Analysen
Level 4	Performanzoptimierung Sensoreinsatzplanung Adaptive Datenakquisition

Die Ebenen des JDL-Datenfusionsmodells bilden eine Kategorisierung einzelner Funktionalitäten. Tabelle 2.1 zeigt eine Einordnung einzelner Funktionalitäten in die einzelnen Ebenen nach [Roy01; Hal04] und [Bar07], jedoch ohne den Anspruch auf Vollständigkeit zu erheben.

Die in Tabelle 2.1 aufgelisteten Funktionalitäten können durch viele verschiedene Methoden umgesetzt werden. Im Wesentlichen stammen die Methoden aus dem Bereich des Maschinellen Lernens [Mur12], der Mustererkennung [Dud01] und der Künstlichen Intelligenz [Rus10]. Da das JDL-Datenfusionsmodell kein Prozessmodell ist, müssen in der praktischen Anwendung die einzelnen Funktionalitäten eher als Agenten umgesetzt werden, welche miteinander kommunizieren oder, besser noch, kooperieren müssen [Roy01].

In Tabelle 2.1 werden bewusst keine Literaturreferenzen angegeben. Dies hat den Grund, dass die vielfältigen Methoden in vielen unterschiedlichen Anwendungsgebieten zum Einsatz kommen. Die Literatur zu den einzelnen Funktionalitäten ist somit äußerst umfassend und eine vollständige Literaturangabe würde den Rahmen dieser Tabelle sprengen und keinen Mehrwert erzeugen. Auf die in dieser Arbeit relevanten Veröffentlichungen wird in den Folgekapiteln 2.3, 2.4 und 2.5 detailliert eingegangen. Grundsätzlich ist zu sagen, dass die Methoden zu Level 0 und Level 1 sehr gut untersucht sind und sich die Aufmerksamkeit der Forschung in den letzten Jahren zunehmend auf die höheren Level 2 und 3 richtete [Kha13].

#### 2.2.4. Datenfusion und Situationsbewusstsein

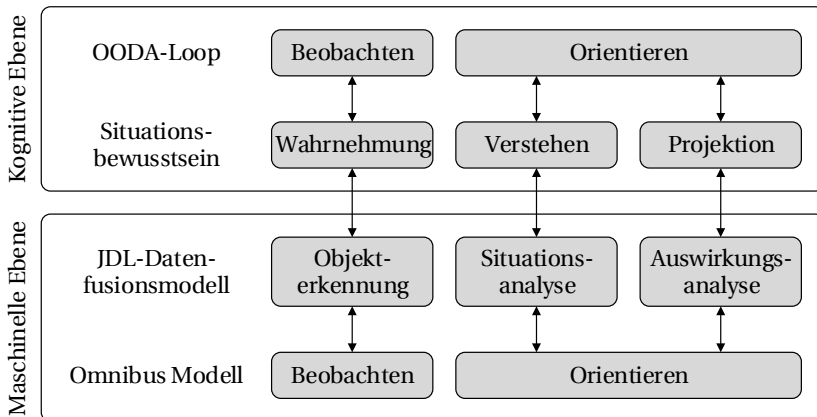
Durch die Kategorisierung der einzelnen Fusionsprozesse mittels des JDL-Datenfusionsmodells lassen sich die in Abschnitt 2.2.1 eingeführten Begriffe den unterschiedlichen Ebenen zuordnen. Nach [Lam03] können die in dieser Arbeit verwendeten Begriffe wie folgt durch den Vereinigungsoperator ausgedrückt werden:

$$\begin{aligned}\text{Sensorfusion} &= \text{Signalverarbeitung} \cup \text{Objekterkennung}, \\ \text{Informationsfusion} &= \text{Situationsanalyse} \cup \text{Auswirkungsanalyse}, \\ \text{Datenfusion} &= \text{Sensorfusion} \cup \text{Informationsfusion}.\end{aligned}$$

Im englischen Sprachgebrauch haben sich noch zwei weitere Bezeichnungen durchgesetzt. So wird für die Sensorfusion, also die Signalverarbeitung und die Objekterkennung, auch der englische Begriff »Low-Level Data Fusion«

verwendet. Analog dazu wird für die Informationsfusion, also die Situationsanalyse und die Auswirkungsanalyse, der Begriff »High-Level Data Fusion« verwendet. Des Weiteren lässt sich eine Analogie zwischen dem Situationsbewusstsein als mentalem Zustand und der Datenfusion auf Maschinenebene ziehen. Lambert identifiziert diese als identische Prozesse, wobei das Erreichen von Situationsbewusstsein als kognitiver Prozess und die Datenfusion als maschineller Prozess zu interpretieren ist [Lam01].

Abbildung 2.5 zeigt die in dieser Arbeit vorgestellten Modelle von Situationsbewusstsein und Datenfusion und ihre Zuordnung zueinander. So decken sich nach Endsley und Jones [End97] die beiden Prozesse Beobachten und Orientieren des OODA-Loops mit den drei Ebenen des Situationsbewusstseins. Die Level 1-3 des JDL-Datenfusionsmodells lassen sich jeweils zu den drei Ebenen des Situationsbewusstseins zuordnen [Lam01]. Die zwei Prozesse des Omnibus-Modells lassen sich analog zum OODA-Loop den Leveln 1-3 des JDL-Datenfusionsmodells zuordnen.



**Abbildung 2.5.:** Vergleich der Modelle auf kognitiver Ebene (Situationsbewusstsein nach Endsley und OODA-Loop) und der Modelle auf maschineller Ebene (Omnibus-Modell und JDL-Datenfusionsmodell).



## 2.3. Maritime Überwachungssysteme

### 2.3.1. Maritimes Situationsbewusstsein

Auch in der maritimen Domäne hat sich der Begriff des Situationsbewusstseins durchgesetzt. So definiert die Europäische Kommission das maritime Situationsbewusstsein wie folgt [Eur09]:

»Maritimes Situationsbewusstsein ist die genaue Wahrnehmung und korrekte Einschätzung des Risikopotenzials aller Tätigkeiten im maritimen Bereich, die die Sicherheit, die Wirtschaft oder die Umwelt der Europäischen Union und ihrer Mitgliedstaaten beeinflussen können. Ausgehend von klar definierten Erfordernissen und Rechten hilft dieses Situationsbewusstsein den Aufsichtsbehörden, solchen Situationen und Vorkommnissen im maritimen Bereich der EU umfassend vorzubeugen und sie zu bewältigen<sup>16</sup>.«

Im englischen Sprachgebrauch wird für das maritime Situationsbewusstsein die Bezeichnung »Maritime Domain Awareness (MDA)« verwendet [IMO13a]. Ein Instrument zur Unterstützung des maritimen Situationsbewusstseins ist das sogenannte gemeinsame Lagebild (COP, engl.: »Common Operational Picture«), welches im maritimen Bereich auch als maritimes Lagebild oder Seelagebild (RMP, engl.: »Recognized Maritime Picture«) bezeichnet wird. Das RMP ist ein zusammengesetztes Bild aller Aktivitäten in einem maritimen Gebiet von Interesse [Sim00; Bro11]. Es beinhaltet nicht nur alle Objekte von Interesse, sondern auch deren Identitäten und Aktivitäten, soweit diese von den Sensoren erfassbar sind. Das RMP bildet die wichtigste Grundlage für das maritime Situationsbewusstsein und damit auch für weiterführende Entscheidungen. Insbesondere ist die Qualität des RMP in hohem Maße von der Leistungsfähigkeit der eingesetzten Sensorik abhängig.

---

<sup>16</sup> Deutsches Original

## 2.3.2. Eingesetzte Sensorik

### AIS - Automatic Identification System

Das automatische Identifikationssystem AIS<sup>17</sup> (engl.: »Automatic Identification System«) wurde ursprünglich für die Erhöhung der Sicherheit im Schiffsverkehr entwickelt. AIS ist ein Funksystem im UKW (Ultrakurzwellen)-Bereich, welches von der IMO seit 2000 als verbindlicher Standard vorgeschrieben ist. Das AIS-System soll dabei Schiffsinformationen für andere Schiffe und für befähigte Behörden automatisch bereitstellen, um eine präzise Objektverfolgung zu ermöglichen [IMO98]. Die wesentlichen Funktionalitäten beinhalten nach [IMO98]: eine Schiff-zu-Schiff-Kommunikation zur Kollisionsvermeidung, das Einholen von Informationen über Schiffe und ihre Ladung für Küstenstaaten und das Bereitstellen einer Schnittstelle für die landseitige Regelung des Schiffsverkehrs.

Die technische Norm für AIS-Systeme, in der beispielsweise auch unterschiedliche Nachrichtentypen definiert sind, wird von der Internationalen Fernmeldeunion (ITU, engl.: »International Telecommunication Union«) herausgegeben und aktualisiert [ITU13]. Das in AIS-Systemen verwendete Übertragungsprotokoll basiert auf dem NMEA-Standard 0183 [NME08] und wird von der »National Marine Electronics Association« (NMEA) herausgegeben.

Die Vorschrift der IMO besagt, dass ab dem 31.12.2004 folgende Schiffe verpflichtet sind, einen AIS-Transceiver<sup>18</sup> einzusetzen [IMO01; Eur08]: Schiffe auf internationaler Fahrt und mit einer Bruttoreaumzahl von 300 oder mehr, Passagierschiffe jeglicher Größe, Tanker auf internationaler Fahrt und jeglicher Größe und Frachtschiffe mit einer Bruttoreumzahl von 500 oder mehr.

Mittels des AIS-Transceivers können Schiffe sowohl untereinander, als auch mit einer Küstenstation Nachrichten austauschen. Dabei beinhalten die ausgetauschten AIS-Nachrichten statische, dynamische und reisespezifische Informationen [IMO01]. Eine Übersicht über die statischen, dynamischen und reisespezifischen Daten zeigt Tabelle 2.2.

---

<sup>17</sup> <http://www.imo.org/OurWork/Safety/Navigation/Pages/AIS.aspx>, letzter Abruf am 16.04.2015

<sup>18</sup> Kombiniertes Sende- und Empfangsgerät, Kurzwort aus den englischen Begriffen »transmitter« und »receiver«

**Tabelle 2.2.:** Übersicht über die Inhalte in AIS-Nachrichten (nach [IMO01]).

Statische Daten	MMSI-Nummer Schiffsname IMO-Nummer Länge und Breite des Schiffs in Metern Schiffstyp
Dynamische Daten	Position in Längen- und Breitengraden Zeitstempel der Position in UTC Kurs über Grund in Grad Geschwindigkeit über Grund in Knoten Steuerkurs in Grad Navigationsstatus Kursänderungsrate
Reisespezifische Daten	Gefahrgutklasse der Ladung Reiseziel Erwartete Ankunftszeit

Bei den statischen Informationen handelt es sich im Wesentlichen um die MMSI-Nummer (»Maritime Mobile Service Identity«), welche der Rufnummer einer Seefunkstelle im GMDSS (»Global Maritime Distress and Safety System«) entspricht und in Deutschland durch die Bundesnetzagentur<sup>19</sup> vergeben wird, die IMO-Nummer, einer eindeutig vergebenen Schiffsnummer der IMO für Passagierschiffe mit einer Bruttoreaumzahl von 100 oder mehr und für Handelsschiffe mit einer Bruttoreumzahl von 300 oder mehr<sup>20</sup>, der Länge und Breite des Schiffs in Metern, sowie des Schiffstyps, welcher aus einer vordefinierten Liste ausgewählt wird.

Die dynamischen Daten beinhalten hauptsächlich die Position des Schiffs in Längen- und Breitengraden, welche meist über ein GPS-Gerät (engl.: »Global Positioning System«) ermittelt wird, den Zeitstempel der Position in der

<sup>19</sup> [http://www.bundesnetzagentur.de/cln\\_1432/DE/Sachgebiete/Telekommunikation/Unternehmen\\_Institutionen/Frequenzen/SpezielleAnwendungen/Seefunk/Seefunk-node.html](http://www.bundesnetzagentur.de/cln_1432/DE/Sachgebiete/Telekommunikation/Unternehmen_Institutionen/Frequenzen/SpezielleAnwendungen/Seefunk/Seefunk-node.html), letzter Abruf am 16.04.2015

<sup>20</sup> <http://www.imo.org/OurWork/MSAS/Pages/IMO-identification-number-scheme.aspx>, letzter Abruf am 16.04.2015

koordinierten Weltzeit UTC (engl.: »Universal Time, Coordinated«), den Kurs über Grund (COG, engl.: »course over ground«) in Grad, wobei Norden 0° entspricht, der Geschwindigkeit über Grund (SOG, engl.: »speed over ground«) in Knoten (kn)<sup>21</sup>, dem Steuerkurs (engl.: »heading«) in Grad, wobei Norden 0° entspricht, dem Navigationsstatus wie zum Beispiel verankert, vertäut, unterwegs mit Maschine, unterwegs mit Segel, und der Kursänderungsrate (ROT, engl.: »rate of turn«), welche aus einem speziellen Sensor berechnet wird (falls vorhanden).

Des Weiteren beinhalten die AIS-Nachrichten aktuelle Reisedaten wie zum Beispiel die Gefahrgutklasse der Ladung, das Reiseziel oder die geschätzte Ankunftszeit.

Die statischen Informationen sowie die Reisedaten werden vom AIS-Transceiver automatisch alle 6 Minuten versendet. Bei den dynamischen Daten ist die Aktualisierungsrate abhängig von der Geschwindigkeit des Schiffs. So beträgt diese 3 Minuten bei einem verankerten Schiff, 12 Sekunden bei einer Geschwindigkeit zwischen 0 und 14 kn, 6 Sekunden bei einer Geschwindigkeit zwischen 14 und 23 kn, und 3 Sekunden bei einer Geschwindigkeit über 23 kn [IMO01]. Die Reichweite eines küstengestützten AIS-Empfängers wird laut [Eur08] mit 40 sm angegeben, kann jedoch aufgrund günstiger Bedingungen bis zu 100 sm reichen.

Über die generelle Zuverlässigkeit der AIS-Daten gibt es bislang wenige Untersuchungen. Eine Fehlerquelle besteht darin, dass die statischen Informationen und die Reisedaten manuell eingegeben werden müssen. So tritt beispielsweise häufiger die MMSI-Nummer 1193046 auf, da diese dem voreingestellten Wert entspricht. Auch treten eindeutig falsche MMSI-Nummern wie 0, 1, oder 999999999 auf [Har07a]. Falsche Angaben treten auch beim Schiffstyp sowie bei der Angabe der Länge und Breite des Schiffs auf. Auch der Navigationsstatus muss manuell eingegeben werden und Überprüfungen zeigen, dass diese Information in bis zu 30 % der Daten falsch ist. Die Informationen über das Reiseziel und die geschätzte Ankunftszeit waren in bis zu 49 % der Fälle falsch angegeben [Har07a].

Die dynamischen Informationen sind wiederum von der Zuverlässigkeit der gekoppelten Sensorik (GPS, Gyrosensor usw.) abhängig. Jedoch wurden auch hier in bis zu 1 % der Daten falsche Werte identifiziert. Hier wurden beispielsweise Breitengrade von mehr als 90°, Längengrade von mehr als

---

<sup>21</sup> 1 kn = 1 sm/h = 0,514 m/sec, 1 sm = 1 Seemeile = 1,852 km

180°, oder auch die Position 0°N/S, 0°E/W beobachtet [Har07a]. Durch einen Vergleich der berechneten Geschwindigkeit und des berechneten Kurses über Grund (mittels der Schiffsposition über die Zeit hinweg) mit der übermittelten Geschwindigkeit und dem Kurs über Grund konnten eindeutig falsche Werte für diese beiden dynamischen Informationen identifiziert werden [Bai05]. Die Ursache dieser Fehlerquellen kann auf eine falsche Installation des AIS-Transceivers zurückgeführt werden [Har07a].

Eine weitere Problematik besteht darin, dass das AIS-Signal weder verschlüsselt ist, noch dass es eine abgesicherte Datenübertragung gibt. Dies bedeutet, dass es sowohl möglich ist, das eigene AIS-Signal (absichtlich oder unabsichtlich) zu fälschen als auch das gesendete Signal abzufangen und zu verfälschen. Insgesamt ist ein drastischer Anstieg gefälschter AIS-Daten zu beobachten [Win14].

Nach den ursprünglichen Vorschriften der IMO sollte das AIS-Signal ständig eingeschaltet sein. Das unverschlüsselte Signal ermöglicht jedoch auch jeglichem Personenkreis, die aktuellen AIS-Signale zu empfangen und nutzen. Zur Erhöhung der eigenen Sicherheit ist es daher in sicherheitskritischen Gebieten erlaubt, das AIS-Signal auszuschalten. Dies trifft beispielsweise auf Gebiete zu, in denen bekanntermaßen Piraten agieren oder gehäuft bewaffnete Raubüberfälle stattfinden [IMO01].

Mittlerweile haben sich im World Wide Web (WWW) einige Crowdsourcing-Projekte gegründet, welche AIS-Daten von mehreren Stationen sammeln und diese in einer Karte darstellen lassen. Die beiden bekanntesten Anbieter dieser Services sind die Seiten »Marine Traffic«<sup>22</sup> und »Vesseltracker«<sup>23</sup>. Für eine weltweite Abdeckung sorgt das satellitengestützte AIS (SAT-AIS), welches von der Europäischen Raumfahrtagentur ESA (engl.: »European Space Agency«) entwickelt wird [Tob11]. Bisher wurden die dafür benötigten Antennen und Signalverarbeitungsalgorithmen entwickelt und das SAT-AIS erfolgreich getestet. Nun werden spezielle Mikro-Satelliten entwickelt, um eine weltweite Abdeckung zu gewährleisten<sup>24</sup>

Echtzeitdaten im WWW können jedoch genauso wie die unverschlüsselten, direkt empfangenen Daten die Sicherheit der Schiffe und der Crew gefährden. Die IMO rät deswegen von einer Veröffentlichung von Echtzeitdaten im WWW

<sup>22</sup> <https://www.marinetraffic.com>, letzter Abruf am 16.04.2015

<sup>23</sup> <http://www.vesseltracker.com>, letzter Abruf am 16.04.2015

<sup>24</sup> Quelle: <https://artes.esa.int/artes-21/overview>, letzter Abruf am 16.04.2015

ab und missbilligt sowohl bisherige Veröffentlichungen als auch deren Anbieter<sup>25</sup>. Auf »Marine Traffic« und »Vesseltracker« wird zwar mit Echtzeitdaten geworben, jedoch besagen andere, nicht-verifizierte Quellen im WWW, dass die Daten um mehrere Stunden zeitversetzt dargestellt sind.

## Radargestützte Sensorik

Wie das AIS-System wird auch die radargestützte Sensorik sowohl auf den Schiffen selbst als auch an Land eingesetzt. Auch die Radarsensorik wurde in erster Linie zur Unterstützung der Betriebssicherheit entwickelt. Jedoch werden heutzutage die Radar-Informationen auch für Aufgaben der Angriffssicherheit genutzt.

Radaranlagen für Schiffe gehören heute zur Standard-Bordelektronik. Die auf Handelsschiffen angebrachten Radar-Antennen operieren im X- oder S-Frequenzband<sup>26, 27</sup>. Die Antennen sind zwischen 1,2 m und 3,6 m lang und rotieren zwischen 21 und 45 mal pro Minute<sup>28, 29, 30, 31</sup>. Die Radar-Sensorik gibt die Richtung und den Abstand von detektierten Objekten relativ zur eigenen Position zurück. Für die methodischen Grundlagen von Radarsensoren sei hier auf [Ric10] verwiesen. In der maritimen Nutzung auf Handelsschiffen erlauben die Sensoren eine Detektion von bis zu 100 Objekten im Umkreis von bis zu 24 sm und deren automatische Verfolgung<sup>28, 29, 30, 31</sup>.

---

<sup>25</sup> Aussage nach <http://www.imo.org/OurWork/Safety/Navigation/Pages/AIS.aspx>, letzter Abruf am 16.04.2015

<sup>26</sup> X-Band: Frequenz: 8-12 GHz, Wellenlänge 2,5-3,75 cm

<sup>27</sup> S-Band: Frequenz 2-4 GHz, Wellenlänge 7,5-15 cm

<sup>28</sup> aus FAR-28x7 Series Broschüre von Furuno,

<http://www.furuno.com/files/Brochure/103/upload/far-28x7.pdf>, letzter Abruf am 16.04.2015

<sup>29</sup> aus Kongsberg Data sheet - X-band scanner and tranceiver,

[http://www.km.kongsberg.com/ks/web/nokbg0397.nsf/AllWeb/E5CD04C8E973B95EC1256F80002C5F9D/\\$file/1003121B-low-res.pdf?OpenElement](http://www.km.kongsberg.com/ks/web/nokbg0397.nsf/AllWeb/E5CD04C8E973B95EC1256F80002C5F9D/$file/1003121B-low-res.pdf?OpenElement), letzter Abruf am 16.04.2015

<sup>30</sup> aus Kongsberg Data sheet - S-band scanner and tranceiver,

[http://www.km.kongsberg.com/ks/web/nokbg0397.nsf/AllWeb/B5E62086D1A8F9BEC1256F80002BA9A5/\\$file/1003120B-low-res.pdf?OpenElement](http://www.km.kongsberg.com/ks/web/nokbg0397.nsf/AllWeb/B5E62086D1A8F9BEC1256F80002BA9A5/$file/1003120B-low-res.pdf?OpenElement), letzter Abruf am 16.04.2015

<sup>31</sup> aus Synapsis Workstation Broschüre von Raytheon Anschütz,

<http://www.raytheon-anschuetz.com/fileadmin/content/Downloads/Brochures/synapsis-workstation.pdf>, letzter Abruf am 16.04.2015

Die für die Überwachung von Küstenabschnitten eingesetzten Radar-Systeme operieren hauptsächlich im X-Frequenzband, teilweise auch im S-Frequenzband. Ihre Reichweite wird mit ca. 24 sm (ca. 45 km) angegeben<sup>32, 33</sup>. Der Erfassungsbereich ist jedoch abhängig vom Reflexionsgrad des zu detektierenden Objektes. So ist beispielsweise ein Schwimmer mit einem Radarquerschnitt (RCS, engl.: »Radar Cross Section«) von 0,1 m<sup>2</sup> innerhalb von 1 km, ein kleines Boot (z.B. Schlauchboot) oder ein Jet-Ski mit einem RCS von 1,5 m<sup>2</sup> innerhalb von 20 km, und ein großes Schiff mit einem RCS von 100 m<sup>2</sup> innerhalb von 40 km detektierbar<sup>34</sup>. Die Detektionsrate und insbesondere die Falsch-Positiv-Rate<sup>35</sup> ist dabei natürlich auch stark vom aktuellen Seegang abhängig.

### Optronische Sensorik

Optronische Systeme bieten zusätzlich zu AIS- und Radarsystemen optische Verifizierungsmöglichkeiten möglicher Gefahren. So dienen sie auf Schiffen eingesetzt beispielsweise der frühzeitigen Erkennung möglicher Pirateneingriffe oder Raubüberfälle. Solche optronischen Systeme beinhalten einerseits eine visuelle Kamera mit einem optischen Zoomfaktor von bis zu 36 sowie eine Infrarot (IR)-Kamera im Spektralbereich zwischen 3-5 µm mit einem Zoomfaktor von bis zu 16<sup>36, 37</sup>. Die stabilisierten Bilder können dabei auf der Schiffsbrücke analysiert werden. Des Weiteren lassen sich die Sensoren auch von der Schiffsbrücke aus steuern.

---

<sup>32</sup> aus SBS-800 Datenblatt von Kelvin Hughes, <http://www.kelvinhughes.com/upload/pdf/brochures/sbs-800.pdf>, letzter Abruf am 16.04.2015

<sup>33</sup> aus Coast Watcher 100 Datenblatt von Thales, <https://www.thalesgroup.com/sites/default/files/asset/document/coastWatcher100.pdf>, letzter Abruf am 16.04.2015

<sup>34</sup> aus Beschreibung Spexer2000 Coastal von Airbus Defence and Security, [http://www.defenceandsecurity-airbusds.com/en\\_US/spexer-2000-coastal17](http://www.defenceandsecurity-airbusds.com/en_US/spexer-2000-coastal17), letzter Abruf am 16.04.2015

<sup>35</sup> Anteil der fälschlicherweise als Objekte detektierten Signaturen

<sup>36</sup> aus Broschüre Maritime Optronics von Airbus Defence and Security, [http://www.defenceandsecurity-airbusds.com/documents/10157/137612/2014\\_Maritime\\_Optronics\\_24S\\_EN.pdf](http://www.defenceandsecurity-airbusds.com/documents/10157/137612/2014_Maritime_Optronics_24S_EN.pdf), letzter Abruf am 16.04.2015

<sup>37</sup> aus Broschüre EOMS NG - Naval Electro-Optical Multifunction System von Sagem, [http://www.sagem.com/file/download/d1641e\\_eoms\\_ng.pdf](http://www.sagem.com/file/download/d1641e_eoms_ng.pdf), letzter Abruf am 16.04.2015

Die optronischen Systeme sind teilweise mit zusätzlicher Sensorik wie einem Laser-Abstandsmessgerät oder einem kurzwelligem Infrarot-Sensor (SWIR, engl.: »short wavelength IR«) zur Überwindung von atmosphärischen Grenzen ausgestattet. In den neuesten Systemen sind auch automatische Verfahren zur Detektion von bewegten Objekten sowie zur Objektverfolgung integriert<sup>36, 37</sup>. Solche optronischen Systeme werden natürlich auch vom Festland aus eingesetzt. Diese kombinieren auch standardmäßig eine visuelle und eine Infrarot-Kamera. Für den Einsatz auf dem Festland (mit Sicht auf das Meer) sind die visuellen Kameras mit einem optischen Zoomfaktor von bis zu 55 und die IR-Kameras mit einem Zoomfaktor bis zu 32 ausgestattet. Damit lassen sich Boote im Abstand von 20 km oder teilweise noch bis zu 30 km erkennen<sup>38</sup>.

### 2.3.3. Eingesetzte Systeme

#### ARPA - Automatic Radar Plotting Aid

Für Handelsschiffe wird zusammen mit dem Radar-Sensor auch eine Darstellung der erfassten Ziele auf der Kommandobrücke des Schiffs installiert, eine sogenannten ARPA-Anlage (engl.: »Automatic Radar Plotting Aid«). Die technischen Anforderungen an eine ARPA-Anlage wurden von der IMO bereits 1979 festgehalten [IMO79]. Die ARPA-Anlage umfasst nicht nur die Darstellung der detektierten Objekte, sondern erlaubt auch mittels integrierter Verfahren ihre Verfolgung. Meist besitzen die ARPA-Anlagen eine integrierte Kollisionswarnung und eine Schnittstelle zu den AIS-Systemen. Teilweise bieten die Systeme auch eine automatische Assoziation von AIS-Daten mit den detektierten Radar-Zielen an, so dass auf dem Bildschirm die aus beiden Datenquellen fusionierten Objektinformationen visualisiert sind<sup>31</sup>.

#### ECDIS - Electronic Chart Display and Information System

Eine weitere Anlage auf der Schiffsbrücke ist das ECDIS-System (engl.: »Electronic Chart Display and Information System«). Das ECDIS-System dient in erster Linie zur Gewährleistung einer sicheren Navigation. Die technischen

---

<sup>38</sup> aus Broschüre Surveillance Optronics von Airbus Defence and Security, [http://www.defenceandsecurity-airbusds.com/documents/10157/137612/2014\\_Surveillance\\_Optronics\\_16S\\_EN.pdf](http://www.defenceandsecurity-airbusds.com/documents/10157/137612/2014_Surveillance_Optronics_16S_EN.pdf), letzter Abruf am 16.04.2015



Anforderungen an das ECDIS-System wurden von der IMO in [IMO96] festgehalten. Das ECDIS-System beinhaltet unter anderem eine Integration der elektronischen Seekarten (ENC, engl.: »Electronic Navigational Charts«), welche für die deutsche Nord- und Ostsee vom Bundesamt für Seeschifffahrt und Hydrologie bereitgestellt werden<sup>39</sup>. Meist stellen die heutigen ECDIS-Systeme eine Schnittstelle zur ARPA-Anlage und zum AIS-System bereit, so dass detektierte Objekte in der Umgebung mit dargestellt werden können<sup>31</sup>. Da das ECDIS-System jedoch hauptsächlich für die Navigation verwendet wird, muss das System in erster Linie gewisse Funktionalitäten der Routenplanung und -überwachung wie das Zeichnen von Wegpunkten bereitstellen [IMO96].

### VMS - Vessel Monitoring System

Das VMS (engl.: »Vessel Monitoring System«) ist ein satellitengestütztes System, welches in regelmäßigen Abständen Schiffsdaten an die entsprechenden Fischereibehörden sendet<sup>40</sup>. Es wurde von der Generaldirektion für »Maritime Angelegenheiten und Fischerei«<sup>41</sup> der Europäischen Kommission ins Leben gerufen und ist verpflichtend für alle Fischereifahrzeuge mit einer Länge von mehr als 15 m [Eur08]. Der an den Schiffen angebrachte Transponder<sup>42</sup> operiert vollautomatisch und sendet stündlich Daten zur Identität, Position, Kurs und Geschwindigkeit des Schiffs sowie einen Zeitstempel. Die Nachricht wird per Satellitenkommunikation an die Behörden des Staates geschickt, unter dessen Flagge das Schiff fährt. Dieser Flaggenstaat leitet die Nachricht an den Küstenstaat weiter, in dem sich das Schiff aktuell befindet. Der Küstenstaat leitet die Nachricht wiederum an die entsprechende operationelle Behörde weiter. Auf diese Weise ist eine lokale Behörde stets informiert, wo sich ihre eigenen Fischereischiffe weltweit befinden, aber auch welche Fischereischiffe sich in ihren Gewässern befinden. Dabei fallen alle Fischereischiffe, welche sich in der ausschließlichen Wirtschaftszone (EEZ, engl.: »Exclusive Economic Zone«) befinden, unter die landeseigene rechtliche Zuständigkeit [Eur08].

<sup>39</sup> [http://www.bsh.de/de/Produkte/Karten/Elektronische\\_Seekarten/index.jsp](http://www.bsh.de/de/Produkte/Karten/Elektronische_Seekarten/index.jsp), letzter Abruf am 16.04.2015

<sup>40</sup> [http://ec.europa.eu/fisheries/cfp/control/technologies/vms/index\\_en.htm](http://ec.europa.eu/fisheries/cfp/control/technologies/vms/index_en.htm), letzter Abruf am 16.04.2015

<sup>41</sup> [http://ec.europa.eu/dgs/maritimeaffairs\\_fisheries/about\\_us/index\\_de.htm](http://ec.europa.eu/dgs/maritimeaffairs_fisheries/about_us/index_de.htm), letzter Abruf am 16.04.2015

<sup>42</sup> Kommunikationsgerät, welches eingehende Signale automatisch beantwortet, Kurzwort aus den englischen Begriffen »transmitter« und »responder«

Insbesondere können die Behörden somit erkennen, ob sich ein Fischereischiff in einem Schutzgebiet mit Fischereiverbot aufhält und entsprechende Maßnahmen einleiten.

### **VTS - Vessel Traffic Service**

Die VTS (engl.: »Vessel Traffic Services«) sind Systeme, welche speziell in Gebieten mit hohem Verkehrsaufkommen die Betriebssicherheit sicherstellen sollen [Eur08]. Sie werden hauptsächlich in Häfen und in Küstenregionen mit einem erhöhten Kollisionsrisiko eingesetzt. Im letzteren Fall werden oft zusätzlich sogenannte Verkehrstrennunggebiete (engl.: »Traffic Separation Scheme«) verwendet. Verkehrstrennungsgebiete werden von der IMO definiert und beinhalten für ein bestimmtes Gebiet eine Regulierung des Schiffsverkehrs mit unterschiedlichen Fahrspuren. Das erste Verkehrstrennungsgebiet war die »Straße von Dover« im Jahr 1967<sup>43</sup>.

Die VTS-Infrastruktur besteht aus einer an Land angebrachten Station mit einem Lagebild des aktuellen Schiffsverkehrs [Eur08]. Als Basis für das Lagebild wird hauptsächlich Radarsensorik verwendet [Lin06]. Zusätzlich dazu können Information über den UKW-Bordfunk ausgetauscht werden. Im Allgemeinen werden auch visuelle Beobachtungen durchgeführt, welche teilweise durch optronische Sensorik unterstützt wird [Eur08]. Um die Richtung der Funkquelle zu bestimmen, werden auch Peilgeräte (RDF, engl.: »Radio Direction Finder«) eingesetzt. Aufgrund der hohen Verfügbarkeit des AIS-Signals bieten die heutigen Systeme eine AIS-Schnittstelle<sup>44</sup> und sind auch in der Lage, die AIS-Daten mit anderen Datenquellen zu fusionieren [Sig14].

### **LRIT - Long Range Identification and Tracking**

LRIT (engl.: »Long Range Identification and Tracking«) ist ein Nachrichtensystem, welches von der IMO reguliert wird<sup>45</sup> und für Sicherheitszwecke und Such- und Rettungsaktionen (SAR, engl.: »Search and Rescue«) verwendet wird [Eur08]. Es ist seit dem 30.12.2008 verpflichtend für alle Passagierschiffe

<sup>43</sup> <http://www.imo.org/OurWork/Safety/Navigation/Pages/ShipsRouteing.aspx>, letzter Abruf am 16.04.2015

<sup>44</sup> <http://www.signalis.com/products/vessel-traffic-services>, letzter Abruf am 16.04.2015

<sup>45</sup> <http://www.imo.org/OurWork/Safety/Navigation/Pages/LRIT.aspx>, letzter Abruf am 16.04.2015

auf internationaler Fahrt sowie für Frachtschiffe mit einer Bruttoreaumzahl von 300 oder mehr auf internationaler Fahrt. Die Nachricht enthält die Schiffsidentität, die Position und einen Zeitstempel. Küstenstaaten haben Zugang zur LRIT-Information von Schiffen, welche sich innerhalb 1.000 sm vor ihrer Küste befinden. Das Bundesamt für Seeschifffahrt und Hydrographie rät, die LRIT-Information gerade in sicherheitsgefährdeten Gebieten nicht abzuschalten<sup>46</sup>. Im Unterschied zu AIS werden mit LRIT-Systemen satellitengestützte Punkt-zu-Punkt-Verbindungen aufgebaut und sind nicht allgemein empfangbar [Eur08]. LRIT-Informationen ermöglichen dem Flaggenstaat somit eine bessere Unterstützung der eigenen Schiffe in kritischen Regionen.

### CSS - Coastal Surveillance System

Während VTS für die Betriebssicherheit eingesetzt wird, wird CSS (engl.: »Coastal Surveillance System«) für die Angriffssicherheit eingesetzt. Die hauptsächliche Anwendung findet ein CSS in der Grenzüberwachung, jedoch kann dieselbe Technologie auch für die Überwachung kritischer Infrastrukturen (z.B. Bohrinseln) eingesetzt werden [Sig14]. Von Interesse sind bei der Grenzüberwachung das Schmuggeln von Waren und Menschenhandel über die Landesgrenzen hinweg. Ein VTS bildet dabei die Basis eines CSS, wobei dieses noch um gewisse Funktionalitäten erweitert ist. Insbesondere wird für ein CSS alle verfügbare Sensorik genutzt, um Informationen über ein Seegebiet zu erfassen, also im Wesentlichen AIS, radargestützte Sensorik und optronische Sensorik [Sig14]. Zusätzliche Funktionalitäten beinhalten beispielsweise das parallele Verfolgen von kleinen Booten, das automatische Schwenken von IR-Kameras auf Radar-Tracks, das automatische Klassifizieren von Booten oder bereits integrierte Funktionen der Entscheidungsunterstützung<sup>47, 48</sup>. Ein CSS ist somit in der Lage, ein echtzeitfähiges maritimes Lagebild (RMP) zu erstellen.

---

<sup>46</sup> <http://www.bsh.de/de/Schifffahrt/Berufsschifffahrt/LRIT>, letzter Abruf am 16.04.2015

<sup>47</sup> <http://www.signalis.com/products/coastal-surveillance-systems>, letzter Abruf am 16.04.2015

<sup>48</sup> <http://www.kongsberg.com/en/kds/kncit/systems/coastal-surveillance-systems>, letzter Abruf am 16.04.2015

## 2.4. Umweltmodellierung

Die Umweltmodellierung beschäftigt sich damit, die reale Welt mit einem maschinenlesbaren Modell zu beschreiben. Dieses maschinenlesbare Modell der Welt kann als eine Wissensbasis interpretiert werden, welche die systeminterne Repräsentation der externen realen Welt beschreibt [Ang92]. Der Begriff dieses sogenannten Weltmodells hat sich im Bereich der Robotik ausgeprägt, wo es eine zentrale Rolle für die Navigation von autonomen Robotern spielt [Cro89]. Das Konzept des Weltmodells ist jedoch nicht nur auf die Robotik beschränkt, sondern findet auch Anwendung in der Fahrzeugführung und in Überwachungssystemen.

### 2.4.1. Anwendungsbereich Robotik

Die Datenverarbeitungskomponente eines mobilen Roboters kann im Wesentlichen durch drei Komponenten beschrieben werden: das Sensorsystem für die Wahrnehmung der Umgebung, das Weltmodell für die Repräsentation des gesammelten Wissens und das Kontrollsystem für das Ziehen von Schlussfolgerungen [Ang92]. Das Weltmodell agiert dabei als eine Schnittstelle zwischen dem Sensor- und dem Kontrollsystem. Denn obwohl das autonome Robotersystem in der realen Welt agiert, basieren die Schlussfolgerungen auf Informationen in der internen Repräsentation [Ang92].

Eine wesentlicher Informationsbestandteil des Weltmodells bei mobilen Robotern ist die eigene geografische Position. Eine robuste Schätzung der Eigenposition kann beispielsweise durch die Fusion von relativen und absoluten Messungen erreicht werden [Emt10]. Dabei werden relative Positionsschätzungen aus der Inertialsensorik und absolute Schätzungen aus der GPS-Sensorik gewonnen. Die Fusion der so gewonnenen Daten kann dann mit dem Kalman-Filter durchgeführt werden [Emt10]. Das Kalman-Filter, welches von Rudolf E. Kálmán in [Kal60] veröffentlicht wurde, ist ein rekursives Bayes'sches Schätzverfahren, in dem die Variablen linear verknüpft und normalverteilt sind, also ein lineares Gauß'sches System vorliegt [Mit12]. Dadurch ist die sequentielle Bayes'sche Filtergleichung in geschlossener Form lösbar und kann effizient berechnet werden. Das Kalman-Filter hat sich aufgrund dieser Eigenschaft als Standard-Verfahren für das Verfolgen von bewegten Objekten etabliert [Mit12].

Das Weltmodell muss nicht zwingend zentralisiert an einer Systemkomponente vorliegen, sondern kann auch dezentralisiert an mehreren Systemkomponenten hinterlegt sein. Im Falle eines Roboterverbundes kann es somit individuelle Weltmodelle geben, in denen jeweils der eigene Roboterzustand verwaltet wird, sowie geteilte Weltmodelle, in denen der Zustand des gesamten Verbundes festgehalten wird [Rot03]. Im Artikel von Roth et al. [Rot03] wird dies auf ein Fußballspiel angewandt, in dem die einzelnen Spieler durch mobile Roboter ersetzt sind. Die eigenen Weltmodelle der Roboter beinhalten jeweils geschätzte Werte für die eigene Position, die eigene Ausrichtung, die Position des Balls, sowie die Positionen der Teammitglieder und der Gegner. Die geteilten Weltmodelle beinhalten jeweils geschätzte Werte für die Positionen der Teammitglieder, die Ballposition, welche die Teammitglieder ermittelt haben und die Information, ob das Teammitglied den Ball im letzten Zeitschritt wahrgenommen hat. Die Herausforderung besteht darin, die jeweiligen Informationen in diesen Weltmodellen in Echtzeit auszutauschen und zu fusionieren. Roth et al. [Rot03] verfolgen dabei den Ansatz, dass nur dann Informationen ausgetauscht werden, wenn Bedarf besteht und Informationen angefragt werden. Roth et al. [Rot03] konnten nachweisen, dass die geschätzte Ballposition durch Einbezug der geteilten Weltmodelle für die einzelnen Roboter verbessert werden konnte.

Im Anwendungsbereich der humanoiden Robotik besteht der Anspruch darin, dass das Weltmodell des Roboters die wahrgenommenen Elemente der realen Welt repräsentiert und damit die Erhaltung eines stets aktuellen Situationsbewusstseins garantiert [Küh10]. Bei der zugrunde liegenden Modellierung wird der Ansatz einer objektorientierten Weltmodellierung gewählt. Dabei werden die Elemente der realen Welt (Dinge, Personen, Attribute, Relationen) durch vordefinierte Klassen repräsentiert und bei entsprechender Beobachtung instanziiert. Die Klassenkonzepte sind dabei durch Relationskonzepte als Ontologien strukturiert und die wahrgenommenen Elemente werden in einem semantischen Netzwerk repräsentiert. Das Weltmodell selbst ist also charakterisiert durch zwei Arten von Modellen: das Vorwissen (auch A-priori-Wissen) bestehend aus Klassen- und Relationskonzepten, und das dynamische Modell bestehend aus instanziierten Elementen und semantischen Netzen [Küh10].

Ein wesentliches Relationskonzept ist die Spezialisierung. Spezialisierte Klassen haben mehr Attribute als ihre Elternklasse, welche folglich abstrakter ist. Jedes Element im Weltmodell kann also in unterschiedlichen Abstraktionsebenen instanziiert werden. Beispielsweise repräsentieren leere Instanzen

ohne jegliche Attribute die abstrakteste Klasse. Je mehr Attributwerte über das instanziierte Element bekannt sind, desto niedriger ist sein Abstraktionsgrad [Küh10]. Die Idee der Abstraktionsebenen liegt darin begründet, dass der Roboter zu Beginn seines Einsatzes wenig über seine Umgebung weiß. Mit längerer Einsatzzeit nimmt er immer mehr Informationen über die Umwelt wahr, aktualisiert sein dynamisches Weltmodell und verringert den Abstraktionsgrad seiner instanziierten Elemente.

Innerhalb des Weltmodells werden die Attribute der Instanzen als Wahrscheinlichkeitsverteilung modelliert und als »Degree-of-Belief« (DoB)-Verteilung interpretiert<sup>49</sup>. Basierend auf der DoB-Verteilung der Instanzen kann die Aktualisierung des Weltmodells als ein Bayes'sches Filterproblem modelliert werden [Bau10b; Ghe10; Hei10]. Dabei wird die Instanziiierung der Elemente explizit mit betrachtet und als Existenz bezeichnet. Ist nun die Wahrscheinlichkeit dieser Existenz größer als ein Instanziiierungs-Schwellwert, so wird die Instanz im Weltmodell erzeugt. Fällt die Wahrscheinlichkeit unter einen Lösungs-Schwellwert, so wird diese Instanz wieder gelöscht. Die Existenzwahrscheinlichkeit unterliegt dabei einem Alterungsprozess, das heißt die Existenzwahrscheinlichkeit sinkt über die Zeit hinweg exponentiell ab, solange keine neue Beobachtung gemacht wird [Bau10b; Ghe10; Hei10].

Eine besondere Herausforderung bei der Aktualisierung des Weltmodells stellt die sogenannte Datenassoziation dar, also die Entscheidung, ob eine Sensorbeobachtung einer Instanz zugeordnet werden kann, und wenn ja, welcher. Diese Assoziation kann durch Ähnlichkeitsmaße bestimmt werden. Bei Anwendungen des Kalman-Filters wird hierbei oft auf den Nächste-Nachbarn-Ansatz (NN, engl.: »Nearest-Neighbor«) zurückgegriffen [Mit12]. Betrachtet man jedoch wie im Falle des Weltmodells hierarchische Strukturen, so können diese ausgenutzt werden, um eine verbesserte Assoziation durchzuführen [Bel12a]. Dieses Konzept wurde bereits erfolgreich in einen humanoiden Roboter integriert [Bel12b].

Weitere Fragestellungen behandeln die Thematik, dass nicht jedes Element der realen Welt durch Vorwissen modelliert werden kann. Es gilt also die Annahme, dass es Elemente gibt, welche dem Weltmodell noch nicht bekannt sind (engl.: »Open World Assumption«). Für diese Thematik gibt es Lösungsan-

---

<sup>49</sup> »Degree-of-Belief« bezeichnet den Bayes'schen Wahrscheinlichkeitsbegriff. Dieser interpretiert die Wahrscheinlichkeit als Grad des Dafürhaltens (subjektive Interpretation). Im Gegensatz dazu steht der frequentistische Wahrscheinlichkeitsbegriff, welcher die Wahrscheinlichkeit als relative Häufigkeit (objektive Interpretation) interpretiert [Bey07; Rob07; Nea12].

sätze, welche das Vorwissen adaptiv an die Beobachtungen anpassen [Kuw14]. Dieses adaptive Wissensmanagement konzentriert sich darauf, wie mit beobachteten Elementen umgegangen werden soll, welche durch das Modell noch nicht gut repräsentiert werden. Kuwertz et al. [Kuw14] definieren Maße für die Modellgüte, also die Fähigkeit des Modells, die beobachteten Elemente zu repräsentieren, sowie Maße für die Identifikation schlecht repräsentierter Elemente. Diese schlecht repräsentierten Elemente können wiederum als Trainingsbeispiele verwendet werden, um das Modellwissen dynamisch zu adaptieren. Um eine stets ansteigende Komplexität des Modells zu vermeiden, ist nach der Modelladaption eine Generalisierung nötig. Mit diesem Ansatz ist es möglich, noch nicht im Vorwissen abgebildete Elemente in das Modell mit aufzunehmen, ohne dass die Modellkomplexität zu stark wächst.

### 2.4.2. Anwendungsbereich Fahrzeugführung

Da ein autonomes Fahrzeug als mobiler Roboter interpretiert werden kann, sind die Prinzipien der Umweltmodellierung im Anwendungsbereich Robotik auf die Fahrzeugführung übertragbar. Wie in der Robotik entspricht auch bei autonomen Fahrzeugen das Weltmodell der systeminternen Repräsentation der realen Welt und somit der wesentlichen Komponente eines intelligenten Systems [Alb02; Hon02].

Eine im militärischen Bereich entwickelte Referenzarchitektur für autonome Fahrzeuge ist das 4D/RCS (engl.: »Real-Time Control System«). 4D/RCS ist im Wesentlichen eine vielschichtige Hierarchie, welche es erlaubt, Berechnungsknoten auf unterschiedlichen Auflösungsebenen zu modellieren [Alb02]. Für Berechnungsknoten auf einer niedrigeren Ebene ist der räumliche und zeitliche Umfang eher klein und die Auflösung eher fein. Dies kann beispielsweise die Berechnung einer Radstellung im Sekundenabstand sein. Umgekehrt ist auf höheren Ebenen der räumliche und zeitliche Umfang eher groß und die Auflösung eher grob wie beispielsweise eine grobe Bahnplanung über die nächsten 50 m im 5 sec-Abstand.

Jeder Berechnungsknoten der 4D/RCS-Architektur enthält vier funktionale Elemente: die Sensordatenverarbeitung, das Weltmodell, die Lagebeurteilung und die Verhaltensgenerierung [Alb02]. Außerdem ist innerhalb jedes Berechnungsknotens eine Wissensbasis hinterlegt. Die einzelnen Elemente haben jeweils die folgenden Funktionen:

- **Sensordatenverarbeitung:** Die Sensordatenverarbeitung skaliert, gruppiert, segmentiert und filtert Sensordaten, berechnet beobachtete Merkmale und Attribute und vergleicht diese unter Einbeziehung von Vorwissen mit den Vorhersagen der internen Modelle. Auf diese Weise werden Objekte, Ereignisse und Situationen detektiert und die Wissensbasis aktualisiert.
- **Weltmodell:** Das Weltmodell ist eine interne Repräsentation der realen Welt und umfasst Instanzen von Objekten, Ereignissen und Situationen.
- **Wissensbasis:** Die Wissensbasis umfasst die Datenstrukturen, welche gemeinsam das Weltmodell bilden. Die Wissensbasis lässt sich dabei in drei Teile unterteilen:
  1. ein Langzeitgedächtnis bestehend aus symbolischen Repräsentationen von generischen und spezifischen Objekten, Ereignissen, Situationen und Regeln,
  2. ein Kurzzeitgedächtnis bestehend aus symbolischen Repräsentationen von Entitäten, welche aktuell im Interessensfokus stehen,
  3. eine unmittelbare, dynamische Repräsentation bestehend aus aktuellen Sensordaten sowie Ausprägungen von beobachteten, geschätzten und vorhergesagten Attributen und Zustandsvariablen.
- **Lagebeurteilung:** Die Lagebeurteilung berechnet Kosten, Risiken und Vorteile von Aktionen und Plänen, schätzt die Zuverlässigkeit von Informationen und berechnet Belohnungen oder Bestrafungen für wahrgenommene Zustände und Ereignisse. Damit erlaubt sie der Verhaltensgenerierung, Prioritäten zu setzen.
- **Verhaltensgenerierung:** Die Verhaltensgenerierung formuliert und selektiert Pläne und kontrolliert die ausgeführten Aktionen. Sie kombiniert dazu die Ergebnisse der Lagebeurteilung mit den Echtzeitinformationen.



Insgesamt hat sich für autonome Fahrzeuge das Weltmodell als Schnittstelle zwischen Sensorsystem und Fahrsystem durchgesetzt. Mit dieser Repräsentation der realen Welt erreicht man eine Entkopplung des Sensorsystems vom Fahrsystem. Die Entscheidungen, die das Fahrsystem trifft, sind dadurch unabhängig von der eingesetzten Sensorik. Somit kann das Fahrsystem für sensoruell unterschiedlich ausgestattete Fahrzeuge verwendet werden [Hon02; Reg04; Fur10; Sch11a].

Die funktionalen Anforderungen, welche ein Weltmodell für eine solche Aufgabe zu erfüllen hat, wurden beispielsweise von Furda und Vlacic zusammengefasst [Fur10]:

- Speichern von Vorwissen wie beispielsweise zu Straßen, Kreuzungen oder Ampeln,
- Speichern von Sensorinformationen wie beispielsweise Hindernisse, Fahrspuren oder sensoruell erfasste Ampeln,
- Speichern von Informationen, welche durch die Kommunikation mit anderen Fahrzeugen oder mit einer Verkehrsmanagementzentrale erfasst wurden,
- zyklisches Aktualisieren von Vorwissen mittels Informationen aus den Sensor- oder Kommunikationskomponenten,
- zyklisches Berechnen der Relationen zwischen den gespeicherten Entitäten wie beispielsweise erfassten Hindernissen auf der aktuellen Fahrspur und den eigenen Abstand dazu,
- asynchrones Benachrichtigen anderer Subsysteme über relevante Ereignisse der Verkehrsumgebung,
- Gewährleisten von Datenzugriffen anderer Subsysteme auf alle gespeicherten Informationen durch synchrone Datenanfragen.

Zusätzlich zu den funktionalen Anforderungen sollte das Weltmodell neben der Zuverlässigkeit und der Robustheit noch weitere nicht-funktionale Anforderungen erfüllen. Darunter fallen die Echtzeitfähigkeit, die Interoperabilität mit unterschiedlichen Sensorkomponenten, ein modulares Design sowie die leichte Integrierbarkeit [Fur10].

### 2.4.3. Anwendungsbereich Videoüberwachung

Für die Anwendung in der Videoüberwachung ist der Ansatz der Weltmodellierung in einer analogen Weise übertragbar. Dazu wurde am Fraunhofer IOSB<sup>50</sup> im Rahmen des Videoüberwachungssystems NEST (engl.: »Network Enabled Surveillance and Tracking«) das sogenannte objektorientierte Weltmodell entwickelt [Bau08; Moß10; Fis14a]. Die zentrale Motivation des objektorientierten Weltmodells (OOWM) ist, die sensororientierte Sicht von Videoüberwachungssystemen wie beispielsweise das Sichten einzelner Videoströme in eine aufgabenorientierte Sicht zu transformieren [Emt08; Bau09]. Das Ziel ist hierbei, dem Operator eine anwendungsbezogene Informationsdarstellung zu präsentieren [Bey08; Bau10a].

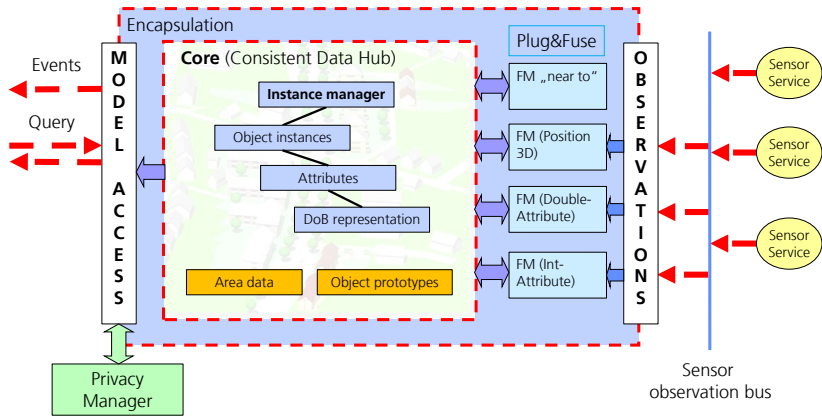
Das OOWM dient in einem Gesamtsystem als Informationsdrehscheibe zwischen allen Systemkomponenten und ermöglicht somit eine Entkopplung der Sensordatenerfassung von der Situationserkennung [Bau09]. Das OOWM stellt eine einheitliche Schnittstelle für eingehende Sensorbeobachtungen bereit sowie eine Modellschnittstelle für Anfragen und Abonnements von anderen Systemkomponenten, welche zusätzlich mit einer Datenschutzkomponente ausgestattet ist. Die Architektur des OOWM nach [Bau09] ist in Abbildung 2.6 dargestellt und wird im Folgenden kurz erläutert.

Über die Schnittstelle für Sensordaten nimmt das OOWM Objektbeobachtungen entgegen und übergibt diese den Fusionsmodulen, welche für eine Verschmelzung der eingehenden Datenströme zuständig sind. Diese Fusionsmodule sind in der Lage, auch mit widersprüchlichen Information umzugehen und eine konsistente Interpretation zu gewährleisten. Innerhalb des Kerns des OOWM ist ein Instanzenmanager verantwortlich für die Verwaltung aller instanziierten dynamischen Objekte. Neu detektierte Objekte werden instanziiert und durch die Fusionsmodule aktualisiert, veraltete Objektinstanzen werden gelöscht. Die Objektinstanzen selbst werden über ihre Attribute wie beispielsweise ihre Position, Farbe oder Größe beschrieben. Diese Attribute werden in Form einer DoB-Verteilung im System vorgehalten. Weiter enthält das OOWM Vorwissen wie räumliche Umgebungsdaten, z.B. einen Gebäudeplan mit Räumen, Türen, Fahrstühlen oder Treppen, und Prototypen von Objekten, z.B. von einer Person oder einem Koffer. Dieses Vorwissen wird vor dem Einsatz des Systems konfiguriert. Die instanziierten Objekte

---

<sup>50</sup> Fraunhofer Institut für Optronik, Systemtechnik und Bildauswertung (Karlsruhe), <http://www.iosb.fraunhofer.de/>, letzter Abruf am 16.04.2015

der Modellwelt sind basierend auf der besten Übereinstimmung der Attributwerte mit diesen Prototypen dynamisch verknüpft. Um die Komplexität zu reduzieren, wird angenommen, dass die Objektinstanzen und auch die Attributwerte untereinander unabhängig sind [Bau09]. Durch diese Objektrepräsentation können in den Fusionsmodulen Bayes'sche Fusionsmethoden wie beispielsweise das Kalman-Filter angewandt werden [Bey07; Mit12].



**Abbildung 2.6.:** Architektur des objektorientierten Weltmodells im Videoüberwachungssystem NEST (Abbildung aus [Bau09]).

Die Bayes'schen Fusionsalgorithmen betrachten das im OOWM vorkonfigurierte Wissen als Vorwissen  $p(\theta)$  und die neuen Beobachtungen als Likelihood  $p(o|\theta)$  [Bau09]. Dabei bezeichnet  $\theta$  ein Objektattribut und  $o$  den Wert einer Beobachtung. Damit lässt sich die A-posteriori-Verteilung mit dem Bayes-Theorem wie folgt berechnen [Mit12]:

$$p(\theta|o) = \frac{p(o|\theta)p(\theta)}{p(o)} = \frac{p(o|\theta)p(\theta)}{\int p(o|\theta)p(\theta)d\theta}. \quad (2.5)$$

Da sich die Attributwerte der Objekte über die Zeit hinweg ändern, wird ein Ausbreitungsmodell angenommen, mit dem die jeweiligen Unsicherheiten über die Zeit hinweg anwachsen [Bau09]. Bei einer neuen Beobachtung wird dieses Ausbreitungsmodell in die Bayes'sche Fusion mit einbezogen, so dass

sich eine sequentielle Bayes'sche Filterung ergibt. Bezeichne nun  $t$  den aktuellen Zeitpunkt und  $o_{1:t} = o_1, o_2, \dots, o_t$  alle Beobachtungen bis zum Zeitpunkt  $t$ , so lässt sich dies wie folgt formulieren [Mit12]:

$$p(\theta_t | o_{1:t}) = \frac{p(o_t | \theta_t) p(\theta_t | o_{1:t-1})}{p(o_t | o_{1:t-1})}, \quad (2.6)$$

wobei

$$p(\theta_t | o_{1:t-1}) = \int p(\theta_t | \theta_{t-1}) p(\theta_{t-1} | o_{1:t-1}) d\theta_{t-1}, \quad (2.7)$$

und


$$p(o_t | o_{1:t-1}) = \int p(o_t | \theta_t) p(\theta_t | o_{1:t-1}) d\theta_t. \quad (2.8)$$

Das Ausbreitungsmodell ist dabei im Term  $p(\theta_t | o_{1:t-1})$  in Gleichung (2.6) festgehalten. Die Ausbreitungsmodelle selbst sind wiederum abhängig vom Attribut selbst, da diese unterschiedlich interpretiert werden können. So wächst beispielsweise die Unsicherheit über die Position einer Person schneller als die Unsicherheit über deren Größe [Bau09].

Für die Qualität der Fusion ist neben der Konfiguration der Fusionsalgorithmen die Datenassoziation ein weiterer wichtiger Aspekt. Diese entscheidet, zu welcher schon bestehenden Objektinstanz eine neue Beobachtung zugeordnet wird. Dies kann beispielsweise über die Maximum-Likelihood-Methode im Instanzenmanager gelöst werden, welche die am besten zur Beobachtung passende Objektinstanz bestimmt. Findet sich keine passende Beobachtung, so wird eine neue Objektinstanz erzeugt [Bau09]. Für das Löschen von Objektinstanzen wird für jede Instanz eine Existenzwahrscheinlichkeit als zusätzliches Attribut hinzugefügt und die Instanz gelöscht, wenn diese unter einen bestimmten Schwellwert fällt. Dieses Vorgehen ist analog zur vorgestellten Vorgehensweise im Bereich der Robotik in Abschnitt 2.4.1 zu sehen.

Das Ergebnis der Fusionsprozesse ist ein konsistentes, dynamisches, objektorientiertes und probabilistisches Modell des beobachteten Gebietes. Zur graphischen Darstellung des aktuellen Inhalts des OOWM dient eine Lagerdarstellung [Fis14a]. Diese ist in Abbildung 2.7 dargestellt. Zu sehen ist der Gebäude-Grundriss, sowie die Abdeckungsbereiche der Videokameras und ihre Positionen (gelbe Kamerasymbole). In der aktuellen Ansicht befinden sich innerhalb des Erfassungsbereiches drei dynamische Objektinstanzen (rote

Kreise), in diesem Fall Personen. Außerdem sind zusätzlich die geschätzten Trajektorien der Instanzen (cyanfarbene Linie) und die dem Fusionsprozess zugrunde liegenden Beobachtungen visualisiert (rote Punkte).



**Abbildung 2.7.:** Ansicht des objektorientierten Weltmodells im Videoüberwachungssystem NEST nach [Fis14a].

## 2.5. Wissensmodellierung und Situationserkennung

Während sich die Umweltmodellierung mit der Modellierung und Repräsentation detektierter Objekte beschäftigt, dient die Wissensmodellierung der Modellierung und Repräsentation von detektierten Ereignissen oder Situationen. Die Wissensmodellierung dient somit als Grundlage für Verfahren zur Situationserkennung. Die Situationserkennung soll den kognitiven Prozess des Verstehens in Endsleys Modell des Situationsbewusstseins auf maschineller Ebene unterstützen und ist somit in das Level 2 des JDL-Datenfusionsmodells einzuordnen. Die in diesem Abschnitt vorgestellten Methoden stammen vorwiegend aus dem maritimen Anwendungsgebiet, da eine vollumfassende Darstellung anderer Anwendungsgebiete den Rahmen sprengen würde.

### 2.5.1. Methoden zur Anomaliedetektion

Speziell bei der Analyse von großen und komplexen Datenmengen werden Methoden zur Anomaliedetektion angewendet [Lav11; Abi13]. Die Anomaliedetektion behandelt das Problem, Muster in Daten zu finden, welche nicht zum erwarteten Verhalten passen [Cha09]. Diese nicht-konformen Muster werden als Anomalien oder auch als Ausreißer bezeichnet. Die Anomaliedetektion wird also dann angewandt, wenn die zu erkennenden Situationen nicht explizit bekannt sind und sich dadurch auszeichnen, dass sie selten auftreten und von normalem Verhalten abweichen [Roy08]. Die gängige Vorgehensweise, um diese Abweichungen zu detektieren ist, ein sogenanntes Normalmodell mit Trainingsdaten zu lernen. Für neue Beobachtungen wird dann geprüft, ob diese zum Normalmodell passen oder nicht, und sie werden entsprechend als normal oder anormal klassifiziert.

#### Punktbasierte Anomalie Maße

In [Aus11] stellen Ausländer et al. vier unterschiedliche Maße vor, mit denen eine punktuelle Auswertung von neuen Beobachtungen basierend auf bereits vorhandenen Daten durchgeführt werden kann. Dabei werden zwei globale Maße basierend auf einem k-Means-Clustering und einem k-Nächste-Nachbarn (k-NN)-Ansatz sowie zwei lokale Maße basierend auf einem normalisierten lokalen Ausreißerfaktor (LOF, engl.: »Local Outlier Factor«) und einem k-NN mit normalisierter mittlerer Dichte vorgestellt. Als Merkmale für die Daten wurden jeweils die zweidimensionalen Positions- und Geschwindigkeitswerte verwendet. Für die Evaluierung wurden aufgezeichnete, reale Daten als normal angenommen, während die getesteten Anomalien aus simulierten Daten generiert wurden. Insgesamt zeigte sich, dass der globale k-NN-Ansatz die besten Ergebnisse erzielte. In [Bra09] stellen Brax et al. eine zustandsbasierte Anomaliedetektion mit vier diskretisierten Zuständen vor. Die vier Zustände sind dabei wie folgt definiert:

- **Kurs:** Der Kurs ist in acht unterschiedliche Richtungen diskretisiert (Nord, Nordost, Ost, Südost, Süd, Südwest, West, Nordwest).
- **Relation:** Die Relation beschreibt die Ausrichtung eines Schiffes bezüglich des am nächsten gelegenen Schiffes (vor, hinter, links, rechts, undefiniert). Der Zustand wird als undefiniert eingestuft, wenn die Schiffe einen Höchstabstand überschreiten.

- **Geschwindigkeit:** Die Geschwindigkeit wird in vier unterschiedliche Zustände diskretisiert (gestoppt, langsam, mittel, schnell). Die Schwellwerte für die Diskretisierung wurden von Experten gesetzt.
- **Position:** Die Position ist eine Diskretisierung der Längen- und Breitengrade in ein  $n \times m$ -Gitter.

Diese vier atomaren Zustände repräsentieren die Basismerkmale eines Schiffes. Durch Kombination untereinander kann ein Schiff in einem gemeinsamen Zustand repräsentiert werden. Das Normalmodell wird nun in der Weise gebildet, dass mittels aufgezeichneter Daten die relativen Häufigkeiten für den jeweiligen gemeinsamen Zustand berechnet werden. Diese Häufigkeiten können dann verwendet werden, um eine neue Beobachtung als normal oder anormal zu klassifizieren. Zunächst wird der gemeinsame Zustand der neuen Beobachtung berechnet und die entsprechende relative Häufigkeit extrahiert. Ist diese kleiner als ein Schwellwert, dann wird die Beobachtung als anormal klassifiziert. In [Bra09] wurde mit diesem Verfahren keine quantitative Evaluierung durchgeführt, sondern einige ausgewählte qualitative Ergebnisse gezeigt, um die Anwendbarkeit des Verfahrens zu demonstrieren.

### Gauß'sche Mischverteilungen

Eine weitere, häufig verwendete Methodik zur Modellierung des Normalmodells ist, eine Mischverteilung aus Gaußverteilungen zu lernen (GMM, engl.: »Gaussian Mixture Model«) [Riv08b; Abi14; Lax08]. Das GMM ist ein Clustering-Verfahren, bei dem jeder Cluster durch eine multivariate Normalverteilung repräsentiert ist und das GMM durch eine gewichtete Summe dieser einzelnen Komponenten [Rey09]. Das GMM ist also repräsentiert durch

$$p(x|w_{1:M}, \mu_{1:M}, \Sigma_{1:M}) = \sum_{i=1}^M w_i g(x|\mu_i, \Sigma_i), \quad (2.9)$$

wobei  $x$  einen  $d$ -dimensionalen Datenvektor bezeichnet,  $w_i$  die Gewichte der einzelnen Komponenten und  $g(x|\mu_i, \Sigma_i)$  die Gauß'schen Mischkomponenten, jeweils mit dem Erwartungswertvektor  $\mu_i$  und der Kovarianzmatrix  $\Sigma_i$  ( $i = 1, \dots, M$ ). Die Gewichte sind dabei so zu wählen, dass sie sich zu Eins summieren:  $\sum_{i=1}^M w_i = 1$ . Jede Komponente ist dabei als reellwertige Funktion  $g: \mathbb{R}^d \rightarrow \mathbb{R}$  definiert:

$$g(x|\mu_i, \Sigma_i) = \frac{1}{(2\pi)^{d/2} |\Sigma_i|^{1/2}} \exp \left\{ -\frac{1}{2} (x - \mu_i)' \Sigma_i^{-1} (x - \mu_i) \right\}. \quad (2.10)$$

Das komplette GMM ist also durch die Erwartungswertvektoren, die Kovarianzmatrizen und die Gewichte aller Komponenten parametrisiert. Diese können beispielsweise mit dem Expectation-Maximization (EM)-Algorithmus [Bis06] bzw. einer Greedy-Version davon [Vla02] gelernt werden.

Laxhammar wendete das Lernen eines GMM auf die Positions-, Geschwindigkeits- und Kursdaten an [Lax08]. Dabei verwendete er reale Datensätze und bestimmte die Anzahl der Komponenten mit dem Greedy-EM-Algorithmus. Außerdem wurde das gesamte Gebiet in ein Gitter unterteilt, um besser lokale Gegebenheiten repräsentieren zu können. Dabei wird für jede Gitterzelle ein GMM gelernt. Für die Bewertung von neuen Datenpunkten wird die Likelihood der Beobachtung bei gegebenem Modell verwendet. Der Schwellwert der Anomaliedetektion wurde dabei so gewählt, dass 0,1 % der Datenpunkte in Anomalien resultieren. Die Daten wurden also nicht annotiert und ermöglichen somit auch keine quantitative Analyse. Mit einem solchen Modell können Anomalien bezüglich der Position, der Geschwindigkeit oder der Richtung erkannt werden, wie beispielsweise Schiffe, welche eine Schifffahrtsstraße kreuzen oder sich in entgegengesetzter Richtung bewegen. Laxhammar stellte in [Lax08] einige ausgewählte qualitative Ergebnisse vor, welche die Möglichkeiten des Verfahrens aufzeigen. Laxhammar betont jedoch auch, dass das Erkennen komplexerer Anomalien, welche mehrere Schiffe betreffen oder zeitliche Abläufe involvieren, ausgereifere Verfahren erfordert [Lax08].

### Kerndichteschätzung

Ein weiteres punktbasierendes Verfahren ist die Kerndichteschätzung (KDE, engl.: »Kernel Density Estimation«), welche auch als Parzen Window bezeichnet wird und die Wahrscheinlichkeitsverteilung einer Zufallsvariablen schätzt [Par62]. Die geschätzte Wahrscheinlichkeitsdichtefunktion des KDE ist gegeben durch

$$f(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x-x_i}{h}\right), \quad (2.11)$$

wobei  $x$  einen reellwertigen Vektor bezeichnet,  $n$  die Anzahl der Datenpunkte,  $x_i$  mit  $i = 1, \dots, n$  die einzelnen Datenpunkte,  $h$  die Bandbreite bzw. die Fenstergröße und  $K$  den Kernel bzw. das Fenster [Ris08; Lax09]. Der Kernel muss dabei immer größer Null sein und das Integral über den Kernel muss Eins ergeben. Beispielsweise kann man in Gleichung (2.11) für den Kernel eine multivariate Gaußverteilung mit Erwartungswertvektor  $\mu = (0, \dots, 0)$  und



Kovarianzmatrix  $\Sigma$  einsetzen. Gleichung (2.11) entspricht dann dem gelernten Normalmodell. Neue Datenpunkte können mit dem Modell verglichen werden und basierend auf einem Schwellwertverfahren als normal oder anormal klassifiziert werden.

In [Lax09] vergleichen Laxhammar et al. den GMM-Ansatz mit dem KDE-Ansatz. Dabei wird erneut ein Gitter über das komplette Gebiet aufgespannt und die Verfahren für die einzelnen Zellen gelernt. Dabei wurden reale Daten verwendet, welche alle als normal angenommen wurden. Anormale Trajektorien wurden simuliert. Es wurden zwei Schwellwerte verwendet, jeweils einer für das GMM und für das KDE. Der Schwellwert wurde so gewählt, dass jeweils 1 % der Testdaten als Anomalien klassifiziert wurden. Insgesamt konnte zwischen den Ergebnissen der beiden Verfahren kein signifikanter Unterschied festgestellt werden, obwohl zu Beginn angenommen worden war, dass das KDE-Verfahren bessere Ergebnisse zeigen würde.

### Bayes'sche Netze

Als probabilistisches graphisches Modell wird für die Anomaliedetektion auch das Bayes'sche Netz verwendet. Ein Bayes'sches Netz ist eine faktorisierte Repräsentationsform für die gemeinsame Wahrscheinlichkeitsverteilung einer Menge von Zufallsvariablen. Dabei werden die bedingten Unabhängigkeiten der einzelnen Zufallsvariablen ausgenutzt [Pea88; Jen07; Kol09].

**Definition 1** (nach [Kol09]) Ein *Bayes'sches Netz (BN)* über die Zufallsvariablen  $X^1, \dots, X^n$  ist ein Paar  $(G, P)$ , wobei

- $G$  ist ein gerichteter, azyklischer Graph mit den Knoten  $X^1, \dots, X^n$  und
- $P$  ist die gemeinsame Wahrscheinlichkeitsverteilung mit

$$P(X^1, \dots, X^n) = \prod_{i=1}^n P(X^i | Pa(X^i)), \quad (2.12)$$

wobei mit  $Pa(X^i)$  die Eltern der Zufallsvariable  $X^i$  bezeichnet werden.


Ist  $Pa(X^i) = \emptyset$ , dann ist  $X^i$  ein Wurzelknoten und  $P(X^i | Pa(X^i)) = P(X^i)$  bezeichnet die A-priori-Wahrscheinlichkeit von  $X^i$ .  $\square$

Die Menge  $\{P(X^i | Pa(X^i)) | i = 1, \dots, n\}$  ist also eine Menge von bedingten Wahrscheinlichkeitsverteilungen (CPD, engl.: »Conditional Probability Distribution«), wobei jede CPD genau einem Knoten bzw. einer Zufallsvariable zugeordnet ist. Sind die Zufallsvariablen diskret, so wird auch der Begriff der bedingten Wahrscheinlichkeitstabelle (CPT, engl.: »Conditional Probability Table«) verwendet.

**Beispiel 1** Abbildung 2.8 zeigt ein Beispiel eines Bayes'schen Netzes mit den fünf Zufallsvariablen  $A, B, C, D$  und  $E$  und den assoziierten CPDs. Die gemeinsame Wahrscheinlichkeitsverteilung ist dann gegeben durch das Produkt der einzelnen CPDs:

$$P(A, B, C, D, E) = P(A)P(B)P(C|A, B)P(D|B)P(E|C). \quad (2.13)$$

□



**Abbildung 2.8.:** Beispiel eines Bayes'schen Netzes mit den Zufallsvariablen  $A, B, C, D$  und  $E$  und den assoziierten CPDs.

In [Joh07] wenden Johansson et al. ein Bayes'sches Netz auf die Anomaliedetektion an. Dabei verfolgen Sie den Ansatz, sowohl die Struktur als auch die Parameter des BN aus einem simulierten Datensatz zu lernen. Für das Lernen der Struktur verwenden sie den PC-Algorithmus [Spi00], benannt nach den Vornamen der Erstveröffentlicher Peter Spirtes und Clark Glymour. Für das Lernen der bedingten Wahrscheinlichkeiten (CPTs) verwenden sie ein einfaches Auszählen der Häufigkeiten. Dies ist möglich, da der simulierte Datensatz vollständig ist. Ist dieser nicht vollständig, so wird für das Lernen der CPTs in

der Regel der EM-Algorithmus verwendet [Dem77; Dud01; Rus10]. Als Eingabeattribute bzw. als Knoten des BN verwenden sie diskretisierte Zustände für Position  $(x, y)$ , Richtung  $(h)$ , Geschwindigkeit  $(s)$ , Geschwindigkeitsänderung  $(\Delta s)$ , Richtungsänderung  $(\Delta h)$  sowie Schiffstyp  $(type)$ .

Zur Anomalieklassifikation berechnen Johansson et al. für jede Schiffsidentität  $(id)$  die Wahrscheinlichkeit einer Beobachtung zum Zeitpunkt  $t$ , also  $P(obs_{t,id})$ , wobei

$$P(obs_{t,id}) = P(x, y, h, s, \Delta s, \Delta h, type). \quad (2.14)$$

Um zeitliche Einzelfehler auszufiltern, wird zusätzlich noch ein gleitender Fensteransatz (engl.: »Sliding Window«) angewendet, indem der Mittelwert über mehrere Zeitpunkte berechnet wird:

$$\bar{P}(obs_{t,id}) = \frac{1}{k} \sum_{i=0}^{k-1} P(obs_{t-i,id}). \quad (2.15)$$

Ein Schiff wird dann als anormal klassifiziert, wenn die gefilterte Wahrscheinlichkeit kleiner als ein Schwellwert  $\delta$  ist:

$$\bar{P}(obs_{t,id}) < \delta. \quad (2.16)$$

In [Joh07] wird ein Fenster der Größe  $k = 5$  gewählt sowie der Schwellwert auf  $\delta = 1 \times 10^{-9}$  gesetzt. Dabei konnte in einem wiederum simulierten Testdatensatz mit manuell eingefügten Anomalien aus 99 Schiffen 10 als anormal herausgefiltert werden. Weitere quantitative Angaben zu den Ergebnissen werden nicht gemacht. Johansson et al. erwähnen jedoch, dass in den Ergebnissen sowohl Schiffe als Anomalie detektiert wurden, welche keine waren (sogenannte Falsch-Positive), als auch Anomalien nicht erkannt wurden (sogenannte Falsch-Negative). Insgesamt halten Johansson et al. den Einsatz von Bayes'schen Netzen für die Erkennung von Anomalien als sinnvoll. Dies wurde in einer späteren Arbeit von Mascaro et al. bestätigt [Mas14].

### Explizite Trajektorienmodellierung

Weitere Ansätze, um Normalmodelle von Schiffen zu lernen, sind neuronale Netze [Rho06; Sei06; Bom06; Abi14] oder genetische Algorithmen [Che14]. Beim Lernen wird dabei meist auf die kinematischen Variablen zurückgegriffen. Diese reichen jedoch im Allgemeinen nicht aus, um Anomalien als solche

zu klassifizieren [Che14]. Vielmehr müssen für eine zuverlässige Anomaliedetektion noch weitere Kontextvariablen verwendet werden, beispielsweise die Start- und Zielpunkte der Trajektorien [Lax09]. Aufgrund dessen gibt es bereits einige Ansätze, welche die Trajektorien direkt miteinander vergleichen. Beispielsweise wurde in [Dah07] eine spline-basierte Trajektorienmodellierung vorgestellt, wobei einzelne Trajektorien geclustert werden, um das Normalmodell zu repräsentieren. Splines repräsentieren dabei die Haupttrajektorie eines Clusters und Anomalien werden detektiert, indem ein Zugehörigkeitswert zu einem Cluster berechnet wird [Pic05]. In [Lax11b; Lax11a] wird ein Ähnlichkeitsmaß basierend auf der Hausdorff-Metrik definiert und für die Anomaliedetektion angewendet, welches eine hohe Erkennungsrate und eine niedrige Falschalarmrate lieferte.

[Pal13] und [Ves12] gehen noch einen Schritt weiter und modellieren eine Trajektorie explizit mittels unterschiedlicher Wegpunkte-Klassen. Unterschiedliche Klassen sind beispielsweise Umkehrpunkte, also Punkte, in denen Schiffe ihre Richtung ändern, oder Hafeneintrittspunkte, also Punkte, in denen Schiffe die Geschwindigkeit Null haben. Über Eintritts- und Austrittspunkte für einzelne Wegpunkte und deren direkte Verbindungen können die Trajektorien als gerichtete Graphen gelernt und repräsentiert werden. Eine Anomaliedetektion wird dann schwellwertbasiert durchgeführt, indem die Wahrscheinlichkeit berechnet wird, wie gut eine beobachtete Trajektorie zu einer gelernten Repräsentation passt [Pal13]. Zusätzlich zu einem statistischen Anomaliedetektor nutzen Holst et al. in [Hol12] einen regelbasierten Ansatz für die Anomaliedetektion. Dabei wird die statistische Anomaliedetektion als Trigger für die wissensbasierte Anomaliedetektion verwendet und diese dann nur bei auffälligen Schiffen angewandt.

## 2.5.2. Regelbasierte Methoden zur Situationserkennung

### Aussagenlogik

Regelbasierte Methoden zur Situationserkennung basieren auf der klassischen Aussagenlogik. Die Aussagenlogik stellt einen Formalismus bereit, um Argumente auf ihre Gültigkeit hin zu prüfen [Das08]. Die Argumente werden in Form von Aussagen, also erklärenden Sätzen beschrieben, welche entweder wahr ( $T$  für engl.: »True«) oder falsch ( $F$  für engl.: »False«) sind. Einzelne Aussagen, auch atomare Formeln genannt, können mittels Junktoren zu komplexeren Sätzen kombiniert werden [Gör03; Kle13]. Es gibt die Junk-

toren Negation ( $\neg$  für »nicht«), Konjunktion ( $\wedge$  für »und«), Disjunktion ( $\vee$  für »oder«), materielle Implikation ( $\Rightarrow$  für »wenn...,dann«) und Bikonditional ( $\Leftrightarrow$  für »genau dann wenn«). Für alle Junktoren kann für zwei Aussagen  $A$  und  $B$  eine Wahrheitstabelle aufgestellt werden. Diese ist in Tabelle 2.3 dargestellt.

**Tabelle 2.3.:** Wahrheitstabelle für die Junktoren der Aussagenlogik.

$A$	$B$	$\neg A$	$A \wedge B$	$A \vee B$	$A \Rightarrow B$	$A \Leftrightarrow B$
T	T	F	T	T	T	T
T	F	F	F	T	F	F
F	T	T	F	T	T	F
F	F	T	F	F	T	T

## Prädikatenlogik

Die Prädikatenlogik erweitert die Aussagenlogik um Quantoren, Terme und Prädikate und besitzt dadurch eine größere Ausdrucksstärke. Als Quantoren werden der Existenzquantor ( $\exists$  für »es gibt ein«) und der Allquantor ( $\forall$  für »für alle«) verwendet. Die Symbolik wird zusätzlich noch um Variablen, Konstanten sowie um Funktions- und Prädikatensymbole erweitert. Terme sind Variablen, Konstanten oder in rekursiver Weise  $n$ -wertige Funktionen über Terme. Ein Prädikat ist eine Funktion, welche sich zu wahr oder falsch auswerten lässt, oder eine Aussage über eine Relation, welche entweder wahr oder falsch ist. Formeln in der Prädikatenlogik bestehen dann aus Termen, Quantoren, Prädikaten und den Booleschen Operatoren wahr und falsch [Gör03; Das08].

In [Dou93] stellen Dousson et al. eine Situationserkennung auf Basis der Prädikatenlogik im Bereich der Robotik vor, welche zeitliche Abläufe erkennt. Dabei werden Prädikate definiert, welche ein Ereignis symbolisieren und Änderungen des Wahrheitszustands einer Aussage innerhalb von zeitlich eingeschränkten Intervallen entsprechen. Diese sind

$$\text{ON}(P,t) \Leftrightarrow \exists t_1 < t < t_2 : \text{False}(P,t_1,t) \wedge \text{True}(P,t,t_2), \quad (2.17)$$

$$\text{OFF}(P,t) \Leftrightarrow \exists t_1 < t < t_2 : \text{True}(P,t_1,t) \wedge \text{False}(P,t,t_2), \quad (2.18)$$

wobei die Aussagen  $(P, t_1, t_2)$  genau dann wahr oder falsch sind, wenn für jedes  $t$  mit  $t_1 \leq t < t_2$  die Aussage  $P$  wahr oder falsch ist. Damit modellieren Dousson et al. einen zeitlichen Ablauf von Ereignissen, welchen sie mit Hilfe dieser Regeln modellieren und erkennen können.

Auch Dahlbom et al. arbeiten mit Prädikaten, indem sie diese als »Fakt« bezeichnen [Dah09]. Ein Fakt ist also immer wahr, auch wenn seine konkrete Ausprägung wahr oder falsch sein kann. Ein Zustand wird dann als Menge von Fakten definiert. Wie in [Dou93] definieren Dahlbom et al. ein Ereignis als eine Zustandsänderung [Dah09]. Weiter wird eine Situation  $S$  als eine Teilmenge einer Zustandsfolge definiert. Die Definition einer Situation ermöglicht es also, jede mögliche Ausprägung einer Zustandsfolge zu modellieren. Eine solche Modellierung wird wiederum zur Definition eines Situations-Templates genutzt, welches eine Menge von Objekten und eine Menge von Bedingungen umfasst. Die Situationserkennung wird dann durch logisches Schließen durchgeführt. Um die Zustandsänderungen und zeitlichen Abläufe explizit zu modellieren, können auch Petri-Netze verwendet werden [Dah11]. Für ein maritimes Szenario modelliert Dahlbom in [Dah11] die Relationen »Close«, »InArea«, »InHarbour« und »Waiting«. Mögliche Abläufe, also sowohl parallele als auch sequentielle Abläufe dieser symbolischen Relationen, wurden dann als Petri-Netz modelliert und für die Situationserkennung genutzt.

Für maritime Anwendungsfälle besteht die Wissensbasis für die regelbasierte Situationserkennung aus einer Menge von Regeln, hinsichtlich derer die Echtzeitdaten ausgewertet werden, und welche dann entweder den Wert wahr oder falsch zurückgeben [Sei06]. Dies wird beispielsweise auch in [Kaz13] vorgestellt. Dort werden die AIS-Informationen als Datenquelle genutzt und mittels Regeln Unstimmigkeiten, also Anomalien, in den Daten detektiert. Eine Anomalie ist beispielsweise, wenn die Positionsdaten einem anderen Ort entsprechen als dem angegebenen Hafen. Insgesamt stellen Kazemi et al. in [Kaz13] elf Regeln auf, welche unterschiedliche Anomalien klassifizieren. Alle Regeln sind dabei formuliert als: »Wenn..., dann Anomalie.« Diese Wenn-Dann-Formulierung nutzt auch [Roy10a]. Roy verwendet dabei ebenfalls den Begriff des Fakts und formuliert die Regeln der Wissensbasis als »Wenn Fakt 1 und Fakt 2 und ... und Fakt  $n$ , dann Fakt  $x$ «. In Form der Prädikatenlogik entspricht dies genau der Formel

$$F^1 \wedge F^2 \wedge \dots \wedge F^n \Rightarrow F^x, \quad (2.19)$$

wobei  $F^x$  der zu erkennenden Situation entspricht. Die einzelnen Fakten entsprechen wie in [Dah11] symbolischen Aussagen wie »inRegion«, »Vesseltype«,

»hasRoute« usw. Damit modelliert Roy sowohl illegale Fischereiaktivitäten als auch mögliche Schmuggelaktivitäten (als mögliches »Rendezvous« auf See). Auch Polomski et al. verwenden in [Pol13] solche Wenn-Dann-Regeln, um einen Piratenangriff zu modellieren. Um zeitliches Schließen zu ermöglichen, verwenden sie die sieben, von Allen in [All83] identifizierten Relationen für zeitliche Intervalle. Für zwei Intervalle  $X$  und  $Y$  sind diese:  $X$  findet vor  $Y$  statt,  $X$  trifft auf  $Y$ ,  $X$  überschneidet sich mit  $Y$ ,  $X$  beginnt mit  $Y$ ,  $X$  findet während  $Y$  statt,  $X$  endet mit  $Y$ , und  $X$  ist gleich  $Y$ .

## Ontologien

Das Problem solcher regelbasierter Wissensbasen ist, dass sie mit ansteigender Größe sehr schnell nicht mehr handhabbar und insbesondere ihre Zusammenhänge nicht mehr ersichtlich sind. Eine Möglichkeit, dem entgegen zu treten, ist die Modellierung der Wissensbasis als Ontologie. Eine Ontologie definieren Studer et al. in [Stu98] wie folgt:

»Eine Ontologie ist eine explizite Spezifikation einer gemeinsamen Konzeptualisierung<sup>51</sup>«.

In [Roy10b] wenden Roy und Davenport die Ontologie-Modellierungssprache OWL (»Web Ontology Language«) an, welche vom »World Wide Web Consortium« (W3C<sup>52</sup>) entwickelt wurde. Zur Formalisierung des Expertenwissens verwenden sie die Beschreibungslogik (DL, engl.: »Description Logic«), eine Untermenge der Prädikatenlogik, mit der Konzepte, Rollen und Individuen beschrieben werden können. Um beobachtete Schiffe zu analysieren, verwendet die DL-Inferenz die zuvor modellierten Situationen von Interesse, setzt also das logische Schließen ein. Auch Vandecasteele et al. verwenden in [Van12] eine Ontologie, um Trajektorien semantisch zu beschreiben und Situationen wie paralleles Fahren zu detektieren. Edlund et al. verwenden in [Edl06] eine hinterlegte Ontologie als Wissensbasis. Als Situationen modellieren sie beispielsweise ein Schmuggelszenario ähnlich wie in [Dah11] als ein Rendezvous auf See. Auch Garcia et al. verwenden in [Gar11] eine Ontologie zur Modellierung von Kontextwissen. Sie modellieren dabei einzelne Zonen innerhalb eines Hafens und können damit ein unzulässiges Verhalten einzelner

<sup>51</sup> eigene Übersetzung. Original: »An ontology is an explicit specification of a shared conceptualization«.

<sup>52</sup> <http://www.w3.org/>, letzter Abruf am 16.04.2015

Schiffe innerhalb bestimmter Zonen detektieren. Zur Modellierung solcher Beispielsituationen ist es in der Regel notwendig, die relevanten Regeln im Rahmen von Workshops mit Endanwendern zu bestimmen [Nil08]. Als wesentliche auffällige Situationen wurden in [Nil08] zu hohe Geschwindigkeiten, plötzliche Richtungsänderungen, Geschwindigkeitsänderungen, paralleles Fahrverhalten oder ein Rendezvous auf See festgehalten.

### **Fuzzybasierte Ansätze**

Im Vergleich zur binärwertigen Logik, in der die Variablen nur die Werte wahr oder falsch annehmen können, bietet die Fuzzy-Logik den Ansatz, den Variablen Wahrheitswerte zwischen Null und Eins zuzuordnen [Kle04]. Generell besteht ein Fuzzy-System aus drei wesentlichen Komponenten: Fuzzy-Mengen, Zugehörigkeitsfunktionen und Produktionsregeln in Form einer Wenn-Dann-Formulierung. Damit können einerseits Daten aus verschiedenen Sensoren fusioniert werden [Gad09], aber auch Risikowerte berechnet werden [Sii01; Bal09]. Neuere Ansätze modellieren mit Fuzzy-Logik auch das Gruppenverhalten von Personen über die Zeit hinweg [Mün11; IJs14], eine Methode welche auch übertragbar wäre auf das Analysieren von maritimen Situationen.

## **2.5.3. Probabilistische Methoden zur Situationserkennung**

### **Bayes'sche Netze**

Ein grundlegendes probabilistisches Verfahren zur Erkennung spezifischer Situationen ist das BN. Es wurde bereits in Abschnitt 2.5.1 für die Anomaliedetektion eingeführt. Für die Anwendung im Bereich der intelligenten Fahrzeuge kann ein BN für die Entscheidungsunterstützung eingesetzt werden, beispielsweise für die Entscheidung, wann ein Spurwechsel stattfinden soll [Sch11b]. In diesem Fall wird das BN um einen sogenannten Entscheidungsknoten erweitert und wird dann als Entscheidungs-Graph (engl.: »Decision Graph«) bezeichnet [Jen07].

Für den Anwendungsbereich der maritimen Situationserkennung modellieren Fooladvandi et al. ein BN mit einer baumähnlichen Struktur zur Erkennung eines Lotsenszenarios [Foo09]. Dabei ist der Wurzelknoten die Situation von Interesse (das »Lotsen eines Schiffes«) und die Blattknoten entsprechen den Indikatoren, welche diese Situation unterstützen. Indikatoren sind beispielsweise, dass das Schiff wartet, dass das Schiff auf das Lotsenboot trifft,



dass das Schiff eskortiert wird, dass das Schiff den Hafen erreicht oder dass das Lotsenboot zum Ausgangsgebiet zurückkehrt. In [Foo09] werden die für das BN benötigten Einträge der CPTs über Expertenbefragungen ermittelt. Eine Evaluation wurde über einen AIS-Datensatz von 14 Tagen durchgeführt, in dem 74 Lotsenszenarien detektiert wurden. Von diesen 74 Szenarien wurden 45 richtig positiv und 29 als falsch positiv erkannt. Die hohe Falschalarmrate wird in [Foo09] damit erklärt, dass sich auf See viele Szenarien mit ähnlichen Indikatoren abspielen.

Auch Lane et al. verwenden in [Lan10] den Ansatz eines BN, um unterschiedliche Kriterien, welche für eine Situation sprechen, zu kombinieren. Dabei ist das Ziel, auffälliges Verhalten von Schiffen zu detektieren. Dieses lässt sich anhand von fünf Kriterien modellieren:

- Abweichen von der normalen Route: Für jedes Schiff die Wahrscheinlichkeit, dass der angegebene Zielhafen angefahren wird, gegeben seiner bisher gefahrenen Route.
- Erkennen einer ungewöhnlichen AIS-Aktivität: Dabei wird aus historischen Daten eine Abdeckungskarte erstellt, mit Hilfe derer ermittelt werden kann, wo ein AIS-Signal zukünftig zu erwarten ist.
- Unerwartetes Eintreffen in einen Hafen: Dabei wird die Information verwendet, wie oft welches Schiff bestimmte Häfen besucht hat.
- Das Ereignis, dass zwei Schiffe sich ungewöhnlich nahe kommen.
- Das Ereignis, dass ein Schiff in ein bestimmtes Gebiet einfährt.

Bei der Modellierung wählen Lane et al. wie in [Foo09] eine baumähnliche Struktur für das BN [Lan10]. Der Wurzelknoten entspricht dabei der Situation von Interesse, also dem auffälligen Verhalten, welches in mehrere Kategorien unterteilt werden kann. Die einzelnen Kriterien werden als kontinuierliche Blattknoten modelliert. Zwischen Wurzel- und Blattknoten werden diskrete Variablen eingeführt, welche binär den Zustand der einzelnen Kriterien schätzen. In [Lan10] wurden die Ergebnisse mit diesem Ansatz nur mit numerischen Beispielwerten verdeutlicht und keine Evaluierung mit realen Daten durchgeführt.

In [Pil12] modellieren Pilato et al. zwei BNs, welche als Frühwarnung für einen Piratenangriff eingesetzt werden sollen. Für das Management des Domänenwissens wurde eine maritime Ontologie aufgebaut. Dabei schätzt ein

BN, ob es sich bei einem Schiff um ein mögliches Piratenboot handeln könnte, unter anderem anhand der Geschwindigkeit und der Tatsache, ob es sich identifiziert hat. Das zweite BN wird eingesetzt, um den Abstand zu anderen Schiffen auszuwerten und mit Hilfe dessen einen möglichen Gefährdungsgrad zu berechnen. In [Pil12] wurden sowohl für die Parameterbestimmung als auch für die Verifikation der Funktionsweise nur simulierte Daten verwendet. Eine umfassende Evaluierung wurde nicht durchgeführt.


In [Krü12] modellieren Krüger et al. ein wesentlich komplexeres BN mit 40 Knoten, um damit Schmuggelaktivitäten in Küstennähe zu detektieren. Auch hier wird die Funktionalität nur an einzelnen Beispielen aufgezeigt, aber keine Evaluierung an simulierten oder realen Daten durchgeführt.

In [Bro14] verwenden van den Broek et al. ein BN in Form eines naiven Bayes-Klassifikators. Dabei hat das BN eine Struktur wie in Abbildung 2.9 dargestellt [Cow99; Kol09]. Die Zielklasse  $C$  kann dabei die Zustände  $c^1, \dots, c^k$  annehmen. Insbesondere sind bei gegebener Klasse  $C$  die Merkmalsvariablen  $X^1, \dots, X^n$  bedingt unabhängig voneinander. Unter dieser Unabhängigkeitsvoraussetzung lässt sich die A-posteriori-Wahrscheinlichkeit darstellen als

$$P(C|X^1, \dots, X^n) = \frac{P(C) \prod_{i=1}^n P(X^i|C)}{P(X^1, \dots, X^n)}. \quad (2.20)$$

Für Beobachtungen  $x^1, \dots, x^n$  ist der Nenner  $P(x^1, \dots, x^n)$  konstant. Die Zielklasse wird dann bestimmt durch den Maximum-A-posteriori-Schätzer (MAP)

$$\arg \max_{c^j, j=1, \dots, k} P(c^j|x^1, \dots, x^n) = \arg \max_{c^j, j=1, \dots, k} P(c^j) \prod_{i=1}^n P(x^i|c^j). \quad (2.21)$$



**Abbildung 2.9.:** Darstellung eines naiven Bayes-Klassifikators als BN.

In [Bro14] wird die Situation von Interesse als Zielklasse, also als Wurzelknoten modelliert, und die Indikatoren für die Situation als Merkmalsvariablen. Die Situation von Interesse ist dabei ein Piratenangriff. Indikatoren für diese Situation sind beispielsweise ein präsentes Mutterschiff, mächtige Antriebsmotoren des Piratenschiffs, eine Klettervorrichtung an Bord des Piratenschiffs (z.B. eine Leiter), Waffen an Bord des Piratenschiffs oder dass das Piratenschiff sich in einer Pirateriegegend aufhält. Auch in [Bro14] wurde der Ansatz mit simulierten und nicht mit realen Daten evaluiert. Die Ergebnisse zeigen ein sehr gutes Resultat bei der Detektion von Piratenangriffen. In diesem speziellen Fall ist es jedoch fraglich, inwieweit die verwendeten Indikatoren, zum Beispiel die Existenz von Waffen an Bord, robust zu detektieren sind.

### Dynamische Bayes'sche Netze

Eine andere Möglichkeit der Situationserkennung bieten die dynamischen Bayes'schen Netze (DBN). Sie erweitern die Bayes'schen Netze um die Zeitkomponente. Die Grundidee dabei ist, dass ein Bayes'sches Netz über die Zeit hinweg »ausgerollt« werden kann. Struktur und CPD bleiben dabei pro Zeitschritt erhalten und dienen als Schablonen für den Ausrollprozess.

**Definition 2** (nach [Kol09]) Ein *dynamischen Bayes'sches Netz (DBN)* ist ein Paar  $(B_0, 2TBN)$ , mit

- $B_0$  ist die A-priori-Verteilung  $P(X_0^{1:n})$  zum Zeitpunkt 0 über die Menge  $X^{1:n} = X^1, \dots, X^n$  von Zufallsvariablen, und
- $2TBN$  (engl.: »2-Time-Slice Bayesian Network«) definiert die bedingte Wahrscheinlichkeitsverteilung über einen Zeitschritt hinweg mit


$$P(X_t^{1:n} | X_{t-1}^{1:n}) = \prod_{i=1}^n P(X_t^i | Pa(X_t^i)), \quad (2.22)$$

wobei  $X_t^i$  ein Knoten der Zeitscheibe  $t$  ist und  $Pa(X_t^i)$  die Menge der Elternknoten von  $X_t^i$ . Die einzelnen Elternknoten können sich dabei in der Zeitscheibe  $t$  oder in der Zeitscheibe davor, also in  $t-1$  befinden.  $\square$


Für eine beliebige Zeitspanne  $T > 0$  ist die gemeinsame Wahrscheinlichkeitsverteilung von  $X_{0:T}^{1:n}$  definiert als das ausgerollte DBN und kann nach [Mur02] berechnet werden als

$$P(X_{0:T}^{1:n}) = \prod_{t=0}^T \prod_{i=1}^n P(X_t^i | Pa(X_t^i)). \quad (2.23)$$

**Beispiel 2** (nach [Dor10]) In Abbildung 2.10 ist links beispielhaft eine A-priori-Verteilung über drei Zufallsvariablen als graphisches Modell dargestellt. Rechts in Abbildung 2.10 ist beispielhaft ein  $2TBN$  dargestellt. Insbesondere wird hier ersichtlich, dass die Abhängigkeiten in  $B_0$  nicht zwingend den Abhängigkeiten innerhalb der Zeitscheibe  $t$  des  $2TBN$  entsprechen müssen und dass das  $2TBN$  nicht die Abhängigkeiten innerhalb der Zeitscheibe  $t - 1$  definiert.



**Abbildung 2.10.:** Beispiel eines DBN mit der A-priori-Verteilung  $B_0$  (links) und dem  $2TBN$  (rechts).



**Abbildung 2.11.:** Beispiel eines ausgerollten DBN über vier Zeitschritte mit  $(B_0, 2TBN)$  aus Abbildung 2.10.

In Abbildung 2.11 wird das in Abbildung 2.10 definierte, und über 3 Zeitschritte ausge rollte DBN visualisiert. Es ist deutlich zu erkennen, wie  $B_0$  als Startverteilung dient und  $2TBN$  als Schablone für den Ausrollprozess verwendet wird. □

Dynamische Bayes'sche Netze wurden in der Dissertation von Murphy umfassend behandelt, insbesondere ihre Repräsentationsformen und effiziente Inferenz- und Lernverfahren [Mur02]. Sie zeigen besonders dann gute Ergebnisse, wenn die Sensorbeobachtungen verrauscht sind [Wig11].

In [Kas07] wird ein DBN verwendet, um die Aktivität älterer Personen in einer smarten Umgebung zu erkennen. Dabei wurde ein DBN in Form eines dynamischen naiven Bayes-Klassifikators (DNBC, engl.: »Dynamic Naive Bayes Classifier«) gewählt, welches sehr gute Ergebnisse zeigt, wenn Beobachtungswerte über ein Zeitintervall hinweg verfügbar sind. Der DNBC hat innerhalb einer Zeitscheibe die Struktur eines naiven Bayes-Klassifikators und verbindet über eine temporale Kante die Wurzelknoten miteinander [Mar08]. Die Struktur eines DNBC ist in Abbildung 2.12 skizziert.




Abbildung 2.12.: Struktur eines DNBC.

Digioia et al. verwenden in [Dig13] ein ähnliches DBN, um das Verhalten eines Schiffs zu modellieren. Dabei hat jede Zeitscheibe die Struktur eines naiven Bayes-Klassifikators. Dabei entspricht der Wurzelknoten der Situation von Interesse und die Blattknoten den einzelnen beobachtbaren Merkmalen Geschwindigkeit, Richtung und Position. Die temporalen Kanten zeigen jedoch nicht wie beim DNBC von Wurzelknoten zu Wurzelknoten, sondern von dem Wurzelknoten in  $t-1$  zu den Merkmalsknoten in  $t$ . Das Modell wurde weder mit simulierten noch mit realen Daten evaluiert. In diesem Modell ist jedoch

die Anzahl der Parameter für die gleiche Anzahl Knoten wesentlich höher als bei einem DNBC-Modell und das Lernen der Parameter ist damit wesentlich aufwändiger.

Dabrowski et al. verwenden in [Dab15] ein dynamisches Bayes'sches Netz, um das Auftreten von Piratenangriffen zu modellieren. Dieses dient als Grundlage dafür, simulierte Piratenangriffe zu erzeugen. Das erzeugte Modell wurde mit realen Daten, also mit tatsächlich aufgetretenen Piratenangriffen im Golf von Aden aus dem Jahr 2011 evaluiert. Dabei wurde festgestellt, dass das DBN sehr gut geeignet ist, um eine realistische räumliche und zeitliche Verteilung von Piratenangriffen zu simulieren.

Eine weitere Spezialisierung eines DBNs ist neben dem DNBC das Hidden-Markov-Modell (HMM), welches ursprünglich für die ersten Spracherkennung eingesetzt wurde [Rab89; Zwe98]. Das HMM ist ein DNBC mit nur einem Merkmalsknoten. HMMs können dazu eingesetzt werden, unterschiedliche Verkehrssituationen zu erkennen. Dazu wird für jede Situation ein HMM trainiert. Bei der Erkennung werden diese dann parallel evaluiert [Mey09]. In [And10] setzen Andersson et al. HMMs ein, um einen Piratenangriff zu erkennen. Dabei trainieren sie das Modell mit simulierten Daten, welche keinem Piratenangriff entsprechen. Ein Piratenangriff wird dann detektiert, wenn die Beobachtungen nicht mehr zum Modell passen. Dieser Ansatz ist vergleichbar mit dem Ansatz in der Anomaliedetektion. In [And10] wurde jedoch nur an einem konstruierten Minimalbeispiel gezeigt, dass der Ansatz funktioniert.

## Objektorientierte Bayes'sche Netze

Eine Möglichkeit, Bayes'sche Netze mit einer objektorientierten Sicht zu verknüpfen, bieten die objektorientierten Bayes'schen Netze (OOBN) [Kol97]. Mit OOBNs lassen sich Klassenhierarchien von Objekten als Schablonen modellieren, welche für verschiedene Objektinstanzen verwendet werden können. Kasper et al. wenden OOBNs an, um einen Spurwechsel während einer Fahr-situation zu erkennen [Kas12]. Ein wesentlicher Nachteil der OOBNs ist jedoch, dass sie nicht in der Lage sind, Situationen zu modellieren, in die mehrere Objekte involviert sind und die sich über die Zeit hinweg verändern [Kol97].

### **Objektorientierte probabilistische relationale Modelle**

Um dieses Problem zu adressieren, wurde von Howard et al. die Sprache der objektorientierten probabilistischen relationalen Modelle (OPRM) [How05] entwickelt, welche die probabilistischen relationalen Modelle [Get07] mit einer objektorientierten Sicht verknüpft. Die Sprache besteht aus einer relationalen und einer probabilistischen Komponente. Die relationale Komponente beschreibt dabei die Klassenstrukturen und -beziehungen. Die probabilistische Komponente beschreibt die probabilistischen Abhängigkeiten zwischen den Attributen [How09]. Insgesamt definiert ein OPRM genau wie ein BN eine Wahrscheinlichkeitsverteilung über alle möglichen Ausprägungen der modellierten Variablen. OPRMs sind dafür geeignet, komplexe Domänen vollständig zu modellieren, insbesondere auch die Unsicherheit über die Existenz von Objekten, Attributen und Relationen sowie über die modellierte Struktur [How05]. In [Sch11a] verwenden Schamm et al. ein OPRM, um Fahrsituationen zu modellieren und eine mögliche Kollision zu detektieren.

### **Multi-Entitäts-Bayes'sche Netze**

Eine Erweiterung der Ontologie-Modellierungssprache OWL um eine probabilistische Komponente ist die probabilistische OWL (PR-OWL, engl.: »Probabilistic Web Ontology Language«), welche in [Cos05] vorgestellt wurde. PR-OWL wendet die Theorie der Multi-Entitäts-Bayes'schen Netze (MEBN, »Multi-Entity Bayesian Network«) an, welche von Laskey entwickelt wurde und in [Las08] im Detail vorgestellt wurde. MEBNs erweitern die Bayes'schen Netze, so dass sie die Repräsentation eines graphischen Modells mit sich wiederholenden Teilstrukturen erlauben. MEBN verwalten das Wissen als eine Menge von Fragmenten, sogenannten MFragments, welche wiederum als MEBN Theorien (MTheories) gruppiert werden [Las08; Car10]. Ein MFragment enthält Zufallsvariablen und einen Graphen, welcher die Abhängigkeiten zwischen den Zufallsvariablen definiert. Ein MFragment repräsentiert eine wiederholbare Wissensstruktur, welche mehrere Male instanziiert werden kann. Bei der Instanziiierung wird ein situationsspezifisches Bayes'sches Netz (SSBN) gebildet, mit welchem dann der Inferenzprozess für eine spezielle Anfrage durchgeführt werden kann [Mah98; Las08]. Ein MFragment kann also als Schablone für das Erstellen eines Teils eines Bayes'schen Netzes interpretiert werden. Die

Software UnBBayes<sup>53</sup> stellt eine Oberfläche zum Erstellen von MTheories und MFragments bereit sowie den Algorithmus, mit dem entsprechende SSBNs erstellt werden können [Car10].

In [Car11] erstellen Carvalho et al. eine probabilistische Ontologie für die maritime Domäne basierend auf MEBNs. Sie dient dazu, Schiffe von Interesse zu detektieren, welche sich durch ungewöhnliches Verhalten auszeichnen. Kriterien für ein ungewöhnliches Verhalten sind in diesem Falle nicht nur eine anormale Trajektorie, sondern beispielsweise auch, ob Waffen an Bord sichtbar sind oder ein Mitglied der Crew verdächtigt wird, einer Terrorgruppe anzugehören. In [Las11] wird aus dieser modellierten Ontologie ein SSBN erzeugt, um Schiffe von Interesse zu identifizieren, und ein SSBN, um den militärischen Schiffstyp zu identifizieren. In [Cos12] wird dieselbe Ontologie verwendet, um den Algorithmus, welcher die SSBN erzeugt, zu evaluieren. Dies wurde mittels simulierter Daten durchgeführt. Dabei wurden Erkennungsraten von bis zu 88 % erreicht.

### Markov-Logik-Netze

Markov-Logik-Netze sind ein Ansatz, um Prädikatenlogik und probabilistische graphische Modelle in einer Form zu repräsentieren. Ein Markov-Logik-Netz (MLN) ist definiert als eine Wissensbasis erster Ordnung, wobei jeder Formel ein Gewicht zugeordnet ist. Zusammen mit einer Menge von Konstanten, welche Objekte in der Domäne repräsentieren, spezifiziert es ein »belegtes« Markov-Netz, also ein Netzwerk ohne freie Variablen. Das Markov-Netz beinhaltet dann ein Merkmal für jede mögliche geschlossene Formel der Wissensbasis und sein zugehöriges Gewicht [Ric06]. Inferenz kann in einem solchen Markov-Netzwerk mit den gängigen Methoden durchgeführt werden, also beispielsweise mit der approximativen Markov-Ketten-Monte-Carlo (MCMC)-Methode oder der sogenannten Belief Propagation [Ric06].

MLNs wurden bereits im Bereich der kognitiven Automobile erfolgreich angewendet. So wurden sie in [Sti08] eingesetzt, um symbolisches Wissen über die Verkehrsszene zu formulieren. Dabei wurden MLNs erfolgreich zur Klassifikation von Objekten der Verkehrsszene eingesetzt. Auch in [Nie14] wurden MLNs für die Situationserkennung im Straßenverkehr eingesetzt. Ni-

---

<sup>53</sup> <http://sourceforge.net/projects/unbbayes>, letzter Abruf am 16.04.2015



enhüser modelliert dabei Wissensbasen, welche es ermöglichen, Baustellen zu erkennen oder die Relevanz von Tempolimits oder Ampeln zu bestimmen.

In [Sni12] wurden MLN eingesetzt, um in einem maritimen Szenario ein auffälliges Boot zu erkennen. Dazu wurden Variablen verwendet wie beispielsweise der Schiffstyp, ob das Schiff in Richtung eines Hafens fährt, ob das Schiff Fracht an Bord hat, ob ein Schiff seine Route geändert hat oder ob ein Crewmitglied verdächtig ist. Eine Evaluation mit realen Daten wurde nicht durchgeführt. Das MLN wurde mit Beispielervidenzen, also mit Beobachtungen befüllt und exemplarisch wurden einige Ergebnisse aufgezeigt, um die Einsetzbarkeit von MLNs zu demonstrieren.

Eine Evaluation mit realen Daten wurde in [Aus12] durchgeführt. Die Daten wurden manuell als Angriff, normales Fahren und Flucht annotiert. Als Merkmale für das MLN wurden aus den Trackdaten folgende extrahiert: vorhergehender Zustand des Schiffs, Abstand von zwei Schiffen, ein Schiff peilt ein anderes an, Abstand von zwei Schiffen verringert sich. Die eingesetzten Regeln werden in [Aus12] nicht explizit aufgezählt, jedoch wurde erwähnt, dass es sich um Wenn-Dann-Regeln handelt. Bei der Evaluation wurden Genauigkeit (engl.: »Precision«) und Trefferquote (engl.: »Recall«) berechnet, wobei das MLN im Vergleich zu anderen Methoden wie beispielsweise einem HMM, am besten abschnitt.

## 2.6. Zusammenfassung

Das Situationsbewusstsein als mentaler Zustand des Menschen ist bei der Bedienung komplexer Systeme, welche zur Entscheidungsfindung genutzt werden, von essentieller Bedeutung. Für die Messung des Situationsbewusstseins gibt es unterschiedliche Ansätze, wobei noch nicht hinreichend untersucht ist, welche der Methoden welche Aspekte des Situationsbewusstseins bewerten. Auf maschineller Ebene ist analog zum Situationsbewusstsein die Datenfusion einzuordnen, wobei das bekannteste Modell das JDL-Datenfusionsmodell ist. Insbesondere entspricht die Situationsanalyse auf maschineller Ebene dem Verstehen auf kognitiver Ebene. Speziell in maritimen Überwachungssystemen werden heutzutage Systeme eingesetzt, welche die Objekterkennung und -verfolgung unterstützen, jedoch noch nicht die Situationsanalyse.

Ein zentrales Element, um die Ergebnisse der Objekterkennung vorzuhalten, ist das sogenannte Weltmodell. Dieser Ansatz wurde ursprünglich in der Robotik entwickelt und erfolgreich in der Fahrzeugführung und der Vi-

deüberwachung eingesetzt. Er wurde jedoch noch nicht auf die maritime Überwachung übertragen. Ein solches Weltmodell bietet einheitliche Schnittstellen, über die Situationserkennungsmodule auf den Inhalt zugreifen können und Schlussfolgerungen ziehen können, und zwar entkoppelt von der eingesetzten Sensorik.

Methoden zur Situationserkennung lassen sich generell unterscheiden in Methoden zur Anomaliedetektion und Methoden zur Erkennung spezifischer Situationen. Bei der Anomaliedetektion besteht der Ansatz darin, ein Normalmodell zu lernen und die Beobachtungen mit diesem Modell zu vergleichen. Bei einer zu starken Abweichung vom Normalmodell wird eine Anomalie detektiert. Die eingesetzten Methoden basieren auf lernenden Verfahren, was bedeutet, dass zwingend eine ausreichend große und ausreichend repräsentative Menge an Trainingsdaten zur Verfügung stehen muss. Methoden zur Erkennung spezifischer Situationen lassen sich in regelbasierte und probabilistische Verfahren unterteilen. Regelbasierte Verfahren haben den Vorteil, dass der Mensch in der Lage ist, die Regeln selbst zu formulieren und zu verwalten. Die Inferenzmechanismen liefern jedoch nur einen Wahr- oder Falsch-Wert zurück. Die probabilistischen Verfahren können hingegen mit Unsicherheiten umgehen und somit verrauschte Sensordaten kompensieren, sind jedoch für den Menschen nicht intuitiv modellierbar.

Vielversprechende Ansätze beruhen auf den Bayes'schen Netzen, im Besonderen auf dynamischen Bayes'schen Netzen, welche in der Lage sind, die Zeitkomponente mit abzubilden. Diese liefern sowohl in der Anomaliedetektion als auch in der spezifischen Situationserkennung sehr gute Ergebnisse. Da das Vorhandensein von Trainingsdaten nicht vorausgesetzt werden kann, müssen die Netze geeignet parametrisiert werden. In den Veröffentlichungen, welche ohne Trainingsdaten Bayes'sche Netze einsetzen, ist selten die Bestimmung der Parameter adressiert, sondern meist nur die Bestimmung der Struktur. Insbesondere fehlt eine strukturierte Vorgehensweise, wie Situationen in einem BN oder DBN zu modellieren sind und wie die Parameter zu wählen sind, so dass sich das Modell so verhält, wie der Mensch es erwarten würde.

Veröffentlichungen, in denen quantitative Evaluierungen von Methoden zur Situationserkennung durchgeführt werden, sind kaum zu finden. Meist beruhen die Evaluierungen auf simulierten Daten oder wenigen exemplarischen Ergebnissen. Dies liegt zum einen daran, dass für eine quantitative Evaluierung die Daten hinsichtlich ihrer Situationen annotiert werden müssen. Dies ist einerseits zeitaufwändig, andererseits nicht trivial, da sich unterschiedliche

---

Situationen in ihrer Ausprägung, also den beobachtbaren Merkmalen, sehr ähnlich sein können. Zum anderen liegt es daran, dass die Situationserkennung generell nicht als Klassifikation interpretiert werden kann, sondern als Entscheidungsunterstützung für den Menschen dienen soll. Im strengen Sinne müsste schlussendlich das Situationsbewusstsein eines Operators evaluiert werden, welcher die Situationsanalysedienste nutzt, um einen Nachweis für deren Nutzen zu bringen.



# 3

---

## Umweltmodellierung

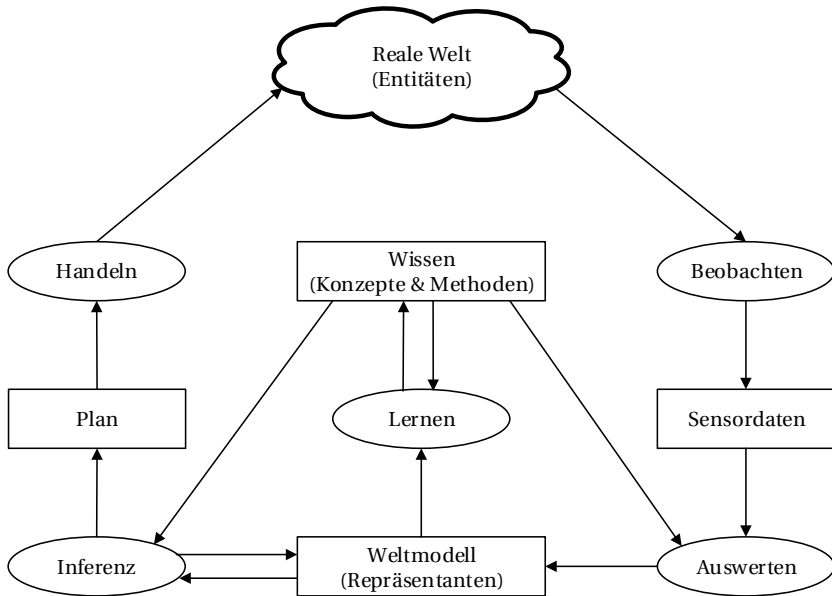
---

In diesem Kapitel wird zunächst der Informationsfluss in intelligenten Überwachungssystemen ermittelt und vorgestellt. Des Weiteren wird eine konsistente Terminologie definiert und im Speziellen auf die in dieser Arbeit verwendete Modellierung von Objekten und Situationen eingegangen. Abschließend wird das objektorientierte Weltmodell auf die maritime Anwendungsdomäne übertragen.

### 3.1. Informationsfluss in Überwachungssystemen

Die grundlegende Aufgabe von Überwachungssystemen besteht darin, einen räumlich-zeitlichen Ausschnitt der *realen Welt* zu beobachten. Alle Elemente der realen Welt werden im Folgenden als *Entitäten* bezeichnet. Die Bezeichnung Entität umfasst weit mehr als nur die physikalischen Objekte, vielmehr werden damit auch nicht-physikalische Elemente wie Objektattribute, Beziehungen zwischen physikalischen Objekten, Ereignisse und Situationen mit einbezogen. Eine Entität kann also sowohl eine konkrete, physikalische Ausprägung, als auch eine sehr abstrakte Gegebenheit sein. Alle Entitäten zusammengefasst beschreiben somit den vollständigen Zustand der realen Welt auf allen Abstraktionsebenen. Aufbauend auf dem Zustand der realen Welt wird im Folgenden der Informationsfluss in Überwachungssystemen

erläutert, welcher sukzessive entwickelt wurde [Fis10a; Fis11a; Fis12a; Fis13]. Zur Verdeutlichung der Ausführungen ist der Informationsfluss in Abbildung 3.1 visualisiert.



**Abbildung 3.1.:** Der Informationsfluss in Überwachungssystemen. Informationsaggregate sind als Rechtecke, Prozesse als Ellipsen visualisiert.

### 3.1.1. Beobachten

Im ersten Schritt des Informationsflusses werden die Entitäten der realen Welt mit Hilfe von Sensoren *beobachtet*. Ein wichtiger Aspekt ist dabei, dass nicht alle Entitäten direkt beobachtet werden können. Beispielsweise gibt es keinen Sensor, welcher direkt eine kritische Situation wie einen Piratenangriff erkennen kann. Die Entitäten der realen Welt können also entweder direkt beobachtbare oder nicht direkt beobachtbare Elemente repräsentieren. Die

Sensorik selbst kann in Überwachungssystemen höchst heterogen ausgeprägt sein. So werden in gängigen Videoüberwachungssystemen hauptsächlich optische und Infrarot-Kameras, in maritimen Systemen hauptsächlich das AIS-System und Radarsensorik eingesetzt (siehe Abschnitt 2.3.2). Der hier vorgestellte Informationsfluss erlaubt auch den Mensch als Sensor, wobei das System natürlich die Schnittstellen zur Weiterverarbeitung der Information bereitstellen muss. Die Beobachtung der realen Welt resultiert in einem Informationsaggregat, den *Sensordaten*. Sensordaten sind beispielsweise Videobilder oder die noch unverarbeiteten AIS-Funkdaten.

### 3.1.2. Auswerten

Die *Auswertung* der Sensordaten wird mit Hilfe von *Wissen* durchgeführt. Das Wissen besteht aus deskriptivem Wissen in Form von abstrakten *Konzepten* und prozeduralem Wissen in Form von *Methoden*. Es enthält also die notwendigen Signalverarbeitungsmethoden und Algorithmen, um die Sensordaten zu verarbeiten und auszuwerten. Die Auswertung der Sensordaten beinhaltet beispielsweise die Detektion, die Lokalisation oder das Verfolgen von bewegten Objekten in Videoströmen, oder auch die Dekodierung der AIS-Funkdaten. Die aus der Auswertung resultierende Information wird anschließend an das *Weltmodell* weitergeleitet.

Das *Weltmodell* dient als Repräsentation der Entitäten der realen Welt und besteht demnach aus *Repräsentanten*. Jeder Repräsentant im Weltmodell entspricht einer Entität der realen Welt. Die Abbildungen von Entitäten auf Repräsentanten ist durch Konzepte definiert, welche im Wissensaggregat abgelegt sind. Konzepte werden beispielsweise im Auswertungsprozess verwendet, indem sie definieren, wie ein beobachtetes Schiff im Weltmodell repräsentiert werden soll, also welche Objektmerkmale extrahiert werden sollen. Da die beobachtete reale Welt hoch-dynamisch ist und sich deren Zustand über die Zeit hinweg ändert, werden auch die Historien der Repräsentanten im Weltmodell vorgehalten. Jedoch ist das Weltmodell eher als Kurzzeitspeicher zu interpretieren und nicht wie eine Datenbank als Langzeitspeicher von Information.

### 3.1.3. Inferenz und Lernen

Da, wie zuvor erwähnt, nicht alle Entitäten direkt beobachtbar sind, greift ein *Inferenzprozess* auf die vorgehaltenen Informationen im Weltmodell zu und schlussfolgert über nicht-beobachtbare (oder auch nicht beobachtete) Entitäten. Für den Inferenzprozess werden, wie zuvor beim Auswerteprozess, Methoden und Konzepte aus dem Wissensaggregat herangezogen. Ein einfacher Inferenzprozess berechnet beispielsweise die Geschwindigkeit eines Schiffes anhand der aktuellen und der letzten bekannten Position. Ein komplexerer Inferenzprozess ist beispielsweise die wahrscheinlichkeitsbasierte Schätzung, ob ein beobachtetes Schiff illegale Fischerei betreibt.

Die Ergebnisse der Inferenzprozesse fließen dabei wieder als neue Repräsentanten in das Weltmodell zurück. Auf diese Weise wird das Weltmodell durch vordefinierte Inferenzprozesse ständig aktualisiert und um neue Informationen ergänzt. Des Weiteren wird dadurch das Ziel unterstützt, dass das Weltmodell stets einer aktuellen und kompletten Repräsentation der realen Welt entspricht. Das Wissen, welches dafür verwendet wird, stellt dabei alle Methoden zur Auswertung der Sensordaten und zur Durchführung der Inferenzprozesse bereit. Die vordefinierten abstrakten Konzepte werden zur Repräsentation der Entitäten im Weltmodell herangezogen. Die Ausprägung des Wissensaggregates ist dementsprechend bestimmt durch die Anwendungsdomäne, ist also abhängig von der vorhandenen Sensorik und den Aufgaben des Überwachungssystems. Des Weiteren muss die Ausprägung des Wissensaggregates nicht zwingend statisch sein. Der Inhalt des Weltmodells kann von einem *Lernprozess* verwendet werden, um neues Wissen zu generieren. Dazu zählen beispielsweise maschinelle Lernverfahren, welche anhand einer Sammlung von Trainingsdaten die Parameter der eingesetzten Methoden bestimmen.

Die folgenden zwei Beispiele geben eine kurze Ausführung über den konkreten Informationsfluss bei Inferenzprozessen.

**Beispiel 3** In diesem Beispiel wird der Informationsfluss einer Trackinganwendung erläutert. In dieser Anwendung werden bei der Auswertung der Sensordaten kontinuierlich Beobachtungen von Schiffspeditionen generiert, beispielsweise durch ein Küstenradar, und an das Weltmodell gesendet. Der darauf aufsetzende Inferenzprozess verwendet nun die letzten bekannten Schiffspeditionen von bereits verifizierten Tracks, sowie die neu erfassten Beobachtungen. Der Inferenzprozess führt eine Datenassoziation und -fusion durch, bei der die neuen Beobachtungen den verifizierten Tracks zugeordnet



werden. Dies leistet beispielsweise das Nächste-Nachbarn-Verfahren. Anschließend kann das Kalman-Filter verwendet werden, um die aktualisierte Position der Schiffe zu schätzen. Die aktualisierte Position wird dann dem Weltmodell als neue Information zurückgegeben. □

**Beispiel 4** Ähnlich zu betrachten ist der Informationsfluss bei der Situationserkennung, beispielsweise bei der Kollisionserkennung zweier Schiffe. Dazu verwendet der Inferenzprozess die aktuellen Positionen, Geschwindigkeiten und Bewegungsrichtungen aller Schiffe im Weltmodell. Der Inferenzprozess führt nun paarweise eine Schätzung durch, ob sich die beiden Bewegungsrichtungen überschneiden und ob die aktuellen Geschwindigkeiten zu einer Kollision am Schnittpunkt führen würden. Diese Kollisionserkennung kann als Repräsentant in das Weltmodell zurückgegeben werden. □

### 3.1.4. Handeln

Ein weiteres Ergebnis eines Inferenzprozesses kann auch die Generierung eines *Plans* sein, also die Generierung eines Handlungsvorschlags, wie man in der realen Welt agieren sollte. Ein solcher Plan kann beispielsweise ein Befehl zur Kursänderung eines beobachteten Schiffes sein oder auch ein Vorschlag zum Einsatz bestimmter Sensoren. Die Generierung eines Plans kann auch als Entscheidungsunterstützung interpretiert werden, falls beispielsweise dem Operator des Überwachungssystems Handlungsvorschläge angezeigt werden und der Operator selbst die Entscheidung treffen muss. Im nächsten Schritt findet die *Handlung* selbst statt, also die Ausführung des generierten Plans, welche wiederum eine Auswirkung auf den Zustand der realen Welt haben kann.

Dies schließt den Zyklus des hier vorgestellten Informationsflusses eines intelligenten Überwachungssystems. Abschließend sei bemerkt, dass die einzelnen Prozesse des Informationsflusses nicht zwingend autonom vom System durchgeführt werden. Vielmehr kann jeder der fünf Prozesse auch als interaktive Systemkomponente gestaltet werden, oder sogar als ein vom Menschen selbst durchgeführter Prozess umgesetzt werden. Bei der Umsetzung des Systems sind dabei, wie schon oben erwähnt, die entsprechenden Schnittstellen zur Weiterverarbeitung der Information zu integrieren.

## 3.2. Modellierung von Objekten

In diesem Abschnitt wird das in dieser Arbeit verwendete Konzept eines Objektes vorgestellt. In der Messtechnik wird nach der [DIN95] ein Messobjekt als Träger der Messgröße definiert. Weiter können Messobjekte demnach Körper, Vorgänge oder Zustände sein. Diese Arbeit orientiert sich an den Grundbegriffen der Messtechnik und definiert ein Objekt wie folgt.

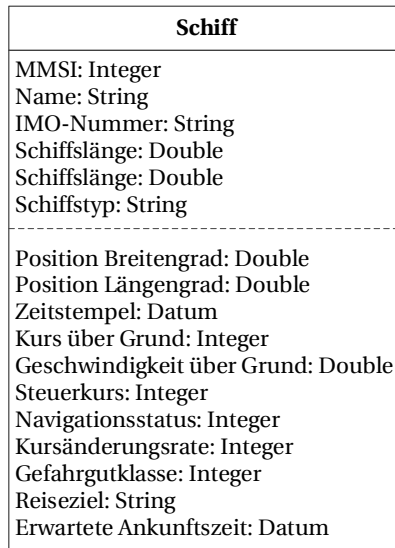
**Definition 3** Ein *Objekt* ist ein abstraktes Konzept, welches in der realen Welt einer Entität mit physikalisch messbaren Größen entspricht. □

Aus der Sichtweise der objektorientierten Programmierung ist ein Objekt über seine Objektklasse beschrieben [Poe09]. Eine Objektklasse ist wiederum ein abstraktes Modell, welches als Konzept für einen konkreten Repräsentanten dient. Eine Objektklasse ist eindeutig bestimmt durch eine Menge von Attributen welche das Objekt semantisch beschreiben. Darunter fallen unter anderem auch die physikalisch messbaren Größen. Sie kann also als Äquivalenzklasse aller Objekte, welche die gleiche Attributliste besitzen, interpretiert werden. Die Äquivalenzklasse eines Objektes  $O$  auf der Menge aller Objekte  $\mathcal{O}$  lässt sich also mathematisch beschreiben als

$$[O] = \{X \in \mathcal{O} \mid X \sim O\} \subseteq \mathcal{O}. \quad (3.1)$$

Des Weiteren lassen sich die Attribute eines Objektes in statische und dynamische Attribute unterteilen. Attribute, deren Werte sich über die Zeit hinweg nicht ändern, also zeit-invariant sind, werden als statisch bezeichnet. Attribute, deren Werte sich über die Zeit hinweg ändern, werden als dynamisch bezeichnet. Als Objektzustand wird dann die Wertausprägung aller Attribute eines Objektes zu einem Zeitpunkt bezeichnet [Fis12a; Fis13].

**Beispiel 5** Als Beispiel eines Objektconzeptes wird nun die Objektklasse des Schiffes vorgestellt. Zur Modellierung der Attribute greifen wir auf die Informationen zurück, welche mit dem AIS-Signal gesendet werden. Diese Attributliste kann jedoch noch beliebig erweitert werden. Die Objektklasse Schiff wird nun mit der in Abbildung 3.2 aufgelisteten Attributliste definiert.



**Abbildung 3.2.:** UML-Klassendiagramm zur Darstellung des Objekts Schiff.

Die Darstellung orientiert sich an der Notation des UML-Klassendiagramms (engl.: »Unified Modeling Language«<sup>54</sup>), wobei die statischen und dynamischen Attribute hier durch eine gestrichelte Linie unterteilt sind.

Weitere Beispiele von Objekt Konzepten sind sogenannte Geobjekte, also topografische Objekte auf der Erdoberfläche [Stä10]. Das wesentliche Attribut solcher Geobjekte ist deren geografische Position, welche entweder als Punkt, als Linienzug oder Polygon dargestellt werden kann. Beispiele für Objektklassen sind Häfen, Schiffsrouten, Ländergrenzen oder auch kritische Gebiete. Auch Sensoren können als Geobjekte modelliert werden, wobei deren Position und deren Empfangs- oder Abdeckungsbereich als wesentliche Attribute anzusehen sind. Bezüglich der räumlichen Position kann ein Geobjekt sowohl stationär als auch beweglich sein, wie beispielsweise ein Sensor, der seine Position ändert. Die Position kann also je nach Objekttyp als statisches oder dynamisches Attribut modelliert werden. □

<sup>54</sup> Graphische Modellierungssprache, spezifiziert von der Object Management Group, siehe <http://www.omg.org/spec/UML/>, letzter Abruf am 17.04.2015

### 3.3. Modellierung von Situationen

In diesem Abschnitt wird das in dieser Arbeit verwendete Konzept einer Situation vorgestellt. Zunächst wird der Situationsbegriff eingegrenzt und auf bestehende Literatur verwiesen, um anschließend die formale Definition einer Situation vorzustellen und deren Existenz zu definieren.

#### 3.3.1. Eingrenzung des Situationsbegriffs

Im Gegensatz zum Begriff des Objektes wird der Begriff der Situation in der Fachliteratur sehr viel allgemeiner verwendet. Für den Begriff der Situation gibt es bisher keine eindeutige und formale Definition, welche sich durchgesetzt oder verbreitet hat. Um diese Lücke zu schließen, befasst sich diese Arbeit unter anderem auch mit der Findung einer solchen Definition, welche einen generischen Einsatz ermöglicht.

Eine allgemeine Bedeutung des Begriffs der Situation liefert das Online-Wörterbuch des Dudens<sup>55</sup>. Der Situation wird dort unter anderem folgende Bedeutungen zugemessen: »Verhältnisse, Umstände, die einen allgemeinen Zustand kennzeichnen; allgemeine Lage«. Als Synonyme werden im Duden die folgenden Begriffe aufgelistet: »Gegebenheit, (Gesamt)lage, Position, Sachlage, Stand (der Dinge), Umstände, Verhältnisse«. Diese umgangssprachlich verwendete Bedeutung wird auch so in der Fachliteratur verwendet. So definiert Roy in [Roy01] eine Situation beispielsweise als eine »spezifische Kombination von Umständen, d.h. Bedingungen, Fakten oder Zuständen, in einem bestimmten Moment«. Eine weitere natürlichsprachliche Definition einer Situation aus dem Bereich des Pervasive Computing<sup>56</sup> liefern Ye et al. in [Ye12]:

»Eine Situation ist definiert als eine externe semantische Interpretation von Sensordaten. Interpretation heißt, dass Situationen den Sensordaten Bedeutungen zuordnen. Extern heißt, dass die Interpretation eher aus der Anwendungsperspektive als aus den Sensordaten stammt. Semantisch heißt, dass die Interpretation

<sup>55</sup> <http://www.duden.de/rechtschreibung/Situation>, letzter Abruf am 18.04.2015

<sup>56</sup> Pervasive Computing bezeichnet die allgegenwärtige und im Hintergrund laufende Nutzung, Erzeugung, Verarbeitung, Übertragung und Speicherung von Informationen. Dabei werden Alltagsgegenstände zu »smarten Objekten«, die miteinander vernetzt sind, auf ihre Umgebung reagieren und mit ihren Nutzern interagieren [BSI06].

den Sensordaten Bedeutungen zuordnet, welche auf Strukturen und Beziehungen innerhalb von gleichartigen Sensordaten und zwischen unterschiedlichen Arten von Sensordaten basieren<sup>57</sup>.«

Im Bereich der Datenfusion wird eine Situation als ein aggregierter Zustand interpretiert [Ste01]. Dieser aggregierte Zustand basiert auf geschätzten Relationen zwischen Entitäten. Entitäten können dabei einzelnen Objekten entsprechen, Gruppen von Objekten oder bereits inferierten Relationen. Eine Situation ist also definiert als eine Menge von Relationen [Ste08]. Lambert wird in [Lam99] und [Lam01] noch einen Schritt konkreter und definiert eine Situation als Abstraktion der realen Welt. Dabei basiert seine Definition auf der Beschreibung der realen Welt mittels räumlich-zeitlicher Fakten, wobei ein Fakt einer Relation zwischen Objekten entspricht und als prädikatenlogischer Ausdruck formuliert wird. Eine Menge von Fakten wird dann als Ereignis bezeichnet, und eine Menge von Ereignissen wiederum als Szenario. Den Begriff der Situation verwendet Lambert nun entsprechend für ein Ereignis oder ein Szenario [Lam01].

Lambert stützt seine Aussagen dabei auf die Veröffentlichungen von Barwise, welcher sich mit der Anwendung von Logik in der natürlichen Sprache beschäftigte und diese als Situationssemantik (engl.: »Situation Semantics«) bezeichnete [Bar89]. Eine Situation wird dabei als Teil der realen Welt definiert, wobei die reale Welt aus Objekten mit Attributen besteht, welche in Beziehungen zueinander stehen [Dev06]. Basierend auf der Situationssemantik entwickelte Devlin die formale Situationstheorie (engl.: »Situation Theory«) [Dev06]. Das zentrale Element der Situationstheorie ist das sogenannte Infon, eine Informationseinheit, welche folgende Formen besitzt:

$$\langle\langle R, x^1, \dots, x^n, 1 \rangle\rangle \text{ oder } \langle\langle R, x^1, \dots, x^n, 0 \rangle\rangle . \quad (3.2)$$

<sup>57</sup> Eigene Übersetzung. Original: »A situation is defined as an external semantic interpretation of sensor data. Interpretation means that situations assign meanings to sensor data. External means that the interpretation is from the perspective of applications, rather than from sensors. Semantic means that the interpretation assigns meaning on sensor data based on structures and relationships within the same type of sensor data and between different types of sensor data.«

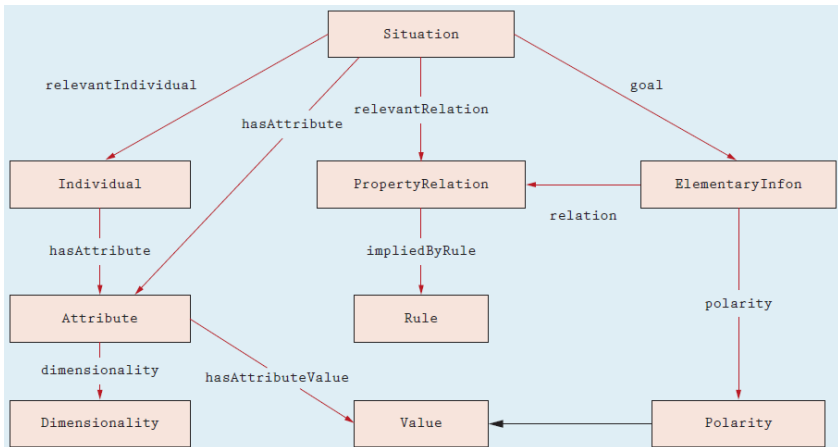
Dabei ist  $R$  eine  $n$ -wertige Relation und  $x^1, \dots, x^n$  die entsprechenden Argumente der Relation. Infons selbst können nicht wahr oder falsch sein, jedoch kann ein Infon  $\sigma$  in einer Situation  $S$  ein Fakt darstellen. Dies wird als  $S$  unterstützt  $\sigma$  bezeichnet und formal dargestellt als

$$S \models \sigma. \quad (3.3)$$

$S \models \ll R, x^1, \dots, x^n, 1 \gg$  bedeutet also, dass in der Situation  $S$  die Argumente  $x^1, \dots, x^n$  in Relation  $R$  stehen, wohingegen  $S \models \ll R, x^1, \dots, x^n, 0 \gg$  bedeutet, dass in der Situation  $S$  die Argumente  $x^1, \dots, x^n$  nicht in Relation  $R$  stehen. Des Weiteren können Infons rekursiv kombiniert werden, um komplexere Sachverhalte darzustellen. Unterschiedliche Situationsklassen können dann definiert werden als

$$S = \{S \mid S \models \ll R, x^1, \dots, x^n, 1 \gg\}. \quad (3.4)$$

Basierend auf der Situationstheorie haben Kokar et al. eine Ontologie entwickelt, welche die Situationstheorie mittels OWL modelliert [Kok09]. Der Aufbau der Ontologie ist in Abbildung 3.3 aus [Kok12] abgebildet.



**Abbildung 3.3.:** Ontologie nach [Kok12], welche die Situationstheorie abbildet.

In der Ontologie lassen sich Fakten abbilden und mittels Inferenzmechanismen neue Fakten ableiten. Sind also zwei Situationen  $S^1$  und  $S^2$  gegeben, so kann eine dritte Situation  $S^3$  inferiert werden mittels einer einfachen Mengenoperation:

$$S^1 \cap S^2 \subseteq S^3. \quad (3.5)$$

Speziell in [Jak06] und [Jak07] gehen Jakobson et al. auf den dynamischen Aspekt einer Situation ein und definieren diese nicht nur zu einem Zeitpunkt, sondern über ein Zeitintervall  $d$ . Dabei werden drei Situationstypen definiert. Die Basissituation, welche die Attributwerte von Objekten oder Relationen umfasst. Es bezeichne  $\delta$  das Zeitintervall, welches der Lebensdauer eines Objektes bzw. einer Relation entspricht und es gilt  $d \subseteq \delta$ . Mit  $X^1, \dots, X^n$  werden die Attribute eines Objektes oder einer Relation bezeichnet. Die Basissituation trifft eine Aussage darüber, welchen Zustand ein Objekt oder eine Relation innerhalb eines Zeitintervalls annimmt und ist definiert als

$$S(d) = \{(X^1(t), \dots, X^n(t)) | X^i(t_1) = X^i(t_2), \forall t_1, t_2 \in d, i = 1, \dots, n\}. \quad (3.6)$$

Der zweite Situationstyp ist die relationale Situation. Dabei wird eine binäre Relation  $O^1RO^2$  zwischen den Objekten  $O^1$  und  $O^2$  betrachtet, welche jeweils die Lebensdauer  $\delta_1$  und  $\delta_2$  besitzen. Es ist  $\delta = \delta_1 \cap \delta_2$  die Lebensdauer der Relation  $R$ . Für  $d \subseteq \delta$  trifft die relationale Situation eine Aussage über das Bestehen einer Relation und ist definiert als

$$S(d) = O^1RO^2. \quad (3.7)$$

Der dritte Relationstyp ist die zusammengesetzte Relation. Diese basiert auf der Basissituation und der relationalen Situation. Es seien  $S^1(d_1)$  und  $S^2(d_2)$  zwei Situationen, also entweder Basissituationen oder relationale Situationen, jeweils mit der Lebensdauer  $d_1$  und  $d_2$ . Für  $d = d_1 \cap d_2$  lassen sich zusammengesetzte Situationen definieren durch

$$S(d) = S^1(d) \cup S^2(d) \text{ oder } S(d) = S^1(d) \cap S^2(d). \quad (3.8)$$

Die hier vorgestellten Definitionen decken sich mit dem Verständnis des in dieser Arbeit verwendeten Begriffs einer Situation für den Anwendungsbereich von Überwachungssystemen. Wie in [Ye12] wird in dieser Arbeit unter einer Interpretation verstanden, dass eine Situation  $S$  stets mit einer semantischen Aussage verknüpft ist. Auch die Tatsache, dass eine Situation durch

externe Anforderungen definiert wird, ist auf den Anwendungsfall der Überwachungssysteme übertragbar. Überwachungssysteme erfüllen stets einen bestimmten Zweck, nämlich die Überwachung eines bestimmten Gebietes. In diesem Gebiet bewegen sich Objekte, welche vom Anwender vorab definiert werden, also beispielsweise Schiffe in maritimen Systemen. Ebenfalls vom Anwender können relevante Situationen definiert werden. Situationen sind dann relevant, wenn deren Erkennung dem Zweck des Überwachungssystems dient. Dieser Ansatz wird auch als aufgabenorientiert bezeichnet, welcher im Gegensatz zum datengetriebenen Ansatz steht.

Wie in der Situationstheorie von Devlin in [Dev06] und der daraus entstandenen Ontologie von Kokar et al. in [Kok09] bilden die Wertausprägungen von Objektattributen, also die Objektzustände, und die Beziehungen zwischen diesen Objekten die Grundlage für die semantische Aussage. Die Beziehungen können dabei entweder zwischen unterschiedlichen Attributen desselben Objektes oder zwischen Attributen von unterschiedlichen Objekten bestehen. Die Attributwerte selbst können dabei aus Daten desselben Sensors, aus Daten von unterschiedlichen Sensoren oder aus fusionierten Sensordaten geschätzt werden.

Im folgenden Abschnitt wird die in dieser Arbeit verwendete formale Definition einer Situation vorgestellt, welche sich auf einen Zeitpunkt bezieht. Diese Modellierung erlaubt jedoch mit dem Ansatz aus [Jak07] eine direkte Erweiterung auf Zeitintervalle.

### 3.3.2. Formale Definition einer Situation

Eine Situation zum Zeitpunkt  $t$  ist immer mit einer externen semantischen Aussage verknüpft. Diese semantische Aussage betrifft einen Teil der realen Welt und ist dort entweder wahr oder falsch. Die semantische Aussage kann also als ein Fakt angesehen werden. Des Weiteren basiert die semantische Aussage auf einer zeitlichen Abfolge einer speziellen Konstellation der in der realen Welt vorhandenen Objekte bzw. deren Attribute. Die Objekte bzw. deren Attribute, welche für die semantische Aussage eine Rolle spielen, werden als *relevante Objekte* bzw. als *relevante Attribute* bezeichnet. Die Situation, welche mit der semantischen Aussage verknüpft ist, wird als *Situation von Interesse* bezeichnet. Eine Situation ist genau dann von Interesse, wenn deren Erkennung dem Zweck des Gesamtsystems dient.

Es sei  $\{O^1, O^2, \dots, O^m\}$  die Menge von Objekten, welche für die semantische Aussage relevant sind. Weiter sei  $\{X^{i,1}, X^{i,2}, \dots, X^{i,m_i}\}$  die Menge der relevan-



ten Attribute des Objektes  $O^i$ , mit  $i = 1, \dots, n$ . Formal lässt sich ein Objekt über seine Attribute definieren. Für ein relevantes Objekt  $O^i$  mit relevanten Attributen  $X^{i,1}, X^{i,2}, \dots, X^{i,m_i}$  ist also

$$O^i = \prod_{j=1}^{m_i} X^{i,j}. \quad (3.9)$$

**Definition 4** Der Zustandsraum einer Situation von Interesse  $S$  ist definiert als

$$\Omega_S := \prod_{i=1}^n O^i \times \mathbb{T} = \prod_{i=1}^n \prod_{j=1}^{m_i} X^{i,j} \times \mathbb{T}, \quad (3.10)$$

wobei mit  $\mathbb{T}$  die Zeitdimension bezeichnet wird. Dabei kann  $t \in \mathbb{T}$  entweder diskret oder kontinuierlich sein, es ist also entweder  $\mathbb{T} = \mathbb{N}$  oder  $\mathbb{T} = \mathbb{R}_0^+$ . Der Zustandsraum besitzt die Dimension  $\dim \Omega_S = 1 + \sum_{i=1}^n m_i$ .  $\square$

Der Zustandsraum ist nun die Basis für die Definition einer Situation [Fis13; Fis14b]. Anzumerken ist hier, dass der Zustandsraum von der jeweiligen Situation von Interesse abhängt, da unterschiedliche Situationen sich auf unterschiedliche Objekte und Attribute beziehen können.

**Definition 5** Eine Situation  $S_t$  zum Zeitpunkt  $t$  ist definiert als die Abbildung

$$S_t : \Omega_S \rightarrow \{0,1\}. \quad (3.11)$$

Die Menge  $\tilde{\Omega}_S \subseteq \Omega_S$  wird als Träger der Situation  $S_t$  bezeichnet, wenn gilt

$$S_t(\omega) = \begin{cases} 1, & \text{wenn } \omega \in \tilde{\Omega}_S, \\ 0, & \text{wenn } \omega \notin \tilde{\Omega}_S. \end{cases} \quad (3.12)$$

$\square$

Folgendes Beispiel zeigt eine einfache Situation von Interesse, welche in dieser Weise modelliert werden kann.

**Beispiel 6** Die semantische Aussage zur Situation von Interesse ist, dass zwei Objekte zum Zeitpunkt  $t$  nahe beieinander sind, deren euklidischer Abstand also kleiner als  $r$  ist. Für das Objekt  $A$  sind nun die Positionsattribute  $X^1$  und  $X^2$  relevant, für das Objekt  $B$  die Positionsattribute  $Y^1$  und  $Y^2$ . Der Zustandsraum ist also

$$\Omega_S := X^1 \times X^2 \times Y^1 \times Y^2 \times \mathbb{T}. \quad (3.13)$$

Der Träger der Situation  $S_t$  lässt sich dann beschreiben als

$$\tilde{\Omega}_S = \{\omega \in \Omega_S : \|x - y\| \leq r\}, \quad (3.14)$$

wobei  $x = (x^1, x^2)$ ,  $y = (y^1, y^2)$ ,  $\omega = (x, y, t)$  und  $x^1 \in X^1$ ,  $x^2 \in X^2$ ,  $y^1 \in Y^1$  und  $y^2 \in Y^2$  die Positionszustände zum Zeitpunkt  $t$  beschreiben.  $\square$

In Beispiel 6 wird die semantische Aussage über genau einen Zeitpunkt getroffen. Eine zeitliche Relation ist in dieser Situation nicht enthalten. Eine zeitliche Relation soll das folgende Beispiel verdeutlichen.

**Beispiel 7** Die semantische Aussage zur Situation von Interesse ist, dass zwei Objekte sich zum Zeitpunkt  $t$  annähern, sich also deren euklidischer Abstand zum vorherigen Zeitpunkt  $t - 1$  verringert hat. Für das Objekt  $A$  sind nun die Positionsattribute  $X^1$  und  $X^2$  relevant, für das Objekt  $B$  die Positionsattribute  $Y^1$  und  $Y^2$ . Der Zustandsraum ist also erneut

$$\Omega_S := X^1 \times Y^1 \times X^2 \times Y^2 \times \mathbb{T}. \quad (3.15)$$

Der Träger der Situation  $S_t$  lässt sich dann beschreiben als

$$\tilde{\Omega}_S = \{\omega \in \Omega_S : \|x_t - y_t\| \leq \|x_{t-1} - y_{t-1}\|\}, \quad (3.16)$$

wobei  $x_t = (x_t^1, x_t^2)$ ,  $y_t = (y_t^1, y_t^2)$ ,  $\omega = (x_t, y_t, t)$  und  $x_t^1 \in X^1$ ,  $x_t^2 \in X^2$ ,  $y_t^1 \in Y^1$  und  $y_t^2 \in Y^2$  die Positionszustände zum Zeitpunkt  $t$  beschreiben.  $\square$

Eine Erweiterung des Situationsbegriffs auf ein diskretes Zeitintervall liefert die folgende Definition.

**Definition 6** Es sei  $\Omega_S$  der Zustandsraum der Situation von Interesse  $S$ ,  $\omega_t \in \Omega_S$  eine Ausprägung zum Zeitpunkt  $t$ , und  $d = (t_1, \dots, t_k)$  ein diskretes Zeitintervall mit  $k$  Zeitschritten. Dann beschreibt  $\omega_d = (\omega_{t_1}, \dots, \omega_{t_k})$  eine Trajektorie durch den Zustandsraum  $\Omega_S$  über das Zeitintervall  $d$  hinweg.

Eine Situation  $S_d$  über ein Zeitintervall  $d$  ist dann definiert als die Abbildung

$$S_d : \prod_{i=1}^k \Omega_S \rightarrow \{0,1\}, \quad (3.17)$$

mit

$$S_d(\omega_d) := \begin{cases} 1, & \text{wenn } \forall i \in 1, \dots, k : S_{t_i}(\omega_{t_i}) = 1, \\ 0, & \text{sonst.} \end{cases} \quad (3.18)$$

$\square$

### 3.3.3. Existenzwahrscheinlichkeit einer Situation

Eine Situation von Interesse existiert in der realen Welt, wenn deren semantische Aussage wahr ist, und sie existiert nicht, wenn deren semantische Aussage falsch ist [Fis13; Fis14b]. Sie existiert also, wenn die durch Sensoren beobachteten Objekte den relevanten Objekten der semantischen Aussage zugeordnet werden können, und für deren Zustände  $\omega \in \tilde{\Omega}$  gilt. Im weiteren Verlauf der Arbeit gelten folgende Schreibweisen:

- S existiert:  $S = 1$  oder kurz  $S$ ,
- S existiert nicht:  $S = 0$  oder kurz  $\neg S$ .

Aufgrund der Annahme, dass die Sensorbeobachtungen unsicher oder veräuscht sind, ist jedoch kein eindeutiger Rückschluss auf die Existenz einer Situation möglich. Deshalb ist es sinnvoll, die Existenz von Situationen nicht als binäre wahr-falsch-Entscheidung zu treffen, sondern stattdessen die Wahrscheinlichkeit der Existenz zu ermitteln. Diese Existenzwahrscheinlichkeit kann als ein Maß interpretiert werden, wie gut die über die Zeit hinweg beobachteten Objekte und deren Attribute zum Träger der Situation von Interesse passen.

Dazu wird die Situation, also die Abbildung  $S_t : \Omega_S \rightarrow \{0,1\}$  als binäre Zufallsvariable interpretiert. Es sei also  $\Sigma_S$  eine Sigma-Algebra über  $\Omega_S$ , also eine Teilmenge der Potenzmenge von  $\Omega_S$ , und  $P$  ein Wahrscheinlichkeitsmaß auf  $(\Omega_S, \Sigma_S)$ . Damit ist  $(\Omega_S, \Sigma_S, P)$  ein Wahrscheinlichkeitsraum und  $P$  eine Verteilungsfunktion der Zufallsvariablen  $S_t$  mit

$$P(S_t = s) = P(\{\omega \in \Omega_S : S_t(\omega) = s\}), \quad (3.19)$$

wobei  $s \in \{0,1\}$ .

Die Existenzwahrscheinlichkeit einer Situation  $S_t$  ist demnach gegeben durch  $P(S_t = 1)$ , oder in vereinfachender Schreibweise  $P(S_t)$ , und es gilt

$$P(\neg S_t) = 1 - P(S_t). \quad (3.20)$$

Bei der Situationserkennung ist man also an der Bestimmung der Wahrscheinlichkeit  $P(S_t)$  interessiert. Diese Existenzwahrscheinlichkeit kann als eine DoB-Verteilung interpretiert werden, da nicht frequentistisch ermittelt wird, wie oft bei gegebenen Objektzuständen die Situation existiert. Vielmehr wird auf Basis von Expertenwissen die Existenzwahrscheinlichkeit bestimmt.

Aus dieser Wahrscheinlichkeit kann dann mittels geeignet gewählter Schwellwerte eine Schätzung für die Existenz einer Situation ausgegeben werden, wie beispielsweise durch vier Schwellwerte die Ergebnisse sehr unwahrscheinlich, unwahrscheinlich, neutral, wahrscheinlich, sehr wahrscheinlich. Durch diese Modellierung ist die Existenz einer Situation nur zu einem Zeitpunkt bestimmbar. Ihre Existenz im darauffolgenden Zeitpunkt muss dann erneut ermittelt werden [Fis13; Fis14b].

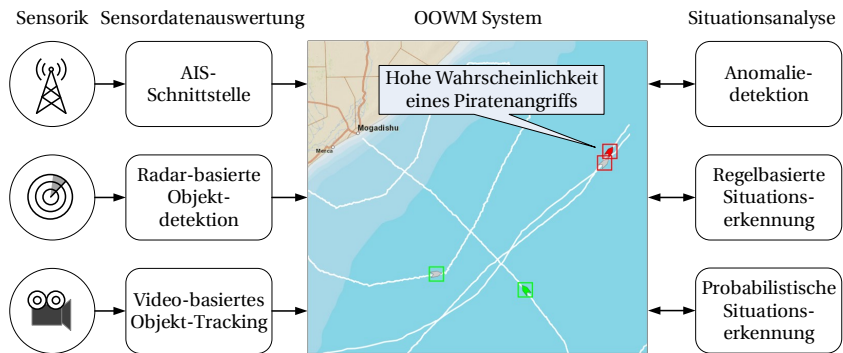
### 3.4. Modellierung weiterer Konzepte

Analog zu dem hier vorgestellten Objekt- und Situationskonzept können für die Umweltmodellierung noch weitere Konzepte definiert werden. In Zusammenhang mit der Situationserkennung wird oft die Erkennung von Ereignissen, Aktivitäten und Verhalten erwähnt. Innerhalb dieser Begriffe gibt es keine scharfe Abgrenzung, weshalb die einzelnen Begriffe teilweise für den selben Sachverhalt verwendet werden. Der Begriff des Ereignisses wird oft als eine Menge von Fakten modelliert, welche zu einem Zeitpunkt ausgewertet werden [Lam99; Tra08], oder auch als eine Zustandsänderung definiert [Dah09]. Dahingegen bezeichnen Aktivitäten und Verhalten meist Zustände von spezifischen Objekten (wie beispielsweise Personen oder Schiffen) über ein Zeitintervall hinweg [Kas07; Xia08; Bra08; Foo09; Cha12].

Eine scharfe Abgrenzung dieser Begriffe stellt eher ein philosophisches Problem dar und wird in dieser Arbeit daher nicht angegangen. Des Weiteren werden mit der hier vorgestellten Modellierung einer Situation sehr viele dieser Gegebenheiten abgedeckt, so dass von einer weiteren Eingrenzung von Begrifflichkeiten abgesehen werden kann.

### 3.5. Das objektorientierte Weltmodell

Als Repräsentationsplattform für detektierte Objekte und erkannte Situationen wird in dieser Arbeit das OOWM verwendet [Fis10b]. Dieses wurde bereits in Abschnitt 2.4.3 für die Videoüberwachung vorgestellt [Emt08; Bau09]. Das OOWM dient als Informationsdrehscheibe zwischen der Sensordatenauswertung und den Situationsanalysemodulen. Eine Visualisierung des OOWMs als Lagebild ist in Abbildung 3.4 skizziert.



**Abbildung 3.4.:** Darstellung des OOWMs als Lagebild inklusive Schnittstellen zur Sensordatenauswertung und Situationsanalyse (adaptiert aus [Fis10b]).

### 3.5.1. Funktionalitäten des OOWM

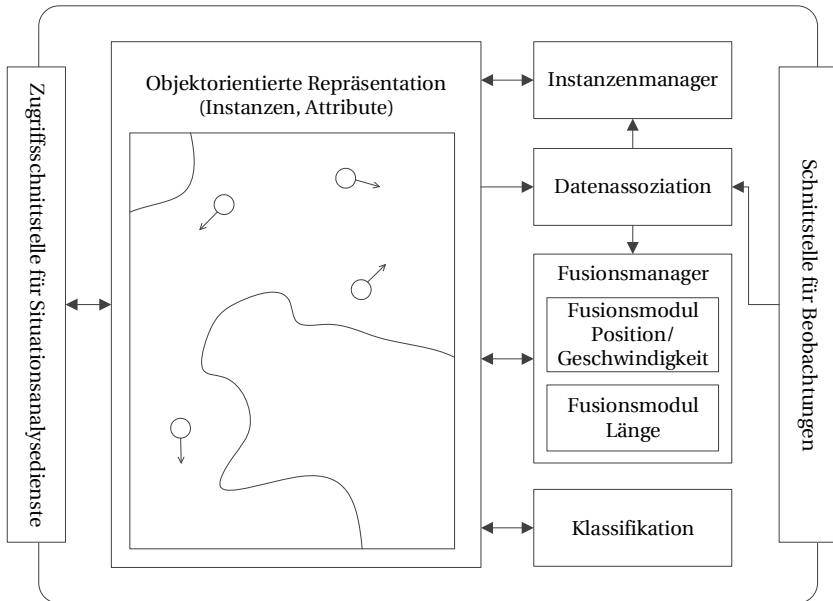
Die OOWM-Systemarchitektur bietet jedoch weit mehr als eine aggregierte Visualisierung von Objektbeobachtungen. Vielmehr bietet das OOWM folgende Funktionalitäten [Fis10b]:

- **Einheitliche Empfangsschnittstelle für Objektbeobachtungen:** Diese können in einer asynchronen Weise verarbeitet werden. Die asynchrone Verarbeitung ist deshalb wichtig, weil die Abtastrate der einzelnen Sensoren stark variieren kann.
- **Repräsentation und Verarbeitung von unsicherer Information:** Ursache für unsichere Informationen sind einerseits die Genauigkeit der Auswertelgorithmen, andererseits aber auch Falschdetektionen oder fehlende Detektionen. Durch eine probabilistische DoB-Modellierung der Objekte können diese Unsicherheiten berücksichtigt werden.
- **Management von Objektrepräsentanten:** Das Weltmodell entscheidet, wann aufgrund von Beobachtungen die Instanziierung von neuen Objekten oder die Entfernung von veralteten Objektinstanzen gerechtfertigt ist. Dies ist insbesondere nötig, weil sich im Überwachungsgebiet eine unbekannte Anzahl von Objekten befindet. Die Objektanzahl wird also kontinuierlich mitgeschätzt.

- **Einheitliche Zugriffsschnittstelle für Situationsanalyse Dienste:** Diese Dienste können sowohl synchron als auch asynchron auf den Inhalt des OOWM zugreifen und die Informationen auswerten.

### 3.5.2. Architektur des OOWM

In Abbildung 3.5 ist eine detailliertere Ansicht des OOWMs nach [Fis10b] skizziert, welche das Zusammenspiel der oben aufgelisteten Funktionalitäten verdeutlicht.



**Abbildung 3.5.:** Die Systemarchitektur des OOWM (adaptiert aus [Fis10b]).

Über die Schnittstelle für Beobachtungen nimmt das OOWM die von den Auswertelgorithmen erzeugten Objektbeobachtungen entgegen und leitet diese an die Datenassoziation weiter. Diese entscheidet anhand der Objektattribute, ob die Beobachtung einer schon existierenden Objektinstanz zugeordnet

werden kann. Sendet das Objekt wie in den AIS-Daten einen eindeutigen Identifikator (wie beispielsweise die IMO-Nummer) mit, so stellt die Zuordnung kein Problem dar. Sind in der Beobachtung jedoch nur Positionswerte vorhanden, so kann die Zuordnung nur über diese Attributwerte erfolgen. Im OOWM geschieht dies über einen Nächste-Nachbarn-Ansatz mit einem sogenannten Gating-Schwellwert. Dabei wird geprüft, welche Objektinstanzen innerhalb einer Gating-Umgebung liegen, und davon die euklidisch nächste ausgewählt. Befindet sich keine Objektinstanz innerhalb des Gating-Umgebung, so wird die Beobachtung an den Instanzenmanager weitergeleitet.

Wird die Beobachtung einer Objektinstanz zugeordnet, so greift der Fusionsmanager. Dieser fusioniert mittels verschiedener Fusionsmodule die neuen Informationen mit den schon bestehenden Informationen. Für jedes Objektattribut ist ein Fusionsmodul verantwortlich. Für die Fusion von Position und Geschwindigkeit kann ein Fusionsmodul verwendet werden. Im OOWM wird diese mit dem Kalman-Filter durchgeführt [Mit12]. Auch für statische Attribute gibt es Fusionsmodule, welche beispielsweise prüfen können, ob die alte und neue Information identisch sind.

Kann die Beobachtung keiner Objektinstanz zugeordnet werden, so prüft der Instanzenmanager, ob es sich um eine Falschdetektion handelt, oder ob ein neues Objekt in den Beobachtungsbereich eingedrungen ist. Dabei sammelt der Instanzenmanager mögliche Kandidaten für eine neue Objektinstanz über einige Zeitschritte hinweg. Können genügend Kandidaten für eine neue Objektinstanz innerhalb eines vorgegebenen Zeitintervalls gesammelt werden, so wird eine neue Objektinstanz erzeugt. Falls nicht, werden die gesammelten Kandidaten als Falschdetektionen verworfen. Zur Prüfung verwendet auch der Instanzenmanager den Nächste-Nachbarn-Ansatz mit einem Gating-Schwellwert. Der Instanzenmanager prüft außerdem die bestehenden Objektinstanzen und deren Alter. Wurde eine Objektinstanz schon seit längerer Zeit nicht mehr aktualisiert, so wird angenommen, dass diese sich aus dem Beobachtungsbereich entfernt hat und sie wird somit aus der Repräsentation gelöscht. Der Instanzenmanager gewährleistet also, dass die Repräsentation stets aktuell gehalten wird und dass keine falschen Objektinstanzen erzeugt werden.

Wird ein Objektattribut nicht als Beobachtungswert mitgeliefert, so kann dies mittels der anderen Attribute geschätzt werden. Dies wird mittels eines Klassifikationsmoduls durchgeführt. Dieses Modul kann anhand von vordefinierten Prototypen beispielsweise den Schiffstyp anhand der Länge, der Breite, oder der Geschwindigkeit des Schiffs bestimmen. Einsetzbar sind hier auch

wesentlich komplexere Klassifikationsalgorithmen, welche auf dem räumlich-zeitlichen Verhalten des Objektes basieren [Fal14].

Die Situationsanalyseedienste können über eine Schnittstelle auf die Objektrepräsentationen zugreifen. Diese Dienste können sich einerseits auf spezielle, asynchron auftretende Ereignisse abonnieren, z.B. wenn ein neues Objekt instanziiert wird, oder in synchroner Weise spezielle Informationen, wie z.B. die Position und Geschwindigkeit von Instanzen, anfragen.

Die Ergebnisse der Situationsanalyseedienste können in analoger Weise als Instanzen im OOWM repräsentiert werden. Beispielsweise kann abhängig von der Existenzwahrscheinlichkeit einer Situation von Interesse, diese vom Instanzenmanager instanziiert werden. Die Assoziation von zwei Situationen kann dabei über einen eindeutigen Identifikator durchgeführt werden. Dieser wird während der Situationserkennung bestimmt und bezeichnet dabei eine Situation von Interesse, welche über die selben Objekte ermittelt wurde.

### 3.6. Zusammenfassung

In diesem Kapitel wurde der Informationsfluss in Überwachungssystemen, wie er in dieser Arbeit verwendet wird, analysiert und vorgestellt. Weiter wurde auf die im weiteren verwendete Modellierung von Objekten eingegangen. Der wesentliche Betrag dieses Kapitels ist die Analyse des Situationsbegriffs bezüglich dessen Verwendung in bisherigen Veröffentlichungen sowie eine formale Definition einer Situation. Insbesondere wird eine Situation als binäre Zufallsvariable modelliert und deren Existenz in Form einer Wahrscheinlichkeitsverteilung repräsentiert. Als Repräsentationsform für Objekt- und Situationsinstanzen wurde das objektorientierte Weltmodell gewählt und dessen verwendete Architektur im Detail erläutert.



# 4

---

## Wissensbasierte Modellierung von Situationen

---

Ein Expertensystem besteht aus einer Wissensbasis und einer Inferenzmaschine [Cow99; Nea12]. In diesem Kapitel wird nun der Aufbau einer Wissensbasis für das Expertensystem beschrieben, während sich das darauffolgende Kapitel der Inferenzproblematik widmet. In diesem Kapitel wird zunächst erläutert, wie eine semantische Aussage formuliert wird. Weiter wird zwischen unterschiedlichen Situationstypen und unterschiedlichen Abhängigkeiten unterschieden. Als Wissensmodellierung selbst dient dann ein sogenanntes Situationsnetzwerk.

### 4.1. Die semantische Aussage

#### 4.1.1. Deduktion und Abduktion

In regelbasierten Systeme besteht die Wissensbasis aus logischen Ausdrücken in Form von Wenn-Dann-Formulierungen. Für Anwendungen in der Situationserkennung besitzen diese meist die folgende Form [Nil08; Tra08; Riv09; Roy10a; Kaz13]:

$$X^1 \wedge X^2 \wedge \dots \wedge X^n \Rightarrow S. \quad (4.1)$$

Ist das System im Einsatz, so wird deduktives logisches Schließen angewandt, um Inferenz zu betreiben. Deduktion bedeutet, dass aus der Regel  $X^1 \wedge X^2 \wedge \dots \wedge X^n \Rightarrow S$  und dem Fakt, dass  $X^1 \wedge X^2 \wedge \dots \wedge X^n$  wahr ist, die Wahrheit von  $S$  folgt [Kna06]. Diese Inferenzregel wird auch als Modus Ponens bezeichnet [Rus10]. Es werden also die Beobachtungen  $X^1 \wedge X^2 \wedge \dots \wedge X^n$  als Ursache, und die Situation  $S$  als Wirkung interpretiert. Situationen werden also genau dann inferiert, wenn bestimmte Beobachtungen gemacht werden.

Ein anderer Ansatz ist, die Situation als Ursache für die Beobachtungen zu interpretieren. Um die Existenz einer Situation anhand von Beobachtungen zu inferieren, wird die abduktive Schlussfolgerung angewandt, welche aus der Regel  $S \Rightarrow X^1 \wedge X^2 \wedge \dots \wedge X^n$  und dem Fakt, dass  $X^1 \wedge X^2 \wedge \dots \wedge X^n$  wahr ist, die Wahrheit von  $S$  folgert [Pau93; Bib93]. Die Abduktion schließt also von der Wirkung auf die Ursache und liefert somit eine Erklärung für die beobachteten Daten [Pau93; Bib93]. Eine weit verbreitete Anwendung findet die Abduktion beispielsweise in Diagnosesystemen [Pau93; Pea88; Nea12].

#### 4.1.2. Formalisierung der semantischen Aussage

In dieser Arbeit werden beide Mechanismen berücksichtigt. Bei der Interpretation der Situationsanalyse als abduktiver Prozess wird eine Situation als eine Erklärung für die beobachteten Daten interpretiert. Dies deckt sich auch mit dem Verständnis einer Situation in der Situationstheorie [Dev06], in der die Beobachtungen als Informationseinheiten, also Infons, angesehen werden und eine Situation als Erklärung für bestimmte Infons dient ( $S \models \sigma$ , siehe Abschnitt 3.3.1). Die Regeln zur Beschreibung einer Situation, bzw. zur Beschreibung derer semantischen Aussage, haben also folgende Form:

$$S \Rightarrow X^1 \wedge X^2 \wedge \dots \wedge X^n. \quad (4.2)$$

Die Regel in Gleichung (4.2) lässt sich auch in ihre einzelnen Beobachtungsanteile aufspalten:

$$\begin{aligned} S \Rightarrow (X^1 \wedge X^2 \wedge \dots \wedge X^n) &\Leftrightarrow \neg S \vee (X^1 \wedge X^2 \wedge \dots \wedge X^n) \\ &\Leftrightarrow (\neg S \vee X^1) \wedge (\neg S \vee X^2) \wedge \dots \wedge (\neg S \vee X^n) \quad (4.3) \\ &\Leftrightarrow (S \Rightarrow X^1) \wedge (S \Rightarrow X^2) \wedge \dots \wedge (S \Rightarrow X^n). \end{aligned}$$

Zusätzlich zur abduktiven Schlussfolgerung wird in dieser Arbeit noch ein spezieller deduktiver Regeltyp zugelassen. Dieser lässt zu, dass eine einzelne

Beobachtung als eine Erklärung für eine Situation dienen. Aus mehreren optionalen Erklärungen kann also direkt auf eine Situation geschlossen werden:

$$X^1 \vee X^2 \vee \dots \vee X^n \Rightarrow S. \quad (4.4)$$

Auch die Regel in Gleichung (4.4) lässt sich wieder in ihre einzelnen Beobachtungsanteile aufspalten:

$$\begin{aligned} X^1 \vee X^2 \vee \dots \vee X^n \Rightarrow S &\Leftrightarrow \neg(X^1 \vee X^2 \vee \dots \vee X^n) \vee S \\ &\Leftrightarrow (\neg X^1 \wedge \neg X^2 \wedge \dots \wedge \neg X^n) \vee S \\ &\Leftrightarrow (\neg X^1 \vee S) \wedge (\neg X^2 \vee S) \wedge \dots \wedge (\neg X^n \vee S) \\ &\Leftrightarrow (X^1 \Rightarrow S) \wedge (X^2 \Rightarrow S) \wedge \dots \wedge (X^n \Rightarrow S). \end{aligned} \quad (4.5)$$

Um die beiden Schlussfolgerungsmechanismen miteinander zu kombinieren, können beide Arten von Regeln mit einer Konjunktion verbunden werden:

$$(X^1 \vee X^2 \vee \dots \vee X^k \Rightarrow S) \wedge (S \Rightarrow X^{k+1} \wedge X^{k+2} \wedge \dots \wedge X^n). \quad (4.6)$$

Nach der Umformung erhält man also die folgende Regel als Formalisierung einer semantischen Aussage:

$$(X^1 \Rightarrow S) \wedge \dots \wedge (X^k \Rightarrow S) \wedge (S \Rightarrow X^{k+1}) \wedge \dots \wedge (S \Rightarrow X^n). \quad (4.7)$$

## 4.2. Wissensbasis einer Situation

### 4.2.1. Abstraktion von Situationen

Die Problematik bei der Beschreibung von Situationen besteht nun darin, dass diese in unterschiedliche Abstraktionsgrade eingeordnet werden können. In Abschnitt 3.3.2 wurde zwei Beispielsituationen beschrieben, deren Träger explizit modellierbar war (Beispiel 6 und Beispiel 7). Dies ist jedoch nicht immer möglich. Betrachtet man beispielsweise die Situation, dass ein Schiff ein Schmuggelboot ist, dann ist der Träger nicht mehr explizit modellierbar, die Situation besitzt also einen wesentlich höheren Abstraktionsgrad.

Semantische Aussagen mit einem höheren Abstraktionsgrad können beliebig komplex sein. Für die Formalisierung einer semantischen Aussage einer abstrakteren Situation können jedoch die folgenden beiden Annahmen getroffen werden:

- Die Existenz einer abstrakteren Situation  $S^a$  kann die Existenz einer weniger abstrakten Situation  $S^b$  implizieren:

$$S^a \Rightarrow S^b, \quad (4.8)$$

- Die Existenz einer weniger abstrakten Situation  $S^b$  kann zur Existenz einer abstrakteren Situation  $S^a$  führen:

$$S^b \Rightarrow S^a. \quad (4.9)$$

### 4.2.2. Elementare und abstrakte Situationen

Diese beiden Annahmen erlauben somit die beliebige hierarchische Gestaltung einer semantischen Aussage, und zwar unter Zuhilfenahme anderer Situationen. Um die Formalisierung der semantischen Aussage einer abstrakteren Situation weiter zu beschreiben, werden nun zwei unterschiedliche Situationstypen eingeführt, und zwar die sogenannte elementare Situation und die abstrakte Situation [Fis13; Fis14b].

**Definition 7** Eine *elementare Situation* ist eine Situation, deren Träger explizit modellierbar ist. Die Existenzwahrscheinlichkeit einer elementaren Situation  $S$  ist also gegeben durch die deterministische Abbildung

$$P(S) := \begin{cases} 1, & \text{wenn } S = 1, \\ 0, & \text{wenn } S = 0. \end{cases} \quad (4.10)$$

Eine *abstrakte Situation* ist eine Situation, deren Träger nicht explizit modellierbar ist und deren Existenz von der Existenz anderer (elementarer oder abstrakter) Situationen abhängt. Die Existenzwahrscheinlichkeit einer abstrakten Situation  $S$  ist also gegeben durch die Marginalverteilung

$$P(S) = \sum_{\substack{s^i \in \{0,1\}, \\ i=1,\dots,n}} P(S, S^1 = s^1, \dots, S^n = s^n), \quad (4.11)$$

wobei  $S^1, S^2, \dots, S^n$  entweder elementare oder wiederum abstrakte Situationen sein können.  $\square$

Mit der Definition der bedingten Wahrscheinlichkeit

$$P(S|S^1, S^2, \dots, S^n) = \frac{P(S, S^1, S^2, \dots, S^n)}{P(S^1, S^2, \dots, S^n)}, \quad (4.12)$$

lässt sich Gleichung (4.11) auch schreiben als [Pea88]

$$P(S) = \sum_{\substack{s^i \in \{0,1\}, \\ i=1,\dots,n}} P(S|S^1 = s^1, \dots, S^n = s^n) P(S^1 = s^1, \dots, S^n = s^n). \quad (4.13)$$

Zur Faktorisierung der Wahrscheinlichkeitsverteilung  $P(S^1, \dots, S^n)$  kann der Multiplikationssatz verwendet werden [Gör03], so dass insgesamt:

$$P(S) = \sum_{\substack{s^i \in \{0,1\}, \\ i=1,\dots,n}} P(S|S^1 = s^1, \dots, S^n = s^n) P(S^1 = s^1) \prod_{j=2}^n P(S^j = s^j | S^1 = s^1, \dots, S^{j-1} = s^{j-1}). \quad (4.14)$$

### 4.2.3. Die formalisierte semantische Aussage einer Situation

Die Zerlegung (4.14) zeigt, dass es für die Berechnung der Existenzwahrscheinlichkeit einer abstrakten Situation ausreichend ist, die bedingten Wahrscheinlichkeiten zu den abhängigen Situationen zu bestimmen. Dies sind genau die einzelnen Komponenten aus der Formalisierung von semantischen Aussagen (Gleichung (4.7)), also einzelne Komponenten der Form  $S^i \Rightarrow S^j$ , wobei  $S^i$  und  $S^j$  entweder elementare oder abstrakte Situationen sein können. Damit lässt sich nun die Formalisierung einer semantischen Aussage definieren.

**Definition 8** Eine *formalisierte semantische Aussage einer Situation von Interesse*  $F(S)$  ist definiert als ein logischer Ausdruck der Form


$$F(S) := (S^1 \Rightarrow S) \wedge \dots \wedge (S^k \Rightarrow S) \wedge (S \Rightarrow S^{k+1}) \wedge \dots \wedge (S \Rightarrow S^n), \quad (4.15)$$

wobei  $S^1, \dots, S^n$  entweder elementare oder abstrakte Situationen sind.  $\square$

**Beispiel 8** Eine Beispielskizze solcher Abhängigkeiten ist in Abbildung 4.1 dargestellt. Abbildung 4.1 ist also eine graphische Darstellung einer formalisierten semantischen Aussage zur Situation  $S$ , welche Abhängigkeiten zu den elementaren Situationen  $E^1, E^2$  und zu den abstrakten Situationen  $A^1, A^2$  besitzt. Die entsprechende formalisierte semantische Aussage der Situation  $S$  lässt sich also wie folgt schreiben:

$$F(S) := (E^1 \Rightarrow S) \wedge (S \Rightarrow E^2) \wedge (S \Rightarrow A^1) \wedge (S \Rightarrow A^2). \quad (4.16)$$

$\square$



**Abbildung 4.1.:** Graphische Darstellung einer semantischen Aussage zur Situation  $S$ .

#### 4.2.4. Wissensbasis einer Situation

Enthält die Formalisierung  $F(S)$  abstrakte Situationen, so können auch diese wiederum durch eine formalisierte semantische Aussage beschrieben werden.

**Definition 9** Eine *Wissensbasis*  $WB(S)$  zu einer Situation  $S$  ist definiert als eine Menge von formalisierten semantischen Aussagen. Die Wissensbasis enthält dabei die formalisierte semantische Aussage der Situation  $S$ , sowie in rekursiver Weise die formalisierten semantischen Aussagen aller abstrakter Situationen in  $F(S)$ .

Die Wissensbasis zur Situation  $S$  heißt *vollständig*, wenn sowohl  $S$  als auch jede auftretende abstrakte Situation in der Wissensbasis durch eine formalisierte semantische Aussage vertreten ist. Ist also  $\mathcal{A}$  die Menge aller in  $WB(S)$  auftretenden abstrakten Situationen, so ist eine Wissensbasis  $WB(S)$  genau dann vollständig, wenn Gleichungen (4.17) und (4.18) gelten:

$$F(S) \in WB(S), \quad (4.17)$$

$$\forall A^i \in \mathcal{A} : F(A^i) \in WB(S). \quad (4.18)$$

□

**Beispiel 9** In Abbildung 4.1 aus Beispiel 8 seien die beiden abstrakten Situationen  $A^1$  und  $A^2$  ebenfalls wieder durch eine Formalisierung einer semantischen Aussage beschrieben. Vervollständigt man diese hierarchische Vorgehensweise, so erhält man das in Abbildung 4.2 dargestellte Netzwerk. Das in Abbildung 4.2 dargestellte Netzwerk stellt eine vollständige Wissensbasis zur


Situation  $S$  dar. Es ist also  $WB(S) = \{F(S), F(A^1), F(A^2)\}$  und die vollständige Wissensbasis lässt sich beschreiben durch folgende semantische Aussagen:

$$F(S) := (E^1 \Rightarrow S) \wedge (S \Rightarrow E^2) \wedge (S \Rightarrow A^1) \wedge (S \Rightarrow A^2), \quad (4.19)$$

$$F(A^1) := (A^1 \Rightarrow E^3) \wedge (A^1 \Rightarrow E^4), \quad (4.20)$$

$$F(A^2) := (A^2 \Rightarrow E^4) \wedge (A^2 \Rightarrow E^5) \wedge (A^2 \Rightarrow E^6). \quad (4.21)$$

□



**Abbildung 4.2.:** Graphische Darstellung einer vollständigen Wissensbasis zur Situation  $S$ .

## 4.3. Abhängigkeiten zwischen Situationen

### 4.3.1. Notwendige und hinreichende Bedingungen

Die formalisierte semantischen Aussage einer Situation lässt sich wie in Gleichung (4.15) darstellen. Die Situation von Interesse wird also in einer Weise charakterisiert, als dass sie einerseits durch die Existenz von anderen Situationen erklärt wird, und andererseits auch die Existenz anderer Situationen erklärt. Diese beiden Arten von Abhängigkeiten lassen sich als notwendige und hinreichende Bedingungen unterscheiden [Fis13; Fis14b].

**Definition 10** Eine Situation  $S_{\text{suf}}$  ist eine *hinreichende Situation* für eine andere Situation  $S$  (Schreibweise  $S_{\text{suf}} \xrightarrow{S} S$ ), wenn aus der Existenz von  $S_{\text{suf}}$  die Existenz von  $S$  folgt, also

$$S_{\text{suf}} \Rightarrow S. \quad (4.22)$$

Gleichung (4.22) wird als *hinreichende Bedingung* bezeichnet. Für mehrere hinreichende Situationen  $S^1, \dots, S^n$  gilt dann

$$S^1 \vee \dots \vee S^n \Rightarrow S. \quad (4.23)$$

Eine Situation  $S_{\text{nec}}$  ist eine *notwendige Situation* für eine andere Situation  $S$  (Schreibweise  $S \xrightarrow{N} S_{\text{nec}}$ ), wenn aus der Existenz von  $S$  die Existenz von  $S_{\text{nec}}$  folgt, also

$$S \Rightarrow S_{\text{nec}}. \quad (4.24)$$

Gleichung (4.24) wird als *notwendige Bedingung* bezeichnet. Für mehrere notwendige Situationen  $S^1, \dots, S^n$  gilt dann

$$S \Rightarrow S^1 \wedge \dots \wedge S^n. \quad (4.25)$$

□

### 4.3.2. Bedeutung für die formalisierte semantische Aussage

Ist also  $F(S)$  eine formalisierte semantische Aussage der Situation  $S$  der Form

$$F(S) := (S^1 \Rightarrow S) \wedge \dots \wedge (S^k \Rightarrow S) \wedge (S \Rightarrow S^{k+1}) \wedge \dots \wedge (S \Rightarrow S^n), \quad (4.26)$$

wobei  $S^1, \dots, S^n$  entweder elementare oder abstrakte Situationen sind, dann sind

- $S^1, \dots, S^k$  hinreichende Situationen für die Situation  $S$ , und
- $S^{k+1}, \dots, S^n$  notwendige Situationen für die Situation  $S$ .

Hinreichende Situationen sind also Situationen, welche die Situation  $S$  erklären, und notwendige Situationen sind Situationen, welche sich durch  $S$  erklären lassen.



## 4.4. Situationsnetzwerk als Wissensmodellierung

### 4.4.1. Gemeinsame Wissensbasis mehrerer Situationen

Sind nun mehrere Wissensbasen von mehreren unterschiedlichen Situationen vorhanden, so lassen sich diese in eine gemeinsame Wissensbasis zusammenführen.

**Definition 11** Es seien  $WB(S^i)$  Wissensbasen von unterschiedlichen Situationen  $S^1, \dots, S^n$ . Dann heißt

$$WB(S^1, \dots, S^n) := \bigcup_{i=1}^n WB(S^i) \quad (4.27)$$

die *gemeinsame Wissensbasis von  $S^1, \dots, S^n$* . In der gemeinsamen Wissensbasis sind also keine Duplikate von formalisierten semantischen Aussagen vorhanden.

Die gemeinsame Wissensbasis  $WB(S^1, \dots, S^n)$  ist genau dann *vollständig*, wenn alle einzelnen Wissensbasen  $WB(S^1), \dots, WB(S^n)$  vollständig sind.  $\square$

**Beispiel 10** Die vollständige Wissensbasis  $WB(S^1)$  von  $S^1$  sei gegeben durch

$$F(S^1) := (E^1 \Rightarrow S^1) \wedge (S^1 \Rightarrow E^2) \wedge (S^1 \Rightarrow A^1) \wedge (S^1 \Rightarrow A^2), \quad (4.28)$$

$$F(A^1) := (A^1 \Rightarrow E^3) \wedge (A^1 \Rightarrow E^4), \quad (4.29)$$

$$F(A^2) := (A^2 \Rightarrow E^4) \wedge (A^2 \Rightarrow E^5) \wedge (A^2 \Rightarrow E^6). \quad (4.30)$$

Die vollständige Wissensbasis  $WB(S^2)$  von  $S^2$  sei gegeben durch

$$F(S^2) := (S^2 \Rightarrow A^2) \wedge (S^2 \Rightarrow E^7), \quad (4.31)$$

$$F(A^2) := (A^2 \Rightarrow E^4) \wedge (A^2 \Rightarrow E^5) \wedge (A^2 \Rightarrow E^6). \quad (4.32)$$

Die gemeinsame vollständige Wissensbasis  $WB(S^1, S^2)$  von  $S^1$  und  $S^2$  ist dann gegeben durch  $WB(S^1) \cup WB(S^2)$ :

$$F(S^1) := (E^1 \Rightarrow S^1) \wedge (S^1 \Rightarrow E^2) \wedge (S^1 \Rightarrow A^1) \wedge (S^1 \Rightarrow A^2), \quad (4.33)$$

$$F(S^2) := (S^2 \Rightarrow A^2) \wedge (S^2 \Rightarrow E^7), \quad (4.34)$$

$$F(A^1) := (A^1 \Rightarrow E^3) \wedge (A^1 \Rightarrow E^4), \quad (4.35)$$

$$F(A^2) := (A^2 \Rightarrow E^4) \wedge (A^2 \Rightarrow E^5) \wedge (A^2 \Rightarrow E^6). \quad (4.36)$$

$\square$

Die einzelnen formalisierten semantischen Aussagen einer gemeinsamen vollständigen Wissensbasis können als einzelne Situationsbeschreibungen interpretiert werden. Dieser Ansatz ist analog zum Ansatz der MEBN, welcher in Abschnitt 2.5.3 vorgestellt wurde. Dabei können einzelne formalisierte Situationsbeschreibungen als Fragmente, also als MFragments, und eine gemeinsame Wissensbasis als MEBN Theorie, also als MTheory, interpretiert werden. Ein wesentlicher Unterschied zum Ansatz der MEBN ist jedoch, dass MEBNs keine Modellierung von notwendigen Bedingungen zulassen. Sie erlauben also nicht, dass Beobachtungen durch eine Situation erklärt werden.

#### 4.4.2. Situationsnetzwerk

Eine gemeinsame vollständige Wissensbasis kann auch graphisch dargestellt werden und wird dann als Situationsnetzwerk bezeichnet.

**Definition 12** Ein *Situationsnetzwerk* (SN) ist eine Repräsentationsform einer gemeinsamen vollständigen Wissensbasis und ist definiert als ein gerichteter Graph, wobei elementare und abstrakte Situationen als Knoten repräsentiert werden und die notwendigen und hinreichenden Bedingungen als gerichtete Kanten. Die Richtung der Pfeile entspricht dabei der Richtung der Implikationspfeile von notwendigen und hinreichenden Bedingungen aus (4.22) und (4.24). Ein Situationsnetzwerk heißt *wohldefiniert*, wenn der Graph keine Zyklen besitzt. Die entsprechende Wissensbasis wird dann ebenfalls als wohldefiniert bezeichnet.  $\square$

**Beispiel 11** In Abbildung 4.3 ist das zugehörige Situationsnetzwerk aus Beispiel 10 visualisiert. Da das Situationsnetzwerk keine Zyklen besitzt, ist das SN selbst und damit auch die Wissensbasis  $WB(S^1, S^2)$  wohldefiniert.  $\square$


#### 4.4.3. Abstraktionslevel von Situationen

Ist ein SN wohldefiniert, so können den einzelnen Situationen Abstraktionslevel zugeordnet werden.

**Definition 13** Für elementare Situationen wird das Abstraktionslevel auf den Wert 0 gesetzt. Die Abstraktionslevel der abstrakten Situation lassen sich dann rekursiv berechnen durch

$$L(S^i) := 1 + \max \left\{ L(S^j) : (S^j \xrightarrow{S} S^i) \vee (S^i \xrightarrow{N} S^j) \right\}. \quad (4.37)$$

$\square$



**Abbildung 4.3.:** Situationsnetzwerk der gemeinsamen Wissensbasis  $WB(S^1, S^2)$  aus Beispiel 10.

Eine Vorgehensweise um die Abstraktionslevel aller Situationen in einem SN zu berechnen, ist in Algorithmus 1 dargestellt [Fis13; Fis14b].

---

#### Algorithmus 1 Berechnung von Abstraktionsleveln

---

**Eingabe:** Wohldefiniertes SN mit den Knoten  $\{S^1, \dots, S^n\}$

**Ausgabe:** Abstraktionslevel  $L(S^i)$  für alle  $S^i$  ( $i = 1, \dots, n$ )

- 1:  $S^0 := \{S^i : S^i \text{ ist elementare Situation}\};$
  - 2: **for all**  $S^i \in S^0$  **do**
  - 3:      $L(S^i) := 0;$
  - 4: **end for**
  - 5:  $\ell := 1$
  - 6:  $S^\ell := \{S^i : \exists S^j \in S^{\ell-1} \text{ mit } (S^j \xrightarrow{S} S^i) \vee (S^i \xrightarrow{N} S^j)\};$
  - 7: **while**  $S^\ell \neq \emptyset$  **do**
  - 8:     **for all**  $S^i \in S^\ell$  **do**
  - 9:          $L(S^i) := \ell;$
  - 10:     **end for**
  - 11:      $\ell := \ell + 1;$
  - 12:      $S^\ell := \{S^i : \exists S^j \in S^{\ell-1} \text{ mit } (S^j \xrightarrow{S} S^i) \vee (S^i \xrightarrow{N} S^j)\};$
  - 13: **end while**
-

**Beispiel 12** Für das Situationsnetzwerk in Abbildung 4.3 sind die einzelnen Ergebnisse des Algorithmus 1 wie folgt:

1.  $S^0 = \{E^1, E^2, E^3, E^4, E^5, E^6, E^7\}$ ,
2.  $L(E^1) = L(E^2) = L(E^3) = L(E^4) = L(E^5) = L(E^6) = L(E^7) = 0$ ,
3.  $S^1 = \{S^1, S^2, A^1, A^2\}$ ,
4.  $L(S^1) = L(S^2) = L(A^1) = L(A^2) = 1$ ,
5.  $S^2 = \{S^1, S^2\}$ ,
6.  $L(S^1) = L(S^2) = 2$ ,
7.  $S^3 = \emptyset$ .

In Abbildung 4.3 sind also die einzelnen Situationen im Situationsnetzwerk so visualisiert, dass Situationen gleichen Abstraktionslevels auf einer horizontalen Ebene liegen. □

Die Rechnung aus Beispiel 12 zeigt insbesondere, dass der Algorithmus teilweise die schon gesetzten Abstraktionslevel überschreibt und die Situationen damit quasi noch ein Level höher schiebt. Mit der Berechnung der Abstraktionslevel aus Algorithmus 1 gilt also immer

$$S^i \xrightarrow{S} S^j \Rightarrow L(S^i) < L(S^j), \quad (4.38)$$

und

$$S^i \xrightarrow{N} S^j \Rightarrow L(S^i) > L(S^j). \quad (4.39)$$

## 4.5. Zusammenfassung

In diesem Kapitel wurde zunächst identifiziert, welche Form eine formalisierte semantische Aussage einer Situation sinnvollerweise besitzen soll. Darauf aufbauend wurden die beiden Typen der elementaren und abstrakten Situation und die formalisierte semantische Aussage einer Situation definiert. Weiter wurde eine vollständige Wissensbasis als Menge von formalisierten semantischen Aussagen definiert. Abhängigkeiten zwischen Situationen wurden als notwendige und hinreichende Bedingungen charakterisiert.

---

Basierend auf den vorhergehenden Definitionen wurde ein Situationsnetzwerk als graphische Repräsentationsform einer gemeinsamen vollständigen Wissensbasis definiert. Der Graph besteht aus Knoten, welche die Situationen repräsentieren, und aus gerichteten Kanten, welche die Abhängigkeiten repräsentieren. Ein wohldefiniertes SN besitzt keine Zyklen. Das Situationsnetzwerk erlaubt die Berechnung eines Abstraktionslevels für jeden Knoten bzw. jede Situation.



# 5

---

## Situationsanalyse

---

Dieses Kapitel beschäftigt sich mit der Situationsanalyse und insbesondere mit der Situationserkennung, also dem Inferenzprozess, wie aus beobachteten Objekten und deren Attributen die Existenz von Situationen abgeleitet werden kann. Dazu wird zunächst das Gesamtkonzept zur Situationsanalyse beschrieben. Weiter wird speziell darauf eingegangen, wie aus einem Situationsnetzwerk ein probabilistisches Modell erstellt wird, ein sogenanntes situationsspezifisches DBN. Dieses situationsspezifische DBN kann dann für die Berechnung der Existenzwahrscheinlichkeit eingesetzt werden.

### 5.1. Gesamtkonzept der Situationsanalyse

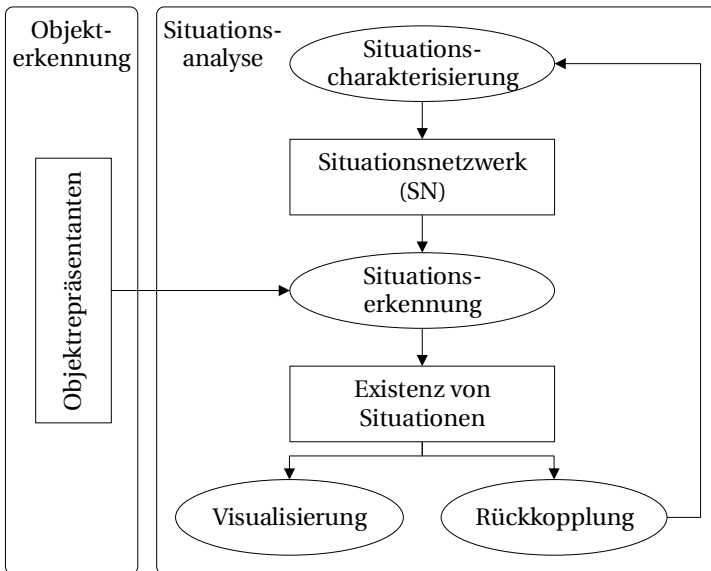
Roy definiert in [Roy01] die Situationsanalyse wie folgt:

»Die Situationsanalyse ist ein Prozess, welcher eine Situation, ihre Elemente und ihre Relationen überprüft, um ein Produkt, nämlich das Situationsbewusstsein, für einen Entscheidungsträger bereitzustellen und zu verwalten<sup>58</sup>.«

---

<sup>58</sup> Eigene Übersetzung. Original: »...we define situation analysis as: a process, the examination of a situation, its elements, and their relations, to provide and maintain a product, i.e., a state of situation Awareness, for the decision maker.«

Auch in dieser Arbeit wird die Situationsanalyse als Prozess interpretiert. Dieser umfasst jedoch mehr als nur die Erkennung von Situationen an sich, sondern auch den Prozess der Zerlegung von Situationen in ihre Elemente und Relationen, sowie Prozesse, welche das Situationsbewusstsein unterstützen. Der Prozess der Situationsanalyse setzt sich also aus mehreren Teilprozessen zusammen, nämlich der Charakterisierung, der Erkennung, der Visualisierung und der Rückkopplung [Fis11b; Fis13]. Deren Zusammenspiel ist in Abbildung 5.1 illustriert und wird im Folgenden erläutert.



**Abbildung 5.1.:** Der Gesamtprozess der Situationsanalyse. Informationsaggregate sind als Rechtecke, Teilprozesse als Ellipsen visualisiert.



### 5.1.1. Objekterkennung

Der Prozess der Objekterkennung dient dem Erzeugen von Objektrepräsentanten im objektorientierten Weltmodell. Wird ein Objekt mit einem Sensor beobachtet, so werden in der anschließenden Auswertung dessen Attributwerte extrahiert und dessen Objektklasse ermittelt. Mit dem entsprechend hinterlegten Objektkonzept (siehe Abschnitt 3.2) wird ein Repräsentant im Weltmodell erzeugt, welcher den ermittelten Objektzustand besitzt. Durch Inferenzprozesse können die Attributwerte dieses Repräsentanten mit dem vorhergehenden Zustand des selben Objektes fusioniert werden, um eine verbesserte Zustandsschätzung zu erhalten. Über diese Repräsentation lässt sich auch die Historie eines Objektes, also dessen vergangene Zustände, rekonstruieren. Außerdem lassen sich nicht beobachtete Attributwerte ermitteln, wie beispielsweise die Geschwindigkeit aus den Positionswerten der vergangenen Zustände und des aktuellen Zustands.

### 5.1.2. Situationscharakterisierung

Bei der Charakterisierung von Situationen wird das Expertenwissen als Wissensbasis formuliert, es werden also relevante Situationen von einem Experten als Situationsnetzwerk modelliert. Aufgrund der semantischen Abhängigkeiten von Situationen müssen die Beziehungen zwischen Situationen modelliert werden. Insbesondere ist wichtig, dass die dazugehörige gemeinsame Wissensbasis vollständig und wohldefiniert sein muss.

Das generelle Vorgehen zur Erstellung einer gemeinsamen Wissensbasis ist in Algorithmus 2 vorgestellt. Dabei geht man so vor, dass zunächst aufgabenorientiert die relevanten Situationen identifiziert werden. Für jede dieser Situationen identifiziert man abhängige Situationen, falls diese keine elementare Situation ist. Weiter muss bestimmt werden, ob diese abhängigen Situationen von der relevanten Situation erklärt werden oder ob diese sie erklären, also ob eine notwendige oder eine hinreichende Bedingung vorliegt. Iterativ werden nun alle verwendeten Situationen modelliert und die formalisierten semantischen Aussagen dazu formuliert. Aus diesen formalisierten semantischen Aussagen bilden sich dann die Wissensbasen der einzelnen Situationen und insgesamt die gemeinsame Wissensbasis. Durch die iterative Vorgehensweise ist die so erstellte gemeinsame Wissensbasis vollständig.

---

**Algorithmus 2** Vorgehen zur Erstellung einer gemeinsamen Wissensbasis
 

---

**Eingabe:** Menge von relevanten Situationen  $\mathcal{S} := \{S^1, \dots, S^n\}$

**Ausgabe:** Gemeinsame vollständige Wissensbasis  $WB(S^1, \dots, S^n)$

```


1:  $WB(S^1, \dots, S^n) := \emptyset$ ;
2: while  $\mathcal{S} \neq \emptyset$  do
3:   for all  $S^i \in \mathcal{S}$  do
4:     if  $S^i$  elementare Situation then
5:       Modelliere den Träger zu  $S^i$ ;
6:        $\mathcal{S} := \mathcal{S} \setminus S^i$ ;
7:     else
8:       Identifiziere abhängige Situationen  $\mathcal{D} = \{S^{i_1}, \dots, S^{i_k}\}$ ;
9:        $F(S^i) = \text{TRUE}$ ;
10:      for all  $(S^i, S^j) \in \mathcal{D} \times \mathcal{S}$  do
11:        if  $S^j$  notwendige Situation für  $S^i$  then
12:           $F(S^i) := F(S^i) \wedge (S^i \Rightarrow S^j)$ ;
13:        else if  $S^j$  hinreichende Situation für  $S^i$  then
14:           $F(S^i) := F(S^i) \wedge (S^j \Rightarrow S^i)$ ;
15:        end if
16:      end for
17:       $WB(S^i) := \{F(S^i)\}$ ;
18:       $WB(S^1, \dots, S^n) := WB(S^1, \dots, S^n) \cup WB(S^i)$ 
19:       $\mathcal{S} := \{\mathcal{S} \setminus S^i\} \cup \{S^{i_1}, \dots, S^{i_k}\}$ ;
20:    end if
21:  end for
22: end while

```

---

Basierend auf der so modellierten gemeinsamen Wissensbasis kann ein Situationsnetzwerk als graphische Repräsentationsform generiert werden. Das Situationsnetzwerk wird dann auf Zyklen hin geprüft. Werden Zyklen identifiziert, so muss an der entsprechenden Stelle nachmodelliert werden. Ist das Situationsnetzwerk zyklensfrei, so ist die Wissensbasis wohldefiniert und es können mit Algorithmus 1 die Abstraktionsebenen der einzelnen Situationen bestimmt werden.

**Beispiel 13** Ein einfaches Beispiel eines Situationsnetzwerks zur Situation, dass ein Schiff ein Schmuggelboot ist, ist in Abbildung 5.2 dargestellt. Die Situation von Interesse ist also, dass ein Schiff ein Schmuggelboot ist. Dies ist keine elementare Situation. Folglich muss sie von anderen Situationen abhängig sein.



**Abbildung 5.2.:** Vereinfachtes Beispiel eines SNs. Elementare Situationen werden als Rechtecke dargestellt, abstrakte Situationen als Rechtecke mit abgerundeten Kanten.

Eine abhängige Situation ist, dass das Schiff in einem Schmuggelgebiet war. War das Schiff in einem Schmuggelgebiet, dann ist es wahrscheinlich, dass das Schiff ein Schmuggelboot ist. Diese Schmuggelgebiet-Situation wird also als eine Erklärung für ein Schmuggelboot modelliert, also als hinreichende Situation. Außerdem ist die Schmuggelgebiet-Situation eine elementare Situation. Der Träger kann beispielsweise so modelliert werden, dass mindestens eine vergangene Position des Schiffes innerhalb eines Zeitfensters in einem Schmuggelgebiet, also einem Polygon liegt. Eine weitere abhängige Situation ist, dass das Schiff kein AIS-Signal sendet, sich also nicht identifiziert. Ist das Schiff ein Schmuggelboot, dann ist es sehr wahrscheinlich, dass es kein AIS-Signal sendet. Die Modellierung ist also so, dass das Schmuggelboot die AIS-Situation erklärt. Die AIS-Situation ist also eine notwendige Situation. Außerdem ist die AIS-Situation eine elementare Situation. Der Träger kann beispielsweise so modelliert werden, dass geprüft wird, ob das Objektattribut MMSI einen Wert besitzt. Das Situationsnetzwerk ist vollständig und wohldefiniert. Die Situation von Interesse besitzt das Abstraktionslevel 1, die beiden elementaren Situationen das Abstraktionslevel 0. □

### 5.1.3. Situationserkennung

Der Teilprozess der Situationserkennung analysiert die Objektrepräsentationen über die Zeit hinweg hinsichtlich der Existenz von Situationen von Interesse. Dazu verwendet die Situationserkennung das in der Charakterisierung modellierte Situationsnetzwerk. Das Ziel der Situationserkennung ist also, für jede Situation von Interesse eine Existenzwahrscheinlichkeit über die Zeit hinweg zu berechnen.

Sei nun  $S$  die Situation von Interesse. Um die Existenzwahrscheinlichkeit  $P(S)$  zu berechnen, müssen die Abhängigkeiten zu den anderen Situationen berücksichtigt werden. Die Existenzwahrscheinlichkeit von  $S$  lässt sich berechnen durch die in Gleichung (4.11) bzw. Gleichung (4.14) angegebenen Formeln, also der Marginalverteilung von  $S$ . Außerdem sind nur die elementaren Situationen der Wissensbasis  $WB(S)$  beobachtbar, das heißt die elementaren Situationen stellen die Evidenzvariablen dar.

Die Marginalverteilung wird also mit einem probabilistischen Modell berechnet, und zwar einem dynamischen Bayes'schem Netz. Dazu wird bezüglich einer Situation von Interesse jeweils ein situationspezifisches DBN (SSDBN) erstellt. Diese Vorgehensweise ist zu vergleichen mit dem Ansatz der MEBNs (siehe Abschnitt 2.5.3, [Las08]). Dort wird aus einer MTheory, also aus einer Wissensbasis, bezüglich einer Situation von Interesse ein situationspezifisches BN (SSBN) erstellt. Analog zum MEBN-Ansatz wird das hier erstellte probabilistische Modell auch als situationspezifisch bezeichnet. Die Generierung eines solchen Modells, basierend auf einem modellierten Situationsnetzwerk, ist ein wesentlicher Beitrag dieser Arbeit und wird in den folgenden Abschnitten 5.3, 5.4 und 5.5 erläutert.

Insbesondere ermöglicht es das SSDBN, die Marginalverteilung einer Situation  $S$  zum Zeitpunkt  $t$  berechnen, und zwar indem die Evidenzvariablen mittels der Objektzustände über die Zeit hinweg berechnet und in das Modell eingespeist werden. Da sich im beobachteten Gebiet unter Umständen sehr viele Objekte befinden können, muss das SSDBN mehrmals angewendet werden. Bezieht sich der Zustandsraum der Situation von Interesse (siehe Gleichung (3.10)) auf genau ein Objekt, so muss das SSDBN also jeweils einmal für jede Objektinstanz ausgeführt werden. Bezieht er sich auf zwei Objekte, so muss das SSDBN für jedes mögliche Objektpaar ausgeführt werden. Ist also  $k$  die Anzahl der repräsentierten Objektinstanzen und der Zustandsraum der Situation bezieht sich auf  $r$  Objekte, so muss das SSDBN  $\binom{k}{r}$  mal

ausgeführt werden. Einschränken lässt sich diese Anzahl, indem vorher die entsprechende Objektklasse berücksichtigt wird.

#### 5.1.4. Visualisierung

Die Visualisierung der Situationserkennung in der dynamischen Lagedarstellung ist ein essentieller Baustein zur Unterstützung des Situationsbewusstseins [End95b], denn Sie erlaubt eine zeitnahe Beurteilung der Lage durch den Experten und somit auch das Treffen zeitnaher Entscheidungen. Die Visualisierung von Situationen kann dabei auf deren Existenzwahrscheinlichkeit basieren. Aus der berechneten Existenzwahrscheinlichkeit einer Situation kann deren Existenz abgeleitet werden, wenn ein gewisser Schwellwert überschritten wird, und diese dann visualisiert werden. Wie in Abschnitt 3.3.3 erwähnt, können auch mehrere Schwellwerte eingesetzt werden. Bei der Wahl von beispielsweise zwei Schwellwerten kann ein ampelbasiertes Farbschema für die Visualisierung gewählt werden: grün für unwahrscheinlich, gelb für neutral, und rot für wahrscheinlich. Die Situationen können in der dynamischen Darstellung des OOWMs als Kästchen um die involvierten Objekte visualisiert werden, wie in Abbildung 3.4 dargestellt. Zusätzlich kann in einer Bedienoberfläche noch die tatsächlich berechnete Existenzwahrscheinlichkeit der Situationen mit ausgegeben werden.

Die Wahl der Schwellwerte ist nicht pauschal zu beantworten. Einerseits hängt die Wahl von der Aufgabe des Systems ab, andererseits auch von der Anzahl der beobachteten Objekte. Sind die Situationen von Interesse beispielsweise sicherheitskritisch, so möchte der Operator auch schon bei einer geringen Existenzwahrscheinlichkeit informiert werden. Bewegen sich jedoch sehr viele Objekte in dem beobachteten Gebiet, so wird bei einem zu gering gewählten Schwellwert der Operator mit Fehlalarmen überflutet.

Um eine optimale Unterstützung des Situationsbewusstseins zu gewährleisten, ist es in jedem Fall sinnvoll, die Justierung der Schwellwerte dem Operator zu überlassen. Die Untersuchung geeigneter Visualisierungstechniken für die Situationserkennung würde in einer Messung des Situationsbewusstseins resultieren, mit den in Abschnitt 2.1.2 beschriebenen Methoden. Eine umfassende Analyse würde jedoch den Rahmen dieser Arbeit sprengen, weshalb in dieser Arbeit abschließend eine Benutzerstudie durchgeführt wurde, um die Arbeitsbeanspruchung nach der NASA TLX-Methode zu messen (siehe Kapitel 6).

### 5.1.5. Rückkopplung

Die Situationsanalyse ist insgesamt als ein interaktiver Prozess zu betrachten. Ein wesentlicher Grund dafür ist, dass sich die Situationen von Interesse ändern oder neue hinzukommen, und somit die Wissensbasis aktualisiert werden muss. Dies wird durch einen Rückkopplungsprozess gewährleistet. Die Rückkopplung ist also ein Prozess, welcher den Benutzer des Systems explizit mit einbezieht.

Diese Rückkopplung kann beispielsweise auf die berechneten Existenzwahrscheinlichkeiten zugreifen und Statistiken berechnen, wie oft die einzelnen Situationen von Interesse innerhalb eines Zeitfensters erkannt wurden. Basierend auf diesen Statistiken können dem Experten Hinweise gegeben werden, ob eine Situation sehr selten aufgetreten ist und eventuell aus der Wissensbasis zu entfernen ist. Die Rückkopplung kann auch Lernverfahren nutzen, um einerseits oft auftretende Zusammenhänge in den Daten zu erkennen oder andererseits auch Anomalien in den Daten zu identifizieren und dem Experten neue Situationen vorschlagen.

## 5.2. Das situationspezifische DBN

### 5.2.1. Motivation zur Nutzung eines SSDBN

Um die Marginalverteilung der Situation  $S$  zu berechnen, bietet sich die Methode der Bayes'schen Netze an. Ein Bayes'sches Netz entspricht in diesem Fall der Wahrscheinlichkeitsverteilung über die vollständige Wissensbasis  $WB(S)$ , also der gemeinsamen Wahrscheinlichkeitsverteilung von  $S, S^1, \dots, S^n$ , wenn dies alle in  $WB(S)$  vorkommenden Situationen sind. Ein Bayes'sches Netz ist genau dafür konzipiert, solche Schlussfolgerungen zu berechnen.

Da anzunehmen ist, dass die Sensorbeobachtungen generell verrauscht sind, muss das probabilistische Model in der Lage sein, diese zu kompensieren. Verrauschte Sensorbeobachtungen resultieren einerseits in falschen, andererseits auch in fehlenden Objektzuständen. Zur Kompensation solcher verrauschten Objektzustände ist es sinnvoll, den Prozess der Situationserkennung mit einer Trägheit zu versehen. Die Trägheit soll also folgende Aussagen unterstützen:

- Bei der Beobachtung eines Gebietes über eine bestimmte Zeit hinweg sollte eine einzige Beobachtung, welche für die Existenz einer Situation von Interesse spricht, nicht zur Erkennung der Situation führen, da es sich höchstwahrscheinlich um eine verrauschte Beobachtung handelt.
- Existiert eine Situation von Interesse im Zeitschritt zuvor, dann existiert sie höchstwahrscheinlich auch im aktuellen Zeitschritt, auch wenn eine aktuelle Beobachtung dagegen spricht.

Um diese Trägheit zu gewährleisten, muss das Bayes'sche Netz mit zeitlichen Abhängigkeiten versehen werden, das heißt mit gerichteten Kanten über Zeitscheiben hinweg. Dies entspricht genau der Definition eines dynamischen Bayes'schen Netzes. Das situationsspezifische DBN ist also ein probabilistisches Modell, genauer gesagt ein dynamisches Bayes'sches Netz, mit welchem sich die Marginalverteilung einer Situation  $S$  zum Zeitpunkt  $t$  berechnen lässt.

Ist nun SSDBN ein DBN über die Zufallsvariablen  $S_t^1, \dots, S_t^n$  für  $t = 0, \dots, T$ , dann repräsentiert das SSDBN also die gemeinsame Wahrscheinlichkeitsverteilung

$$P(S_{0:T}^{1:n}) = \prod_{t=0}^T \prod_{i=1}^n P(S_t^i | Pa(S_t^i)). \quad (5.1)$$

Aufgrund der Abhängigkeiten zwischen elementaren und abstrakten Situationen und der Tatsache, dass Evidenzen nur durch die elementaren Situationen in das Netz gelangen, lässt sich die gemeinsame Wahrscheinlichkeitsverteilung auch zeitlich rekursiv schreiben. Dabei wird die Annahme getroffen, dass die Zustände nur von den Zuständen im vorherigen Zeitschritt abhängen (die sogenannte Markov-Annahme), und dass die aktuellen Beobachtungen bedingt unabhängig von den vergangenen Beobachtungen sind. Sei nun  $\mathcal{E} = \{E^1, E^2, \dots\}$  die Menge der elementaren Situationen und  $\mathcal{A} = \{A^1, A^2, \dots\}$  die Menge der abstrakten Situationen. Dann ist die rekursive Schreibweise gegeben durch

$$P(\mathcal{A}_{0:T}, \mathcal{E}_{1:T}) = P(\mathcal{A}_0) \cdot \prod_{t=1}^T P(\mathcal{A}_t | \mathcal{A}_{t-1}) P(\mathcal{E}_t | \mathcal{A}_t). \quad (5.2)$$

**Definition 14** Es sei  $WB(S)$  eine vollständige und wohldefinierte Wissensbasis der Situation  $S$  und  $\mathcal{S} = \{S, S^1, \dots, S^n\}$  die Menge aller Situationen in  $WB(S)$ . Ein *situationsspezifisches dynamisches Bayes'sches Netzwerk* zu einer Situation  $S$  ist definiert als ein DBN mit den Knoten  $S_t, S_t^1, \dots, S_t^n$ , sowie den Kanten, welche die Abhängigkeiten des entsprechenden Situationsnetzwerkes repräsentieren. Damit ist das SSDBN in der Lage, die Existenzwahrscheinlichkeit einer Situation  $S$ , also die Marginalverteilung  $P(S)$ , über die Zeit hinweg zu berechnen.  $\square$

Um ein solches probabilistisches Modell für die Inferenz zu nutzen, muss es vollständig definiert sein. Nach [Cow99] bedeutet dies:

- Die Variablen des SSDBN müssen identifiziert werden. Dies ist bereits durch den Charakterisierungsprozess aus Abschnitt 5.1.2 abgedeckt.
- Die strukturellen Abhängigkeiten zwischen den Variablen müssen identifiziert werden. Auch diese sind bereits durch den Charakterisierungsprozess abgedeckt. Wie genau die Struktur des SSDBN basierend auf einem Situationsnetzwerk generiert wird, wird in Abschnitt 5.3 erläutert.
- Die bedingten Wahrscheinlichkeiten, also die CPDs müssen bestimmt werden. Die Generierung von CPDs basierend auf Vorwissen und Expertenwissen wird in Abschnitt 5.5 erläutert.

### 5.2.2. Möglichkeiten der Inferenz im SSDBN

Für eine Situation von Interesse  $S$  sei nun  $WB(S)$  die vollständige und wohldefinierte Wissensbasis und  $\mathbf{e}$  die Menge der beobachteten Evidenzen, also  $\mathbf{e} = \{e^1, e^2, \dots\}$ , mit  $E^1 = e^1, E^2 = e^2, \dots$

Die Existenz der Situation  $S$  bei gegebenen Beobachtungen  $\mathbf{e}$  entspricht nun der Marginalverteilung von  $S$  bei gegebenen Evidenzen  $\mathbf{e}$ , also der Wahrscheinlichkeit  $P(S|\mathbf{e})$ . Das Ziel der Inferenz ist also die Berechnung der bedingten Wahrscheinlichkeit  $P(S|\mathbf{e})$ . Dies ist das Herzstück der Bayes'schen Inferenz und lässt sich mit der Bayes'schen Formel [Pea88] umformen zu

$$P(S|\mathbf{e}) = \frac{P(\mathbf{e}|S)P(S)}{P(\mathbf{e})}. \quad (5.3)$$



Da  $S$  nun nicht zwingend direkt von Variablen aus  $\mathcal{E}$  abhängig ist, sondern von weiteren abstrakten Situationen aus  $\mathcal{A}$ , lässt sich  $P(\mathbf{e}|S)$  in Gleichung (5.3) zerlegen zu [Pea88]

$$P(\mathbf{e}|S) = \sum_{A^i \in \mathcal{A} \setminus S} P(\mathbf{e}|A^i, S)P(A^i|S). \quad (5.4)$$

Betrachtet man nun diese Inferenz über eine Zeitspanne hinweg, so ergeben sich mehrere Möglichkeiten der Inferenzberechnung, welche im Folgenden vorgestellt werden (nach [Mur02] und [Sär13]).

### Filterung

Die Filterung berechnet die Existenzwahrscheinlichkeit der Situation  $S$  zum aktuellen Zeitpunkt  $t$ , basierend auf den über die Zeit hinweg gesammelten Evidenzen  $\mathbf{e}_1, \dots, \mathbf{e}_t$ . Diese lässt sich in rekursiver Weise berechnen [Mur02]:

$$P(S_t|\mathbf{e}_{1:t}) \propto P(\mathbf{e}_t|S_t, \mathbf{e}_{1:t-1})P(S_t|\mathbf{e}_{1:t-1}) \quad (5.5)$$

$$= P(\mathbf{e}_t|S_t)P(S_t|\mathbf{e}_{1:t-1}) \quad (5.6)$$

$$= P(\mathbf{e}_t|S_t) \sum_{S_{t-1} \in \{0,1\}} P(S_t|S_{t-1})P(S_{t-1}|\mathbf{e}_{1:t-1}). \quad (5.7)$$

Dabei entspricht die Proportionalitätskonstante  $1/P(\mathbf{e}_t|\mathbf{e}_{1:t-1})$ . Im Schritt von (5.5) zu (5.6) wird angenommen, dass die aktuellen Beobachtungen  $\mathbf{e}_t$  bedingt unabhängig von den vergangenen Beobachtungen  $\mathbf{e}_{1:t-1}$  bei gegebener aktueller Situation  $S_t$  sind. Im Schritt von (5.6) zu (5.7) wird angenommen, dass die Situation  $S_t$  nur vom direkt vorhergehenden Zustand der Situation  $S_{t-1}$  abhängt (Markov-Annahme), dass also gilt [Mur02]

$$P(S_t|S_{1:t-1}) = P(S_t|S_{t-1}). \quad (5.8)$$

Die Rekursivität der Filterung entsteht dadurch, dass der letzte Term in (5.7) genau wieder dem Filterungsergebnis aus dem Zeitschritt davor entspricht.

## Glättung

Die Glättung berechnet die Existenzwahrscheinlichkeit der Situation  $S$  zu einem vergangenen Zeitpunkt  $k$  ( $k < t$ ), basierend auf den über die Zeit hinweg gesammelten Evidenzen  $\mathbf{e}_1, \dots, \mathbf{e}_t$ . Sie lässt sich rückwärts rekursiv berechnen (Herleitung siehe [Sär13]):

$$P(S_k | \mathbf{e}_{1:t}) = \sum_{S_{k+1}=\{0,1\}} P(S_k, S_{k+1} | \mathbf{e}_{1:t}) \quad (5.9)$$

$$= P(S_k | \mathbf{e}_{1:k}) \sum_{S_{k+1}=\{0,1\}} \frac{P(S_{k+1} | S_k) P(S_{k+1} | \mathbf{e}_{1:t})}{P(S_{k+1} | \mathbf{e}_{1:k})}. \quad (5.10)$$

Über das Filterergebnis  $P(S_t | \mathbf{e}_{1:t})$  und den Term  $P(S_{k+1} | \mathbf{e}_{1:t})$  in (5.10) lässt sich also das Glättungsergebnis für jedes  $k < t$  rückwärts rekursiv berechnen.

## Prädiktion

Die Prädiktion berechnet die Existenzwahrscheinlichkeit der Situation  $S$  zu einem zukünftigen Zeitpunkt  $k$  ( $k > t$ ), basierend auf den über die Zeit hinweg gesammelten Evidenzen  $\mathbf{e}_1, \dots, \mathbf{e}_t$ .

$$P(S_k | \mathbf{e}_{1:t}) = \sum_{S_{k-1}=\{0,1\}} P(S_k, S_{k-1} | \mathbf{e}_{1:t}) \quad (5.11)$$

$$= \sum_{S_{k-1}=\{0,1\}} P(S_k | S_{k-1}) P(S_{k-1} | \mathbf{e}_{1:t}). \quad (5.12)$$

Über das Filterergebnis  $P(S_t | \mathbf{e}_{1:t})$  und den Term  $P(S_{k-1} | \mathbf{e}_{1:t})$  in (5.12) lässt sich das Prädiktionsergebnis für jedes  $k > t$  rekursiv berechnen.

## Wahrscheinlichste Erklärung

Die wahrscheinlichste Erklärung berechnet die wahrscheinlichste Folge von Situationszuständen  $S_{1:t}$ , welche die Beobachtungen  $\mathbf{e}_1, \dots, \mathbf{e}_t$  erzeugt hat. Sie ist also definiert als

$$S_{1:t}^* := \operatorname{argmax}_{S_{1:t}} P(S_{1:t} | \mathbf{e}_{1:t}). \quad (5.13)$$

Diese wahrscheinlichste Folge von Situationszuständen lässt sich in rekursiver Weise berechnen durch

$$S_k^* = \operatorname{argmax}_{S_k} P(S_{k+1} | S_k) \delta_k(S_k), \quad (5.14)$$

wobei

$$\delta_k(S_k) := \max_{S_{1:k-1}} P(S_{1:k-1}, S_k | \mathbf{e}_{1:t}). \quad (5.15)$$

Auch  $\delta_k(S_k)$  lässt sich rekursiv berechnen durch

$$\delta_k(S_k) = P(\mathbf{e}_k | S_k) \max_{S_{k-1}} P(S_k | S_{k-1}) \delta_{k-1}(S_{k-1}). \quad (5.16)$$

### 5.2.3. Algorithmen zur Inferenzberechnung

Zur Berechnung dieser möglichen Inferenzergebnisse gibt es eine Menge von Algorithmen, die teilweise exakte, aber auch approximative Lösungen bereitstellen. Generell ist die exakte Inferenz in Bayes'schen Netzen NP-Hart [Coo90]. Hier soll nur eine Übersicht über die wichtigsten Algorithmen gegeben werden. Für Details wird auf die angegebenen Quellen verwiesen.

#### Der Forward-Algorithmus

Der Forward-Algorithmus ist dafür ausgelegt, das Filterergebnis  $P(S_t | \mathbf{e}_{1:t})$  exakt zu berechnen. Außerdem kann er dafür verwendet werden, das Prädiktionsergebnis  $P(S_k | \mathbf{e}_{1:t})$  für ein  $k > t$  zu berechnen. Durch die Markov-Annahmen arbeitet er in einer rekursiven Weise. Somit ist seine Laufzeit und sein Speicherbedarf in jedem Zeitschritt konstant. Insgesamt beträgt sein Zeitaufwand  $O(K^2 T)$  und sein Speicheraufwand  $O(K^2)$ , wobei  $K$  die Anzahl der Zustände ist, welche ein Knoten annehmen kann, und  $T$  die Anzahl der Zeitschritte ist [Kol09].

#### Der Forward-Backward-Algorithmus

Der Forward-Backward-Algorithmus berechnet für ein  $k < t$  das Glättungsergebnis  $P(S_k | \mathbf{e}_{1:t})$ . Er ist für HMMs ausgelegt, kann jedoch auf beliebige DBNs angewendet werden, indem dieses in ein HMM umgewandelt wird [Mur02]. Da in einem HMM jedoch pro Zeitscheibe nur eine versteckte und eine beobachtbare Variable erlaubt ist, werden bei komplexen DBNs mit vielen Knoten die CPTs extrem umfangreich. Der Forward-Backward-Algorithmus ist daher für komplexe DBNs nicht zu empfehlen.

Der Forward-Backward-Algorithmus besteht aus zwei Teilen. Im ersten Schritt wird im sogenannten Forward-Pass das Filterergebnis  $P(S_t|\mathbf{e}_{1:t})$  berechnet. Im zweiten Schritt wird im sogenannten Backward-Pass dann rekursiv der Wert  $P(\mathbf{e}_{k+1:t}|S_k)$  berechnet, um dann insgesamt das Glättungsergebnis für ein  $k < t$  zu bestimmen [Mur02]

$$P(S_k|\mathbf{e}_{1:t}) = P(S_k|\mathbf{e}_{1:k}, \mathbf{e}_{k+1:t}) \quad (5.17)$$

$$= \frac{1}{P(\mathbf{e}_{1:t})} P(\mathbf{e}_{k+1:t}|S_k, \mathbf{e}_{1:k}) P(S_k, \mathbf{e}_{1:k}) \quad (5.18)$$

$$= \frac{1}{P(\mathbf{e}_{1:t})} P(\mathbf{e}_{k+1:t}|S_k) P(S_k|\mathbf{e}_{1:k}). \quad (5.19)$$

Der Zeitaufwand für den Forward-Backward-Algorithmus beträgt  $O(K^2T)$  und der Speicheraufwand beträgt  $O(KT)$  [Mur02; Kol09].

### Der Frontier-Algorithmus

Der Frontier Algorithmus erweitert den Forward-Backward-Algorithmus, indem er für beliebige DBNs anwendbar ist. Auch im Frontier-Algorithmus wird ein Forward-Pass und ein Backward-Pass durchgeführt. Dabei wird mit einer Menge gearbeitet, der sogenannten Frontier-Menge, welche die Menge der Knoten während der einzelnen Durchläufe in vergangene und zukünftige Knoten unterteilen, also d-separiert. Die Frontiermenge enthält dabei alle versteckten Knoten [Mur02]. Der Zeitaufwand und der Speicheraufwand für den Frontier-Algorithmus beträgt  $O(TDK^{D+2})$ , wobei  $D$  für die Anzahl der versteckten Zustände steht [Mur02].

### Der Interface-Algorithmus

Der Interface-Algorithmus ist eine Optimierung des Frontier-Algorithmus. Er minimiert dabei die Anzahl der Knoten, welche in die Frontier-Menge aufgenommen wird. So werden beim Interface-Algorithmus nicht alle versteckten Knoten in die Frontier-Menge mit aufgenommen, sondern nur diejenigen, welche eine ausgehende Kante zur nächsten Zeitscheibe besitzen. Diese Menge wird als Interface bezeichnet [Mur02]. Durch diese Optimierung liegt die Komplexität des Algorithmus bei  $O(K^ID)$ , wobei mit  $I$  die Anzahl der Knoten im Interface bezeichnet wird [Mur02].

## Der Viterbi-Algorithmus

Der Viterbi-Algorithmus berechnet die wahrscheinlichste Erklärung zu einer Folge von Beobachtungen. Er geht dabei wie in Abschnitt 5.2.2 beschrieben in rekursiver Weise vor. Wie beim Forward-Algorithmus ist sein Speicher- und Zeitaufwand linear in  $T$ .

## Der Partikelfilter

Der Partikelfilter ist ein stochastisches Verfahren, welches ein approximatives Ergebnis für die Filterung ergibt. Die Grundidee des Partikelfilters besteht darin, das Filterergebnis durch eine gewichtete Summe von Stichproben zu approximieren [Mur02]

$$P(S_t | \mathbf{e}_{1:t}) \approx \sum_{i=1}^M w_t^{(i)} \delta(S_t, S_t^{(i)}), \quad (5.20)$$

wobei mit  $S_t^{(i)}$  die  $i$ -te Stichprobe von  $S_t$ , mit  $M$  die Anzahl der Stichproben, und mit  $w_t^{(i)}$  das Gewicht der  $i$ -ten Stichprobe bezeichnet wird.  $\delta$  bezeichnet die Dirac-Funktion, sie ist also gleich Eins, wenn ihre beiden Argumente identisch sind und ansonsten Null.

Der Partikelfilter geht dabei wie folgt vor [Rus10]: Initial erzeugt er zunächst  $M$  Stichproben mit der A-priori-Verteilung  $P(S_0)$ . Für jeden Zeitschritt werden die Stichproben basierend auf der Übergangswahrscheinlichkeit  $P(S_t | S_{t-1})$  propagiert. Jeder Stichprobe wird dabei ein Gewicht zugeordnet, welches der Likelihood der neuen Beobachtung entspricht, also  $P(\mathbf{e}_{t-1} | S_{t-1})$ . Schließlich wird aus diesen gewichteten Stichproben eine neue Population von Stichproben erzeugt. Dabei ist die Wahrscheinlichkeit, dass eine Stichprobe für die neue Population ausgewählt wird, proportional zu ihrem Gewicht. Insbesondere kann eine Stichprobe für die neue Population auch mehrmals ausgewählt werden und Stichproben mit einem geringen Gewicht verlieren an Bedeutung. Für das Generieren von Stichproben wird generell das sogenannte Importance Sampling verwendet. Der Partikelfilter für DBNs wird dann auch als Sequentielles Importance Sampling bezeichnet [Mur02]. Ein entscheidender Faktor bei der Laufzeit des Partikelfilters ist die Anzahl der erzeugten Stichproben.

### Der Rao-Blackwellised Partikelfilter

Um dieses Problem zu adressieren, kann der Rao-Blackwellised Partikelfilter eingesetzt werden. Dabei wird der Partikelfilter nur auf eine Teilmenge der Zustandsvariablen angewendet und für die restlichen Variablen eine exakte Inferenzberechnung verwendet. Dadurch werden mit weniger Partikeln ähnlich gute Ergebnisse erzielt als nur mit dem Partikelfilter [Rus10]. Voraussetzung für eine effizientere Berechnung ist natürlich, dass die exakte Inferenz nicht mehr Zeit benötigt als der Mehraufwand für mehr Stichproben [Mur02].

## 5.3. Generierung der SSDBN Struktur

Sei nun SN das Situationsnetzwerk der vollständigen und wohldefinierten gemeinsamen Wissensbasis  $WB(S^1, \dots, S^n)$ . Um die Inferenzmethoden aus Abschnitt 5.2.2 einzusetzen, werden aus der Wissensbasis für Situationen von Interesse situationsspezifische dynamische Bayes'schen Netze (SSDBN) erzeugt. In diesem Abschnitt wird nun die Generierung der Struktur eines solchen SSDBN vorgestellt [Fis13; Fis14b]. Da das SSDBN ein DBN ist, muss die Struktur des SSDBN die folgenden Annahmen erfüllen [Dor10]:

- die Eltern eines Knotens dürfen nur in der selben Zeitscheibe oder in der Zeitscheibe davor sein (entspricht der Markov-Annahme),
- (zeitliche) Kanten zwischen zwei Zeitscheiben sind im Sinne der zeitlichen Entwicklung nur von vergangenen zu zukünftigen Knoten erlaubt,
- die Struktur des Netzes hat innerhalb einer Zeitscheibe die Struktur eines BN, d.h. es sind keine Zyklen erlaubt,
- die Struktur ändert sich nicht über die Zeit, sie ist also für alle Zeitscheiben identisch und insbesondere unabhängig vom Zeitpunkt  $t$ .

Die Wissensbasis  $WB(S^1, \dots, S^n)$  kann mitunter sehr umfangreich sein und viele Situationen von Interesse beinhalten. In diesem Ansatz wird jedoch zu jeder Situation von Interesse genau ein SSDBN erstellt, daher auch die Bezeichnung situationsspezifisch. Der Operator wählt also aus der Wissensbasis bzw. dem SN eine Situation von Interesse aus. Basierend auf der Auswahl wird das SSDBN erstellt, und zwar so, dass nur die Knoten verwendet werden, welche der Situationsbeschreibung dienen. Die Generierung der SSDBN-Struktur basierend auf dem SN ist in Algorithmus 3 beschrieben.

**Algorithmus 3** Algorithmus zur Erstellung der Struktur eines SSDBN**Eingabe:** SN über  $WB(S^1, \dots, S^n)$ , Situation von Interesse  $S \in \{S^1, \dots, S^n\}$ **Ausgabe:** Struktur des SSDBN von  $S$  als  $(B_0, 2TBN)$ 


---

```


1: Füge  $S$  als  $S_t$  dem  $2TBN$ , und als  $S_0$  dem  $B_0$  hinzu;
2:  $\ell := 0$ ;
3:  $\mathcal{S}^\ell := \{S\}$ ;
4:  $\mathcal{A} := \{S\}$ ;
5: while  $\mathcal{S}^\ell \neq \emptyset$  do
6:    $\ell := \ell + 1$ ;
7:   for all  $S^i \in \mathcal{S}^{\ell-1}$  do
8:      $\mathcal{S}_{\text{suf}}^\ell := \{S^j : (S^j \xrightarrow{S} S^i)\}$ ;
9:     for all  $S^j \in \mathcal{S}_{\text{suf}}^\ell$  do
10:      Füge  $S^j$  dem  $2TBN$  als  $S_t^j$ , und als  $S_0^j$  dem  $B_0$  hinzu;
11:      Füge dem  $2TBN$  Kante  $S_t^j \rightarrow S_t^i$  und dem  $B_0$  Kante  $S_0^j \rightarrow S_0^i$  hinzu;
12:    end for
13:     $\mathcal{S}_{\text{nec}}^\ell := \{S^j : (S^i \xrightarrow{N} S^j)\}$ ;
14:    for all  $S^j \in \mathcal{S}_{\text{nec}}^\ell$  do
15:      Füge  $S^j$  dem  $2TBN$  als  $S_t^j$ , und als  $S_0^j$  dem  $B_0$  hinzu;
16:      Füge dem  $2TBN$  Kante  $S_t^i \rightarrow S_t^j$  und dem  $B_0$  Kante  $S_0^i \rightarrow S_0^j$  hinzu;
17:    end for
18:     $\mathcal{S}^\ell := \mathcal{S}_{\text{suf}}^\ell \cup \mathcal{S}_{\text{nec}}^\ell$ 
19:    for all  $S^j \in \mathcal{S}^\ell$  do
20:      if  $S^j$  abstrakte Situation then
21:         $\mathcal{A} = \mathcal{A} \cup S^j$ ;
22:      end if
23:    end for
24:  end while
25: for all  $S^j \in \mathcal{A}$  do
26:   Füge  $S^j$  dem  $2TBN$  als  $S_{t-1}^j$  hinzu;
27:   Füge dem  $2TBN$  Kante  $S_{t-1}^i \rightarrow S_t^j$  hinzu;
28: end for

```

---

Der Algorithmus generiert eine DBN-Struktur, definiert durch die beiden Netze  $B_0$  und  $2TBN$ . Der Algorithmus verwendet für die Struktur innerhalb einer Zeitscheibe des  $2TBN$ s genau eine Teilstruktur des SNs. Dabei werden in rekursiver Weise Knoten hinzugefügt, welche eine Abstraktionsebene niedriger sind und mit der Situation eine direkte Abhängigkeit besitzen. Die Initiale Netzstruktur  $B_0$  wird identisch gewählt. Der Zeitscheibe  $t-1$  des  $2TBN$  werden alle Situationen hinzugefügt, welche ursprünglich abstrakt waren. Zwischen diesen abstrakten Situationen wird abschließend noch eine zeitliche Kante eingefügt, um die gewünschte Trägheit im Prozess abbilden zu können.

**Beispiel 14** Betrachtet man das Situationsnetzwerk aus Abbildung 4.3 in Beispiel 11 und wählt die Situation  $S^1$  als Situation von Interesse aus, so erhält man das in Abbildung 5.3 abgebildete  $2TBN$  als SSDBN-Komponente. Das nicht dargestellte Netz  $B_0$  weist dabei die selbe Struktur auf wie das Teilnetz innerhalb der Zeitscheibe  $t$ .



**Abbildung 5.3.:**  $2TBN$  für die Situation von Interesse  $S^1$  aus Beispiel 11. Zeitliche Kanten sind als gestrichelte Linien dargestellt.

Insgesamt wird durch die Auswahl einer Situation von Interesse  $S^1$  aus einer vollständigen und wohldefinierten Wissensbasis  $WB(S^1, \dots, S^n)$  nur die Information aus der vollständigen und wohldefinierten Wissensbasis  $WB(S^1)$  verwendet. Daher ist das SSDBN zur Situation  $S^1$  mit zugrundeliegender Wissensbasis  $WB(S^1, \dots, S^n)$  identisch mit dem SSDBN der Situation  $S^1$  mit zugrundeliegender Wissensbasis  $WB(S^1)$ .  $\square$



## 5.4. Methoden zur Spezifizierung der Parameter

Die Parameter des SSDBN, also die einzelnen CPTs pro Knoten, bestimmen maßgeblich das Verhalten des SSDBN. Eine zentrale Voraussetzung für DBNs ist, dass sich die Parameter über die Zeit hinweg nicht ändern [Dor10]. Die CPTs sind also unabhängig von  $t$ . Die Größe der CPTs ist abhängig von der Anzahl der Zustände des Knoten, von der Anzahl der Elternknoten und von der Anzahl der Zustände der Elternknoten.

### 5.4.1. Anzahl der zu bestimmenden Parameter

Ist  $S$  ein Knoten im DBN und  $Pa(S) = \{S^1, \dots, S^k\}$ , so ist die Anzahl der Einträge in der CPT von  $S$  gegeben durch

$$|CPT(S)| = |S| \cdot |S^1| \cdot |S^2| \cdots |S^k|, \quad (5.21)$$

wobei mit  $|\cdot|$  jeweils die Anzahl der Einträge bzw. der Zustände bezeichnet wird. Davon sind jedoch nur  $(|S| - 1) \cdot |S^1| \cdot |S^2| \cdots |S^k|$  zu spezifizieren, da sich die Summe der bedingten Wahrscheinlichkeiten von  $S$  für jede mögliche Ausprägung der Elternzustände zu Eins summieren muss. Sind sowohl  $S$  als auch die Elternknoten  $S^1, \dots, S^k$  binäre Zufallsvariablen, so ergibt sich die Anzahl der CPT-Einträge zu

$$|CPT(S)| = 2 \cdot 2^k = 2^{k+1}, \quad (5.22)$$

und die Anzahl der zu spezifizierenden Zustände beträgt  $2^k$  [Kol09].

### 5.4.2. Expertenbefragungen

Eine Möglichkeit, diese  $2^k$  Einträge einer CPT pro Knoten zu bestimmen ist, diese durch Befragungen zu ermitteln [Foo09]. Dabei muss für jeden Knoten und für jeden der zu spezifizierenden Zustände eine Frage beantwortet werden. Diese Fragen haben beispielsweise folgende Form: »Wie hoch ist die Wahrscheinlichkeit, dass  $A$  auftritt, wenn man annimmt dass  $B$  eingetreten ist und  $C$  nicht eingetreten ist?« Die Problematik bei solchen Befragungen ist einerseits, dass unter Umständen sehr viele Fragen zu beantworten sind, vor allem wenn die Knoten mehr als zwei Zustände besitzen, und andererseits,

dass die Fragestellungen sehr komplex formuliert sind, so dass sie oft nicht intuitiv zu beantworten sind.

### 5.4.3. Gewichtete CPT-Berechnung

Eine weitere Möglichkeit um die Parameter zu spezifizieren stellt Fenz in [Fen12] vor. Für einen Knoten  $S$  mit den Elternknoten  $S^1, \dots, S^k$  ordnet er jeder Kante ein Gewicht  $w_i$  ( $i = 1, \dots, k$ ) zu, wobei die Summe der Gewichte eines Elternknotens Eins ergeben muss, es gilt also

$$\sum_{i=1}^k w_i = 1. \quad (5.23)$$

Die Gewichte entsprechen dabei den einzelnen Einflüssen der Elternknoten und können durch Experten bestimmt werden. Die zu spezifizierenden bedingten Wahrscheinlichkeiten werden dann berechnet durch

$$P(S|S^1 = s^1, \dots, S^k = s^k) = \sum_{i=1}^k w_i s^i, \quad (5.24)$$

wobei  $s^i$  entweder dem Wert 0 oder dem Wert 1 entspricht. Fenz stellt unter anderem auch eine Verallgemeinerung für die Verwendung von mehr als zwei Zuständen vor, also nicht nur eingeschränkt auf binäre Variablen.

Dieser Ansatz von [Fen12] wurde auch in [Fis13] angewandt. Gilt für alle  $i = 1, \dots, k$ , dass  $s^i = 1$ , so ist  $P(S|S^1 = 1, \dots, S^k = 1) = 1$ . Dies ist jedoch nicht wünschenswert, da in realen Anwendungen oft eine Restwahrscheinlichkeit  $r$  bleibt, dass die Situation  $S$  trotzdem nicht existiert, obwohl alle Evidenzen dafür sprechen, dass also mit  $r < 1$  gilt

$$P(S|S^1 = 1, \dots, S^k = 1) = 1 - r. \quad (5.25)$$

In [Fis13] wurde aus diesem Grund die gewichtete CPT-Berechnung modifiziert, indem das Gesamtintervall  $[0, 1]$  auf das Intervall  $[r, 1 - r]$ , für  $r \in [0, 1/2]$  gestaucht wurde. Dies resultiert in der folgenden CPT-Berechnung

$$P(S|S^1 = s^1, \dots, S^k = s^k) = (1 - 2r) \left( \sum_{i=1}^k w_i s^i \right) + r. \quad (5.26)$$

#### 5.4.4. Noisy-Or-Modell

Beim Noisy-Or-Modell wird angenommen, dass der gemeinsame Einfluss der Elternknoten von  $S$  dem kombinierten Einfluss der einzelnen Elternknoten entspricht. Das bedeutet also, dass jeder Elternknoten den Knoten  $S$  unabhängig beeinflusst. Das Noisy-Or-Modell gehört damit zu den sogenannten ICI-Modellen (engl.: »Independence of Causal Influence«) [Kol09].

Das Noisy-Or-Modell ist definiert durch  $k+1$  Parameter  $\lambda_0, \lambda_1, \dots, \lambda_k$ , welche durch Experten definiert werden können. Dabei entsprechen  $\lambda_1, \dots, \lambda_k$  den einzelnen Einflüssen, also  $\lambda_i = P(S = 1 | S^i = 1)$ .  $\lambda_0$  ist der sogenannte Leak-Parameter, er entspricht der Wahrscheinlichkeit der Fehlentscheidung, also  $\lambda_0 = P(S = 1 | S^1 = 0, \dots, S^k = 0)$ . Insgesamt lässt sich die CPT berechnen durch

$$P(S = 0 | S^1 = s^1, \dots, S^k = s^k) = (1 - \lambda_0) \prod_{i=1}^k (1 - \lambda_i)^{s^i}, \quad (5.27)$$


und

$$P(S = 1 | S^1 = s^1, \dots, S^k = s^k) = 1 - \left[ (1 - \lambda_0) \prod_{i=1}^k (1 - \lambda_i)^{s^i} \right]. \quad (5.28)$$

#### 5.4.5. Generalisiertes lineares Modell

Ein generalisiertes lineares Modell (GLM) stellt ein weiteres ICI-Modell dar [Kol09]. Dabei wird der gemeinsame Einfluss der Elternknoten als lineare Funktion der Form  $f(S^1, \dots, S^k) = \sum_{i=1}^k w_i S^i$  modelliert. Wie bei der gewichteten CPT-Berechnung fließt das Expertenwissen über die Gewichte  $w_i$  ein. Weiter wird angenommen, dass die Wahrscheinlichkeit von  $S$  in der Weise von den Eltern  $S^1, \dots, S^k$  abhängt, dass mit hoher Wahrscheinlichkeit  $S = 1$  gilt, wenn  $f(S^1, \dots, S^k)$  größer als ein Schwellwert  $\tau$  ist, und mit hoher Wahrscheinlichkeit  $S = 0$  gilt, wenn  $f(S^1, \dots, S^k)$  kleiner als der Schwellwert  $\tau$  ist. Ersetzt man  $\tau$  durch  $-w_0$ , so erhält man  $f(S^1, \dots, S^k) = w_0 + \sum_{i=1}^k w_i S^i$ . Für die Modellierung, wie die Wahrscheinlichkeit von  $S = 1$  von  $f(S^1, \dots, S^k)$  abhängt, wird am häufigsten die in Abbildung 5.4 dargestellte Sigmoidfunktion verwendet

$$\text{sig}(z) = \frac{e^z}{1 + e^z} = \frac{1}{1 + e^{-z}}. \quad (5.29)$$



**Abbildung 5.4.:** Die Sigmoidfunktion

Für die CPT-Berechnung wendet man nun die Sigmoidfunktion wie folgt an

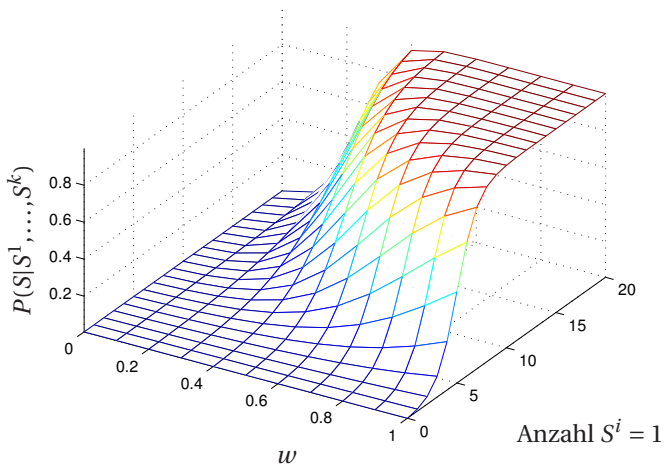
$$P(S = 1 | S^1 = s^1, \dots, S^k = s^k) = \text{sig}\left(f(S^1, \dots, S^k)\right) \quad (5.30)$$

$$= \text{sig}\left(w_0 + \sum_{i=1}^k w_i S^i\right). \quad (5.31)$$

Für das Quotenverhältnis von  $S$  gilt dann mit  $z = w_0 + \sum_{i=1}^k w_i S^i$

$$\frac{P(S = 1 | S^1 = s^1, \dots, S^k = s^k)}{P(S = 0 | S^1 = s^1, \dots, S^k = s^k)} = \frac{e^z / (1 + e^z)}{1 / (1 + e^z)} = e^z. \quad (5.32)$$

Abbildung 5.5 zeigt das Verhalten von  $P(S = 1 | S^1, \dots, S^k)$  in Abhängigkeit von der Gewichtung  $w$  und der Anzahl der Elternknoten mit  $S^i = 1$ . Dabei wurden angenommen, dass für alle  $i = 1, \dots, k$  die identischen Gewichte  $w_i = w$  gelten, und für  $w_0 = -5$ .



**Abbildung 5.5.:** Die Verhalten des GLM-Modells als Funktion von  $w$  und der Anzahl der Elternknoten mit  $S^i = 1$ . Dabei ist  $w_0 = -5$ . Abbildung nach [Kol09].

## 5.5. Generierung der SSDBN Parameter

### 5.5.1. Erwartungen an das SSDBN-Verhalten

Die Herausforderung bei der Generierung eines SSDBN ist nun, die Parameter so zu wählen, dass das SSDBN sich so verhält, wie man es erwarten würde. Im Folgenden werden nun Beobachtungen, welche für die Existenz einer Situation sprechen, als positive Evidenzen bezeichnet, und Beobachtungen, welche gegen die Existenz einer Situation sprechen, als negative Evidenzen. Außerdem sei

$$\max(S) := \max_{t>0} P(S_t = 1) \quad (5.33)$$

$$\min(S) := \min_{t>0} P(S_t = 1). \quad (5.34)$$

Die Erwartungen können dann in den folgenden drei Punkten formuliert werden [Fis13]:

- **Asymptotisches Verhalten:** Werden nur positive Evidenzen über die Zeit hinweg beobachtet, so soll  $P(S_t)$  gegen das Maximum  $\max(S)$  konvergieren. Werden nur negative Evidenzen über die Zeit hinweg beobachtet, so soll  $P(S_t)$  gegen das Minimum  $\min(S)$  konvergieren. Werden keine Evidenzen beobachtet, so soll  $P(S_t)$  in seiner A-priori-Verteilung verbleiben.
- **Sprungverhalten:** Wechseln die Evidenzen von ausschließlich positiven auf ausschließlich negative, so soll  $P(S_t)$  monoton fallen und gegen das Minimum  $\min(S)$  konvergieren. Wechseln die Evidenzen von ausschließlich negativen auf ausschließlich positive, so soll  $P(S_t)$  monoton wachsen und gegen das Maximum  $\max(S)$  konvergieren.
- **Robustheit:** Werden vereinzelt verrauschte Evidenzen beobachtet, also entweder falsche oder fehlende Beobachtungen, so sollte  $P(S_t)$  nicht sofort darauf reagieren, sondern diese kompensieren.

### 5.5.2. Nutzung von Vorwissen

Ein Vorteil bei der Nutzung von Bayes'schen Verfahren wie einem DBN ist, dass es möglich ist, Vorwissen in das Modell zu integrieren. Ist beispielsweise vor der Erstellung des Modells die Wahrscheinlichkeit, dass es sich bei einem beobachteten Schiff um ein Schmuggelboot handelt, bekannt, so kann dieses Wissen im Modell verwendet werden. Solches Vorwissen kann beispielsweise aus vorhergehender frequentistischer Betrachtung entstehen. Das Vorwissen ist als A-priori-Wahrscheinlichkeit für jede Situation im SSDBN hinterlegt [Fis14b]. Die A-priori-Wahrscheinlichkeit einer Situation  $S$  entspricht genau der Marginalverteilung der Situation  $S$  zum Zeitpunkt Null, also

$$\text{prior}(S) := P(S_0). \quad (5.35)$$

Ist kein Vorwissen über eine Situation vorhanden, so wird das Prinzip der maximalen Entropie angewandt. Dabei wird diejenige Verteilung als A-priori-Verteilung angenommen, welche die Entropie  $H$  maximiert, also die größtmögliche Ungewissheit repräsentiert [Jay68]:

$$H = - \sum_{s \in \{0,1\}} P(S = s) \log_2 P(S = s). \quad (5.36)$$

Im Falle einer diskreten Verteilung ist dies die Gleichverteilung, es gilt also

$$\text{prior}(S) = 0,5. \quad (5.37)$$

### 5.5.3. Stationaritäts-Bedingung

Bezüglich des asymptotischen Verhaltens des SSDBN wird nun eine Stationaritäts-Bedingung formuliert. Diese Stationaritäts-Bedingung garantiert, dass die Wahrscheinlichkeit einer Situation in ihrer A-priori-Verteilung verbleibt, wenn keine Beobachtungen gemacht werden. Die A-priori-Verteilung soll also die stationäre Verteilung des DBN sein [Fis14b]. Sind  $S_t^1, \dots, S_t^n$  die Knoten des SSDBN in der Zeitscheibe  $t$ , so ist die Stationaritäts-Bedingung genau dann erfüllt, wenn für alle  $i = 1, \dots, n$  und für alle  $t \geq 0$  gilt:

$$P(S_t^i) = \text{prior}(S^i). \quad (5.38)$$

### 5.5.4. Sprungverhalten

Werden einem SSDBN über die Zeit hinweg Evidenzen hinzugefügt, so berechnet dieses die Existenzwahrscheinlichkeit einer Situation über die Zeit hinweg, wobei positive Evidenzen die Existenzwahrscheinlichkeit erhöhen und negative Evidenzen die Existenzwahrscheinlichkeit verringern. Ein Parameter für die Beschreibung des Sprungverhaltens ist nun die Anzahl der Zeitschritte, die das SSDBN benötigt, um ausgehend von der A-priori-Wahrscheinlichkeit bei ausschließlich positiven Evidenzen die Maximalwahrscheinlichkeit zu erreichen. Es bezeichne nun  $\max(S)$  die Maximalwahrscheinlichkeit und  $\mathbf{e}_{0,1,\dots}$  seien nur positive Evidenzen, dann ist für ein  $\varepsilon > 0$

$$g_{pos} := \min \{t_1 : |\max(S) - P(S_{t_1} | \mathbf{e}_{0:t_1})| < \varepsilon\}. \quad (5.39)$$

Der Parameter  $g_{pos}$  ist also ein Kriterium, wie sensitiv das SSDBN auf positive Evidenzen reagiert. Analog könnte das Sprungverhalten für negative Evidenzen definiert werden. Aus Symmetriegründen kann hierauf jedoch verzichtet werden.

### 5.5.5. Robustheit

Zur Beurteilung der Robustheit bezüglich negativer Evidenzen wird ein weiterer Parameter definiert. Dieser entspricht der Anzahl der Zeitschritte, die das SSDBN benötigt, um ausgehend von der Maximalwahrscheinlichkeit bei ausschließlich negativen Evidenzen die A-priori-Wahrscheinlichkeit zu erreichen. Es sei nun  $P(S_{t_1}) = \max(S)$  und  $\mathbf{e}_{t_1+1, t_1+2, \dots}$  nur negative Evidenzen, dann ist für ein  $\varepsilon > 0$

$$g_{neg} := \min \{t_2 : |P(S_{t_1+t_2} | \mathbf{e}_{t_1+1:t_2}) - \text{prior}(S)| < \varepsilon\}. \quad (5.40)$$

Der Parameter  $g_{neg}$  ist also ein Kriterium, wie sensitiv das SSDBN auf negative Evidenzen reagiert, also wie viele aufeinanderfolgende negative Evidenzen das SSDBN kompensieren kann. Ist beispielsweise  $g_{neg} = 1$ , so würde in diesem Fall das SSDBN nach nur einem Zeitschritt von der Maximalwahrscheinlichkeit auf die A-priori-Wahrscheinlichkeit fallen. Ein solches reaktives Verhalten zeigt eine sehr hohe Sensitivität gegenüber verrauschten Beobachtungen und ist für ein robustes Verfahren nicht wünschenswert. Auch hier wird aus Gründen der Symmetrie auf die Definition der Robustheit bezüglich positiver Evidenzen verzichtet.

### 5.5.6. Asymptotisches Verhalten

Befindet sich das SSDBN in der Maximalwahrscheinlichkeit und es werden keine Beobachtungen mehr gemacht, so garantiert die Stationaritäts-Bedingung, dass die Existenzwahrscheinlichkeit über die Zeit hinweg wieder den Wert der A-priori-Verteilung annimmt. Dies ist sinnvoll, da veraltete Evidenzen keinen Einfluss mehr auf die Existenzwahrscheinlichkeit haben sollen. Da keine aktuellen Evidenzen vorhanden sind, kann nur auf das Vorwissen zugegriffen werden, d.h. die A-priori-Wahrscheinlichkeit wird angenommen. Ein Parameter für die Beschreibung des asymptotischen Verhaltens ist nun die Anzahl der Zeitschritte, die das Netz benötigt, um von der maximalen Wahrscheinlichkeit  $\max(S)$  wieder auf die A-priori-Wahrscheinlichkeit  $\text{prior}(S)$  zu sinken. Es sei nun  $P(S_{t_1}) = \max(S)$  und  $e_{t_1+1, t_1+2, \dots} = \emptyset$ , dann ist für ein  $\varepsilon > 0$

$$g_{asym} := \min \{ t_2 : |P(S_{t_1+t_2}) - \text{prior}(S)| < \varepsilon \}. \quad (5.41)$$

Der Parameter  $g_{asym}$  ist damit als Kriterium für die Trägheit des SSDBN zu interpretieren. Auf die Konvergenz gegen  $\max(S)$  bei positiven Evidenzen und gegen  $\min(S)$  bei negativen Evidenzen wird in Abschnitt 5.5.8 eingegangen.

### 5.5.7. Berechnung der CPT

Für die Berechnung der CPT wird nun das generalisierte lineare Modell, welches in Abschnitt 5.4.5 vorgestellt wurde, verwendet. Um die Berechnung zu realisieren, müssen nun die Gewichte  $w_0, w_1, \dots, w_k$  für jeden Knoten  $S_t$  mit den Elternknoten  $S^1, \dots, S^k$  spezifiziert werden, um die Formel (5.31) anzuwenden. Dabei befinden sich die Elternknoten entweder in der selben Zeitscheibe  $t$  oder in der Zeitscheibe  $t - 1$ .



Die Gewichte  $w_1, \dots, w_k$  können als Kantengewichte interpretiert werden und das Gewicht  $w_0$  als Justierparameter für den Schwellwert. Unter der Annahme, dass  $w_1, \dots, w_k$  und die CPTs der Elternknoten  $S^1, \dots, S^k$  schon bekannt sind, kann der Parameter  $w_0$  dahingehend berechnet werden, dass das SSDBN die Stationaritäts-Bedingung (5.38) erfüllt. Die Annahme, dass die CPTs der Elternknoten schon bekannt sind, kann erfüllt werden, wenn man die knotenweise CPT-Berechnung in topologischer Ordnung durchführt, also mit dem Wurzelknoten des *2TBN* beginnt [Fis14b]. Die Marginalwahrscheinlichkeit von  $S$  lässt sich also mit (5.31) berechnen durch

$$P(S_t = 1) = \sum P(S_t = 1 | S^1, \dots, S^k) \cdot P(S^1, \dots, S^k) \quad (5.42)$$

$$= \sum \text{sig} \left( w_0 + \sum_{i=1}^n w_i S^i \right) \cdot P(S^1, \dots, S^k), \quad (5.43)$$

wobei die Summe über jede Kombination  $S^1 = s^1, \dots, S^k = s^k$  mit  $s^i \in \{0, 1\}$  gebildet wird. Damit die Stationaritäts-Bedingung (5.38) erfüllt ist, muss nun gelten

$$P(S_t = 1) = \text{prior}(S). \quad (5.44)$$

Da  $\text{prior}(S)$  bekannt ist, lässt sich  $w_0$  als Nullstelle zu  $\text{prior}(S) - P(S_t = 1)$  berechnen. Mit einem solchen  $w_0$  gilt also

$$\text{prior}(S) - \sum \text{sig} \left( w_0 + \sum_{i=1}^n w_i S^i \right) \cdot P(S^1, \dots, S^k) = 0. \quad (5.45)$$

Für ein komplettes SSDBN sind nun für mehrere Knoten solche CPT-Berechnungen nötig. Dabei ist die Anzahl der CPTs abhängig von der Anzahl der Knoten innerhalb einer Zeitscheibe und der Anzahl der Knoten, welche eine eingehende temporale Kante besitzen, also die Anzahl der abstrakten Situationen. Bezeichnet  $n_t$  die Anzahl aller Knoten in Zeitscheibe  $t$  und  $n_t^a$  die Anzahl aller abstrakten Situationen in Zeitscheibe  $t$ , so ist die Anzahl der zu bestimmenden CPTs  $m$  gegeben durch

$$m = n_0 + n_1^a. \quad (5.46)$$

Damit sind die CPTs für die Struktur  $B_0$  bestimmt, sowie für alle abstrakten Situationen zum Zeitpunkt 1. Die CPTs für die elementaren Situationen zum Zeitpunkt 1 sind dann identisch zu den CPTs der elementaren Situationen

zum Zeitpunkt 0. Für die weiteren Zeitpunkte werden dann die CPTs aus Zeitpunkt 1 verwendet. Das Verfahren, um diese CPTs zu berechnen, ist in Algorithmus 4 dargestellt [Fis14b].

---

**Algorithmus 4** Algorithmus zur Berechnung der CPTs eines SSDBN bei bekannten Kantengewichten

---

**Eingabe:** Struktur des SSDBN, Gewichte für jede Kante, A-priori-Wahrscheinlichkeiten für jeden Knoten

**Ausgabe:** Alle zu bestimmenden CPTs des SSDBN

```

1:  $\mathcal{S} := \{S_0^1, \dots, S_0^{n_0}, S_1^1, \dots, S_1^{n_1^a}\};$ 
2:  $m := n_0 + n_1^a;$ 
3:  $\mathcal{S}^m := \{S^1, \dots, S^m\}$ , wobei  $S^1, \dots, S^m$  topologisch sortiert sind und genau
   den Elementen aus  $\mathcal{S}$  entsprechen (also  $\mathcal{S} = \mathcal{S}^m$ );
4: for  $i = 1, \dots, m$  do
5:    $k :=$  Anzahl der Elternknoten  $Pa(S^i)$  von  $S^i$ ;
6:   if  $k = 0$  then
7:     Setze  $\text{prior}(S^i)$  als CPT;
8:   else
9:     berechne  $P(Pa(S^i))$ ;
10:    berechne  $w_0$  als Nullstelle von  $\text{prior}(S^i) - P(S^i)$  unter Verwendung
      von Gleichung (5.45);
11:    berechne CPT-Einträge  $P(S^i | Pa(S^i))$  mit Gleichung (5.31);
12:   end if
13: end for

```

---

### 5.5.8. Bestimmung der Kantengewichte

Grundsätzlich können die Kantengewichte absolut beliebig gewählt werden. Da jedoch das Verhalten des SSDBN genau von diesen Parametern abhängt, wird hier ein Vorgehen zur sinnvollen Spezifizierung der Kantengewichte vorgestellt.

Um die Kantengewichte zu spezifizieren, sollen die Erwartungen an das Verhalten des SSDBN aus Abschnitt 5.5.1 erfüllt werden. Diese adressieren einerseits den Einfluss, den temporäre Kanten auf die zeitliche Filterung haben,

und andererseits den Einfluss, den die Beobachtungen auf die resultierende Wahrscheinlichkeit haben. Aus diesem Grund werden für ein SSDBN alle Kanten innerhalb einer Zeitscheibe mit einem Gewicht  $w_{obs}$ , und alle Kanten zwischen zwei Zeitscheiben mit einem Gewicht  $w_{temp}$  versehen.

Die Erwartungen, dass  $P(S_t)$  über die Zeit hinweg bei positiven Evidenzen gegen  $\max(S)$  und bei negativen Evidenzen gegen  $\min(S)$  konvergiert, ist durch die Wahl von positiven Gewichten  $w_{obs}$  und  $w_{temp}$  gewährleistet. Wären diese Gewichte negativ, so wäre der Effekt genau umgekehrt.

Zur Spezifizierung der beiden Gewichte werden die beiden Werte  $g_{pos}$  und  $g_{neg}$  aus den Gleichungen (5.39) und (5.40) verwendet. Für ein SSDBN mit vorhandenen CPTs können diese Werte, also die Anzahl der Zeitschritte, berechnet werden. Insbesondere kann ein Nutzer die Zielwerte dieser zwei Kriterien intuitiv festlegen. Diese Zielwerte werden im Folgenden als  $z_{pos}$ , und  $z_{neg}$  bezeichnet und beziehen sich immer auf eine Situation von Interesse  $S$ .

Um diejenigen Gewichte  $w_{obs}$  und  $w_{temp}$  zu bestimmen, welche diese Zielwerte erreichen, wird ein Optimierungsverfahren verwendet. Dabei wird angenommen, dass alle Werte kleiner als  $z_{pos}$  akzeptabel sind, also dass bei positiven Evidenzen die Maximalwahrscheinlichkeit auch in weniger Schritten als  $z_{pos}$  erreicht wird. Damit wäre das SSDBN reaktiver auf positive Evidenzen. Analog dazu wird angenommen, dass alle Werte größer als  $z_{neg}$  akzeptabel sind, also dass bei negativen Evidenzen die A-priori-Wahrscheinlichkeit auch in mehr Schritten als  $z_{neg}$  erreicht wird. Damit wäre das SSDBN also robuster gegenüber negativen Evidenzen. Für ein SSDBN seien nun

$$d_{pos} := \max(0, g_{pos} - z_{pos}), \quad (5.47)$$

$$d_{neg} := \max(0, z_{neg} - g_{neg}). \quad (5.48)$$

Damit lässt sich die Zielfunktion des Optimierungsverfahrens, welche es zu minimieren gilt, wie folgt definieren:

$$f(w_{obs}, w_{temp}) := 1 + d_{pos} + d_{neg} - \max(S). \quad (5.49)$$

Da es für das Minimum von  $d_{pos} + d_{neg}$  keine eindeutige Lösung gibt, sollen diejenigen Gewichte  $w_{obs}$  und  $w_{temp}$  gewählt werden, welche zusätzlich die maximale Wahrscheinlichkeit von  $S$  maximieren. Die maximale Wahrscheinlichkeit von  $S$  hängt von den Parametern  $w_{obs}$  und  $w_{temp}$  ab und fällt damit für unterschiedliche CPTs unterschiedlich aus. Die Addition mit Eins dient nur der besseren späteren Darstellung, da damit  $f(w_{obs}, w_{temp}) \geq 0$  gilt. Zusätzlich dazu sei erwähnt, dass es auch möglich ist, dass die Zielwerte nicht


erreicht werden. Die Formulierung der Zielfunktion gewährleistet jedoch, dass zumindest die bestmögliche Annäherung daran gesucht wird.

Das Finden des Minimums der Zielfunktion (5.49) stellt ein nichtlineares Optimierungsproblem dar. Da die Gradienten von  $S$  nicht bekannt sind, wird hier ein direktes Suchverfahren verwendet [Kol03]. Zur Lösung des Problems kann beispielsweise das Pattern-Search-Verfahren verwendet werden, welches auch in dieser Arbeit eingesetzt wird [Kol03; Lew07].

Ist das Optimierungsproblem gelöst und sind die optimalen Werte für  $w_{obs}$  und  $w_{temp}$  bekannt, so kann Algorithmus 4 angewandt werden, um die finalen CPTs zu berechnen.

## 5.6. Beispielberechnung für ein HMM

Als Beispiel wird nun die Berechnung der Parameter für ein HMM vorgestellt. Das SSDBN besitzt also pro Zeitscheibe zwei Knoten, einen Evidenzknoten  $E$  und einen Knoten für die Situation von Interesse  $S$ . Dabei existiert eine Kante von der Situation zum Evidenzknoten mit dem Gewicht  $w_{obs}$  und eine temporale Kante von der Situation in  $t - 1$  zur Situation in  $t$  mit dem Gewicht  $w_{temp}$ . Die Struktur des ausgerollten HMMs ist in Abbildung 5.6 dargestellt.



**Abbildung 5.6.:** Struktur eines ausgerollten HMM mit den Kantengewichten  $w_{obs}$  und  $w_{temp}$ .

Im Folgenden beträgt die A-priori-Wahrscheinlichkeit zunächst  $\text{prior}(S) = 0,5$ . Für das HMM zeigen Abbildung 5.7 und 5.8 jeweils die Anzahl der Zeitschritte  $g_{pos}$  und  $g_{neg}$  in Abhängigkeit von  $w_{obs}$  und  $w_{temp}$ , und Abbildung 5.9 die Maximalwahrscheinlichkeit  $\text{max}(S)$  in Abhängigkeit der beiden Parameter.




Abbildung 5.7.: Anzahl Zeitschritte  $g_{pos}$  in Abhängigkeit von  $w_{obs}$  und  $w_{temp}$ .






Abbildung 5.8.: Anzahl Zeitschritte  $g_{neg}$  in Abhängigkeit von  $w_{obs}$  und  $w_{temp}$ .



**Abbildung 5.9.:** Die Maximalwahrscheinlichkeit  $\max(S)$  in Abhängigkeit von  $w_{obs}$  und  $w_{temp}$ .



**Abbildung 5.10.:** Die Zielfunktion  $f(w_{obs}, w_{temp})$ .

Nun wurden als Eingabe für die CPT-Berechnung die Werte  $z_{pos} = 6$  und  $z_{neg} = 3$  verwendet. Abbildung 5.10 zeigt die Zielfunktion  $f(w_{obs}, w_{temp})$ , berechnet mit Gleichung (5.49). Die Optimierung selbst liefert die in Tabelle 5.1 aufgelisteten Werte, wobei mit  $w_0(K)$  jeweils der Parameter  $w_0$  für den Knoten  $K$  bezeichnet ist. Die entsprechenden Werte der CPTs, berechnet mit Gleichung (5.31), sind in Tabelle 5.2 aufgelistet.

**Tabelle 5.1.:** Parameterwerte für  $z_{pos} = 6$ ,  $z_{neg} = 3$  und  $\text{prior}(S) = 0,5$ .

$w_0(E_t)$	$w_0(S_t)$	$w_{obs}$	$w_{temp}$	$g_{pos}$	$g_{neg}$	$g_{asym}$	$\max(S)$
-3,5	-8	7	16	3	3	47	1

**Tabelle 5.2.:** CPTs, berechnet mit Parameterwerten aus Tabelle 5.1.

$P(E_t S_t)$	$S_t$	$\neg S_t$	$P(S_t S_{t-1})$	$S_{t-1}$	$\neg S_{t-1}$
$E_t$	0,97069	0,02931	$S_t$	0,99966	0,00034
$\neg E_t$	0,02931	0,97069	$\neg S_t$	0,00034	0,99966

Führt man die Berechnung analog mit  $z_{pos} = 12$  und  $z_{neg} = 6$  durch, so erhält man die in Tabelle 5.3 aufgelisteten Parameterwerte und die in Tabelle 5.4 aufgelisteten CPTs.

**Tabelle 5.3.:** Parameterwerte für  $z_{pos} = 12$ ,  $z_{neg} = 6$  und  $\text{prior}(S) = 0,5$ .

$w_0(E_t)$	$w_0(S_t)$	$w_{obs}$	$w_{temp}$	$g_{pos}$	$g_{neg}$	$g_{asym}$	$\max(S)$
-1,75	-12	3,5	24	6	6	44	1

**Tabelle 5.4.:** CPTs, berechnet mit Parameterwerten aus Tabelle 5.3.

$P(E_t S_t)$	$S_t$	$\neg S_t$	$P(S_t S_{t-1})$	$S_{t-1}$	$\neg S_{t-1}$
$E_t$	0.85195	0.14805	$S_t$	0,99999	0,00001
$\neg E_t$	0.14805	0.85195	$\neg S_t$	0,00001	0,99999

Bei den bisherigen Berechnungen wurde die A-priori-Wahrscheinlichkeit auf 0,5 gesetzt. Im Folgenden werden dieselben Berechnungen durchgeführt, jedoch wird für die A-Priori-Wahrscheinlichkeit ein Wert von 0,1 angenommen. Tabellen 5.5, 5.6, 5.7 und 5.8 zeigen jeweils die berechneten Parameterwerte und die entsprechenden CPTs für unterschiedliche Angaben der Zielschritte.

**Tabelle 5.5.:** Parameterwerte für  $z_{pos} = 6$ ,  $z_{neg} = 3$  und  $\text{prior}(S) = 0,1$ .

$w_0(E_t)$	$w_0(S_t)$	$w_{obs}$	$w_{temp}$	$g_{pos}$	$g_{neg}$	$g_{asym}$	$\max(S)$
-8,5993	-13,0986	15	24	2	3	48	1

**Tabelle 5.6.:** CPTs, berechnet mit Parameterwerten aus Tabelle 5.5.

$P(E_t S_t)$	$S_t$	$\neg S_t$	$P(S_t S_{t-1})$	$S_{t-1}$	$\neg S_{t-1}$
$E_t$	0,99834	0,00018	$S_t$	0,99998	0,00000
$\neg E_t$	0,00166	0,99982	$\neg S_t$	0,00002	1,00000

**Tabelle 5.7.:** Parameterwerte für  $z_{pos} = 12$ ,  $z_{neg} = 6$  und  $\text{prior}(S) = 0,1$ .

$w_0(E_t)$	$w_0(S_t)$	$w_{obs}$	$w_{temp}$	$g_{pos}$	$g_{neg}$	$g_{asym}$	$\max(S)$
-4,6389	-13,0986	7	24	3	6	47	1


**Tabelle 5.8.:** CPTs, berechnet mit Parameterwerten aus Tabelle 5.7.

$P(E_t S_t)$	$S_t$	$\neg S_t$	$P(S_t S_{t-1})$	$S_{t-1}$	$\neg S_{t-1}$
$E_t$	0,91382	0,00958	$S_t$	0,99998	0,00000
$\neg E_t$	0,08618	0,99042	$\neg S_t$	0,00002	1,00000



Insgesamt ist zu sehen, dass die CPTs symmetrisch sind, wenn die A-priori-Wahrscheinlichkeit 0,5 beträgt. Grundsätzlich wird immer der Minimalwert von  $g_{neg}$  als Optimierungsergebnis erreicht. Der optimierte Wert von  $g_{pos}$  hingegen liegt weit unter dem als Maximalwert angegebenen. Dies bedeutet, dass die resultierenden SSDBN die minimalen Robustheitsanforderungen erfüllen, jedoch ein reaktiveres Verhalten auf positive Evidenzen aufweisen.

Abbildung 5.11 zeigt den zeitlichen Verlauf der Ergebnisse  $P(S)$  für die vier unterschiedlich generierten SSDBN. Dabei wurden in den ersten 6 Zeitschritten positive Evidenzen und in den restlichen 6 Zeitschritten negative Evidenzen verwendet. In der Abbildung sind die berechneten Werte für  $g_{pos}$  und  $g_{neg}$  in den einzelnen Graphen wiederzufinden.



**Abbildung 5.11.:** Ergebnisse von  $P(S)$  über 12 Zeitschritte hinweg. Für die Zeitschritte 1-6 wurden positive Evidenzen und für die Zeitschritte 7-12 wurden negative Evidenzen verwendet.

## 5.7. Zusammenfassung

In diesem Kapitel wurde zunächst das Gesamtkonzept der Situationsanalyse vorgestellt. Zwei wesentliche Teilprozesse der Situationsanalyse sind die Charakterisierung und die Erkennung von Situationen. Aus dem Prozess der Charakterisierung resultiert das im vorhergehenden Kapitel definierte Situationsnetzwerk. Dieses Situationsnetzwerk wird verwendet, um ein situationspezifisches DBN (SSDBN) zu generieren, welches dann für die Situationserkennung eingesetzt werden kann.

Die Struktur des SSDBN basiert auf dem Situationsnetzwerk. Entscheidend für das Verhalten des SSDBN ist die Wahl der Parameter. Als zwei wesentliche Kriterien für das Verhalten wurden das Sprungverhalten und die Robustheit identifiziert. Um das Verhalten zu bewerten, wurden zwei Kennzahlen definiert, welche jeweils einer bestimmten Anzahl von Zeitschritten entsprechen. Zusätzlich dazu sollte das SSDBN die Stationaritäts-Bedingung erfüllen. Diese garantiert, dass die A-priori-Verteilung der stationären Verteilung entspricht. Unter diesen Voraussetzungen können die notwendigen CPTs für ein SSDBN berechnet werden. Die Berechnung basiert dabei auf dem generalisierten linearen Modell und einer Optimierung hinsichtlich der Zielparameter. Insbesondere können mit der Eingabe von nur zwei Zielparametern alle notwendigen CPTs berechnet werden. Darüber hinaus sind diese zwei Zielparameter für den Menschen nachvollziehbar und somit intuitiv wählbar.

Das Kapitel schließt mit einer ausführlichen Analyse und Darstellung der Verfahrensergebnisse anhand eines HMMs.

# 6

---

## Ergebnisse am Beispiel der maritimen Überwachung

---

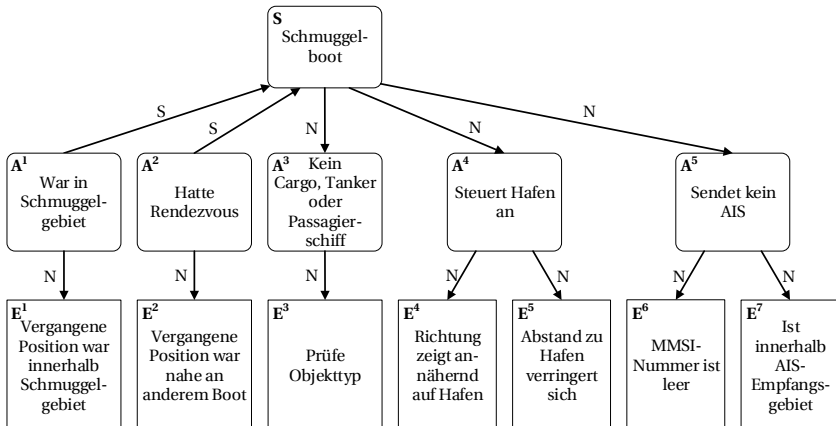
In diesem Kapitel werden Ergebnisse und Evaluationen zu dem hier entwickelten Verfahren vorgestellt. Zunächst wird mittels simulierter Daten die Robustheit und das Sprungverhalten eines exemplarischen SSDBN evaluiert. Anschließend werden unterschiedliche SSDBNs mit einem realen Datensatz evaluiert. Als Vergleichswerte dienen dabei die Ergebnisse des deduktiven logischen Schließens. Die Evaluierung erfolgt anhand der Genauigkeit und der Trefferquote. Abschließend wird eine Benutzerstudie vorgestellt, in der die Arbeitsbeanspruchung und die Akzeptanz des Nutzers bei der Verwendung eines Situationsanalysedienstes untersucht werden.

### 6.1. Evaluation mit simulierten Daten

#### 6.1.1. Maritime Situation von Interesse

Für die Evaluierung mit simulierten Daten wurde ein relativ komplexes Situationsnetzwerk modelliert. Die Komplexität wurde dadurch erlangt, dass das Netz aus vielen abstrakten und elementaren Situationen besteht, dass sowohl notwendige als auch hinreichende Bedingungen enthalten sind, und dass mehr als nur zwei Abstraktionsebenen vorhanden sind. Dazu wurde die Situation eines Schmuggelbootes gewählt.

Für die Modellierung selbst wurde angenommen, dass in einem Hafen ein maritimes Überwachungssystem installiert ist und der dort eingesetzte Sicherheitsbeamte daran interessiert ist, verdächtige Schmuggelboote zu identifizieren. Als Hintergrundinformation wurde angenommen, dass sich auf offener See in der Nähe des Hafens ein Gebiet befindet, welches oft von Schmugglern frequentiert wird. Bei der Schmuggelaktivität selbst wird dann speziell in diesem Gebiet die Schmuggelware oft von einem Boot auf ein anderes Boot übergeben. Aufgrund dessen sind die beiden Situationen »War in Schmuggelgebiet« und »Hatte Rendezvous« als hinreichende Situationen modelliert. Die weiteren Charakteristiken, welche für die Identifizierung eines Schmuggelbootes sprechen, sind, dass es sich bei dem Boot nicht um ein Cargoschiff, einen Tanker oder um ein Passagierschiff handelt, dass es den Hafen ansteuert und dass es kein AIS-Signal sendet. Diese drei weiteren Charakteristiken wurden als notwendige Situationen modelliert. Das so modellierte Situationsnetzwerk ist in Abbildung 6.1 abgebildet. Aus Gründen der Vereinfachung, wird im Folgenden jede Situation mit einer Nummerierung versehen ( $S, A^1, \dots, A^5, E^1, \dots, E^7$ ). Die Zuordnung ist aus Abbildung 6.1 zu entnehmen, wobei die jeweilige Nummerierung in der linken oberen Ecke jeder Situation vermerkt ist.



**Abbildung 6.1.:** Das Situationsnetzwerk der evaluierten Situation, dass ein Boot ein Schmuggelboot ist. Elementare Situationen werden als Rechtecke dargestellt, abstrakte Situationen als Rechtecke mit abgerundeten Kanten.

Aus dem Situationsnetzwerk wurde mit dem in Kapitel 5 vorgestellten Verfahren ein SSDBN generiert. Dieses SSDBN besitzt nach (5.46) insgesamt 19 zu definierende CPTs, da die Anzahl der Knoten in Zeitscheibe 0  $n_0 = 13$  ist ( $S, A^1, \dots, A^5, E^1, \dots, E^7$ ) und die Anzahl der abstrakten Situationen in Zeitscheibe 1  $n_1^a = 6$  ist ( $S, A^1, \dots, A^5$ ). Wie in Abschnitt 5.4.1 beschrieben, ist die Anzahl der zu bestimmenden Parameter pro CPT abhängig von der Anzahl der Elternknoten. Für das aus dem Situationsnetzwerk aus Abbildung 6.1 generierte SSDBN sind also insgesamt 50 Parameter zu bestimmen. Diese Anzahl ist Tabelle 6.1 zu entnehmen, wobei  $S_0, A_0^i, E_0^i$  die Situationen in Zeitscheibe 0 bezeichnet und  $S_1, A_1^i$  die abstrakten Situationen in Zeitscheibe 1. Da die abstrakten Situationen in Zeitscheibe 1 noch eine eingehende temporale Kante besitzen, ist deren Exponent jeweils um Eins höher als der entsprechende Exponent für die Zeitscheibe 0. Die entsprechende Summe der Anzahl der Einträge aller CPTs berechnet sich aus  $1 \cdot 8 + 2 \cdot 2 + 10 \cdot 4 + 1 \cdot 16 + 2 \cdot 4 + 3 \cdot 8 = 100$  und die Anzahl der insgesamt zu bestimmenden Parameter beträgt somit  $0,5 \cdot 100 = 50$ .

**Tabelle 6.1.:** Anzahl der CPT-Einträge und der zu bestimmenden Parameter für das Situationsnetzwerk aus 6.1.

Situation $S^i$	$ CPT(S^i) $	zu bestimmende Parameter
$S_0$	$2^{2+1} = 8$	$2^2 = 4$
$A_0^1, A_0^2$	$2^{0+1} = 2$	$2^0 = 1$
$A_0^3, A_0^4, A_0^5, E_0^1, \dots, E_0^7$	$2^{1+1} = 4$	$2^1 = 2$
$S_1$	$2^{3+1} = 16$	$2^3 = 8$
$A_1^1, A_1^2$	$2^{1+1} = 4$	$2^1 = 2$
$A_1^3, A_1^4, A_1^5$	$2^{2+1} = 8$	$2^2 = 4$
Summe	100	50

Für die Optimierung wurden die Werte  $z_{pos} = 12$  und  $z_{neg} = 6$  gewählt. Eine A-priori-Wahrscheinlichkeit wurde nicht gewählt, so dass diese automatisch auf  $\text{prior}(S) = 0,5$  gesetzt wurde. Es wurden also die Parameter gewählt, welche in Abbildung 5.11 die stärksten Trägheitseffekte aufweisen. Insgesamt wurden also zur Generierung des SSDBN zwei Parameter gesetzt, nämlich  $z_{pos}$  und  $z_{neg}$ . Hätte ein Experte diese manuell setzen müssen, so wären dies im Gegen-

satz dazu 50 Parameter gewesen. Tabelle 6.2 zeigt die aus der Optimierung resultierenden Werte, wobei aufgrund der Übersichtlichkeit auf die Auflistung der  $w_0$ -Werte verzichtet wurde.

**Tabelle 6.2.:** Parameterwerte für  $z_{pos} = 12$ ,  $z_{neg} = 6$  und  $\text{prior}(S) = 0,5$ .

$w_{obs}$	$w_{temp}$	$g_{pos}$	$g_{neg}$	$g_{asym}$	$\max(S)$
2,3867	24	6	6	44	0,9886

### 6.1.2. Robustheit


Um die Robustheit des generierten SSDBN zu verifizieren, werden simulierte Evidenzen erzeugt. Dabei wird für jeden Zeitschritt und jede Elementarsituation eine Zufallszahl erzeugt, welche mit einer bestimmten Wahrscheinlichkeit einer negativen bzw. einer positiven Evidenz entspricht. Es sei nun  $q$  die Wahrscheinlichkeit, mit der eine negative Evidenz erzeugt wird. Dann gilt also für jede Elementarsituation  $E$

$$P(E) = \begin{cases} 1, & \text{mit Wahrscheinlichkeit } 1 - q, \\ 0, & \text{mit Wahrscheinlichkeit } q. \end{cases} \quad (6.1)$$

Diese Zufallszahlgenerierung wird für jede Elementarsituation des SSDBN angewandt, also für die Situationen  $E^1, \dots, E^7$ . Des Weiteren wurden die Zufallszahlen unabhängig voneinander generiert. Abbildung 6.2 zeigt die Ergebnisse der Filterung mit unterschiedlichen Werten für  $q$ .

Abbildung 6.2 zeigt, dass das SSDBN wie gewünscht sehr robust gegenüber verrauschten Beobachtungen ist. Durch den relativ hohen Wert von  $g_{neg}$  bleiben die Ergebnisse des SSDBN im oberen Bereich, sogar wenn mehrere verrauschte Beobachtungen hintereinander in das Modell einfließen. Dies zeigt insbesondere auch die Statistik über die Ergebnisse in Tabelle 6.3. Dabei wurde der Mittelwert und die Standardabweichung über die Zeit hinweg berechnet, um eine quantitative Aussage über die Streuung zu erhalten. Die ersten 10 Werte wurden dabei nicht berücksichtigt, da sich hier die Werte zunächst einpendeln. Es zeigt sich, dass bei einem Rauschwert von 50% die Streuung am größten ist und bei einer Erhöhung bzw. einer Verringerung

von  $q$  die Streuung abnimmt. Die Mittelwerte zeigen deutlich, dass selbst bei einem Rauschwert von  $q = 0,4$ , also wenn die Daten mit einer Wahrscheinlichkeit von 40% verrauscht sind, das SSDBN in der Lage ist, die Situation eines Schmuggelbootes zu erfassen.



**Abbildung 6.2.:** Filterergebnisse von  $P(\text{Schmuggelboot})$  mit unterschiedlichen Rauschwerten  $q$  über 100 Zeitschritte hinweg.

**Tabelle 6.3.:** Mittelwert und Standardabweichung von  $P(\text{Schmuggelboot})$ .

$q$	$\mu$	$\sigma$
0,1	0,993	0,003
0,2	0,990	0,006
0,3	0,988	0,008
0,4	0,933	0,068
0,5	0,588	0,327
0,6	0,052	0,087
0,7	0,010	0,006
0,8	0,008	0,004
0,9	0,007	0,004

### 6.1.3. Sprungverhalten

Auch um das Sprungverhalten des generierten SSDBN zu beurteilen, wurden simulierte Evidenzen verwendet. Hierbei wurden unterschiedlich lange Verweildauern in positiven und negativen Evidenzen berücksichtigt. Für jede Elementarsituation wurde eine Folge von Evidenzen generiert, und zwar abhängig vom Sprungwert  $c$ . Der Sprungwert  $c$  sagt aus, wie oft hintereinander positive Evidenzen bzw. negative Evidenzen aufeinander folgen, bevor ein Wechsel stattfindet. Für  $c = 1$  wechselt also die Evidenz in jedem Zeitschritt von positiv auf negativ oder umgekehrt, während für  $c = 10$  die Evidenz nur bei jedem zehnten Zeitschritt von positiv nach negativ oder umgekehrt wechselt.

Abbildungen 6.3, 6.4 und 6.5 zeigen, jeweils über 50 Zeitschritte hinweg, die Ergebnisse von  $P(\text{Schmuggelboot})$  für unterschiedliche Werte von  $c$ , nämlich für  $c = 1$ ,  $c = 5$  und  $c = 10$ . Zusätzlich sind die generierten Evidenzwerte als rote Punkte visualisiert und man kann an der Anzahl der aufeinanderfolgenden roten Punkte den Wert von  $c$  ablesen.

Für  $c = 1$  ist zu sehen, dass die Ergebnisse in jedem Zeitschritt springen. Dass die Ergebnisse stets im oberen Bereich liegen, also zwischen 0,6 und 1, liegt daran, dass der erste Evidenzwert positiv ist. Wäre der erste Evidenzwert negativ, so würden die Ergebnisse alle im unteren Bereich liegen. Dieses Sprungverhalten erscheint auch sinnvoll, da die Evidenzen nicht dauerhaft für die Existenz der Situation sprechen.

Für  $c = 5$  lässt sich die Trägheit des Prozesses sehr gut erkennen. Bei einem Wechsel von positiven zu negativen Evidenzen lässt sich ablesen, dass für die ersten 3-4 negativen Evidenzen das Ergebnis für  $P(\text{Schmuggelboot})$  sehr hoch bleibt. Erst bei der fünften aufeinanderfolgenden negativen Evidenz fällt die Existenzwahrscheinlichkeit der Situation ab. Die Tatsache, dass nach der fünften negativen Evidenz der Wert schon unter die A-priori-Wahrscheinlichkeit fällt, liegt daran, dass mit nur fünf aufeinanderfolgenden positiven Evidenzen noch nicht die Maximalwahrscheinlichkeit erreicht wurde.

Für  $c = 10$  ist die Trägheit des Prozesses noch offensichtlicher. Da dort die Maximalwahrscheinlichkeit nach den positiven Evidenzen erreicht wurde, benötigt man mindestens sechs aufeinanderfolgende negative Evidenzen, um die Wahrscheinlichkeit erheblich zu senken. Umgekehrt haben die vielen aufeinanderfolgenden negativen Evidenzen einen großen Einfluss, so dass wiederum mehrere aufeinanderfolgende positive Evidenzen notwendig sind, um die Existenzwahrscheinlichkeit auf einen hohen Wert zu ziehen.






Abbildung 6.3.: Filterergebnisse von  $P(\text{Schmuggelboot})$  mit  $c = 1$ .




Abbildung 6.4.: Filterergebnisse von  $P(\text{Schmuggelboot})$  mit  $c = 5$ .




Abbildung 6.5.: Filterergebnisse von  $P(\text{Schmuggelboot})$  mit  $c = 10$ .

## 6.2. Evaluation mit Realdaten

### 6.2.1. Datengrundlage

Als Datengrundlage für die Evaluierung dient ein Datensatz, welcher von der »Wehrtechnischen Dienststelle für Schiffe und Marinewaffen, Maritime Technologie und Forschung (WTD 71)<sup>59</sup>« in Eckernförde zur Verfügung gestellt wurde. Der Datensatz beinhaltet eine Aufzeichnung von empfangenen AIS-Daten in der Ostsee über drei Tage hinweg. Der Zeitraum erstreckt sich von ca. 12:30 Uhr am 16.05.2011 bis ca. 15:00 Uhr am 18.05.2011.

Der Datensatz selbst wird als Textdatei bereitgestellt, wobei jede Zeile einem übermittelten AIS-Datenpunkt im NMEA-Format entspricht. Abbildung 6.6 zeigt einen Ausschnitt über fünf Datenpunkte des originalen AIS-Datensatzes im NMEA-Format. Die Originaldaten wurden entsprechend dem NMEA-Protokoll übersetzt [NME08]. Daraus resultieren dann pro Datenpunkt die in Tabelle 2.2 aufgelisteten Informationen. Jede Zeile enthält also unter anderem Informationen zur MMSI-Nummer, zum Zeitpunkt, zur Position, zur Geschwindigkeit und zur Richtung.

```
!AIVDM,1,1,,A,139Kw4P01EPkBV<0=9a1SSe80@FI,0*56
!AIVDM,1,1,,A,138Q8D00000k081O<5g2kFW@08G8,0*2F
!AIVDM,1,1,,B,139L;6PP0:0kkHpO:;buJ?w@0GN,0*3F
!AIVDM,1,1,,A,13@nfKh02RPkTjtO=oJom6I<0PRh,0*22
!AIVDM,1,1,,B,139KDPgP?w<tSF014Q@>4?wv0hGQ,0*40
```

**Abbildung 6.6.:** Original AIS-Datensatz im NMEA-Format.

Innerhalb dieses Datensatzes wird die MMSI-Nummer als Identifikator (ID) für ein Schiff interpretiert. Soll nun der Fahrweg eines Schiffes über die Zeit hinweg dargestellt werden, so können die zeitlich geordneten Datenpunkte eines Schiffes mittels eines Linienzuges verbunden und visualisiert werden. Dabei zeigt sich jedoch, dass dies teilweise keinen Sinn ergibt und der Fahrweg beispielsweise die Insel Fehmarn kreuzt. Die Ursache liegt darin, dass einzelne Schiffe teilweise über einen längeren Zeitraum kein AIS-Signal mehr senden, sich jedoch trotzdem bewegen. Fährt ein Schiff also um die Insel Fehmarn

<sup>59</sup> <http://www.baainbw.de/portal/poc/baain?uri=ci%3Abw.baain.diensts.wtd71>, letzter Abruf am 26.04.2015

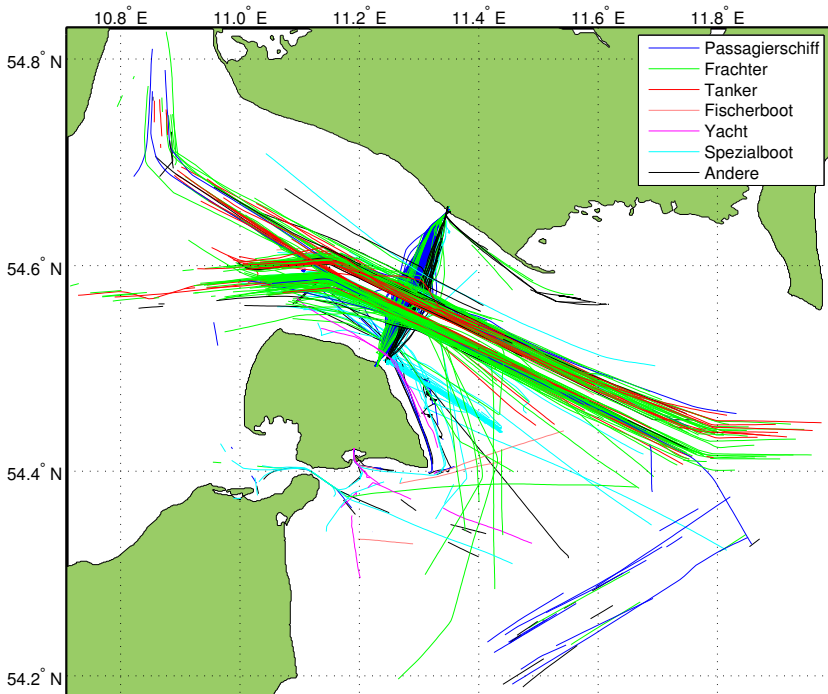
herum und schaltet das AIS-Signal vorher aus und danach wieder an, so kann die gefahrene Route um die Insel herum nicht rekonstruiert werden. Um diese Problematik zu adressieren, wurde mittels eines Schwellwertes der Datensatz eines Schiffes in mehrere Fahrwege, sogenannte Tracks unterteilt. Für diesen Datensatz wurde ein Schwellwert von 10 min gesetzt. Sendet also ein Schiff über 10 min lang kein AIS-Signal mehr, so wird der Track an diese Stelle abgebrochen und mit dem nächsten Datenpunkt ein neuer Track aufgesetzt. Ein Schiff kann somit also mehrere Schiffstracks generieren.

Da die AIS-Daten in asynchroner Weise erfasst werden, sind die Zeitschritte zwischen den einzelnen Datenpunkten nicht immer gleich groß. Nach dem Setzen des Schwellwertes für die Trackunterteilung von 10 min können die Differenzen der Datenpunkte eines Schiffes zwischen einer Sekunde und 600 Sekunden liegen. Da eine Anwendung des SSDBN jedoch synchron arbeitet, also jeder Zeitschritt die selbe Länge besitzen muss, wurden die Daten mit einer bestimmten Rate abgetastet. Für diesen Datensatz wurde eine Abtastrate von 60 sec gewählt. Dabei wurde zwischen den einzelnen Datenpunkten linear interpoliert und die Positionsdaten für jeden vollen Minute abgetastet. Dabei wurden die dynamischen Daten wie Kurs über Grund oder Geschwindigkeit neu berechnet. Die statischen Daten wie die MMSI-Nummer oder der Schiffstyp wurden aus dem letzten gesendeten Datenpunkt übernommen. Dies resultiert in einem Datensatz, welcher aus 528 Tracks mit insgesamt 61.742 Datenpunkten besteht. Tabelle 6.4 zeigt eine Übersicht über die Anzahl der Schiffstypen für den Datensatz.

**Tabelle 6.4.:** Anzahl unterschiedlicher Schiffstypen pro Datensatz.

Schiffstyp	Anzahl Tracks
Passagierschiff	59
Frachter	214
Tanker	71
Fischerboot	6
Yacht	9
Spezialboot	83
Andere	86
Summe	528

Abbildung 6.7 zeigt die einzelnen Schiffstracks des kompletten Datensatzes in einer Kartendarstellung. Die einzelnen Schiffstypen sind mit unterschiedlichen Farben kodiert. Deutlich zu sehen sind hier zwei sich kreuzende Schifffahrtsrouten. Eine Route wird häufiger von Passagierschiffen frequentiert und repräsentiert den Fährverkehr zwischen Puttgarden auf der Insel Fehmarn und Rødby in Dänemark. Quer dazu liegt der Kiel-Ostsee-Weg, welcher hauptsächlich von Frachtern und Tankern befahren wird.



**Abbildung 6.7.:** Visualisierter Datensatz in geographischen Koordinaten mit unterschiedlicher Farbgebung für die einzelnen Schiffstypen.

### 6.2.2. Maritime Situationen von Interesse

Die in der Evaluierung mit Realdaten verwendeten Situationen von Interesse basieren sowohl auf den bereits diskutierten Situationen in Abschnitt 2.5, als auch auf Diskussionen mit der WTD 71 und der Firma »Schönhofer Sales and Engineering GmbH<sup>60</sup>«. Insgesamt wurden 12 Situationen evaluiert. Diese sind in Tabelle 6.5 aufgelistet und werden im Folgenden mit  $S^1$  bis  $S^{12}$  bezeichnet.

**Tabelle 6.5.:** Situationen von Interesse.

$S^1$	Zu niedrige Geschwindigkeit in Schifffahrtsweg
$S^2$	Zu hohe Geschwindigkeit in Ostsee
$S^3$	Ungewöhnliche Richtungs- und Geschwindigkeitsänderung
$S^4$	Ungewöhnliche Geschwindigkeit für Handelsschiff
$S^5$	Ungewöhnliche Beschleunigung für Handelsschiff
$S^6$	Ungewöhnliche Kursänderung für Handelsschiff
$S^7$	Ungewöhnlich hohe Geschwindigkeit für kleines Boot
$S^8$	Verlassen der Fährroute
$S^9$	Verlassen des Kiel-Ostsee-Weges
$S^{10}$	Paralleles Fahren auf offener See
$S^{11}$	Rendezvous auf offener See
$S^{12}$	Baldiges Rendezvous auf offener See

<sup>60</sup> <http://www.schoenhofer.de/>, letzter Abruf am 26.04.2015

Diese 12 Situationen werden mittels weiterer abstrakter und elementarer Situationen definiert. Die verwendeten 15 abstrakten und 19 elementaren Situationen sind in den Tabellen 6.6 und 6.7 aufgelistet und werden im Folgenden mit  $A^1$  bis  $A^{15}$  bzw. mit  $E^1$  bis  $E^{19}$  bezeichnet.

**Tabelle 6.6.:** Abstrakte Situationen.

$A^1$		Fahrt in Gebiet Kiel-Ostsee-Weg
$A^2$		niedrige Geschwindigkeit
$A^3$		Fahrt in Gebiet offene Ostsee
$A^4$		Zu hohe Geschwindigkeit
$A^5$		Ungewöhnliche Beschleunigung
$A^6$		Ungewöhnliche Kursänderung
$A^7$		Ungewöhnliche Handelsschiffgeschwindigkeit
$A^8$		Ungewöhnliche Handelsschiffbeschleunigung
$A^9$		Ungewöhnliche Handelsschiffkursänderung
$A^{10}$		Hohe Kleinbootgeschwindigkeit
$A^{11}$		Neben einem anderen Schiff
$A^{12}$		Bewegt sich
$A^{13}$		Bewegt sich nicht
$A^{14}$		Schiffe steuern aufeinander zu
$A^{15}$		Gleiche Ankunftszeit am Schnittpunkt

**Tabelle 6.7.:** Elementare Situationen.

$E^1$	Punkt in Polygon »Kiel-Ostsee-Weg«
$E^2$	Geschwindigkeit kleiner 5 kn
$E^3$	Punkt in Polygon »offene Ostsee«
$E^4$	Geschwindigkeit größer 35 kn
$E^5$	Schiffstyp nicht High Speed Craft
$E^6$	Geschwindigkeitsänderung größer 5 kn über letzte Viertelstunde
$E^7$	Richtungsänderung größer 30° über letzte Viertelstunde
$E^8$	Schiffstyp ist Frachter oder Tanker
$E^9$	Geschwindigkeit kleiner 3 kn oder größer 21 kn
$E^{10}$	Schiffstyp nicht Tanker, Frachter oder Passagierschiff
$E^{11}$	Geschwindigkeit größer 25 kn
$E^{12}$	Punkt außerhalb Polygon »Fährroute Rødby-Puttgarden«
$E^{13}$	MMSI ist 211188000, 211190000, 219000431 oder 219000429
$E^{14}$	Punkt außerhalb Polygon »Kiel-Ostsee-Weg«
$E^{15}$	Abstand zu anderem Schiff kleiner als 20 m
$E^{16}$	Geschwindigkeit größer 0,5 kn
$E^{17}$	Geschwindigkeit kleiner 0,5 kn
$E^{18}$	Richtung schneidet sich mit Richtung eines anderen Bootes in weniger als 3 km
$E^{19}$	Zeitdifferenz zu Schnittpunkt kleiner als 1 min

Die formalisierten semantischen Aussagen von  $S^1$  bis  $S^{12}$  und von  $A^1$  bis  $A^{15}$  sind in den Gleichungen (6.2) bis (6.28) definiert. Insgesamt bilden die Gleichungen (6.2) bis (6.28) also die gemeinsame Wissensbasis  $WB(S^1, \dots, S^{12})$ . Mit Hilfe dieser gemeinsamen Wissensbasis lassen sich die vollständigen Wissensbasen zu den einzelnen Situationen  $WB(S^1)$  bis  $WB(S^{12})$ , und damit auch die einzelnen SNs und SSDBNs bilden. Die entsprechenden SNs zu den einzelnen Situationen sind aus Gründen der Übersichtlichkeit in Anhang A abgebildet.

$$F(S^1) := (S^1 \Rightarrow A^1) \wedge (S^1 \Rightarrow A^2), \quad (6.2)$$

$$F(S^2) := (S^2 \Rightarrow A^3) \wedge (S^2 \Rightarrow A^4), \quad (6.3)$$

$$F(S^3) := (S^3 \Rightarrow A^3) \wedge (S^3 \Rightarrow A^5) \wedge (S^3 \Rightarrow A^6), \quad (6.4)$$

$$F(S^4) := (S^4 \Rightarrow A^3) \wedge (S^4 \Rightarrow A^7), \quad (6.5)$$

$$F(S^5) := (S^5 \Rightarrow A^3) \wedge (S^5 \Rightarrow A^8), \quad (6.6)$$

$$F(S^6) := (S^6 \Rightarrow A^3) \wedge (S^6 \Rightarrow A^9), \quad (6.7)$$

$$F(S^7) := (S^7 \Rightarrow A^3) \wedge (S^7 \Rightarrow A^{10}), \quad (6.8)$$

$$F(S^8) := (S^8 \Rightarrow E^{12}) \wedge (S^8 \Rightarrow E^{13}), \quad (6.9)$$

$$F(S^9) := (S^9 \Rightarrow E^{14}) \wedge (S^9 \Rightarrow E^8), \quad (6.10)$$

$$F(S^{10}) := (S^{10} \Rightarrow A^3) \wedge (S^{10} \Rightarrow A^{11}) \wedge (S^{10} \Rightarrow A^{12}), \quad (6.11)$$

$$F(S^{11}) := (S^{11} \Rightarrow A^3) \wedge (S^{11} \Rightarrow A^{11}) \wedge (S^{11} \Rightarrow A^{13}), \quad (6.12)$$

$$F(S^{12}) := (S^{12} \Rightarrow A^3) \wedge (S^{12} \Rightarrow A^{14}) \wedge (S^{12} \Rightarrow A^{15}), \quad (6.13)$$

$$F(A^1) := (A^1 \Rightarrow E^1), \quad (6.14)$$

$$F(A^2) := (A^2 \Rightarrow E^2), \quad (6.15)$$

$$F(A^3) := (A^3 \Rightarrow E^3), \quad (6.16)$$

$$F(A^4) := (A^4 \Rightarrow E^4) \wedge (A^4 \Rightarrow E^5), \quad (6.17)$$

$$F(A^5) := (A^5 \Rightarrow E^6), \quad (6.18)$$

$$F(A^6) := (A^6 \Rightarrow E^7), \quad (6.19)$$

$$F(A^7) := (A^7 \Rightarrow E^8) \wedge (A^7 \Rightarrow E^9), \quad (6.20)$$

$$F(A^8) := (A^8 \Rightarrow E^8) \wedge (A^8 \Rightarrow E^6), \quad (6.21)$$

$$F(A^9) := (A^9 \Rightarrow E^8) \wedge (A^9 \Rightarrow E^7), \quad (6.22)$$



$$F(A^{10}) := (A^{10} \Rightarrow E^{10}) \wedge (A^{10} \Rightarrow E^{11}), \quad (6.23)$$

$$F(A^{11}) := (A^{11} \Rightarrow E^{15}), \quad (6.24)$$

$$F(A^{12}) := (A^{12} \Rightarrow E^{16}), \quad (6.25)$$

$$F(A^{13}) := (A^{13} \Rightarrow E^{17}), \quad (6.26)$$

$$F(A^{14}) := (A^{14} \Rightarrow E^{18}), \quad (6.27)$$

$$F(A^{15}) := (A^{15} \Rightarrow E^{19}). \quad (6.28)$$

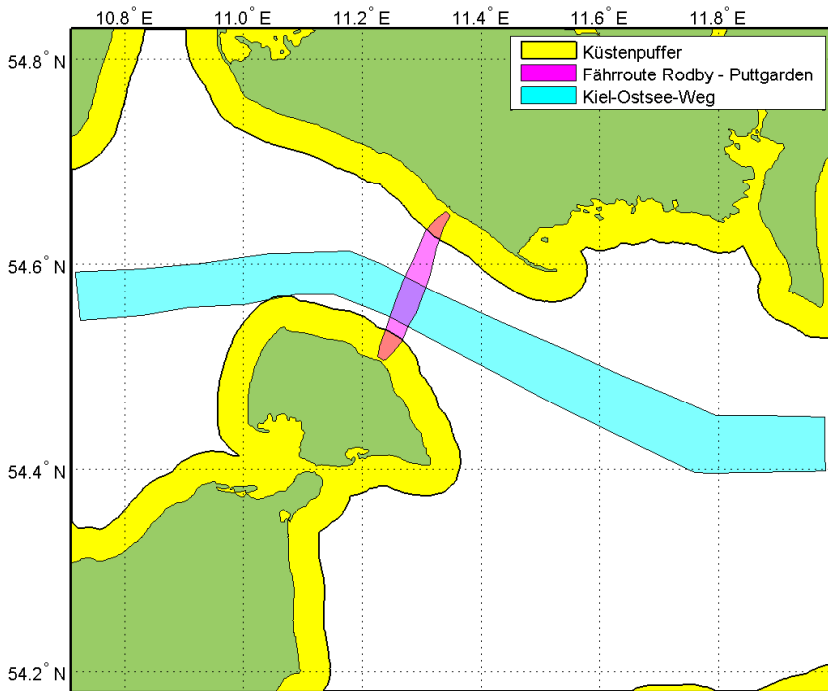
### 6.2.3. Berechnung der Evidenzen

Nach der Definition der Situationen von Interesse werden nun für den realen Datensatz die Evidenzwerte berechnet, also die Ergebnisse der deterministischen Funktionen für die elementaren Situationen. Diese Berechnung wird für jede elementare Situation und für jeden Datenpunkt eines jeden Schiffstracks durchgeführt. Das Ergebnis der Berechnung ist dann jeweils der Wert 1 wenn die elementare Situation existiert oder 0 wenn diese nicht existiert.

Die Existenzen der elementaren Situationen werden genau so berechnet, wie sie in Tabelle 6.7 beschrieben sind. So wird beispielsweise für jeden Datenpunkt geprüft, ob die Geschwindigkeit kleiner als 5 kn ist und dementsprechend  $E_2$  gesetzt. Für die Situationen  $E_1$ ,  $E_3$ ,  $E_{12}$  und  $E_{14}$  wurden händisch erstellte Polygone verwendet. Diese sind in Abbildung 6.8 abgebildet. Als »offene Ostsee« wird dabei jeder Punkt bezeichnet, welcher nicht innerhalb des Küstenpuffers liegt.

Für die Situationen  $E_6$  und  $E_7$  wurde eine Fensterfunktion umgesetzt, welche die Geschwindigkeitsänderung bzw. die Kursänderung über das Zeitfenster von 15 min ermittelt. Für die Geschwindigkeit wurde dabei die maximale und die minimale Geschwindigkeit innerhalb der letzten 15 min ermittelt. Die Änderung wurde dann mittels der Differenz berechnet. Für die Kursänderung wurde in analoger Weise die größte Kursrichtung gegen den Uhrzeigersinn und die größte Kursrichtung im Uhrzeigersinn innerhalb der letzten 15 min ermittelt. Die Änderung wurde dann mittels der Differenz berechnet.

Für die Situationen  $E_{18}$  und  $E_{19}$  wurde für jeden Datenpunkt berechnet, ob sich die Kursrichtung mit der eines anderen Schiffes überschneidet. Wenn dies für ein anderes Schiff zutrifft, so wird berechnet, ob dieser Schnittpunkt näher als 3 km liegt und ob die Zeit, bis das Schiff diesen Schnittpunkt erreicht, unter einer Minute liegt.



**Abbildung 6.8.:** Verwendete Polygone zur Berechnung der Evidenzwerte, dargestellt in geographischen Koordinaten.

### 6.2.4. Ergebnisse

Die SSDBNs zu den einzelnen Situationen  $S^1$  bis  $S^{12}$  wurden mit den Parametern  $z_{pos} = 12$ ,  $z_{neg} = 6$  und  $\text{prior}(S^i) = 0,5$  erstellt. Mittels dieser SSDBN wurde jeweils pro Schiffstrack das Filterergebnis für jeden Zeitschritt berechnet. Das Ergebnis ist also für jeden Schiffstrack die Existenzwahrscheinlichkeit jeder Situation über die Zeit hinweg. Um die Ergebnisse bewerten zu können, wurden zusätzlich dazu noch die Ergebnisse des logischen Schließens berechnet. Das Ergebnis des logischen Schließens liefert entweder den Existenzwert Eins oder Null. Die Situation existiert nach dem logischen Schluss genau dann, wenn alle dazugehörigen Evidenzen wahr sind, also den Wert Eins haben. Dies bedeutet also, dass für die Existenz einer Situation alle elementaren Situationen existieren müssen. Die Existenzen der zusätzlichen abstrakten Situationen werden hier nicht weiter betrachtet. Zu den einzelnen Situationen berechnen sich also die Ergebnisse des logischen Schließens wie folgt:

$$E_1 = 1 \wedge E_2 = 1 \Rightarrow S^1 = 1, \quad (6.29)$$

$$E_3 = 1 \wedge E_4 = 1 \wedge E_5 = 1 \Rightarrow S^2 = 1, \quad (6.30)$$

$$E_3 = 1 \wedge E_6 = 1 \wedge E_7 = 1 \Rightarrow S^3 = 1, \quad (6.31)$$

$$E_3 = 1 \wedge E_8 = 1 \wedge E_9 = 1 \Rightarrow S^4 = 1, \quad (6.32)$$

$$E_3 = 1 \wedge E_8 = 1 \wedge E_6 = 1 \Rightarrow S^5 = 1, \quad (6.33)$$

$$E_3 = 1 \wedge E_8 = 1 \wedge E_7 = 1 \Rightarrow S^6 = 1, \quad (6.34)$$

$$E_3 = 1 \wedge E_{10} = 1 \wedge E_{11} = 1 \Rightarrow S^7 = 1, \quad (6.35)$$

$$E_{12} = 1 \wedge E_{13} = 1 \Rightarrow S^8 = 1, \quad (6.36)$$

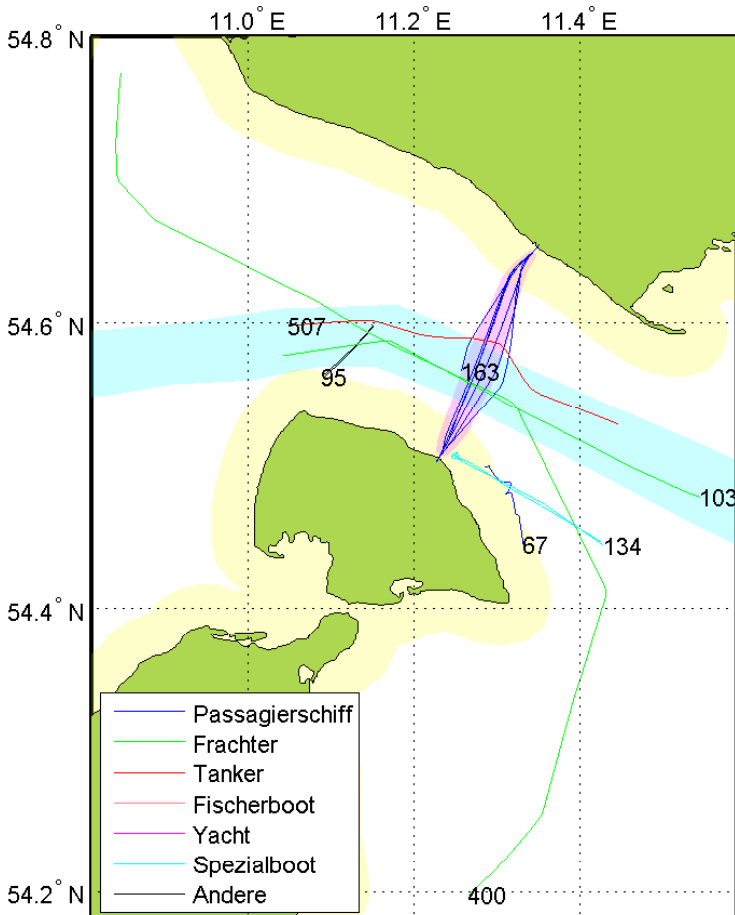
$$E_{14} = 1 \wedge E_8 = 1 \Rightarrow S^9 = 1, \quad (6.37)$$

$$E_3 = 1 \wedge E_{15} = 1 \wedge E_{16} = 1 \Rightarrow S^{10} = 1, \quad (6.38)$$

$$E_3 = 1 \wedge E_{15} = 1 \wedge E_{17} = 1 \Rightarrow S^{11} = 1, \quad (6.39)$$


$$E_3 = 1 \wedge E_{18} = 1 \wedge E_{19} = 1 \Rightarrow S^{12} = 1. \quad (6.40)$$

Abbildung 6.9 zeigt einige ausgewählte Schiffstracks, welche jeweils mit ihrer Tracknummer versehen sind. Zu diesen sieben Tracks werden nun ausgewählte Filterergebnisse des SSDBN mit den Ergebnissen des logischen Schließens verglichen.




**Abbildung 6.9.:** Ausgewählte Schiffstracks mit Tracknummern, dargestellt in geographischen Koordinaten.

Der Schiffstrack mit der Nummer 95 startet außerhalb des Kiel-Ostsee-Weges, fährt auf geradem Wege in den Kiel-Ostsee-Weg, verweilt dort längere Zeit an derselben Stelle und fährt anschließend auf fast dem identischen Weg zurück. Dies spiegelt sich auch im Verlauf der Filterergebnisse des SSDBN und den Ergebnissen des logischen Schließens zur Situation  $S^1$  (Zu niedrige Geschwindigkeit in Schifffahrtsweg) wieder, welche in Abbildung 6.10 dargestellt sind. Das SSDBN-Ergebnis erreicht dabei den Wert 0,5, wenn das Schiff in den Kiel-Ostsee-Weg eintritt. Sobald auch noch die Geschwindigkeit kleiner als 5 kn ist, steigt die Existenzwahrscheinlichkeit weiter an.



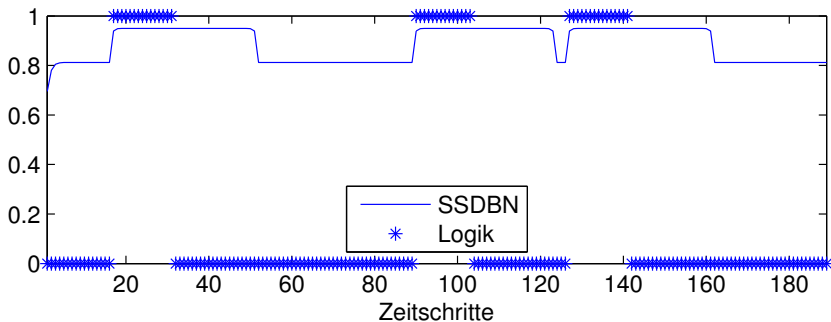
**Abbildung 6.10.:** Ergebnisse für Situation  $S^1$  (Zu niedrige Geschwindigkeit in Schifffahrtsweg) und Tracknummer 95.

Der Schiffstrack mit der Nummer 67 zeigt einen kurvigen Verlauf am Rand der Küstenpufferzone. Zusätzlich zu diesen starken Richtungsänderungen unterliegt der Schiffstrack noch starken Geschwindigkeitsänderungen. Dies führt zu den Ergebnissen der Situation  $S^3$  (Ungewöhnliche Richtungs- und Geschwindigkeitsänderung) in Abbildung 6.11. Hier ist der Filtereffekt des SSDBN sehr gut zu erkennen. Änderungen in den Ergebnissen des logischen Schließens führen nicht sofort zu einer Änderung der Ergebnisse des SSDBN. Dieses Verhalten ist beispielsweise zwischen dem 30ten und 50ten Zeitschritt zu beobachten.




**Abbildung 6.11.:** Ergebnisse für Situation  $S^3$  (Ungewöhnliche Richtungs- und Geschwindigkeitsänderung) und Tracknummer 67.

Das Schiff mit der Tracknummer 400 fährt von Norden Richtung Süden und befindet sich außerhalb der Küstenpufferzone. Gut zu erkennen sind 4 Richtungsänderungen, von denen die drei ersten mehr als  $30^\circ$  betragen. Da es sich um ein Handelsschiff handelt, sind diese drei Richtungsänderungen auch in den Ergebnissen zur Situation  $S^6$  (Ungewöhnliche Kursänderung für Handelsschiff) in Abbildung 6.12 zu beobachten.




**Abbildung 6.12.:** Ergebnisse für Situation  $S^6$  (Ungewöhnliche Kursänderung für Handelsschiff) und Tracknummer 400.

Bei dem Schiff mit der Tracknummer 163 handelt es sich um die Fähre zwischen Rødby und Puttgarden. Da die beiden Häfen nicht mehr in der Fährroute enthalten sind und die Fähre sich auch teilweise während der Überfahrt neben der Fährroute befindet, wechseln die logischen Ergebnisse der Situation  $S^8$  (Verlassen der Fährroute) von wahr zu falsch. Dies ist in Abbildung 6.13 zu sehen. Da die Wechselintervalle länger sind, bricht auch hier öfter der Filtereffekt des SSDBN ein.




**Abbildung 6.13.:** Ergebnisse für Situation  $S^8$  (Verlassen der Fährroute) und Tracknummer 163.

In Abbildung 6.14 sind die Ergebnisse zur Situation  $S^9$  (Verlassen des Kiel-Ostsee-Weges) und zum Track mit der Nummer 507 abgebildet. Gut zu erkennen ist das Abweichen vom Kiel-Ostsee-Weg durch eine Kurve. Auch hier ist der Filtereffekt des SSDBN gut zu erkennen, da die Existenzwahrscheinlichkeit bei einem Wechsel der Evidenzen nicht sofort absinkt.



**Abbildung 6.14.:** Ergebnisse für Situation  $S^9$  (Verlassen des Kiel-Ostsee-Weges) und Tracknummer 507.


Die Abbildung 6.15 zeigt die Ergebnisse der Tracknummer 134 für die Situation  $S^{11}$  (Rendezvous auf offener See). Diese ist nach dem logischen Schließen zu keinem Zeitpunkt existent. Das SSDBN-Ergebnis zeigt zwischenzeitlich jedoch einen erhöhten Wert, da zumindest zwei der drei Evidenzen wahr sind. In diesem Fall ist nur die Evidenz  $E_3$ , dass das Schiff sich in der offenen Ostsee befindet, nicht wahr. Die Nähe zu einem andere Schiff und die geringe Geschwindigkeit treffen jedoch zu. Hier würde bei einem geeigneten Schwellwert die Situation vom SSDBN erkannt werden, vom logischen Schluss jedoch nicht.



**Abbildung 6.15.:** Ergebnisse für Situation  $S^{11}$  (Rendezvous auf offener See) und Tracknummer 134.



In Abbildung 6.16 sind die Ergebnisse des Tracks mit der Nummer 103 für die Situation  $S^{12}$  (Baldiges Rendezvous auf offener See) dargestellt. Diese zeigen vereinzelte Existenzen für den logischen Schluss. Das SSDBN ist jedoch in der Lage, diese vereinzelten Evidenzen auszufiltern. Hier würde bei einem geeigneten Schwellwert die Situation vom SSDBN zu keiner Zeit erkannt werden, es würden also Fehlalarme minimiert werden.



**Abbildung 6.16.:** Ergebnisse für Situation  $S^{12}$  (Baldiges Rendezvous auf offener See) und Tracknummer 103.

Abschließend stellt sich die Frage, wie ein geeigneter Schwellwert zu setzen ist. Die ausgewählten Ergebnisse aus den Abbildungen 6.10 bis 6.16 zeigen, dass für unterschiedliche Situationen auch unterschiedliche Schwellwerte sinnvoll sind. Ein wesentlicher Faktor dabei ist die Graphenstruktur des SSDBN. Die SSDBNs der hier vorgestellten Situationen  $S^1$  bis  $S^{12}$  besitzen insgesamt vier unterschiedliche Graphenstrukturen. Diese sind auch aus den einzelnen Abbildungen der SNs in Anhang A zu entnehmen. Tabelle 6.8 zeigt deren Gruppierung.

**Tabelle 6.8.:** Gruppierung der einzelnen Situationen nach ihrer identischen Graphenstruktur.

Struktur A	$S^1$
Struktur B	$S^2, S^4, S^5, S^6, S^7$
Struktur C	$S^3, S^{10}, S^{11}, S^{12}$
Struktur D	$S^8, S^9$

Zu diesen vier Gruppen wurden jeweils die Genauigkeit und die Trefferquote bezüglich des logischen Schließens und in Abhängigkeit des Schwellwertes berechnet [Moe06; Dav06]. Zur Berechnung dieser Werte wurden die in Tabelle 6.9 aufgelisteten Häufigkeiten verwendet.

**Tabelle 6.9.:** Verwendete Bezeichnungen der Häufigkeiten.

	Logik=1	Logik=0
SSDBN=1	richtig positiv (RP)	falsch positiv (FP)
SSDBN=0	falsch negativ (FN)	richtig negativ (RN)

Für jeden Schwellwert zwischen 0 und 1 wurden diese Häufigkeiten ermittelt und anschließend die Genauigkeit und die Trefferquote für diesen Schwellwert mit den Gleichungen (6.41) und (6.42) berechnet [Moe06].

$$\text{Genauigkeit} = \frac{RP}{RP + FP}. \quad (6.41)$$

$$\text{Trefferquote} = \frac{RP}{RP + FN}. \quad (6.42)$$

Die Genauigkeit entspricht also der Wahrscheinlichkeit, dass die Existenz einer Situation bezüglich des SSDBN auch hinsichtlich des logischen Schließens existiert. Die Trefferquote entspricht der Wahrscheinlichkeit, dass die Existenz einer Situation bezüglich des logischen Schließens auch mittels des SSDBN erkannt wird. Wären also beide Kennzahlen Eins, so würden sowohl die SSDBNs als auch der logische Schluss die identischen Situationsexistenzen liefern.

Um ein einzelnes Maß für die Beurteilung zu erhalten, wird oft das F-Maß verwendet. Dieses berechnet sich als das harmonische Mittel aus Genauigkeit und Trefferquote [Moe06]:


$$F = \frac{2 \cdot \text{Genauigkeit} \cdot \text{Trefferquote}}{\text{Genauigkeit} + \text{Trefferquote}}. \quad (6.43)$$

Das F-Maß kann also als ein Ähnlichkeitsmaß zwischen den Ergebnissen des logischen Schließens und den Ergebnissen mit den SSDBN interpretiert werden. Abbildungen 6.17 bis 6.20 zeigen jeweils die Genauigkeit, die Trefferquote und das F-Maß für die einzelnen Graphenstrukturen in Abhängigkeit des Schwellwertes. Den Abbildungen ist deutlich zu entnehmen, dass sich Genauigkeit und Trefferquote jeweils an anderen Werten für den Schwellwert schneiden.


Werden Genauigkeit und Trefferquote zur Bewertung von Klassifikatoren herangezogen, so kommt es auf die Anwendung an, ob eher eine hohe Genauigkeit oder eine hohe Trefferquote gewünscht ist. Ist es entscheidend, Fehldetektionen zu minimieren, so ist das Ziel, einen hohen Genauigkeitswert zu erhalten. Ist es entscheidend, möglichst keine fehlenden Detektionen zu haben, so ist das Ziel, eine möglichst hohe Trefferquote zu erhalten [Moe06].

Hier ist zu bemerken, dass die Ergebnisse des logischen Schließens keiner Annotation der tatsächlich zu erkennenden Situationen entsprechen. Der logische Schluss entspricht also nicht einer Referenz für die korrekte Klassifikation, wie sie für die Bewertung von Klassifikatoren eingesetzt wird. Vielmehr soll das logische Schließen als eine dem Menschen verständliche Annotation verwendet werden, um die Ergebnisse des SSDBN mit dieser vergleichen zu können und insbesondere die Unterschiede zu verdeutlichen. Das Ziel ist also nicht, möglichst nahe an die Ergebnisse des logischen Schließens heranzukommen.


Das relativ niedrige Maximum des F-Maßes in Abbildung 6.19 ist also nicht als ein schlechtes Ergebnis zu bewerten. Vielmehr ist es für die Situationen mit der Graphenstruktur C so, dass sehr viele vereinzelt Detektionen ausgefiltert werden und deshalb insgesamt die Genauigkeit hinsichtlich des logischen Schließens sehr niedrig ist. Die Genauigkeiten der Situationen mit den Strukturen A, B und D zeigen in den Abbildungen 6.17, 6.18 und 6.20 jeweils relativ hohe Werte für das F-Maß. Dies weist darauf hin, dass diese Ergebnisse wesentlich ähnlicher zu den Ergebnissen des logischen Schließens sind.




**Abbildung 6.17.:** Genauigkeit, Trefferquote und F-Maß für Situationen mit der Graphenstruktur A ( $S^1$ ) in Abhängigkeit des Schwellwertes.



**Abbildung 6.18.:** Genauigkeit, Trefferquote und F-Maß für Situationen der Graphenstruktur B ( $S^2, S^4, S^5, S^6, S^7$ ) in Abhängigkeit des Schwellwertes.



**Abbildung 6.19.:** Genauigkeit, Trefferquote und F-Maß für Situationen der Graphenstruktur C ( $S^3, S^{10}, S^{11}, S^{12}$ ) in Abhängigkeit des Schwellwertes.



**Abbildung 6.20.:** Genauigkeit, Trefferquote und F-Maß für Situationen der Graphenstruktur D ( $S^8, S^9$ ) in Abhängigkeit des Schwellwertes.

## 6.3. Benutzerstudie

### 6.3.1. Aufgabenstellung

In einer Nutzerstudie wurden die Arbeitsbeanspruchung der Nutzer bei der Verwendung von automatischen Situationsanalysediensten und die Akzeptanz solcher Unterstützungsfunktionen seitens der Nutzer untersucht [Fis12b]. Acht nicht fachkundige Versuchspersonen mussten dabei jeweils ein Szenario mit und ein Szenario ohne die Unterstützungsfunktion bearbeiten. Die Benutzeroberfläche war dabei wie in Abbildung 6.21 gestaltet.

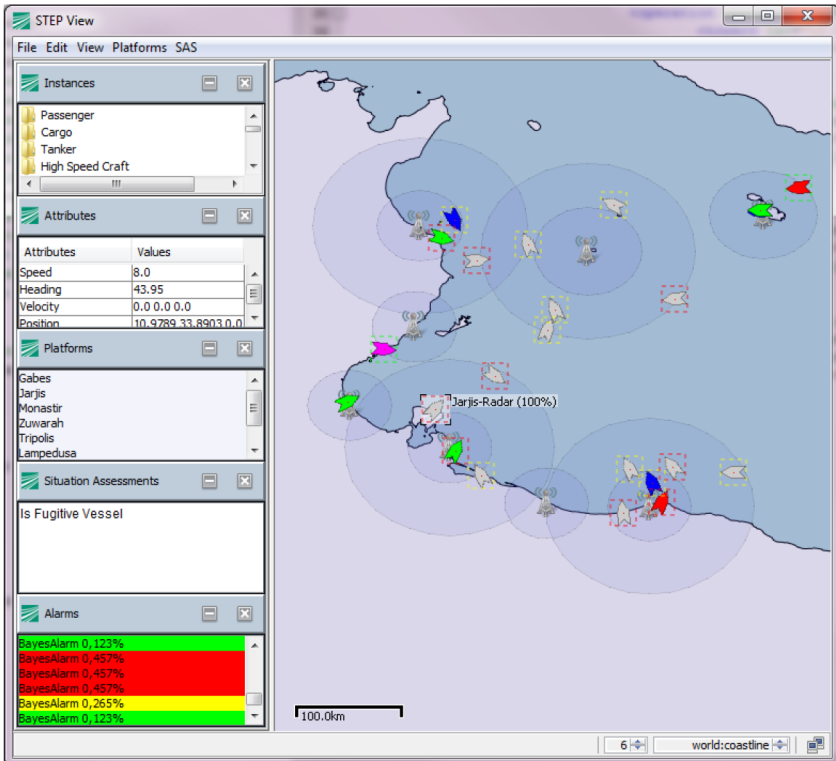


Abbildung 6.21.: Benutzeroberfläche zur Nutzerstudie.

Die Aufgabe selbst für die Nutzer war in jedem Szenario dieselbe und wurde dabei wie folgt beschrieben:

»In einem Kontrollzentrum wird ein Lagebild über den aktuellen Schiffsverkehr dargestellt. Der Entscheider in solch einer Kontrollstation muss nun aufgrund der ihm zur Verfügung stehenden Informationen Entscheidungen fällen. Anhand der beobachteten Objekteigenschaften sollen verdächtige Flüchtlingsboote identifiziert werden. Zur Kontrolle hat man 3 Boote der Küstenwache zur Verfügung, mit denen man die Schiffe vor Ort überprüfen kann. Zu welchen 3 beobachteten Schiffen sollen die Boote der Küstenwache entsendet werden?«

Dabei wurden die Nutzer über die folgenden Eigenschaften von Flüchtlingsbooten informiert:


- das Schiff sendet keine AIS-Daten,
- die Länge beträgt weniger als 20 Meter,
- die Geschwindigkeit beträgt weniger als 10 Knoten,
- das Schiff startet von der afrikanischen Küste, meist Libyen oder Tunesien,
- das Schiff fährt Richtung Lampedusa.

Die Nutzer konnten in der dynamischen Kartenansicht einzelne Schiffe selektieren und deren Attribute betrachten (Geschwindigkeit, AIS-Information, usw.). Bei einem eingefärbten Schiffssymbol (nicht grau) ist die AIS-Information zu dem Schiff verfügbar und das Symbol repräsentiert eine Schiffsklasse (Tanker, Frachter, Passagierschiff, usw.). Die Nutzer hatten zur Bearbeitung der Aufgabe beliebig viel Zeit zur Verfügung. Da die Schiffe sich in dem angezeigten Maßstab relativ langsam bewegten, gerieten die Nutzer demnach auch nicht unter Zeitdruck.

Wenn die Nutzer die Situationsanalyse als Unterstützung zur Verfügung hatten, dann hatten diese noch eine weitere Zusatzinformation zu den einzelnen Schiffen verfügbar. Diese Zusatzinformation beinhaltete das Ergebnis des automatischen Verfahrens, welches als blinkende Box um die Schiffe visualisiert wurde. Dabei wurde folgende Farbkodierung verwendet:

- rote Box: Wahrscheinlichkeit für ein Flüchtlingsboot hoch,
- gelbe Box: Wahrscheinlichkeit für ein Flüchtlingsboot mittel,
- grüne Box: Wahrscheinlichkeit für ein Flüchtlingsboot gering,
- keine Box: Wahrscheinlichkeit für ein Flüchtlingsboot quasi Null.

Die Wahrscheinlichkeit, welche der Situationsanalysedienst berechnete, wurde zusätzlich in der Oberfläche angezeigt (Fenster links unten in Abbildung 6.21). Die Wahrscheinlichkeit selbst wurde mit einem Bayes'schen Netz, wie in Abbildung 6.22 dargestellt, berechnet. Die Parameter wurden dabei manuell gesetzt.



**Abbildung 6.22.:** Bayes'sches Netz, welches für die Benutzerstudie verwendet wurde.

### 6.3.2. Arbeitsbeanspruchung


Für die Berechnung der Arbeitsbeanspruchung wurde eine Modifikation des in Abschnitt 2.1.2 vorgestellten NASA Task Load Index (TLX) verwendet. Dabei wurden fünf Fragen gestellt, wobei die Frage nach der physischen Beanspruchung hier im Gegensatz zum originalen NASA TLX nicht gestellt wurde:

- Mentale Beanspruchung: In welchem Ausmaß beinhaltete die Aufgabe geistige Tätigkeiten und Wahrnehmungsvorgänge (Denken, Entscheiden, Rechnen, Erinnern, Beobachten, Suchen usw.)?
- Zeitliche Beanspruchung: Wie hoch war die zeitliche Anforderung der Aufgabe?




- **Leistung:** Wie gut ist es Ihnen Ihrer Ansicht nach gelungen, das vom Versuchsleiter gesetzte Aufgabenziel zu erreichen? In welchem Ausmaß waren Sie bei der Verfolgung dieser Ziele mit Ihrer Leistung zufrieden?
- **Anstrengung:** Wie hart mussten Sie arbeiten (geistig und körperlich), um Ihr Leistungsniveau zu erreichen?
- **Frustrationsniveau:** Wie verunsichert, entmutigt, irritiert, gestresst und verärgert waren Sie?

Die Beantwortung der Fragen erfolgte jeweils über eine Skala von 1 bis 5 (niedrig bis hoch bzw. gut bis schlecht). Die gemittelten Ergebnisse zu diesen Fragen sind in Abbildung 6.23 visualisiert, wobei die Werte auf eine Skala von 0-100 skaliert worden sind. Die Werte sind so zu interpretieren, dass niedrigere Werte als bessere Ergebnisse anzusehen sind. Die absoluten Werte sind innerhalb der Balken notiert. Bei näherer Betrachtung der Ergebnisse ist zu sehen, dass in vier von fünf Fragen die Bearbeitung mit der Unterstützungsfunktion bessere Ergebnisse liefert. Einzig die Einschätzung nach der eigenen Leistung ist geringfügig schlechter bei der Aufgabenbearbeitung mit der Unterstützungsfunktion.



**Abbildung 6.23.:** NasaTLX Ergebnisse (niedrigere Werte zeigen bessere Ergebnisse).

Basierend auf diesen Ergebnissen wurde die Arbeitsbeanspruchung durch eine Mittelwertbildung mit gleichen Gewichtsanteilen berechnet, siehe Gleichung (2.2). Die Ergebnisse sind in Abbildung 6.24 visualisiert. Insgesamt ergibt sich eine Arbeitsbelastung von 38 % mit und 46 % ohne Verwendung der Unterstützungsfunktion, d.h. die Arbeitsbeanspruchung bei der Verwendung der Unterstützungsfunktion ist geringer.



**Abbildung 6.24.:** Aus dem NASA TLX berechnete Arbeitsbeanspruchung (niedrigere Werte zeigen bessere Ergebnisse).


### 6.3.3. Akzeptanz

Bezüglich der Akzeptanz der Unterstützungsfunktion wurden den Benutzern folgende Fragen gestellt:

- Wie lange empfanden Sie die Einarbeitungszeit in das System?
- Wie einfach war das System zu bedienen?
- Wie hilfreich fanden Sie die Farbkodierung (grün, gelb, rot) der Unterstützungsfunktion für die Lösung der Aufgabe?

- Wie hilfreich fanden Sie die Angabe des Wahrscheinlichkeitswertes für die Lösung der Aufgabe?
- Wie hilfreich fanden Sie generell die Unterstützungsfunktion für die Lösung der Aufgabe?

Die Beantwortung der Fragen erfolgte jeweils über eine Skala von 1 bis 5 (lang bis kurz bzw. schwer bis einfach bzw. nicht hilfreich bis hilfreich). Die Ergebnisse dieser Fragen sind in Abbildung 6.25 dargestellt, wobei die Werte auf eine Skala von 0-100 skaliert worden sind, und in diesem Fall höhere Werte als bessere Ergebnisse zu interpretieren sind. Bei näherer Betrachtung der Ergebnisse ist zu sehen, dass alle Fragen eine relativ hohe Bewertung erhalten haben, speziell die Farbkodierung der einzelnen Schiffe. Einzig die Anzeige der tatsächlichen Wahrscheinlichkeiten empfanden die Nutzer als nicht hilfreich. Der Grund für den niedrigen Wert kann am Design der Oberfläche liegen. Da der Benutzer die Aufmerksamkeit hauptsächlich auf die Kartendarstellung lenkt, ist es für ihn sehr aufwändig, die Wahrscheinlichkeiten in der unteren linken Ecke zu lesen. Die Nutzer merkten an, dass Sie die Wahrscheinlichkeiten oft auch gar nicht betrachtet hätten.



**Abbildung 6.25.:** Akzeptanz der automatischen Situationsanalyse (höhere Werte zeigen bessere Ergebnisse).

Generell wurde der Nutzen der Unterstützungsfunktion mit einem Wert von 84 % als sehr hoch eingestuft und alle Versuchspersonen würden die Arbeit mit der Funktion bevorzugen. Die Ergebnisse der Studie zeigen, dass eine solche Funktion von Benutzern akzeptiert wird und sie diese auch als Entlastung, d.h. als Reduktion ihrer Beanspruchung verstehen, auch wenn den Nutzern selbst nicht genau bekannt ist, wie die Wahrscheinlichkeiten im Hintergrund berechnet wurden.

## 6.4. Zusammenfassung

In diesem Kapitel wurde die in dieser Arbeit entwickelte Methodik auf drei unterschiedliche Arten evaluiert. In der ersten Evaluierung wurde eine Schmutzbootssituation modelliert und mit simulierten Daten hinsichtlich der Robustheit und des Sprungverhaltens untersucht. Hier zeigte sich, dass das Verfahren sowohl die nötige Robustheit als auch das anvisierte Sprungverhalten liefert. In der zweiten Evaluierung wurden reale Daten verwendet. Dazu wurden zwölf unterschiedliche Situationen als gemeinsame Wissensbasis und als einzelne Situationsnetzwerke modelliert und die entsprechenden SSDBNs erzeugt. Diese SSDBNs wurden auf die realen Daten angewandt und die entsprechenden Existenzwahrscheinlichkeiten über die Zeit hinweg berechnet. Die exemplarischen Beispiele bestätigen das Verhalten, welches mit den simulierten Daten erzielt wurde. Die Ergebnisse der SSDBN wurden mit den Ergebnissen des deduktiven logischen Schließens verglichen. Dabei zeigten sich teilweise deutliche Unterschiede anhand der Genauigkeit und der Trefferquote. Dieser Unterschied ist jedoch beabsichtigt, da dieser genau aus der Filterfunktion des SSDBN resultiert. Abschließend wurde in einer Benutzerstudie die Arbeitsbeanspruchung der Nutzer bei der Verwendung eines Situationsanalysedienstes und die Akzeptanz einer solchen Funktionalität seitens der Nutzer untersucht. Dabei bestätigte sich die Grundmotivation der Arbeit, nämlich dass der Einsatz des in dieser Arbeit entwickelten Verfahrens die Arbeitsbeanspruchung senkt und damit als wesentlicher Faktor das Situationsbewusstsein von Entscheidern unterstützt.

# 7

---

## Schlussbetrachtungen

---

### 7.1. Zusammenfassung

In der vorliegenden Arbeit wurde ein Konzept zur probabilistischen Situationsanalyse entwickelt und evaluiert. Dazu wurde zunächst der Begriff der Situation formalisiert und definiert. Eine Situation wurde dabei als binäre Zufallsvariable modelliert und deren Existenz als Wahrscheinlichkeitsverteilung definiert. Diese Formalisierung war bisher in der Literatur so nicht existent. Auf Basis dieser Definition wurde eine Wissensmodellierung entwickelt, welche es Domänenexperten erlaubt, Situationen von Interesse zu modellieren. Dabei wurden einerseits die Situationen selbst modelliert, aber auch die Abhängigkeiten zwischen Situationen. Insbesondere wurden in dieser Arbeit unterschiedliche Abstraktionsebenen herausgearbeitet, in denen sich Situationen beschreiben lassen. Grundsätzlich lassen sich Situationen in zwei Klassen unterteilen: in elementare Situationen und in abstrakte Situationen. Die Abhängigkeiten zwischen Situationen wurden auf zwei Arten ermöglicht, einerseits als notwendige Bedingung und andererseits als hinreichende Bedingung.

Für diese Modellierung einer Situation wurde der Begriff der formalisierten semantischen Aussage definiert. Dabei bilden mehrere formalisierte semantische Aussagen eine Wissensbasis oder auch eine gemeinsame Wissensbasis mehrerer Situationen. Ist die Wissensbasis vollständig, also existiert zu jeder abstrakten Situation in der Wissensbasis eine formalisierte semantische

Aussage, so kann die Wissensbasis als Situationsnetzwerk repräsentiert werden. Insbesondere muss das Situationsnetzwerk zur weiteren Verwendung wohldefiniert sein, d.h. es darf keine Zyklen besitzen.

Einer der wesentlichen Beiträge dieser Arbeit ist die Generierung eines probabilistischen graphischen Modells, basierend auf der Modellierung des Situationsnetzwerks. Dieses Modell, ein situationsspezifisches dynamisches Bayes'sches Netz (SSDBN), kann dann in der Anwendung als Echtzeitauswertemodul eingesetzt werden. Zur Generierung des SSDBN wurde zunächst die Struktur aus dem Situationsnetzwerk übernommen. Die besondere Herausforderung für die Arbeit lag darin, dass keine Trainingsdaten verwendet werden sollten, um die Modellparameter zu bestimmen.

Um die Entwicklung eines Black-Box-Verfahrens zu vermeiden, wurden mehrere Erwartungen an das Verhalten des SSDBN formuliert. Zum einen sollte es eine gewisse Robustheit gegenüber Fehldetektionen zeigen und zum anderen ein Sprungverhalten bei wechselnden Evidenzen aufweisen. Des Weiteren wurde die Verwendung von Vorwissen innerhalb eines SSDBN möglich gemacht. Das Einhalten der Stationaritäts-Bedingung gewährleistet, dass sich das SSDBN bei ausbleibenden Beobachtungen stets bei der A-priori-Verteilung einpendelt. Unter diesen Voraussetzungen wurden unter Einsatz eines Optimierungsverfahrens die optimalen Parameter gewählt. Die Berechnung der Parameter selbst wurde mittels eines generalisierten linearen Modells durchgeführt. Insgesamt sind zur Generierung der Parameter nur zwei Werte von dem Domänenexperten vorzugeben.

Die abschließende Evaluierung zeigte die Funktionsweise des SSDBN am Beispiel der maritimen Überwachung auf. Zum einen wurde mit simulierten Daten speziell die Robustheit und das Sprungverhalten untersucht und gezeigt, dass das SSDBN das gewünschte Verhalten aufzeigt. Zum anderen wurden mit realen Daten umfassende Ergebnisse zu zwölf modellierten Situationen erzeugt. Ausgewählte Beispiele zeigen die Ergebnisse der SSDBN im Vergleich zum deduktiven logischen Schließen und belegen auch hier das gewünschte Verhalten. Um diesen Vergleich besser hervorzuheben, wurden für alle Ergebnisse Ähnlichkeitsmaße berechnet, wie sie üblicherweise bei der Bewertung von Klassifikatoren eingesetzt werden. Diese Ergebnisse zeigten, dass sich die probabilistische Inferenz mittels des SSDBN wesentlich vom logischen Schließen unterscheiden kann. Dies ist jedoch nicht als Nachteil zu interpretieren. Im Gegenteil, diese Ergebnisse zeigten besonders die Vorteile des Filtereffektes des SSDBN, also die Kompensation von Fehldetektionen auf.

Um den Nutzen eines Situationsanalysedienstes nachzuweisen, wurde eine Benutzerstudie durchgeführt. Die Nutzer mussten dabei eine Überwachungsaufgabe bewältigen und abschließend einen Fragebogen zur empfundenen Beanspruchung beantworten. Hierbei zeigte sich deutlich, dass eine solche Unterstützungsfunktion von den Nutzern eine hohe Akzeptanz erfährt und zudem die Arbeitsbeanspruchung senken kann.

## 7.2. Ausblick

Für den praktischen Einsatz der hier vorgestellten Vorgehensweise ist im nächsten Schritt eine benutzerfreundliche Oberfläche für die wissensbasierte Modellierung der Situationen bzw. der Wissensbasis zu entwerfen. Insbesondere sollten schon im Modellierungsschritt Inkonsistenzen in der Wissensbasis detektiert werden und der Nutzer darauf aufmerksam gemacht werden. Grundsätzlich spräche auch nichts dagegen, ein Werkzeug für die Erstellung von Ontologien zu verwenden, da diese bereits eine Konsistenzprüfung beinhalten. Da solche Werkzeuge bereits existieren, wurde diese Problematik in dieser Arbeit nicht weiter behandelt. Eine solche Benutzeroberfläche sollte in jedem Fall mit maritimen Endanwendern evaluiert werden.

In einem weiteren Schritt könnte die Optimierung der Parameter verbessert werden, da diese teilweise sehr viel Zeit in Anspruch nimmt. Die Berechnungszeit für die Optimierung ist dabei stark abhängig von der Struktur des SSDBN bzw. der Anzahl der Knoten und kann von einigen Minuten bis hin zu wenigen Stunden dauern. Diese Zeitspanne ist für den praktischen Einsatz nicht akzeptabel. Würde man zusätzlich noch eine Optimierung über mehr als zwei Gewichte in Betracht ziehen, also beispielsweise eine Optimierung für jede einzelne Kante des SSDBN, so würde dies die Komplexität noch einmal erheblich steigern. Hier wäre beispielsweise eine Methodik zu finden, wie das Optimierungsproblem ausreichend gut und in akzeptabler Zeit zu lösen wäre.

Ist das SSDBN einmal erstellt, so ist dessen Anwendung in Echtzeit möglich. Dazu können auch exakte Inferenzalgorithmen verwendet werden, da die Anzahl der Knoten in dieser Anwendung meist überschaubar ist. Für den praktischen Einsatz von bereits erstellten SSDBN müssten also nur die entsprechenden Schnittstellen in vorhandenen maritimen Systemen geschaffen bzw. die Situationserkennung als Modul integriert werden.

Insgesamt können die Konzeptentwicklungen und Untersuchungen in dieser Arbeit die Basis für den praktischen Einsatz von Situationsanalysediensten in den unterschiedlichsten Domänen liefern. Bedarf besteht hier neben der maritimen Domäne unter anderem in der Robotik, der Fahrzeugführung oder auch in der Videoüberwachung.



---

# Literaturverzeichnis

---

- [Abi92] M. A. ABIDI und R. C. GONZALEZ.: *Data Fusion in Robotics and Machine Intelligence*. Academic Press Professional, Inc, 1992.
- [Abi13] R. ABIELMONA: »Tackling Big Data in Maritime Domain Awareness«. *Vanguard - The Forum for Canada's Security and Defence Community, Ausgabe August/September*. <http://vanguardcanada.uberflip.com/i/155544-aug-sep-2013/41/>, letzter Abruf am 14.05.2015. 2013: S. 42–43.
- [Abi14] R. ABIELMONA, R. FALCON, P. VACHON und V. GROZA: »Vessel Tracking and Anomaly Detection using Level 0/1 and High-Level Information Fusion Techniques«. *Proceedings of the 6th International Workshop on Soft Computing Applications (SOFA)*. 2014.
- [Alb02] J. S. ALBUS: »4D/RCS: A Reference Model Architecture for Intelligent Unmanned Ground Vehicles«. *Proc. SPIE 4715, Unmanned Ground Vehicle Technology IV*, 303. 2002: S. 303–310.
- [All83] J. F. ALLEN: »Maintaining Knowledge about Temporal Intervals«. *Communications of the ACM* (1983), Bd. 26(11): S. 832–843.
- [And10] M. ANDERSSON und R. JOHANSSON: »Multiple Sensor Fusion for Effective Abnormal Behaviour Detection in Counter-Piracy Operations«. *Proceedings of the 2nd International Conference on Waterside Security (WSS)*. 2010: S. 1–7.
- [Ang92] E. ANGELOPOULOU, T.-H. HONG und A. Y. WU: »World Model Representations for Mobile Robots«. *Proceedings of the Intelligent Vehicles '92 Symposium*. 1992: S. 293–297.

- [Aus11] B. AUSLANDER, K. M. GUPTA und D. W. AHA: »A Comparative Evaluation of Anomaly Detection Algorithms for Maritime Video Surveillance«. *Proc. SPIE 8019, Sensors, and Command, Control, Communications, and Intelligence (C3I) Technologies for Homeland Security and Homeland Defense X, 801907*. 2011: S. 1–14.
- [Aus12] B. AUSLANDER, K. M. GUPTA und D. W. AHA: »Maritime Threat Detection Using Probabilistic Graphical Models«. *Proceedings of the 25th International Florida Artificial Intelligence Research Society Conference (FLAIRS)*. 2012: S. 2–7.
- [Azu99] F. AZUAJE, W. DUBITZKY, N. BLACK und K. ADAMSON: »Improving Clinical Decision Support through Case-Based Data Fusion«. *IEEE Transactions on Biomedical Engineering* (1999), Bd. 46(10): S. 1181–1185.
- [Bai05] N. BAILEY: »Training, Technology and AIS: Looking Beyond the Box«. *Proceeding of The Seafarers International Research Centre's Fourth International Symposium*. 2005: S. 108–128.
- [Bal09] J.-F. BALMAT, F. LAFONT, R. MAIFRET und N. PESSSEL: »MARitime RiSk Assessment (MARISA), a Fuzzy Approach to define an individual Ship Risk Factor«. *Ocean Engineering* (2009), Bd. 36(15-16): S. 1278–1286.
- [Bar07] J. BARRHO: »Sensor- und bildverarbeitungsgestützte Erkennung von Gefahrensituationen«. Diss. Universität Karlsruhe (TH), 2007.
- [Bar89] J. BARWISE: *The Situation in Logic*. Center for the Study of Language und Information, 1989.
- [Bau08] A. BAUER, S. ECKEL, T. EMTER, A. LAUBENHEIMER, E. MONARI, J. MOSSGRABER und F. REINERT: »N.E.S.T. - Network Enabled Surveillance and Tracking«. *Proceedings of the 3rd Security Research Conference (Future Security)*. Fraunhofer Press, 2008: S. 349–353.
- [Bau09] A. BAUER, T. EMTER, H. VAGTS und J. BEYERER: »Object-Oriented World Model for Surveillance Systems«. *Proceedings of the 4th Security Research Conference (Future Security)*. Fraunhofer Press, 2009: S. 339–345.

- [Bau10a] A. BAUER und Y. FISCHER: »Task-Oriented Situation Recognition«. *Proc. SPIE 7709, Cyber Security, Situation Management, and Impact Assessment II; and Visual Analytics for Homeland Defense and Security II*. Hrsg. von J. F. BUFORD, G. JAKOBSON, J. ERICKSON, W. J. TOLONE und W. RIBARSKY. Bd. 770906. SPIE, 2010: S. 1–9.
- [Bau10b] M. BAUM, I. GHETA, A. BELKIN, J. BEYERER und U. D. HANEBECK: »Data Association in a World Model for Autonomous Systems«. *Proceedings of the IEEE Conference on Multisensor Fusion and Integration for Intelligent Systems (MFI)*. 2010: S. 187–192.
- [Bec00] J. C. BECKER und A. SIMON: »Sensor and Navigation Data Fusion for an Autonomous Vehicle«. *Proceedings of the IEEE Intelligent Vehicles Symposium*. 2000: S. 156–161.
- [Bed99] M. BEDWORTH und J. O’BRIEN: »The Omnibus Model: A New Model of Data Fusion?« *Proceedings of the 2nd International Conference on Information Fusion (FUSION)*. 1999.
- [Bel12a] A. BELKIN und J. BEYERER: »Prior Knowledge Employment Based on the K-L and Tanimoto Distances Matching for Intelligent Autonomous Robots«. *Intelligent Robotics and Applications*. Hrsg. von C.-Y. SU, S. RAKHEJA und H. LIU. Bd. 7508. Lecture Notes in Computer Science. Springer, 2012: S. 171–180.
- [Bel12b] A. BELKIN, A. KUWERTZ, Y. FISCHER und J. BEYERER: »World Modeling for Autonomous Systems«. *Innovative Information Systems Modelling Techniques*. Hrsg. von D. C. KALLONIATIS. <http://www.intechopen.com/books/innovative-information-systems-modelling-techniques/world-modelling-for-autonomous-systems>, letzter Abruf am 14.05.2015. InTech, 2012. Kap. 7: S. 137–158.
- [Bey08] J. BEYERER und J. GEISLER: »Next Generation Video Surveillance Systems«. *Proceedings of the 3rd Security Research Conference (Future Security)*. Fraunhofer Press, 2008: S. 155–160.
- [Bey07] J. BEYERER, J. SANDER und S. WERLING: »Bayes’sche Methodik zur lokalen Fusion heterogener Informationsquellen«. *tm - Technisches Messen* (2007), Bd. 74(3): S. 103–111.
- [Bib93] W. BIBEL: *Wissensrepräsentation und Inferenz*. Vieweg, 1993.

- [Bis06] C. M. BISHOP: *Pattern Recognition and Machine Learning*. Springer, 2006.
- [Bla12a] E. BLASCH, E. BOSSE und D. LAMBERT: *High-Level Information Fusion: Management and Systems Design*. Artech House, Inc., 2012.
- [Bla12b] E. BLASCH, P. VALIN, A.-L. JOUSSELME, D. LAMBERT und E. BOSSE: »Top ten trends in High-Level Information Fusion«. *Proceedings of the 15th International Conference on Information Fusion (FUSION)*. 2012: S. 2323–2330.
- [Bom06] N. A. BOMBERGER, B. J. R. and Michael SEIBERT und A. M. WAXMAN: »Associative Learning of Vessel Motion Patterns for Maritime Situation Awareness«. *Proceedings of the 9th International Conference on Information Fusion (FUSION)*. 2006: S. 1–8.
- [Bra09] C. BRAX und L. NIKLASSON: »Enhanced Situational Awareness in the Maritime Domain: An Agent-based Approach for Situation Management«. *Proc. SPIE 7352, Intelligent Sensing, Situation Management, Impact Assessment, and Cyber-Sensing, 735203*. 2009: S. 1–10.
- [Bra08] C. BRAX, L. NIKLASSON und M. SMEDBERG: »Finding Behavioural Anomalies in Public Areas using Video Surveillance Data«. *Proceedings of the 11th International Conference on Information Fusion*. 2008: S. 1–8.
- [Bro11] A. C. van den BROEK, R. M. NEEF, P. HANCKMANN, S. P. van GOSLIGA und D. van HALSEMA: »Improving Maritime Situational Awareness by Fusing Sensor Information and Intelligence«. *Proceedings of the 14th International Conference on Information Fusion (FUSION)*. 2011: S. 1–8.
- [Bro14] B. van den BROEK, A. SMITH, E. den BREEJEN und I. van de VOORDE: »Inference of Vessel Intent and Behaviour for Maritime Security Operations«. *Proc. SPIE 9248, Unmanned/Unattended Sensors and Sensor Networks X, 92480E*. 2014: S. 1–12.

- [BSI06] BSI: BUNDESAMT FÜR SICHERHEIT IN DER INFORMATIONSTECHNIK: *Pervasive Computing: Entwicklungen und Auswirkungen*. [https://www.bsi.bund.de/SharedDocs/Downloads/DE/BSI/Publikationen/Studien/Percenta/Percenta\\_dlay\\_pdf.pdf?\\_\\_blob=publicationFile](https://www.bsi.bund.de/SharedDocs/Downloads/DE/BSI/Publikationen/Studien/Percenta/Percenta_dlay_pdf.pdf?__blob=publicationFile), letzter Abruf am 14.05.2015. 2006.
- [Bul13] H.-J. BULLINGER: *Ergonomie: Produkt- und Arbeitsplatzgestaltung*. Bd. Neuausgabe. unter Mitarbeit von and Rolf Ilg und Marin Schmauder. Springer Fachmedien, 2013.
- [Car07] C. CARTHEL, S. CORALUPPI und P. GRIGNAN: »Multisensor tracking and fusion for maritime surveillance«. *Proceedings of the 10th International Conference on Information Fusion (FUSION)*. 2007: S. 1–6.
- [Car11] R. N. CARVALHO, R. HABERLIN, P. C. COSTA, K. B. LASKEY und K. C. CHANG: »Modeling a Probabilistic Ontology for Maritime Domain Awareness«. *Proceedings of the 14th International Conference on Information Fusion (FUSION)*. 2011: S. 1–8.
- [Car10] R. CARVALHO, K. LASKEY, P. COSTA, M. LADEIRA, L. SANTOS und S. MATSUMOTO: »UnBBayes: Modeling Uncertainty for Plausible Reasoning in the Semantic Web«. *Semantic Web*. Hrsg. von G. WU. <http://www.intechopen.com/books/semantic-web/unbbayes-modeling-uncertainty-for-plausible-reasoning-in-the-semantic-web>, letzter Abruf am 14.05.2015. InTech, 2010. Kap. 1: S. 1–26.
- [Cha12] P. CHAHUARA, A. FLEURY, F. PORTET und M. VACHER: »Using Markov Logic Network for On-Line Activity Recognition from Non-visual Home Automation Sensors«. *Proceedings of the 3rd International Joint Conference on Ambient Intelligence (AMI)*. 2012: S. 177–192.
- [Cha09] V. CHANDOLA, A. BANERJEE und V. KUMAR: »Anomaly Detection: A Survey«. *ACM Computing Surveys (CSUR)* (2009), Bd. 41(3): 15:1–15:58.
- [Che14] C.-H. CHEN, L. P. KHOO, Y. T. CHONG und X. F. YIN: »Knowledge Discovery using Genetic Algorithm for Maritime Situational Awareness«. *Expert Systems with Applications* (2014), Bd. 41(6): S. 2742–2753.

- [Coo90] G. F. COOPER: »The Computational Complexity of Probabilistic Inference using Bayesian Belief Networks«. *Artificial Intelligence* (1990), Bd. 42(2-3): S. 393–405.
- [Cos05] P. C. G. COSTA: »Bayesian Semantics for the Semantic Web«. Diss. George Mason University, 2005.
- [Cos12] P. COSTA, K. LASKEY, K. CHANG, W. SUN, C. PARK und S. MATSUMOTO: »High-Level Information Fusion with Bayesian Semantics«. *Proceedings of the Conference on Uncertainty in Artificial Intelligence (UAI) - 9th Bayesian Modeling Applications Workshop*. 2012: S. 1–10.
- [Cow99] R. G. COWELL, A. P. DAWID, S. L. LAURITZEN und D. J. SPIEGELHALTER: *Probabilistic Networks and Expert Systems*. Springer, 1999.
- [Cro89] J. L. CROWLEY: »World Modeling and Position Estimation for a Mobile Robot Using Ultrasonic Ranging«. *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA)*. 1989: S. 674–680.
- [Dab15] J. J. DABROWSKI und J. P. de VILLIERS: »Maritime Piracy Situation Modelling with Dynamic Bayesian Networks«. *Information Fusion* (2015), Bd. 23: S. 116–130.
- [Dah11] A. DAHLBOM: »Petri nets for Situation Recognition«. Diss. Örebro University, 2011.
- [Dah07] A. DAHLBOM und L. NIKLASSON: »Trajectory Clustering for Coastal Surveillance«. *Proceedings of the 10th International Conference on Information Fusion*. 2007: S. 1–8.
- [Dah09] A. DAHLBOM, L. NIKLASSON, G. FALKMAN und A. LOUTFI: »Towards Template-based Situation Recognition«. *Proc. SPIE 7352, Intelligent Sensing, Situation Management, Impact Assessment, and Cyber-Sensing, 735205*. 2009: S. 1–12.
- [Dar08] M. DARMS, P. RYBSKI und C. URMSON: »Classification and Tracking of Dynamic Objects with Multiple Sensors for Autonomous Driving in Urban Environments«. *Proceedings of the IEEE Intelligent Vehicles Symposium*. 2008: S. 1197–1202.
- [Das08] S. DAS: *High-Level Data Fusion*. Artech House, Inc., 2008.

- [Das01] B. V. DASARATHY: »Information Fusion - What, Where, Why, When, and How?« *Information Fusion* (2001), Bd. 2(2): S. 75–76.
- [Dav06] J. DAVIS und M. GOADRICH: »The Relationship Between Precision-Recall and ROC Curves«. *Proceedings of the 23rd International Conference on Machine Learning (ICML)*. 2006: S. 233–240.
- [Dem77] A. P. DEMPSTER, N. M. LAIRD und D. B. RUBIN: »Maximum-Likelihood from Incomplete Data via the EM Algorithm«. *Journal of the Royal Statistical Society* (1977), Bd. 39(1): S. 1–38.
- [Dev06] K. DEVLIN: »Situation Theory and Situation Semantics«. *Handbook of the History of Logic* (2006), Bd. 7: S. 601–664.
- [Dig13] G. DIGIOIA, C. FOGLIETTA, G. OLIVA, S. PANZIERI und R. SETOLA: »Moving from Measuring to Understanding: Situation Awareness in Homeland Security«. *Effective Surveillance for Homeland Security: Balancing Technology and Social Issues*. CRC Press, 2013. Kap. 10: S. 229–256.
- [DIN95] DIN DEUTSCHES INSTITUT FÜR NORMUNG E.V.: *Grundlagen der Messtechnik DIN 1319-1*. 1995.
- [Dor10] A. DORE, M. SOTO und C. S. REGAZZONI: »Bayesian Tracking for Video Analytics: An overview«. *IEEE Signal Processing Magazine* (2010), Bd. 27(5): S. 46–55.
- [Dou93] C. DOUSSON, P. GABORIT und M. GHALLAB: »Situation Recognition: Representation and Algorithms«. *Proceedings of the 13th International Joint Conference on Artificial intelligence (IJCAI)*. 1993: S. 166–172.
- [Dud01] R. O. DUDA, P. E. HART und D. G. STORK: *Pattern Classification*. John Wiley & Sons, 2001.
- [Dur98] F. T. DURSO, C. A. HACKWORTH, T. R. TRUITT, J. CRUTCHFIELD, D. NIKOLIC und C. A. MANNING: »Situation Awareness As a Predictor of Performance in En Route Air Traffic Controllers«. *Air Traffic Control Quarterly* (1998), Bd. 6(1): S. 1–20.
- [Edl06] J. EDLUND, M. GRÖNKVIST, A. LINGVALL und E. SVIESTINS: »Rule Based Situation Assessment for Sea-Surveillance«. *Proc. SPIE 6242, Multisensor, Multisource Information Fusion: Architectures, Algorithms, and Applications 2006, 624203*. 2006: S. 1–11.

- [Emt08] T. EMTER, I. GHETA und J. BEYERER: »Object Oriented Environment Model for Video Surveillance Systems«. *Proceedings of the 3rd Security Research Conference (Future Security)*. Fraunhofer Press, 2008: S. 155–160.
- [Emt10] T. EMTER, A. SALTOGLU und J. PETEREIT: »Multi-Sensor Fusion for Localization of a Mobile Robot in Outdoor Environments«. *Proceedings of the 41st International Symposium on Robotics (ISR) and 6th German Conference on Robotics (ROBOTIK)*. 2010: S. 662–667.
- [End88] M. R. ENDSLEY: »Situation Awareness Global Assessment Technique (SAGAT)«. *Proceedings of the National Aerospace and Electronics Conference (NAECON)*. IEEE, 1988: S. 789–795.
- [End95a] M. R. ENDSLEY: »Measurement of Situation Awareness in Dynamic Systems«. *Human Factors: The Journal of the Human Factors and Ergonomics Society* (1995), Bd. 37(1): S. 65–84.
- [End95b] M. R. ENDSLEY: »Toward a Theory of Situation Awareness in Dynamic Systems«. *Human Factors: The Journal of the Human Factors and Ergonomics Society* (1995), Bd. 37(1): S. 32–64.
- [End08] M. R. ENDSLEY und E. S. CONNORS: »Situation Awareness: State of the Art«. *Power and Energy Society General Meeting - Conversion and Delivery of Electrical Energy in the 21st Century*. IEEE, 2008: S. 1–4.
- [End11] M. R. ENDSLEY und D. G. JONES: *Designing for Situation Awareness: An Approach to User-Centered Design, Second Edition*. CRC Press, 2011.
- [End97] M. R. ENDSLEY und W. M. JONES: *Situation Awareness Information Dominance & Information Warfare*. Technical Report No. AL/CF-TR-1997-0156. United States Air Force Armstrong Laboratory, 1997.
- [End98] M. R. ENDSLEY, S. J. SELCON, T. D. HARDIMAN und D. G. CROFT: »A comparative analysis of SAGAT and SART for evaluations of situation awareness«. *Proceedings of the Human Factors and Ergonomics Society 42nd Annual Meeting*. 1998: S. 82–86.



- [Eur09] EUROPEAN COMMISSION - MARITIME AFFAIRS AND FISHERIES: *Mitteilung der Kommission - Auf dem Weg zur Integration der Meeresüberwachung: Ein gemeinsamer Informationsraum für den maritimen Bereich der EU*. 2009.
- [Eur10] EUROPEAN COMMISSION - MARITIME AFFAIRS AND FISHERIES: *Integrating Maritime Surveillance: Common Information Sharing Environment (CISE) - Roadmap*. 2010.
- [Eur08] EUROPEAN COMMISSION / JOINT RESEARCH CENTRE ISPRA, ITALY: *Integrated Maritime Policy for the EU - Working Document III on Maritime Surveillance Systems*. 2008.
- [Fal14] R. FALCON, R. ABIELMONA und E. BLASCH: »Behavioral Learning of Vessel Types with Fuzzy-Rough Decision Trees«. *Proceedings of the 17th International Conference on Information Fusion (FUSION)*. 2014: S. 1–8.
- [Fen12] S. FENZ: »An Ontology-based Approach for Constructing Bayesian Networks«. *Data & Knowledge Engineering* (2012), Bd. 73: S. 73–88.
- [Fio12] M. FIORINI: »Maritime Awareness through Data Sharing in VTS Systems«. *Proceedings of the 12th International Conference on ITS Telecommunications*. IEEE, 2012: S. 402–407.
- [Fis10a] Y. FISCHER: »World Modeling for Advanced Surveillance Systems«. *Proceedings of the 2010 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory*. Hrsg. von J. BEYERER und M. HUBER. Bd. 7. Karlsruher Schriften zur Anthropomatik. Technischer Bericht IES-2010-02. KIT Scientific Publishing, 2010: S. 17–30.
- [Fis11a] Y. FISCHER: »Modeling and Recognizing Situations in the Maritime Domain«. *Proceedings of the 2011 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory*. Hrsg. von J. BEYERER und A. PAK. Bd. 11. Karlsruher Schriften zur Anthropomatik. Technischer Bericht IES-2011-02. KIT Scientific Publishing, 2011: S. 19–33.
- [Fis10b] Y. FISCHER und A. BAUER: »Object-Oriented Sensor Data Fusion for Wide Maritime Surveillance«. *Proceedings of the 2nd International Conference on Waterside Security (WSS)*. IEEE, 2010: S. 1–6.

- [Fis11b] Y. FISCHER, A. BAUER und J. BEYERER: »A Conceptual Framework for Automatic Situation Assessment«. *Proceedings of the 1st International Multi-Disciplinary Conference on Cognitive Methods in Situation Awareness and Decision Support (CogSIMA)*. IEEE, 2011: S. 234–239.
- [Fis12a] Y. FISCHER und J. BEYERER: »A Top-Down-View on Intelligent Surveillance Systems«. *Proceedings of the 7th International Conference on Systems (ICONS)*. IARIA, 2012: S. 43–48.
- [Fis12b] Y. FISCHER und J. BEYERER: »Acceptance of Automatic Situation Assessment in Surveillance Systems«. *Proceedings of the 2nd International Multi-Disciplinary Conference on Cognitive Methods in Situation Awareness and Decision Support (CogSIMA)*. IEEE, 2012: S. 324–331.
- [Fis13] Y. FISCHER und J. BEYERER: »Modeling of Expert Knowledge for Maritime Situation Assessment«. *International Journal On Advances in Systems and Measurements* (2013), Bd. 6(3&4). [http://www.iariajournals.org/systems\\_and\\_measurements](http://www.iariajournals.org/systems_and_measurements), letzter Abruf am 14.05.2015: S. 245–259.
- [Fis14a] Y. FISCHER, E. KREMPEL, P. BIRNSTILL, G. UNMÜSSIG, E. MONARI, J. MOSSGRABER, M. SCHENK und J. BEYERER: »Privacy-Aware Smart Video Surveillance Revisited«. *Proceedings of the 9th Security Research Conference (Future Security)*. Fraunhofer Verlag, 2014: S. 91–99.
- [Fis14b] Y. FISCHER, A. REISWICH und J. BEYERER: »Modeling and Recognizing Situations of Interest in Surveillance Applications«. *Proceedings of the 4th International Multi-Disciplinary Conference on Cognitive Methods in Situation Awareness and Decision Support (CogSIMA)*. IEEE, 2014: S. 186–192.
- [Flo09] M. C. FLOREA und É. BOSSÉ: »Crisis Management Using Dempster Shafer Theory: Using Dissimilarity Measures to Characterize Sources' Reliability«. *Proceedings of the NATO Symposium on C3I for Crisis, Emergency and Consequence Management (RTO-MP-IST-086)*. NATO Information Systems und Technology Panel (IST). 2009: S. 1–14.

- [Foo13] P. H. FOO und G. W. NG: »High-level Information Fusion: An Overview«. *Journal of Advances in Information Fusion* (2013), Bd. 8(1): S. 33–72.
- [Foo09] F. FOOLADVANDI, C. BRAX, P. GUSTAVSSON und M. FREDIN: »Signature-based Activity Detection based on Bayesian Networks acquired from Expert Knowledge«. *Proceedings of the 12th International Conference on Information Fusion (FUSION)*. 2009: S. 436–443.
- [Fur10] A. FURDA und L. VLACIC: »An Object-Oriented Design of a World Model for Autonomous City Vehicles«. *Intelligent Vehicles Symposium (IV)*. 2010: S. 1054–1059.
- [Gab12] R. GABLER und W. KOCH: »Detection and Tracking of Non-Cooperative Vessels«. *Proceedings of the NATO Symposium on Port and Regional Maritime Security (RTO-MP-SCI-247)*. NATO Systems Concepts und Integration Panel (SCI) Panel. 2012: S. 1–17.
- [Gad09] A. S. GAD: »A Fuzzy Logic-Based Multisensor Data Fusion for Maritime Surveillance - Real Data Testing«. *Proceedings of the 26th National Radio Science Conference (NRSC)*. 2009: S. 1–10.
- [Gad02] A. GAD und M. FAROOQ: »Data Fusion Architecture for Maritime Surveillance«. *Proceedings of the 5th International Conference on Information Fusion (FUSION)*. 2002: S. 448–455.
- [Gar11] J. GARCIA, J. GOMEZ-ROMERO, M. A. P. J. M. MOLINA und G. ROGOVA: »On the Representation and Exploitation of Context Knowledge in a Harbor Surveillance Scenario«. *Proceedings of the 14th International Conference on Information Fusion (FUSION)*. 2011: S. 1–8.
- [Gar10] J. GARCIA, J. L. GUERRERO, A. LUIS und J. M. MOLINA: »Robust Sensor Fusion in Real Maritime Surveillance Scenarios«. *Proceedings of the 13th International Conference on Information Fusion (FUSION)*. 2010: S. 1–8.
- [Get07] L. GETOOR, N. FRIEDMAN, D. KOLLER, A. PFEFFER und B. TASKAR: »Probabilistic Relational Models«. *Introduction to Statistical Relational Learning*. Hrsg. von L. GETOOR und B. TASKAR. MIT Press, 2007. Kap. 5: S. 129–174.

- [Ghe10] I. GHETA, M. BAUM, A. BELKIN, J. BEYERER und U. D. HANEBECK: »Three Pillar Information Management System for Modeling the Environment of Autonomous Systems«. *Proceedings of the IEEE International Conference on Virtual Environments Human-Computer Interfaces and Measurement Systems (VECIMS)*. 2010: S. 12–17.
- [Gör03] G. GÖRZ, C.-R. ROLLINGER und J. SCHNEEBERGER, Hrsg.: *Handbuch der künstlichen Intelligenz*. Oldenbourg Verlag, 2003.
- [Gra05] T. GRANT und B. KOOTER: »Comparing OODA & other models as Operational View C2 Architecture«. *Proceedings of the 10th International Command and Control Research and Technology Symposium: The Future of C2*. 2005.
- [Gue08] M. GUERRIERO, P. WILLETT, S. CORALUPPI und C. CARTEL: »Radar/AIS data fusion and SAR tasking for Maritime Surveillance«. *Proceedings of the 11th International Conference on Information Fusion (FUSION)*. 2008: S. 1–5.
- [Hal97] D. L. HALL und J. LLINAS: »An Introduction to Multisensor Data Fusion«. *Proceedings of the IEEE* (1997), Bd. 85(1): S. 6–23.
- [Hal04] D. L. HALL und S. A. H. MCMULLEN: *Mathematical Techniques in Multisensor Data Fusion*. Artech House, Inc., 2004.
- [Har07a] A. HARATI-MOKHTARI, A. WALL, P. BROOKS und J. WANG: »Automatic Identification System (AIS): Data Reliability and Human Error Implications«. *Journal of Navigation* (2007), Bd. 60: S. 373–389.
- [Har07b] J. HARRALD und T. JEFFERSON: »Shared Situational Awareness in Emergency Management Mitigation and Response«. *Proceedings of the 40th Annual Hawaii International Conference on System Sciences (HICSS)*. IEEE, 2007: S. 1–8.
- [Har06] S. G. HART: »NASA-Task Load Index (NASA-TLX); 20 Years Later«. *Proceedings of the Human Factors and Ergonomics Society 50th Annual Meeting*. 2006: S. 904–908.
- [Har88] S. G. HART und L. E. STAVELAND: »Development of NASA-TLX (Task Load Index): Results of Empirical and Theoretical Research«. *Human Mental Workload*. Hrsg. von P. A. HANCOCK und N. MESHKATI. Bd. 52. *Advances in Psychology*. Elsevier, 1988: S. 139–183.

- [Hau03] Y. HAUSS und K. EYFERTH: »Securing future ATM-concepts' safety by measuring situation awareness in ATC«. *Aerospace Science and Technology* (2003), Bd. 7(6): S. 417–427.
- [Hei10] M. HEIZMANN, I. GHETA, F. P. LÉON und J. BEYERER: »Sensoreinsatzplanung und Informationsfusion zur Umgebungsexploration«. *tm - Technisches Messen* (2010), Bd. 77(10): S. 558–567.
- [Hol12] A. HOLST, B. BJURLING, J. EKMAN, A. RUDSTROM, K. WALLENIUS, M. BJORKMAN, F. FOOLADVANDI, R. LAXHAMMAR und J. TRONNINGER: »A Joint Statistical and Symbolic Anomaly Detection System: Increasing performance in maritime surveillance«. *Proceedings of the 15th International Conference on Information Fusion (FUSION)*. 2012: S. 1919–1926.
- [Hon02] T. HONG, S. BALAKIRSKY, E. MESSINA, T. CHANG und M. SHNEIER: »A Hierarchical World Model for an Autonomous Scout Vehicle«. *Proc. SPIE 4715, Unmanned Ground Vehicle Technology IV*, 343. 2002: S. 343–354.
- [Hos12] T. N. HOSSEIN, S. MITA, L. HAN und Q. H. DO: »Multi-Sensor Data Fusion for Autonomous Vehicle Navigation and Localization through Precise Map«. *International Journal of Automotive Engineering* (2012), Bd. 3(1): S. 19–25.
- [How05] C. HOWARD und M. STUMPTNER: »Situation Assessments Using Object Oriented Probabilistic Relational Models«. *Proceedings of the 8th International Conference on Information Fusion (FUSION)*. 2005: S. 1489–1496.
- [How09] C. HOWARD und M. STUMPTNER: »Automated compilation of Object-Oriented Probabilistic Relational Models«. *International Journal of Approximate Reasoning* (2009), Bd. 50(9): S. 1369–1398.
- [IJs14] J. IJSSELMUIDEN, D. MÜNCH, A.-K. GROSSEFINGER, M. ARENS und R. STIEFELHAGEN: »Automatic Understanding of Group Behavior using Fuzzy Temporal Logic«. *Journal of Ambient Intelligence and Smart Environments* (2014), Bd. 6(6): S. 623–649.
- [IMO79] IMO: INTERNATIONAL MARITIME ORGANIZATION: *Performance Standards for Automatic Radar Plotting Aids (ARPA) - Resolution A.422(XI)*. 1979.

- [IMO96] IMO: INTERNATIONAL MARITIME ORGANIZATION: *Performance Standards for Electronic Chart Display and Information Systems (ECDIS) - Resolution A.817(19)*. 1996.
- [IMO98] IMO: INTERNATIONAL MARITIME ORGANIZATION: *Adoption of new and amended performance Standards - Resolution MSC.74(69)*. 1998.
- [IMO01] IMO: INTERNATIONAL MARITIME ORGANIZATION: *Guidelines for the onboard operational use of shipborne automatic identification systems (AIS) - Resolution A.917(22)*. 2001.
- [IMO13a] IMO: INTERNATIONAL MARITIME ORGANIZATION: *Amendments to the International Aeronautical and Maritime Search and Rescue (IAMSAR) Manual*. 2013.
- [IMO13b] IMO: INTERNATIONAL MARITIME ORGANIZATION: *IMO - What it is*. [http://www.imo.org/About/Documents/What%20it%20is%200ct%202013\\_Web.pdf](http://www.imo.org/About/Documents/What%20it%20is%200ct%202013_Web.pdf), letzter Abruf am 14.05.2015. 2013.
- [ITU13] ITU-R: RADIOCOMMUNICATION SECTOR OF INTERNATIONAL TELECOMMUNICATION UNION: *Recommendation ITU-R M.1371-5, Technical Characteristics for an Automatic Identification System using Time Division Multiple Access in the VHF Maritime Mobile Frequency Band*. 2013.
- [Jak06] G. JAKOBSON, J. BUFORD und L. LEWIS: »A Framework of Cognitive Situation Modeling and Recognition«. *Proceedings of the Military Communications Conference (MILCOM)*. 2006: S. 1–7.
- [Jak07] G. JAKOBSON, J. BUFORD und L. LEWIS: »Situation Management: Basic Concepts and Approaches«. *Proceedings of the 3rd International Workshop Information Fusion and Geographic Information Systems*. 2007: S. 18–33.
- [Jay68] E. T. JAYNES: »Prior Probabilities«. *IEEE Transactions on Systems Science and Cybernetics* (1968), Bd. 4(3): S. 227–241.
- [Jen07] F. V. JENSEN und T. D. NIELSEN: *Bayesian Networks and Decision Graphs*. Second Edition. Springer, 2007.
- [Joh07] F. JOHANSSON und G. FALKMAN: »Detection of Vessel Anomalies - a Bayesian Network Approach«. *Proceedings of the 3rd International Conference on Intelligent Sensors, Sensor Networks and Information (ISSNIP)*. 2007: S. 395–400.

- [Jot09] A. JOTSHI, Q. GONG und R. BATTA: »Dispatching and Routing of Emergency Vehicles in Disaster Mitigation using Data Fusion«. *Socio-Economic Planning Sciences* (2009), Bd. 43(1): S. 1–24.
- [Jun12] M. JUNGE: »Die Relevanz des Konstruktes Situation Awareness für den Rettungsdienst unter Berücksichtigung von Messverfahren«. Bachelorarbeit. Hochschule für Angewandte Wissenschaften Hamburg, 2012.
- [Kal60] R. E. KALMAN: »A New Approach to Linear Filtering and Prediction Problems«. *Journal of Basic Engineering* (1960), Bd. 82: S. 35–45.
- [Kas12] D. KASPER, G. WEIDL, T. DANG, G. BREUEL, A. TAMKE, A. WEDEL und W. ROSENSTIEL: »Object-Oriented Bayesian Networks for Detection of Lane Change Maneuvers«. *IEEE Intelligent Transportation Systems Magazine* (2012), Bd. 4(3): S. 19–31.
- [Kas07] T. van KASTEREN und B. KRÖSE: »Bayesian Activity Recognition in Residence for Elders«. *Proceedings of the 3rd IET International Conference on Intelligent Environments (IE)*. 2007: S. 209–212.
- [Kaz13] S. KAZEMI, S. ABGHARI, N. LAVESSON, H. JOHNSON und P. RYMAN: »Open Data for Anomaly Detection in Maritime Surveillance«. *Expert Systems with Applications* (2013), Bd. 40(14): S. 5719–5729.
- [Kha13] B. KHALEGHI, A. KHAMIS, F. O. KARRAY und S. N. RAZAVI: »Multi-sensor Data Fusion: A Review of the State-of-the-Art«. *Information Fusion* (2013), Bd. 14(1): S. 28–44.
- [Kle04] L. A. KLEIN: *Sensor- and Data Fusion: A Tool for Information Assessment and Decision Making*. SPIE Press, 2004.
- [Kle13] S. KLEINBERG: *Causality, Probability, and Time*. Cambridge University Press, 2013.
- [Kna06] M. KNAUFF: »Deduktion und logisches Denken«. *Denken und Problemlösen*. Hrsg. von J. FUNKE. Enzyklopädie der Psychologie, Band 8. Hogrefe, 2006: S. 167–264.
- [Koc14] W. KOCH: *Tracking and Sensor Data Fusion*. Springer, 2014.
- [Kok12] M. M. KOKAR und M. R. ENDSLEY: »Situation Awareness and Cognitive Modeling«. *Intelligent Systems* (2012), Bd. 27(3): S. 91–96.

- [Kok09] M. M. KOKAR, C. J. MATHEUS und K. BACLAWSKI: »Ontology-based Situation Awareness«. *Information Fusion* (2009), Bd. 10(1): S. 83–98.
- [Kol03] T. G. KOLDA, R. M. LEWIS und V. TORCZON: »Optimization by Direct Search: New Perspectives on Some Classical and Modern Methods«. *SIAM Review* (2003), Bd. 45(3): S. 385–482.
- [Kol09] D. KOLLER und N. FRIEDMAN: *Probabilistic Graphical Models: Principles and Techniques*. MIT Press, 2009.
- [Kol97] D. KOLLER und A. PFEFFER: »Object-Oriented Bayesian Networks«. *Proceedings of the 13th Annual Conference on Uncertainty in Artificial Intelligence (UAI)*. 1997: S. 302–313.
- [Krü12] M. KRÜGER, J. ZIEGLER und K. HELLER: »A Generic Bayesian Network for Identification and Assessment of Objects in Maritime Surveillance«. *Proceedings of the 15th International Conference on Information Fusion (FUSION)*. 2012: S. 2309–2316.
- [Küh10] 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 Modeling approach for Humanoid Robots«. *Proceedings of the 41st International Symposium on Robotics (ISR) and 6th German Conference on Robotics (ROBOTIK)*. 2010: S. 1296–1303.
- [Kuw14] A. KUWERTZ und J. BEYERER: »Dealing With Poorly Mapped Entities in Adaptive Object-Oriented World Modeling«. *Proceedings of the 4th International Multi-Disciplinary Conference on Cognitive Methods in Situation Awareness and Decision Support (CogSIMA)*. 2014: S. 83–89.
- [Lam99] D. A. LAMBERT: »Assessing Situations«. *Proceedings of the Symposium on Information, Decision and Control (IDC)*. 1999: S. 503–508.
- [Lam01] D. A. LAMBERT: »Situations for Situation Awareness«. *Proceedings of the 4th International Conference on Information Fusion (Fusion)*. 2001: S. 1–7.
- [Lam03] D. A. LAMBERT: »Grand Challenges of Information Fusion«. *Proceedings of the 6th International Conference of Information Fusion (FUSION)*. 2003: S. 213–220.



- [Lan10] R. O. LANE, D. A. NEVELL, S. D. HAYWARD und T. W. BEANEY: »Maritime Anomaly Detection and Threat Assessment«. *Proceedings of the 13th International Conference on Information Fusion (FUSION)*. 2010: S. 1–8.
- [Las08] K. B. LASKEY: »MEBN: A Language for First-Order Bayesian Knowledge Bases«. *Artificial Intelligence* (2008), Bd. 172(2-3): S. 140–178.
- [Las11] K. B. LASKEY, R. HABERLIN, R. N. CARVALHO und P. C. G. COSTA: »PR-OWL 2 Case Study: A Maritime Domain Probabilistic Ontology«. *Proceedings of the 6th International Conference on Semantic Technologies for Intelligence, Defense, and Security (STIDS)*. 2011: S. 76–83.
- [Lav11] V. LAVIGNE, D. GOUIN und M. DAVENPORT: »Visual Analytics for Maritime Domain Awareness«. *Proceeding of the International Conference on Technologies for Homeland Security (HST)*. IEEE, 2011: S. 49–54.
- [Lax08] R. LAXHAMMAR: »Anomaly Detection for Sea Surveillance«. *Proceedings of the 11th International Conference on Information Fusion (FUSION)*. 2008: S. 1–8.
- [Lax11a] R. LAXHAMMAR: »Anomaly Detection in Trajectory Data for Surveillance Applications«. Diss. Örebro University, 2011.
- [Lax11b] R. LAXHAMMAR und G. FALKMAN: »Sequential Conformal Anomaly Detection in Trajectories based on Hausdorff Distance«. *Proceedings of the 14th International Conference on Information Fusion (FUSION)*. 2011: S. 1–8.
- [Lax09] R. LAXHAMMAR, G. FALKMAN und E. SVIESTINS: »Anomaly Detection in Sea Traffic - a Comparison of the Gaussian Mixture Model and the Kernel Density Estimator«. *Proceedings of the 12th International Conference on Information Fusion (FUSION)*. 2009: S. 756–763.
- [Lew07] R. M. LEWIS, A. SHEPHERD und V. TORCZON: »Implementing Generating Set Search Methods for Linearly Constrained Minimization«. *SIAM Journal on Scientific Computing* (2007), Bd. 29(6): S. 2507–2530.

- [Lin06] B. LIN und C.-H. HUANG: »Comparison between ARPA Radar and AIS Characteristics for Vessel Traffic Services«. *Journal of Marine Science and Technology (JMST)* (2006), Bd. 14(3): S. 182–189.
- [Lli02] J. LLINAS: »Information Fusion for Natural and Man-Made Disasters«. *Proceedings of the 5th International Conference on Information Fusion (FUSION)*. 2002: S. 570–576.
- [Mah98] S. M. MAHONEY und K. B. LASKEY: »Constructing Situation Specific Belief Networks«. *Proceedings of the 14th Conference on Uncertainty in Artificial Intelligence (UAI)*. 1998: S. 370–378.
- [Mar08] M. MARTÍNEZ und L. E. SUCAR: »Learning Dynamic Naive Bayesian Classifiers«. *Proceedings of the 21st International Florida Artificial Intelligence Research Symposium Conference (FLAIRS)*. 2008: S. 655–659.
- [Mas14] S. MASCARO, A. E. NICHOLSON und K. B. KORB: »Anomaly Detection in Vessel Tracks using Bayesian Networks«. *International Journal of Approximate Reasoning* (2014), Bd. 55(1): S. 84–98.
- [Mey09] D. MEYER-DELIUS, C. PLAGEMANN und W. BURGARD: »Probabilistic Situation Recognition for Vehicular Traffic Scenarios«. *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA)*. 2009: S. 459–464.
- [Mit12] H. B. MITCHELL: *Data Fusion: Concepts and Ideas*. Springer, 2012.
- [Moe06] M.-F. MOENS: »Evaluation of Information Extraction Technologies«. *Information Extraction: Algorithms and Prospects in a Retrieval Context*. Springer, 2006: S. 179–197.
- [Moß10] J. MOSSGRABER, F. REINERT und H. VAGTS: »An Architecture for a Task-Oriented Surveillance System: A Service- and Event-Based Approach«. *Proceedings of the 5th International Conference on Systems (ICONS)*. 2010: S. 146–151.
- [Mün11] D. MÜNCH, J. IJSSELMUIDEN, M. ARENS und R. STIEFELHAGEN: »High-Level Situation Recognition Using Fuzzy Metric Temporal Logic, Case Studies in Surveillance and Smart Environments«. *Proceedings of the IEEE International Conference on Computer Vision Workshops*. 2011: S. 882–889.

- [Mur02] K. P. MURPHY: »Dynamic Bayesian Networks: Representation, Inference and Learning«. Diss. University of California, Berkeley, 2002.
- [Mur12] K. P. MURPHY: *Machine Learning: A Probabilistic Perspective*. The MIT Press, 2012.
- [Nea12] R. E. NEAPOLITAN: *Probabilistic Reasoning In Expert Systems: Theory and Algorithms*. CreateSpace Independent Publishing Platform, 2012.
- [Nie14] D. NIENHÜSER: »Kontextsensitive Erkennung und Interpretation fahrrelevanter statischer Verkehrselemente«. Diss. Karlsruhe Institut für Technologie (KIT), 2014.
- [Nil08] M. NILSSON, J. van LAERE, T. ZIEMKE und J. EDLUND: »Extracting Rules from Expert Operators to support Situation Awareness in Maritime Surveillance,« *Proceedings of the 11th International Conference on Information Fusion (FUSION)*. 2008: S. 1–8.
- [NME08] NMEA: NATIONAL MARINE ELECTRONICS ASSOCIATION: *NMEA 0183 Version 4.10, The Standard for Interfacing Marine Electronics*. 2008.
- [Oka09] T. OKAZAKI: »A Study of Situation Awareness of Evading Navigation using Marine Radar«. *Proceedings of the 13th International Symposium on Consumer Electronics (ISCE)*. IEEE, 2009: S. 841–844.
- [Osi07] F. P. B. OSINGA: *Science, Strategy and War - The Strategic Theory of John Boyd*. Hrsg. von C. GRAY und W. MURRAY. Bd. 18. Strategy and History. Routledge, 2007.
- [Pal13] G. PALLOTTA, M. VESPE und K. BRYAN: »Vessel Pattern Knowledge Discovery from AIS Data: A Framework for Anomaly Detection and Route Prediction«. *Entropy* (2013), Bd. 15(6): S. 2218–2245.
- [Par62] E. PARZEN: »On Estimation of a Probability Density Function and Mode«. *The Annals of Mathematical Statistics* (1962), Bd. 33(3): S. 1065–1076.
- [Pau93] G. PAUL: »Approaches to abductive reasoning: an overview«. *Artificial Intelligence Review* (1993), Bd. 7(2): S. 109–152.
- [Pea88] J. PEARL: *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*. Morgan Kaufmann Publishers, inc., 1988.

- [Pic05] C. PICIARELLI, G. L. FORESTI und L. SNIDARO: »Trajectory Clustering and its Applications for Video Surveillance«. *Proceedings of the IEEE Conference on Advanced Video and Signal Based Surveillance (AVSS)*. 2005: S. 40–45.
- [Pil12] G. PILATO, A. AUGELLO, M. MISSIKOFF und F. TAGLINO: »Integration of Ontologies and Bayesian Networks for Maritime Situation Awareness«. *Proceedings of the IEEE Sixth International Conference on Semantic Computing (ICSC)*. 2012: S. 170–177.
- [Poe09] A. POETZSCH-HEFFTER: *Konzepte Objektorientierter Programmierung: Mit Einer Einführung in Java*. Springer, 2009.
- [Pol08] R. POLIKAR, A. TOPALIS, D. PARIKH, D. GREEN, J. FRYMIARE, J. KOUNIOS und C. M. CLARK: »An Ensemble Based Data Fusion Approach for Early Diagnosis of Alzheimer’s Disease«. *Information Fusion* (2008), Bd. 9(1): S. 83–95.
- [Pol13] T. POLOMSKI und H.-J. KLEIN: »How to improve Maritime Situational Awareness using Piracy Attack Patterns«. *Proceedings of the 8th Security Research Conference (Future Security)*. 2013: S. 97–106.
- [Rab89] L. R. RABINER: »A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition«. *Proceedings of the IEEE* (1989), Bd. 77(2): S. 257–286.
- [Reg04] R. REGELE und P. LEVI: »Cooperation based on Communication: An Approach for an Autonomous Driving System«. *Proceedings of the 16th European Conference on Artificial Intelligence (ECAI)*. IOS Press, 2004: S. 1079–1080.
- [Rey09] D. REYNOLDS: »Gaussian Mixture Models«. *Encyclopedia of Biometrics*. Hrsg. von S. Z. LI und A. JAIN. Springer US, 2009: S. 659–663.
- [Rho06] B. J. RHODES, N. A. BOMBERGER, M. SEIBERT und A. M. WAXMAN: »SeeCoast: Automated Port Scene Understanding Facilitated by Normalcy Learning«. *Military Communications Conference (MILCOM)*. 2006: S. 1–7.
- [Ric10] M. A. RICHARDS, J. A. SCHEER und W. A. HOLM: *Principles of Modern Radar*. Hrsg. von M. A. RICHARDS, J. A. SCHEER und W. A. HOLM. SciTech Publishing Inc., 2010.

- [Ric06] M. RICHARDSON und P. DOMINGOS: »Markov Logic Networks«. *Machine Learning* (2006), Bd. 62(1-2): S. 107–136.
- [Ris08] B. RISTIC, B. L. SCALA, M. MORELANDE und N. GORDON: »Statistical analysis of motion patterns in AIS Data: Anomaly detection and motion prediction«. *Proceedings of the 11th International Conference on Information Fusion (FUSION)*. 2008: S. 1–7.
- [Riv09] M. RIVEIRO und G. FALKMAN: »Interactive Visualization of Normal Behavioral Models and Expert Rules for Maritime Anomaly Detection«. *Proceedings of the 6th International Conference on Computer Graphics, Imaging and Visualization (CGIV)*. 2009: S. 459–466.
- [Riv08a] M. RIVEIRO, G. FALKMAN und T. ZIEMKE: »Improving Maritime Anomaly Detection and Situation Awareness through Interactive Visualization«. *Proceedings of the 11th International Conference on Information Fusion (FUSION)*. IEEE, 2008: S. 1–8.
- [Riv08b] M. RIVEIRO, G. FALKMAN und T. ZIEMKE: »Visual Analytics for the Detection of Anomalous Maritime Behavior«. *Proceedings of the 12th International Conference on Information Visualisation (IV)*. 2008: S. 273–279.
- [Rob07] C. P. ROBERT: *The Bayesian Choice*. Springer, 2007.
- [Rot03] M. ROTH, D. VAIL und M. VELOSO: »A Real-time World Model for Multi-Robot Teams with High-Latency Communication«. *Proceedings of the International Conference on Intelligent Robots and Systems*. 2003: S. 2494–2499.
- [Row07] J. ROWLEY: »The Wisdom Hierarchy: Representations of the DIKW Hierarchy«. *Journal of Information Science* (2007), Bd. 33(2): S. 163–180.
- [Roy01] J. ROY: »From Data Fusion to Situation Analysis«. *Proceedings of the 4th International Conference on Information Fusion (FUSION)*. 2001.
- [Roy08] J. ROY: »Anomaly Detection in the Maritime Domain«. *Proceedings of SPIE 6945, Optics and Photonics in Global Homeland Security IV, 69450W*. 2008: S. 1–14.

- [Roy10a] J. ROY: »Rule-based Expert System for Maritime Anomaly Detection«. *Proc. SPIE 7666, Sensors, and Command, Control, Communications, and Intelligence (C3I) Technologies for Homeland Security and Homeland Defense IX, 76662N*. 2010: S. 1–12.
- [Roy10b] J. ROY und M. DAVENPORT: »Exploitation of Maritime Domain Ontologies for Anomaly Detection and Threat Analysis«. *Proceedings of the International Waterside Security Conference (WSS)*. 2010: S. 1–8.
- [Rus10] S. J. RUSSELL und P. NORVIG: *Artificial Intelligence: A Modern Approach*. Pearson Education, Inc., 2010.
- [Sal09] P. M. SALMON, N. A. STANTON, G. H. WALKER, D. JENKINS, D. LADVA, L. RAFFERTY und M. YOUNG: »Measuring Situation Awareness in Complex Systems: Comparison of Measures Study:« *International Journal of Industrial Ergonomics* (2009), Bd. 39(3): S. 490–500.
- [Sär13] S. SÄRKKÄ: *Bayesian Filtering and Smoothing*. Cambridge University Press, 2013.
- [Sch11a] T. SCHAMM und J. M. ZÖLLNER: »A Model-Based Approach to Probabilistic Situation Assessment for Driver Assistance Systems«. *Proceedings of the 14th International IEEE Conference on Intelligent Transportation Systems (ITSC)*. 2011: S. 1404–1409.
- [Sch11b] R. SCHUBERT und G. WANIELIK: »A Unified Bayesian Approach for Object and Situation Assessment«. *IEEE Intelligent Transportation Systems Magazine* (2011), Bd. 3(2): S. 6–19.
- [Sch13] C. M. SCHULZ, M. R. ENDSLEY, E. F. KOCHS, A. W. GELB und K. J. WAGNER: »Situation Awareness in Anesthesia: Concept and Research«. *Anesthesiology* (2013), Bd. 118(3): S. 729–742.
- [Sei06] M. SEIBERT, B. J. RHODES, N. A. BOMBERGER, P. O. BEANE, J. J. SROKA, W. KOGEL, W. KREAMER, C. STAUFFER, L. KIRSCHNER, E. CHALOM, M. BOSSE und R. TILLSON: »SeeCoast Port Surveillance«. *Proc. SPIE 6204, Photonics for Port and Harbor Security II, 62040B*. 2006: S. 1–11.

- [Sel91] S. J. SELCON, R. M. TAYLOR und E. KORITSAS: »Workload or Situational Awareness?: TLX vs. SART for Aerospace Systems Design Evaluation«. *Proceedings of the Human Factors Society 35th Annual Meeting, Aerospace Systems: Situational Awareness: Tools and Measurement*. 1991: S. 62–66.
- [Sig14] SIGNALIS - A CASSIDIAN AND ATLAS ELEKTRONIK COMPANY: *SIGNALIS Company Profile*. <http://www.signalis.com>, letzter Abruf am 14.05.2015. 2014.
- [Sii01] H. S. SII, T. RUXTON und J. WANG: »A Fuzzy-Logic-based Approach to Qualitative Safety Modelling for Marine Systems«. *Reliability Engineering & System Safety* (2001), Bd. 73(1): S. 19–34.
- [Sim00] M.-A. SIMARD, E. LEFEBVRE und C. HELLEUR: »Multisource Information Fusion applied to Ship Identification for the Recognized Maritime Picture«. *Proc. SPIE 4051, Sensor Fusion: Architectures, Algorithms, and Applications IV*, 67. 2000: S. 67–78.
- [Sni04] L. SNIDARO, G. L. FORESTI, R. NIU und P. K. VARSHNEY: »Sensor Fusion for Video Surveillance«. *Proceedings of the 7th International Conference on Information Fusion (FUSION)*. 2004: S. 739–746.
- [Sni12] L. SNIDARO, I. VISENTINI, K. BRYAN und G. L. FORESTI: »Markov Logic Networks for Context Integration and Situation Assessment in Maritime Domain«. *Proceedings of the 15th International Conference on Information Fusion (FUSION)*. 2012: S. 1534–1539.
- [Sni11] L. SNIDARO, I. VISENTINI und G. L. FORESTI: »Data Fusion in Modern Surveillance«. *Innovations in Defence Support Systems - 3*. Hrsg. von P. REMAGNINO, D. N. MONEKOSSO und L. C. JAIN. Bd. 336. *Studies in Computational Intelligence*. Springer, 2011: S. 1–21.
- [Sol99] B. SOLAIMAN, R. DEBON, F. PIPELIER, J.-M. CAUVIN und C. ROUX: »Information Fusion, Application to Data and Model Fusion for Ultrasound Image Segmentation«. *IEEE Transactions on Biomedical Engineering* (1999), Bd. 46(10): S. 1171–1175.
- [Spi00] P. SPIRITES, C. N. GLYMOUR und R. SCHEINES: *Causation, Prediction, and Search*. MIT Press, 2000.

- [Stä10] STÄNDIGER AUSSCHUSS FÜR GEOGRAPHISCHE NAMEN (STAGN): *Deutsches Glossar zur toponymischen Terminologie, Bundesamt für Kartographie und Geodäsie, Frankfurt am Main*. [http://141.74.33.52/stagn/Portals/0/100419\\_Glossar\\_3.pdf](http://141.74.33.52/stagn/Portals/0/100419_Glossar_3.pdf), letzter Abruf am 14.05.2015. 2010.
- [Ste01] A. N. STEINBERG und C. L. BOWMAN: »Revisions to the JDL Data Fusion Model«. *Handbook of Multisensor Data Fusion*. CRC Press LLC, 2001. Kap. 2: S. 1–19.
- [Ste08] A. N. STEINBERG und G. ROGOVA: »Situation and Context in Data Fusion and Natural Language Understanding«. *Proceedings of the 11th International Conference on Information Fusion (FUSION)*. 2008: S. 1–8.
- [Sti08] C. STILLER, S. KAMMEL, I. LULCHEVA und J. ZIEGLER: »Probabilistische Methoden in der Umfeldwahrnehmung Kognitiver Automobile«. *Automatisierungstechnik* (2008), Bd. 56(11): S. 563–574.
- [Str01] A. W. STROUPE, M. C. MARTIN und T. BALCH: »Distributed sensor fusion for object position estimation by multi-robot systems«. *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA)*. 2001: S. 1092–1098.
- [Stu98] R. STUDER, V. R. BENJAMINS und D. FENSEL: »Knowledge Engineering: Principles and Methods«. *Data & Knowledge Engineering* (1998), Bd. 25(1-2): S. 161–197.
- [Syr07] M. SYRBE und J. BEYERER: »Mensch-Maschine-Wechselwirkungen, Anthropotechnik«. *Hütte: Das Ingenieurwissen*. Hrsg. von H. CZICHOS und M. HENNECKE. Bd. 33. Springer, 2007: K80–K99, K104.
- [Tay90] R. M. TAYLOR: »Situational awareness rating technique (SART): The development of a tool for aircrew systems design«. *Proceedings of the AGARD AMP Symposium on Situational Awareness in Aerospace Operations, CP478*. NATO AGARD. 1990.



- [Tay95] R. M. TAYLOR, S. J. SELCON und A. D. SWINDEN: »Measurement of Situational Awareness and Performance: A Unitary SART Index Predicts Performance on a Simulated ATC Task«. *Human Factors in Aviation Operations: Proceedings of the 21st Conference of the European Association for Aviation Psychology (EAAP)*. Hrsg. von R. FULLER, N. JOHNSTON und N. McDONALD. Avebury Aviation, Ashgate Publishing, 1995: S. 275–280.
- [Tob11] C. TOBEHN, A. SCHÖNENBERG, R. RINALDO, A. GINESI, A. GINATI und L. SCIBERRAS: »European Satellite AIS under Joint EMSA/ESA Integrated Applications Programme«. *62nd International Astronautical Congress*. 2011: S. 1–10.
- [Tra08] S. D. TRAN und L. S. DAVIS: »Event Modeling and Recognition Using Markov Logic Networks«. *Proceedings of the 10th European Conference on Computer Vision: Part II (ECCV)*. 2008: S. 610–623.
- [Uni13] UNITED NATIONS CONFERENCE ON TRADE AND DEVELOPMENT (UNCTAD): *Review of Maritime Transport*. [http://unctad.org/en/PublicationsLibrary/rmt2013\\_en.pdf](http://unctad.org/en/PublicationsLibrary/rmt2013_en.pdf), letzter Abruf am 14.05.2015. United Nations Publication, 2013.
- [Van12] A. VANDECASTEELE und A. NAPOLI: »An enhanced spatial reasoning ontology for maritime anomaly detection«. *Proceedings of the 7th International Conference on System of Systems Engineering (SoSE)*. 2012: S. 247–252.
- [Ves12] M. VESPE, I. VISENTINI, K. BRYAN und P. BRACA: »Unsupervised Learning of Maritime Traffic Patterns for Anomaly Detection«. *Proceedings of 9th IET Data Fusion & Target Tracking Conference (DF&TT)*. 2012: S. 1–5.
- [Vla02] N. VLASSIS und A. LIKAS: »A Greedy EM Algorithm for Gaussian Mixture Learning«. *Neural Processing Letters* (2002), Bd. 15(1): S. 77–87.
- [Whi91] F. E. WHITE: *Data Fusion Lexicon*. Technischer Bericht. The Data Fusion Panel of the Joint Directors of Laboratories, Technical Panel for C3, 1991.
- [Wig11] P. WIGGERS, B. MERTENS und L. ROTHKRANTZ: »Dynamic Bayesian Networks for Situational Awareness in the Presence of Noisy Data«. *Proceedings of the 12th International Conference on Computer Systems and Technologies (CompSysTech)*. 2011: S. 411–416.

- [Win14] WINWARD: *AIS Data on the High Seas: An Analysis of the Magnitude and Implications of Growing Data Manipulation at Sea*. <http://www.windward.eu/wp-content/uploads/2015/02/AIS-Data-on-the-High-Seas-Executive-Summary-Windward-October-20-2014.pdf>, letzter Abruf am 14.05.2015. 2014.
- [Wul13] F. WULF, K. ZEEB, M. RIMINI-DÖRING, M. ARNON und F. GAUTERIN: »Effects of human-machine interaction mechanisms on situation awareness in partly automated driving«. *Proceedings of the 16th International IEEE Conference on Intelligent Transportation Systems (ITSC)*. IEEE, 2013: S. 2012–2019.
- [Xia08] T. XIANG und S. GONG: »Video Behavior Profiling for Anomaly Detection«. *IEEE Transactions on Pattern Analysis and Machine Intelligence* (2008), Bd. 30(5): S. 893–908.
- [Ye12] J. YE, S. DOBSON und S. MCKEEVER: »Situation Identification Techniques in Pervasive Computing: A Review«. *Pervasive and Mobile Computing* (2012), Bd. 8(1): S. 36–66.
- [Zwe98] G. ZWEIG und S. RUSSELL: »Speech Recognition with Dynamic Bayesian Networks«. *Proceedings of the 15th National Conference on Artificial Intelligence (AAAI)*. 1998: S. 173–180.

---

# Eigene Veröffentlichungen

---

- [Fis09] Y. FISCHER: »On Situation Modeling and Recognition«. *Proceedings of the 2009 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory*. Hrsg. von J. BEYERER und M. HUBER. Bd. 4. Karlsruher Schriften zur Anthropomatik. Technischer Bericht IES-2009-14. KIT Scientific Publishing, 2009: S. 203–215.
- [Bau10] A. BAUER und Y. FISCHER: »Task-Oriented Situation Recognition«. *Proc. SPIE 7709, Cyber Security, Situation Management, and Impact Assessment II; and Visual Analytics for Homeland Defense and Security II*. Hrsg. von J. F. BUFORD, G. JAKOBSON, J. ERICKSON, W. J. TOLONE und W. RIBARSKY. Bd. 770906. SPIE, 2010: S. 1–9.
- [Fis10a] Y. FISCHER: »World Modeling for Advanced Surveillance Systems«. *Proceedings of the 2010 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory*. Hrsg. von J. BEYERER und M. HUBER. Bd. 7. Karlsruher Schriften zur Anthropomatik. Technischer Bericht IES-2010-02. KIT Scientific Publishing, 2010: S. 17–30.
- [Fis10b] Y. FISCHER und A. BAUER: »Object-Oriented Sensor Data Fusion for Wide Maritime Surveillance«. *Proceedings of the 2nd International Conference on Waterside Security (WSS)*. IEEE, 2010: S. 1–6.

- [Hil10] J. HILD, J. OTT, Y. FISCHER und C. GLÖKLER: »Markov Based Decision Support for Cost-Optimal Response in Security Management«. *Proceedings of the 7th International Conference on Information Systems for Crisis Response and Management (ISCRAM)*. Hrsg. von S. FRENCH, B. TOMASZEWSKI und C. ZOBEL. 2010: S. 1–5.
- [Bau11] A. BAUER und Y. FISCHER: »Object-Event Graph Matching for Complex Activity Recognition«. *Proceedings of the 1st International Multi-Disciplinary Conference on Cognitive Methods in Situation Awareness and Decision Support (CogSIMA)*. IEEE, 2011: S. 88–93.
- [Fis11a] Y. FISCHER: »Modeling and Recognizing Situations in the Maritime Domain«. *Proceedings of the 2011 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory*. Hrsg. von J. BEYERER und A. PAK. Bd. 11. Karlsruher Schriften zur Anthropomatik. Technischer Bericht IES-2011-02. KIT Scientific Publishing, 2011: S. 19–33.
- [Fis11b] Y. FISCHER, A. BAUER und J. BEYERER: »A Conceptual Framework for Automatic Situation Assessment«. *Proceedings of the 1st International Multi-Disciplinary Conference on Cognitive Methods in Situation Awareness and Decision Support (CogSIMA)*. IEEE, 2011: S. 234–239.
- [Fis11c] Y. FISCHER, J. GEISLER und A. BAUER: »Task-Oriented Sensor Management for Wide-Area Surveillance«. *Proceedings of the 8th NATO Military Sensing Symposium (RTO-MP-SET-169)*. NATO Sensors und Electronics Technology (SET) Panel. 2011: S. 1–12.
- [Fis11d] Y. FISCHER und J. IJSSELMUIDEN: »A Bayesian Network Approach to Maritime Situation Assessment«. *Proceedings of the 1st International Workshop on Maritime Anomaly Detection (MAD)*. <http://mad.uvt.nl/mad/mad2011-proceedings.pdf>. 2011: S. 31–32.
- [Vag11] H. VAGTS, E. KREMPPEL und Y. FISCHER: »Access Controls for Privacy Protection in Pervasive Environments«. *Proceedings of the 4th International Conference on Pervasive Technologies Related to Assistive Environments (PETRA-PSPA)*. ACM, 2011: 52:1–52:8.

- [Bel12] A. BELKIN, A. KUWERTZ, Y. FISCHER und J. BEYERER: »World Modeling for Autonomous Systems«. *Innovative Information Systems Modelling Techniques*. Hrsg. von D. C. KALLONIATIS. <http://www.intechopen.com/books/innovative-information-systems-modelling-techniques/world-modelling-for-autonomous-systems>, letzter Abruf am 14.05.2015. InTech, 2012. Kap. 7: S. 137–158.
- [Fis12a] Y. FISCHER, M. BAUM, F. FLOHR, U. D. HANEBECK und J. BEYERER: »Evaluation of Tracking Methods for Maritime Surveillance«. *Proc. SPIE 8392, Signal Processing, Sensor Fusion, and Target Recognition XXI*. Bd. 839208. SPIE, 2012: S. 1–11.
- [Fis12b] Y. FISCHER und J. BEYERER: »A Top-Down-View on Intelligent Surveillance Systems«. *Proceedings of the 7th International Conference on Systems (ICONS)*. IARIA, 2012: S. 43–48.
- [Fis12c] Y. FISCHER und J. BEYERER: »Acceptance of Automatic Situation Assessment in Surveillance Systems«. *Proceedings of the 2nd International Multi-Disciplinary Conference on Cognitive Methods in Situation Awareness and Decision Support (CogSIMA)*. IEEE, 2012: S. 324–331.
- [Fis12d] Y. FISCHER und J. BEYERER: »Defining Dynamic Bayesian Networks for Probabilistic Situation Assessment«. *Proceedings of the 15th International Conference on Information Fusion (FUSION)*. ISIF. IEEE, 2012: S. 888–895.
- [Fis12e] Y. FISCHER und J. GEISLER: »A Bayesian Approach to the Detection of Hazardous Shipping Activity«. *Proceedings of the NATO Symposium on Port and Regional Maritime Security (RTO-MP-SCI-247)*. NATO Systems Concepts und Integration Panel (SCI) Panel. 2012: S. 1–11.
- [Kuw12] A. KUWERTZ, Y. FISCHER, B. ESSENDORFER und E. PEINSIPP-BYMA: »Using Context Knowledge for Maritime Situation Assessment«. *Proceedings of the 3rd International Conference on Waterside Security (WSS)*. 2012: S. 1–7.

- [Ess13] B. ESSENDORFER und Y. FISCHER: »System Architecture Supporting Detection of Threats in Asymmetric Warfare«. *Prediction and Recognition of Piracy Efforts Using Collaborative Human-Centric Information Systems*. Hrsg. von É. BOSSÉ, E. SHAHBAZIAN und G. ROGOVA. Bd. 109. NATO Science for Peace and Security Series - E: Human and Societal Dynamics. IOS Press, 2013: S. 160–167.
- [Fis13a] Y. FISCHER und J. BEYERER: »Modeling of Expert Knowledge for Maritime Situation Assessment«. *International Journal On Advances in Systems and Measurements* (2013), Bd. 6(3&4). [http://www.iariajournals.org/systems\\_and\\_measurements](http://www.iariajournals.org/systems_and_measurements), letzter Abruf am 14.05.2015: S. 245–259.
- [Fis13b] Y. FISCHER und J. BEYERER: »Ontologies for Probabilistic Situation Assessment in the Maritime Domain«. *Proceedings of the 3rd International Multi-Disciplinary Conference on Cognitive Methods in Situation Awareness and Decision Support (CogSIMA)*. IEEE, 2013: S. 102–105.
- [Hil13] J. HILD, Y. FISCHER, E. PEINSIPP-BYMA und J. BEYERER: »Gaze-Based Interaction for Real-Time Video Surveillance Systems«. *Proceedings of the 8th Security Research Conference (Future Security)*. Fraunhofer Verlag, 2013: S. 63–72.
- [Fis14a] Y. FISCHER, E. KREMPEL, P. BIRNSTILL, G. UNMÜSSIG, E. MONARI, J. MOSSGRABER, M. SCHENK und J. BEYERER: »Privacy-Aware Smart Video Surveillance Revisited«. *Proceedings of the 9th Security Research Conference (Future Security)*. Fraunhofer Verlag, 2014: S. 91–99.
- [Fis14b] Y. FISCHER, A. REISWICH und J. BEYERER: »Modeling and Recognizing Situations of Interest in Surveillance Applications«. *Proceedings of the 4th International Multi-Disciplinary Conference on Cognitive Methods in Situation Awareness and Decision Support (CogSIMA)*. IEEE, 2014: S. 186–192.
- [Ann15] M. ANNEKEN, M. TEUTSCH, S. BRÜSTLE, G. UNMÜSSIG, T. SCHUCHERT und Y. FISCHER: »Automatic Detection of Abnormal Vehicle Behavior within Large-scale Aerial Video Data«. *Proceedings of the NATO Symposium on Information Fusion (Hard and Soft) for Intelligence, Surveillance & Reconnaissance (IST-SET-126)*. NATO Information Systems und Technology (IST) Panel. 2015: S. 1–12.

---

# Betreute studentische Arbeiten

---

- [Bor10] J. BORNE: »High-Level Markov Random Fields«. Proseminar Anthropomatik: Von der Theorie zur Anwendung. Karlsruher Institut für Technologie (KIT), 2010.
- [Flo11] F. FLOHR: »Implementierung und Evaluation echtzeitfähiger Multi-Target-Tracking-Verfahren in der NEST-Modellwelt«. Masterarbeit. Karlsruher Institut für Technologie (KIT), 2011.
- [Hei11] T. HEISTERMANN: »Erklärungsmethoden für Bayessche Netzwerke in maritimen Entscheidungsunterstützungssystemen«. Proseminar Anthropomatik: Von der Theorie zur Anwendung. Karlsruher Institut für Technologie (KIT), 2011.
- [Kru12] J. KRUCK: »Bayessche Netze für die Situationsanalyse«. Bachelorarbeit. Karlsruher Institut für Technologie (KIT), 2012.
- [Put12a] D. PUTSCH: »Generierung Dynamischer Bayes-Netze für die maritime Situationsanalyse«. Diplomarbeit. Karlsruher Institut für Technologie (KIT), 2012.
- [Put12b] D. PUTSCH: »Komplexitätsabschätzung bei dynamischen Bayes-Netzen«. Studienarbeit. Karlsruher Institut für Technologie (KIT), 2012.
- [Wit12] S. WITT: »Situationsanalyse auf Basis unvollständiger Information«. Bachelorarbeit. Hochschule Karlsruhe (HS), 2012.
- [Wör13] T. WÖRTWEIN: »Multi-Entity Bayesian Networks (MEBN)«. Proseminar Anthropomatik: Von der Theorie zur Anwendung. Karlsruher Institut für Technologie (KIT), 2013.

- [Unm14] G. UNMÜSSIG: »Maschinelle Lernverfahren für die Anomaliedetektion«. Masterarbeit. Hochschule Karlsruhe (HS), 2014.
- [Phi15] P. PHILIPP: »Modellierung medizinischer Leitlinien zur interaktiven Unterstützung von Diagnoseprozessen«. Diplomarbeit. Karlsruher Institut für Technologie (KIT), 2015.
- [Zho15] Y. ZHOU: »Maritime Situation Analysis with Markov Logic Networks«. Masterarbeit. Karlsruher Institut für Technologie (KIT), 2015.




# A

---


## Situationsnetzwerke

---


Abbildungen A.1 bis A.6 zeigen die in Abschnitt 6.2 verwendeten Situationsnetzwerke.




**Abbildung A.1.:** Situationsnetzwerke zu den Situationen  $S^1$  und  $S^2$ .



**Abbildung A.2.:** Situationsnetzwerke zu den Situationen  $S^3$  und  $S^4$ .



**Abbildung A.3.:** Situationsnetzwerke zu den Situationen  $S^5$  und  $S^6$ .



**Abbildung A.4.:** Situationsnetzwerke zu den Situationen  $S^7$  und  $S^8$ .




Abbildung A.5.: Situationsnetzwerke zu den Situationen  $S^9$  und  $S^{10}$ .




Abbildung A.6.: Situationsnetzwerke zu den Situationen  $S^{11}$  und  $S^{12}$ .



# Karlsruher Schriftenreihe zur Anthropomatik (ISSN 1863-6489)

---

Herausgeber: Prof. Dr.-Ing. Jürgen Beyerer

Die Bände sind unter [www.ksp.kit.edu](http://www.ksp.kit.edu) als PDF frei verfügbar  
oder als Druckausgabe bestellbar.

- Band 1**      Jürgen Geisler  
**Leistung des Menschen am Bildschirmarbeitsplatz.** 2006  
ISBN 3-86644-070-7
  
- Band 2**      Elisabeth Peinsipp-Byma  
**Leistungserhöhung durch Assistenz in interaktiven Systemen  
zur Szenenanalyse.** 2007  
ISBN 978-3-86644-149-1
  
- Band 3**      Jürgen Geisler, Jürgen Beyerer (Hrsg.)  
**Mensch-Maschine-Systeme.** 2010  
ISBN 978-3-86644-457-7
  
- Band 4**      Jürgen Beyerer, Marco Huber (Hrsg.)  
**Proceedings of the 2009 Joint Workshop of Fraunhofer IOSB and  
Institute for Anthropomatics, Vision and Fusion Laboratory.** 2010  
ISBN 978-3-86644-469-0
  
- Band 5**      Thomas Usländer  
**Service-oriented design of environmental information systems.** 2010  
ISBN 978-3-86644-499-7
  
- Band 6**      Giulio Milighetti  
**Multisensorielle diskret-kontinuierliche Überwachung und  
Regelung humanoider Roboter.** 2010  
ISBN 978-3-86644-568-0
  
- Band 7**      Jürgen Beyerer, Marco Huber (Hrsg.)  
**Proceedings of the 2010 Joint Workshop of Fraunhofer IOSB and  
Institute for Anthropomatics, Vision and Fusion Laboratory.** 2011  
ISBN 978-3-86644-609-0
  
- Band 8**      Eduardo Monari  
**Dynamische Sensorselektion zur auftragsorientierten  
Objektverfolgung in Kameranetzwerken.** 2011  
ISBN 978-3-86644-729-5

- Band 9** Thomas Bader  
**Multimodale Interaktion in Multi-Display-Umgebungen.** 2011  
ISBN 3-86644-760-8
- Band 10** Christian Frese  
**Planung kooperativer Fahrmanöver für kognitive Automobile.** 2012  
ISBN 978-3-86644-798-1
- Band 11** Jürgen Beyerer, Alexey Pak (Hrsg.)  
**Proceedings of the 2011 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory.** 2012  
ISBN 978-3-86644-855-1
- Band 12** Miriam Schleipen  
**Adaptivität und Interoperabilität von Manufacturing Execution Systemen (MES).** 2013  
ISBN 978-3-86644-955-8
- Band 13** Jürgen Beyerer, Alexey Pak (Hrsg.)  
**Proceedings of the 2012 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory.** 2013  
ISBN 978-3-86644-988-6
- Band 14** Hauke-Hendrik Vagts  
**Privatheit und Datenschutz in der intelligenten Überwachung: Ein datenschutzgewährendes System, entworfen nach dem „Privacy by Design“ Prinzip.** 2013  
ISBN 978-3-7315-0041-4
- Band 15** Christian Kühnert  
**Data-driven Methods for Fault Localization in Process Technology.** 2013  
ISBN 978-3-7315-0098-8
- Band 16** Alexander Bauer  
**Probabilistische Szenenmodelle für die Luftbildauswertung.** 2014  
ISBN 978-3-7315-0167-1
- Band 17** Jürgen Beyerer, Alexey Pak (Hrsg.)  
**Proceedings of the 2013 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory.** 2014  
ISBN 978-3-7315-0212-8
- Band 18** Michael Teutsch  
**Moving Object Detection and Segmentation for Remote Aerial Video Surveillance.** 2015  
ISBN 978-3-7315-0320-0

- Band 19** Marco Huber  
**Nonlinear Gaussian Filtering:  
Theory, Algorithms, and Applications.** 2015  
ISBN 978-3-7315-0338-5
- Band 20** Jürgen Beyerer, Alexey Pak (Hrsg.)  
**Proceedings of the 2014 Joint Workshop of Fraunhofer IOSB and  
Institute for Anthropomatics, Vision and Fusion Laboratory.** 2014  
ISBN 978-3-7315-0401-6
- Band 21** Todor Dimitrov  
**Permanente Optimierung dynamischer Probleme  
der Fertigungssteuerung unter Einbeziehung von  
Benutzerinteraktionen.** 2015  
ISBN 978-3-7315-0426-9
- Band 22** Benjamin Kühn  
**Interessengetriebene audiovisuelle Szenenexploration.** 2016  
ISBN 978-3-7315-0457-3
- Band 23** Yvonne Fischer  
**Wissensbasierte probabilistische Modellierung für die  
Situationsanalyse am Beispiel der maritimen Überwachung.** 2016  
ISBN 978-3-7315-0460-3

Lehrstuhl für Interaktive Echtzeitsysteme  
Karlsruher Institut für Technologie

Fraunhofer-Institut für Optronik, Systemtechnik und  
Bildauswertung IOSB Karlsruhe

In heutigen Überwachungssystemen wird eine Vielzahl heterogener Sensorik in einem Systemverbund eingesetzt. Mit dem verstärkten Einsatz von Sensorik wächst auch das zu verarbeitende Datenvolumen deutlich an. Daraus resultiert wiederum der Bedarf, den menschlichen Entscheider zu entlasten, indem diese Daten intelligent verarbeitet und ihm die Ergebnisse aufgabenabhängig präsentiert werden. Die vorliegende Arbeit leistet einen Beitrag zur Situationsanalyse, einem Teilbereich der Datenfusion. Das hier entwickelte Gesamtkonzept der Situationsanalyse behandelt unter anderem den Prozess, welcher Echtzeitdaten hinsichtlich modellierter Situationen von Interesse auswertet und dem Entscheider die erkannten Situationen entsprechend präsentiert. Dazu wird eine Situation mathematisch definiert und die wissensbasierte Modellierung von Situationen in einem Situationsnetzwerk vorgestellt. Für die Auswertung wird aus dem Situationsnetzwerk ein situationsspezifisches dynamisches Bayes'sches Netz (SSDBN) generiert, wobei die Herausforderung bei der Bestimmung der Parameter liegt. Um die Funktionalität des in dieser Arbeit entwickelten Ansatzes zu demonstrieren, werden mehrere Situationen von Interesse in der maritimen Domäne modelliert und bezüglich ihrer Erkennungsqualität evaluiert. Die Evaluierung wird dabei sowohl mittels simulierter Daten als auch mittels Realdaten durchgeführt.

ISSN 1863-6489  
ISBN 978-3-7315-0460-3

