

Erkennung von Fahrmanövern mit objektorientierten Bayes-Netzen in Autobahnszenarien

Dissertation

der Mathematisch-Naturwissenschaftlichen Fakultät
der Eberhard Karls Universität Tübingen
zur Erlangung des Grades eines
Doktors der Naturwissenschaften
(Dr. rer. nat.)

vorgelegt von
Dipl.-Ing. (FH) Dietmar Kasper, MSc
aus Krasnokamensk

Tübingen
2012

Tag der mündlichen Qualifikation:

25.03.2013

Dekan:

Prof. Dr. Wolfgang Rosenstiel

1. Berichterstatter:

Prof. Dr. Wolfgang Rosenstiel

2. Berichterstatter:

Prof. Dr.-Ing. Christoph Stiller

Vorwort

Die vorliegende Dissertation entstand in der Abteilung Fahrerassistenzsysteme (RD/FFA) der Daimler AG Forschung und Vorentwicklung sowie am Lehrstuhl für Technische Informatik des Wilhelm-Schickard-Instituts der Eberhard Karls Universität Tübingen.

Herrn Prof. Dr. Wolfgang Rosenstiel danke ich ganz herzlich für die Betreuung und Unterstützung, die wichtigen Anregungen und Diskussionen sowie ein angenehmes Arbeitsklima mit vielen Freiheiten in meiner wissenschaftlichen Arbeit.

Herrn Prof. Dr.-Ing. Christoph Stiller gilt mein Dank für die spontane Übernahme des Korreferats und sein Interesse an meiner Arbeit.

Bei allen Kollegen der Abteilung Fahrerassistenzsysteme möchte ich mich für die gute Atmosphäre und für ihre Hilfsbereitschaft bedanken. Frau Dr. Gabi Breuel verdanke ich ein spannendes Promotionsthema, die Förderung durch wichtige Anregungen und Motivation. Mein besonderer Dank gilt Herrn Arthur Riesen und allen die sich die mühsame Arbeit des Korrekturlesens gemacht haben. Frau Dr. Galia Weidl und Herrn Dr. Thao Dang, Dr. Andreas Wedel, Andreas Tamke, Adam Berthelot danke ich herzlich für die fachliche Unterstützung, anregende Diskussionen und viele praktische Hilfestellungen während meiner gesamten Promotion. Herr Dr. Clemens Rabe gilt mein Dank für die hervorragende \LaTeX -Vorlage, mit deren Hilfe diese Arbeit entstanden ist.

Mein ganz besonderer Dank gilt meiner Familie und meinen Freunden, die mir jederzeit zur Seite standen. Ihnen ist diese Arbeit gewidmet.

Tübingen, im März 2013

Dietmar Kasper

„The future belongs to those who see possibilities before they become obvious.”

- John Sculley

Inhaltsverzeichnis

Symbolverzeichnis	VII
1 Einleitung	1
1.1 Motivation	1
1.2 Aufbau der Arbeit	5
2 Grundlagen	7
2.1 Warum Bayes-Netze?	7
2.2 Einführung in Bayes-Netze	9
2.2.1 Repräsentation	9
2.2.2 Inferenz	17
2.2.3 Lernen	29
2.3 Objektorientierte Bayes-Netze	30
3 Stand der Technik	35
3.1 Fahrerassistenzsysteme	35
3.1.1 Fahrerassistenz auf Stabilisierungsebene	37
3.1.2 Fahrerassistenz auf Bahnführungs- und Navigationsebene	37
3.2 Methoden der Aktionserkennung	38
3.2.1 Fuzzy-Logik	39

3.2.2	Bayes-Netze	40
3.2.3	Dynamische Bayes-Netze	41
3.2.4	Hidden Markov Modelle	42
3.2.5	Dempster-Shafer-Theorie	43
3.2.6	Neuronale Netze	44
3.2.7	Relevance-Vector-Machine	44
3.3	Bedarf neuer Lösungen	44
4	Erkennung von Fahrmanövern	49
4.1	Modellierungsansatz	49
4.1.1	Schichtenmodell	51
4.2	Merkmalsextraktion	52
4.2.1	Koordinatensysteme	52
4.2.2	Situationsmerkmale	54
4.3	Objektorientierte Modellierung	68
4.3.1	Modellierung der Unsicherheiten in Sensordaten	69
4.3.2	Modellierung der Grundhypothesen	70
4.3.3	Modellierung der Fahrmanöver-Hypothesen	72
4.4	Bayes-Netz-Parameter	75
4.4.1	Parameter der Grundhypothesen	76
4.4.2	Parameter der Fahrmanöver-Hypothesen	81
5	Umsetzung im Fahrzeug	87
5.1	Hardware-Architektur	87
5.1.1	Versuchsträger	87
5.1.2	Rechnersysteme und Vernetzung	89
5.2	Software-Architektur	91
5.2.1	Situationsbeschreibung und Weltmodell	93
5.2.2	Eingangsdaten	96

5.2.3	Sensordatenfusion	99
5.2.4	Fahrmanöver-Erkennungsmodul	100
6	Experimentelle Ergebnisse und Evaluation	103
6.1	Ziele der Untersuchung	103
6.2	Online-Evaluierung	105
6.2.1	Evaluierungsmodul	105
6.2.2	Systemauslegung	107
6.3	Diskussion der Ergebnisse	109
6.3.1	Ergebnisse am Beispiel einzelner Manöver	109
6.3.2	Gesamtergebnis der Online-Evaluierung	115
6.3.3	Fehlerursachen	118
7	Zusammenfassung und Ausblick	121
A	Frenet Koordinaten	125
B	Maximum Likelihood Methode	129
	Literaturverzeichnis	132

Symbolverzeichnis

Akürzungen

PGM	engl. <i>Probabilistic Graphical Models</i>
DAG	engl. <i>Directed Acyclic Graph</i>
BN	Bayes-Netz
DBN	dynamisches Bayes-Netz
OoBN	objektorientiertes Bayes-Netz
HMM	engl. <i>Hidden Markov Model</i>
RVM	engl. <i>Relevance Vector Machine</i>
SVM	engl. <i>Support Vector Machine</i>
CPT	engl. <i>Conditional Probability Table</i>
CPD	engl. <i>Conditional Probability Distribution</i>
JTA	engl. <i>Junction Tree Algorithm</i>
ABS	Antiblockiersystem
ESP	elektronisches Stabilitätsprogramm
ACC	engl. <i>Adaptive Cruise Control</i>
CAN	engl. <i>Controller Area Network</i>
GPS	engl. <i>Global Positioning System</i>
UDP	engl. <i>User Datagram Protocol</i>
TCP	engl. <i>Transmission Control Protocol</i>
CMOS	engl. <i>Complementary Metal Oxide Semiconductor</i>
NBR	Nahbereichsradar

FBR	Fernbereichsradar
MI-Box	Mess-Interface-Box
RAM	engl. <i>Random Access Memory</i>
LVDS	engl. <i>Low Voltage Differential Signaling</i>
BV	Bildverarbeitung
SG	Steuergerät
API	engl. <i>Application Programming Interface</i>

Notationsvereinbarungen

Skalare	nicht fett, kursiv: $x, y, z, X, Y, Z \dots$
Vektoren	fett, nicht kursiv: $\mathbf{x}, \mathbf{y}, \mathbf{z}, \mathbf{X}, \mathbf{Y}, \mathbf{Z} \dots$
Matrizen	fett, nicht kursiv, groß: $\mathbf{A}, \mathbf{B}, \mathbf{C} \dots$

Symbole

Ego	eigenes Fahrzeug
Obj	Objekt in der Umgebung (z.B. Fahrzeug)
id	Eindeutige ID eines Objektes
t_{life}	Lebensdauer eines Objektes [s]
x_{rel}	relative Position in x-Richtung [m]
y_{rel}	relative Position in y-Richtung [m]
$v_{x_{rel}}$	relative Geschwindigkeit in x-Richtung [m/s]
$v_{y_{rel}}$	relative Geschwindigkeit in y-Richtung [m/s]
$a_{x_{rel}}$	relative Beschleunigung in x-Richtung [m/s ²]
$a_{y_{rel}}$	relative Beschleunigung in y-Richtung [m/s ²]
ψ	Gierwinkel eines Fahrzeuges [rad]
$\dot{\psi}$	Giergeschwindigkeit eines Fahrzeuges [rad/s]
ϕ_{spur}	Kurswinkel relativ zum Spurverlauf [rad]
R	Radius [m]

B	Breite eines Fahrzeuges [m]
L	Länge eines Fahrzeuges [m]
c_0	Krümmung [$1/m$]
c_1	Krümmungsänderung [s/m]
$dy_{spur}, \Delta y$	lateraler Abstand zur Spurmarkierung [m]
K_{spur}	krummliniges Spurkoordinatensystem
K_{ego}	Fahrzeugkoordinatensystem nach DIN70000
Pos^p	Position eines Fahrzeuges in der Spur $p \in \{links, rechts, voraus\}$
$olat$	Spurversatz [m]
v_{lat}	laterale Geschwindigkeit eines Fahrzeuges in der Spur [m/s]
T_{lcr}	Zeit bis zur Überquerung einer Spurmarkierung [m/s]
$a_{lat_{max}}$	maximal ausgenutzte laterale Beschleunigung [m/s^2]
T_{TE}	Zeit bis zum Eintritt in eine Zone [s]
T_{TD}	Zeit bis zum Austritt aus einer Zone [s]
S_{TE}	Abstand bis zum Beginn einer Zone [m]
S_{TD}	Abstand bis zum Ende einer Zone [m]
$l, v, r, h, vl, vr, hl, hr$	Position der Zellen eines Belegungsgitters (links, vorne, rechts, hinten)
μ	Erwartungswert
σ	Standardabweichung
σ^2	Varianz
$P(A)$	Wahrscheinlichkeit einer Variable
$P(A B)$	bedingte Wahrscheinlichkeit einer Variable
$P(A, B)$	Verbundwahrscheinlichkeit von Variablen
$P(\mathcal{G})$	Verbundwahrscheinlichkeit im Graph
$pa(A)$	Elternknoten einer Variable im Graph

<i>E</i>	Evidenz
<i>e</i>	Zustände von Evidenzen
<i>e</i>	Fehler
\mathbb{R}	Menge der reellen Zahlen
$\mathcal{N}(\mu, \sigma^2)$	Normalverteilung mit Erwartungswert μ und Varianz σ^2
<i>R</i>	Rotationsmatrix
<i>T</i>	Tangentenvektor
<i>N</i>	Hauptnormalenvektor
<i>B</i>	Binormalenvektor

Kapitel 1

Einleitung

„Eine Baustellenabspernung fällt um: Der Autofahrer kann nicht ausweichen, denn auf der Nebenspur fahren weitere Fahrzeuge. Mit einer neuen Software können Autos in Gefahrensituationen künftig gemeinsam koordinierte Fahrmanöver durchführen. [...]“ [1].

1.1 Motivation

Seit langer Zeit beschäftigen sich die Automobilhersteller mit der Aufgabe, das Fahren immer sicherer und komfortabler zu machen. Die Einführung des Sicherheitsgurtes in den 50er Jahren war einer der ersten Schritte auf diesem Weg. Im Laufe der Jahre fanden immer mehr Assistenzsysteme Einzug in das Automobil. So wurde in den 70er Jahren das Antiblockiersystem (ABS), in den 80er Jahren der Airbag als passives Sicherheitssystem sowie in den 90er Jahren das elektronische Stabilisierungsprogramm (ESP) eingeführt. Diese Assistenzsysteme sind aus dem alltäglichen Autofahren nicht mehr wegzudenken und wurden entwickelt, um fahrdynamische Stabilität zu garantieren (ABS, ESP) oder die Unfallschwere zu reduzieren (Airbag).

Eine weitere Entwicklung auf dem Gebiet Fahrerassistenzsysteme stellt der Abstandsregeltempomat dar, welcher in den 90er Jahren eingeführt wurde. Hierfür wurde erstmals ein Radarsensor zur Umgebungserfassung eingesetzt. Seitdem wurde dieses Assistenzsystem weiterentwickelt und ständig um neue Funktionalitäten erweitert. Derzeit verbessern die Assistenzsysteme nicht nur den Fahr-

komfort, sondern greifen auch in kritischen Situationen in das Fahrgeschehen ein, um bereits vor dem Unfall verschiedene Maßnahmen zur Unfallvermeidung oder -minderung einzuleiten.

Während immer mehr Assistenzsysteme neu- oder weiterentwickelt und auf dem Markt zur Verfügung gestellt werden, wachsen gleichzeitig auch die Anforderungen an diese enorm. Der Reifegrad und die Akzeptanz von derzeit verfügbaren Fahrerassistenzsystemen wurde in der Autobild untersucht [2]. Daraus geht hervor, dass bei vielen Assistenzsystemen ein Verbesserungsbedarf besteht. Ein vom Fahrer nicht nachvollziehbares Warnen in unterschiedlichen Situationen ist nur eines der Probleme bei der Entwicklung von Fahrerassistenzsystemen. Um eine große Kundenakzeptanz zu erreichen, muss die vorliegende Situation von Assistenzsystemen besser interpretiert werden können. Dies erfordert nicht nur die Verbesserung der eingesetzten Sensorik zur Umfelderkennung, sondern auch den Einsatz neuer Techniken, unter anderem die Anwendung von Methoden der künstlichen Intelligenz.

Künstliche Intelligenz ist ein Teilgebiet der Informatik, welches sich mit der Entwicklung intelligenter Maschinen oder Programme beschäftigt. Dabei wird versucht, die Intelligenz eines Menschen nachzubilden [3], [4]. Die Definition nach Elaine Rich, „*Artificial Intelligence is the study of how to make computers do things at which, at the moment, people are better. [...]*“, passt am besten für den Einsatz der künstlichen Intelligenz auf dem Gebiet der Fahrerassistenzsysteme.

Abbildung 1.1 stellt den grundsätzlichen Aufbau eines intelligenten Programms, auch Agent genannt, dar. Bei einer Aufgabenbewältigung findet in den meisten Fällen immer eine Interaktion eines intelligenten Agenten mit seiner Um-

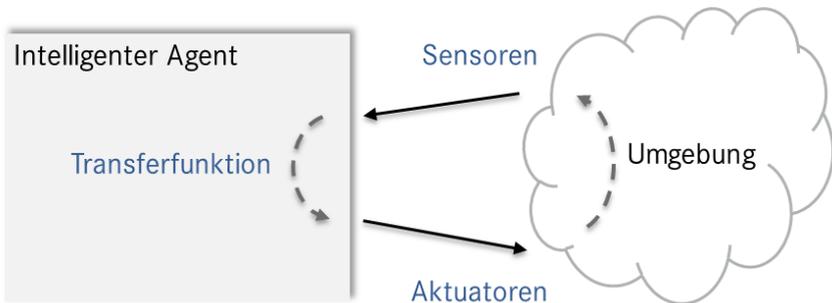


Abbildung 1.1: Aufbau eines intelligenten Agenten

gebung statt. Die Informationen über die Umgebung werden über die Sensoren zur Verfügung gestellt (Radar, Kamera, Ultraschall, etc.). Der Rückkanal, also die Einflussnahme auf die Umgebung, wird durch optische, akustische Hinweise und Aktuatoren ermöglicht (Lenkung, Bremse). Die Abbildung einer möglichen Handlung, basierend auf den zur Verfügung stehenden Informationen der Umgebungserfassung, wird als Transferfunktion bezeichnet. Der Prozess von der Umgebungserfassung bis zur Ableitung einer notwendigen Aktion wird auch *Perception-Action-Cycle* genannt.

Eines der Ziele der Entwickler auf dem Gebiet der Fahrerassistenzsysteme ist das Finden einer geeigneten Transferfunktion, die für eine bestimmte Art von Aufgaben am besten geeignet ist. Diese ist für das Verhalten eines Assistenzsystems verantwortlich und spiegelt sich direkt in der Kundenakzeptanz dieser Systeme wieder. Die Suche nach einer passenden Transferfunktion ist aus verschiedenen Gründen eine sehr schwierige Aufgabe der Forschung und Entwicklung. Um eine bestimmte Situation besser verstehen zu können, müssen Kriterien gefunden werden, anhand welcher der Mensch seine Entscheidungen trifft. Dies wird auch als die Fähigkeit der kognitiven Wahrnehmung bezeichnet. Die Entscheidungen eines Menschen basieren meistens auf einem großen Erfahrungsschatz, welcher den Assistenzsystemen bereitgestellt werden muss. Außerdem kann die Informationsfülle, die zur Entscheidungsfindung einem Menschen durch Sinnesorgane zur Verfügung steht, von keinem Sensor zur Umgebungserfassung abgedeckt werden.

Abbildung 1.2 zeigt einen möglichen Aufbau einer Transferfunktion im Bereich der Fahrerassistenzsysteme. Diese beinhaltet drei Schichten von der Objektbildung über die Situationsanalyse bis hin zur Funktion. Die Situationsanalyse kann noch einmal in verschiedene Aufgabenbereiche unterteilt werden. Diese können mit einer menschlichen Analyse einer vorliegenden Situation und Ableitung einer notwendigen Handlung verglichen werden. Als erstes muss eine Situation beschrieben werden. Dazu gehört die Festlegung von Objekteigenschaften und die Definition von möglichen Objekt-Beziehungen. Zur nächsten Aufgabe gehört die Interpretation und Klassifikation einer Situation. Nach dem eine Situation beschrieben und klassifiziert wurde folgt die Situationsprognose. Die Situationsprognose beschäftigt sich mit der Vorhersage einer möglichen Weiterentwicklung von Situationen. Zum Beispiel dauert ein vollständiges Spurwechselmanöver in der Regel 2.0s bis 4.0s. Wird dieses innerhalb der ersten Millisekunden klassifiziert, so wird eine Vorhersage getroffen, dass dieses stattfinden wird oder wie dieses sich weiterentwickeln könnte. Da aber die tatsächliche Entwicklung einer Situation nicht bekannt ist, wird im weiteren Verlauf dieser Arbeit das Ergebnis der Klassifikation auch als Prognose bezeichnet. Zum Schluss wird die vorliegende Situation und deren mögliche Weiterentwicklung bezüglich Sicherheit oder Komfort bewertet. Je nachdem, wie die Bewertung aussieht, können Handlungen wie Lenken, Bremsen, Warnen oder Informieren abgeleitet werden.

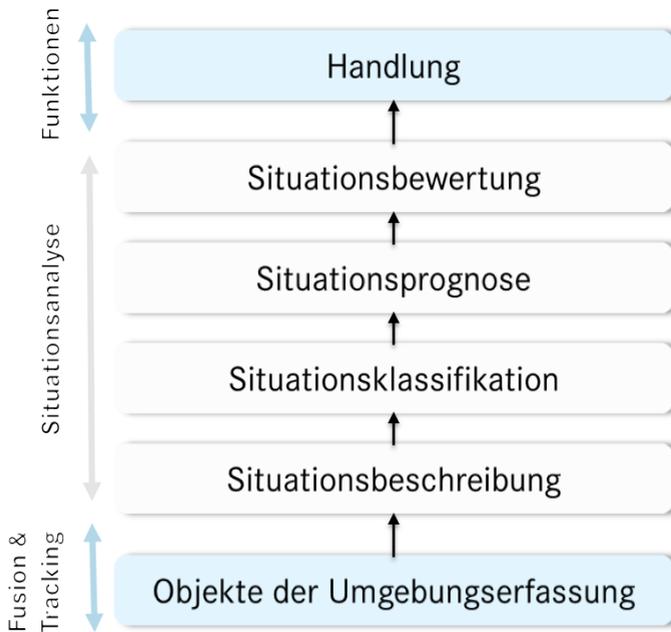


Abbildung 1.2: Aufbau einer Transferfunktion für ein Fahrerassistenzsystem

Die Situationsklassifikation spielt eine wichtige Rolle bei der Suche nach einer passenden Transferfunktion. Das Verhalten eines Assistenzsystems kann an eine bestimmte Fahr-situation, falls diese verstanden werden kann, angepasst werden. Dadurch wird die Kundenakzeptanz erhöht, was dem Ziel der Entwicklung entspricht. Um dies zu erreichen, müssen im ersten Schritt ein passendes Modell und entsprechende Modellparameter zur Modellierung einer Situation gefunden werden. Derzeit gibt es viele Methoden wie Neuronale Netze, Fuzzy-Logik, Bayes-Netze auf dem Gebiet der künstlichen Intelligenz, die für solche Aufgabestellungen geeignet sind. Die Aufgabe der Forschung ist die Untersuchung von vorhandenen Methoden und deren Weiter- oder Neuentwicklung, um das bestmögliche Ergebnis bei der Lösung einer bestimmten Aufgabe zu erzielen.

Diese Arbeit beschäftigt sich mit der allgemeingültigen Beschreibung einer Fahr-situation (*Situationsbeschreibung*) sowie mit der Erkennung von Fahr-situationen (*Situationsklassifikation*).

1.2 Aufbau der Arbeit

Die vorliegende Arbeit baut auf den Ergebnissen von [5], [6], [7], [8] auf. Hier wurde eine Verbesserung der Funktionalität eines Abstandsregeltempomaten durch die Erkennung von Einscherer-Situationen mit Bayes-Netzen untersucht.

Eine konsequente Erweiterung dieser Arbeiten, um mehr Verständnis über die vorliegende Situation zu gewinnen, ist die Erkennung von Einscherer- und Auscherer-Situationen sowohl für die umgebenden Fahrzeuge als auch für das Ego-Fahrzeug. Dazu wurde in dieser Arbeit ein neues Bayes-Netz-Modell entwickelt und neue Situationsmerkmale zur Beschreibung einer Fahrsituation eingeführt. Die vorliegende Arbeit ist wie folgt gegliedert:

- Um ein besseres Verständnis für die in dieser Arbeit eingesetzten Methoden und Begriffe zu bekommen, werden in Kapitel 2 die notwendigen mathematischen Grundlagen der Bayes-Netze vorgestellt.
- Kapitel 3 gibt einen Überblick über den Stand der Technik und eingesetzte Methoden der Situationsklassifikation sowie derzeit vorhandene Fahrerassistenzsysteme wieder. Daraus werden notwendige Erweiterungen der Aktionserkennung auf dem Gebiet der Fahrerassistenzsysteme abgeleitet.
- Kapitel 4 beschäftigt sich mit der Modellierung von Fahrmanövern in einem Autobahnszenario. Zunächst wird der Modellierungsansatz und die Idee der Erkennung von Fahrmanövern vorgestellt. Danach werden Situationsmerkmale zur Beschreibung einer Situation, deren Berechnung sowie das entwickelte Bayes-Netz-Modell und der Bayes-Netz-Parameter beschrieben.
- Der Aufbau des entwickelten Moduls zur Erkennung von Fahrmanövern und die Umsetzung im Fahrzeug wird in Kapitel 5 vorgestellt. Zusätzlich wird das entwickelte Modell zur Beschreibung einer Situation, der eingesetzte Versuchsträger mit der entsprechenden Sensorik sowie die verwendeten Sensoreingangsdaten beschrieben.
- Die Erkennungsleistung des Fahrmanöver-Erkennungsmoduls wurde in einem Fahrversuch evaluiert. Diese Ergebnisse werden in Kapitel 6 vorgestellt. Dabei werden verschiedene Systemauslegungen und deren Auswirkungen auf das Klassifikationsergebnis untersucht.
- Kapitel 7 fasst die wichtigsten Ergebnisse dieser Arbeit zusammen und gibt einen kurzen Ausblick auf mögliche weitere Aufgabenstellungen und Verbesserungen des in dieser Arbeit entwickelten Modells zur Erkennung von Fahrmanövern in einem Autobahnszenario.

Kapitel 2

Grundlagen

Die nächsten Kapitel geben einen Überblick über Bayes-Netze, die in dieser Arbeit als Methode zur Klassifikation von Fahrmanövern eingesetzt wurden. Die Motivation für den Einsatz der Bayes-Netze, ihre mathematischen Grundlagen sowie ihre Funktionsweise werden in den Kapiteln 2.1 und 2.2 vorgestellt. Objektorientierte Bayes-Netze stellen eine Erweiterung der klassischen Bayes-Netze dar. Ihre Vorteile und Aufbau werden in Kapitel 2.3 erklärt. Die in den nächsten Kapiteln vorgestellten Grundlagen stammen aus der Literatur [9], [10], [11], [12], [13].

2.1 Warum Bayes-Netze?

Bei vielen Aufgaben, die ein Mensch im täglichen Leben bewältigen muss, findet ein Prozess der Schlussfolgerung (Ergebnis des Nachdenkens) statt [9], [10], [11]. Dazu muss der Mensch im ersten Schritt die verfügbaren Informationen verarbeiten, um im zweiten abschätzen zu können, was *wahr* ist. Daraus können dann mögliche Handlungen abgeleitet werden. An dieser Stelle unterscheidet man grundsätzlich zwischen einem sicheren und unsicheren Schlussfolgern. Ein Arzt muss zum Beispiel anhand der Symptome eines Patienten eine mögliche Krankheit feststellen, um dann zu entscheiden, was zu tun ist, um diese zu bekämpfen. Da ein Arzt nicht immer in seiner Entscheidungsfindung sicher sein kann, versucht er abzuschätzen, was dem Patienten fehlen könnte. In anderen Worten muss er die Frage beantworten: „*Wie wahrscheinlich ist eine mögliche Krankheit?*“. Die Unsicherheiten bei der Schlussfolgerung entstehen aus dem fehlenden Erfahrungsschatz auf dem Aufgabengebiet („*So ein Fall wurde noch nie beobachtet.*“) oder

aus der zur Verfügung stehenden Information. Dabei können die Informationen unsicher sein („*Der Patient ist nicht sicher zu welcher Uhrzeit gegessen wurde.*“) oder komplett fehlen („*Ergebnis eines durchgeführten Tests fehlt.*“). Besitzt ein Arzt einen großen Erfahrungsschatz und stehen gleichzeitig genügend Informationen zur Verfügung, so ist die Wahrscheinlichkeit sehr hoch, dass eine richtige Entscheidung getroffen wird. An dieser Stelle spricht man von einem Experten auf einem bestimmten Aufgabengebiet [11], [12].

Um den Menschen bei seinen Schlussfolgerungen zu unterstützen, werden Computersysteme benötigt, die in der Lage sind unterschiedliche Möglichkeiten bei der Entscheidungsfindung zu berücksichtigen. Einer der Ansätze ist eine einfache Auswahl von nur einer der vielen Möglichkeiten. Da aber meistens Informationen zur Entscheidungsfindung unsicher sind, ist es unglücklicherweise nicht immer möglich, sich nur für eine der Möglichkeiten zu entscheiden. In unserem obigen Beispiel könnte es viele Krankheiten geben, die bei der gleichen zur Verfügung stehenden Information möglich wären. Viele davon können auch höchst unwahrscheinlich sein, sind aber nicht sicher auszuschließen. Daraus folgt, dass ein Computersystem nicht nur die Möglichkeiten, sondern gleichzeitig auch die Wahrscheinlichkeiten für diese berücksichtigen muss. Der Umgang mit unvollständigen oder unsicheren Informationen spielt dabei eine wichtige Rolle.

Die Wahrscheinlichkeitstheorie bietet an dieser Stelle einen Formalismus zur Berücksichtigung von vielen möglichen Ereignissen und deren Wahrscheinlichkeiten. Dazu gehört im Allgemeinen die Vielfalt von probabilistischen, grafischen Modellen. Der Aufbau von solchen intelligenten Systemen besteht aus drei wesentlichen Komponenten: Repräsentation, Inferenz und Lernen. Es wird eine angemessene mathematische Beschreibungsform zur Repräsentation unserer Welt („*Modell für medizinische Diagnostik.*“) benötigt. Aufbauend auf dieser Form müssen viele Fragen, die von Interesse sind, effektiv beantwortet werden können („*Wie wahrscheinlich ist eine Krankheit bei gegebener Information?*“). Außerdem muss es möglich sein, anhand der zur Verfügung stehenden Informationen und Expertenwissen, das Schlussfolgern von solchen Systemen zu verbessern. („*Je mehr gleiche Symptome für eine bestimmte Krankheit beobachtet worden sind, desto sicherer ist man, dass es sich auch um diese handelt.*“)

Bei der Bewältigung einer Fahraufgabe muss der Mensch die gleiche Art der Schlussfolgerung durchführen („*Wie wahrscheinlich ist ein möglicher Ausgang einer Fahr-situation bei gegebener Information?*“). Somit müssen die eingesetzten Methoden zum Verstehen einer Situation auf dem Gebiet der Fahrerassistenzsysteme dies unterstützen. Die Anforderungen an die möglichen Verfahren können folgendermaßen zusammengefasst werden:

- Umgang mit Unsicherheiten (Sensorrauschen) und unvollständigen Informationen. Umgang mit Modellunsicherheiten, da ein Modell nur einen ver-

einfachen Ausschnitt der Realität repräsentiert.

- Beherrschung der Komplexität durch Einbringung von a-priori Wissen und kausalen Zusammenhängen.
- Schnelle und effiziente Inferenz-Algorithmen.
- Lernfähigkeit zur Optimierung der Ergebnisse einer Schlussfolgerung.

Bayes-Netze gehören zu probabilistischen graphischen Modellen, die Schlussfolgerungen unter Berücksichtigung von Unsicherheiten unterstützen. Bayes-Netze bieten eine Beschreibungsform zur Bildung eines Modells zur Lösung einer bestimmten Aufgabe. Die kausalen Zusammenhänge zwischen den verschiedenen Variablen werden durch die Netzstruktur und das a-priori Wissen über das Verhalten eines Systems durch die Bayes-Netz-Parameter abgebildet. Außerdem gehören Bayes-Netze zu den lernfähigen Klassifikationsverfahren. Da Bayes-Netze in den letzten Jahren zur Lösung von verschiedenen Aufgaben verwendet wurden, gibt es viele Werkzeuge auf dem Markt, die die Erstellung von Modellen, eine effiziente Berechnung der Inferenz und den Einsatz von Lernverfahren unterstützen. Somit wären alle Anforderungen für den Einsatz der Bayes-Netze auf dem Gebiet der Fahrerassistenzsysteme erfüllt.

2.2 Einführung in Bayes-Netze

Probabilistische graphische Modelle bestehen aus drei wesentlichen Hauptkomponenten: *Repräsentation*, *Inferenz*, *Lernen*. In den nächsten Kapiteln werden diese Komponenten und deren Grundlagen vorgestellt [11].

2.2.1 Repräsentation

Bayes-Netze sind kausale Netze, welche aus einem qualitativen und einem quantitativen Teil aufgebaut sind [10], [11], [12].

Der qualitative Teil beschreibt eine Bayes-Netz-Struktur (\mathcal{G}), welche einen gerichteten, azyklischen Graphen darstellt (engl. *directed acyclic graph (DAG)*). Ein *DAG* besteht aus einem Satz von *Variablen*, die als Knoten in einem Bayes-Netz abgebildet werden. Dabei können die Variablen diskrete oder kontinuierliche Zustände annehmen. Diskrete Zustände sind zum Beispiel (*true, false*) oder (*rot, grün, blau*). Kontinuierliche Zustände werden dagegen durch eine Dichtefunktion dargestellt. Eine typische Dichtefunktion stellt die Normalverteilung $y = f(x|\mu, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$ dar. Die kausalen Zusammenhänge zwischen den *Variablen* in einem *DAG* werden durch *gerichtete Kanten* dargestellt. Wenn eine

Verbindung zwischen einer Variable A zu einer Variable B vorhanden ist, so ist B ein *Kindknoten* der Variable A , und A ein *Elternknoten* der Variable B [11].

Der quantitative Teil beschreibt die *Stärke* einer Verbindung zwischen zwei Variablen. Wenn A ein Elternknoten von B ist, so beschreibt die bedingte Wahrscheinlichkeit $P(B | A)$ die Stärke dieser Verbindung. Im Allgemeinen muss einer Variable B in einem Bayes-Netz mit den *Elternknoten* A_0, \dots, A_n eine bedingte Wahrscheinlichkeitstabelle $P(B | A_0, \dots, A_n)$ hinzugefügt werden (engl. *conditional probability table (CPT)*). Besitzt eine Variable B keine Elternknoten, so verringert sich die Tabelle zu einer nicht bedingten Wahrscheinlichkeitstabelle $P(B)$.

Abbildung 2.1 a) zeigt ein Beispiel für ein Bayes-Netz. Eine besondere Struktur eines gerichteten azyklischen Grafen stellt Abbildung 2.1 b) vor. Diese wird auch als Polybaumstruktur bezeichnet. Ein Graph hat eine Polybaumstruktur wenn nur ein einziger Pfad von einer Variable zu einer anderen vorhanden ist. In Abbildung 2.1 a) sind zwei Pfade von der Variable A zu Variable E dargestellt, dagegen ist in Abbildung 2.1 b) nur ein einziger Pfad vorhanden. Abbildung 2.1 c) stellt einen gerichteten zyklischen Graphen dar. Dieser ist bei der Betrachtung von Bayes-Netzen nicht erlaubt.

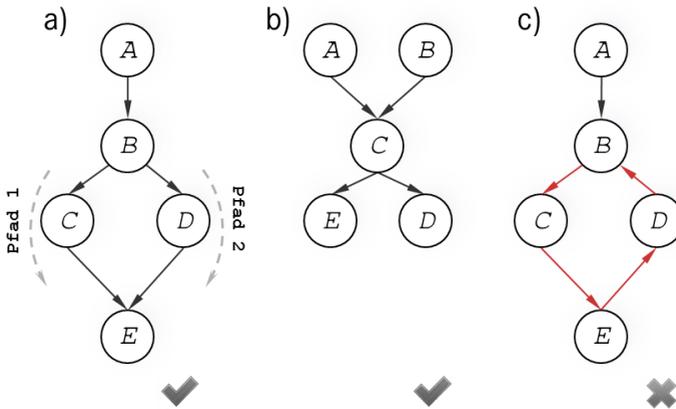


Abbildung 2.1: a) Gerichteter azyklischer Graph mit den zu definierenden Wahrscheinlichkeiten: $P(A)$, $P(B | A)$, $P(C | B)$, $P(D | B)$, $P(E | C, D)$. b) Gerichteter azyklischer Graph mit Polybaumstruktur. c) Gerichteter zyklischer Graph. Nicht erlaubt für den Einsatz von Bayes-Netzen [10].

Ein **Bayes-Netz** \mathcal{G} besteht aus:

- Einem Satz von Variablen und gerichteten Verbindungen zwischen diesen.
- Jede Variable beinhaltet einen Satz von Zuständen, welche diskret oder kontinuierlich sein können.
- Alle Variablen zusammen mit den gerichteten Kanten bilden einen azyklischen, gerichteten Graphen. Ein gerichteter Graph ist azyklisch wenn keine gerichtete Verbindung von $A_0 \rightarrow \dots \rightarrow A_n$ existiert, so dass $A_0 = A_n$.
- Jede Variable X im Netz mit den Eltern A_0, \dots, A_n beinhaltet eine bedingte Wahrscheinlichkeitstabelle $P(X | A_0, \dots, A_n)$ [10].

2.2.1.1 Bestimmung von Bayes-Netz-Strukturen und bedingten Wahrscheinlichkeitstabellen

Beim Modellieren eines Systems mit einem Bayes-Netz müssen drei Schritte befolgt werden: Auswahl der notwendigen Variablen, Bestimmung der kausalen Zusammenhänge und Bestimmung von bedingten Wahrscheinlichkeitstabellen (*CPT's*). Dabei muss beachtet werden, dass das Ergebnis der Schlussfolgerung bei gegebenen Informationen immer nachvollziehbar ist und das Verhalten sich in der Welt widerspiegelt [10], [11].

Bei der Auswahl von Variablen wird zwischen beobachtbaren (*Informations-Variable*) und nicht beobachtbaren Variablen (*Hypothesen-Variable*) unterschieden. Ein Bayes-Netz dient dem Zweck, anhand der Beobachtungen Schlussfolgerungen über die nicht beobachtbaren Variablen zu ziehen.

Nach der Auswahl von Variablen müssen im nächsten Schritt die kausalen Zusammenhänge (*gerichtete Verbindungen*) zwischen diesen identifiziert werden. Dies kann sich als schwierig erweisen, da nicht immer klar ist, auf welche Art und Weise Ereignisse in der Welt zusammenhängen und wie diese sich gegenseitig beeinflussen. Außerdem müssen die Variablen so zusammenhängen, dass der Mensch in der Lage ist, den Einfluss von Variablen zu verstehen und zu bestimmen. Bei einer falschen Auswahl von Verbindungen können absurde Abhängigkeiten entstehen, deren Einfluss in der Welt nicht beobachtet und bestimmt werden kann.

Die Anzahl der bedingten Wahrscheinlichkeitstabellen, die spezifiziert werden müssen, hängen von der Bayes-Netz-Struktur ab und werden als Parameter eines Bayes-Netzes bezeichnet. Eine richtige Auswahl von Parametern ist sehr wichtig, da diese das Verhalten in der Welt beschreiben. Das Finden der richtigen Parameter ist eine sehr schwierige Aufgabe und braucht sehr viel Erfahrung. Bei der Auswahl der Parameter kann auf *Beobachtungen in der Welt* oder auf eine *subjektive Schätzung* von Experten zurückgegriffen werden. Im ersten Fall gibt

es Hilfestellungen durch Einsatz von Lernmethoden, die einen optimalen Parametersatz anhand der Daten approximieren können. Im zweiten Fall muss der Entwickler selbst einschätzen, wie der richtige Parametersatz aussehen könnte, damit ein bestimmtes Verhalten am besten beschrieben werden kann. Dabei verlässt man sich meistens auf die Erfahrung vom Experten. Je besser das Verhalten durch einen Parametersatz beschrieben werden kann, desto besser und glaubwürdiger ist das Ergebnis einer Schlussfolgerung. In der medizinischen Diagnostik könnten durch eine falsche Auswahl von Parametern falsche Erkrankungen eines Patienten diagnostiziert werden.

2.2.1.2 Verbindungsarten und d-Separation

Das Schlussfolgern in einem Bayes-Netz bedeutet die Beantwortung der Frage: „Wie beeinflusst die Änderung des Zustandes einer Variable im Netz eine andere?“ Dazu müssen die Abhängigkeiten der Variablen im Netz untersucht werden. Abbildung 2.2 zeigt alle möglichen Verbindungen zwischen Variablen in einem Bayes-Netz. Dabei wird zwischen *seriellen*, *divergierenden* und *konvergierenden*

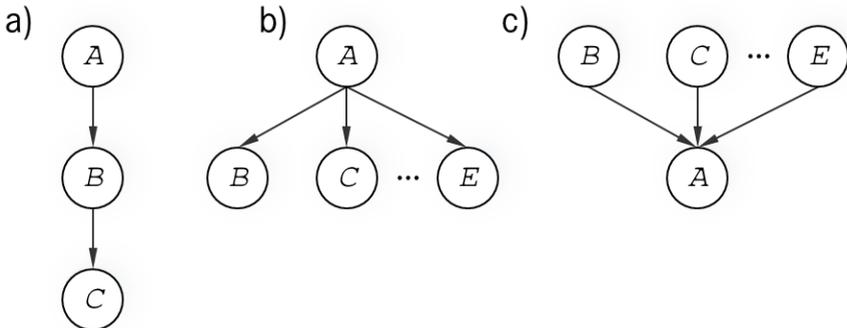


Abbildung 2.2: a) Serielle Verbindung: Wenn B bekannt ist, so wird die Verbindung zwischen A und C blockiert. b) Divergierende Verbindung: Wenn A bekannt ist, so ist die Verbindung zwischen den *Kindknoten* blockiert. c) Konvergierende Verbindung: Wenn A bekannt ist, so ist die Verbindung zwischen den *Elternknoten* nicht blockiert [10].

Verbindungen unterschieden [10], [13]. Die Unabhängigkeit zwischen den Variablen in einem kausalen Netz wird auch als *d-Separation* bezeichnet. Im Folgenden wird im Detail jede einzelne Verbindungsart und der Einfluss der Variablen aufeinander vorgestellt.

Abbildung 2.2 a) zeigt eine serielle Verbindung zwischen den Variablen A , B und C . Offensichtlich beeinflusst eine Änderung des Zustandes in A den Zustand von B , welcher seinerseits eine Änderung des Zustandes in C verursacht. In ähnlicher Weise beeinflusst die Änderung in C den Zustand in A und B . Andererseits, wenn der Zustand von B bekannt ist, so ist die Verbindung zwischen A und C blockiert. Die Variablen A und C sind *d-separiert*, solange B gegeben ist. *Für eine serielle Verbindung gilt: Die Zustandsänderungen in Eltern-, oder Kindknoten beeinflussen sich gegenseitig, solange der Zustand der dazwischenliegenden Variablen nicht bekannt ist.*

Beispiel 1 (serielle Verbindung)

Abbildung 2.3 zeigt ein serielles Bayes-Netz mit den Beziehungen zwischen den Variablen *Regenfall* (*kein, leicht, mittel, stark*), *Wasserstand* (*gering, mittel, hoch*) und *Überflutung* (*ja, nein*). Wenn der *Wasserstand* nicht beobachtet werden kann, gleichzeitig aber bekannt ist, dass der *Regenfall* stark ist, so wird diese Information den Zustand der Variable *Wasserstand* ändern. Die Wahrscheinlichkeit ist sehr hoch, dass bei einem starken *Regenfall* der *Wasserstand* hoch ist. Diese wiederum wird die Wahrscheinlichkeit im Knoten *Überflutung* verändern. Die Wahrscheinlichkeit ist sehr hoch, dass bei hohem *Wasserstand* eine *Überflutung* stattfindet. Diese Schlussfolgerung gilt genauso in die andere Richtung. Andererseits, wenn der *Wasserstand* bekannt ist, dann wird die Zustandsänderung im Knoten *Regenfall* keine neue Aussage über eine mögliche *Überflutung* bringen [10].

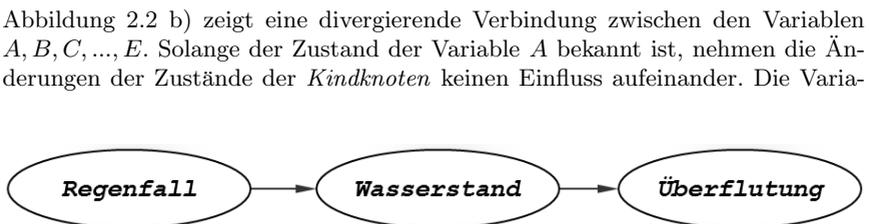


Abbildung 2.3: Ein Bayes-Netz-Modell für den kausalen Zusammenhang zwischen den Variablen *Regenfall*, *Wasserstand* und *Überflutung* [10].

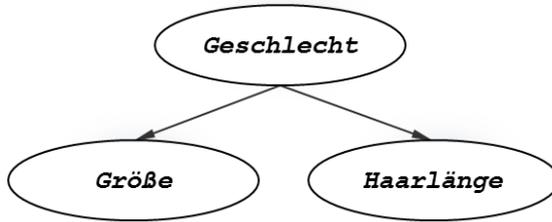


Abbildung 2.4: *Geschlecht* eines Menschen beeinflusst seine *Größe* und *Haarlänge* [10].

blen B, C, \dots, E sind d-separiert, solange A gegeben ist. Für eine divergierende Verbindung gilt: Die Änderungen in den Zuständen der Kindknoten beeinflussen sich gegenseitig, solange der Zustand des Elternknotens nicht bekannt ist.

Beispiel 2 (divergierende Verbindung)

Abbildung 2.4 zeigt ein divergierendes Bayes-Netz mit den Beziehungen zwischen den Variablen *Geschlecht* (*männlich*, *weiblich*), *Größe* ($< 168\text{cm}$, $> 168\text{cm}$) und *Haarlänge* (*kurz*, *lang*). Wenn das *Geschlecht* einer Person nicht bekannt ist, so können Rückschlüsse auf das *Geschlecht*, über das Beobachten der *Haarlänge* eines Menschen, gezogen werden. Personen mit langen Haaren haben eine größere Wahrscheinlichkeit weiblich zu sein. Das *Geschlecht* verändert gleichzeitig die Wahrscheinlichkeit für die *Größe* einer Person. Ist die Wahrscheinlichkeit hoch, dass für eine Person, weiblich zu sein, so ist die Wahrscheinlichkeit hoch, dass diese kleiner als 168cm ist. Andererseits, wenn das *Geschlecht* einer Person bekannt ist, gibt die Information über die *Haarlänge* keine neuen Erkenntnisse über ihre *Größe* [10].

Abbildung 2.2 c) zeigt eine konvergierende Verbindung zwischen den Variablen A, B, C, \dots, E . Das Wissen über ein mögliches Ereignis eines *Elternknotens*, lässt keine Schlussfolgerungen über andere mögliche Ereignisse zu, solange der Zustand des *Kindknotens* nicht bekannt ist. Die Variablen B, C, \dots, E sind d-separiert, solange A nicht gegeben ist. Für eine konvergierende Verbindung gilt: Die Änderungen der Zustände der Elternknoten beeinflussen sich gegenseitig, solange der Zustand des Kindknotens (oder seiner Nachkommen) bekannt ist.

Beispiel 3 (konvergierende Verbindung)

Abbildung 2.5 zeigt ein konvergierendes Bayes-Netz mit den Beziehungen zwischen den Variablen *Salmonellen*, *Grippe*, *Brechreiz*, *Blässe*. Ist nichts über einen möglichen *Brechreiz* oder *Blässe* einer Person bekannt, so sind keine Rückschlüsse

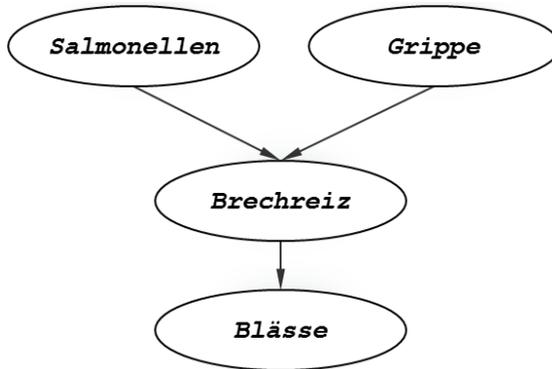


Abbildung 2.5: Eine Vergiftung durch *Salmonellen* oder eine *Grippe* können *Brechreiz* auslösen, welcher *Blässe* verursachen kann [10].

auf eine *Grippe* möglich, falls Informationen über eine Vergiftung durch *Salmonellen* vorliegen. Andererseits, wenn eine Information über die *Blässe* eines Menschen vorhanden ist, ist die Wahrscheinlichkeit für eine mögliche *Grippe* hoch, wenn bekannt ist, dass keine Vergiftung durch *Salmonellen* vorliegt [10].

Der gegenseitige Einfluss von Variablen aufeinander ist vollständig durch die drei vorgestellten Verbindungsarten beschrieben. Die allgemeinen Regeln sind in der folgenden Definition zusammengefasst.

d-Separation: Zwei Variablen A und B in einem kausalen Netz sind *d-Separiert*, wenn für alle Pfade zwischen A und B ein Zwischenglied C existiert, so dass bei

- einer seriellen oder divergierenden Verbindung C bekannt ist, oder
- einer konvergierenden Verbindung weder C noch seine Nachkommen bekannt sind [11].

2.2.1.3 Multiplikationssatz für bedingte Wahrscheinlichkeiten

Ist die Abhängigkeit von Variablen in einem kausalen Netz bekannt, so lässt sich im nächsten Schritt die Wahrscheinlichkeit für ein Ereignis im Netz bestimmen. Dazu muss zunächst die Verbundwahrscheinlichkeit aller Variablen im Netz berechnet werden [10], [11].

Wenn $\mathcal{G} = \{A_0, \dots, A_n\}$ ein Bayes-Netz und $P(\mathcal{G}) = P(A_0, \dots, A_n)$ die Verbundwahrscheinlichkeit darstellen, so lässt sich die Wahrscheinlichkeit $P(A_i)$ als auch $P(A_i | \mathbf{E})$ berechnen, wobei \mathbf{E} die bekannten Evidenzen im gesamten Netz repräsentiert. Die Verbundwahrscheinlichkeit $P(\mathcal{G})$ muss die Eigenschaften eines Bayes-Netzes \mathcal{G} widerspiegeln: (i) die bedingte Wahrscheinlichkeit für eine Variable im Netz bei gegebenen Eltern muss in $P(\mathcal{G})$ genauso definiert sein, wie in \mathcal{G} spezifiziert und (ii) wenn die Variablen A und B in \mathcal{G} bei gegebenem Satz an Evidenzen \mathbf{E} d-separiert sind, dann müssen diese auch in $P(\mathcal{G})$ unabhängig bleiben [10], [11].

Unter Berücksichtigung dieser Eigenschaften lässt sich der Multiplikationssatz für bedingte Wahrscheinlichkeiten der Wahrscheinlichkeitstheorie für kausale Netze umformulieren.

Multiplikationssatz für bedingte Wahrscheinlichkeiten: Die Verbundwahrscheinlichkeit zwischen den Variablen A_0, \dots, A_n lässt sich nach dem Multiplikationssatz folgendermaßen berechnen [11]:

$$P(A_0, \dots, A_n) = P(A_n | A_0, \dots, A_{n-1}) \cdot P(A_{n-1} | A_0, \dots, A_{n-2}) \cdot \dots \cdot P(A_1 | A_0) \cdot P(A_0).$$

Sind die kausalen Abhängigkeiten der Variablen bekannt, so lässt sich die Verbundwahrscheinlichkeit für Bayes-Netze folgendermaßen darstellen.

Multiplikationssatz für bedingte Wahrscheinlichkeiten (Bayes-Netz): Die Verbundwahrscheinlichkeit aller Variablen in einem Bayes-Netz $\mathcal{G} = \{A_0, \dots, A_n\}$ lässt sich als Produkt der bedingten Wahrscheinlichkeiten, die in \mathcal{G} spezifiziert sind, berechnen:

$$P(\mathcal{G}) = \prod_{i=0}^n P(A_i | \text{pa}(A_i)), \quad (2.1)$$

wobei $\text{pa}(A_i)$ die Elternknoten von A_i repräsentiert [11].

Für das in Abbildung 2.1 a) dargestellte Bayes-Netz ist die Verbundwahrscheinlichkeit nach Gleichung 2.1 folgendermaßen formuliert:

$$P(A, B, C, D, E) = P(A) \cdot P(B|A) \cdot P(C|B) \cdot P(D|B) \cdot P(E|C, D)$$

Ein Bayes-Netz stellt somit eine kompakte Repräsentation einer Verbundwahrscheinlichkeit aller Variablen im Netz dar.

2.2.2 Inferenz

In den vorherigen Kapiteln wurde die Repräsentation von Bayes-Netzen vorgestellt. Dazu wurde auf

- die Variablen in einem Bayes-Netz und kausale Zusammenhänge (*Knoten, gerichtete Kanten*)
- den Einfluss der Variablen aufeinander und deren Unabhängigkeit (*CPT's, d-Separation*)

eingegangen.

Das Schlussfolgern bedeutet das Bestimmen des Einflusses einer Variablen im Netz auf eine andere, bei gegebenen Informationen. Evidenzen im Netz werden mit \mathbf{E} und der Zustand einer Evidenz mit \mathbf{e} bezeichnet. Gesucht ist die Wahrscheinlichkeit einer Variablen A im Netz bei gegebenen Informationen (Evidenzen):

$$P(A|\mathbf{E} = \mathbf{e}) = ?$$

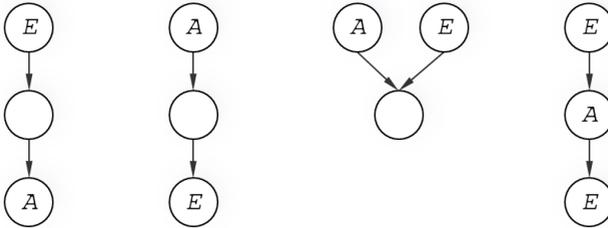
Dabei unterscheidet man nach Algorithmen, die exakt oder approximiert in einem Bayes-Netz eine Inferenzrechnung durchführen können. In den nächsten Kapiteln werden die Grundlagen des Schlussfolgerns in einem Bayes-Netz vorgestellt.

2.2.2.1 Arten der Inferenz

Die Parameter in einem Bayes-Netz werden immer ausgehend von der Ursache zur Wirkung angegeben. Nichtsdestotrotz können in Bayes-Netzen verschiedene Schlussfolgerungen durchgeführt werden. Die Arten einer Schlussfolgerung sind in Abbildung 2.6 dargestellt. Er wird zwischen *kausaler*, *diagnostischer*, *interkausaler* und *gemischter* Inferenz unterschieden [13].

2.2.2.2 Einfügen von Evidenzen

Bayes-Netze werden für die Berechnung von neuen Wahrscheinlichkeiten nach Einfügen von neuen Informationen ins Netz benutzt. Werden in ein Bayes-Netz \mathcal{G} mit den Variablen $A \in \mathcal{G}$ Evidenzen \mathbf{E} eingefügt, so müssen die Wahrscheinlichkeiten für A mit den Beobachtungen \mathbf{e} multipliziert und anschließend normiert werden. Ein Beobachtungsvektor \mathbf{e} für eine Variable *Farbe* mit den Zuständen (*rot, grün, blau*) und Wahrscheinlichkeit $P(\text{Farbe}) = (0.3, 0.6, 0.1)$ könnte folgendermaßen aussehen:



Kausal Diagnostisch Interkausal Gemischt

Abbildung 2.6: Arten einer Inferenz in Bayes-Netzen. \mathbf{E} steht für Evidenz, A für eine Abfrage (die Wahrscheinlichkeit von A ist von Interesse) [13].

- $\mathbf{e} = (0.0, 0.0, 1.0)$ heißt, der Zustand der Variable *Farbe* ist *blau* und ist sicher beobachtbar,
- $\mathbf{e} = (0.8, 0.1, 0.3)$ heißt, die Beobachtung ist unsicher, aber es wird geglaubt, dass die Farben *rot* zu 80%, *grün* zu 10% und *blau* zu 30% vertreten sein könnten. Die Wahrscheinlichkeit $P(\text{Farbe} | \mathbf{E} = \mathbf{e})$ ändert sich zu $(0.73, 0.18, 0.09)$.

Evidenzen im ersten Fall werden als harte und im zweiten Fall als weiche oder Likelihood-Beobachtung bezeichnet. Obwohl der Wert einer Beobachtung zwischen null und eins liegt, muss die Summe der Beobachtungen nicht unbedingt eins ergeben. An dieser Stelle kann nur bedingt von Wahrscheinlichkeiten gesprochen werden. Es ist eher ein Glaubenswert einer Beobachtung für einen Zustand einer Variablen im Netz. Nichtsdestotrotz wird $P(\mathbf{E})$ als a-priori Wahrscheinlichkeit einer Evidenz und $P(A, \mathbf{E})$ als Ergebnis der Multiplikation von $P(A)$ und \mathbf{e} bezeichnet.

Wenn $\mathcal{G} = \{A_0, \dots, A_n\}$ ein Bayes-Netz und $\mathbf{e}_0, \dots, \mathbf{e}_m$ als statistisch unabhängig angenommene Evidenzen im gesamten Netz darstellen, dann lässt sich das Einfügen von diesen folgendermaßen formulieren:

$$P(\mathcal{G}, \mathbf{E} = \mathbf{e}) = \prod_{i=0}^n P(A_i | \text{pa}(A_i)) \cdot \prod_{j=0}^m \mathbf{e}_j \quad (2.2)$$

Die a-priori Wahrscheinlichkeit einer Evidenz $P(\mathbf{E})$ ist das Ergebnis der Marginalisierung der Wahrscheinlichkeit von $P(\mathcal{G})$.

$$P(\mathbf{E}) = \sum_{\mathcal{G}} P(\mathcal{G}, \mathbf{E}) \quad (2.3)$$

Somit lässt sich im nächsten Schritt die neue Wahrscheinlichkeit für die Zustände einer Variablen im Netz nach Einfügen von neuen Informationen bestimmen.

$$P(A_i | \mathbf{E} = \mathbf{e}) = \frac{\sum_{\mathcal{G} \setminus \{A_i\}} P(\mathcal{G}, \mathbf{E})}{P(\mathbf{E})} \quad (2.4)$$

In unserem vorherigen Beispiel lässt sich die Wahrscheinlichkeit $P(\text{Farbe} | \mathbf{E} = \mathbf{e})$ für harte Evidenzen folgendermaßen berechnen.

$$\begin{aligned} P(\text{Farbe} = r, \mathbf{E} = \mathbf{e}_r) &= P(\text{Farbe} = r) \cdot \mathbf{e}_r = 0.3 \cdot 0.0 = 0.0 \\ P(\text{Farbe} = g, \mathbf{E} = \mathbf{e}_g) &= P(\text{Farbe} = g) \cdot \mathbf{e}_g = 0.6 \cdot 0.0 = 0.0 \\ P(\text{Farbe} = b, \mathbf{E} = \mathbf{e}_b) &= P(\text{Farbe} = b) \cdot \mathbf{e}_b = 0.1 \cdot 1.0 = 0.1 \\ P(\mathbf{E}) &= \sum_{\text{Farbe}} P(\text{Farbe}, \mathbf{E}) = 0 + 0 + 0.1 = 0.1 \\ P(\text{Farbe} = r | \mathbf{E} = \mathbf{e}_r) &= \frac{P(\text{Farbe} = r, \mathbf{E} = \mathbf{e}_r)}{P(\mathbf{E})} = \frac{0.0}{0.1} = 0.0 \\ P(\text{Farbe} = g | \mathbf{E} = \mathbf{e}_g) &= \frac{P(\text{Farbe} = g, \mathbf{E} = \mathbf{e}_g)}{P(\mathbf{E})} = \frac{0.0}{0.1} = 0.0 \\ P(\text{Farbe} = b | \mathbf{E} = \mathbf{e}_b) &= \frac{P(\text{Farbe} = b, \mathbf{E} = \mathbf{e}_b)}{P(\mathbf{E})} = \frac{0.1}{0.1} = 1.0 \\ P(\text{Farbe} | \mathbf{E} = \mathbf{e}) &= (0.0, 0.0, 1.0) \end{aligned}$$

Beim Einfügen von Likelihood-Evidenzen ist die gleiche Rechnung durchzuführen.

$$\begin{aligned} P(\text{Farbe} = r, E = \mathbf{e}_r) &= P(\text{Farbe} = r) \cdot \mathbf{e}_r = 0.3 \cdot 0.8 = 0.24 \\ P(\text{Farbe} = g, E = \mathbf{e}_g) &= P(\text{Farbe} = g) \cdot \mathbf{e}_g = 0.6 \cdot 0.1 = 0.06 \\ P(\text{Farbe} = b, E = \mathbf{e}_b) &= P(\text{Farbe} = b) \cdot \mathbf{e}_b = 0.1 \cdot 0.3 = 0.03 \\ P(E) &= \sum_{\text{Farbe}} P(\text{Farbe}, E) = 0.24 + 0.06 + 0.3 = 0.33 \\ P(\text{Farbe} = r | E = \mathbf{e}_r) &= \frac{P(\text{Farbe} = r, E = \mathbf{e}_r)}{P(E)} = \frac{0.24}{0.33} = 0.73 \\ P(\text{Farbe} = g | E = \mathbf{e}_g) &= \frac{P(\text{Farbe} = g, E = \mathbf{e}_g)}{P(E)} = \frac{0.06}{0.33} = 0.18 \\ P(\text{Farbe} = b | E = \mathbf{e}_b) &= \frac{P(\text{Farbe} = b, E = \mathbf{e}_b)}{P(E)} = \frac{0.03}{0.33} = 0.09 \\ P(\text{Farbe} | E = \mathbf{e}) &= (0.73, 0.18, 0.09) \end{aligned}$$

2.2.2.3 Eliminierung von Variablen

Die Eliminierung von Variablen ist ein allgemeingültiger Algorithmus zur Berechnung der Inferenz in einem Bayes-Netz [10], [11], [12]. Bei diesem Prozess wird die Verbundwahrscheinlichkeit der gesamten Variablen im Netz bestimmt und die Variablen, die nicht von Interesse sind, eliminiert.

$$P(A_i) = \sum_{G \setminus \{A_i\}} \prod_{A \in G} P(A | \text{pa}(A)) \quad (2.5)$$

Die Funktionsweise dieses Algorithmus zur Eliminierung von Variablen wird anhand eines Beispiels vorgestellt. Abbildung 2.7 stellt ein Bayes-Netz dar, welches die Polizei oder die Feuerwehr durch ein *Computersystem* (CS) oder eine *Person* (PRS) über einen *Alarm* (A) informiert. Der Alarm kann von einem *Bewegungssensor* (BS) oder von einem *Rauchsensor* (RS) ausgelöst werden. Nach Gleichung 2.1 ergibt sich die Verbundwahrscheinlichkeit für dieses Bayes-Netz zu:

$$P(G) = P(BS) \cdot P(RS) \cdot P(A|BS, RS) \cdot P(CS|A) \cdot P(PRS|A)$$

Zur Berechnung der Inferenz sind neben der Bayes-Netz-Struktur auch die entsprechenden Wahrscheinlichkeitstabellen in Abbildung 2.7 dargestellt.

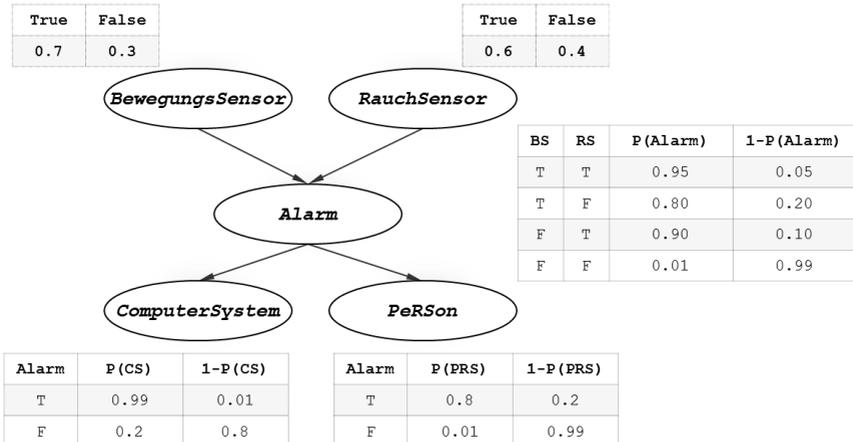


Abbildung 2.7: Bayes-Netz zur Überwachung eines Hauses [13].

Um eine bessere Darstellung der Berechnung zu erreichen, wird eine Faktorschreibweise eingeführt. Ein Faktor ϕ ist eine Funktion oder eine Tabelle über eine endliche Anzahl Variablen X , die zu jeder Konfiguration von X einen realen Wert \mathbb{R} liefert [12].

$$\phi : \text{Val}(X) \rightarrow \mathbb{R}$$

Die Faktoren für die bedingten Wahrscheinlichkeitstabellen im obigen Beispiel sehen folgendermaßen aus:

$$\begin{aligned}\phi_1(BS) &= P(BS) \\ \phi_2(RS) &= P(RS) \\ \phi_3(A, BS, RS) &= P(A|BS, RS) \\ \phi_4(CS, A) &= P(CS|A) \\ \phi_5(PRS, A) &= P(PRS|A)\end{aligned}$$

Mit dieser Schreibweise gilt:

$$P(\mathcal{G}) = \phi_1\phi_2\phi_3\phi_4\phi_5$$

Sind die Bayes-Netz-Struktur und die Bayes-Netz-Parameter bekannt, so können verschiedene Fragestellungen beantwortet werden. Die folgenden Beispiele zeigen ausführlich die Berechnung von *kausaler* und *diagnostischer* Inferenz. Alle anderen Typen der Inferenz lassen sich auf die gleiche Art bestimmen.

Beispiel 4 (Kausale Inferenz ohne Evidenzen)

Wie groß ist die Wahrscheinlichkeit $P(CS)$, dass die Polizei durch ein *Computersystem* informiert wird?

Die Wahrscheinlichkeit $P(CS)$ ist nach Gleichung 2.5 folgendermaßen gegeben:

$$P(CS) = \sum_{BS, RS, A, PRS} \phi_1\phi_2\phi_3\phi_4\phi_5$$

Nach dem Distributivgesetz lässt sich diese umformulieren zu:

$$\begin{aligned}P(CS) &= \sum_{BS} \phi_1(BS) \cdot \\ &\quad \sum_{RS} \phi_2(RS) \sum_A \phi_3(A, BS, RS) \phi_4(CS, A) \sum_{PRS} \phi_5(PRS, A)\end{aligned}$$

Wie man sieht, werden die Variablen nach und nach marginalisiert und das Ergebnis mit der nächsten Summe multipliziert. Als erstes wird die Summe

$\sum_{PRS} \phi_5 (PRS, A)$ über alle Zustände der Variablen PRS berechnet. Mit τ^t wird der Zustand $A = true$ und mit dem τ^f Zustand $A = false$ bezeichnet.

$$\begin{aligned}\tau_5 (A) &= \sum_{PRS} \phi_5 (PRS, A) \\ \tau_5^t (A) &= 0.8 + 0.2 = 1 \\ \tau_5^f (A) &= 0.01 + 0.99 = 1\end{aligned}$$

Als zweites wird das Ergebnis der ersten Summe mit dem der zweiten Summe multipliziert und anschließend die Variable A eliminiert. Die Verbundwahrscheinlichkeit $P(BS, RS, CS)$ enthält alle möglichen Kombinationen der Variablen BS, RS, CS .

$$\begin{aligned}\tau_4 (BS, RS, CS) &= \sum_A \phi_3 (A, BS, RS) \phi_4 (CS, A) \tau_5 (A) \\ \tau_4^{ttt} (BS, RS, CS) &= 0.95 \cdot 0.99 \cdot 1 + 0.05 \cdot 0.2 \cdot 1 = 0.9505 \\ \tau_4^{tft} (BS, RS, CS) &= 0.80 \cdot 0.99 \cdot 1 + 0.20 \cdot 0.2 \cdot 1 = 0.8320 \\ \tau_4^{ftt} (BS, RS, CS) &= 0.90 \cdot 0.99 \cdot 1 + 0.10 \cdot 0.2 \cdot 1 = 0.9110 \\ \tau_4^{fft} (BS, RS, CS) &= 0.01 \cdot 0.99 \cdot 1 + 0.99 \cdot 0.2 \cdot 1 = 0.2079 \\ \tau_4^{ttf} (BS, RS, CS) &= 0.95 \cdot 0.01 \cdot 1 + 0.05 \cdot 0.8 \cdot 1 = 0.0495 \\ \tau_4^{tff} (BS, RS, CS) &= 0.80 \cdot 0.01 \cdot 1 + 0.20 \cdot 0.8 \cdot 1 = 0.1680 \\ \tau_4^{ftf} (BS, RS, CS) &= 0.90 \cdot 0.01 \cdot 1 + 0.10 \cdot 0.8 \cdot 1 = 0.0890 \\ \tau_4^{fff} (BS, RS, CS) &= 0.01 \cdot 0.01 \cdot 1 + 0.99 \cdot 0.8 \cdot 1 = 0.7921\end{aligned}$$

In den nächsten Schritten werden die Variablen RS, BS eliminiert.

$$\begin{aligned}\tau_3 (BS, CS) &= \sum_{RS} \phi_2 (RS) \tau_4 (BS, RS, CS) \\ \tau_3^{tt} (BS, CS) &= 0.9505 \cdot 0.6 + 0.8320 \cdot 0.4 = 0.9031 \\ \tau_3^{ft} (BS, CS) &= 0.9110 \cdot 0.6 + 0.2079 \cdot 0.4 = 0.6298 \\ \tau_3^{tf} (BS, CS) &= 0.0495 \cdot 0.6 + 0.1680 \cdot 0.4 = 0.0969 \\ \tau_3^{ff} (BS, CS) &= 0.0890 \cdot 0.6 + 0.7921 \cdot 0.4 = 0.3702\end{aligned}$$

$$\begin{aligned}P (CS) &= \sum_{BS} \phi_1 (BS) \tau_3 (BS, CS) \\ P (CS = t) &= 0.9031 \cdot 0.7 + 0.6298 \cdot 0.3 = 0.8211 \\ P (CS = f) &= 0.0969 \cdot 0.7 + 0.3702 \cdot 0.3 = 0.1789\end{aligned}$$

Beispiel 5 (Kausale Inferenz mit Evidenzen)

Wie groß ist die Wahrscheinlichkeit $P(CS|BS = true)$, dass die Polizei durch ein *Computersystem* informiert wird, wenn bekannt ist, dass ein *Bewegungssensor* aktiviert wurde?

Es wird die gleiche Rechnung wie im vorherigen Beispiel durchgeführt, mit dem Unterschied, dass jetzt Evidenzen in das Netz eingeführt und danach die Variablen marginalisiert werden (s. Gleichung 2.2, 2.5). Dies führt zu folgender Gleichung:

$$P(CS, \mathbf{e}_{BS}) = \sum_{BS, RS, A, PRS} \phi_1 \phi_2 \phi_3 \phi_4 \phi_5 \mathbf{e}_{BS}$$

oder umformuliert:

$$P(CS, \mathbf{e}_{BS}) = \sum_{BS} \phi_1(BS) \mathbf{e}_{BS} \cdot \sum_{RS} \phi_2(RS) \sum_A \phi_3(A, BS, RS) \phi_4(CS, A) \sum_{PRS} \phi_5(PRS, A)$$

Die Eliminierung bis zur Variablen RS wird aus der vorherigen Rechnung übernommen. Es muss nur noch die letzte Summe berechnet werden.

$$\begin{aligned} P(CS, \mathbf{e}_{BS}) &= \sum_{BS} \phi_1(BS) \mathbf{e}_{BS} \tau_3(BS, CS) \\ P(CS = t, \mathbf{e}_{BS}) &= 0.9031 \cdot 1 \cdot 0.7 + 0.6298 \cdot 0 \cdot 0.3 = 0.6322 \\ P(CS = f, \mathbf{e}_{BS}) &= 0.0969 \cdot 1 \cdot 0.7 + 0.3702 \cdot 0 \cdot 0.3 = 0.0678 \end{aligned}$$

Im letzten Schritt wird die gesuchte Wahrscheinlichkeit $P(CS|\mathbf{e}_{BS})$ nach Gleichung 2.4 bestimmt.

$$\begin{aligned} P(CS|\mathbf{e}_{BS}) &= \frac{P(CS, \mathbf{e}_{BS})}{\sum_{CS} P(CS, \mathbf{e}_{BS})} \\ P(CS = t|\mathbf{e}_{BS}) &= \frac{0.6322}{0.6322 + 0.0678} = 0.9031 \\ P(CS = f|\mathbf{e}_{BS}) &= \frac{0.0678}{0.6322 + 0.0678} = 0.0969 \end{aligned}$$

Auf die gleiche Art können auch Likelihood-Evidenzen ins Netz eingefügt werden.

Beispiel 6 (Diagnostische Inferenz mit Evidenzen)

Wie groß ist die Wahrscheinlichkeit $P(BS|CS = true)$, dass ein *Bewegungssensor* aktiviert ist, wenn die Polizei durch ein *Computersystem* informiert wurde?

Die Wahrscheinlichkeit $P(BS|CS = true)$ wird wieder als Summe über das Produkt der einzelnen Wahrscheinlichkeiten dargestellt:

$$P(BS, \mathbf{e}_{CS}) = \sum_{RS, A, CS, PRS} \phi_1 \phi_2 \phi_3 \phi_4 \phi_5 \mathbf{e}_{CS}$$

Die Umformulierung dieser Gleichung führt zu:

$$P(BS, \mathbf{e}_{CS}) = \sum_{RS} \phi_1(BS) \phi_2(RS) \cdot \sum_A \phi_3(A, BS, RS) \sum_{CS} \phi_4(CS, A) \mathbf{e}_{CS} \sum_{PRS} \phi_5(PRS, A)$$

Als erstes wird die Variable PRS eliminiert.

$$\begin{aligned} \tau_5(A) &= \sum_{PRS} \phi_5(PRS, A) \\ \tau_5^t(A) &= 0.8 + 0.2 = 1 \\ \tau_5^f(A) &= 0.01 + 0.99 = 1 \end{aligned}$$

Als zweites werden die Evidenzen ins Netz eingefügt und die nächste Variable CS marginalisiert.

$$\begin{aligned} \tau_4(A, \mathbf{e}_{CS}) &= \sum_{CS} \phi_4(CS, A) \mathbf{e}_{CS} \tau_5(A) \\ \tau_4^t(A, \mathbf{e}_{CS}) &= 0.99 \cdot 1 \cdot 1 + 0.01 \cdot 0 \cdot 1 = 0.9900 \\ \tau_4^f(A, \mathbf{e}_{CS}) &= 0.2 \cdot 1 \cdot 1 + 0.8 \cdot 0 \cdot 1 = 0.2000 \end{aligned}$$

Die Berechnung der nächsten Summe führt zur Eliminierung der Variablen A .

$$\begin{aligned} \tau_3(BS, RS, \mathbf{e}_{CS}) &= \sum_A \phi_3(A, BS, RS) \tau_4(A, \mathbf{e}_{CS}) \\ \tau_3^{tt}(BS, RS, \mathbf{e}_{CS}) &= 0.95 \cdot 0.99 + 0.05 \cdot 0.2 = 0.9505 \\ \tau_3^{tf}(BS, RS, \mathbf{e}_{CS}) &= 0.80 \cdot 0.99 + 0.20 \cdot 0.2 = 0.8320 \\ \tau_3^{ft}(BS, RS, \mathbf{e}_{CS}) &= 0.90 \cdot 0.99 + 0.10 \cdot 0.2 = 0.9110 \\ \tau_3^{ff}(BS, RS, \mathbf{e}_{CS}) &= 0.01 \cdot 0.99 + 0.99 \cdot 0.2 = 0.2079 \end{aligned}$$

Im letzten Schritt wird die Variable RS marginalisiert und die Wahrscheinlichkeit $P(BS|CS = true)$ berechnet.

$$\begin{aligned} P(BS, \mathbf{e}_{CS}) &= \sum_{RS} \phi_1(BS) \phi_2(RS) \tau_3(BS, RS, \mathbf{e}_{CS}) \\ P(BS = t, \mathbf{e}_{CS}) &= 0.9505 \cdot 0.6 \cdot 0.7 + 0.8320 \cdot 0.4 \cdot 0.7 = 0.6322 \\ P(BS = f, \mathbf{e}_{CS}) &= 0.9110 \cdot 0.6 \cdot 0.3 + 0.2079 \cdot 0.4 \cdot 0.3 = 0.1889 \end{aligned}$$

$$\begin{aligned}
 P(BS|\mathbf{e}_{CS}) &= \frac{P(BS, \mathbf{e}_{CS})}{\sum_{BS} P(BS, \mathbf{e}_{CS})} \\
 P(BS = t|\mathbf{e}_{CS}) &= \frac{0.6322}{0.6322 + 0.1889} = 0.7699 \\
 P(BS = f|\mathbf{e}_{CS}) &= \frac{0.1889}{0.6322 + 0.1889} = 0.2301
 \end{aligned}$$

2.2.2.4 Clique (Junction) Tree Algorithmus

Wie in dem vorherigen Kapitel gezeigt wurde, ist der Algorithmus zur Eliminierung von Variablen sehr einfach und kann sowohl für Bayes-Netze als auch für Markov-Netze zur Berechnung von Inferenz herangezogen werden [11], [12]. Dabei wird das Distributivgesetz auf das Produkt der bedingten Wahrscheinlichkeiten angewandt, Variablen, die nicht von Interesse sind, marginalisiert und zum Schluss die gesuchte Wahrscheinlichkeit normiert.

Die Komplexität der Berechnung, also Anzahl der notwendigen mathematischen Operationen, hängt sehr stark von der Reihenfolge ab, in welcher die Variablen eliminiert werden. Junction Tree Algorithmus (*JTA*) ist eine spezielle Form des bereits vorgestellten Algorithmus zur Eliminierung von Variablen, welcher sehr effizient eine exakte Berechnung von Inferenz durchführen kann. Die Effizienz wird durch das Finden einer optimalen Reihenfolge für die Eliminierung von Variablen erreicht. Wie der Name des Algorithmus bereits sagt, wird die Berechnung von Inferenz in einem sogenannten Clique Tree durchgeführt. Dazu wird eine Umstrukturierung des originalen Bayes-Netzes und eine Neuorganisation von Variablen im Netz benötigt.

Um ein besseres Verständnis von der Funktionsweise des Algorithmus zu bekommen, werden im Folgenden Grundlagen der Graphentheorie ohne eine Beweisführung vorgestellt.

Cluster Graph: Ein Cluster Graph ist ein ungerichteter Graph, bei welchem:

- Die Knoten eine Teilmenge von Variablen im Netz, auch Cluster genannt $C_i \subseteq \{X_1, \dots, X_n\}$, darstellen.
- Die Verbindungen zwischen zwei Cluster C_i und C_j eine Teilmenge $S_{i,j} \subseteq C_i \cap C_j$ zwischen diesen darstellen [11], [12].

Cluster Graphen müssen folgende Eigenschaften erfüllen:

- Jeder Ausgangsfaktor ϕ_k der Variablen X_k in einem Originalgraphen muss in einem Cluster Graphen berücksichtigt werden.
- Für jeden Ausgangsfaktor ϕ_k muss ein Cluster C_i existieren, so dass dieser dem Cluster zugeordnet werden kann.

- Der Ausgangsfaktor ψ_i eines Clusters C_i ist das Produkt der Ausgangsfaktoren ϕ_k von Variablen, die zu diesem Cluster gehören $\psi_i(C_i) = \prod \phi_k$.
- Wenn zwischen Cluster C_i, C_j eine Variable $X \in C_i \cap C_j$ existiert, so muss es einen einzigen Pfad zwischen C_i und C_j geben, so dass alle Cluster und Verbindungen auf dem Pfad die Variable X enthalten.

Abbildung 2.8 stellt einen ungerichteten Graphen und eine mögliche Cluster Repräsentation von diesem dar. Im Beispiel sind vier Cluster $C_1 = (A, B)$, $C_2 = (B, C)$, $C_3 = (C, D)$ und $C_4 = (A, D)$ dargestellt.

Abbildung 2.9 stellt zwei ungültige Cluster Graphen dar. Im Fall a) entspricht die Schnittmenge $C_1 \cap C_3$ der Variablen $X \in \{B\}$. Da aber der Pfad zwischen diesen Cluster keine Variable B enthält, ist dieser Graph ungültig. Im Fall b) existieren zwei Pfade vom Cluster C_2 zu C_4 , und zwar über die Cluster C_1 und C_3 , was nicht erlaubt ist.

Die Inferenz in Cluster Graphen wird durch das Senden von Nachrichten zwischen den Cluster realisiert. Im ersten Schritt werden jedem Cluster, wie auch bei der Eliminierung von Variablen, Faktoren ψ_1 bis ψ_4 zugeordnet (Abb. 2.8). Möchte ein Cluster C_1 eine Nachricht $\delta_{1 \rightarrow 4}$ an Cluster C_4 senden, so wird die ankommende Nachricht $\delta_{2 \rightarrow 1}$ vom Cluster C_2 mit den Ausgangsfaktoren des Clusters C_1 multipliziert. Anschließend werden alle Variablen, die nicht in der Verbindung zu Cluster C_4 enthalten sind, marginalisiert.

$$\delta_{1 \rightarrow 4} = \sum_B \delta_{2 \rightarrow 1}(B) \psi_1(A, B)$$

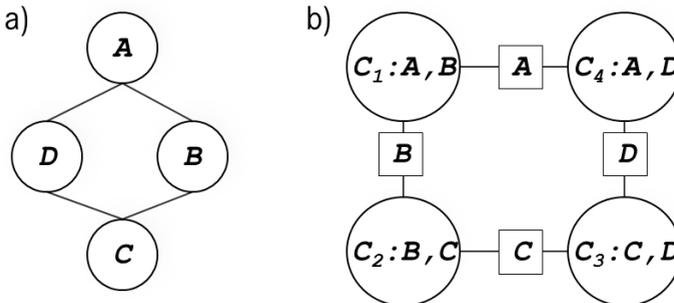


Abbildung 2.8: a) Ungerichteter Graph b) Cluster Graph [12].

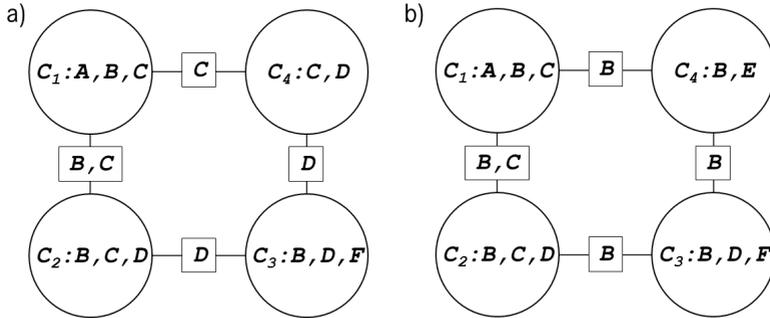


Abbildung 2.9: Ungültige Cluster Graphen: a) Verbindung C_1 und C_3 ist falsch. b) Zwei Pfade von C_2 über $C_{1,3}$ zu C_4 [12].

Die Nachricht $\delta_{2 \rightarrow 1}$ kann auf die gleiche Art berechnet werden.

$$\delta_{2 \rightarrow 1} = \sum_C \delta_{3 \rightarrow 2}(C) \psi_2(B, C)$$

Das Senden von Nachrichten in einem solchen Cluster Graph ist auch als *Belief Propagation Algorithm* bekannt. Es gibt mehrere Strategien, die hier nicht diskutiert werden, zur Beantwortung der Fragen: „Wie werden die Cluster gebildet?“, „Wie lange und über welche Verbindungen müssen die Nachrichten gesendet werden, damit das Ergebnis der Berechnung konvergiert?“

Eine spezielle Form von Cluster Graphen stellen Clique Trees dar. Diese weisen die gleichen Eigenschaften auf und garantieren durch ihren Aufbau eine optimale Reihenfolge zur Eliminierung von Variablen in einem Netz. Im Vergleich zur Berechnung von Inferenz in allgemeinen Cluster Graphen kann hier eine exakte Berechnung durchgeführt werden.

Clique Tree: Ein Clique Tree ist ein Cluster Graph mit einer Baumstruktur, bei welchem:

- Die Knoten eine Teilmenge von Variablen im Netz, auch Cluster genannt $C_i \subseteq \{X_1, \dots, X_n\}$, darstellen.
- Die Verbindungen zwischen zwei Cluster C_i und C_j eine Schnittmenge $S_{i,j} = C_i \cap C_j$ zwischen diesen darstellen [11], [12].

Die bekanntesten Algorithmen zur Erstellung eines Clique Trees und Berechnung von Inferenz wurden von [14], [15] vorgestellt. Diese führen folgende Arbeits-

schritte durch: *Moralisierung eines Bayes-Netzes, Triangulation, Erstellung eines Clique Trees, Berechnung von Inferenz.*

Moralischer Graph: Ein moralischer Graph \mathcal{G} ist ein ungerichteter Graph, welcher eine äquivalente Darstellung eines gerichteten azyklischen Graphen repräsentiert. Um diesen darzustellen, werden in einem gerichteten azyklischen Graph die Elternknoten mit gemeinsamen Kindknoten verbunden und die Richtungen aller Kanten entfernt [11], [12].

Triangulation: Ein ungerichteter Graph \mathcal{G} ist trianguliert, wenn jeder Zyklus der Länge größer Drei eine Kante besitzt, welche zwei nicht benachbarte Knoten in diesem Zyklus verbindet (Abb. 2.10).

Ein triangulierter Graph besitzt eine optimale Reihenfolge zur Eliminierung von Variablen [11], [12].

Laut der vorherigen Definition ist die Triangulation eines Graphen äquivalent zu der Suche nach einer optimalen Reihenfolge zur Eliminierung von Variablen im Netz. Je nach Problemstellung, die durch Triangulation gelöst werden muss, können verschiedene Optimierungskriterien definiert werden. Im Allgemeinen versucht ein Algorithmus zur Triangulation eines Bayes-Netzes die Anzahl von Variablen in einer Clique ($C_i \subseteq \{X_1, \dots, X_n\}$) oder die Größe von resultierenden bedingten Wahrscheinlichkeitstabellen einer Clique ($\psi_i(C_i) = \prod \phi_k$) so klein wie möglich zu halten.

Abbildung 2.11 stellt a) Ein Bayes-Netz b) den dazu erstellten moralischen und c) triangulierten Graph sowie d) einen möglichen Clique Tree dar. In diesem Beispiel gibt es auch andere Möglichkeiten, die Cluster miteinander zu verbinden, so dass

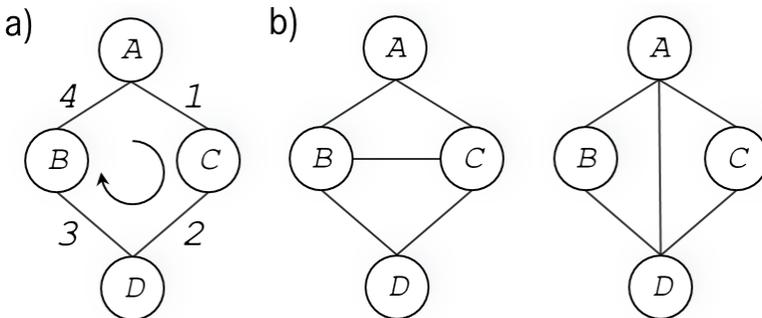


Abbildung 2.10: a) Ungerichteter Graph. b) Triangulierter ungerichteter Graph.

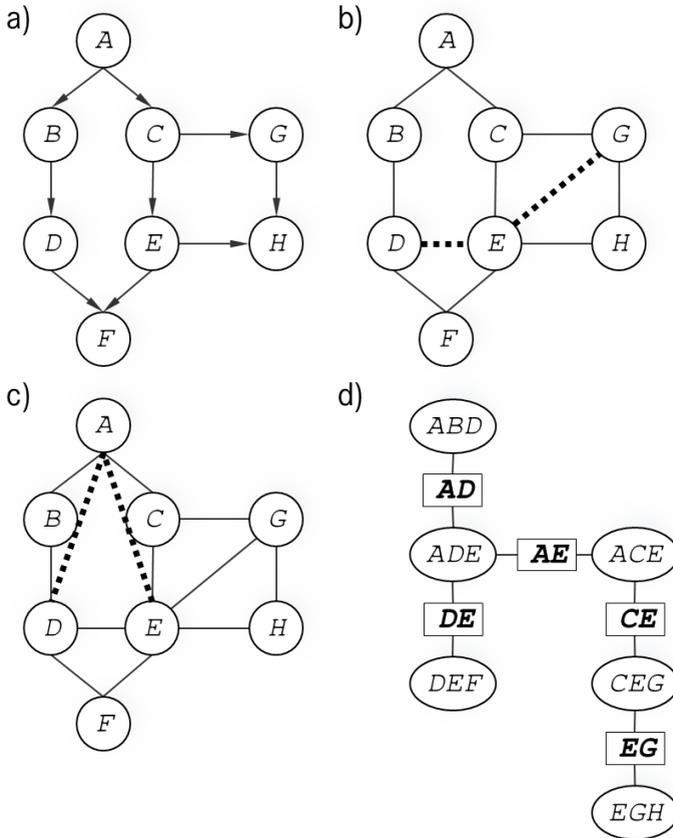


Abbildung 2.11: a) Bayes-Netz b) moralischer Graph c) triangulierter Graph d) möglicher Clique Tree [12].

wieder ein gültiger Clique Tree entsteht.

2.2.3 Lernen

In diesem Kapitel werden die Grundideen für das Anwenden von Lernmethoden vorgestellt. Beim Optimieren von Bayes-Netz-Parametern oder dem Lernen einer Bayes-Netz-Struktur gibt es mehrere Ausgangsszenarien. Die Daten, die zum Ler-

nen verwendet werden, können entweder vollständig oder unvollständig vorliegen. Zusätzlich kann die Bayes-Netz-Struktur bekannt oder unbekannt sein [11].

Angenommen, die zur Verfügung stehenden Daten D besitzen eine zutreffende Wahrscheinlichkeitsverteilung P^* , die von einem probabilistischen graphischen Modell \mathcal{M}^* generiert werden kann. Bei der Suche nach einem passenden Parametersatz ist das Ziel von Lernalgorithmen die Approximation der Verteilung P^* anhand dieser Daten. Dabei wird das Verhalten des Modells untersucht. Kann die Verteilung P^* für die Daten D approximiert werden, so ist wichtig, im nächsten Schritt die Generalisierbarkeit des gefundenen Parametersatzes anhand von neuen Daten D' , die nicht zum Lernen verwendet worden sind, zu überprüfen.

Mit Hilfe von Lernalgorithmen kann auch nach einer möglichen Struktur eines Bayes-Netzes, die dem Modell \mathcal{M}^* am ehesten entspricht, gesucht werden. Dabei werden direkte und indirekte Abhängigkeiten von Variablen und deren Kausalität untersucht [11].

Wird eine Lernmethode auf einen vorhandenen Datensatz zu lange angewandt oder stehen nicht sehr viele Daten zum Lernen zur Verfügung, so kann der Lernalgorithmus sich an sehr spezifische Zufallseigenschaften von Trainingsdaten, die keinen Zusammenhang oder keine Zielfunktion besitzen, einstellen. Dieses Problem ist auch als *Overfitting* bekannt. Beim Lernen von Parametern bedeutet dies, dass der gelernte Parametersatz die Zufallsfehler oder das Rauschen anstatt des tatsächlich vorliegenden Sachverhalts beschreibt. Beim Lernen von Strukturen tritt das *Overfitting* Problem auf, wenn zu komplexe und absurde Strukturen gelernt werden. Beides kann durch Einführung von Lernregeln (i.d.R. durch Regularisierung, Bestrafung von Komplexität) kontrolliert werden. Die Auswahl von solchen Regeln ist schwierig und beeinflusst stark die Leistungsfähigkeit einer Lernmethode [11].

Einer der Algorithmen, welcher zum Lernen von Parametern eingesetzt werden kann, wurde von [16] vorgestellt. Dieser ist auch als Expectation Maximization Algorithmus (EM-Algorithmus) bekannt. Zum Lernen von Strukturen eines Bayes-Netzes kann auf die Arbeiten von [17] verwiesen werden. Dieses basiert auf Randbedingungen (engl. *constraint based*) und ist auch als PC-Algorithmus bekannt.

2.3 Objektorientierte Bayes-Netze

Komplexe Bayes-Netze beinhalten oft identische Bayes-Netz Fragmente. Im bereits vorgestellten Modell zur Überwachung eines Hauses (Abb. 2.7) könnten zum Beispiel mehrere Sensorgruppen verbaut worden sein. Jede ist damit in der Lage, einen Alarm auszulösen. Abbildung 2.12 a) zeigt ein neues Bayes-Netz Modell

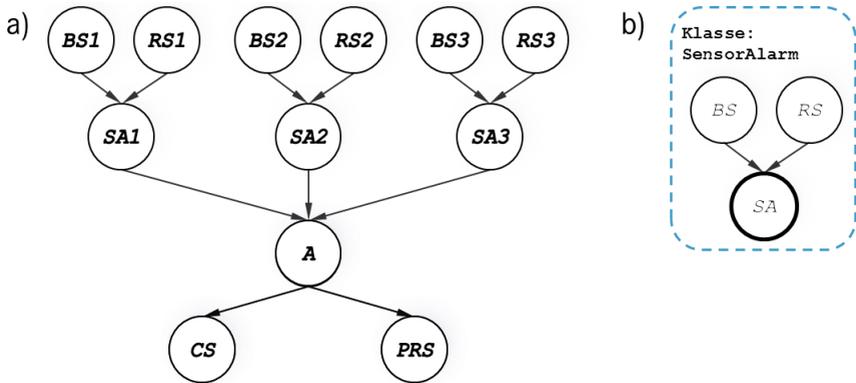


Abbildung 2.12: a) Bayes-Netz zur Überwachung eines Hauses mit drei Sensorgruppen ($SA1$, $SA2$, $SA3$). b) Bayes-Netz Klasse für eine Sensorgruppe (SA).

mit drei Sensorgruppen $SA1$, $SA2$, $SA3$.

Nachteil eines solchen Modells ist der entstehende Aufwand bei einer möglichen Änderung. Sollen neue Sensoren einer Gruppe hinzugefügt oder Parameter geändert werden, müssen die Änderungen im Beispiel drei mal durchgeführt werden. In großen Modellen kann der Änderungsaufwand noch höher ausfallen.

Haben identische Bayes-Netz Fragmente die gleiche Anzahl an Zuständen und identische bedingte Wahrscheinlichkeitstabellen, so kann ein generisches Bayes-Netz Fragment erstellt werden. Abbildung 2.12 b) stellt ein BN-Fragment für eine Sensorgruppe dar. So ein Fragment wird als eine *Klasse* und jede instanziierte Klasse als ein *Objekt* bezeichnet. Für jede *Klasse* müssen zusätzlich die Eingangs- und Ausgangsknoten definiert werden. Mit so einer Beschreibungsform werden im weiteren Vorgehen entsprechende Bayes-Netz-Objekte zum Modellieren verwendet. Das entstehende Bayes-Netz-Modell wird auch als objektorientiertes Bayes-Netz (*OBN*) bezeichnet [10], [18].

Abbildung 2.13 a) zeigt die objektorientierte Form eines Bayes-Netzes, erstellt für das Modell in Abbildung 2.12 a). In diesem Beispiel werden keine identischen Bayes-Netz Fragmente kopiert, sondern die entsprechenden Instanzen zum Modellieren verwendet. Wird in dem vorgestellten Beispiel ein neues Sensorsystem hinzugefügt oder Parameter in der Sensorkonfiguration geändert, so muss

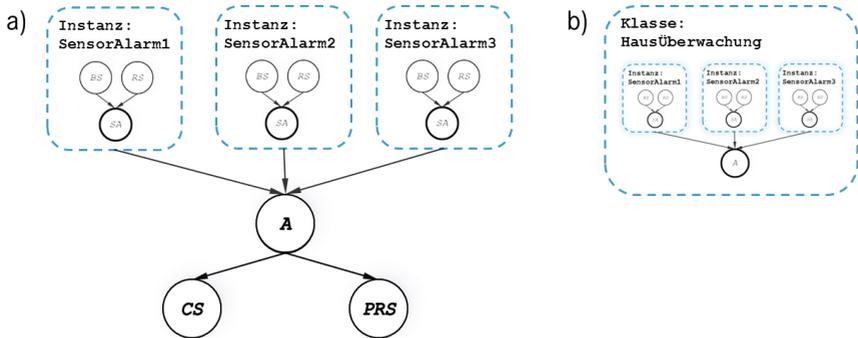


Abbildung 2.13: a) Objektorientiertes Bayes-Netz zur Überwachung eines Hauses mit drei Sensorinstanzen. b) Bayes-Netz Klasse zur Überwachung eines Hauses.

nur die *Klasse:SensorAlarm* modifiziert werden. Die verwendeten Instanzen der *Klasse:SensorAlarm* bekommen die Änderung automatisch mit und müssen nicht geändert werden.

Beim objektorientierten Modellieren können Instanzen von Klassen in weiteren Klassen verwendet werden. In unserem Beispiel können die drei Instanzen der *Klasse:SensorAlarm* zu einer neuen *Klasse:HausÜberwachung* zusammengefasst werden (Abb. 2.13, b). Auf dieser Ebene können auch weitere Variablen hinzugefügt werden. Es kann jetzt ein Bayes-Netz-Modell zum Beispiel zur Überwachung von mehreren Häusern aufgebaut werden. Dieses ist in Abbildung 2.14 dargestellt.

Abbildung 2.15 zeigt das nicht objektorientierte Bayes-Netz zur Überwachung mehrerer Häuser. Wie man sieht, ist dieses Modell sehr schwer zu ändern und zu erweitern.

Ein objektorientiertes Bayes-Netz kann als ein klassisches Bayes-Netz mit speziellen Eigenschaften betrachtet werden. Bevor eine Inferenzrechnung durchgeführt werden kann, werden die objektorientierten Modelle in ein klassisches Bayes-Netz-Modell transformiert. Um solche Transformationen durchzuführen, wurden entsprechende Algorithmen entwickelt.

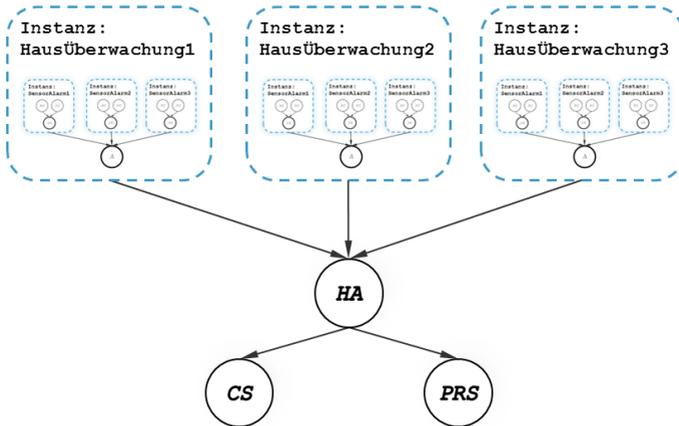


Abbildung 2.14: Objektorientiertes Bayes-Netz zur Überwachung mehrerer Häuser.

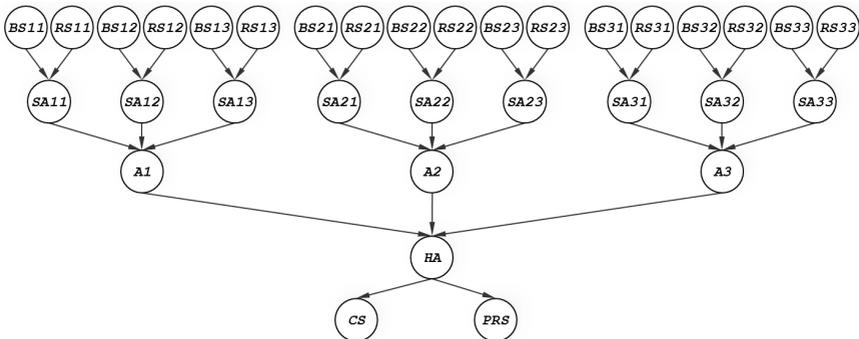


Abbildung 2.15: Bayes-Netz zur Überwachung mehrerer Häuser.

Kapitel 3

Stand der Technik

In diesem Kapitel wird der aktuelle Stand der Technik und aktuelle Entwicklungen von Fahrerassistenzsystemen in der Automobilindustrie vorgestellt. Kapitel 3.1 gibt einen kurzen Überblick über die derzeit verfügbaren Assistenzsysteme und deren Aufbau wieder. Um das Verhalten eines Fahrerassistenzsystems zu verbessern, spielt die Entwicklung eines Verständnisses für die vorliegende Situation eine wichtige Rolle. Die Erkennung von Aktionen, welche die Fahrzeuge durchführen können, ist einer der ersten Schritte in diesem Entwicklungsprozess. Kapitel 3.2 fasst die aktuellen Arbeiten und Ansätze bei der Aktionserkennung zusammen. Kapitel 3.3 stellt mögliche Erweiterungen auf diesem Gebiet vor.

3.1 Fahrerassistenzsysteme

Der Begriff Fahrerassistenzsystem könnte nach [19] folgendermaßen definiert werden: *Ein Fahrerassistenzsystem ist ein System, welches den Fahrer beim Führen eines Kraftfahrzeuges unterstützt.* Das Ziel der Fahrerassistenzsysteme ist die Steigerung des Fahrkomforts und der Sicherheit. Diese können in zwei Bereiche Fahrerassistenz auf Stabilisierungsebene und Fahrerassistenz auf Bahnführungs- und Navigationsebene gegliedert werden. Die Daimler AG verfolgt auf dem Gebiet der Fahrerassistenzsysteme ein integrales Sicherheitskonzept, welches in die vier Bereiche *Sicher Fahren*, *Bei Gefahr*, *Bei einem Unfall* und *Nach einem Unfall* unterteilt ist [20].

Abbildung 3.1 stellt schematisch ein Vierschichtenmodell eines Fahrerassistenzsystems dar. Dieses besteht aus *Umgebungserfassung*, *Fusion*, *Situationsanalyse*

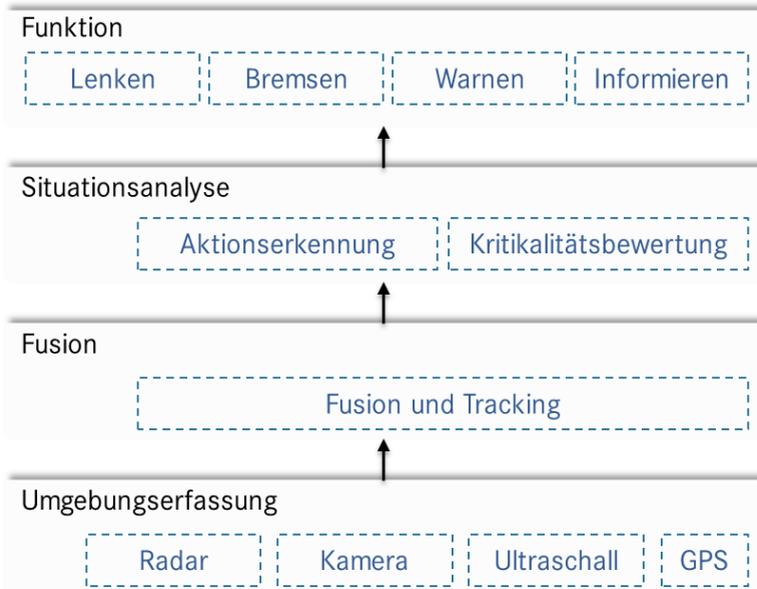


Abbildung 3.1: Schichtenmodell eines Fahrerassistenzsystems

und *Funktion*.

Zur Umgebungserfassung werden derzeit verschiedene Sensorsysteme eingesetzt. Dazu gehören Kamera-, Radar-, Lidar-Systeme, Ultraschallsensoren und andere Datenquellen, wie z.B. das GPS (Global Positioning System), digitale Karten oder Fahrzeug-Fahrzeug-Kommunikation. Der Zustand des eigenen Fahrzeuges kann mit Hilfe von Drehraten-, Beschleunigungs- und Raddrehzahlsensoren erfasst werden.

Die zur Verfügung stehenden Sensordaten werden im nächsten Schritt in einem Fusionsmodul fusioniert. Dies erhöht die Qualität und Zuverlässigkeit von vorhandenen Informationen.

Damit ein Fahrerassistenzsystem eine adäquate Reaktion auf eine Verkehrssituation berechnen kann, muss dieses in der Lage sein, nicht nur die Umgebung zu erfassen, sondern auch die vorliegende Situation zu analysieren. Mit dieser Aufgabe befasst sich die dritte Schicht eines Fahrerassistenzsystems. Zu den Aufgaben der Situationsanalyse gehören die Entwicklung eines Verständnisses für eine Si-

tuation (z.B. Aktionserkennung) sowie die Bewertung derer Kritikalität.

Die Aufgabe der vierten Schicht ist die Ableitung notwendiger Handlungen (Lenken, Bremsen, Warnen, Informieren), um den Komfort bei einer Fahraufgabe zu erhöhen oder um einen in Gefahrensituationen bevorstehenden Unfall zu verhindern oder die Unfallschwere zu reduzieren.

Im Folgenden werden Beispiele für Fahrerassistenzsysteme vorgestellt, die derzeit auf dem Markt verfügbar sind. Diese sind in Fahrerassistenz auf Stabilisierungsebene und auf Bahnführungs- und Navigationsebene aufgeteilt.

3.1.1 Fahrerassistenz auf Stabilisierungsebene

Assistenzsysteme auf einer Stabilisierungsebene haben als Aufgabe, die Stabilität und Lenkbarkeit eines Fahrzeuges in der Längs- und Querrichtung zu garantieren [19], [20]. Dazu gehören z.B. das Antiblockiersystem (ABS), die Antriebs-schlupfregelung (ASR) oder das Elektronische Stabilisierungsprogramm (ESP).

Das Antiblockiersystem verhindert das Blockieren der Räder bei einer Bremsung, um so die Lenkbarkeit eines Fahrzeuges in jeder Situation zu garantieren.

Um die Leistung eines Motors optimal auf die Straße zu bringen regelt die Antriebs-schlupfregelung den Motormoment oder bremst die Antriebsräder gezielt ab. Dabei verhindert das System das Durchdrehen der Räder. Dies erleichtert das Anfahren auf unterschiedlicher Fahrbahnbeschaffenheit.

Durch das Abbremsen einzelner Rädern ist das ESP in der Lage, das Fahrzeug im querdynamischen Grenzbereich z.B. beim plötzlichen Ausweichen zu stabilisieren. Dabei wird das Abkommen von der Fahrbahn oder das Schleudern eines Fahrzeuges verhindert.

3.1.2 Fahrerassistenz auf Bahnführungs- und Navigationsebene

Assistenzsysteme auf der Bahnführungs- bzw. Navigationsebene können in Sichtverbesserungs-, Einparkassistent-, Frontalkollisionsschutz-, Spurhalteassistentensysteme sowie Abstandsregelung und Navigation unterteilt werden [19], [20].

Als ein Beispiel für zahlreiche Sichtverbesserungssysteme können Abbiegelicht, Fernlicht-Assistent, aktives Kurvenlicht, Nachtsicht-Assistent genannt werden. Das Abbiegelicht vergrößert den Sichtbereich bei Abbiegemanövern. Es schaltet sich automatisch ein, wenn bei eingeschalteten Scheinwerfern der Blinkerhebel betätigt oder das Lenkrad eingeschlagen wird. Der Fernlicht-Assistent erkennt

mittels einer Kamera den Gegenverkehr und blendet gezielt den Bereich aus, in dem sich das vorausfahrende Fahrzeug befindet. Aktives Kurvenlicht vergrößert den Sichtbereich auf kurvenreichen Strecken, dabei folgen die Scheinwerfer den Lenkbewegungen der Räder. Bei einem Nachtsicht-Assistenten wird der Sichtbereich mittels einer Infrarotkamera erhöht.

Die Parkassistenzsysteme warnen nicht nur vor Hindernissen beim Einparken. Die heutige Generation der Parkassistenzsysteme übernimmt zusätzlich die Aufgabe der Suche nach einem passenden Parkplatz bis hin zum teilautonomen Einparken des Fahrzeuges.

Zu den Frontalkollisionsschutzsystemen gehören der Bremsassistent, welcher bei einer drohenden Kollision den Fahrer warnt und gleichzeitig den Bremsdruck im Bremssystem so anpasst, dass bei einer Bremsung der Unfall noch verhindert werden kann. Ist der Unfall nicht mehr vermeidbar leitet der Bremsassistent eine Vollbremsung ein, um so die Unfallschwere zu reduzieren. Um den optimalen Insassenschutz zu erreichen, können weitere Maßnahmen wie das Ausrichten der Sitze, straffen des Anschnallgurtes oder situationsabhängige Auslösung eines Airbags eingeleitet werden. Die neueste Generation der Frontalkollisionsschutzsysteme basieren auf einem Radarsensor, welcher die Information über die vorausfahrenden Fahrzeuge liefert.

Droht das Fahrzeug die Spur zu verlassen, greifen die Spurhalteassistenzsysteme in das Fahrgeschehen ein. Im ersten Schritt wird der Fahrer beim Verlassen der Spur gewarnt. Reagiert der Fahrer nicht, so wird im zweiten Schritt durch einen Brems- oder Lenkeingriff das Fahrzeug in die Spur zurückgeführt. Unter anderem wird der Fahrer zusätzlich bei der Spurführung unterstützt, indem das Fahrzeug in der Spurmitte geführt wird. Zu solchen Systemen gehört auch die Überwachung des toten Winkels, was das Spurwechseln sicherer macht.

Die Regelung des Abstandes zu einem vorausfahrenden Fahrzeug wird von einem Abstandsregeltempomaten übernommen. Die Abstands- und die Geschwindigkeitsinformation der umgebenden Fahrzeuge wird mittels eines Radarsystems bestimmt. Basierend auf diesen Informationen können Geschwindigkeit und Abstand des eigenen Fahrzeuges an die Situation angepasst werden. Eine Erweiterung dieses Systems stellt die Stop&Go Funktion dar, welche das Fahren in einem Stau durch automatisches Abbremsen und vom Fahrer initiiertes Anfahren des Fahrzeuges erleichtert.

3.2 Methoden der Aktionserkennung

Um die Akzeptanz der Fahrerassistenzsysteme zu erhöhen, müssen diese genauso so gut oder besser als Fahrer auf verschiedene Situationen reagieren. Dazu ist es

notwendig, die vorliegende Situation zu analysieren und zu verstehen. Die Erkennung von Aktionen, die ein Fahrzeug durchführt oder durchführen kann, spielt dabei eine wichtige Rolle. Zum Beispiel könnte der Abstandsregeltempomat mit dem entsprechenden Wissen über die aktuelle Situation bei verschiedenen Fahrmanövern wie Einscheren, Ausscheren sowie Überholen oder Abfahren von einer Autobahn, die Regelung der Geschwindigkeit und des Abstandes besser umsetzen. Die Klassifikation von Gefahrensituationen könnte dem Bremsassistenten helfen, die entsprechenden Schutzmaßnahmen früher einzuleiten, um einen optimalen Schutz bis hin zu Unfallvermeidung zu garantieren.

Eine der vielen Herausforderungen bei einer solchen Aufgabe ist die Modellierung der entsprechenden Situation. Dazu gehört auf der einen Seite der Umgang mit unvollständigem Wissen, da nicht jede Situation komplett beobachtbar ist, und auf der anderen Seite der Umgang mit Messunsicherheiten, die bei Verwendung von Fahrzeugmessdaten stets vorhanden sind. Des Weiteren hängt die Art der Durchführung einer Aktion vom individuellen Fahrerverhalten ab, wodurch sich eine Vielzahl von Möglichkeiten ergibt.

In den letzten Jahren haben sich viele Methoden zur Aktionserkennung im Bereich der Fahrerassistenzsysteme bewährt. Dazu gehört der Einsatz von Fuzzy-Logik, Hidden Markov Modellen, Bayes-Netzen, dynamischen Bayes-Netzen, Dempster-Shafer-Theorie, Neuronalen Netzen und Relevance Vector Machines.

Unter einer Aktion wird hier eine mögliche Handlung oder Absicht eines Fahrers während einer Fahraufgabe verstanden. Dazu gehören die Ausführung von unterschiedlichen Fahrmanövern wie Fahrzeug- und Spurfolgen, Spurwechseln, Einscheren, Ausscheren, Überholen in einem Autobahnzenario sowie Anhalten, Abbiegen, Wenden im städtischen Gebiet, z.B. auf einer Kreuzung. Unter anderem wird auch versucht, den mentalen Zustand des Fahrers wie Müdigkeit oder Aufmerksamkeit zu bestimmen.

Als Eingangsdaten für die Klassifikationsverfahren können die eigenen Ego-Fahrzeugdaten, Daten aus der Umgebungserfassung, kommunizierte Daten über Fahrzeug-Fahrzeug Kommunikation sowie die GPS Daten zur Lokalisierung von Fahrzeugen verwendet werden.

3.2.1 Fuzzy-Logik

Die Arbeiten von [21] stellen einen autonomen Überholassistenten vor. Das Überholverhalten eines Fahrers wird mit Hilfe der Fuzzy-Logik nachgebildet. Als Eingangsdaten dienen die Positionen, Geschwindigkeiten u.s.w. der Fahrzeuge, die mit einem hoch genauen GPS Systemen bestimmt und via Wireless-LAN kommuniziert werden.

Der Vorschlag von [22] arbeitet mit Fuzzy-Logik und kombiniert diese mit einem endlichen probabilistischen Zustandsautomaten [23], [24]. Ein Manöver besteht aus einer Folge von Basis-Elementen (z.B. Bremsen, Beschleunigen, Lenken), die in einem Zustandsautomat abgebildet werden. Die Sensoreingangsdaten werden in einem ersten Schritt in linguistische Terme umgesetzt (Fuzzifizierung). Anhand dieser wird die Fuzzy-Regelbasis evaluiert und der Zugehörigkeitsgrad zwischen den Basiselementen bestimmt. Zum Schluss wird mit einem Bayes-Filter der wahrscheinlichste Zustand (Basis-Element) des Zustandsautomaten bestimmt.

In [25] wird eine komplette Systemarchitektur zur Empfehlung eines Spurwechselmanövers mit einer entsprechenden HMI-Schnittstelle vorgestellt. Als Grundlage für die Erkennung der Fahrerabsicht wird ein Fuzzy-Logik Ansatz wie bei [26] bevorzugt, welcher mit CAN-Busdaten arbeitet.

Ein System zum Durchführen eines automatischen Spurwechselmanövers wird in [27] vorgestellt. Dieses basiert auf zwei Zustandsautomaten, welche das Spurwechsel- und Geschwindigkeitsverhalten modellieren. Die Entscheidung für einen Zustandsübergang von einem Zustand in einen anderen ist mit Hilfe der Fuzzy-Logik realisiert.

3.2.2 Bayes-Netze

Die Arbeiten von [5], [6], [7] beschäftigen sich mit Erkennung von Einscherer-Situationen mit Bayes-Netzen in einem Autobahnszenario. Hier wurde eine Verbesserung der Funktionalität eines Abstandsregeltempomaten durch die Erkennung von Einscherer-Situationen untersucht. Die vorliegende Arbeit baut auf diesen Ergebnissen auf und führt folgende Erweiterungen ein. Als erstes wird in dieser Arbeit ein symmetrisches Spurkoordinatensystem zur Berechnung von Situationsmerkmalen eingeführt. In diesen Koordinatensystemen ist das Verhalten der definierten Situationsmerkmale gleich. Dies erleichtert die Modellierung und Parametrierung eines Bayes-Netzes. Als zweites werden verschiedene Objekt-Objekt-Beziehungen eingeführt (z.B. Fahrzeug-Fahrzeug-Beziehung). Dies ermöglicht die Klassifikation von mehreren Fahrmanövern zwischen allen beteiligten Verkehrsteilnehmern (nicht nur Einscherer). Als drittes werden in dieser Arbeit objektorientierte Bayes-Netze (*OBN*) eingesetzt. Durch den Aufbau von generischen Bayes-Netz-Objekten und deren Wiederverwendung kann das Bayes-Netz-Modell hierarchisch in Schichten aufgebaut werden. Dadurch wird die Komplexität des Modells und die Anzahl der zu definierenden Bayes-Netz-Parameter deutlich reduziert.

Ein Ansatz zur Erkennung von Fahrmanövern, welcher die Fuzzy-Logik mit den Bayes-Netzen kombiniert, wird in [28] diskutiert. Die Situationsmerkmale werden mit Hilfe einer Fuzzy-Regelbasis in linguistische Terme transformiert (Fuzzifizie-

rung), welche als Evidenzen in ein Bayes-Netz einfließen. Hier wird ein System zur Erkennung von Notbremsituationen als Beispiel vorgestellt.

In [29] werden zwei Modelle basierend auf einer linearen Regression und Bayes-Netzen zur Prädiktion von Fahrerverhalten (Bremsen, Beschleunigen, Lenken) im Kreuzungsbereich beschrieben. In den Arbeiten von [30], [31] wird auch das Verhalten von Verkehrsteilnehmern im Kreuzungsbereich modelliert. Dabei setzt sich die gesamte Situation aus einzelnen, zusammenhängenden Einheiten, welche das Verhalten von unterschiedlichen Verkehrsteilnehmern direkt beeinflussen, zusammen.

Die Arbeiten von [32], [33], [34], [35], [36] beschäftigen sich mit dem Umgang von unsicheren Informationen bei der Objekterkennung, Datenfusion und Situationsanalyse. Unter anderem wird hier ein System zur Empfehlung eines Spurwechselmanövers unter Einsatz von Bayes-Netzen vorgestellt.

3.2.3 Dynamische Bayes-Netze

Die Modellierung des Fahrerverhaltens (Fahrzeugfolgen, Spurwechsel) wird in den Arbeiten von [8] mit Hilfe eines DBN durchgeführt. Dabei werden die Fahreraktionen über einen bestimmten Zeitraum beobachtet und daraus eine Spurwechselintention abgeleitet. Da die Berechnung der dafür erforderlichen Inferenz in einem dynamischen Bayes-Netz rechenintensiv ist und gleichzeitig auch die Anzahl der zu definierenden Parameter ansteigt, handelt es sich bei diesen Arbeiten primär um einen theoretischen Ansatz, der in der Praxis nicht umgesetzt wurde.

Die Arbeiten von [37] beschäftigen sich mit der Erkennung von Situationen in einem Autobahnzenario, die zu einem Stau führen können. Hier werden auch Spurwechselmanöver klassifiziert. Die Modellierung von Situationen wird mit Hilfe von dynamischen Bayes-Netzen (DBN) durchgeführt. Dazu wird im ersten Schritt mit Hilfe von Kalman-Filtern der Bewegungszustand von detektierten Objekten geschätzt und vorhergesagt. Die Daten wie Position und Geschwindigkeit von Objekten gehen dann als Evidenzen in das DBN ein.

In [38] wird unter Einsatz eines DBN's Fahrerstress während verschiedenen Manövern (Überholen, Notbremsen oder Abbiegen) klassifiziert. Dabei ist der Stressfaktor in die vier Stufen *normal*, *low*, *medium* und *high* unterteilt.

Ein Modell für Kreuzungen und Fahrerverhalten im Kreuzungsbereich wird in [39] vorgestellt. Eine Kreuzung wird dabei als eine Anzahl vorhandener Spuren und möglicher Spurübergänge dargestellt. Das Fahrerverhalten hängt direkt von diesem Modell ab und wird verallgemeinert mit Hilfe eines probabilistischen Graphen modelliert. Es wird davon ausgegangen, dass der Fahrer einer Spur folgt. Die Prädiktion eines Fahrerverhaltens wird mit DBN realisiert.

In den Arbeiten von [40] wird eine Situation als eine zeitliche Entwicklung verschiedener Größen (relative Geschwindigkeit, Abstand, Winkelfehler zwischen zwei Fahrzeugen) betrachtet. Diese wird als ein DBN modelliert. Die Parameter des dynamischen Bayes-Netzes werden mit Hilfe der Kernel Regression anhand eines gelabelten Datensatzes trainiert. Das System wurde für die Erkennung von Überholmanövern entwickelt.

In [41], [42] wird unter Einsatz von DBN eine Risikoanalyse im Kreuzungsbereich durchgeführt. Dazu wird die Intention eines Verkehrsteilnehmers („*Was hat der Fahrer vor?*“) mit der erwarteten Entwicklung einer Situation („*Was muss der Fahrer tun?*“) verglichen. Durch diesen Vergleich können gefährliche Situationen erkannt werden.

3.2.4 Hidden Markov Modelle

Bei dem Ansatz von Hidden Markov Modellen (HMM) wird meistens eine Aktion (z.B. Fahrmanöver) als Folge von Zuständen modelliert. In [43] wird ein HMM, mit dem Fahrmanöver wie Abbiegen, Spurwechseln, Überholen usw. klassifiziert werden können, vorgestellt. Dabei wird auch der Einsatz von Coupled Hidden Markov Modellen (CHMM) untersucht [44]. Als Eingangsdaten für das HMM dienen Ego-Fahrzeugdaten (Gaspedal, Bremspedal, Lenkwinkel), Spurinformatoren sowie die relative Geschwindigkeit und Position von umgebenden Fahrzeugen.

In den Arbeiten von [45] wird ein Fahrmanöver als eine zeitliche Entwicklung von gemessenen Fahrzeugdaten (Lenkradwinkel und Geschwindigkeit) betrachtet. Dabei wird der zeitliche Verlauf der Daten in vier für das Fahrmanöver charakteristische Phasen unterteilt. Diese Phasen werden dann mit Hilfe von neuronalen Netzen erkannt. Die Vorhersage, welches Fahrmanöver (zeitliche Entwicklung der vier Phasen) gerade stattfindet, wird mit Hilfe von HMM's durchgeführt. In dieser Arbeit werden Fahrmanöver wie Rechts-, Linksabbiegen, Wenden usw. adressiert.

Eine mögliche Systemarchitektur für die Entwicklung der Fahrerassistenzsysteme der neuen Generation wird in [46] vorgestellt. Diese umfasst ein Vierschichtenmodell von Umgebungserfassung, Informationsfusion, Situationsanalyse und Wissensrepräsentation. Die Modellierung von Fahrscenen wird mit Hilfe von Markov-Logik-Netzwerken durchgeführt [47].

In [48] werden anhand der Fahrzeugdaten wie Geschwindigkeit, Lenkwinkel und Bremsdruck die drei verschiedenen Manöver Links-, Rechtsabbiegen und Spurwechseln klassifiziert. Als Vorlage für das vorgestellte Modell wurden Ansätze auf dem Gebiet der Spracherkennung herangezogen.

Die Arbeiten von [49], [50], [51], [52] beschäftigen sich mit der Erkennung und

der Plausibilitätsprüfung von prädierten Fahrmanövern. Es werden Fahrmanöver wie Spurwechsel, Überholen, Fahrzeug- oder Spurfolgen erkannt. Die Manöver werden einzeln als eigenständige Hidden Markov Modelle mit fünf Zuständen modelliert. Zur Prädiktion eines Manövers werden Informationen wie Straßentyp, Einfluss anderer Verkehrsteilnehmer, Straßengeometrie, aber auch zuletzt durchgeführte Manöver mitberücksichtigt. Die Parameter der Modelle werden mithilfe von Lernmethoden trainiert.

Um eine frühzeitige Erkennung von Fahrmanövern zu ermöglichen, schlägt der Ansatz von [53] vor, nur die ersten Zustände (Submodell) eines gesamten Hidden Markov Modells zu betrachten. Die Parameter des HMM's werden anhand gelabelten Daten unter Einsatz von Lernmethoden bestimmt. Dabei wurde die Erkennungsleistung für eine unterschiedliche Anzahl von Zuständen des gesamten Hidden Markov Modells und Submodellen evaluiert. Das System wurde für die Erkennung von Spurwechselmanövern sowie Abbiegemanövern trainiert.

Ein allgemeines Framework zur Modellierung und Erkennung von Fahrsituationen mit HMM's wird in den Arbeiten von [54] vorgestellt. Dabei wird jede einzelne Fahrsituation durch ein individuelles HMM modelliert. Als Beispiel wird hier ein Überholmanöver klassifiziert.

In [55], [56] wird ein HMM zur Klassifizierung vom Fahrerverhalten wie Anhalten an einer Stopplinie im Kreuzungsbereich vorgestellt.

3.2.5 Dempster-Shafer-Theorie

In den Arbeiten von [57], [58] wird eine Fahrsituation als eine Menge von Zuständen modelliert, die die elementaren Aktionen von und Interaktionen zwischen Objekten beschreiben. Dabei werden auch Verkehrsregeln mitberücksichtigt. Die Beschreibung von Interaktionen zwischen Objekten und deren elementaren Aktionen wird mit Hilfe von unscharfen Regeln in einem Dempster-Shafer-Framework durchgeführt.

In [59], [60], [61] werden mit Hilfe der Dempster-Shafer-Theorie Fahrmanöver wie Spurwechsel, Überholen, Einscheren, Fahrzeugfolgen usw. klassifiziert. Der Übergang eines Manövers in ein anderes (z.B. Einscheren, Fahrzeugfolgen) wird mit Hilfe eines Zustandsautomaten modelliert.

Ähnliche Ansätze zur Klassifizierung von Fahrermüdigkeit werden in [62] vorgestellt.

3.2.6 Neuronale Netze

Die Arbeiten von [63] beschäftigen sich mit der Erkennung von Spurwechselmanövern und vergleichen dabei unterschiedliche Methoden miteinander. Hier wird der Einsatz von Neuronalen Netzen und Support-Vector-Machines (SVM) untersucht. Die Spurwechselmanöver konnten 1.5s früher vorhergesagt werden, wobei der Einsatz von SVM die beste Erkennungsleistung zeigte.

In [64] werden Spurwechselmanöver anhand von abgefahrenen Trajektorien-Historien der Fahrzeuge unter Einsatz von Neuronalen Netzen klassifiziert.

3.2.7 Relevance-Vector-Machine

In [65], [66], [67] werden mit Hilfe von Relevance-Vector-Machine (RVM) [68], die eine Erweiterung der klassischen Support-Vector-Machines darstellen [69], eine Intention für ein Spurwechselmanöver vorhergesagt. Als Basis für das vorgestellte Klassifikationsverfahren dienen die Arbeiten von [70], [71], die sich auch mit der Erkennung von Spurwechselmanövern beschäftigen. Ähnliche Ansätze wurden zur Erkennung von Abbiegemanövern auf einer Kreuzung [72] sowie zur Analyse vom Bremsverhalten eines Fahrers [73], [74] vorgestellt. In diesen Arbeiten wurde ein mehrdimensionaler Merkmalsvektor definiert, welcher verschiedene Sensordaten mit Ego-Fahrzeugdaten zusammenfasst. Die RVM's wurden mit Hilfe von Lernmethoden trainiert und anhand von zahlreichen Versuchen im Labor und im Realverkehr getestet.

Eine weitere Distanzfunktion zur Clusterung von Trajektorien stellt das LCSS (engl. *longest common subsequence*) Ähnlichkeitsmaß dar [75]. Der Vorteil des Verfahrens liegt in der Möglichkeit, die Koordinaten der einzelnen zu vergleichenden Trajektorien zu überspringen. Es werden nur ähnliche Abschnitte von zwei Trajektorien für die Berechnung des Ähnlichkeitsmaßes berücksichtigt, was das Verfahren gegen Ausreißer robust macht. Viele Variationen des LCSS wurden auf dem Gebiet des Fahrzeug-Trajektorien-Clusterings veröffentlicht. In den Arbeiten von [76], [77] wurde zur Prädiktion von Trajektorien ein rotationsinvariantes Ähnlichkeitsmaß vorgestellt. In den Arbeiten von [78], [79] wurde das LCSS zur Klassifikation von verschiedenen Verkehrssituationen erweitert.

3.3 Bedarf neuer Lösungen

Obwohl die in Kapitel 3.2 vorgestellten Ansätze bereits gute Ergebnisse bei der Situationsklassifikation und Aktionserkennung auf dem Gebiet der Fahrerassistenzsysteme liefern, ist noch viel Verbesserungspotenzial vorhanden.

Evaluierung von modernen Fahrerassistenzsystemen in realen Verkehrsszenarien spielt bereits in den frühen Entwicklungsphasen eine wichtige Rolle. Dazu ist eine schnelle Entwicklung von Prototypen und die Integration in ein Fahrzeug notwendig. Um dies zu ermöglichen wird speziell für die Situationsklassifikation ein strukturierter, leicht erweiterbarer und generischer Ansatz benötigt, welcher als Baukastensystem eingesetzt werden kann. Dazu ist eine Modellierung von Grundbausteinen mit verschiedenen Situationsmerkmalen, die sich als Basismodule zur Erkennung von verschiedenen Aktionen zusammensetzen lassen, unumgänglich. Zusätzlich wird eine allgemeingültige Beschreibung einer Fahrsituation (Fahrszene), die sich auf weitere Situationen erweitern lässt, benötigt. Diese Beschreibungsform würde eine einheitliche Schnittstelle für die entwickelten Softwaremodulen bilden und so den Integrationsaufwand reduzieren.

Die Anforderungen wurden von bisherigen Arbeiten nicht immer berücksichtigt. Bei vielen Arbeiten handelt es sich primär um einen theoretischen Ansatz, welcher in der Praxis nicht umgesetzt wurde. Viele Ansätze wurden nur im Labor untersucht. Die Realisierung im Fahrzeug war manchmal aus Komplexitätsgründen oder der fehlenden Rechenleistung nicht möglich.

Das Ziel dieser Arbeit ist die Entwicklung eines neuen Ansatzes zur Erkennung von unterschiedlichen Fahrmanövern in einem Autobahnscenario für alle Verkehrsteilnehmer. Das Klassifikationsmodul soll im Fahrzeug umgesetzt und evaluiert werden.

Die neuen Teilziele und Anforderungen können folgendermaßen formuliert werden:

- Erkennung von unterschiedlichen Fahrmanövern sowohl für das Ego-Fahrzeug als auch für die erkannten Objekte.
- Entwicklung eines allgemeingültiges Modells zur Behandlung von Unsicherheiten.
- Entwicklung einer allgemeingültigen Beschreibung verschiedener Fahrsituationen (Fahrszenen).
- Beherrschbarkeit der Komplexität des eingesetzten Verfahren.
- Erweiterbarkeit von Modellen für weitere Klassifikationsaufgaben.
- Umsetzbarkeit der Modelle in einem Versuchsträger.

Durch das Klassifizieren bzw. Verstehen einer Fahrsituation können die in Kapitel 3.1 vorgestellten Fahrerassistenzsysteme verbessert werden. Dabei kann das Ergebnis der Klassifikation für die Sicherheitssysteme oder Komfortsysteme verwendet werden. Während Sicherheitssysteme wie Bremsassistent immer aktiv sind und nur kurzzeitig bei Gefahr in die Situation eingreifen, werden Komfortsysteme wie ein ACC-System vom Fahrer aktiviert, um bei der Durchführung einer

Fahraufgabe entlastet zu werden. Der Einsatz eines Klassifikationssystems zur Erweiterung und Verbesserung von Fahrerassistenzsystemen wird an folgenden Beispielen vorgestellt:

- Ein ACC-System muss z.B. ein relevantes Objekt, zur Regelung des Abstandes und der Geschwindigkeit des Ego-Fahrzeuges, auswählen. Durch die Klassifikation von Fahrmanövern kann ein ACC-System in ihrer Entscheidungsfindung unterstützt werden, um so schneller auf die einscherenden und ausscherenden Fahrzeuge zu reagieren [80].
- Die Regelparameter eines Spurhaltesystems können an die vorliegende Situation angepasst werden. Wird z.B. eine Baustellendurchfahrt durch ein Klassifikationssystem klassifiziert, so kann die Lenkung straffer eingestellt werden, um so das Fahren einer Schlangenlinie in engen Durchfahrten zu verhindern.
- Wird z.B. ein Linksabbiegemanöver von einem Klassifikationssystem prognostiziert, so kann diese Information bei drohender Kollisionsgefahr mit einem entgegenkommenden Fahrzeug als Aktivierungsbedingung für einen Bremsingriff benutzt werden. Je früher diese Klassifikation stattfindet, desto mehr Zeit verbleibt, um den drohenden Unfall zu verhindern. Fehlt das notwendige Verständnis über die Situation, müssen die Sicherheitssysteme bis zum letztmöglichen Zeitpunkt warten (z.B. keine Eingriffsmöglichkeiten für den Fahrer vorhanden) um dann den Eingriff durchzuführen. In den meisten Fällen ist hier nur eine Minderung der Unfallschwere und keine Unfallvermeidung möglich [22], [81].

Wie man sieht, können durch die Entwicklung eines Verständnisses für eine Situation die Auslösezeitpunkte oder die Regelparameter der Fahrerassistenzsysteme in Bezug auf Sicherheit und Komfort verändert werden. Das in dieser Arbeit entwickelte System zur Klassifikation von Fahrmanövern dient zur Unterstützung eines ACC-Systems und Erhöhung des Fahrkomforts. Dabei wurde die Erkennungsleistung und die Umsetzbarkeit des Klassifikationssystems in einem Versuchsträger evaluiert. Die Kundenakzeptanz wurde in dieser Arbeit jedoch nicht untersucht.

Um solche Klassifikationssysteme entwickeln zu können, werden ein Modell und Modellparameter für eine zu verstehende Situation benötigt. Da aber bei weitem nicht alle Aspekte einer Situation beobachtbar sind (insbesondere die Intentionen von Verkehrsteilnehmern), muss das eingesetzte Klassifikationsverfahren gleichzeitig mit unvollständigem Wissen und unsicheren Informationen umgehen können. Um die aufgestellten Anforderungen zu erfüllen, wird in dieser Arbeit der in Kapitel 2.1 vorgestellte Ansatz der objektorientierten Bayes-Netzen herangezogen. Die Bayes-Netze bieten eine qualitative (Modell) und quantitative (Modellparameter) Modellierung einer Situation. Die Bayes-Netz-Struktur beschreibt

die bekannten Abhängigkeiten zwischen der Bayes-Netz Variablen. Dadurch kann a-priori Wissen in das Klassifikationssystem eingebracht werden, welches zur Reduktion der Komplexität in einem Modell beiträgt. Durch Bayes-Netz-Parameter wird der Einfluss zwischen zusammenhängenden Variablen modelliert. Außerdem ist ein Bayes-Netz Ansatz deterministisch und bietet die Möglichkeit der impliziten Behandlung von Unsicherheiten. Letzteres wird durch das Einfügen von weichen Evidenzen (engl. *likelihood evidence*) realisiert.

Das im Rahmen dieser Arbeit entwickelte OOBN ist hierarchisch in logischen Schichten strukturiert, welche für verschiedene Aufgaben vorgesehen sind (Kap. 4). Durch die Modellierung und Bildung von generischen Bayes-Netz-Objekten, die wiederverwendet werden können, ist der Aufbau von sehr komplexen Klassifikationssystemen möglich. Die Bayes-Netz-Objekte lassen sich zur Erkennung von verschiedenen Fahrmanövern auf unterschiedliche Art und Weise zusammensetzen. Es können leicht neue Bayes-Netz-Objekte auf unterschiedlichen Ebenen hinzugefügt werden. Somit ist es möglich, das Modell auf weitere Klassifikationsaufgaben zu erweitern. Außerdem kann für das aufgestellte Bayes-Netz-Modell mit Hilfe der zur Verfügung stehenden Werkzeugen ein C-Code generiert werden, der relativ einfach in jede beliebige Entwicklungsumgebung integriert werden kann [82], [83]. Zusätzlich wird in dieser Arbeit eine allgemeine softwaretechnische Lösung zur Beschreibung einer Fahrscene vorgestellt (Kap. 5). Somit werden durch den verwendeten Modellierungsansatz alle aufgestellten Anforderungen erfüllt.

Die Flexibilität des objektorientierten Ansatzes, die Möglichkeit der impliziten Behandlung von Unsicherheiten und die Beherrschbarkeit der Komplexität des Modells sind die Gründe für den Einsatz von objektorientierten Bayes-Netzen als Klassifikationsverfahren. Da das Bayes-Netz-Modell und die Bayes-Netz-Parameter explizit definiert werden können, ist das Ergebnis der Klassifikation damit sowohl nachvollziehbar als auch deterministisch. Diese Nachvollziehbarkeit spielt eine wichtige Rolle bei Entwicklungen auf dem Gebiet der Fahrerassistenzsysteme.

Kapitel 4

Erkennung von Fahrmanövern

In diesem Kapitel wird der in der vorliegenden Arbeit entwickelte Ansatz zur Erkennung von Fahrmanövern in Autobahnszenarien beschrieben. Grundlegend für die Anwendung von Bayes-Netzen zur Lösung einer Klassifikationsaufgabe sind die Definition geeigneter Situationsmerkmale, die Modellierung der Bayes-Netz-Struktur und die Auswahl der Bayes-Netz-Parameter. Dazu wird in Kapitel 4.1 zunächst die Idee zur Erkennung von Fahrmanövern vorgestellt. Kapitel 4.2 stellt die definierten Situationsmerkmale und deren Berechnung im Detail dar. Weiterhin werden in den Kapiteln 4.3 und 4.4 das objektorientierte Bayes-Netz sowie die entsprechenden Parameter diskutiert.

4.1 Modellierungsansatz

Die Idee zur Modellierung von Fahrmanövern in typischen Autobahnverkehrsszenarien basiert auf sogenannten Objekt-Objekt-Beziehungen [84], [85], [86]. Ein Objekt kann dabei eine Fahrbahnbegrenzung (z.B. Spurmarkierung, Leitplanke) oder ein Fahrzeug repräsentieren. Diese Betrachtung ermöglicht objektorientierte Modellierung von Fahrmanövern (z.B. Spurwechsel, Spurfolgen, Objektfolgen) auf mehreren Fahrspuren mit Bayes-Netzen.

Zur qualitativen Beschreibung der Bewegung eines Fahrzeuges in einer Spur werden *Bewegungsklassen* $\in \{L, R, F\}$ eingeführt. Ein Fahrzeug kann dabei die

Spur nach rechts (Klasse R), links (Klasse L) verlassen oder einfach einer Spur folgen (Klasse F). Dies ist schematisch in Abbildung 4.1 a) dargestellt.

Im nächsten Schritt werden jeweils zwei Fahrzeuge zusammen betrachtet. Durch die Permutation der *Bewegungsklassen* in einer solchen Beziehung entstehen neun Möglichkeiten der relativen Bewegung der Fahrzeuge zueinander. Diese werden als *Beziehungsklassen* $\in \{LL, \dots, FF\}$ bezeichnet (Abb. 4.1, b).

Durch die zusätzliche Information über die Position des Bezugsfahrzeuges in der Spur ($Pos^p, p \in \{links, rechts, voraus\}$) entstehen daraus dann 27 mögliche Fahrmanöver (Abb. 4.1, c).

Ein Einscherer ist nur einer von vielen Fahrmanövern und kann folgendermaßen definiert werden: *Fahrzeug 1 folgt der Spur (F), Fahrzeug 2 befindet sich auf der linken Spur (Pos^{links}) und führt ein Spurwechselmanöver nach rechts durch (R).*

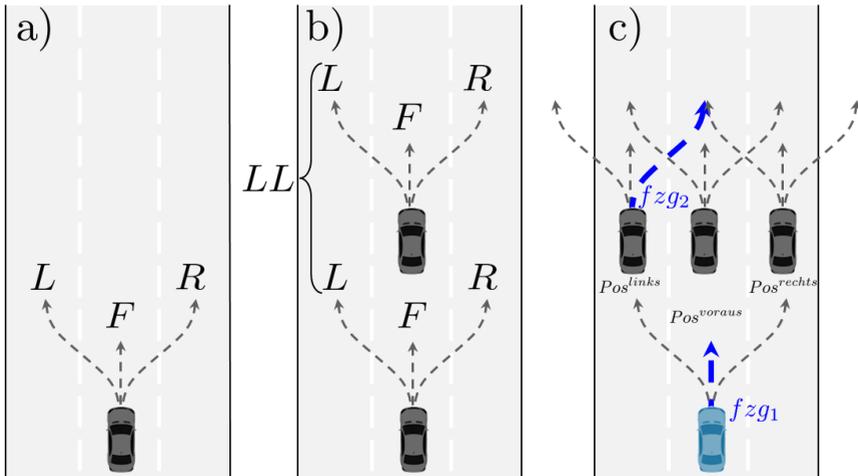


Abbildung 4.1: a) Bewegungsklassen (L, F, R) pro Fahrzeug. b) Beziehungsklassen (LL, \dots, FF) in einer Fahrzeug-Fahrzeug-Beziehung. c) Fahrmanöver in einer Fahrzeug-Fahrzeug-Beziehung mit den Positionsklassen (Pos^p). Ein Einscher-Manöver ist in einer $fzg_1 - fzg_2$ Beziehung mit einem fetten Pfeil markiert.

4.1.1 Schichtenmodell

Zur Modellierung von Fahrmanövern wird der in Kapitel 2 beschriebene Ansatz der objektorientierten Bayes-Netze verwendet. Das Bayes-Netz-Modell ist hierarchisch aufgebaut und besteht aus den vier Abstraktionsebenen. Diese sind in Abbildung 4.2 dargestellt. Die Objekte und deren Beziehungen werden auf diesen Ebenen diskutiert.

Die unterste Schicht stellt ein Modell zur Behandlung der Sensordaten dar. Dazu gehören die Berücksichtigung der Messunsicherheiten und Diskretisierung der Messsignale.

Das Verhalten eines Fahrzeuges relativ zu einer Spurmarkierung wird in der nächst höheren Ebene als eine abstrahierte *Fahrzeug-Spurmarkierung-Beziehung* modelliert. Um dieses Verhalten zu beschreiben, werden verschiedene Situationsmerkmale definiert, die aus Sensordaten berechnet und als Evidenzen in das Bayes-Netz eingefügt werden.

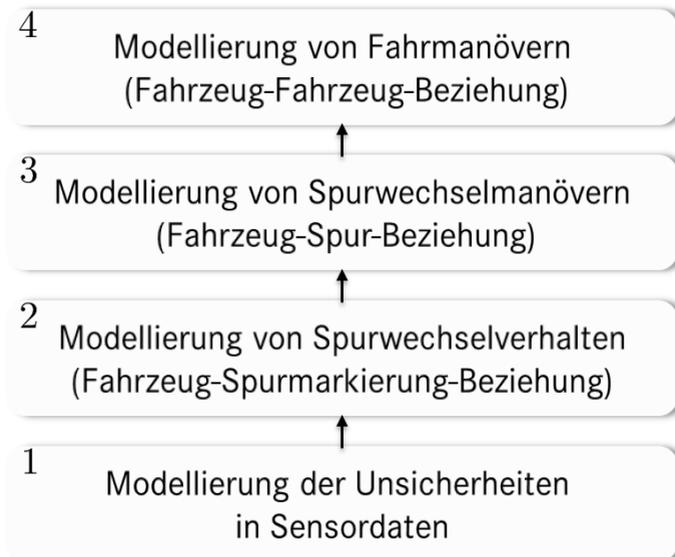


Abbildung 4.2: Hierarchischer Aufbau des objektorientierten Bayes-Netz-Modells zur Erkennung von Fahrmanövern

Die Modellierung einer *Fahrzeug-Spur-Beziehung* wird von der dritten Abstraktionsebene übernommen. Aus der *Fahrzeug-Spur-Beziehung* ergeben sich drei unterschiedliche Spurwechsellmöglichkeiten pro Fahrzeug (*Bewegungsklassen*, Abb. 4.1, a).

In der obersten und vierten Ebene werden zusätzlich alle möglichen *Fahrzeug-Fahrzeug-Beziehungen* paarweise betrachtet (*Beziehungsklassen*, Abb. 4.1, b). Durch die zusätzliche Information über die Position des Bezugsfahrzeuges in der Spur ergeben sich insgesamt in einer *Fahrzeug-Fahrzeug-Beziehung* 27 durchführbare Fahrmanöver, die vom Bayes-Netz modelliert und erkannt werden (Abb. 4.1, c).

Der Unterschied zwischen der dritten und der vierten Abstraktionsebene liegt in der Betrachtungsweise der auf diesen Ebenen aufgestellten Hypothesen. Auf der dritten Ebene wird eine Hypothese über einen Spurwechsel pro Fahrzeug aufgestellt. Auf der vierten Ebene wird diese dann in einer Fahrzeug-Fahrzeug-Beziehung, also für zwei Fahrzeuge, betrachtet. Das Verhalten eines Fahrzeuges in der Spur (Beschreibung von Situationsmerkmalen, die auf einen Spurwechsel hindeuten) wird dementsprechend auf der zweiten Abstraktionsebene modelliert.

4.2 Merkmalsextraktion

Die wesentliche Grundlage zur Erkennung von Fahrmanövern ist die Beobachtung und Auswertung von charakteristischen Situationsmerkmalen, die als Evidenzen in das Bayes-Netz einfließen. Hierzu müssen solche Merkmale definiert und modelliert werden. Wie bereits in Kapitel 4.1 beschrieben, basiert die Idee zur Erkennung von Fahrmanövern auf der qualitativen Beschreibung der Bewegung eines Fahrzeuges in der Spur (*Bewegungsklassen*). Im Idealfall soll die Trennung der *Bewegungsklassen* durch die Situationsmerkmale eindeutig sein. Dies ist in der Realität nicht immer möglich. Aus diesem Grund spielt die Auswahl der Merkmale bei allen Klassifikationsaufgaben eine wichtige Rolle. Dieser Schritt muss sehr sorgfältig durchgeführt werden und ist daher zeitaufwendig.

4.2.1 Koordinatensysteme

Da auf Autobahnen Kurven oder Verengungen berücksichtigt werden müssen, findet in dieser Arbeit die Berechnung der Situationsmerkmale in krummlinigen Spurkoordinatensystemen statt. Abbildung 4.3 zeigt die gleiche Fahr situation in verschiedenen Koordinatensystemen. Führt ein Objekt z.B. in einer Rechtskurve, so führt dieses in dem Ego-Koordinatensystem eine Bewegung nach rechts durch. Die gemessene y -Koordinate zu verschiedenen Zeitpunkten wird größer (Abb. 4.3,

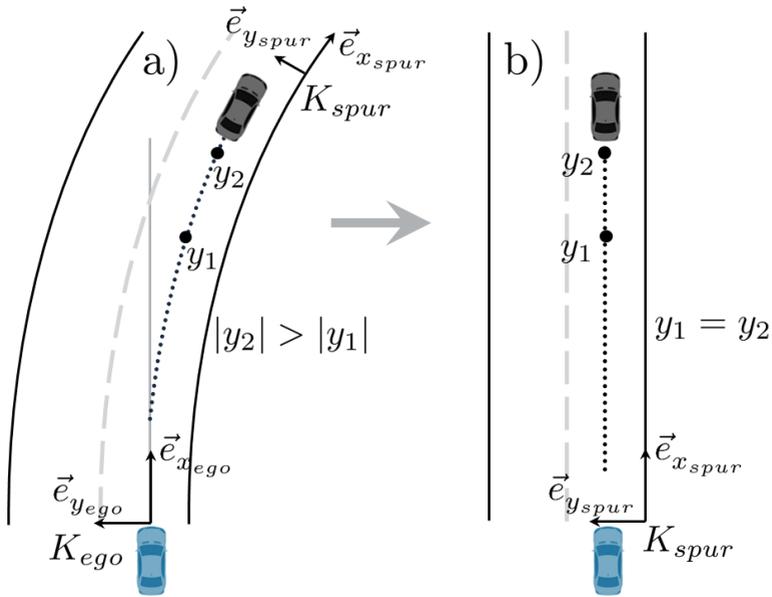


Abbildung 4.3: a) Situation in dem Ego-Koordinatensystem. b) Situation in dem krummlinigen Spurkoordinatensystem.

a). Dieses Koordinatensystem eignet sich nicht zur Beschreibung der Bewegung eines Objektes in der Spur.

Um unterscheiden zu können, ob ein Objekt der Spur folgt oder tatsächlich ein Spurwechselmanöver durchführt, wird dessen Bewegung in ein krummliniges Spurkoordinatensystem transformiert (Abb. 4.3, b).

Die Transformation kann mit Hilfe von Frenet-Serret-Formeln durchgeführt werden [87], [88]. Dabei wird zu jedem Punkt auf einer Kurve $\vec{r}(s)$ ein Tangentenvektor \mathbf{T} , Hauptnormalenvektor \mathbf{N} und Binormalenvektor \mathbf{B} bestimmt. Diese drei Vektoren spannen ein neues Koordinatensystem auf, in welchem der Zustand eines Objektes beschrieben wird (Anhang A).

Bei geradem Straßenverlauf wird ein Spurwechsel nach links oder rechts als symmetrisch angenommen. Um diese Symmetriebetrachtung im allgemeinen Fall zu ermöglichen, werden für alle n beobachtbaren Objekte Obj_1, \dots, Obj_n symmetri-

sche, krummlinige Spurkoordinatensysteme

$$K_{spur}^{s,i}, \quad s \in \{l, r\}, \quad i \in \{Obj_1, \dots, Obj_n\}$$

zur linken (l) und rechten (r) Spurmarkierung (bzw. Fahrbahnbegrenzung) eingeführt (Abb. 4.4, a). Die Situationsmerkmale werden sowohl für das linke als auch das rechte Spurkoordinatensystem berechnet. Durch die Symmetriebetrachtung wird das gleiche Verhalten der Situationsmerkmale in diesen symmetrischen Spurkoordinatensystemen erreicht. Dies vereinfacht die Berechnung der Merkmale und die Modellierung der Bayes-Netz-Struktur.

4.2.2 Situationsmerkmale

Um ein Spurwechselverhalten zu modellieren, werden Situationsmerkmale benötigt, die auf den Spurwechsel hindeuten. Geeignete charakteristische Situationsmerkmale zur Erkennung von Spurwechselmanövern wurden bereits in früheren Arbeiten publiziert [5], [6], [7], [8]. Der hier vorgestellte Ansatz stellt eine Erweiterung dieser Arbeiten dar. Zusammengefasst betrifft dies im Einzelnen die Modellierung:

- von Objekt-Objekt-Beziehungen,
- der Situationsmerkmale für das linke und rechte symmetrische Spurkoordinatensystem, und
- eines neu eingeführten Belegungszeitgitters zur zeitlichen Freiraumanalyse.

Die neu definierten Situationsmerkmale werden in dieser Arbeit für alle beobachtbaren Fahrzeuge und erkannten Fahrbahnbegrenzungen berechnet (Abb. 4.4, a).

Für die Erkennung von Fahrmanövern werden auf den bereits vorgestellten Abstraktionsebenen verschiedene Hypothesen aufgestellt und durch die definierten Situationsmerkmale beschrieben (Abb. 4.2). Dabei wird nach Grundhypothesen und abgeleiteten Hypothesen unterschieden. Die Grundhypothesen werden direkt anhand von definierten Situationsmerkmalen aufgestellt. Die abgeleiteten Hypothesen setzen sich aus den Grundhypothesen zusammen.

Auf der ersten Ebene wird ein allgemeingültiges Modell zur Behandlung von Messunsicherheiten aufgestellt (s. Kap. 4.3.1).

Auf der zweiten Ebene wird ein Spurwechselverhalten in einer *Fahrzeug-Spurmarkierung-Beziehung* modelliert (Abb. 4.2). Dazu wird die Hypothese *Überschreitung einer Spurmarkierung* (**ÜSPM-H**, Kap. 4.3.3.1) aufgestellt. Diese setzt sich aus den Grundhypothesen

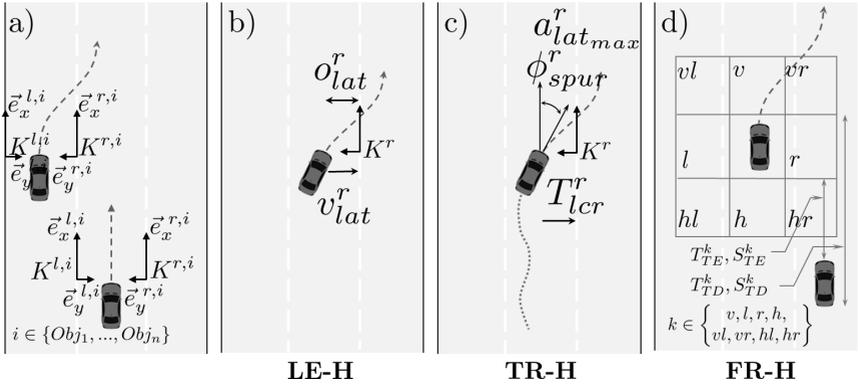


Abbildung 4.4: a) Symmetrisches Spurkoordinatensystem pro Fahrzeug. b,c) Situationsmerkmale zur Beschreibung eines Spurwechselverhaltens. d) Belegungszeitgitter zur Beschreibung einer Spurwechsellmöglichkeit.

- Laterale Evidenz (**LE-H**),
- Trajektorie (**TR-H**) und
- Freiraum (**FR-H**) zusammen.

Im Folgenden werden die Situationsmerkmale zum Aufstellen der Grundhypothesen vorgestellt.

Die **LE**-Hypothese wird durch die Merkmale

- laterale Geschwindigkeit v_{lat}^s und
- Spurversatz o_{lat}^s modelliert (Abb. 4.4, b).

Zum Aufstellen der **TR**-Hypothese werden Merkmale

- die Zeit bis zur Überquerung einer Spurmarkierung T_{lcr}^s ,
- die maximal ausgenutzte laterale Beschleunigung $a_{lat_{max}}^s$ sowie
- der Kurswinkel relativ zum Spurverlauf ϕ_{spur}^s definiert (Abb. 4.4, c).

Die beiden **LE**-, **TR**-Hypothesen beschreiben das Spurwechselverhalten eines Fahrzeuges zu einer Spurmarkierung. Eine detaillierte Berechnung dieser Situationsmerkmale wird in Kapiteln 4.2.2.1 und 4.2.2.2 vorgestellt. Die entsprechenden Bayes-Netz-Modelle werden in Kapiteln 4.3.2.1 und 4.3.2.2 beschrieben.

Die **FR**-Hypothese überprüft, ob ein Spurwechselmanöver möglich ist oder z.B. durch eine Bebauung, andere Verkehrsteilnehmer nicht durchgeführt werden kann. Zur Beschreibung dieser Hypothese wird ein sogenanntes Belegungszeitgitter eingeführt. Hier werden nicht die klassischen Belegungsgitter, die aus der Robotik bekannt sind, verwendet [89]. Das Gitter ist einem Fahrzeug fest zugeordnet und bewegt sich mit diesem mit. Hierbei werden die Zellen nicht binär als *belegt* oder *nicht belegt* markiert, sondern beinhalten die Zeitinformation, wann die Zelle belegt oder freigegeben wird. Um dies zu berechnen, werden folgende Merkmale eingeführt (Abb. 4.4, d):

- die Zeit T_{TE}^k , $k \in \{l, v, r, h, vl, vr, hl, hr\}$, die ein Fahrzeug bis zum Eintritt in die Zelle k braucht (engl. *TimeToEnter*),
- die Zeit T_{TD}^k , die ein Fahrzeug bis zum Austritt aus der Zelle k braucht (engl. *TimeToDisappear*), sowie
- die entsprechenden Abstände eines Objektes S_{TE}^k, S_{TD}^k bis zum Eintritt in bzw. Austritt aus der Zelle k .

Das Bayes-Netz-Modell der **FR**-Hypothese wird in Kapitel 4.3.2.3 vorgestellt. Die Berechnung der entsprechenden Situationsmerkmale wird in Kapitel 4.2.2.3 beschrieben.

Mit der **ÜSPM**-Hypothese kann nur festgestellt werden ob ein Fahrzeug entweder die linke oder die rechte Spurmarkierung überquert. Die Modellierung dieser Hypothese wird in Kapitel 4.3.3.1 beschrieben.

Wie bereits in Kapitel 4.1 vorgestellt, wird zur Erkennung von Fahrmanövern zusätzlich die Position (Pos^p) des Fahrzeuges in der Spur benötigt. Die Berechnung der Position eines Fahrzeuges wird in Kapitel 4.2.2.4 beschrieben.

Der neu definierte Merkmalsvektor F beinhaltet alle definierten Situationsmerkmale zur Beschreibung eines Spurwechselmanövers und ist wie folgt definiert:

$$F^{s,i,k,p} = \left(o_{lat}^{s,i}, v_{lat}^{s,i}, a_{lat_{max}}^{s,i}, \phi_{spur}^{s,i}, T_{lcr}^{s,i}, Pos^{p,i}, T_{TE}^{k,i}, S_{TE}^{k,i}, T_{TD}^{k,i}, S_{TD}^{k,i} \right)^T, \quad (4.1)$$

wobei die Indizes $s \in \{l, r\}$ das linke und rechte Spurkoordinatensystem, $i \in \{Fzg_1, \dots, Fzg_n\}$ das betrachtete Fahrzeug, $k \in \{l, v, r, h, vl, vr, hl, hr\}$ die einzelne Gitterzelle und $p \in \{links, rechts, voraus\}$ die Position des Bezugsfahrzeuges

beschreiben. Der Merkmalsvektor der gesamten beobachteten Verkehrssituation hat demnach die Dimension $n \cdot 45$. Hierfür wird vorausgesetzt, dass der Fahrzeugzustand aller betrachteten Fahrzeuge sowie der Spurverlauf von den Sensoren erfasst werden und damit bekannt sind.

Im Folgenden werden die abgeleiteten Hypothesen vorgestellt, die zur Erkennung von Fahrmanövern aufgestellt werden.

Auf der dritten Ebene wird ein Spurwechselmanöver in einer *Fahrzeug-Spur-Beziehung* modelliert (Abb. 4.2). Dazu wird die Hypothese *Überschreitung einer Spurmarkierung* sowohl für die linke als auch die rechte Spurmarkierung pro Fahrzeug aufgestellt. Die beiden Hypothesen bilden die Hypothese *Spurwechsel (SW-H)*. Auf dieser Ebene können die bereits vorgestellten *Bewegungsklassen* klassifiziert werden (s. Kap. 4.1). Ein Fahrzeug kann dabei die Spur nach links oder nach rechts verlassen. Sind die beiden Hypothesen falsch so folgt das Fahrzeug der Spur. Die Modellierung der *Spurwechsel*-Hypothese wird in Kapitel 4.3.3.2 vorgestellt.

Auf der vierten Ebene werden die Fahrmanöver in einer *Fahrzeug-Fahrzeug-Beziehung* modelliert (Abb. 4.2). Dazu wird die Hypothese *Fahrmanöver (FM-H)* aufgestellt. Die *Fahrmanöver*-Hypothese setzt sich aus den pro Fahrzeug aufgestellten *Spurwechsel*-Hypothesen zusammen. Daraus können die bereits vorgestellten *Beziehungsklassen* klassifiziert werden (s. Kap. 4.1). Durch die zusätzliche Information über die Position (Pos^p) des Bezugsfahrzeuges in der Spur werden die endgültigen Fahrmanöver prognostiziert. Die Modellierung der *Fahrmanöver*-Hypothese wird in Kapitel 4.3.3.3 beschrieben.

Die Berechnung der Situationsmerkmale der Grundhypothesen wird in den nächsten Kapiteln im Detail vorgestellt (Gl. 4.1).

4.2.2.1 Merkmale der Hypothese *Laterale Evidenz*

Grundlage für die Berechnung der Merkmale v_{lat}, o_{lat} der **LE**-Hypothese stellt ein Spurverlaufs-Modell dar (Abb. 4.4, b). Ein Straßenverlauf besteht grundsätzlich aus drei Segmenten: einem Geraden-Segment mit einem Radius $R = \infty$, einem Kreis-Segment mit einem konstanten Radius $R = konst$ und einem Klothoiden-Segment mit $R \neq konst$. Klothoiden bilden den Übergang zwischen einem Geraden- und einem Kreis-Segment. Dadurch erreicht man eine ruckfreie Fahrdynamik und ermöglicht somit eine gleichmäßige Lenkbewegung am Lenkrad [90], [91], [92]. Dieses Straßenmodell bildet die Grundlage für viele optischen Spurerkennungsalgorithmen. Da die Modellierung mit Klothoiden zu schwer lösbaren Integralen führt, werden die Klothoiden-Parameter durch eine Taylor-Reihenentwicklung angenähert. Dies führt zu einem vereinfachten Spurverlaufs-

Modell und wird vereinfacht durch ein Polynom 3. Ordnung beschrieben [93].

$$y_{spur}(x) = \frac{1}{2} \cdot c_0 \cdot x^2 + \frac{1}{6} \cdot c_1 \cdot x^3 \quad (4.2)$$

Das Spurverlaufs-Modell wird zur Berechnung der lateralen Geschwindigkeit v_{lat} eines Fahrzeuges in der Spur und des Spurversatzes o_{lat} verwendet. Zur Berechnung dieser Merkmale werden die Objekt- und die Spurdaten benötigt. Die Objektdaten werden im Ego-Koordinatensystem zur Verfügung gestellt. Die optischen Spurerkennungsalgorithmen liefern die Spurparameter im Koordinatensystem K_1 (Abb. 4.5). Dieses Koordinatensystem ist tangential zur Spurtangente ausgerichtet. Es sind folgende Spurparameter bekannt:

- c_0, c_1 - Krümmung und Krümmungsänderung
- dy_{spur} - lateraler Abstand zur Spurmarkierung
- ϕ_{spur} - Spurwinkelfehler

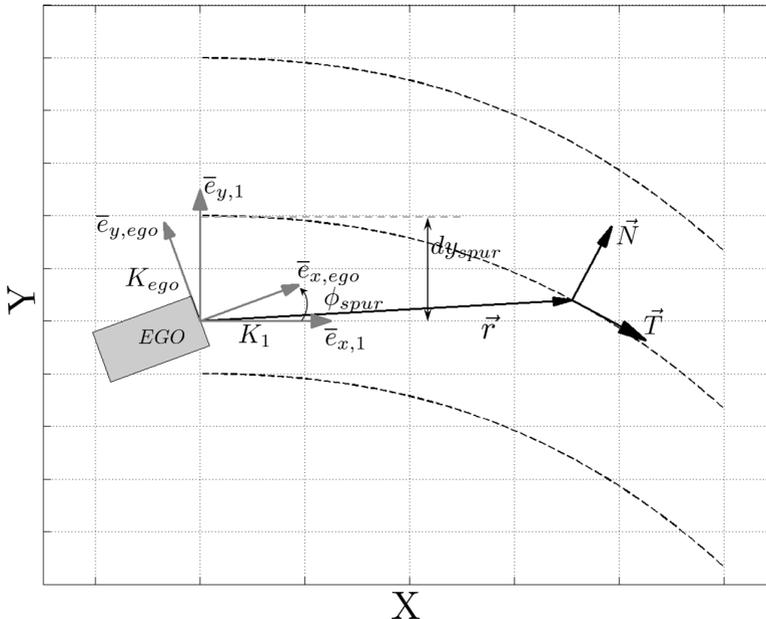


Abbildung 4.5: Spurverlaufs-Modell

Abbildung 4.5 stellt schematisch die definierten Koordinatensysteme K_1, K_{ego} und die Spurparameter dar. Der Vektor \mathbf{N} ist der Normalenvektor und der Vektor \mathbf{T} ist der Tangentenvektor auf der von Vektor \vec{r} beschriebenen Funktion. Diese sind im Koordinatensystem K_1 definiert. In vektorieller Schreibweise kann der Verlauf einer Spurmarkierung in folgender Form angegeben werden:

$$\begin{aligned}\vec{r}_{K_1}(x) &= (f_{sv}(x), g_{sv}(x))^T \\ f_{sv}(x) &= x \\ g_{sv}(x) &= dy_{spur} + \frac{1}{2} \cdot c_0 \cdot x^2 + \frac{1}{6} \cdot c_1 \cdot x^3\end{aligned}\quad (4.3)$$

Somit beschreibt der Vektor $\vec{r}_{K_1}(x)$ den Verlauf jeder Spurmarkierung in einem Abstand dy_{spur} . Der Tangentenvektor \mathbf{T} im Koordinatensystem K_1 ergibt sich aus

$$\begin{aligned}\mathbf{T}_{K_1} &= \frac{\vec{r}'}{\|\vec{r}'\|} = \\ &\left(\frac{1}{\sqrt{1 + (c_0 \cdot x + \frac{1}{2} \cdot c_1 \cdot x^2)^2}}, \frac{c_0 \cdot x + \frac{1}{2} \cdot c_1 \cdot x^2}{\sqrt{1 + (c_0 \cdot x + \frac{1}{2} \cdot c_1 \cdot x^2)^2}} \right)^T\end{aligned}\quad (4.4)$$

und demzufolge ist

$$\begin{aligned}\mathbf{N}_{K_1} &= \\ &\left(\frac{-c_0 \cdot x - \frac{1}{2} \cdot c_1 \cdot x^2}{\sqrt{1 + (c_0 \cdot x + \frac{1}{2} \cdot c_1 \cdot x^2)^2}}, \frac{1}{\sqrt{1 + (c_0 \cdot x + \frac{1}{2} \cdot c_1 \cdot x^2)^2}} \right)^T\end{aligned}\quad (4.5)$$

der Normalenvektor. Im zweidimensionalen Fall lässt sich der Vektor \mathbf{N} durch das Vertauschen der x - und y -Komponenten des Vektors \mathbf{T} darstellen, wobei die x -Komponente einen Vorzeichenwechsel erfährt.

Abbildung 4.6 stellt beispielhaft die notwendigen Größen zur Berechnung des lateralen Spurversatzes und der lateralen Geschwindigkeit eines Objektes in der Spur dar. Das rechte Spurkoordinatensystem K_{spur}^r ist aus der Sicht des im Beispiel dargestellten Objektes durch die Vektoren \mathbf{T} und \mathbf{N} aufgespannt. Die Koordinaten des Objektes in diesem Koordinatensystem K_{spur}^r sind demnach $\vec{P}_{objK_{spur}^r} = (0, y_{\perp})_{K_{spur}^r}^T$. Um den lateralen Spurversatz des Objektes zur Spurmarkierung zu bestimmen, muss folgendes Gleichungssystem gelöst werden:

$$\vec{P}_{objK_1} = \vec{r}_{K_1}(x_{\perp}) + y_{\perp} \cdot \mathbf{N}_{K_1}(x_{\perp})\quad (4.6)$$

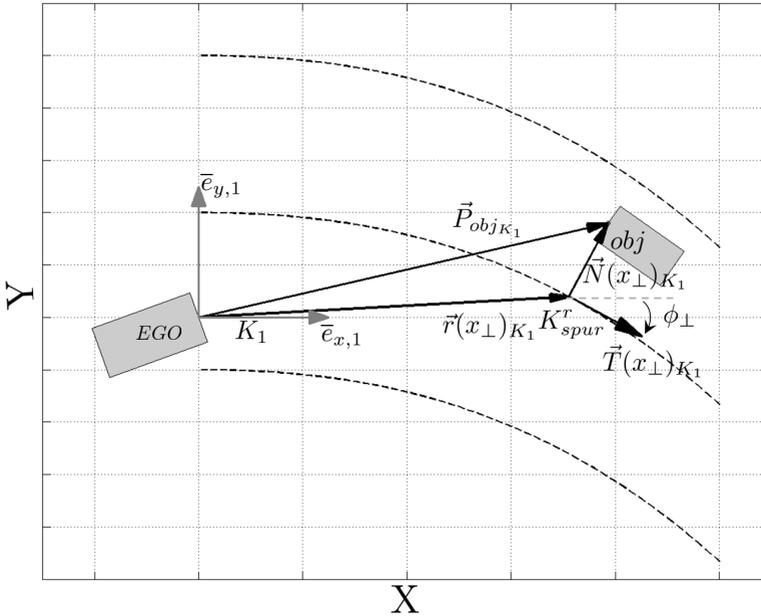


Abbildung 4.6: Berechnung vom lateralen Spurversatz zur Spurmarkierung

Dabei wird nach den Größen $(x_{\perp}, y_{\perp})^T$ gesucht, so dass der Vektor $\vec{P}_{obj_{K_1}}$, also die Position des Objektes, durch die Summe der Vektoren \vec{r} und \vec{N} gebildet wird. Da die Koordinaten des Objektes im Ego-Koordinatensystem K_{ego} gegeben sind, müssen diese noch in das Koordinatensystem K_1 transformiert werden.

$$\vec{P}_{obj_{K_1}} = \mathbf{R}(\phi_{spur}) \cdot \begin{pmatrix} x_{obj} \\ y_{obj} \end{pmatrix}_{K_{ego}} \quad (4.7)$$

Wobei die Matrix

$$\mathbf{R}(\phi_{spur}) = \begin{pmatrix} \cos(\phi_{spur}) & -\sin(\phi_{spur}) \\ \sin(\phi_{spur}) & \cos(\phi_{spur}) \end{pmatrix} \quad (4.8)$$

eine 2D Drehung um den Winkel ϕ_{spur} darstellt. Die Lösung des Gleichungssystems 4.6 liefert die gesuchten Größen $(x_{\perp}, y_{\perp})^T$. Zur Bestimmung des lateralen Spurversatzes des Objektes zur Spurmarkierung, muss der Abstand y_{\perp} um die

halbe Objektbreite B_{obj} korrigiert werden.

$$o_{lat} = y_{\perp} - \frac{1}{2} \cdot B_{obj} \quad (4.9)$$

Die Geschwindigkeit des Objektes wird im Ego-Koordinatensystem K_{ego} gemessen und ist durch den Vektor $\vec{v}_{objK_{ego}} = (v_{x_{obj}}, v_{y_{obj}})_{K_{ego}}^T$ definiert. Um die Geschwindigkeit des Objektes im Spurkoordinatensystem K_{spur}^r zu bestimmen, muss die gemessene Geschwindigkeit $\vec{v}_{objK_{ego}}$ um den Winkel ϕ_{spur} zwischen dem Ego-Fahrzeug und dem Spurkoordinatensystem K_1 minus den Winkel ϕ_{\perp} zwischen dem Spurkoordinatensystem K_1 und dem Tangentenvektor \mathbf{T} korrigiert werden. Die laterale Geschwindigkeit \vec{v}_{lat} des Objektes in der Spur ist demnach folgendermaßen definiert:

$$\begin{aligned} \vec{v}_{lat} &= \mathbf{R}(\phi_{spur} - \phi_{\perp}) \cdot \begin{pmatrix} v_{x_{obj}} \\ v_{y_{obj}} \end{pmatrix}_{K_{ego}} \\ \phi_{\perp} &= \angle \mathbf{T}(x_{\perp}) \end{aligned} \quad (4.10)$$

Das entsprechende Bayes-Netz-Modell der **LE**-Hypothese wird in Kapitel 4.3.2.1 vorgestellt.

4.2.2.2 Merkmale der Hypothese *Trajektorie*

In diesem Kapitel wird die Berechnung der Situationsmerkmale Zeit zur Überschreitung einer Spurmarkierung T_{lcr} , maximal ausgenutzte Querbeschleunigung $a_{lat_{max}}$ und Spurwinkelfehler ϕ_{spur} vorgestellt. Grundlage für die Berechnung dieser Merkmale der **TR**-Hypothese stellt ein Spurwechselmodell dar (Abb. 4.4, c). In der Literatur wird grundsätzlich nach bahn- und trajektorienbasierten Fahrzeugführungen unterschieden [94]. Im Gegensatz zu den bahnbasierten Konzepten, welche keinerlei zeitliche Information zur Planung benutzen, berücksichtigen die trajektorienbasierten Konzepte die Zeitinformation. Da in der vorliegenden Arbeit die Form der Spurwechselbahn von der Geschwindigkeit abhängt (Gl. 4.26), wird hier von einer Spurwechsel-Trajektorie gesprochen. Aus Gründen der Lesbarkeit wird die Funktion der Spurwechsel-Trajektorie mit $y = f_{sw}(x)$ abgekürzt.

Da die Situationsmerkmale T_{lcr} , $a_{lat_{max}}$, ϕ_{spur} nicht direkt messbar sind, müssen diese geschätzt werden. Hierfür wird ein Modell einer Spurwechsel-Trajektorie benötigt. Die Parameter dieses Modells werden aus der Trajektorie-Historie geschätzt. Aus der geschätzten Trajektorie können dann die notwendigen Situationsmerkmale berechnet werden. Die Berechnung erfolgt in bereits vorgestellten

Spurkoordinatensystemen K_{spur}^s . Abbildung 4.7 zeigt ein Modell einer Spurwechsel-Trajektorie, die mit einem Polynom dritter Ordnung modelliert wurde [95].

$$\begin{aligned}
 y = f_{sw}(x) &= a_3 \cdot (x - x_{start})^3 + a_2 \cdot (x - x_{start})^2 & (4.11) \\
 &+ a_1 \cdot (x - x_{start}) + a_0 \\
 x &\in [x_{start}, x_{start} + D]
 \end{aligned}$$

Ein Spurwechselmanöver ist mit diesem Modell nur im Bereich zwischen x_{start} (Anfang der Trajektorie) und $x_{start} + D$ (Ende der Trajektorie) definiert. Die Übergangslänge einer Spurwechsel-Trajektorie wird mit D bezeichnet. Der dabei zu fahrende laterale Versatz $dy = y_{end} - y_{start}$ muss vorgegeben werden (Abb. 4.7). Um die unbekannt Parameter a_0, a_1, a_2, a_3 des Polynoms bestim-

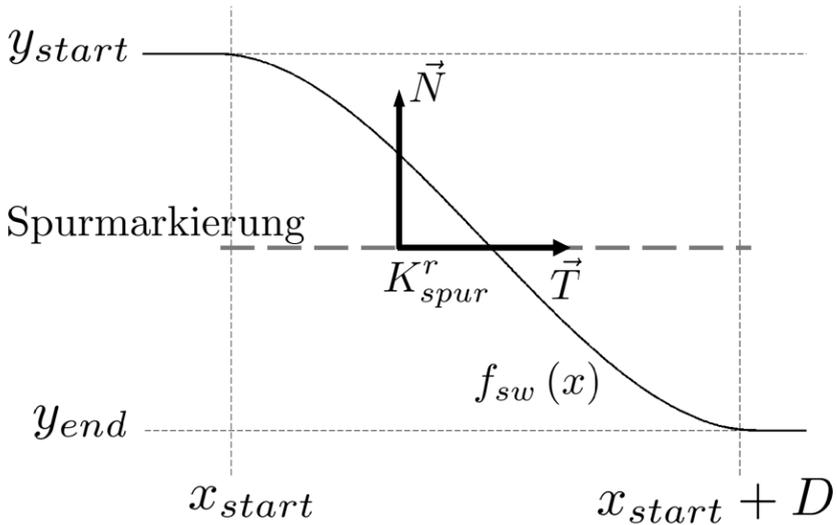


Abbildung 4.7: Modell einer Spurwechsel-Trajektorie

men zu können, werden folgende Bedingungen aufgestellt [95]:

$$f_{sw}(x_{start}) = y_{start} \quad (4.12)$$

$$f_{sw}(x_{start} + D) = y_{end} \quad (4.13)$$

$$\frac{df_{sw}}{dx}(x_{start}) = 0 \quad (4.14)$$

$$\frac{df_{sw}}{dx}(x_{start} + D) = 0 \quad (4.15)$$

Die aufgestellten Bedingungen definieren den y -Offset am Anfang bzw. Ende der Trajektorie. Dieser nimmt entsprechend die Werte y_{start} , y_{end} an. Außerdem wird festgelegt, dass am Anfang bzw. Ende des Manövers die Tangente der Spurmarkierung gleich der Tangente der Spurwechsel-Trajektorie ist. Die Lösung des Gleichungssystem führt zu folgenden Polynom-Parametern:

$$a_0 = y_{start} \quad (4.16)$$

$$a_1 = 0 \quad (4.17)$$

$$a_2 = \frac{3 \cdot (y_{end} - y_{start})}{D^2} \quad (4.18)$$

$$a_3 = \frac{-2 \cdot (y_{end} - y_{start})}{D^3} \quad (4.19)$$

Die einzige Unbekannte in den bestimmten Parametern ist die Übergangslänge D . Um diese berechnen zu können, werden zusätzliche Nebenbedingungen eingeführt [95]. Die folgende Bedingung stellt sicher, dass das Fahrzeug während des gesamten Spurwechselmanövers eine vorgegebene maximale Querbeschleunigung $a_{lat_{max}}$ nicht überschreitet.

$$\frac{d^2 f_{sw}}{dt^2} \leq a_{lat_{max}} \quad (4.20)$$

Die zweite Ableitung der Funktion $f_{sw}(x)$ nach der Zeit liefert:

$$\frac{d^2 f_{sw}}{dt^2} = \ddot{x} \cdot (3a_3 x^2 + 2a_2 x + a_1) + \dot{x}^2 \cdot (6a_3 x + 2a_2) \quad (4.21)$$

Unter der Annahme, dass die Längsgeschwindigkeit $v_{x_{obj}}$ der Fahrzeuggeschwindigkeit v_{obj} entspricht und die Fahrzeuglängsbeschleunigung $a_{x_{obj}}$ vernachlässigt werden kann, gilt [95]:

$$\dot{x} = v_{x_{obj}} \approx v_{obj} \quad (4.22)$$

$$\ddot{x} = a_{x_{obj}} \approx 0 \quad (4.23)$$

Damit kann die Gleichung 4.21 vereinfacht werden:

$$\frac{d^2 f_{sw}}{dt^2} = v_{obj}^2 \cdot (6a_3 x + 2a_2) \quad (4.24)$$

Die Bedingung 4.20 führt zu

$$\left| \frac{d^2 f_{sw}}{dt^2} \right| = \left| \frac{d^2 f_{sw}}{dt^2} (x_{start}) \right| = \left| \frac{d^2 f_{sw}}{dt^2} (x_{start} + D) \right| = \quad (4.25)$$

$$\left| v_{obj}^2 \cdot \frac{6 \cdot (y_{end} - y_{start})}{D^2} \right| \leq a_{lat_{max}}$$

Die Übergangslänge D einer Spurwechsel-Trajektorie berechnet sich nach der Gleichung 4.26.

$$D \geq v_{obj} \cdot \sqrt{\frac{6 \cdot |y_{end} - y_{start}|}{|a_{lat_{max}}|}} \quad (4.26)$$

Da die gesamte Spurwechsel-Trajektorie nur im Bereich zwischen $[x_{start}, x_{start} + D]$ definiert ist, kann für die vollständige Beschreibung der Trajektorie das Gleichungssystem 4.27 angegeben werden [95].

$$y = f_{sw}(x) = \begin{cases} y_{start}, & x < x_{start} \\ a_3 \cdot (x - x_{start})^3 + \\ a_2 \cdot (x - x_{start})^2 + a_0, & x_{start} \leq x \leq x_{start} + D \\ y_{end}, & x > x_{start} + D \end{cases} \quad (4.27)$$

Die Parameter der Trajektorie werden aus der Trajektorien-Historie bestimmt. Abbildung 4.8 zeigt schematisch eine solche Trajektorien-Historie. Diese wird im Koordinatensystem K_{spur}^r , welches durch die Vektoren \mathbf{T} und \mathbf{N} aufgespannt wird, angegeben. Die aktuelle Position des Objektes ist durch den Punkt $P_{obj_{act}} = (0, o_{lat})$ gekennzeichnet.

Zum Aufbau der Trajektorien-Historie werden die letzten N -Positionen (x_i, y_i) , $i \in \{0, \dots, N\}$ der aktuell abgefahrenen Strecke eines Objektes aufgenommen.

$$x_i = x_{i-1} - v_{obj} \cdot \Delta T \quad (4.28)$$

$$y_i = y_{i-1}, \quad i \in \{1, \dots, N\} \quad (4.29)$$

$$x_0 = 0 \quad (4.30)$$

$$y_0 = o_{lat} \quad (4.31)$$

Um die komplette Spurwechsel-Trajektorie zu bestimmen, müssen die Parameter $(x_{start}, y_{start}, y_{end}, a_{lat_{max}})$ geschätzt werden. Da der Parameter y_{end} bekannt ist, wird der zu schätzende Parametervektor folgendermaßen definiert:

$$z = \begin{pmatrix} x_{start} \\ y_{start} \\ a_{lat_{max}} \end{pmatrix} \quad (4.32)$$

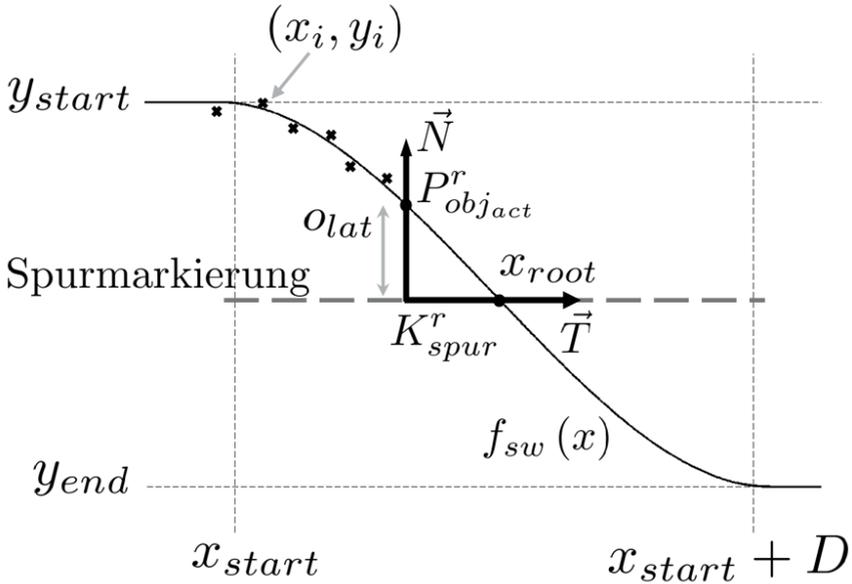


Abbildung 4.8: Schätzung einer Spurwechsel-Trajektorie anhand der Trajektorien-Historie

Die Funktion $\hat{y}_i = f_{sw}(x_i; z)$ beschreibt eine Spurwechsel-Trajektorie, die durch den gegebenen Parametervektor z definiert wird. Unter der Annahme, dass nur die y -Komponenten fehlerbehaftet sind, kann ein Parametervektor z durch Minimierung des quadratischen Fehlers bestimmt werden.

$$\hat{y}_i = f_{sw}(x_i; z) + e_i, \quad i \in \{0, \dots, N\} \quad (4.33)$$

$$z = \arg \min_z \sum_{i=0}^N |f_{sw}(x_i; z) - y_i|^2 \quad (4.34)$$

Zur Schätzung der Parameter wird der Levenberg-Marquardt-Algorithmus verwendet [96], [97], [98], [99].

Das erste Situationsmerkmal $a_{lat,max}$ ist nach Schätzung der Trajektorien-Parameter bekannt. Die definierten Merkmale T_{lcr} und ϕ_{spur} werden von der geschätzten Trajektorie abgeleitet. Der relative Spurwinkelfehler ist durch die erste Ablei-

tion der Funktion $f_{sw}(x)$ an der Stelle P_{object} gegeben.

$$\phi_{spur} = \frac{df_{sw}}{dx}(P_{object}) = \frac{df_{sw}}{dx}(0) \quad (4.35)$$

Die Zeit zur Überschreitung einer Spurmarkierung kann durch die folgende Formel bestimmt werden:

$$T_{lcr} = \frac{x_{start} + x_{root}}{v_{obj}} \quad (4.36)$$

Dabei ist x_{root} der Schnittpunkt der geschätzten Trajektorie mit der Spurmarkierung (Abb. 4.8). Um diesen zu bestimmen, muss die Nullstelle der Spurwechsel-Trajektorie berechnet werden.

$$f_{sw}(x) = a_3x_{root}^3 + a_2x_{root}^2 + a_1x_{root} + a_0 = 0 \quad (4.37)$$

Das entsprechende Bayes-Netz-Modell der **TR**-Hypothese wird in Kapitel 4.3.2.2 vorgestellt.

4.2.2.3 Merkmale der Hypothese *Freiraum*

Die Freiraumanalyse spielt bei der Entwicklung von modernen Fahrerassistenzsystemen eine wichtige Rolle. Die Information über die verfügbaren Handlungsmöglichkeiten kann, je nach Situation, das Verhalten der Systeme beeinflussen. Für die Erkennung von Fahrmanövern ist die Information über die Möglichkeit eines Spurwechsels von Interesse. Diese kann für die Vermeidung von Fehlklassifikationen oder als Information für den Fahrer benutzt werden, falls kein Spurwechselmanöver möglich ist.

Grundlage für die Berechnung der Merkmale $T_{TE,TD}$, $S_{TE,TD}$ der **FR**-Hypothese stellt das neu eingeführte Belegungszeitgitter dar. Das Belegungszeitgitter wird für jeden Verkehrsteilnehmer in der Szene konstruiert und bewegt sich mit diesem mit (Abb. 4.4, d). Jede Zelle besteht dabei aus einem Referenzpunkt (x_{ref}, y_{ref}) , der Zellenlänge l und der Zellenbreite b . Die Zellen können durch Verkehrsteilnehmer oder Randbebauung belegt oder freigegeben werden. Im ersten Schritt werden Objekt-Objekt-Beziehungen zwischen allen Objekten in der Szene aufgebaut. Durch die Position der Objekte in der Spur wird festgelegt, welche Zellen von welchen Objekten belegt werden können. Bei einer Bebauung, links oder rechts von einem Objekt, werden die entsprechende Zellen als belegt markiert.

Das Ziel ist es, eine Beschreibung für eine Möglichkeit eines sicheren Spurwechsels zu finden. Die Idee dabei ist, dass ein Fahrer einen Spurwechsel nur dann durchführt, wenn die Zielspur für eine ausreichend lange Zeit frei ist. Dies wird

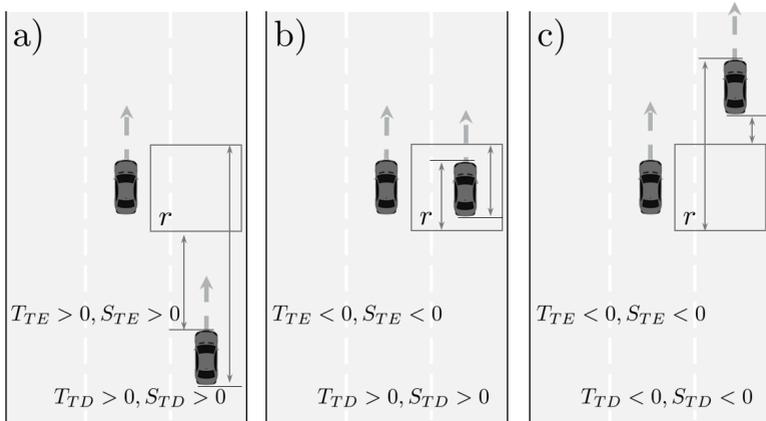


Abbildung 4.9: Modellierung einer Freiraum-Hypothese. a) Fahrzeug nähert sich der Zelle an. b) Fahrzeug befindet sich in der Zelle. c) Fahrzeug entfernt sich von der Zelle.

durch die Zeitreserven für das Eintreten (T_{TE}) bzw. Austreten (T_{TD}) eines Beziehungsobjektes in bzw. aus der Zelle modelliert. Die Belegungszeiten werden aus der Relativgeschwindigkeit v_{rel} , Relativbeschleunigung a_{rel} und den Abständen S_{TE} und S_{TD} der Beziehungsobjekte zu den Zellen berechnet.

$$\frac{1}{2} \cdot a_{rel} \cdot T_{TE,TD}^2 + v_{rel} \cdot T_{TE,TD} - S_{TE,TD} = 0 \quad (4.38)$$

Sind die Beträge der berechneten Zeiten groß genug ($|T_{TE,TD}| > T_{TE,TD}^{min}$), so ist ein Spurwechselmanöver möglich. Diese Zeitreserven sind nur eine hinreichende Bedingung, wenn es darum geht, die Möglichkeit eines sicheren Spurwechselmanövers zu beschreiben. Fährt zum Beispiel ein Objekt kurz vor der betrachteten Zelle mit der gleichen Geschwindigkeit wie das Beziehungsobjekt ($v_{rel} = 0$), dann ist die Zelle zwar frei, da $\left[\lim_{v_{rel} \rightarrow 0, a_{rel} \rightarrow 0} T_{TE} = \infty \right]$, würden jedoch die meisten Fahrer auf ein Spurwechselmanöver verzichten. Ein Spurwechsel in einem solchen Fall wäre nicht im Sinne des kooperativen Fahrens, da es den Fahrer des Beziehungsobjektes in eine riskante Situation versetzt. Demzufolge werden die Abstandsmaße für das Eintreten in (S_{TE}) bzw. Austreten (S_{TD}) aus der Zelle als weitere Merkmale benötigt. Somit ist ein sicheres Spurwechselmanöver nur dann möglich, wenn die Beträge der Zeitreserven und der entsprechenden Abstände

de groß genug sind ($|T_{TE,TD}| > T_{TE,TD}^{min}$, $|S_{TE,TD}| > S_{TE,TD}^{min}$). Bei einer solchen Modellierung ergeben sich insgesamt drei Fälle:

- das Objekt nähert sich der Zelle an, T_{TE} ist positiv (Abb. 4.9, a)
- das Objekt belegt die Zelle, T_{TE} ist negativ und T_{TD} ist positiv (Abb. 4.9, b)
- das Objekt gibt die Zelle frei, T_{TD} ist negativ (Abb. 4.9, c)

An dieser Stelle muss beachtet werden, dass die Situationsmerkmale T_{TE} , S_{TE} , T_{TD} , S_{TD} zu den jeweiligen Zellengrenzen berechnet werden.

Das entsprechende Bayes-Netz-Modell der **FR**-Hypothese wird in Kapitel 4.3.2.3 vorgestellt.

4.2.2.4 Position des Objektes in der Spur

Für die Erkennung der endgültigen Fahrmanöver werden die Positionen der Objekte in der Spur (Pos^p , $p \in \{links, rechts, voraus\}$) benötigt (Abb. 4.1, c). Dazu werden im ersten Schritt aus der Sicht des Ego-Fahrzeuges drei Spuren berechnet ($Spur^{Ego}$, $Spur^{Links}$, $Spur^{Rechts}$). Jede Spur besteht aus einer linken und einer rechten Spurmarkierung. Nach dem bereits in Kapitel 4.2.2.1 vorgestellten Spurverlaufs-Modell können die lateralen Abstände zur linken und rechten Spurmarkierung einer Spur berechnet werden. Sind diese positiv, wird das Objekt dieser Spur zugeordnet. Bei der Überschreitung einer Spurmarkierung muss entschieden werden, wann das Objekt einer neuen Zielspur zugeordnet wird. Befindet sich das betrachtete Objekt zu einem definiertem Abstand in der Zielspur, so wird dieses der neuen Spur zugeordnet.

4.3 Objektorientierte Modellierung von Fahrmanövern mit Bayes-Netzen

Die Grundlage für die Modellierung mit objektorientierten Bayes-Netzen ist die Bildung von generischen Bayes-Netz-Objekten auf verschiedenen Abstraktionsebenen, die wiederverwendet werden können. Die in Kapitel 4.2.2 (Gl. 4.1) vorgestellten Situationsmerkmale bilden die Evidenz-Knoten für das objektorientierte Bayes-Netz. Diese werden zu verschiedenen Grundhypothesen zusammengefasst. Die Grundhypothesen werden als Bayes-Netz-Objekte modelliert. Somit kann das Bayes-Netz hierarchisch in logischen Schichten aufgebaut werden (Abb. 4.2). In den nächsten Kapiteln werden die Bayes-Netz-Objekte der Grundhypothesen sowie die einzelnen Schichten des *OBN*'s vorgestellt.

4.3.1 Modellierung der Unsicherheiten in Sensordaten

Die gemessenen und abgeleiteten Größen eines Signals hängen stark von der Erfassungsgenauigkeit der Sensoren und Sensorrauschen ab. Demnach ist es wichtig, beim Modellieren das Messrauschen eines Sensors zu berücksichtigen. Der Vorteil eines Einsatzes der Bayes-Netze bildet die Möglichkeit der impliziten Berücksichtigung aller Unsicherheiten. Als erstes wird ein Bayes-Netz-Modell zur Behandlung der Unsicherheiten unter Berücksichtigung der Sensorgenauigkeit aufgestellt. Dieses wurde bereits in den Arbeiten von [100] vorgestellt und erfolgreich eingesetzt.

Im Allgemeinen setzt sich das gemessene Signal S_{mess} aus der Überlagerung des realen Wertes und einer Störung zusammen. Der reale Wert eines Signals kann als Erwartung S_{erw} und die Störung als Messfehler S_{err} bezeichnet werden. Somit gilt für das gemessene Signal $S_{mess} = S_{erw} + S_{err}$ [101].

Unter der Annahme, dass die Störung mittelwertfrei und normalverteilt mit der Varianz σ^2 ist, d.h. $S_{err} \sim \mathcal{N}(0, \sigma^2)$, kann die bedingte Wahrscheinlichkeitsverteilung für das gemessene Signal folgendermaßen angegeben werden:

$$p(s_{mess} | s_{erw}, \sigma) = \mathcal{N}(s_{erw}, \sigma^2) \tag{4.39}$$

Abbildung 4.10 zeigt das eingesetzte Modell zur Behandlung der Messunsicherheiten der von einem Sensor gemessenen Daten [100]. Da der reale Wert eines Signals (Knoten *Erwartung*) nicht beobachtet werden kann, wird dessen Wahr-

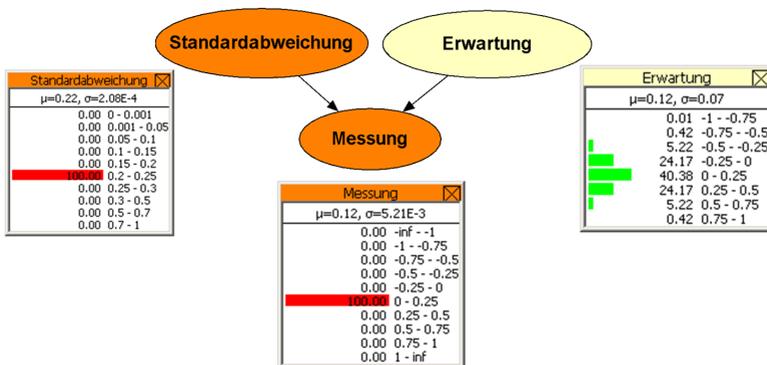


Abbildung 4.10: Modell zur Behandlung der Messunsicherheiten [100]

scheinlichkeitsverteilung durch das Bayes-Netz berechnet (Gleichung 4.39). Dazu muss die *Messung* und deren *Standardabweichung* als Evidenz (rot eingefärbte Knoten) ins Netz eingefügt werden. Da in dieser Arbeit diskrete Bayes-Netze verwendet werden, müssen dementsprechend die gemessenen Signale in einem vordefinierten Bereich diskretisiert werden.

Zur Verdeutlichung wird hier das in Abbildung 4.10 dargestellte Beispiel erläutert. Die Beobachtung beinhaltet zwei Werte, die *Messung* = 0.12 und die entsprechende *Standardabweichung* = 0.22. Die Wahrscheinlichkeit für diese Beobachtung beträgt $p(\text{Messung}) = 1$, $p(\text{Standardabweichung}) = 1$. Durch die vom Bayes-Netz unterstützte diagnostische Inferenz wird die Wahrscheinlichkeitsverteilung des realen Wertes *Erwartung*, nach dem Modell 4.39, berechnet. Diese ist in Tabelle rechts vom Knoten *Erwartung* dargestellt (Abb. 4.10).

Die berechnete Wahrscheinlichkeitsverteilung des realen Wertes (*Erwartung*) wird zur weiteren Inferenz im Bayes-Netz verwendet (Abb. 4.2, Ebene eins).

4.3.2 Modellierung der Grundhypothesen

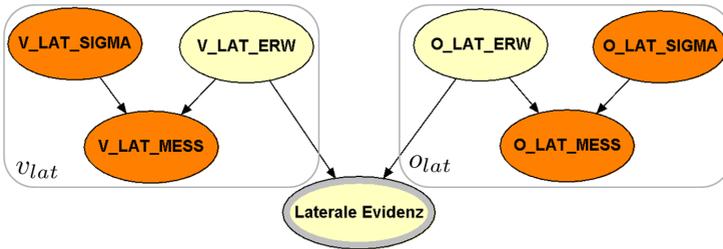
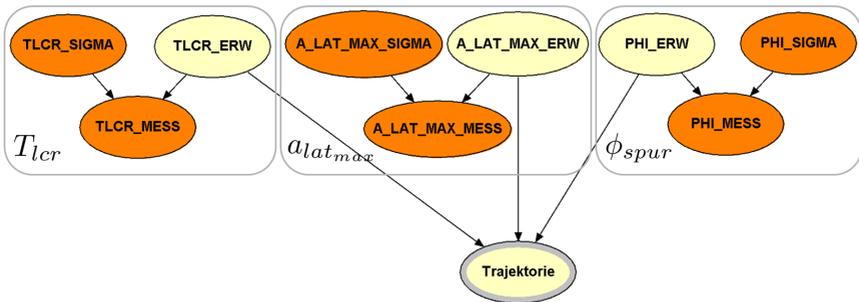
In den folgenden Kapiteln werden die Evidenz-Knoten rot dargestellt. Die Beobachtungen beinhalten die Messung und deren Standardabweichung. Die Wahrscheinlichkeitsverteilung des realen Wertes wird, nach dem bereits in Kapitel 4.3.1 vorgestellten Modell zur Behandlung der Messunsicherheiten, berechnet. Die Situationsmerkmale zur Beschreibung eines Spurwechselmanövers bzw. Spurwechsellmöglichkeit werden als Bayes-Netz-Objekte modelliert. Deren Struktur wird im Folgenden vorgestellt.

4.3.2.1 Modellierung der Hypothese *Laterale Evidenz*

Die Grundhypothese *Laterale Evidenz* (**LE-H**) fasst die Merkmale laterale Geschwindigkeit v_{lat} und lateraler Spurversatz o_{lat} (s. Kap. 4.2.2.1) mit den entsprechenden Standardabweichungen zusammen (Abb. 4.11).

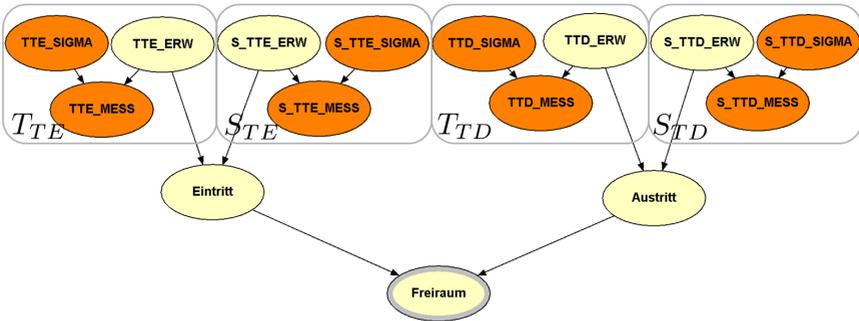
4.3.2.2 Modellierung der Hypothese *Trajektorie*

Die Situationsmerkmale Zeit zur Überschreitung einer Spurmarkierung T_{lcr} , die maximal ausgenutzte Beschleunigung $a_{lat_{max}}$ und relativer Spurwinkelfehler ϕ_{spur} werden im Knoten *Trajektorie* (**TR-H**) zusammengefasst (s. Kap. 4.2.2.2). Das entsprechende Bayes-Netz-Modell ist in Abbildung 4.12 dargestellt.

Abbildung 4.11: Grundhypothese *Laterale Evidenz*Abbildung 4.12: Grundhypothese *Trajektorie*

4.3.2.3 Modellierung der Hypothese *Freiraum*

Um festzustellen, ob ein Spurwechselmanöver durchführbar ist, werden Situationsmerkmale wie die Zeit bis zum Eintritt in bzw. Austritt aus einer Zelle $T_{TE,TD}$, sowie die entsprechenden Abstände $S_{TE,TD}$ benutzt (s. Kap. 4.2.2.3). Der Eintritt in bzw. Austritt aus der Zelle werden durch die Knoten *Eintritt*, *Austritt* modelliert (Abb. 4.13). Diese fassen die entsprechenden Situationsmerkmale zusammen. Der Knoten *Freiraum* (**FR-H**) beschreibt die Wahrscheinlichkeit für die Belegung einer Zelle.

Abbildung 4.13: Grundhypothese *Freiraum*

4.3.3 Modellierung der Fahrmanöver-Hypothesen

4.3.3.1 Modellierung der Hypothese *Überschreitung einer Spurmarkierung*

Um das Spurwechselverhalten und die Spurwechsellmöglichkeit eines Objektes vollständig zu modellieren, werden die bereits vorgestellten Bayes-Netz-Objekte der Grundhypothesen logisch zusammengefasst (Abb. 4.15).

Für die Modellierung des Spurwechselverhaltens eines Objektes zu einer Spurmarkierung werden die Objekte der Grundhypothesen *Laterale Evidenz* und *Trajektorie* verwendet.

Die Möglichkeit für einen sicheren Spurwechsel wird durch die *Freiraum*-Hypothese beschrieben. Diese Instanz reicht für die vollständige Modellierung einer Spurwechsellmöglichkeit nicht aus. Es kann vorkommen, dass während ein Objekt eine Zelle freigibt, ein anderes diese bereits belegt (Abb. 4.14). Um dieses Verhalten zu modellieren, werden zwei Instanzen der *Freiraum*-Hypothese benötigt. Diese bilden die Hypothese *Spurwechsellmöglichkeit*. Ein Spurwechselmanöver ist nur dann möglich, wenn beide *Freiraum*-Hypothesen wahr sind.

Die Bayes-Netz-Objekte der Grundhypothesen bilden eine neue Hypothese *Überschreitung einer Spurmarkierung* (**ÜSPM-H**). Mit dieser kann nur festgestellt werden, ob eines der beobachteten Objekte eine der beiden Spurmarkierungen (links, rechts) überquert (Abb. 4.2, Ebene zwei).

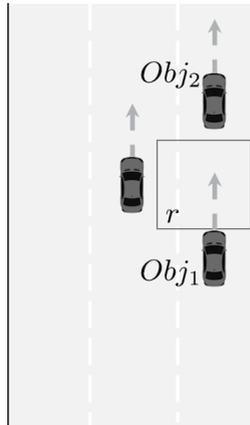


Abbildung 4.14: Fahrsituation, in der die rechte Zelle durch ein Obj_2 freigegeben und gleichzeitig durch ein Obj_1 belegt wird.

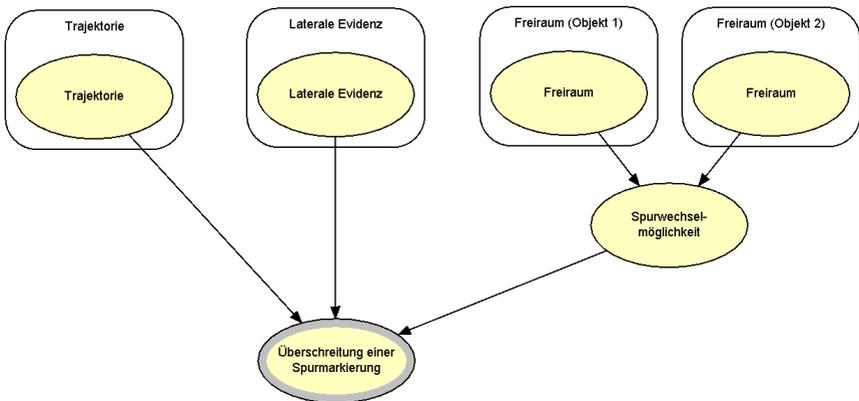


Abbildung 4.15: Hypothese *Überschreitung einer Spurmarkierung*

4.3.3.2 Modellierung der Hypothese *Spurwechsel*

Auf der nächst höheren Ebene wird eine Fahrzeug-Spur-Beziehung modelliert. Wie in den vorherigen Kapiteln bereits erklärt, besteht eine Spur aus der linken und rechten Spurmarkierung. Um das Verhalten eines Objektes in der Spur zu beschreiben, werden zwei Instanzen der Hypothese *Überschreitung einer Spurmarkierung* sowohl für die linke als auch für die rechte Spurmarkierung benötigt. Diese werden zu einer neuen Hypothese *Spurwechsel* zusammengefasst (SW-H, Abb. 4.16).

Die vorgestellten Situationsmerkmale der Grundhypothesen werden sowohl für die linke als auch für die rechte Spurmarkierung berechnet und als Evidenzen in die entsprechenden Instanzen der Hypothese *Überschreitung einer Spurmarkierung* eingefügt (s. Kap. 4.2.2, Gl. 4.1). Auf dieser Ebene ist es somit möglich, die *Bewegungsklassen* eines Objektes zu klassifizieren. Ein Objekt kann dabei die Spur nach links (Klasse *L*) oder nach rechts (Klasse *R*) verlassen. Sind beide der Hypothesen falsch, folgt das Objekt der Spur (Klasse *F*) (Abb. 4.2, Ebene drei).

4.3.3.3 Modellierung der Hypothese *Fahrmanöver*

Auf der letzten Ebene werden die Fahrzeug-Fahrzeug-Beziehungen modelliert. Dazu werden pro Objekt die Instanzen der *Spurwechsel*-Hypothese verwendet (Abb. 4.17). Diese werden zu einer neuen Hypothese *Beziehungsklassen* zusam-

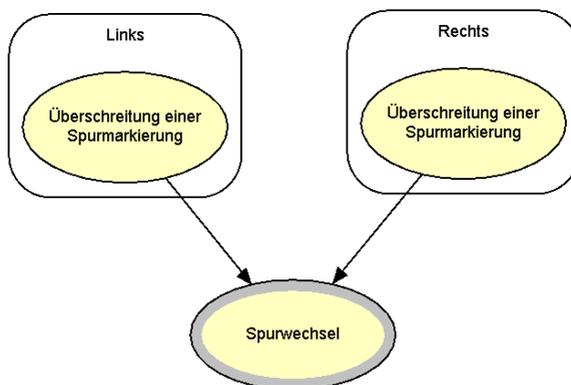


Abbildung 4.16: Hypothese *Spurwechsel*

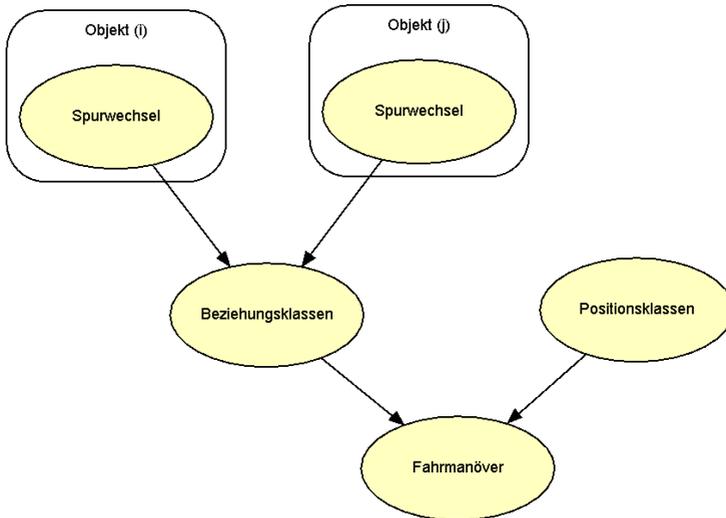


Abbildung 4.17: OOBN für die Modellierung von Fahrmanövern

mengefasst. Die Hypothese *Beziehungsklassen* beschreibt somit die relative Bewegung der Objekte zueinander. Dies entspricht den neun *Beziehungsklassen* (LL, LR, \dots, FF). Der Knoten *Positionsklassen* repräsentiert die möglichen Positionen des Bezugsobjektes in der Spur ($Pos^p, p \in \{links, rechts, voraus\}$).

Aus der Permutation der Zustände der Knoten *Beziehungs-* und *Positionsklassen* ergeben sich 27 mögliche *Fahrmanöver* (**FM-H**), die zwei Objekte in einer Objekt-Objekt-Beziehung durchführen können (Abb. 4.2, Ebene vier).

4.4 Bayes-Netz-Parameter

Die Definition der Bayes-Netz-Struktur ist nur einer der Schritte bei der Modellierung mit Bayes-Netzen. Im zweiten Schritt muss das Bayes-Netz parametrisiert werden. Die Auswahl der Bayes-Netz-Parameter spielt eine sehr wichtige Rolle, da von dem ausgewählten Parametersatz die Erkennungsleistung des Systems abhängt. Um eine möglichst gute Erkennungsleistung zu erreichen, müssen die Parameter so gewählt werden, dass im Falle eines Fahrmanövers die Wahrscheinlichkeit für dieses sehr hoch ist. Eine der Möglichkeiten der Parametrierung des

Bayes-Netzes ist die Anwendung von Lernmethoden. Um eine gute Schätzung und Optimierung der Parameter durchführen zu können, wird eine große Datenmenge benötigt. Für diese Arbeit wurde das Bayes-Netz manuell parametrisiert. In den nächsten Kapiteln werden die Parameter des gesamten Bayes-Netzes vorgestellt.

4.4.1 Parameter der Grundhypothesen

Da in dieser Arbeit diskrete Bayes-Netze verwendet werden, müssen die Eingangsknoten entsprechend diskretisiert werden. Dazu ist es notwendig, den Wertebereich der Evidenz-Variablen zu kennen. Für die Definition eines Wertebereichs der Grundhypothesen wurden während einer Messfahrt die Extremwerte der Situationsmerkmale abgespeichert. Dabei unterscheidet man nach Extremwerten, die während eines Spurwechselmanövers und nach Extremwerten, die nicht während eines Spurwechselmanövers gemessen wurden. Diese sind in Tabelle 4.1 dargestellt.

	Spurwechselmanöver	
	Ja	Nein
$v_{lat}[m/s]$	-1.5	0.5
$o_{lat}[m]$	-1	1
$T_{lcr}[s]$	-1	2
$a_{lat_{max}}[m/s^2]$	1.5	0
$\phi_{spur}[rad]$	-0.05 [2.9°]	0

Tabelle 4.1: Wertebereich der Situationsmerkmale zur Beschreibung eines Spurwechselverhaltens.

Für die Definition eines Wertebereichs der Freiraum-Hypothesen wurden die in Tabelle 4.2 dargestellten Werte definiert. Da die Entscheidung für ein sicheres Spurwechselmanöver vom jeweiligen Fahrer abhängt, ist die Parametrierung dieser Hypothese sehr schwierig. Befindet sich ein Objekt in einem Abstand von $10m$ vor oder hinter der Zelle mit einem gleichzeitigen Zeitabstand von $1s$, so wird angenommen, dass ein sicheres Spurwechselmanöver möglich ist. Dies entspricht einer Relativgeschwindigkeit von $10m/s$.

Die bedingten Wahrscheinlichkeitstabellen der Grundhypothesen werden in dieser Arbeit als Sigmoidfunktionen modelliert [11]. Die Sigmoidfunktionen werden durch die Parameter η , a und b entsprechend dem definierten Wertebereich be-

	Spurwechselfähigkeit	
	Ja	Nein
$T_{TE}[s]$	1	-1
$S_{TE}[m]$	10	-10
$T_{TD}[s]$	-1	1
$S_{TD}[m]$	-10	10

Tabelle 4.2: Wertebereich der Situationsmerkmale zur Beschreibung einer Spurwechselfähigkeit.

geschrieben.

$$P(X = Ja|\mathbf{E}) = \eta \cdot \frac{1}{a + \exp(b \cdot \mathbf{E})}, \quad \forall \mathbf{E} \in \{\mathbf{e}_1, \dots, \mathbf{e}_n\} \quad (4.40)$$

Die η Variable wird zur Normierung der Werte eingesetzt. Die Wahrscheinlichkeit $P(X = Nein|\mathbf{E})$ kann durch die folgende Gleichung berechnet werden.

$$P(X = Nein|\mathbf{E}) = 1 - P(X = Ja|\mathbf{E}) \quad (4.41)$$

In den folgenden Kapiteln werden die gewählten Parameter der Sigmoidfunktionen und die entsprechenden bedingten Wahrscheinlichkeitstabellen des Bayes-Netzes vorgestellt.

4.4.1.1 Parameter der Hypothese *Laterale Evidenz*

Die laterale Geschwindigkeit eines Objektes in der Spur $v_{lat_{erw}}$ und der laterale Spurversatz zur Spurmarkierung $o_{lat_{erw}}$, die durch das bereits vorgestellte Modell zur Behandlung der Unsicherheiten berechnet werden, bilden die diskreten Eingänge des Knotens *Laterale Evidenz* (**LE-H**, Abb. 4.11). Um die bedingte Wahrscheinlichkeit dieses Knotens $P(LE|v_{lat_{erw}}, o_{lat_{erw}})$ anzugeben, wird die Verbundwahrscheinlichkeit $P(v_{lat_{erw}}, o_{lat_{erw}})$ modelliert. Da die Variablen $v_{lat_{erw}}$ und $o_{lat_{erw}}$ als unabhängig angenommen werden, lässt sich die Verbundwahrscheinlichkeit als Produkt zweier unabhängiger Wahrscheinlichkeiten $P(v_{lat_{erw}})$ und $P(o_{lat_{erw}})$ bestimmen. Die einzelnen Wahrscheinlichkeiten werden als Sigmoidfunktionen mit den Parametern $a_{v_{lat}}, b_{v_{lat}}, a_{o_{lat}}, b_{o_{lat}}$ nach Gleichung 4.40 und 4.41 berechnet. Die Parameter der Sigmoidfunktionen entsprechen den Wer-

ten:

$$\begin{aligned}
 P(LE = Ja|v_{laterw}) & : a_{v_{lat}} = 0.1, b_{v_{lat}} = 4.5, \\
 & \forall v_{laterw} \in \{-1.5, \dots, 0.5\} \\
 P(LE = Ja|o_{laterw}) & : a_{o_{lat}} = 0.8, b_{o_{lat}} = 5.0, \\
 & \forall o_{laterw} \in \{-1.0, \dots, 1.0\}
 \end{aligned}$$

Die gesamte bedingte Wahrscheinlichkeitsverteilung (engl. *conditional probability distribution (CPD)*) für die Variable *Laterale Evidenz* kann dann folgendermaßen angegeben werden:

$$\begin{aligned}
 P(LE = Ja|v_{laterw}, o_{laterw}) & = \frac{\eta_1}{a_{v_{lat}} + \exp(b_{v_{lat}} \cdot v_{laterw})} \cdot \\
 & \frac{1}{\eta_2 \frac{1}{a_{o_{lat}} + \exp(b_{o_{lat}} \cdot o_{laterw})}} \\
 P(LE = Nein|v_{laterw}, o_{laterw}) & = 1 - P(LE = Ja|v_{laterw}, o_{laterw}), \\
 & \forall v_{laterw}, o_{laterw}
 \end{aligned}$$

Der Verlauf der Wahrscheinlichkeiten der einzelnen Variablen sowie des Knotens *Laterale Evidenz* ist in Abbildung 4.18 dargestellt.

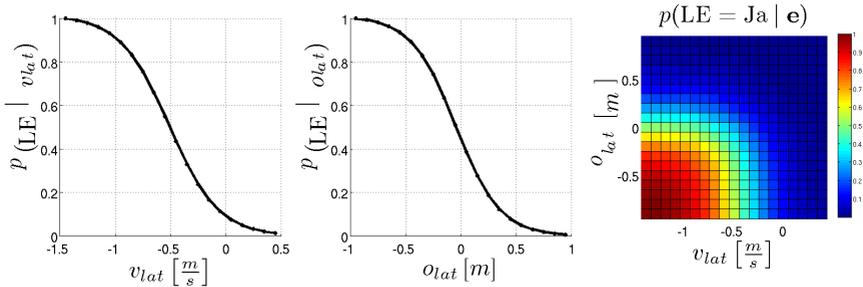


Abbildung 4.18: Parameter des Knotens *Laterale Evidenz*

4.4.1.2 Parameter der Hypothese *Trajektorie*

Die Situationsmerkmale T_{lcrerw} , $a_{latmaxerw}$, $\phi_{spurerw}$ bilden die Eingänge des Knotens *Trajektorie* (**TR-H**, Abb. 4.12). Die Parametrierung wird nach dem gleichen

Prinzip wie bei dem Knoten *Laterale Evidenz* mit den Sigmoidfunktionen durchgeführt. Die Parameter wurden folgendermaßen gewählt:

$$\begin{aligned}
 P(TR = Ja | T_{lcr_{erw}}) &: a_{T_{lcr}} = 18.0, \quad b_{T_{lcr}} = 3.0, \\
 &\quad \forall T_{lcr_{erw}} \in \{-1.0, \dots, 2.0\} \\
 P(TR = Ja | a_{lat_{max_{erw}}}) &: a_{a_{lat}} = 0.05, \quad b_{a_{lat}} = -4.0, \\
 &\quad \forall a_{lat_{max_{erw}}} \in \{0.0, \dots, 1.5\} \\
 P(TR = Ja | \phi_{spur_{erw}}) &: a_{\phi_{spur}} = 0.06, \quad b_{\phi_{spur}} = 130.0, \\
 &\quad \forall \phi_{spur_{erw}} \in \{-0.05, \dots, 0.0\}
 \end{aligned}$$

Abbildung 4.19 zeigt die bedingten Wahrscheinlichkeitsverläufe der einzelnen Variablen sowie des Knotens *Trajektorie*.

Die Hypothesen *Laterale Evidenz* und *Trajektorie* beschreiben das Verhalten eines Fahrzeuges zu einer Spurmarkierung. Sind die Wahrscheinlichkeiten hoch, so bedeutet dies, dass ein Objekt die Spurmarkierung überquert.

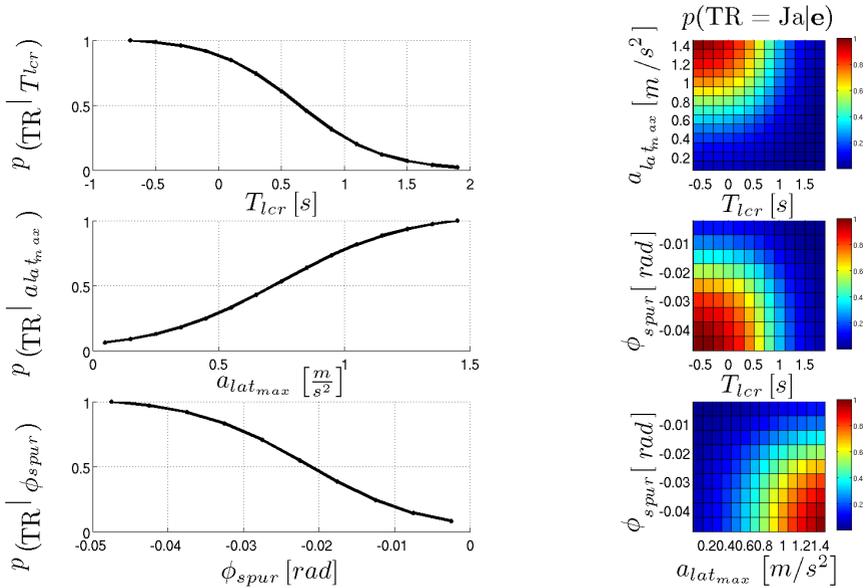


Abbildung 4.19: Parameter des Knotens *Trajektorie*

4.4.1.3 Parameter der Hypothese *Freiraum*

Die Situationsmerkmale $T_{TE_{erw}}, S_{TE_{erw}}$ bilden die Eingänge des Knotens *Eintritt*, sowie die Variablen $T_{TD_{erw}}, S_{TD_{erw}}$ die Eingänge des Knotens *Austritt* (Abb. 4.13). Die Parameter der Sigmoidfunktionen entsprechen den Werten

$$\begin{aligned}
 P(\text{Eintritt} = \text{Ja} | T_{TE_{erw}}) &: a_{T_{TE}} = 0.2, \quad b_{T_{TE}} = -3.0, \\
 &\quad \forall T_{TE_{erw}} \in \{-1, \dots, 1\} \\
 P(\text{Eintritt} = \text{Ja} | S_{TE_{erw}}) &: a_{S_{TE}} = 0.4, \quad b_{S_{TE}} = -0.4, \\
 &\quad \forall S_{TE_{erw}} \in \{-10, \dots, 10\} \\
 P(\text{Austritt} = \text{Ja} | T_{TD_{erw}}) &: a_{T_{TD}} = 0.2, \quad b_{T_{TD}} = 3.0, \\
 &\quad \forall T_{TD_{erw}} \in \{-1, \dots, 1\} \\
 P(\text{Austritt} = \text{Ja} | S_{TD_{erw}}) &: a_{S_{TD}} = 0.4, \quad b_{S_{TD}} = 0.4, \\
 &\quad \forall S_{TD_{erw}} \in \{-10, \dots, 10\}
 \end{aligned}$$

und sind in Abbildung 4.20 dargestellt. Ist die Hypothese *Eintritt* wahr, also $p(\text{Eintritt} = \text{Ja} | \mathbf{E}) = 1$, bedeutet dies, dass ein Objekt sich weit vor der Zelle befindet. Ist die Hypothese *Austritt* wahr, also $p(\text{Austritt} = \text{Ja} | \mathbf{E}) = 1$, bedeutet

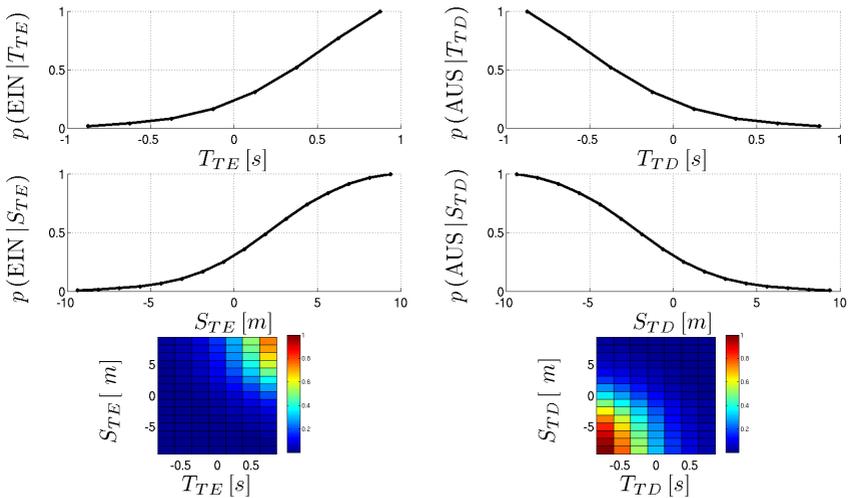


Abbildung 4.20: Parameter der Knoten *Eintritt*, *Austritt*

dies, dass ein Objekt sich weit hinter der Zelle befindet.

Die *Freiraum*-Hypothese setzt sich aus den Hypothesen über den *Eintritt* und *Austritt* zusammen. Diese beschreibt die Wahrscheinlichkeit für ein sicheres Spurwechselmanöver. Ist die Wahrscheinlichkeit hoch, also $p(\text{Freiraum} = \text{Ja} | \mathbf{E}) = 1$, ist ein Spurwechselmanöver möglich.

Die Parameter der *Freiraum*-Hypothese (**FR-H**, Abb. 4.13) sind in Tabelle 4.3 dargestellt. Ein Spurwechselmanöver ist somit nur dann möglich:

- wenn ein Objekt noch nicht in eine der Zellen des Belegungszeitgitters eingetreten ist, also die Wahrscheinlichkeit des Knotens *Eintritt* $p(\text{Eintritt} = \text{Ja} | \mathbf{E}) = 1$, oder
- wenn ein Objekt sich bereits von einer Zelle entfernt, also die Wahrscheinlichkeit des Knotens *Austritt* $p(\text{Austritt} = \text{Ja} | \mathbf{E}) = 1$ (Abb. 4.9 a,c).

Austritt	Nein		Ja	
	Nein	Ja	Nein	Ja
Eintritt				
Freiraum = <i>Nein</i>	1	0	0	0
Freiraum = <i>Ja</i>	0	1	1	1

Tabelle 4.3: Parameter des Knotens *Freiraum*

4.4.2 Parameter der Fahrmanöver-Hypothesen

4.4.2.1 Parameter der Hypothese *Überschreitung einer Spurmarkierung*

Wie in Kapitel 4.3.3.1 vorgestellt, reicht eine Instanz der *Freiraum*-Hypothese für die Modellierung der Möglichkeit eines sicheren Spurwechselmanövers nicht aus. Deswegen werden zwei weitere Instanzen der *Freiraum*-Hypothese eingeführt. Diese werden zu einer neuen Hypothese *Spurwechselmöglichkeit* zusammengefasst (Abb. 4.15). Die Parameter dieser Hypothese sind in Tabelle 4.4 dargestellt. Ein Spurwechselmanöver ist somit nur dann möglich, wenn beide der Instanzen *Freiraum* wahr sind. Dies bedeutet, dass keines der beiden betrachteten Objekte eine der Zellen des Belegungszeitgitters, für welche die Berechnung durchgeführt wird, belegen.

Die Hypothese *Überschreitung einer Spurmarkierung* (**ÜSPM-H**, Abb. 4.15) ist nur dann wahr, wenn die Hypothese *Laterale Evidenz* oder die Hypothese *Trajek-*

Freiraum (Obj_1)	Nein		Ja	
	Nein	Ja	Nein	Ja
Freiraum (Obj_2)				
Spurwechselfähigkeit = <i>Nein</i>	1	1	1	0
Spurwechselfähigkeit = <i>Ja</i>	0	0	0	1

Tabelle 4.4: Parameter des Knotens *Spurwechselfähigkeit*

torie wahr sind. Somit sind diese Hypothesen gleich gewichtet. Gleichzeitig muss auch die Möglichkeit für einen Spurwechsel gegeben sein, also die Hypothese *Spurwechselfähigkeit* auch wahr sein. Die Parameter des Knotens *Überschreitung einer Spurmarkierung* sind in Tabelle 4.5 dargestellt.

Trajektorie	Nein				Ja			
	Nein		Ja		Nein		Ja	
Laterale Evidenz								
Spurwechselfähigkeit	Nein	Ja	Nein	Ja	Nein	Ja	Nein	Ja
Überschr. SprMrk. = <i>Nein</i>	1	1	1	0	1	0	1	0
Überschr. SprMrk. = <i>Ja</i>	0	0	0	1	0	1	0	1

Tabelle 4.5: Parameter des Knotens *Überschreitung einer Spurmarkierung*

4.4.2.2 Parameter der Hypothese *Spurwechsel*

Bei der Modellierung der *Spurwechsel*-Hypothese werden elementare Aktionen, die ein Fahrzeug ausführen kann, betrachtet. Ein Fahrzeug kann in der Spur bleiben (F), die Spur nach links (L) oder nach rechts (R) verlassen. Da die Hypothese *Überschreitung der Spurmarkierung* sowohl für die linke als auch die rechte Spurmarkierung angewandt wird, können drei Bewegungsklassen (L, R, F) pro Objekt im Knoten *Spurwechsel* klassifiziert werden (**SW-H**, Abb. 4.16). Damit ergibt sich die logische Parametrierung des Knotens *Spurwechsel*, die in der Tabelle 4.6 dargestellt ist.

Der Vollständigkeit halber muss der Zustand ($Rechts = Ja \wedge Links = Ja$) der beiden Instanzen der Hypothese *Überschreitung einer Spurmarkierung* ebenfalls im Modell mitberücksichtigt werden. Da in diesem Fall keine Aussage über ein

Überschreitung einer Spurmarkierung (<i>Rechts</i>)	Nein		Ja	
	Nein	Ja	Nein	Ja
Überschreitung einer Spurmarkierung (<i>Links</i>)				
Spurwechsel = L	0	1	0	1/3
Spurwechsel = R	0	0	1	1/3
Spurwechsel = F	1	0	0	1/3

Tabelle 4.6: Parameter des Knotens *Spurwechsel*

Spurwechselmanöver getroffen werden kann, wird diesem Zustand eine gleichförmige Wahrscheinlichkeitsverteilung $Uniform(L, R, F) = (\frac{1}{3}, \frac{1}{3}, \frac{1}{3})$ zugeordnet.

4.4.2.3 Parameter der Hypothese *Fahrmanöver*

Um die relative Bewegung von Objekten zueinander zu beschreiben, werden diese in einer Beziehung betrachtet. Dazu wird jeweils eine Instanz der *Spurwechsel*-Hypothese pro Objekt benötigt (Abb. 4.17). Diese werden zu einer neuen Hypothese *Beziehungsklassen* zusammengefasst. Die Parameter des Knotens *Beziehungsklassen* sind in Tabelle 4.7 vorgestellt. Die erste Bewegungsklasse L , R oder F in den Beziehungsklassen (LL, LR, \dots, FF) bezieht sich auf das erste Objekt, dementsprechend bezieht sich die zweite Bewegungsklasse auf das jeweils betrachtete Objekt.

Spurwechsel Obj_1	L			R			F		
	L	R	F	L	R	F	L	R	F
Spurwechsel Obj_2									
LL	1	0	0	0	0	0	0	0	0
LR	0	1	0	0	0	0	0	0	0
LF	0	0	1	0	0	0	0	0	0
...
FL	0	0	0	0	0	0	1	0	0
FR	0	0	0	0	0	0	0	1	0
FF	0	0	0	0	0	0	0	0	1

Tabelle 4.7: Parameter des Knotens *Beziehungsklassen*

Um die endgültigen Fahrmanöver zu erkennen (**FM-H**, Abb. 4.17), wird zusätzlich die Position des Bezugsobjektes in der Spur mitberücksichtigt. Da die

Position eines Objektes gut bestimmt werden kann, wird diese auch als sichere Evidenz in das Bayes-Netz eingefügt. Ist die Position eines Bezugsobjektes nicht bekannt, so wird den Zuständen des Knotens *Positionsklassen* eine gleichförmige Wahrscheinlichkeitsverteilung zugeordnet ($Uniform(Pos^{links}, Pos^{rechts}, Pos^{voraus}) = (\frac{1}{3}, \frac{1}{3}, \frac{1}{3})$).

Die Hypothesen *Beziehungsklassen* und *Positionsklassen* werden zu einer neuen Hypothese *Fahrmanöver* zusammengefasst. In dieser Arbeit werden nur Beziehungen zwischen dem Ego-Fahrzeug und einem Objekt betrachtet. Die Zustände des Knotens *Fahrmanöver* sind dementsprechend benannt und werden als *Manöverklassen* bezeichnet. Diese sind:

$$\begin{aligned} \text{Manoeverklassen} \in \quad & \{Other, ObjCutIn, EgoCutIn, \\ & ObjCutOut, EgoCutOut, \\ & LaneFollow, ObjFollow\} \end{aligned} \quad (4.42)$$

Im Zustand *Other* werden alle Fahrmanöver zusammengefasst, die nicht von Interesse sind. Tabelle 4.8 zeigt die logische Parametrierung der *Fahrmanöver*-Hypothese. Die Interpretation der Tabelle wird am folgenden Beispiel erklärt.

Das Bezugsobjekt fährt links vom Ego-Fahrzeug (pos^{links}) und folgt gleichzeitig der Spur (Klasse *F*). Wenn das Ego-Fahrzeug einen Spurwechsel nach links durchführt (Klasse *L*, Beziehungsklasse *LF*) bedeutet dies, dass das Ego-Fahrzeug in die Spur des Bezugsobjektes einschert (*EgoCutIn*).

Mit diesem Bayes-Netz-Modell können auch Fahrmanöver zwischen beliebigen Objektpaaren klassifiziert werden. Um dies zu ermöglichen, müssen die berechneten Situationsmerkmale der betrachteten Objektpaare als Evidenzen ins Bayes-Netz eingefügt werden. Damit können auch komplexere Verkehrssituationen analysiert werden, was die Intelligenz in Fahrerassistenzsystemen künftig leisten muss.

Positionsklassen	pos^{links}								
Beziehungsklassen	LL	LR	LF	RL	RR	RF	FL	FR	FF
<i>Other</i>	1	1	0	1	1	1	1	0	0
<i>ObjCutIn</i>	0	0	0	0	0	0	0	1	0
<i>EgoCutIn</i>	0	0	1	0	0	0	0	0	0
<i>ObjCutOut</i>	0	0	0	0	0	0	0	0	0
<i>EgoCutOut</i>	0	0	0	0	0	0	0	0	0
<i>LaneFollow</i>	0	0	0	0	0	0	0	0	1
<i>ObjFollow</i>	0	0	0	0	0	0	0	0	0
Positionsklassen	pos^{voraus}								
Beziehungsklassen	LL	LR	LF	RL	RR	RF	FL	FR	FF
<i>Other</i>	0	1	0	1	0	0	0	0	0
<i>ObjCutIn</i>	0	0	0	0	0	0	0	0	0
<i>EgoCutIn</i>	0	0	0	0	0	0	0	0	0
<i>ObjCutOut</i>	0	0	0	0	0	0	1	1	0
<i>EgoCutOut</i>	0	0	1	0	0	1	0	0	0
<i>LaneFollow</i>	0	0	0	0	0	0	0	0	0
<i>ObjFollow</i>	1	0	0	0	1	0	0	0	1
Positionsklassen	pos^{rechts}								
Beziehungsklassen	LL	LR	LF	RL	RR	RF	FL	FR	FF
<i>Other</i>	1	1	1	1	1	0	0	1	0
<i>ObjCutIn</i>	0	0	0	0	0	0	1	0	0
<i>EgoCutIn</i>	0	0	0	0	0	1	0	0	0
<i>ObjCutOut</i>	0	0	0	0	0	0	0	0	0
<i>EgoCutOut</i>	0	0	0	0	0	0	0	0	0
<i>LaneFollow</i>	0	0	0	0	0	0	0	0	1
<i>ObjFollow</i>	0	0	0	0	0	0	0	0	0

Tabelle 4.8: Parameter des Knotens *Fahrmanöver*

Kapitel 5

Umsetzung im Fahrzeug

Das in dem vorherigen Kapitel vorgestellte Bayes-Netz-Modell zur Erkennung von Fahrmanövern wurde erfolgreich in einem Versuchsträger der Daimler AG umgesetzt und getestet. Die folgenden Kapitel geben einen Überblick über den gesamten Versuchsaufbau. In Kapitel 5.1 wird zunächst die Hardware-Architektur erklärt. Es werden im Einzelnen der eingesetzte Versuchsträger sowie die verwendeten Rechnersysteme und deren Vernetzung vorgestellt. Eine der zahlreichen Aufgaben der Situationsanalyse ist die Beschreibung einer Fahrsituation (auch Szene genannt). Kapitel 5.2 stellt das in dieser Arbeit entwickelte Konzept zur Szenenbeschreibung vor. Unter anderem werden auch die einzelnen Software-Module und deren Implementierungsdetails aufgezeigt.

5.1 Hardware-Architektur

In den folgenden Kapiteln werden die hardware-technische Realisierung sowie die verwendeten Rechner- und Sensorsysteme vorgestellt.

5.1.1 Versuchsträger

Für die Entwicklung und Evaluierung der in dieser Arbeit vorgestellten Algorithmen wurde die Mercedes-Benz E-Klasse (Abb. 5.1) als Versuchsträger eingesetzt. Das Fahrzeug ist mit einem Stereo-Kamerasystem, zwei Radarsystemen, einem Fernbereichs-Radar (ARS30x) und Nahbereichs-Radaren ausgestattet. So-

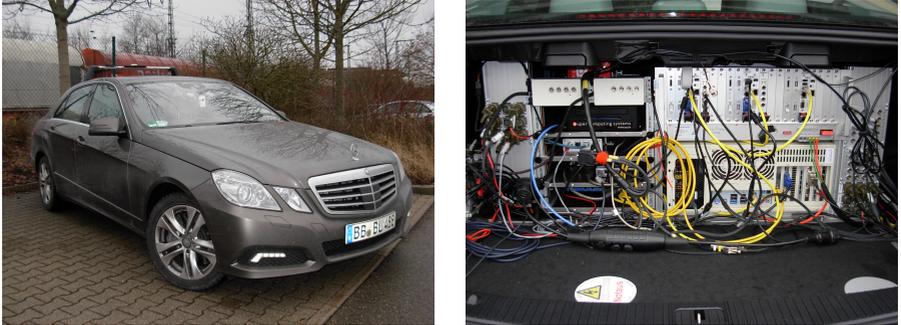


Abbildung 5.1: Links: Mercedes-Benz E-Klasse als Versuchsträger zur Evaluierung des Fahrmanöver-Erkennungsmoduls. Rechts: Aufbau der Rechensysteme.

wohl das ARS30x als auch die Nahbereichs-Radare sind in Serie und werden zur Umsetzung der Serienfunktionen wie DISTRONIC PLUS mit Stop&Go, reversibler Gurtstraffer, adaptiver Gurtkraftbegrenzer, automatische Schließung der Seitenfenster und des Schiebebedachs sowie aller Notbremsfunktionen benutzt. Das eingesetzte Kamerasystem gehört nicht zur Serienausstattung. Es handelt sich hier um ein Entwicklungsmuster, das als ein neues Sensorsystem für die neue Generation der Fahrerassistenzsysteme entwickelt wird. Dies sind die einzigen Sensoren, die in dieser Arbeit zur Umfelderkennung eingesetzt werden.

Die Eigenschaften des ARS30x-Radarsystems sind in Tabelle 5.1 zusammengefasst. Es handelt sich um ein Radar, das über einen Fern- und Nahbereich-Modus verfügt. Demnach werden die Objekte sowohl im Nahbereich von $0.25[m]$ bis $60[m]$ als auch im Fernbereich von bis zu $200[m]$ detektiert. Da die NBR-Sensoren für die Erkennung von Fahrmanövern nicht relevant sind, soll in dieser Arbeit auf diese nicht mehr eingegangen werden.

Das Stereo-Kamerasystem mit einer Basisbreite von $0.2[m]$ ist hinter der Windschutzscheibe montiert (Abb. 5.2). Der Öffnungswinkel des Kamerasystems beträgt ungefähr 40° . Der CMOS-Chip hat eine Auflösung von 1024×440 Pixel und liefert 12 – Bit Grauwertbilder. Die Framerate beträgt 30fps .

	Radareigenschaften	
	Fernbereich	Nahbereich
Auflösung Distanzmessung	2[m]	
Genauigkeit Distanzmessung	0.25[m]	
Auflösung Winkelmessung	1°	4°
Genauigkeit Winkelmessung	0.1°	1°...2°
Geschwindigkeitsauflösung	2.76[km/h]	5.52[km/h]
Geschwindigkeitsgenauigkeit	0.5[km/h]	1.0[km/h]
Zykluszeit	ca. 66[ms]	

Tabelle 5.1: Eigenschaften des Fernbereichsradars ARS30x [102]



Abbildung 5.2: Entwicklungsmuster eines Stereo-Kamerasystems

5.1.2 Rechnersysteme und Vernetzung

Abbildung 5.3 zeigt den gesamten Überblick über die eingesetzte Hardware-Architektur des Versuchsfahrzeuges.

Die Aufgabe des Applikationsrechners ist die Emulation eines ACC- Steuergerätes und die Darstellung der Funktionalität aller Fahrerassistenzsysteme der heutigen Generation. Die notwendigen Daten (z.B. Ego-Fahrzeugdaten, Objek-

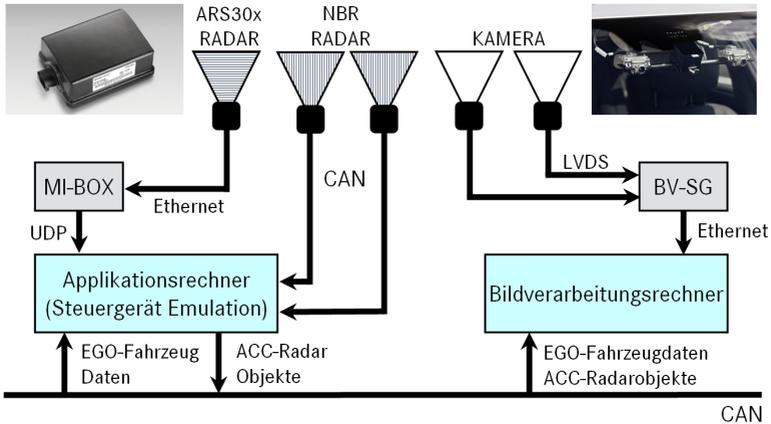


Abbildung 5.3: Hardware-Architektur des Versuchsträgers

te der Nahbereich-Radarsensoren) werden über den CAN-Bus eingelesen. Das ARS30x-Radarsystem liefert im Serienzustand die für die Serienfunktionen notwendigen Daten über den CAN-Bus. Allerdings werden im Sensor selbst mehr Objekte erzeugt. Diese können über eine Messchnittstelle (Mess-Interface-Box, MI-Box) per UDP-Kommunikation zur Verfügung gestellt werden. Die Kommunikation der MI-Box mit dem Radar ist durch eine Ethernet-Verbindung realisiert. Die Radarobjekte werden vom Applikationsrechner für alle anderen Verarbeitungseinheiten auf den CAN-Bus geschrieben. Der Rechner ist mit einem Core 2 Duo Intel Prozessor mit 2.6 GHz Taktfrequenz und einer Speicherkapazität von 2GByte RAM ausgestattet und stellt eine Entwicklungsplattform für Assistenzsysteme der neuen Generation zur Verfügung. Der Aufbau ermöglicht eine schnelle Anbindung neuer Sensoren und eine leichte Integration von Prototypen der neuen Fahrerassistenzsysteme. Diese können direkt im Fahrzeug demonstriert und getestet werden.

Der Bildverarbeitungsrechner liest, wie der Applikationsrechner, die notwendigen Ego-Fahrzeugdaten sowie die Radarobjekte über eine CAN - Verbindung ein. Die Bilder des Stereo-Kamerasystems werden über eine Ethernet - Verbindung vom Bildverarbeitungssteuergerät (BV-SG) zum BV-Rechner kommuniziert. Die Verbindung des BV-Steuergeräts mit dem Kamerasystem ist über eine Low Voltage Differential Signaling (LVDS) Schnittstelle realisiert. Auf dem Bildverarbeitungsrechner laufen verschiedene Bildverarbeitungsalgorithmen, welche die notwendigen Eingangsdaten für die Erkennung von Fahrmanövern berechnen. Die

wichtigsten sind die Spurerkennungsalgorithmen, die Freiraumanalyse sowie die Erkennung von Bildverarbeitungsobjekten (BV-Objekte). Die eingesetzten Bildverarbeitungsalgorithmen sind anspruchsvoll und benötigen viel Rechenleistung. Um den Anforderungen gerecht zu werden ist der Rechner mit einem Intel i7 Quad Core Prozessor und einer Speicherkapazität von 6GByte RAM ausgestattet. Zusätzlich laufen auf diesem Rechner Fusionsalgorithmen, welche die Radarobjekte mit den entsprechenden BV-Objekten fusionieren. Damit bildet dieser Rechner eine gute Ausgangsbasis zur Entwicklung und Evaluierung der in dieser Arbeit vorgestellten Algorithmen. Das Fahrmanöver-Erkennungsmodul wurde in das bestehende Bildverarbeitungs-Framework integriert.

Bei der Entwicklung von verschiedenen Methoden und Algorithmen auf dem Gebiet der Fahrerassistenzsysteme wird immer in zwei Schritten vorgegangen. Im ersten Schritt werden die entwickelten Algorithmen auf ihre Leistungsfähigkeit, ohne Optimierung für den Einsatz in einem Steuergerät, untersucht. Da die Optimierung sehr viel Zeit in Anspruch nimmt, ist diese Vorgehensweise unumgänglich. Zu diesem Entwicklungszeitpunkt steht die Frage, ob die ausgewählte Methode zur Lösung einer aufgestellten Aufgabe geeignet ist, im Vordergrund. Die Algorithmen, welche sich im ersten Schritt als effektiv erwiesen haben, werden dann im zweiten Schritt in Hinsicht auf Rechenzeit und Speichereffizienz optimiert.

Die gesamte Software-Architektur des Bildverarbeitungsrechners wird in den nächsten Kapiteln vorgestellt.

5.2 Software-Architektur

Abbildung 5.4 stellt den gesamten Software-Rahmen mit den eingesetzten Softwaremodulen vor. Die Eingangsdaten (z.B. Radarobjekte, Ego- Fahrzeugdaten usw.) werden vom eingesetzten Bildverarbeitungs-Framework eingelesen und den entsprechenden Modulen zur Verfügung gestellt. Um die Kommunikation zwischen den Modulen zu ermöglichen, wurde in dieser Arbeit eine einheitliche Repräsentation der Daten (hier *Weltmodell* genannt) eingeführt. Das *Weltmodell* wurde nicht nur zur Vereinheitlichung der Schnittstellen zwischen verschiedenen Algorithmen, sondern auch zur Beschreibung einer Fahrsituation (Szene) und zur Organisation der Daten entwickelt. Die Algorithmen tauschen die Daten grundsätzlich nur über das *Weltmodell* aus und stellen damit die Ergebnisse den weiteren Verarbeitungseinheiten zur Verfügung (s. Kap. 5.2.1). Das *Bildverarbeitungsmodul* beinhaltet Bildverarbeitungsalgorithmen wie Spurerkennung, Freiraumanalyse und die Erkennung von Bildverarbeitungsobjekten (s. Kap. 5.2.2). Das *Sensordatenfusionsmodul* bedient sich der erkannten Radar- bzw. BV-Objekte und führt die Fusionsalgorithmen aus (s. Kap. 5.2.3). Basierend auf den Ergebnissen der Bild-

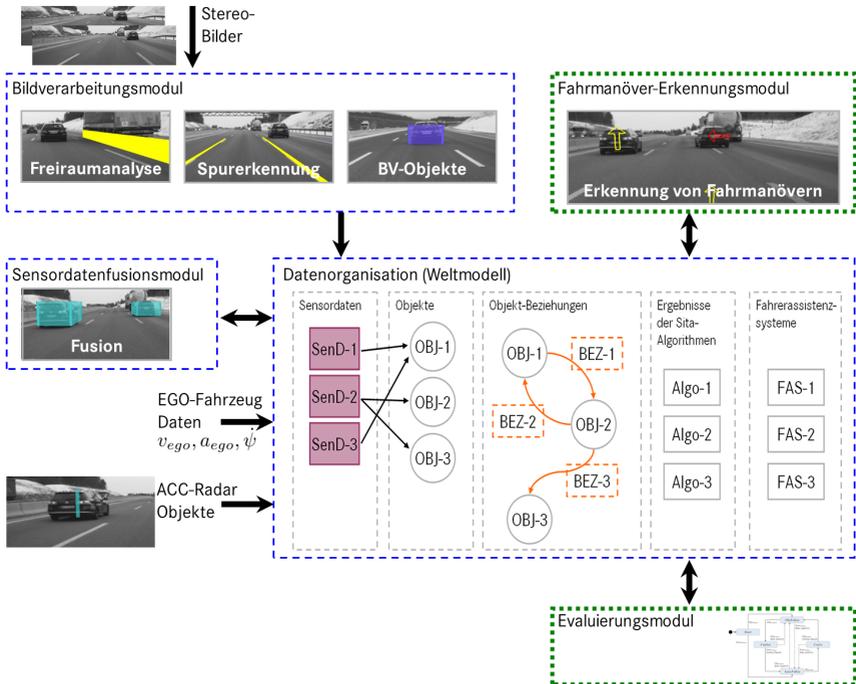


Abbildung 5.4: Software-Architektur des Bildverarbeitungs-Frameworks

verarbeitung und der Fusion werden im *Fahrmanöver-Erkennungsmodul* die Situationsmerkmale berechnet und die Klassifizierung von Fahrmanövern durchgeführt (s. Kap. 5.2.4).

Um die Ergebnisse der Klassifizierung zu evaluieren wurde ein Evaluierungsmodul entwickelt. Die Funktionsweise des Evaluierungsmoduls wird in Kapitel 6.2.1 vorgestellt.

Im Folgenden werden die *Eingangsdaten*, die Aufgabe und der Aufbau des *Weltmodells* sowie die Funktionsweise des *Fahrmanöver-Erkennungsmoduls* im Detail beschrieben.

5.2.1 Situationsbeschreibung und Weltmodell

Eine der Aufgaben der Situationsanalyse ist das Verstehen einer Verkehrssituation (auch Szene genannt). Hierfür wurde in dieser Arbeit ein einheitliches Modell (*Weltmodell*) zur Beschreibung einer Szene entwickelt. Das hier entwickelte Modell soll folgenden Anforderungen genügen. Die Schnittstellen zwischen verschiedenen Algorithmen sollen vereinheitlicht werden. Die Modularität, Erweiterbarkeit und Hardware-Unabhängigkeit des Modells soll gewährleistet sein. Damit die Softwaremodule aufeinander aufbauen können, soll der Austausch der Ergebnisse zwischen diesen erleichtert werden. Zusätzlich ist die Möglichkeit für einen Einsatz in einem Steuergerät bei der Entwicklung zu berücksichtigen.

Abbildung 5.5 zeigt die Beschaffenheit des entwickelten Modells am Beispiel der in dieser Arbeit für die Erkennung von Fahrmanövern umgesetzten Szenenbeschreibung. Ein Framework stellt die notwendigen Eingangsdaten (Ego-Fahrzeugdaten, Bilder des Stereo-Kamerasystems, usw.) den entsprechenden Softwaremodulen

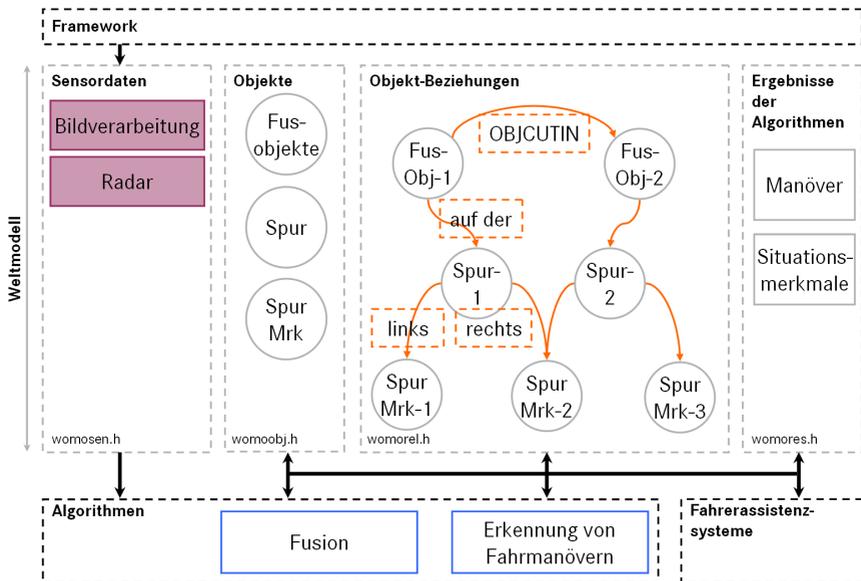


Abbildung 5.5: Weltmodell zur Beschreibung einer Fahrsituation

zur Verfügung und ist gleichzeitig für deren Verwaltung zuständig. Um die Daten, je nach Hardwarearchitektur, einlesen zu können, müssen die Hardwaredreiber neu entwickelt oder es muss auf die bereits vorhandenen Kommunikationsprotokolle (UDP, TCP/IP, CAN) zurückgegriffen werden.

Das *Weltmodell* ist in verschiedene logische Module gegliedert. Dazu gehören die Module *Sensordaten*, *Objekte*, *Objekt-Beziehungen* und die *Ergebnisse der Algorithmen*. Je nach Bedarf kann der notwendige Datenspeicher in den entsprechenden Softwarekomponenten angelegt werden. Wird eine Komponente nicht verwendet, so wird auch kein Speicherplatz benötigt.

Das Modul *Sensordaten* kapselt alle notwendigen Eingangsdaten, die von eingesetzten Sensoren geliefert werden. Dazu gehören z.B. Radardaten, GPS-Daten, Kameradaten, Daten der Fahrzeug-Fahrzeug-Kommunikation usw.

Aus der Sicht der Situationsanalyse besteht eine Szene aus verschiedenen Objekten, die miteinander interagieren können. Die Interaktion zwischen solchen Objekten wird als eine *Objekt-Objekt-Beziehung* modelliert. Die *Objekte* werden aus verschiedenen Sensordaten gebildet. Wie in Abbildung 5.5 dargestellt, sind es z.B. Objekte aus der Objektfusion, Spurmarkierungen oder auch zusammengesetzte Objekte wie eine Fahrspur, die dann aus einer linken und rechten Spurmarkierung besteht.

Im dem Softwaremodul *Objekt-Beziehungen* werden verschiedene Beziehungen zwischen verschiedenen Objekten modelliert. Ein Fahrmanöver findet immer zwischen zwei oder mehreren Fahrzeugen statt. In diesem Fall wird eine Fahrzeug-Fahrzeug-Beziehung benötigt. Des weiteren kann ein Fahrzeug auf einer der vorhandenen Fahrspuren fahren. Dazu wurde eine weitere Fahrzeug-Spur-Beziehung vorgestellt. Eine Fahrspur besteht aus einer linken und rechten Spurmarkierung, die wiederum als eine Spur-Spurmarkierung-Beziehung modelliert wurde.

Die Ergebnisse der einzelnen Algorithmen, die nicht als Objekte oder Objekt-Beziehungen modelliert sind, können im speziellen Softwaremodul *Ergebnisse der Algorithmen* abgelegt werden und stehen somit zur weiteren Verarbeitung zur Verfügung.

Mit dem hier vorgestellten *Weltmodell* kann folgende Situation als Beispiel vollständig beschrieben werden: Ein Fahrzeug-1 fährt auf einer Spur-1 und ein anderes Fahrzeug-2 auf einer anderen Spur-2. Aus der Sicht des Fahrzeuges-1 könnte das Fahrzeug-2 ein Fahrmanöver durchführen, z.B. Einscheren (Abb. 5.6). Die Berechnung von notwendigen Beziehungen zwischen Objekten und Situationsmerkmalen sowie von Bayes-Netz-Inferenz wird vom Fahrmanöver-Erkennungsmodul übernommen.

Das *Weltmodell* zur Beschreibung einer Situation kann auf weitere Szenen z.B. im Kreuzungsbereich erweitert werden. Dazu müssen lediglich *Sensordaten*, *Objek-*

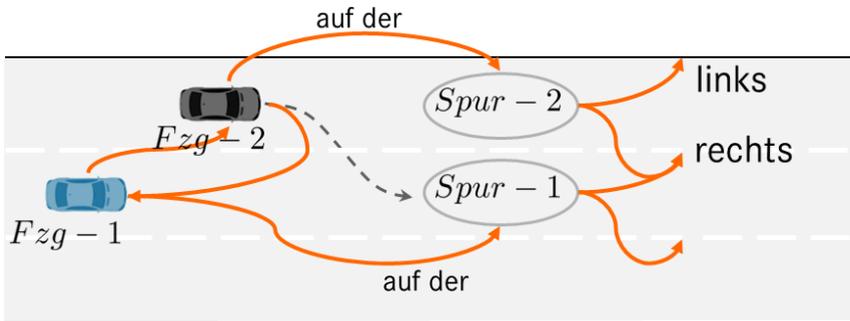


Abbildung 5.6: Beispiel einer Fahrscene abgebildet im *Weltmodell*

te oder *Objekt-Beziehungen* hinzugefügt werden. Somit ist mit diesem Konzept prinzipiell jede beliebige Fahrscene modellierbar.

Das *Weltmodell* ist modular in logischen Schichten aufgebaut und ist auf Grund der Modularität leicht erweiterbar. Ein weiterer Vorteil des Konzepts ist der einfache Austausch der Ergebnisse zwischen verschiedenen Algorithmen. Dadurch ist die Bildung von komplexen Systemen, die sehr einfach wartbar sein müssen, möglich. Dieser Vorteil ist nur durch die Standardisierung von Schnittstellen und die einheitliche Repräsentation einer Szene zu erreichen. Dies ist im vorgestellten *Weltmodell* gewährleistet.

Damit das *Weltmodell* in einem Steuergerät eingesetzt werden kann, wurde die Entwicklung in *C* durchgeführt. Bei der Umsetzung wurde auf die Blackboard-Softwarearchitektur zurückgegriffen [103]. Diese wird dann verwendet, wenn viele kleinere Programme zur Lösung einer aufgestellten Aufgabe beitragen, was auch dem in dieser Arbeit gegebenen Ausgangspunkt entspricht. Die Algorithmen werden von einer zentralen Einheit gesteuert und nacheinander aufgerufen. Dabei schreibt jedes Programm nach der Ausführung die Ergebnisse in einen gemeinsamen Speicher (Blackboard) zurück, so dass andere Algorithmen auf diese zurückgreifen können.

Da die Versuchsträger im Allgemeinen für die Entwicklung von verschiedenen Fahrerassistenzsystemen aufgebaut werden, kann an dieser Stelle nicht garantiert werden, dass die Software- bzw. Hardwarearchitektur immer gleich bleibt. Für die Integration von Algorithmen der Situationsanalyse bedeutet dies eine erforderliche Anpassung der Schnittstellen an die eingesetzte Entwicklungsumge-

bung. Bauen die Algorithmen auf einheitlichen Schnittstellen auf, so muss lediglich ein Umsetzer entwickelt werden, der die Eingangsdaten von der eingesetzten Entwicklungsumgebung in das *Weltmodell* transferiert. Die Algorithmen der Situationsanalyse, die mit dieser Schnittstelle arbeiten, können ohne Veränderung weiterverwendet werden. Dies erleichtert die Austauschbarkeit von Situationsanalysemodulen zwischen verschiedenen Frameworks und verringert somit den Integrationsaufwand.

Im folgenden Kapitel werden die in dieser Arbeit verwendeten Eingangsdaten und ihre Weiterverarbeitung vorgestellt.

5.2.2 Eingangsdaten

5.2.2.1 Freiraumanalyse

Die Algorithmen der Freiraumanalyse liefern den freien befahrbaren Raum bis zu einem erhabenen Objekt (z.B. Leitplanke, Fahrzeug usw.). Es handelt sich hier um die Arbeiten des Bildverarbeitungsteams der Group Research and Advanced Engineering Daimler AG [104]. Basierend auf dem berechneten Freiraum kann der nächste laterale Δy -Abstand zu einem erhabenen Objekt geschätzt werden. Dieser wird zur Weiterverarbeitung der Algorithmen der Situationsanalyse zur Verfügung gestellt. Aus der Sicht des Ego-Fahrzeuges bedeutet dies, dass der Raum bis zu diesem lateralen Δy -Abstand frei ist. Tabelle 5.2 fasst die Eigenschaften des geschätzten Freiraums zusammen.

Freirauminformation	
Δy	lateraler Abstand zum erhabenen Objekt [m]
t_{life}	Lebensdauer [s]

Tabelle 5.2: Freiraumeigenschaften

5.2.2.2 Spurerkennung

Eine der ersten Arbeiten zur bildbasierten Spurerkennung wurde in [93] vorgestellt. Diese Algorithmen wurden optimiert und weiterentwickelt, so dass heutzutage die Spurerkennung für verschiedene Fahrerassistenzsysteme eingesetzt wird. Der Spurerkennungsalgorithmus basiert auf einem Straßenmodell, das bereits in

Kapitel 4.2.2.1 vorgestellt wurde. In dieser Arbeit werden bis zu vier Spurmarkierungen erkannt. Diese werden in den weiteren Verarbeitungseinheiten zu Spuren zusammengefasst. Eine Spur besteht dabei aus einer linken und rechten Spurmarkierung und wird als eine *Spur-Spurmarkierung-Beziehung* modelliert. Mit den erkannten Spurmarkierungen ist es möglich bis zu drei Spuren aufzubauen. Tabelle 5.3 fasst alle Größen, die von einem Spurerkennungsalgorithmus berechnet werden, zusammen.

Spurinformation	
id	Id der Spurmarkierung
c_0	Krümmung $[1/m]$
c_1	Krümmungsänderung $\left[\frac{1}{m/s} \right]$
Δy	Abstand zur Spurmarkierung $[m]$
t_{life}	Lebensdauer $[s]$

Tabelle 5.3: Eigenschaften einer Spurmarkierung

5.2.2.3 Radarobjekte

Alle Radarobjekte werden direkt in einem Radarsteuergerät berechnet und dem Applikationsrechner zur Verfügung gestellt. Die Radarobjekte werden für die Abstandsregelung der ACC-Funktion von den Algorithmen der Situationsanalyse verwendet. Das Radarsteuergerät in der heutigen Serienversion überträgt sechs Radarobjekte, die durch eine eindeutige id identifiziert werden können. Zusätzlich zu der relativen Geschwindigkeit $(v_{x_{rel}}, v_{y_{rel}})$ und relativen Position (x_{rel}, y_{rel}) eines Radarobjektes wird die Positionsinformation ($posinf$) bestimmt. Abbildung 5.7 stellt die sechs Radarobjekte mit entsprechenden Positionen vor. Da das Radarsteuergerät keine Informationen über die erkannten Spurmarkierungen bekommt, hängt die Positionierung der Radarobjekte direkt mit dem berechneten Fahrtschlauch des Ego-Fahrzeuges zusammen. Das Radarobjekt mit der Positionsinformation *Relevant* (auch *ObjectOfInterest* genannt) wird für die ACC-Regelung verwendet. Der Bewegungszustand *movstate* eines Radarobjektes kann folgende Größen annehmen: *Undefiniert*, *Stationär*, *Bewegt*, *Gegenverkehr*. Tabelle 5.4 fasst die Eigenschaften der Radarobjekte zusammen.

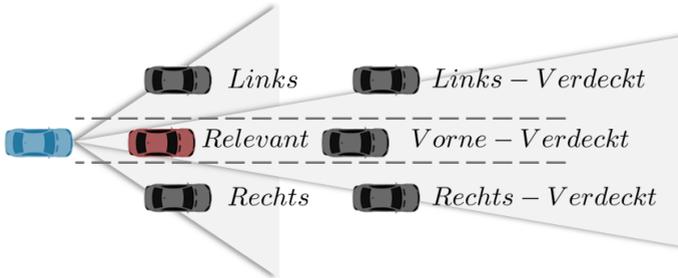


Abbildung 5.7: ACC-Radarobjekte mit Positionsinformation

ACC-Radarobjekte	
id	Id des Objektes
x_{rel}	Relative Position in x-Richtung [m]
y_{rel}	Relative Position in y-Richtung [m]
$v_{x_{rel}}$	Relative Geschwindigkeit in x-Richtung [m/s]
$v_{y_{rel}}$	Relative Geschwindigkeit in y-Richtung [m/s]
$posinf$	Positionsinformation des Objektes
$movstate$	Bewegungszustand des Objektes

Tabelle 5.4: Eigenschaften der ACC-Radarobjekte

5.2.2.4 Bildverarbeitungsobjekte

Bei der Erkennung von Bildverarbeitungsobjekten handelt es sich um Arbeiten von [105], [106], [107], [108] die auch bei der Daimler AG durchgeführt worden sind. Zusätzlich zu den Eigenschaften wie: id , Geschwindigkeit $(v_{x_{rel}}, v_{y_{rel}})$ und Position (x_{rel}, y_{rel}) kann aus der Bildinformation auch die Länge, Breite sowie der Gierwinkel (ψ) und die Gierrate $(\dot{\psi})$ eines BV-Objektes geschätzt werden. Die Bildverarbeitungsalgorithmen zur Objekterkennung liefern drei Objekte, die sich am nächsten zum Ego-Fahrzeug befinden. Diese werden zuverlässig von bis zu 40m Abstand erkannt. Tabelle 5.5 fasst alle Eigenschaften eines Bildverarbeitungsobjektes zusammen.

Bildverarbeitungsobjekte	
id	Id des Objektes
x_{rel}	Relative Position in x-Richtung [m]
y_{rel}	Relative Position in y-Richtung [m]
$v_{x_{rel}}$	Relative Geschwindigkeit in x-Richtung [m/s]
$v_{y_{rel}}$	Relative Geschwindigkeit in y-Richtung [m/s]
$a_{x_{rel}}$	Relative Beschleunigung in x-Richtung [m/s ²]
$a_{y_{rel}}$	Relative Beschleunigung in y-Richtung [m/s ²]
ψ	Gierwinkel des Objektes [rad]
$\dot{\psi}$	Gierrate des Objektes [rad/s]
L	Länge des Objektes [m]
B	Breite des Objektes [m]
t_{life}	Lebensdauer des Objektes [s]

Tabelle 5.5: Eigenschaften der Bildverarbeitungsobjekte

5.2.3 Sensordatenfusion

Um die Qualität und Robustheit der erkannten Objekte zu verbessern, werden verschiedene Messtechniken (Sensoren) zur Umgebungserfassung benutzt. Im Vergleich zum Radarsystem kann aus der Bildverarbeitung die Länge und Breite sowie die laterale Position eines Objektes besser bestimmt werden. Im Gegensatz dazu liefert ein Radarsensor bessere Messwerte bezüglich der Geschwindigkeit und des Abstands in x -Richtung. Um die Ergebnisse der Erkennung der einzelnen Sensoren zusammenzuführen, ist eine Sensordatenfusion notwendig. Bei der Fusion von Messungen verschiedener Sensoren werden die Vorteile des jeweiligen Sensors ausgenutzt, was zu stabileren und qualitativ besseren Objekten führt. Die in dieser Arbeit eingesetzte Objektfusion basiert auf den vorgestellten Ansätzen von [109], [110]. Dabei handelt es sich um einen Kalman-Filter-basierten Fusionsalgorithmus.

Die Eigenschaften eines fusionierten Objektes sind in Tabelle 5.6 zusammengefasst. Neben den bereits vorgestellten Attributen der einzelnen Radar- bzw. BV-Objekte wird noch die Information, von welchem Sensor ein Objekt gesehen wurde (*seenby*), mitgeführt. Zusätzlich dazu werden die Varianzen (*variance*) der geschätzten Größen des Kalman-Filters protokolliert. Dabei handelt es sich um Varianzen in der Position, Geschwindigkeit, Beschleunigung, Gierrate und Gierwinkel. Diese werden zur Berücksichtigung des Messrauschens im Bayes-Netz mitverwendet. Um das für die ACC-Regelung relevante Objekt zu bestimmen wird

Fusionsobjekte	
id	Id des Objektes
x_{rel}	Relative Position in x-Richtung [m]
y_{rel}	Relative Position in y-Richtung [m]
$v_{x_{rel}}$	Relative Geschwindigkeit in x-Richtung [m/s]
$v_{y_{rel}}$	Relative Geschwindigkeit in y-Richtung [m/s]
$a_{x_{rel}}$	Relative Beschleunigung in x-Richtung [m/s^2]
$a_{y_{rel}}$	Relative Beschleunigung in y-Richtung [m/s^2]
ψ	Gierwinkel des Objektes [rad]
$\dot{\psi}$	Gierrate des Objektes [rad/s]
L	Länge des Objektes [m]
B	Breite des Objektes [m]
t_{life}	Lebensdauer des Objektes [s]
$posinf$	Positionsinformation des Objektes
$movstate$	Bewegungszustand des Objektes
$seenby$	Information von welchem Sensor das Objekt gesehen wurde
$variance$	Varianzen der Zustandsgrößen des Kalman-Filters

Tabelle 5.6: Eigenschaften der Fusionsobjekte

die Positionsinformation ($posinf$) direkt von den Radarobjekten übernommen. Die Information auf welchen der vorhandenen Spuren ein Fahrzeug fährt wird in den weiteren Verarbeitungseinheiten berechnet und als eine *Fahrzeug-Spur-Beziehung* modelliert.

5.2.4 Fahrmanöver-Erkennungsmodul

Die Integration des Fahrmanöver-Erkennungsmoduls in die gesamte Entwicklungsumgebung wurde bereits schematisch in Abbildung 5.4 dargestellt. Abbildung 5.8 zeigt die Softwaremodule, die zur Klassifikation von Fahrmanövern entwickelt wurden. Diese sind in drei logische Gruppen unterteilt: *Berechnung von Objekt-Beziehungen*, *Berechnung von Situationsmerkmalen*, *Klassifikation*.

Anhand der im *Weltmodell* gespeicherten Objekte werden im ersten Schritt die notwendigen Objekt-Objekt-Beziehungen zur Beschreibung einer Szene berechnet. Diese Beziehungen werden im Bayes-Netz-Modell durch die Schichten zwei bis vier abgebildet (Abb. 4.2).

Die Verwaltung der berechneten Objekt-Beziehungen wird von einem *Objektverwaltungsmodul* übernommen. Hier wird unter anderem auch die Gültigkeit der Objekte für die Klassifikation bestimmt. Es wird überprüft, ob z.B. reale Spurmarkierungen vorhanden oder ob die fusionierten Objekte gültig sind. Da in dieser Arbeit für die Klassifikation nur Beziehungen zwischen dem Ego-Fahrzeug und anderen Objekten interessieren (Ego-Objekt-Beziehung) werden die Objekt-Ego-Beziehungen nicht berücksichtigt.

Die Module für die Berechnung von *Freiraummerkmalen* (**FR-H**) bzw. *Spurwechselmerkmalen* (**LE-H, TR-H**, Gl. 4.1) werden für die gültigen Objekt-Objekt-Beziehungen vom *Verwaltungsmodul* aufgerufen. Diese *Situationsmerkmale* werden anhand von Sensordaten berechnet. Da die Sensordaten mit Unsicherheiten behaftet sind, müssen diese bei der Modellierung mitberücksichtigt werden. Dies wird im Bayes-Netz-Modell von der ersten Schicht übernommen (Abb. 4.2). Die berechneten Situationsmerkmale werden im *Weltmodell* gespeichert und stehen dem *Klassifikationsmodul* zur Verfügung.

Nach dem Einfügen von Evidenzen und der Berechnung der Bayes-Netz-Inferenz

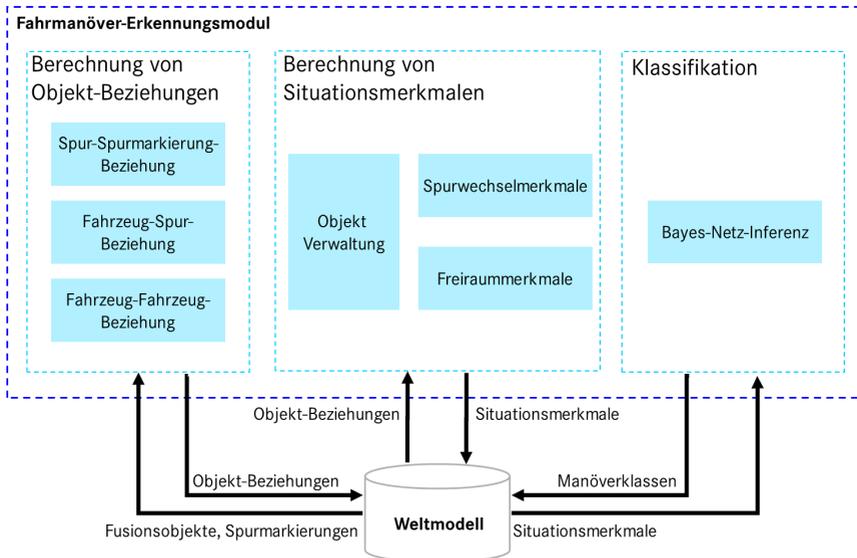


Abbildung 5.8: Fahrmanöver-Erkennungsmodul

kann das Ergebnis der Klassifikation (*Manöverklassen*, **FM-H**, Gl. 4.42) von den anderen Verarbeitungseinheiten verwendet werden. Die Klassifikation von Fahrmanövern wird im Bayes-Netz-Modell durch die vierte Schicht durchgeführt (Abb. 4.2).

Die Umsetzung des in Kapitel 4.3 vorgestellten Bayes-Netzes zur Erkennung von Fahrmanövern wurde mit Hilfe der *HUGIN*-Software durchgeführt [82], [83]. Die Software erlaubt eine grafische Modellierung von Bayes-Netzen, deren Parametrierung sowie die automatische Generierung des *C*-Codes für das entwickelte Modell. Um die Integration vom *C*-Code in verschiedene Entwicklungsumgebungen zu erleichtern, stellt *HUGIN* eine Schnittstelle zur Anwendungsprogrammierung (engl. *application programming interface (API)*) mit den entsprechenden *C*-Bibliotheken zur Verfügung.

Kapitel 6

Experimentelle Ergebnisse und Evaluation

Dieses Kapitel stellt die Leistungsfähigkeit des Fahrmanöver-Erkennungsmoduls in der Praxis vor. Mit Hilfe der in dieser Arbeit entworfenen Algorithmen werden die Fahrmanöver während mehrerer Versuchsfahrten klassifiziert und die Ergebnisse evaluiert. Dazu wird zunächst in Kapitel 6.2.1 das für die Online-Evaluierung entwickelte Evaluierungsmodul vorgestellt. Da die Entscheidungsfindung, ob ein Manöver stattfindet, eine wichtige Rolle für die Erkennungsleistung des Systems spielt, wird die Systemauslegung in Kapitel 6.2.2 vorgestellt. Für die ausgewählte Auslegung des Systems werden in Kapitel 6.3.1 die Ergebnisse am Beispiel einzelner Manöver diskutiert. Das Gesamtergebnis der Evaluierung aller Versuchsfahrten wird in Kapitel 6.3.2 präsentiert.

6.1 Ziele der Untersuchung

Die Untersuchung soll zeigen, wie gut die Klassifizierung von Fahrmanövern mit Bayes-Netzen in Autobahnscenarien funktioniert und ob sich dieser Ansatz hierfür eignet. Dazu wird eine Statistik über richtig und falsch erkannte Fahrmanöver aufgestellt. Bei den falsch erkannten Manövern wird nach zwei Klassifikationsfehlern „*false positive*“ und „*false negative*“ unterschieden. Die „*false positives*“ bedeuten, dass ein Fahrmanöver erkannt wird, obwohl keines stattfindet. Die „*false negatives*“ bedeuten, dass ein Fahrmanöver stattfindet, aber nicht erkannt wird.

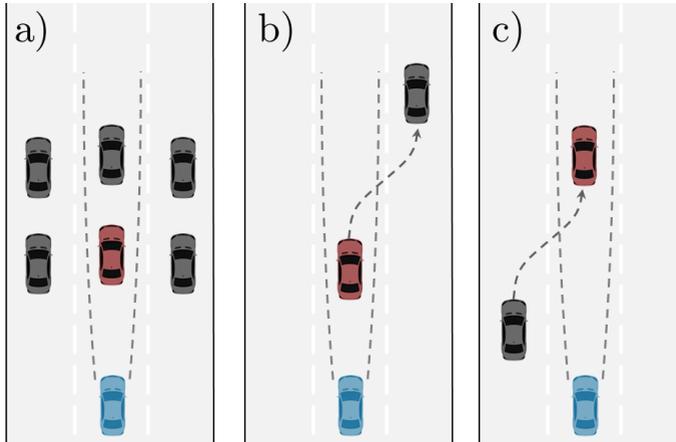


Abbildung 6.1: a) Objekte eines ACC-Systems („relevantes“ Objekt in rot). b) ein ausscherendes Objekt, wird als „nicht relevant“ eingestuft. c) ein einscherendes Objekt, wird als „relevant“ eingestuft.

In diesen Fällen sollen die Ursachen untersucht und eine mögliche Lösung vorgeschlagen werden.

Um den Nutzen der Fahrmanöver-Erkennung aufzuzeigen, wird dieses mit einem bei der Daimler AG verfügbaren Adaptive Cruise Control (ACC) verglichen. Dieses ACC-Seriensystem ist radarbasiert und führt eine Klassifizierung der detektierten Objekte durch. Hierbei werden diese als „relevant“ oder „nicht relevant“ eingestuft. Ein Objekt, welches sich im Fahrschlauch des Ego-Fahrzeuges befindet, wird als „relevant“ klassifiziert. Auf dieses Objekt erfolgt die Regelung des Abstandes und der Geschwindigkeit. Alle anderen erfassten Objekte werden als „nicht relevant“ eingestuft. Ein Einscher-Manöver führt dazu, dass die einscherenden Objekte vom ACC-System als „relevant“ klassifiziert werden. Ein Ausscher-Manöver führt dazu, dass die ausscherenden Objekte als „nicht relevant“ eingestuft werden (Abb. 6.1). Diese Manöver werden auch vom Fahrmanöver-Erkennungsmodul erkannt. An dieser Stelle kann der Zeitunterschied zwischen dem Zeitpunkt, zu welchem ein ACC-System ein Objekt als „relevant“ oder „nicht relevant“ einstuft und dem Zeitpunkt, zu welchem das Erkennungsmodul ein Manöver klassifiziert, gemessen werden. Außerdem soll untersucht werden, bei welchen Fahrmanövern der Zeitgewinn am größten ist. Wird ein Fahrmanöver vom

Erkennungsmodul früher erkannt, so kann diese Information als Unterstützung für die Entscheidungsfindung eines ACC-Systems zur Verfügung gestellt werden.

Aus den Ergebnissen der Untersuchung sollen weitere Schritte zur Verbesserung des Erkennungsmoduls abgeleitet werden.

6.2 Online-Evaluierung

Um die in dem vorherigen Kapitel vorgestellten Ziele zu erreichen, wurde ein Modul zur Evaluierung der klassifizierten Fahrmanöver entwickelt. Der Aufbau und die Funktionsweise des Moduls sowie die ausgewählte Systemauslegung werden in den nächsten Kapiteln vorgestellt.

6.2.1 Evaluierungsmodul

Wie bereits in Kapitel 5.2.4 vorgestellt führt das Fahrmanöver- Erkennungsmodul drei wesentliche Berechnungen durch: *Berechnung von Objekt- Beziehungen*, *Berechnung von Situationsmerkmalen* (Gl. 4.1) und *Klassifikation*. Die Ergebnisse der Berechnung werden im *Weltmodell* gespeichert und stehen zur weiteren Verarbeitung zur Verfügung (Abb. 5.8).

Zur Evaluierung des Fahrmanöver-Erkennungsmoduls werden die berechneten *Situationsmerkmale*, die *Objekt- bzw. Spurdaten* sowie das Ergebnis der Klassifikation (*Manöverklassen*, Gl. 4.42) benötigt. Die Integration des Evaluierungsmoduls in die gesamte Entwicklungsumgebung wurde bereits schematisch in Abbildung 5.4 dargestellt.

Abbildung 6.2 zeigt den gesamten Aufbau des Evaluierungsmoduls. Das entwickelte Evaluierungsmodul beinhaltet einen Zustandsautomaten zur Evaluierung der klassifizierten Fahrmanöver sowie ein LOG-Modul zur Protokollierung der Daten. Anhand der definierten Zustandsübergänge kann festgestellt werden, ob die Fahrmanöver richtig oder falsch klassifiziert wurden. Die Ergebnisse der Klassifikation können direkt während einer Versuchsfahrt evaluiert werden. Somit ist keine aufwendige Offline-Simulation notwendig, da die Evaluierung online stattfindet. Das Log-Modul übernimmt die Protokollierung der berechneten Situationsmerkmale, Objektdaten und der Ergebnisse der Klassifizierung.

Abbildung 6.3 zeigt den Zustandsautomat mit den zulässigen Zustandsübergängen. An dieser Stelle soll die Funktionsweise anhand eines Beispiels vorgestellt werden. Das Ego-Fahrzeug folgt einem Objekt. Die Klasse *ObjFollow* wird klassifiziert. Als nächstes schert das Objekt aus, die Klasse *ObjCutOut* wird klassifiziert. Die nächste erwartete Klasse ist *LaneFollow*. Wird diese vom System

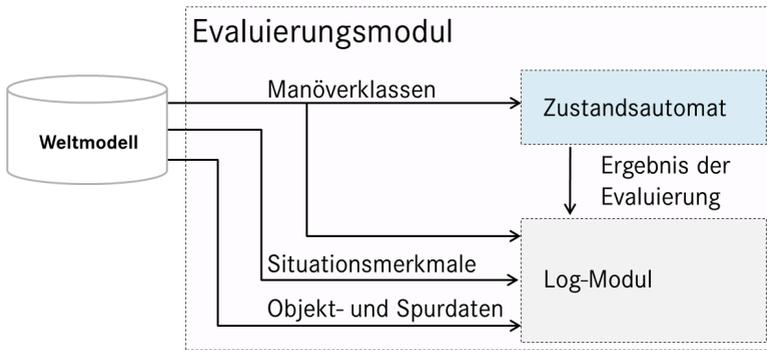


Abbildung 6.2: Schematischer Aufbau des Evaluierungsmoduls

klassifiziert, so wurde dieses Fahrmanöver „*richtig erkannt*“. Wird ein anderes Manöver, wie z.B. *ObjFollow* erkannt, so führt dies zu einem „*false positive*“. Das System klassifiziert hier ein Manöver, obwohl keines stattfindet. Ein Zustandsübergang von *LaneFollow* zu *ObjFollow* und umgekehrt führt dagegen zu einem „*false negative*“. In diesem Fall führt ein Objekt einen Spurwechsel durch, welcher vom System nicht erkannt wird.

Die in Abbildung 6.3 dargestellten Zustandsübergänge sind folgendermaßen definiert:

- „*richtig erkannt*“
 - *ObjFollow* → *ObjCutOut* → *LaneFollow*
 - *LaneFollow* → *ObjCutIn* → *ObjFollow*
- „*false positive*“
 - *ObjFollow* → *ObjCutOut* → *ObjFollow*
 - *LaneFollow* → *ObjCutIn* → *LaneFollow*
- „*false negative*“
 - *ObjFollow* → *LaneFollow*
 - *LaneFollow* → *ObjFollow*

Die erstellte Statistik zeigt, dass die Anzahl der „false positives“ in der gleichen Größenordnung wie die Anzahl der „richtig erkannten“ Manöver liegt. Betrachtet man die Wahrscheinlichkeit der falsch erkannten Fahrmanöver, so liegt diese im Durchschnitt bei $E(p_{error}) = 65\%$. Zur Vermeidung von Fehlklassifikationen darf ein Manöver demzufolge erst dann prognostiziert werden, wenn die Manöver-Wahrscheinlichkeit größer als diese Schwelle beträgt.

Bei der zweiten Versuchsfahrt wurde die *Systemauslegung B* mit einer Schwelle $S = 65\%$ untersucht. Abbildung 6.4 (rechts) zeigt die Fehlerstatistik der *Systemauslegung B*. Es wurden 71 Fahrmanöver richtig klassifiziert. Die Anzahl der „false positives“ ist im Vergleich zur *Systemauslegung A* auf sechs zurückgegangen. Die Anzahl der „false negatives“ ist in etwa gleich geblieben.

Wird der Zeitunterschied Δt zwischen dem Ergebnis der Klassifikation des Erkennungsmoduls und des ACC-Systems verglichen, so liegt dieses für die *Systemauslegung A* bei $-0.671s$ und für die *Systemauslegung B* bei $-0.609s$. Dieser Unterschied zwischen den beiden Systemauslegungen entspricht ca. 10% (62ms) und kann gegenüber einer schnellen Fahrerreaktion, in der Regel bis zu 1s, vernachlässigt werden. Bei der *Systemauslegung B* ist der Zeitgewinn geringer, da die Manöver erst dann klassifiziert werden, wenn die Wahrscheinlichkeit höher als die definierte Schwelle ist.

Der entscheidende Vorteil der *Systemauslegung B* besteht darin, dass die Anzahl der „false positives“, bei nahezu gleichem Zeitgewinn Δt , deutlich geringer ist. Daher wird im Weiteren die *Systemauslegung B* verwendet.

Tabelle 6.1 gibt nochmal eine Übersicht über die Statistik der Ergebnisse beider Systemauslegungen. Da hier zwei Versuchsfahrten durchgeführt wurden ist die

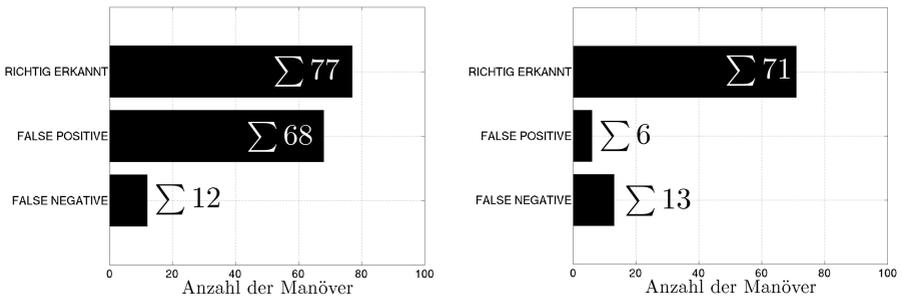


Abbildung 6.4: Vergleich der Fehlerstatistik (links: *Systemauslegung A*, rechts: *Systemauslegung B*)

	Versuchsfahrt	
	<i>Systemauslegung A</i>	<i>Systemauslegung B</i>
„richtig erkannt“	77	71
„false positive“	68	6
„false negative“	12	13
$E(\Delta t)$	-0.671[s]	-0.609[s]

Tabelle 6.1: Vergleich der beiden *Systemauslegungen A, B*

Anzahl der Fahrmanöver unterschiedlich. An dieser Stelle muss erwähnt werden, dass die ausgewählte Systemauslegung für den in Kapitel 4.4 definierten Bayes-Netz-Parametersatz gilt. Werden die Parameter des Bayes-Netzes geändert, ändert sich auch die Erkennungsleistung des Moduls, so dass die Systemauslegung erneut untersucht werden muss.

Um die restlichen „false positive“ Fälle zu vermeiden, müsste die Schwelle z.B. auf 75% oder höher angehoben werden. Dabei sind weitere Untersuchungen der Erkennungsleistung des Systems in Bezug auf Zeitgewinn Δt und der „false positive“ bzw. „false negative“ Rate notwendig. Da in dieser Arbeit keine weiteren Arbeiten bezüglich der Systemoptimierung durchgeführt wurden, stellt die ausgewählte *Systemauslegung B* nicht die optimale Lösung dar. Nichtsdestotrotz zeigt *Systemauslegung B* im Vergleich zu *Systemauslegung A* bessere Klassifikationsergebnisse. Die Optimierung des Erkennungsmoduls hängt im Endeffekt von der Auslegung eines Fahrerassistenzsystems ab und muss somit von einem Funktionsentwickler durchgeführt werden.

6.3 Diskussion der Ergebnisse

6.3.1 Ergebnisse am Beispiel einzelner Manöver

Um die Funktionsweise des Erkennungsmoduls und der Online-Evaluierung besser zu verstehen, werden in diesem Kapitel die Ergebnisse anhand einzelner Manöver im Detail diskutiert.

Abbildung 6.5 zeigt folgende Fahrsituation:

- das Ego-Fahrzeug folgt einem Objekt, welches gerade einen LKW auf der rechten Spur überholt (Abb. 6.5, a)

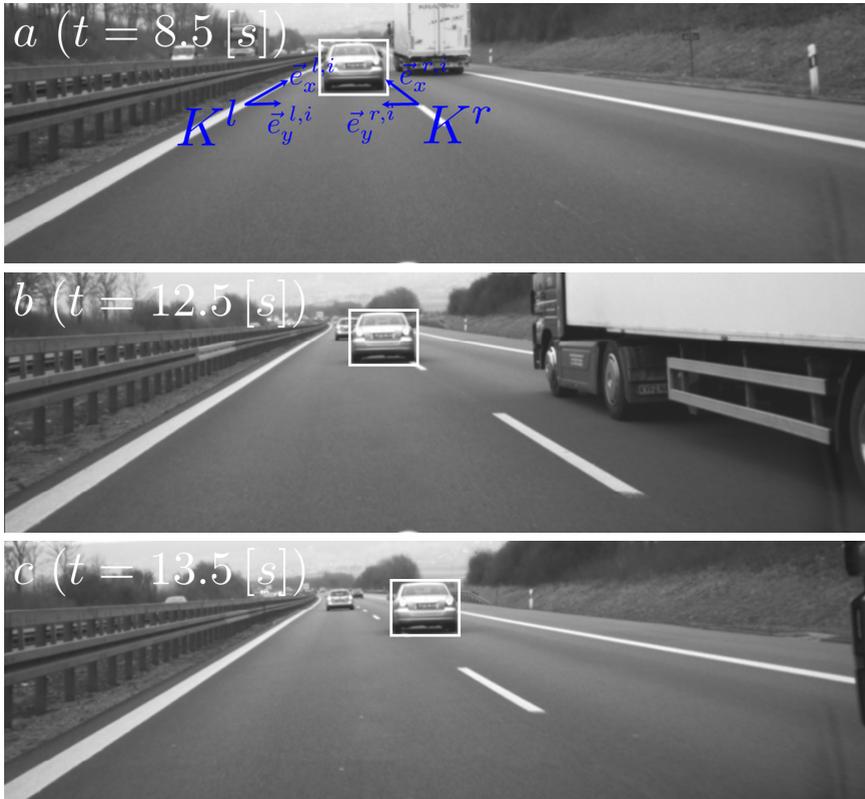


Abbildung 6.5: Fahrsituation: a) *ObjFollow* b) *ObjCutOut* c) *LaneFollow*

- nach dem Überholvorgang scheidet das Objekt nach rechts aus und wird vom ACC-System als „nicht relevant“ klassifiziert (Abb. 6.5, b)
- nach dem Ausscher-Manöver fährt das Objekt auf der rechten Spur weiter. Das Ego-Fahrzeug folgt der linken Spur (Abb. 6.5, c).

Der Verlauf der berechneten Situationsmerkmale wird im Folgenden sowohl für das linke (durchgezogene Linie) als auch rechte (gestrichelte Linie) Spurkoordinatensystem vorgestellt. Das vorausfahrende Objekt überquert die rechte Spurmarkierung zum Zeitpunkt $t \approx 12.3$ s. Dies wird in Abbildung durch einen Kreis

dargestellt.

Der Verlauf der Situationsmerkmale T_{lcr}^s , $a_{lat,max}^s$, ϕ_{lane}^s , die für das betrachtete Objekt berechnet wurden, ist in Abbildung 6.6 dargestellt. Zum Zeitpunkt der Überschreitung der rechten Spurmarkierung ist entsprechend der Wert der Variable $T_{lcr}^r \approx 0s$. Dabei wird eine maximale Querbewegung von $a_{lat,max}^r \approx 1.1m/s^2$ und ein Spurwinkelfehler von $\phi_{lane}^r \approx -1.8^\circ$ geschätzt. Kann keine Spurwechsel-Trajektorie geschätzt werden, so werden die Situationsmerkmale mit den Defaultwerten $T_{lcr} = 4s$, $\phi_{lane} = 0^\circ$, $a_{lat,max} = 0m/s^2$ belegt. Die Defaultwerte bedeuten, dass kein Spurwechselmanöver durchgeführt wird. Dies ist für das linke Spurkoordinatensystem ab ca. $t \approx 12s$ der Fall.

Die Merkmale lateraler Spurversatz o_{lat}^s und laterale Geschwindigkeit v_{lat}^s sind in Abbildung 6.7 dargestellt. In dem linken und rechten Spurkoordinatensystem ist der Verlauf dieser Situationsmerkmale symmetrisch, wobei durch Messunsicherheiten kleine Abweichungen entstehen können. Zum Zeitpunkt der Überschreitung der rechten Spurmarkierung betragen die Werte $o_{lat}^r \approx 0m$ und $v_{lat}^r \approx$

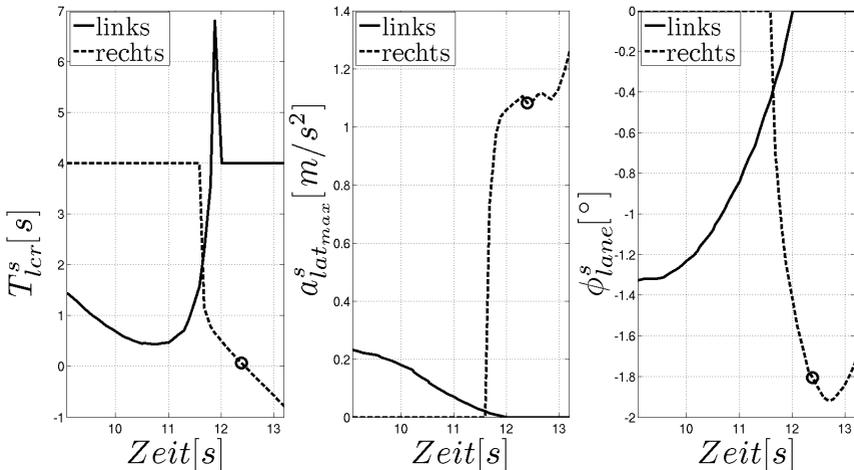


Abbildung 6.6: Verlauf der berechneten Situationsmerkmale für das vorausfahrende Objekt: Zeit zur Überquerung einer Spurmarkierung T_{lcr}^s , maximal ausgenutzte Beschleunigung $a_{lat,max}^s$ und Spurwinkelfehler ϕ_{lane}^s

$-1.6m/s$.

Die Situationsmerkmale der Freiraum-Hypothesen für die rechte Gitterzelle r des vorausfahrenden Objektes sind in Abbildung 6.8 dargestellt. Das Objekt überholt einen LKW, welcher auf der rechten Spur fährt. Zum Zeitpunkt $t \approx 9s$ fährt der LKW in die rechte Zelle hinein, und zum Zeitpunkt $t \approx 10.3s$ aus der Zelle wieder heraus. Die negativen Werte bedeuten, dass ein Objekt sich bereits in der Zelle befindet oder sich von der Zelle entfernt. Die Eintritts- bzw. Austritts-Zeiten sind in Abbildung 6.8 durch einen Kreis gekennzeichnet.

Die berechneten Situationsmerkmale und deren Varianzen werden als Evidenzen in das Bayes-Netz eingefügt. Nach dem Berechnen der Inferenz kann die Wahrscheinlichkeit für ein Fahrmanöver im Knoten *Fahrmanöver* abgefragt werden.

Um das Ergebnis nachvollziehen zu können, wurden auch die Wahrscheinlichkeiten der Grundhypothesen gespeichert. Die Grundhypothesen *Trajektorie*, *Laterale Evidenz* und *Spurwechselfähigkeit* werden sowohl für das linke als auch das rechte Spurkoordinatensystem berechnet und zu der Hypothese *Überschreitung*

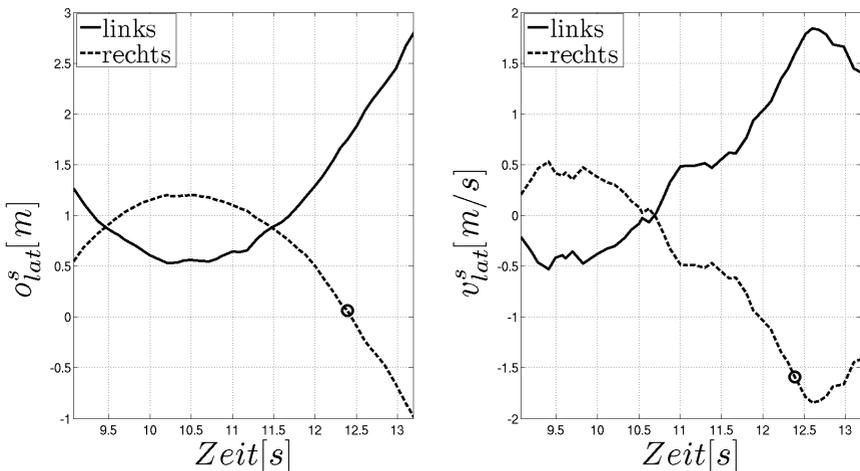


Abbildung 6.7: Verlauf der berechneten Situationsmerkmale für das vorausfahrende Objekt: lateraler Spurversatz o_{lat}^s und laterale Geschwindigkeit v_{lat}^s

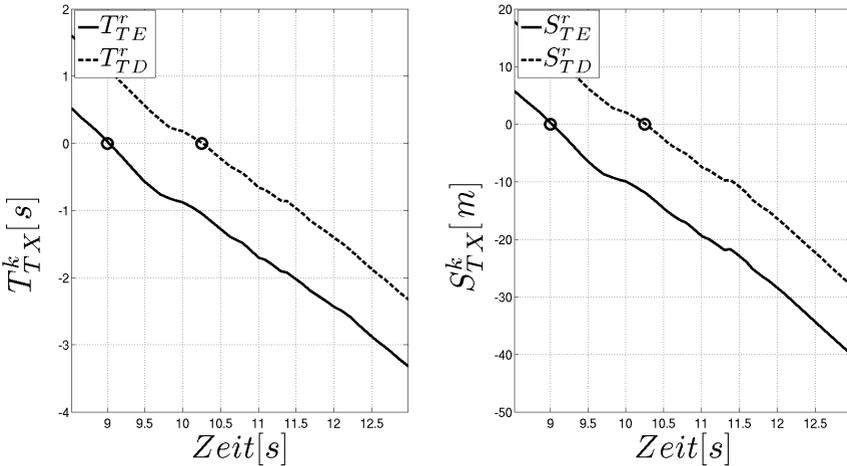


Abbildung 6.8: Verlauf der berechneten Situationsmerkmale T_{TX}^r, S_{TX}^r der rechten Gitterzelle r des vorausfahrenden Objektes

einer Spurmarkierung (Links, Rechts) zusammengefasst (s. Kap. 4.3.3.1, Abb. 4.15). Der Verlauf der einzelnen Wahrscheinlichkeiten ist in Abbildung 6.9 dargestellt und wird im Folgenden verdeutlicht.

Wie bereits beschrieben, verlässt der überholte LKW die rechte Gitterzelle des vorausfahrenden Objektes zum Zeitpunkt $t \approx 10,3s$ (Abb. 6.8, $T_{TD} \approx 0s$). Mit der steigenden Entfernung und Zeit steigt auch die Wahrscheinlichkeit der Hypothese *Spurwechselfähigkeit* an. Zum Zeitpunkt $t \approx 11,5s$ beträgt diese 100%. Im weiteren zeitlichen Verlauf steigen auch die Wahrscheinlichkeiten der beiden rechts Hypothesen *Trajektorie* und *Laterale Evidenz*. Im Vergleich zu den Wahrscheinlichkeiten der Hypothesen *Trajektorie* und *Laterale Evidenz* ist die Wahrscheinlichkeit der Hypothese *Überschreitung einer Spurmarkierung* größer, da diese sich aus den beiden Wahrscheinlichkeiten zusammensetzt. Die Wahrscheinlichkeit der linken Spurwechsel-Hypothesen ist sehr klein, da das vorausfahrende Objekt keinen Spurwechsel nach links durchführt. Außerdem ist wegen der Fahrbahnbegrenzung kein Spurwechsel nach links möglich. Somit ist auch die Wahrscheinlichkeit der Freiraum-Hypothese gering.

In Abbildung 6.10 sind die Wahrscheinlichkeitsverläufe der drei Zustände (Links L ,

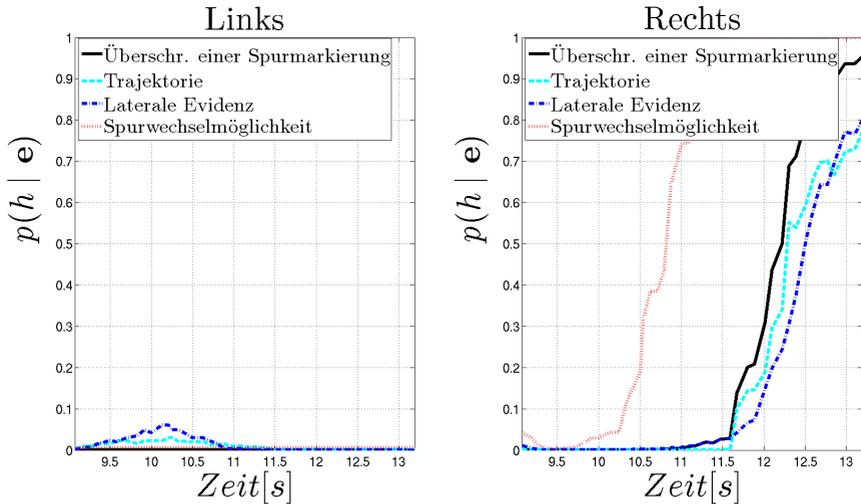


Abbildung 6.9: Verlauf der Wahrscheinlichkeiten der Grundhypothesen

Rechts R , Folgen F) der *Spurwechsel*-Hypothese dargestellt (s. Kap. 4.3.3.2, Abb. 4.16). Das vorausfahrende Objekt folgt zuerst der Spur. Die Wahrscheinlichkeit des Zustandes F bis zum Zeitpunkt $t \approx 11.5s$ beträgt 100%. Führt das Objekt ein Spurwechselmanöver nach rechts durch, so steigt die Wahrscheinlichkeit der entsprechenden Klasse R .

Das Gesamtergebnis des Erkennungsmoduls ist in Abbildung 6.11 dargestellt. Es wird nicht der Verlauf der einzelnen Wahrscheinlichkeiten pro Fahrmanöver, sondern die Entscheidung des Erkennungsmoduls veranschaulicht (s. Kap. 4.3.3.3, Abb. 4.17). Da die Zykluszeit der eingesetzten Entwicklungsumgebung $T_{Zyklus} = 0.42s$ beträgt ist eine Klassifikation zwischen den Zyklen nicht möglich. Zum Zeitpunkt $t \approx 12.3s$ wird ein Ausschler-Manöver erkannt, da die Wahrscheinlichkeit für dieses größer als der Schwellenwert $S = 65\%$ ist. Auf der rechten Achse ist das Ergebnis der Klassifikation des ACC-Systems dargestellt. Da das Objekt ausschert wird dieses für ein ACC-System „nicht relevant“. Diese Entscheidung wird, im Vergleich zum Ergebnis der Klassifikation des Erkennungsmoduls, $\Delta t \approx 1s$ später getroffen.

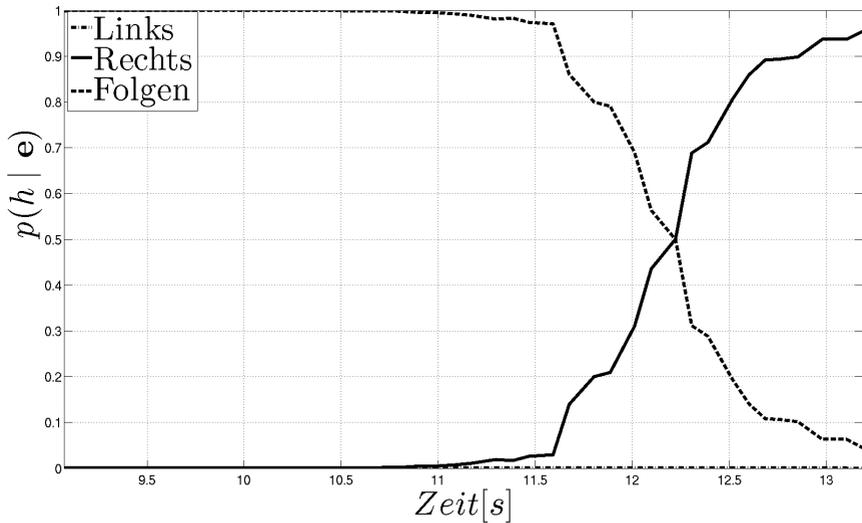


Abbildung 6.10: Verlauf der Wahrscheinlichkeit der Hypothese *Spurwechsel*

6.3.2 Gesamtergebnis der Online-Evaluierung

Das Erkennungsmodul wurde in mehreren Versuchsfahrten für die in den vorherigen Kapiteln beschriebene Systemauslegung evaluiert. Die Dauer des gesamten Versuchs betrug 15h. Die Ergebnisse werden im Folgenden dargestellt.

Während der gesamten Versuchsfahrten wurden insgesamt 1420 Fahrmanöver vom Fahrmanöver-Erkennungsmodul klassifiziert und durch das Evaluierungs-Modul evaluiert. Dabei wurden 1191 Manöver richtig erkannt, 76 führten zu „false positives“ und 153 zu „false negatives“. Abbildung 6.12 (links) zeigt die Manöver-Statistik des gesamten Versuchs.

Die Anzahl der einzelnen Manöver, aufgeteilt in Kategorien, ist in Abbildung 6.12 (rechts) dargestellt. Es wurden insgesamt 320 Ein- und 300 Ausschler-Manöver des Ego-Fahrzeuges klassifiziert. Die Objekte führten während der Versuchsfahrt 194 Ein- und 377 Ausschervorgänge durch.

Um die Erkennungsleistung zu demonstrieren, wurde nicht nur das Ergebnis der Klassifikation evaluiert. Zusätzlich wurde der Zeitunterschied Δt zwischen dem

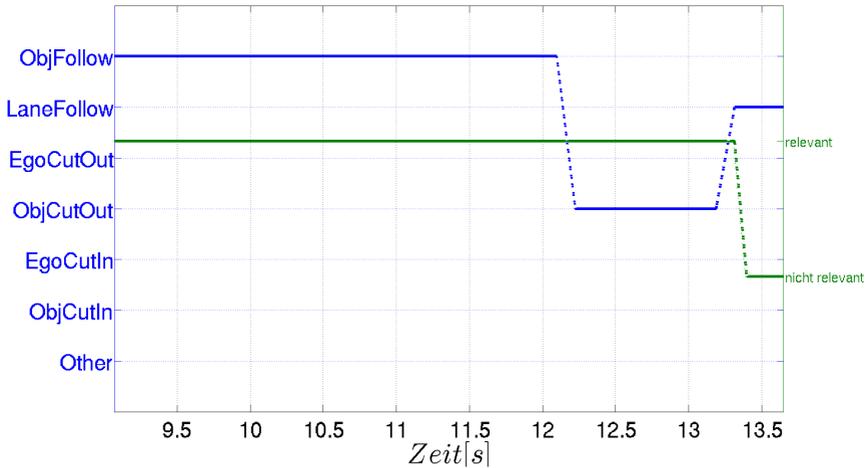


Abbildung 6.11: Gesamtergebnis des Erkennungsmoduls

Zeitpunkt, zu welchem das Erkennungsmodul ein Manöver klassifiziert und dem Zeitpunkt zu welchem ein ACC-System die Objekte als „*relevant*“ oder „*nicht relevant*“ einstuft, berechnet. Sind die Zeiten negativ, so bedeutet dies, dass die Manöver vom Erkennungsmodul, im Vergleich zum ACC-System, früher erkannt wurden.

Abbildung 6.13 zeigt die Histogramme der berechneten Zeitdifferenzen Δt , aufgeteilt nach Fahrmanöver. Die Fahrmanöver wurden im Vergleich zum ACC-System im Durchschnitt immer früher erkannt. Dies ist an dem berechneten Erwartungswert μ zu sehen. Die Standardabweichung ist bei allen Manövern in etwa gleich und liegt bei ca. $\sigma = 550ms$.

Die aus diesen Fahrmanövern ermittelte Statistik spiegelt die Funktionsweise eines ACC-Systems wieder. Aus Komfort- und Sicherheitsgründen stuft ein ACC-System die einscherenden Objekte früh als „*relevant*“ ein. Die ausscherenden Objekte werden dementsprechend spät als „*nicht relevant*“ klassifiziert. Dies ist deutlich an den berechneten Zeitdifferenzen Δt zu sehen (Abb. 6.13, Vergleich von oben nach unten). Außerdem ist der Zeitgewinn Δt für Ein- und Ausschervorgänge des Ego-Fahrzeuges im Vergleich zu den Ein- und Ausschervorgängen des Objektes nochmal deutlich geringer (Abb. 6.13, Vergleich von links nach rechts). Dies hängt mit der besseren Vorhersage der Fahrzeugbewegung des Ego-Fahrzeuges zu-

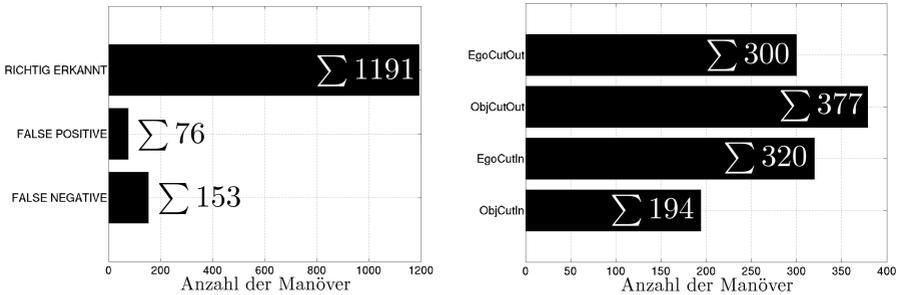


Abbildung 6.12: Fahrmanöver-Statistik (links: Fehlerstatistik, rechts: Fahrmanöver aufgeteilt nach der Kategorie)

sammen, da hierfür genauere Daten gemessen werden können. Für die Objekte liegen lediglich Schätzwerte, die aus Sensordaten abgeleitet werden, vor.

Tabelle 6.2 stellt die wichtigsten Ergebnisse der Evaluierung dar. Zusammenfassend lässt sich sagen, dass die Funktion des Erkennungsmoduls mit den durchgeführten Fahrversuchen nachgewiesen wurde. Wie man an dem berechneten Zeitunterschied Δt sieht, ist die Erkennungsleistung im Vergleich zum Ergebnis der Klassifikation eines ACC-Systems gut. Dieser liegt im Mittel für alle Fahrmanöver bei $\Delta t = -0.603s$. Die Anzahl der vom Evaluierungsmodul erkannten Fehlklas-

	Versuchsfahrt	
	Anzahl	$E(\Delta t)[s]$
EgoCutOut	300	-0.307
ObjCutOut	377	-1.189
EgoCutIn	320	-0.155
ObjCutIn	194	-0.666
	Σ 1191	-0.603
	Fehler	
„false positive“	76	–
„false negative“	153	–

Tabelle 6.2: Übersicht der Fahrmanöver-Statistik

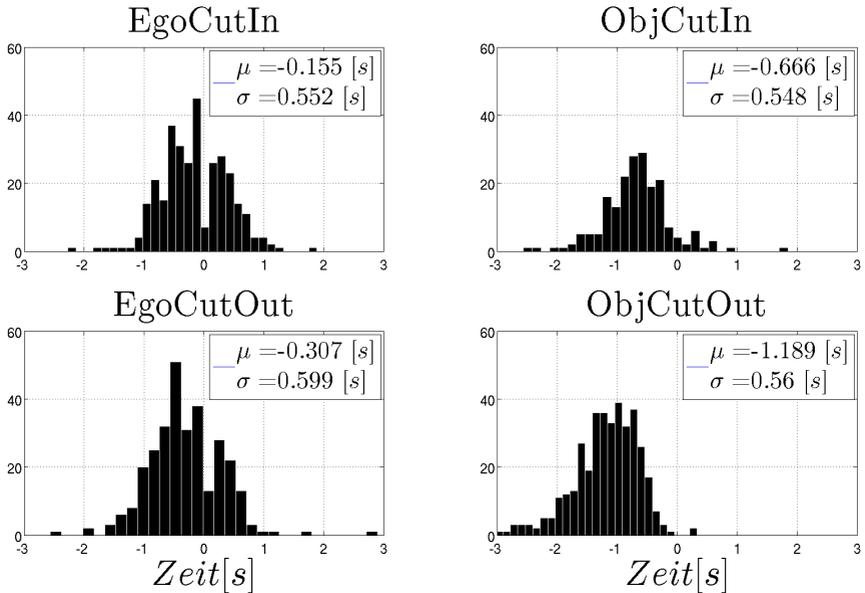


Abbildung 6.13: Statistik der berechneten Zeiten Δt pro Fahrmanöver

sifikationen liegt bei 229. Dies entspricht 16,1% aller erkannten Manöver. Die aufgetretenen Fehler und deren Ursachen sowie verschiedene Verbesserungsvorschläge werden in dem nächsten Kapitel ausführlich diskutiert.

6.3.3 Fehlerursachen

Wie in dem vorherigen Kapitel vorgestellt, traten Klassifikationsfehler wie „*false positive*“ und „*false negative*“ während der einzelnen Fahrten bei den insgesamt 15h umfassenden Fahrversuchen auf. Bei einem offensichtlichen Fehler des Erkennungsmoduls konnte automatisiert eine Sequenz (in der Regel nur 15s lang) zusätzlich abgespeichert werden. Diese Fehler konnten anhand der aufgenommenen Sequenzen analysiert werden. Bei den Analysen konnten drei Fehlerursachen identifiziert werden:

- fehlerhafte Eingangsdaten
- falsche Parametrierung des Bayes-Netzes
- fehlerhafte Festlegung eines Schwellenwertes S bei der Systemauslegung (hier 65%)

Bei den fehlerhaften Eingangsdaten handelt es sich um Spur- oder Objektdaten. Sind diese fehlerbehaftet, so werden inkonsistente Situationsmerkmale berechnet, die zwangsläufig zu Klassifikationsfehlern führen müssen. Bei den Spurdaten handelt es sich um:

- Fehler bei der Schätzung des lateralen Abstands und Krümmung der realen Spur,
- Detektion von Phantom-Spurmarkierungen und
- Beeinträchtigung der Spurerkennung durch Witterungseinflüsse.

Bei den Objektdaten handelt es sich um ungenügend genauen Schätzungen von:

- Objektposition und
- Objekteigenschaften (primär der Breiten).

Bei dem hier vorgestellten Bayes-Netz wurden die Parameter manuell gewählt. Die manuelle Auslegung ist nicht für alle Anwendungen optimal. Die Analyse ergab folgendes Bayes-Netz Fehlverhalten, das mit der Parameterwahl direkt zusammenhängt:

- einige Spurwechselmanöver führten bei richtigen Eingangsdaten zu keinem Anstieg der Wahrscheinlichkeiten, so dass diese nicht erkannt wurden,
- andererseits führten manche Fahrmanöver zu einem schnellen Anstieg der Wahrscheinlichkeiten, so dass ein Manöver erkannt wurde, obwohl keins stattgefunden hat.

Die dritte Fehlerursache ist die Auswahl eines Schwellenwertes bei der Auslegung des Systems. Dabei konnte folgendes Systemverhalten beobachtet werden:

- Anstieg der „*false positive*“ Fälle bei zu niedrig ausgewähltem Schwellenwert und
- sinkende Erkennungsleistung bei zu hoch angesetzter Schwelle.

Eine andere Fehlerquelle ist die Fehlklassifikation des ACC-Systems, also falsche Einstufung eines Objektes als „*relevant*“ oder „*nicht relevant*“. Es ist leider nicht möglich diese Fehler zu untersuchen, so dass keine Aussage bezüglich des prozentualen Anteils dieser Fehler in der Fehlerstatistik gemacht werden kann.

Wie in den vorherigen Kapiteln bereits beschrieben, ist die Auswahl der Bayes-Netz-Parameter und des Schwellenwertes sehr schwierig. Diese hängt unter anderem vom jeweiligem Fahrerassistenzsystem ab. Fast immer muss hier ein Kompromiss zwischen der „*false positive*“ und „*false negative*“ Rate getroffen werden.

Die Fehler bzw. deren negative Auswirkungen auf die Erkennungsleistung der Fahrmanöver-Klassifikation könnten durch folgende Maßnahmen deutlich verbessert werden:

- Weiterentwicklung und Verbesserung von Erkennungs- und Fusionsalgorithmen,
- Optimierung der Bayes-Netz-Parameter durch die Anwendung von Lernmethoden und
- Optimierung des Schwellenwertes zur Abdeckung des jeweiligen Anwendungsfalls durch Funktionsentwickler.

Kapitel 7

Zusammenfassung und Ausblick

In der vorliegenden Arbeit wurde ein Ansatz zur Erkennung von Fahrmanövern in Autobahnszenarien mit objektorientierten Bayes-Netzen beschrieben. Die Grundlage dafür ist eine Erkennung von Spurwechselmanövern einzelner Objekte. Die Betrachtung von Spurwechsellvorgängen in einer Objekt-Objekt-Beziehung ermöglicht eine vollständige Modellierung von Fahrmanövern in einem Autobahnszenario.

Zunächst wurden geeignete Situationsmerkmale, die ein Spurwechselverhalten beschreiben, vorgestellt. Als Basis für die Berechnung der Merkmale dienen symmetrische, krummlinige Spurkoordinatensysteme, die für eine linke und rechte Spurmarkierung pro Objekt aufgespannt werden. Durch die Symmetrieeigenschaften wird der gleiche Verlauf der Situationsmerkmale während eines Spurwechselmanövers, in den symmetrischen Spurkoordinatensystemen, erreicht. Die Vorteile einer solchen Modellierung liegen in der Reduktion der Komplexität des Modells und einer Möglichkeit der Bildung von generischen Bayes-Netz-Objekten, welche wiederverwendet werden können. Die definierten Merkmale werden als Evidenzen ins Bayes-Netz eingefügt.

Die Modellierung von Fahrmanövern erfolgt in dieser Arbeit mit objektorientierten Bayes-Netzen. Durch die Bildung von generischen Bayes-Netz-Objekten konnte die Bayes-Netz-Struktur hierarchisch in mehrere Schichten aufgeteilt werden. Auf den ersten Ebenen wird zunächst ein Modell zur Behandlung der Sensorunsicherheit aufgestellt. Außerdem werden hier die kontinuierlichen Spurwech-

selvorgänge eines Objektes in drei Bewegungsklassen klassifiziert. Dabei kann ein Objekt der Spur folgen (Klasse F) oder die Spur nach rechts (Klasse R) bzw. links (Klasse L) verlassen. Die zu erkennenden Fahrmanöver werden in einer Objekt-Objekt-Beziehung modelliert. Durch die Permutation der Bewegungsklassen in einer solchen Beziehung entstehen neun Möglichkeiten der relativen Bewegung von Objekten zueinander (LL, LR, \dots, FR, FF). Durch die zusätzliche Information über die Position des Bezugsobjektes in der Spur ($Pos^p, p \in \{\text{links, rechts, voraus}\}$) werden 27 mögliche Fahrmanöver klassifiziert.

Nach der Definition der Bayes-Netz-Struktur werden im nächsten Schritt die Bayes-Netz-Parameter bestimmt. In dieser Arbeit erfolgt die Parametrierung des Bayes-Netzes manuell mit Hilfe der Sigmoidfunktionen. Die Auswahl geeigneter Parameter ist ein wichtiger Schritt der Modellierung, da von diesem die Erkennungsleistung des Systems abhängt. Das gesamte Bayes-Netz-Modell beinhaltet somit die Struktur und das Verhalten des Klassifikationssystems.

Im nächsten Schritt wurde in dieser Arbeit ein allgemeingültiges Modell (*Weltmodell*) zur Beschreibung einer Fahrsituation entwickelt. Dafür wurde eine Blackboard-Architektur verwendet. Das Modell ist leicht erweiterbar und entspricht allen Anforderungen zur Umsetzung auf einem Steuergerät.

Die Aufgabe des Fahrmanöver-Erkennungsmoduls ist die Berechnung der definierten Situationsmerkmale und der Bayes-Netz-Inferenz. Dies wurde erfolgreich in einem Versuchsträger umgesetzt. Wichtig für die praktische Anwendung von unterschiedlichen Klassifikatoren ist die Aufstellung einer Hypothese (Klassifikationsergebnis), ob ein Ereignis (hier Manöver) stattfinden wird oder nicht. In dieser Arbeit wurden zwei Systemauslegungen untersucht. Bei der ersten Systemauslegung wird ein Fahrmanöver prognostiziert, wenn dieses, im Vergleich zu anderen Manövern, die höchste Wahrscheinlichkeit besitzt. Bei der zweiten Systemauslegung wird ein Fahrmanöver erst dann vorhergesagt, wenn dessen Wahrscheinlichkeit größer als eine definierte Schwelle ist. Die durchgeführten Untersuchungen ergaben, dass die zweite Systemauslegung bessere Ergebnisse in Bezug auf Fehlklassifikationen liefert.

Im nächsten Schritt wurde die Erkennungsleistung des Systems für die ausgewählte Systemauslegung in mehreren Fahrversuchen untersucht und die Ergebnisse der Klassifikation evaluiert. Dafür wurde ein Zustandsautomat entwickelt, welcher die erkannten Fahrmanöver als „richtig erkannt“, „false positive“ und „false negative“ einstuft. Zusätzlich wurde der Zeitgewinn im Vergleich zur Klassifikation eines ACC-Systems mitberechnet. Die Ergebnisse wurden im Detail diskutiert. Das Klassifikationsmodul zeigte eine sehr gute Erkennungsleistung. Es wurden insgesamt 1191 Manöver richtig und 229 falsch klassifiziert. Die richtig klassifizierten Fahrmanöver wurden im Vergleich zum Ergebnis der Klassifikation eines ACC-Systems, je nach Art eines Manövers mit $|\Delta t| = 0.155s$ bis $1.189s$ früher

erkannt. Für die Fehlklassifikationen wurden die Fehlerursachen identifiziert und Lösungsvorschläge ausgearbeitet.

Der in dieser Arbeit verwendete objektorientierte Ansatz ermöglicht den Aufbau großer Modelle zur Klassifikation, deren Komplexität durch die Bildung von generischen Bayes-Netz-Objekten beherrscht werden kann. Durch das Hinzufügen neuer Situationsmerkmale kann das System leicht um weitere Klassifikationsaufgaben erweitert werden. Die objektorientierten Bayes-Netze eignen sich somit zum Aufbau komplexer Klassifikationssysteme. Die Schwierigkeit bei der Modellierung stellt die Auswahl geeigneter charakteristischer Situationsmerkmale und geeigneter Bayes-Netz-Parameter dar.

Obschon das vorgestellte Verfahren zur Erkennung von Fahrmanövern in vielen Fahrversuchen bereits gute Ergebnisse liefert, sind noch einige Verbesserungen vorstellbar:

- Um die Anzahl der Fehlklassifikationen zu reduzieren, können die Bayes-Netz-Parameter optimiert werden. Dies ist zum Beispiel durch den Einsatz von Lernmethoden möglich. Dazu bedarf es einer großen Datenbank von gelabelten Datensätzen mit welchen das Netz trainiert werden kann. Es bleibt aber immer ein Zielkonflikt zwischen den „*false positives*“ und „*false negatives*“ bestehen.
- Die temporalen Abhängigkeiten der Situationsmerkmale sollten auch untersucht werden. Diese könnten wahrscheinlich die Fehlklassifikationen reduzieren und den Zeitgewinn im Vergleich zum Ergebnis der Klassifikation eines ACC-Systems steigern. Dies kann durch den Einsatz von objektorientierten dynamischen Bayes-Netzen erreicht werden.
- Die Untersuchung und Definition neuer Situationsmerkmale könnten die Erkennungsleistung des Systems entscheidend verbessern. Dabei kann das Bayes-Netz um weitere Klassifikationsaufgaben erweitert werden.

Anhang A

Frenet Koordinaten

Die frenetschen Formeln werden zur Bestimmung der drei Basisvektoren: Tangentenvektor (\mathbf{T}), Hauptnormalenvektor (\mathbf{N}) und Binormalenvektor (\mathbf{B}) für einen Punkt auf einer stetigen Funktion $\vec{r}(t)$ benutzt [87], [88].

Diese sind folgendermaßen definiert:

$$\begin{aligned}\mathbf{T}(t) &= \frac{r'(t)}{\|r'(t)\|} \\ \mathbf{N}(t) &= \frac{\mathbf{T}'(t)}{\|\mathbf{T}'(t)\|} \\ \mathbf{B}(t) &= \mathbf{T}(t)^T \times \mathbf{N}(t)^T\end{aligned}$$

Im Folgenden wird anhand eines Beispiels die Berechnung der Basisvektoren vorgestellt. Die Funktion \vec{r} beschreibt eine Kurve im Raum.

$$\vec{r}(t) = (\cos(t), \sin(t), t)^T$$

Tangentenvektor \mathbf{T} ist die zeitliche Ableitung der Funktion \vec{r} mit anschließenden

Normierung.

$$\begin{aligned}\mathbf{T}(t) &= \frac{r'(t)}{\|r'(t)\|} \\ \mathbf{T}(t) &= \frac{(-\sin(t), \cos(t), 1)^T}{\sqrt{(-\sin^2(t) + \cos^2(t) + 1^2)}} \\ \mathbf{T}(t) &= \left(\frac{-\sin(t)}{\sqrt{2}}, \frac{\cos(t)}{\sqrt{2}}, \frac{1}{\sqrt{2}} \right)^T\end{aligned}$$

Im nächsten Schritt wird der Normalenvektor \mathbf{N} berechnet.

$$\begin{aligned}\mathbf{N}(t) &= \frac{\mathbf{T}'(t)}{\|\mathbf{T}'(t)\|} \\ \mathbf{N}(t) &= \frac{\left(\frac{-\cos(t)}{\sqrt{2}}, \frac{-\sin(t)}{\sqrt{2}}, 0 \right)^T}{\sqrt{\left(\frac{\cos^2(t)}{2} + \frac{\sin^2(t)}{2} + 0 \right)}} \\ \mathbf{N}(t) &= \frac{\left(\frac{-\cos(t)}{\sqrt{2}}, \frac{-\sin(t)}{\sqrt{2}}, 0 \right)^T}{\frac{1}{\sqrt{2}}} \\ \mathbf{N}(t) &= (-\cos(t), -\sin(t), 0)^T\end{aligned}$$

Binormalenvektor \mathbf{B} berechnet sich als Kreuzprodukt (Vektorprodukt) der zwei Vektoren \mathbf{T} , \mathbf{N} .

$$\begin{aligned}\mathbf{B}(t) &= \mathbf{T}(t)^T \times \mathbf{N}(t)^T \\ \mathbf{B}(t) &= \left(\frac{-\sin(t)}{\sqrt{2}}, \frac{\cos(t)}{\sqrt{2}}, \frac{1}{\sqrt{2}} \right)^T \times (-\cos(t), -\sin(t), 0)^T \\ \mathbf{B}(t) &= \begin{pmatrix} \frac{\cos(t)}{\sqrt{2}} \cdot 0 - \frac{1}{\sqrt{2}} \cdot -\sin(t) \\ \frac{1}{\sqrt{2}} \cdot -\cos(t) - \frac{-\sin(t)}{\sqrt{2}} \cdot 0 \\ \frac{-\sin(t)}{\sqrt{2}} \cdot -\sin(t) - \frac{\cos(t)}{\sqrt{2}} \cdot -\cos(t) \end{pmatrix} \\ \mathbf{B}(t) &= \left(\frac{\sin(t)}{\sqrt{2}}, \frac{-\cos(t)}{\sqrt{2}}, \frac{1}{\sqrt{2}} \right)^T\end{aligned}$$

In Abbildung A.1 ist das berechnete Frenet Frame für die Funktion $\vec{r}(t)$ dargestellt.

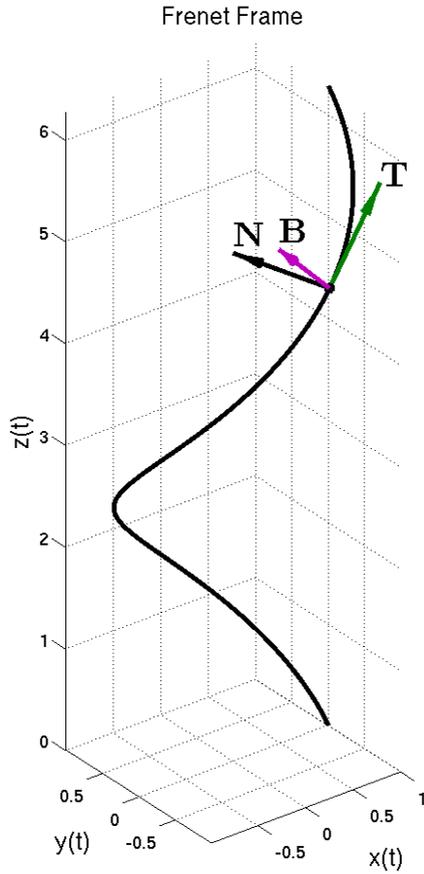


Abbildung A.1: Frenet Frame

Anhang B

Maximum Likelihood Methode

Das Finden der richtigen Bayes-Netz-Parameter ist ein sehr wichtiger Schritt beim Modellieren mit probabilistisch grafischen Modellen. Dazu können verschiedene Lernmethoden eingesetzt werden, die anhand der zur Verfügung stehenden Daten $D = (d_1, \dots, d_M)$ den Parametersatz θ schätzen [11].

Im Falle einer binären Variable $X = (true, false)$ kann die Wahrscheinlichkeitsverteilung für einen Zustand folgendermaßen angegeben werden:

$$P(x[m]|\theta) = \begin{cases} \theta & x[m] = true \\ 1 - \theta & x[m] = false \end{cases}$$

Diese wird auch als Bernoulli-Verteilung bezeichnet. Das Ziel ist das Finden der Parameter $\theta \in [0, 1]$, die am besten den Datensatz D beschreiben, also die Wahrscheinlichkeit für die gesehenen Daten maximieren. Die Wahrscheinlichkeitsverteilung der Daten (Likelihood Funktion) lässt sich als Produkt darstellen.

$$L(\theta : D) = P(D|\theta) = \prod_{m=1}^M P(x[m]|\theta)$$

Im Folgenden wird anhand eines konkreten Beispiels die vorgestellte Wahrscheinlichkeitsverteilung verdeutlicht. Bei einem Zufallsexperiment (z.B. Münzwurf) wurden folgende Daten beobachtet $L(\theta : \langle t, f, f, t, t \rangle)$. Die Zahl wird mit t und

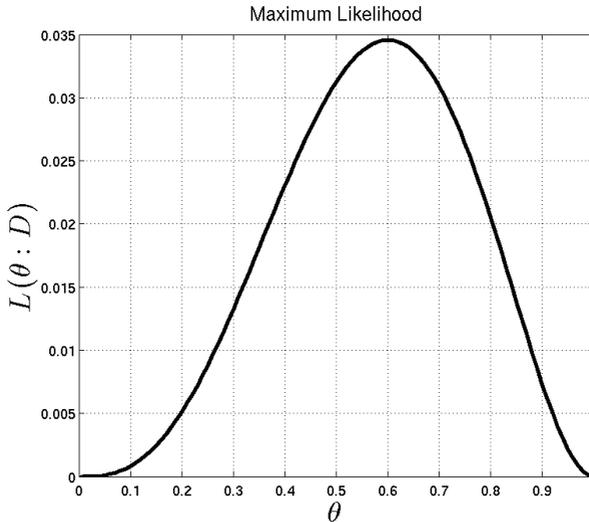


Abbildung B.1: Maximum Likelihood

Kopf mit f bezeichnet. Die Wahrscheinlichkeitsverteilung ist demnach:

$$\begin{aligned}
 P(D|\theta) &= P(t|\theta) \cdot P(f|\theta) \cdot P(f|\theta) \cdot P(t|\theta) \cdot P(t|\theta) \\
 P(D|\theta) &= \theta \cdot (1 - \theta) \cdot (1 - \theta) \cdot \theta \cdot \theta \\
 P(D|\theta) &= \theta^3 \cdot (1 - \theta)^2
 \end{aligned}
 \tag{B.1}$$

Abbildung B.1 stellt die Wahrscheinlichkeitsverteilung nach Gleichung B.1 über den Parameter $\theta \in \{0, \dots, 1\}$ dar. Es wird nach dem Parameter $\hat{\theta}$ gesucht, bei welchem diese Funktion ihr Maximum besitzt. Dies ist bei $\hat{\theta} = 0.6 = 3/5$ der Fall.

Im allgemeinen lässt sich die Maximum Likelihood Methode für eine Bernoulli-Verteilung folgendermaßen verallgemeinern.

$$L(\theta : M_t, M_f) = \theta^{M_t} \cdot (1 - \theta)^{M_f}$$

Um das Maximum der Funktion L zu bestimmen wird ein Logarithmus auf beiden

Seiten angewendet und dann die Funktion L nach θ abgeleitet.

$$\begin{aligned}l(\theta : M_t, M_f) &= M_t \cdot \log(\theta) + M_f \log(1 - \theta) \\ \frac{dl(\theta : M_t, M_f)}{d\theta} &= \frac{M_t}{\theta} - \frac{M_f}{1 - \theta} = 0 \\ \hat{\theta} &= \frac{M_t}{M_t + M_f}\end{aligned}$$

Besitzt eine Variable $X = (x_1, \dots, x_K)$, K Zustände, so können die Parameter θ_k analog mit Maximum Likelihood Methode geschätzt werden. Die gesuchte Wahrscheinlichkeitsverteilung wird auch als Multinomialverteilung bezeichnet.

$$L(\theta : D) = P(D|\theta) = \prod_{k=1}^K \theta_k^{M_k}$$

Die Lösung des Gleichungssystems ergibt:

$$\hat{\theta}_k = \frac{M_k}{\sum_{k=1}^K M_k}$$

Dabei stellt M_k die Anzahl der beobachteten Daten im Zustand k dar.

Literaturverzeichnis

- [1] T. Batz, “Ausweichen im Gleichtakt,” <http://www.archiv.fraunhofer.de/archiv/pi-2005/presse/presseinformationen/2008/11/Mediendienst112008Thema2.html>, November 2008.
- [2] Autobild, “Wie viel Hilfe brauchen wir?” <http://www.autobild.de/artikel/fahrerassistenzsysteme-teil-1-1739556.html>, Mai 2011.
- [3] S. J. Russell and P. Norvig, *Artificial Intelligence: A Modern Approach*. Pearson Education, 2003.
- [4] S. Thrun and P. Norvig, “Introduction to Artificial Intelligence,” <https://www.ai-class.com/>, 2011.
- [5] I. Dagli, *Erkennung von Einscherer-Situationen für Abstandsregeltempomaten*. Dissertation, Februar 2005.
- [6] I. Dagli and D. Reichardt, “Motivation-based approach to behavior prediction,” in *Intelligent Vehicle Symposium, 2002. IEEE*, vol. 1, june 2002, pp. 227 – 233 vol.1.
- [7] I. Dagli, G. Breuel, and H. Schittenhelm, “Einscherer-Erkennung mit erweiterter Umgebungserfassung - Eine Machbarkeitsstudie / Detection of cutting-in vehicles - A feasibility study,” in *Innovativer Kfz-Insassen- und Partnerschutz - Fahrzeugsicherheit 2010*, ser. VDI-Berichte. VDI Nachrichten, november 2003, pp. 287–300.
- [8] I. Dagli, M. Brost, and G. Breuel, “Action recognition and prediction for driver assistance systems using dynamic belief networks,” in *Agent Technologies, Infrastructures, Tools, and Applications for E-Services*, ser. Lecture Notes in Computer Science. Springer Berlin / Heidelberg, 2003, vol. 2592, pp. 179–194.

- [9] J. Pearl, *Probabilistic reasoning in intelligent systems: networks of plausible inference*. Morgan Kaufmann Publishers, 1988.
- [10] F. V. Jensen and N. D. Thomas, *Bayesian Networks and Decision Graphs*, ser. Information Science and Statistics. Springer, 2007.
- [11] N. Friedman and D. Koller, *Probabilistic Graphical Models: Principles and Techniques*. The MIT Press, 2009.
- [12] D. Koller, “Probabilistic Graphical Models,” <http://www.opencourseonline.com/playlist>, 2012.
- [13] P. Dasgupta, “Lecture Series on Artificial Intelligence,” <http://freevidelectures.com/Course/2273/Artificial-Intelligence-II>, <http://nptel.iitm.ac.in/video.php?subjectId=106105079>, 2004.
- [14] S. L. Lauritzen and D. J. Spiegelhalter, “Local Computations with Probabilities on Graphical Structures and Their Application to Expert Systems,” *Journal of the Royal Statistical Society. Series B (Methodological)*, vol. 50, no. 2, pp. 157–224, 1988.
- [15] F. Jensen, *Implementation Aspects of Various Propagation Algorithms in Hugin*. University of Aalborg, Institute for Electronic Systems, Department of Mathematics and Computer Science, 1994.
- [16] S. L. Lauritzen, “The EM algorithm for graphical association models with missing data,” *Computational Statistics and Data Analysis*, vol. 19, pp. 191–201, 1995.
- [17] P. Spirtes, C. Glymour, and R. Scheines, *Causation, Prediction, and Search*, 2nd ed. MIT press, 2000.
- [18] D. Koller and A. Pfeffer, “Object-oriented Bayesian networks,” in *Proceedings of the 13th Annual Conference on Uncertainty in AI (UAI)*, 1997, pp. 302–313, winner of the Best Student Paper Award.
- [19] H. Winner, S. Hakuli, and G. Wolf, *Handbuch Fahrerassistenzsysteme. Grundlagen, Komponenten und Systeme für aktive Sicherheit und Komfort*. Vieweg+Teubner, 2009.
- [20] Mercedes-Benz Deutschland, “Techcenter,” <http://www.mercedes-benz.de>.
- [21] J. Naranjo, C. Gonzalez, R. Garcia, and T. de Pedro, “Lane-Change Fuzzy Control in Autonomous Vehicles for the Overtaking Maneuver,” *Intelligent Transportation Systems, IEEE Transactions on*, vol. 9, no. 3, pp. 438–450, sept. 2008.

- [22] T. Huhnhausen, I. Dengler, A. Tamke, T. Dang, and G. Breuel, "Maneuver recognition using probabilistic finite-state machines and fuzzy logic," in *Intelligent Vehicles Symposium (IV)*, IEEE, june 2010, pp. 65–70.
- [23] E. Vidal, F. Thollard, C. de la Higuera, F. Casacuberta, and R. Carrasco, "Probabilistic finite-state machines - part i," *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. 27, no. 7, pp. 1013–1025, july 2005.
- [24] E. Vidal, F. Thollard, C. de la Higuera, F. Casacuberta, and R. Carrasco., "Probabilistic finite-state machines - part ii," *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. 27, no. 7, pp. 1026–1039, july 2005.
- [25] S. Habenicht, H. Winner, S. Bone, F. Sasse, and P. Korzenietz, "A maneuver-based lane change assistance system," in *Intelligent Vehicles Symposium (IV)*, 2011 IEEE, june 2011, pp. 375–380.
- [26] C. Blaschke, J. Schmitt, and B. Färber, "Fahrmanöver-prädiktion über canbus daten," in *Fahrer im 21. Jahrhundert. Human Machine Interface*. VDI-Bericht. Düsseldorf: VDI-Verlag GmbH, 2007, pp. 165–178.
- [27] W. He, X. Wang, G. Chen, M. Guo, T. Zhang, P. Han, and R. Zhang, "Monocular based lane-change on scaled-down autonomous vehicles," in *Intelligent Vehicles Symposium (IV)*, 2011 IEEE, june 2011, pp. 144–149.
- [28] J. Schneider, A. Wilde, and K. Naab, "Probabilistic approach for modeling and identifying driving situations," in *Intelligent Vehicles Symposium, 2008 IEEE*, june 2008, pp. 343–348.
- [29] H. Amata, C. Miyajima, T. Nishino, N. Kitaoka, and K. Takeda, "Prediction model of driving behavior based on traffic conditions and driver types," in *Intelligent Transportation Systems, 2009. ITSC '09. 12th International IEEE Conference*, oct. 2009, pp. 1–6.
- [30] M. Platho and J. Eggert, "Deciding what to inspect first: Incremental situation assessment based on information gain," in *Intelligent Transportation Systems (ITSC), 15th International IEEE Conference on*, 2012, pp. 888–893.
- [31] M. Platho, H. Gross, and J. Eggert, "Traffic situation assessment by recognizing interrelated road users," in *Intelligent Transportation Systems (ITSC), 15th International IEEE Conference on*, 2012, pp. 1339–1344.
- [32] R. Schubert, K. Schulze, and G. Wanielik, "Situation Assessment for Automatic Lane-Change Maneuvers," *Intelligent Transportation Systems*, vol. 11, no. 3, pp. 607–616, sept. 2010.

- [33] R. Schubert and G. Wanielik, "A unified bayesian approach for tracking and situation assessment," in *Intelligent Vehicles Symposium*, june 2010, pp. 738–745.
- [34] R. Schubert and G. Wanielik, "A Unified Bayesian Approach for Object and Situation Assessment," *Intelligent Transportation Systems Magazine*, vol. 3, no. 2, pp. 6–19, summer 2011.
- [35] R. Schubert and G. Wanielik, "Empirical evaluation of a unified Bayesian object and situation assessment approach for lane change assistance," in *Intelligent Transportation Systems*, oct. 2011, pp. 1471–1476.
- [36] R. Schubert, "Evaluating the Utility of Driving: Toward Automated Decision Making Under Uncertainty," *Intelligent Transportation Systems, IEEE Transactions on*, vol. 13, no. 1, pp. 354–364, March 2012.
- [37] T. Huang, D. Koller, J. Malik, G. Ogasawara, B. Rao, S. Russell, and J. Weber, "Automatic symbolic traffic scene analysis using belief networks," in *Proceedings 12th national conference in AI*. AAAI Press, 1994, pp. 966–972.
- [38] G. Rigas, C. Katsis, P. Bougia, and D. Fotiadis, "A reasoning-based framework for car driver's stress prediction," in *Control and Automation, 2008 16th Mediterranean Conference on*, june 2008, pp. 627–632.
- [39] J. Zhang and B. Roessler, "Situation analysis and adaptive risk assessment for intersection safety systems in advanced assisted driving," in *Autonome Mobile Systeme 2009*. Springer Berlin Heidelberg, 2009, pp. 249–258.
- [40] D. Meyer-Delius, J. Sturm, and W. Burgard, "Regression-based online situation recognition for vehicular traffic scenarios," in *Intelligent Robots and Systems. IROS'09.*, oct. 2009, pp. 1711–1716.
- [41] S. Lefevre, C. Laugier, and J. Ibanez-Guzman, "Risk assessment at road intersections: Comparing intention and expectation," in *Intelligent Vehicles Symposium (IV), IEEE*, 2012, pp. 165–171.
- [42] S. Lefevre, J. Ibanez-Guzman, and C. Laugier, "Evaluating risk at road intersections by detecting conflicting intentions," in *Intelligent Robots and Systems (IROS), IEEE/RSJ International Conference on*, 2012, pp. 4841–4846.
- [43] N. Oliver and A. Pentland, "Graphical models for driver behavior recognition in a smartcar," in *Intelligent Vehicles Symposium, 2000. IV 2000. Proceedings of the IEEE*, 2000, pp. 7–12.

- [44] M. Brand, “Coupled hidden models for modeling interacting process,” in *Neural Computation*, November 1996.
- [45] P. Boyraz, M. Acar, and D. Kerr, “Signal modelling and hidden markov models for driving manoeuvre recognition and driver fault diagnosis in an urban road scenario,” in *Intelligent Vehicles Symposium*, june 2007, pp. 987–992.
- [46] C. Stiller, G. Farber, and S. Kammel, “Cooperative cognitive automobiles,” in *Intelligent Vehicles Symposium*, june 2007, pp. 215–220.
- [47] M. Richardson and P. Domingos, “Markov logic networks,” in *Machine Learning*, vol. 62, 2006, pp. 107–136.
- [48] A. Sathyanarayana, P. Boyraz, and J. Hansen, “Driver behavior analysis and route recognition by hidden markov models,” in *Vehicular Electronics and Safety, 2008. ICVES 2008. IEEE International Conference on*, sept. 2008, pp. 276–281.
- [49] H. Stübing, J. Firl, and S. Huss, “A two-stage verification process for car-to-x mobility data based on path prediction and probabilistic maneuver recognition,” in *Vehicular Networking Conference (VNC), IEEE*, 2011, pp. 17–24.
- [50] J. Firl and Q. Tran, “Probabilistic maneuver prediction in traffic scenarios,” in *European Conference on Mobile Robots (ECMR)*, 2011.
- [51] J. Firl, H. Stübing, and A. S. Huss, “Ein konzept zur plausibilitätsprüfung von car-to-x mobilitätsdaten basierend auf pfadprädiktionen und hidden markov models,” in *Automotive meets Electronics (AmE)*, 2012.
- [52] J. Firl, H. Stübing, S. Huss, and C. Stiller, “Predictive maneuver evaluation for enhancement of car-to-x mobility data,” in *Intelligent Vehicles Symposium (IV), IEEE*, 2012, pp. 558–564.
- [53] H. Berndt, J. Emmert, and K. Dietmayer, “Continuous driver intention recognition with hidden markov models,” in *Intelligent Transportation Systems, 2008. ITSC 2008. 11th International IEEE Conference on*, oct. 2008, pp. 1189–1194.
- [54] D. Meyer-Delius, C. Plagemann, and W. Burgard, “Probabilistic situation recognition for vehicular traffic scenarios,” in *Robotics and Automation, 2009. ICRA '09. IEEE International Conference on*, may 2009, pp. 459–464.

- [55] T. Kumagai, Y. Sakaguchi, M. Okuwa, and M. Akamatsu, "Prediction of driving behavior through probabilistic inference," in *Proceedings of the Eighth International Conference on Engineering Applications of Neural Networks*, 2003.
- [56] Y. Kishimoto and K. Oguri, "A modeling method for predicting driving behavior concerning with driver's past movements," in *Vehicular Electronics and Safety*, sept. 2008.
- [57] J. M. Nigro and M. Rombaut, "IDRES: A rule-based system for driving situation recognition with uncertainty management," *Information Fusion*, vol. 4, no. 4, pp. 309–317, Dec. 2003. [Online]. Available: [http://dx.doi.org/10.1016/S1566-2535\(03\)00042-3](http://dx.doi.org/10.1016/S1566-2535(03)00042-3)
- [58] A. Hermann and J. Desel, "Driving situation analysis in automotive environment," in *Vehicular Electronics and Safety, 2008. ICVES 2008. IEEE International Conference on*, sept. 2008, pp. 216 –221.
- [59] A. Polychronopoulos, C. Koutsimanis, M. Tsogas, and A. Amditis, "Prediction of unintentional lane departure using evidence theory," in *Information Fusion, 2005 8th International Conference on*, vol. 2, july 2005, p. 8 pp.
- [60] M. Tsogas, A. Polychronopoulos, N. Floudas, and A. Amditis, "Situation refinement for vehicle maneuver identification and drivers intention prediction," in *Information Fusion, 2007 10th International Conference on*, july 2007, pp. 1–8.
- [61] M. Tsogas, X. Dai, G. Thomaidis, P. Lytrivis, and A. Amditis, "Detection of maneuvers using evidence theory," in *Intelligent Vehicles Symposium, 2008 IEEE*, june 2008, pp. 126 –131.
- [62] D. Gruyer, A. Rakotonirainy, and J. Vrignon, "The use of belief theory to assess driver's vigilance," in *Australasian Road Safety Research, Policing and Education Conference*, Wellington NZ, 2005.
- [63] U. Dogan, H. Edelbrunner, and I. Iossifidis, "Towards a driver model: Preliminary study of lane change behavior," in *Intelligent Transportation Systems, 2008. ITSC 2008. 11th International IEEE Conference on*, oct. 2008, pp. 931 –937.
- [64] R. Tomar, S. Verma, and G. Tomar, "Prediction of lane change trajectories through neural network," in *Computational Intelligence and Communication Networks (CICN), 2010 International Conference on*, nov. 2010, pp. 249 –253.

- [65] A. Doshi and M. Trivedi, "A comparative exploration of eye gaze and head motion cues for lane change intent prediction," in *Intelligent Vehicles Symposium, 2008 IEEE*, june 2008, pp. 49–54.
- [66] A. Doshi and M. Trivedi., "On the Roles of Eye Gaze and Head Dynamics in Predicting Driver's Intent to Change Lanes," *Intelligent Transportation Systems, IEEE Transactions on*, vol. 10, no. 3, pp. 453–462, sept. 2009.
- [67] B. Morris, A. Doshi, and M. Trivedi, "Lane change intent prediction for driver assistance: On-road design and evaluation," in *Intelligent Vehicles Symposium (IV), 2011 IEEE*, june 2011, pp. 895–901.
- [68] M. Tipping and A. Faul, "Fast marginal likelihood maximisation for sparse Bayesian models," 2003. [Online]. Available: <http://citeseer.ist.psu.edu/tipping03fast.html>
- [69] C. Cortes and V. Vapnik, "Support-vector networks," in *Machine Learning*, 1995, pp. 273–297.
- [70] J. McCall, M. Trivedi, D. Wipf, and B. Rao, "Lane change intent analysis using robust operators and sparse bayesian learning," in *Computer Vision and Pattern Recognition - Workshops, 2005. CVPR Workshops. IEEE Computer Society Conference on*, june 2005, p. 59.
- [71] J. McCall, D. Wipf, M. Trivedi, and B. Rao, "Lane Change Intent Analysis using Robust Operators and Sparse Bayesian Learning," *Intelligent Transportation Systems, IEEE Transactions on*, vol. 8, no. 3, pp. 431–440, sept. 2007.
- [72] S. Cheng and M. Trivedi, "Turn-Intent Analysis Using Body Pose for Intelligent Driver Assistance," *Pervasive Computing, IEEE*, vol. 5, no. 4, pp. 28–37, oct.-dec. 2006.
- [73] J. McCall and M. Trivedi, "Human behavior based predictive brake assistance," in *Intelligent Vehicles Symposium, 2006 IEEE*, 2006, pp. 8–12.
- [74] M. Trivedi and J. McCall, "Driver Behavior and Situation Aware Brake Assistance for Intelligent Vehicles," *Proceedings of the IEEE*, vol. 95, no. 2, pp. 374–387, feb. 2007.
- [75] M. Vlachos, G. Kollios, and D. Gunopulos, "Discovering similar multidimensional trajectories," in *Data Engineering, Proceedings. 18th International Conference on*, 2002, pp. 673–684.
- [76] H. Fashandi and A. Moghaddam, "A new rotation invariant similarity measure for trajectories," in *Computational Intelligence in Robotics and Automation (CIRA)*, 2005, pp. 631–634.

- [77] C. Hermes, C. Wöhler, K. Schenk, and F. Kummert, “Long-term vehicle motion prediction,” in *Intelligent Vehicles Symposium (IV)*, 2009, pp. 652–657.
- [78] E. Käfer, C. Hermes, C. Wöhler, H. Ritter, and F. Kummert, “Recognition of situation classes at road intersections,” in *Robotics and Automation (ICRA)*, 2010, pp. 3960–3965.
- [79] C. Otto and F. Leon, “Long-term trajectory classification and prediction of commercial vehicles for the application in advanced driver assistance systems,” in *American Control Conference (ACC)*, 2012, pp. 2904–2909.
- [80] Automobile, “Adaptive cruise control with cut-in prediction,” <http://rumors.automobilemag.com/honda-demonstrates-automatic-emergency-braking-green-wave-and-i-acc-technologies-184295.html#ixzz2Ed8sxdcf>, Nov 2012.
- [81] A. Tamke, T. Dang, and G. Breuel, “A flexible method for criticality assessment in driver assistance systems,” in *Intelligent Vehicles Symposium*, 2011, pp. 697 – 702.
- [82] A. L. Madsen, F. Jensen, U. Kjærulff, and M. Lang, “The Hugin Tool for Probabilistic Graphical Models,” *International Journal on Artificial Intelligence Tools*, vol. 14, no. 3, pp. 507–544, 2005.
- [83] HUGINEXPERT, “Introduction to Hugin Expert’s Bayesian network development environment,” <http://www.hugin.com/developer>.
- [84] D. Kasper, G. Weidl, T. Dang, G. Breuel, A. Tamke, and W. Rosenstiel, “Object-oriented Bayesian networks for detection of lane change maneuvers,” in *Intelligent Vehicles Symposium (IV), 2011 IEEE*, june 2011, pp. 673 –678.
- [85] D. Kasper, G. Weidl, T. Dang, A. Tamke, G. Breuel, and W. Rosenstiel, “Erkennung von Fahrmanövern mit objektorientierten Bayes-Netzen,” in *7. Workshop. Fahrerassistenzsysteme. FAS2011*, März 2011, pp. 133–144.
- [86] D. Kasper, G. Weidl, G. Breuel, T. Dang, A. Tamke, and W. Rosenstiel, “Object-Oriented Bayesian Networks for Detection of Lane Change Maneuvers,” in *IEEE Intelligent Transportation Systems Magazine*, 2012.
- [87] I. Bronstein, K. Semendjajew, G. Musiol, and H. Muehlig, *Taschenbuch der Mathematik*. Deutsch Harri GmbH, 2008.
- [88] W. Kühnel, *Differentialgeometrie: Kurven-Flächen-Mannigfaltigkeiten*. Vieweg, 2008.

- [89] S. Thrun, W. Burgard, and D. Fox, *Probabilistic Robotics*. The MIT Press, 2005.
- [90] *Richtlinien für die Anlage von Straßen (RAS), Teil: RAS-L (Linienführung)*. Forschungsgesellschaft für Straßen- und Verkehrswesen, 1996.
- [91] H. Kasper, W. Schürba, and H. Lorenz, *Die Klotoide als Trassierungselement*. Dümmlers Verlag, 1968.
- [92] H. Natzschka, *Straßenbau: Entwurf und Bautechnik*. Vieweg+Teubner Verlag, 2011.
- [93] E. Dickmanns and A. Zapp, “A curvature-based scheme for improved road vehicle guidance by computer vision.” SPIE Conference on Mobile Robots, 1987, pp. 161–168.
- [94] M. Werling, *Ein neues Konzept für die Trajektoriengenerierung und -stabilisierung in zeitkritischen Verkehrsszenarien*. Dissertation, 2011.
- [95] H. Fritz, *Vorschrift zur Durchführung eines Fahrspurwechsels durch ein Kraftfahrzeug*. Patentschrift, DaimlerChrysler AG, 2000.
- [96] M. Galassi, J. Davies, J. Theiler, B. Gough, G. Jungman, M. Booth, and F. Rossi, *GNU Scientific Library Reference Manual - Third Edition*. Network Theory Ltd., Januar 2009.
- [97] K. Levenberg, “A method for the solution of certain non-linear problems in least squares,” *Quarterly Journal of Applied Mathematics*, vol. II, no. 2, pp. 164–168, 1944.
- [98] D. Marquardt, “An algorithm for least-squares estimation of nonlinear parameters,” *SIAM Journal on Applied Mathematics*, vol. 11, no. 2, pp. 431–441, 1963. [Online]. Available: <http://dx.doi.org/10.1137/0111030>
- [99] J. Moré, “The Levenberg-Marquardt algorithm: Implementation and theory,” in *Numerical Analysis, Lecture Notes in Mathematics 630*, Springer Verlag, 1977, pp. 105–116.
- [100] G. Weidl, A. Madsen, and S. Israelsson, “Object-Oriented Bayesian Networks for Condition Monitoring, Root Cause Analysis and Decision Support on Operation of Complex Continuous Processes: Methodology and Applications,” <http://www.ist.uni-stuttgart.de/reports/pdf/2005-1.pdf>, 2005.
- [101] DIN 1319-3, *Grundlagen der Messtechnik, Teil 3: Auswertung von Messungen einer einzelnen Messgröße; Messunsicherheit*, Mai 1996.

- [102] Continental AG, “ARS 30x Fernbereichs Radar Sensor 77 ghz,” http://www.conti-online.com/generator/www/de/de/continental/industrial_sensors/themes/download/ars_300_datenblatt_de.pdf, 2011.
- [103] F. Buschmann, R. Meunier, H. Rohnert, P. Sommerlad, and M. Stal, *Pattern-Oriented Software Architecture Volume 1: A System of Patterns*. Wiley, 1996.
- [104] H. Badino, U. Franke, and R. Mester, “Free Space Computation Using Stochastic Occupancy Grids and Dynamic Programming,” in *Workshop on Dynamical Vision, ICCV*, Rio de Janeiro, Brazil, October 2007.
- [105] U. Franke, C. Rabe, H. Badino, and S. Gehrig, “6D-Vision: Fusion of Stereo and Motion for Robust Environment Perception,” in *DAGM*, Vienna, Austria, September 2005.
- [106] A. Barth, D. Pfeiffer, and U. Franke, “Vehicle Tracking at Urban Intersections Using Dense Stereo,” in *3rd Workshop on Behaviour Monitoring and Interpretation, BMI*, Ghent, Belgium, November 2009, pp. 47–58.
- [107] A. Barth and U. Franke, “Tracking Oncoming and Turning Vehicles at Intersections,” in *ITSC*, Madeira Island, Portugal, September 2010, pp. 861–868.
- [108] A. Barth, *Vehicle Tracking and Motion Estimation Based on Stereo Vision Sequences*. Dissertation, 2010.
- [109] R. Möbius and U. Kolbe, “Multi-target multi-object tracking, sensor fusion of radar and infrared,” in *Intelligent Vehicles Symposium*, 2004.
- [110] J. Hillenbrand, *Fahrerassistenz zur Kollisionsvermeidung*. Dissertation, 2007.