

Situations- und fahreradaptives Längs- und Querführungssystem für den urbanen Straßenverkehr

Dissertation

zur Erlangung des akademischen Grades

Doktoringenieurin (Dr.-Ing.)

von Dipl.-Ing. Maike Wall (geb. Beenken)
geb. am 12.02.1986 in Schwäbisch Hall

genehmigt durch die Fakultät für Maschinenbau
der Otto-von-Guericke-Universität Magdeburg

Gutachter:

Jun.-Prof. Dr.-Ing. Stephan Schmidt
Prof. Dr. Frank Köster

Promotionskolloquium am 11. Juni 2020

Die Ergebnisse, Meinungen und Schlüsse dieser Dissertation sind nicht notwendigerweise die der Volkswagen Aktiengesellschaft.

Veröffentlichungen über den Inhalt der Arbeit sind nur mit schriftlicher Genehmigung der Volkswagen Aktiengesellschaft zugelassen.

Zusammenfassung

Durch aktuelle Fahrerassistenzsysteme zur Längs- oder Querführung wird die fahrzeugführende Person bereits gut auf Landstraßen sowie Autobahnen unterstützt. Diese Arbeit liefert einen Beitrag dazu, eine kontinuierliche Unterstützung in Längs- und Querführung auf die erhöhten Anforderungen des urbanen Straßenverkehrs auszuweiten. Dafür wird ein Konzept im Sinne der kooperativen Fahrzeugführung entwickelt und realisiert, um eine Zusammenführung der Fähigkeiten von Mensch und System bei Wahrnehmung, Interpretation und Handlung zu erreichen. Über eine intuitive Schnittstelle wird es der fahrzeugführenden Person ermöglicht, mit der eigenen Wahrnehmung, Erfahrung und dem resultierenden Situationsverständnis, die maschinelle Wahrnehmung des Systems zu ergänzen. Mit einem hierzu entwickelten System erfolgt eine eindeutige Klassifikation der Verkehrssituation aus fünf als relevant identifizierten Situationen. Abhängig von der klassifizierten Situation wird aus der Fahrereingabe ein Manöverwunsch interpretiert und die Längs- und Querführung vom System durchgeführt. Somit kann der urbane Straßenverkehr durch eine integrierte Längs- und Querführung erschlossen und eine Entlastung der fahrzeugführenden Person in einem solchen Umfeld erreicht werden.

Um dem Unterstützungsbedarf verschiedener Fahrerinnen und Fahrer zu begegnen, wird aufbauend auf dem prototypisch umgesetzten System ein Ansatz entwickelt, um maschinell Fahrerprofile bestimmen zu können. Dafür werden mittels Bayes'scher Netze situationsspezifisch Fahrerintentionen prädiziert. Zur Konstruktion der Bayes'schen Netze werden die relevanten Verkehrssituationen analysiert und die kausalen Zusammenhänge im Netz abgebildet. Die A-priori- und Übergangswahrscheinlichkeiten werden aus einem Teil der Daten einer im Rahmen der Arbeit durchgeführten Realfahrstudie gelernt und anschließend zu drei Fahrerprofilen klassifiziert. Aufgrund des Vorliegens weicher Evidenz für mehrere Variablen der Netze erfolgt die Prädiktion der Fahrerintentionen mit Bayes'schen

Zusammenfassung

Netzen unter Anwendung des Big-Clique-Algorithmus. Die Validierung der Prädiktion mit den verbleibenden Datensätzen aus der Realfahrstudie zeigt die grundsätzliche Eignung des Verfahrens zum maschinellen Lernen von unterschiedlichen Fahrerprofilen und lässt den Ausblick zu, dass damit auch für weitere Fahrerassistenzsysteme gute Ergebnisse bei hinreichend großer Datenbasis erzielt werden können.

Abstract

Current driver assistance systems for longitudinal or lateral guidance already provide good support for the driver on country roads and motorways. This work contributes to extending continuous assistance in longitudinal and lateral guidance to meet the increased requirements of urban road traffic. For this purpose, a concept in the sense of Cooperative Vehicle Guidance was conceptualized and implemented into a prototype car, in order to achieve a synergy of human and system capabilities in perception, interpretation and action. An intuitive interface is provided to the driver that allows the use of his or her own perception, experience and understanding of the situation to supplement the system-based perception and request a specific maneuver. The developed system provides a classification of traffic situations, of which five were identified as relevant beforehand. Depending on the classified situation, a driver's maneuver request is interpreted by the system and longitudinal and lateral guidance is performed. In this manner, the presented integrated longitudinal and lateral guidance system makes complex urban traffic accessible and supports the driver in this environment.

In order to meet individual needs of different drivers, a machine-learning approach was developed that derives driver profiles computationally. For this purpose, situation-specific driver intentions are predicted using Bayesian networks. To construct the Bayesian networks, the relevant traffic situations were analyzed and causal relationships were mapped within the network. Urban traffic data was collected in a driving study on public roads using the prototype system. The a-priori and transition probabilities were trained from a subset of this data set and then classified into three different driver profiles. Due to the existence of soft evidence for several variables of the networks, the prediction of driver's intentions is done with Bayesian networks using the big clique algorithm. The validation of the prediction, carried out with the remaining subset of data, demonstrates the general suitability of this machine-learning-based method to derive driver profiles and

Abstract

suggests that this approach could be used for further driver assistance systems, given that sufficient data is available.

Inhaltsverzeichnis

Zusammenfassung	iii
Abstract	v
Abbildungsverzeichnis	xi
Tabellenverzeichnis	xv
Verzeichnis der verwendeten Symbole und Abkürzungen	xvii
1 Einleitung	1
1.1 Motivation	2
1.2 Zielsetzung	5
1.3 Aufbau der Arbeit	5
2 Stand der Technik	8
2.1 Fahrerassistenzsystem	8
2.2 Umfeldwahrnehmung für Längs- und Querführungssysteme	14
2.2.1 Ultraschall	15
2.2.2 Kamerasensorik	15
2.2.3 Lidar	17
2.2.4 Radar	18
2.2.5 Gegenüberstellung	19
2.2.6 Umfeldmodell	20
2.3 Assistenzsysteme zur Längs- und Querführung	21
2.3.1 Längsführungsassistenzsysteme	22
2.3.2 Querführungsassistenzsysteme	24
2.3.3 Kombinierte Längs- und Querführungsassistenzsysteme .	27
2.4 Kooperative Fahrzeugführung	28
2.4.1 Conduct-by-Wire und pieDrive	28

2.4.2	H-Mode	30
2.4.3	Digital driving	32
2.5	Fahrerintentionsprädiktion	33
3	Theoretische Grundlagen	35
3.1	Trajektorienplanung	35
3.1.1	Verfahren zur Trajektorienplanung	36
3.1.2	Kosten	37
3.2	Lernverfahren	41
3.2.1	Fuzzy-Mengen und Fuzzy-Logik	41
3.2.2	Künstliche neuronale Netze	44
3.2.3	Bayes'sche Netze	46
3.2.4	Gegenüberstellung der Verfahren	57
3.3	Gauß'sche Mischverteilungen	59
4	Situationsanalyse und Manöverinterpretation	61
4.1	Konzept einer situationsadaptiven Fahrzeugführung	61
4.2	Umfeld	63
4.2.1	Rahmenbedingungen	64
4.2.2	Anforderungen	64
4.3	Situationen	65
4.3.1	Freie Fahrt	67
4.3.2	Folgefahrt	68
4.3.3	Zufahrt auf eine Kreuzung mit Lichtsignalanlage	69
4.3.4	Stillstand	70
4.3.5	Fahrstreifenwechsel	70
4.4	Situationsklassifikation	71
4.4.1	Eingangsdaten	72
4.4.2	Transitionen	72
4.5	Manöverschnittstelle	74
4.5.1	Bedienelement	74
4.5.2	Fahrereingabe	76
4.6	Manöverinterpretation	78
4.6.1	Freie Fahrt	79
4.6.2	Folgefahrt	80
4.6.3	Zufahrt auf eine Kreuzung	81

4.6.4	Stillstand	83
4.6.5	Fahrstreifenwechsel	84
4.7	Validierung des Konzepts	84
4.8	Diskussion	88
5	Fahrverhaltensanalyse	91
5.1	Fahreradaptives Längs- und Querführungssystem	92
5.2	Fahrerintensionsprädiktion	93
5.2.1	Freie Fahrt	93
5.2.2	Weitere Situationen	100
5.3	Fahrertypabhängige Parameteranpassung	104
5.4	Erhebung der Messdaten in einer Fahrstudie	106
5.4.1	Aufbau des Versuchsfahrzeugs	106
5.4.2	Mensch-Maschine-Schnittstelle	107
5.4.3	Stichprobenbeschreibung	109
5.4.4	Versuchsdurchführung	111
5.5	Aufbereitung der Messdaten	113
5.5.1	Klassifikation der Messdaten mittels Gauß'scher Mischverteilungen	113
5.5.2	Nicht beobachtbare Größen	118
5.6	Validierung der Fahrerintensionsprädiktion	121
5.6.1	Prädiktion für die Situation <i>Freie Fahrt</i>	122
5.6.2	Prädiktion für die Situation <i>Folgefahrt</i>	125
5.6.3	Prädiktion für die Situation <i>Zufahrt auf eine Kreuzung</i>	128
5.6.4	Prädiktion für die Situation <i>Stillstand</i>	130
5.6.5	Prädiktion für die Situation <i>Fahrstreifenwechsel</i>	132
5.6.6	Übersicht über die Fahrprofile	133
5.7	Diskussion	134
6	Zusammenfassung der Arbeit und Ausblick	137
A	Grundlagen zum Rechnen mit Wahrscheinlichkeiten	140
A.1	Grundbegriffe	140
A.2	Definitionen und Regeln	141
B	Inferenz in Bayes'schen Netzen	143
B.1	Herleitung von Gleichung 3.7 zur diagnostischen Inferenz	143

Inhaltsverzeichnis

B.2 Alarmbeispiel	144
B.2.1 Beispiel: Prognostische Inferenz	144
B.2.2 Beispiel: Diagnostische Inferenz	145
C Junction-Trees für die weiteren Situationen	146
C.1 Folgefahrt	146
C.2 Zufahrt auf eine Kreuzung	147
C.3 Stillstand	148
C.4 Fahrstreifenwechsel	149
Literaturverzeichnis	151

Abbildungsverzeichnis

1.1	Unfallursachen für Unfälle mit Personenschaden im Jahr 2017 (Statistisches Bundesamt 2019)	2
1.2	Unfälle mit Personenschaden nach Ortslage im Jahr 2018 (Statistisches Bundesamt 2019)	3
2.1	Schematischer Aufbau eines Assistenzsystems	9
2.2	Einbau von Radaren früher und heute	18
2.3	Umfeldmodell für Fahrerassistenzsysteme (Knaup und Homeier 2010)	21
2.4	Kammscher Kreis und durch den Normalfahrer genutzter Bereich (Wegscheider und Prokop 2005)	22
2.5	Exemplarische Verläufe des Betrags des Hilfsmoments in Abhängigkeit von der Querablage (schematische Darstellung) (Gayko 2012)	26
2.6	Ansicht der Benutzeroberfläche des Touch-Displays (Kauer u. a. 2010)	29
2.7	Ansicht der Benutzeroberfläche des Touch-Displays (Albert 2018)	30
2.8	Geteilte und kooperative Fahrzeugsteuerung von Mensch und System (Flemisch u. a. 2008)	31
2.9	Zweistufige Hierarchie der Manöverebene	32
3.1	Trajektorienbeschreibung in Frenet-Koordinaten der Referenzkurve (Werling 2010)	36
3.2	Schematischer Aufbau eines Neurons	44
3.3	Beispielhafter Aufbau eines neuronalen Netzes	45
3.4	Beispiel für ein Bayes'sches Netz	47
3.5	Bayes'sches Netz zur Darstellung diagnostischer und prognostischer Inferenz	48
3.6	Alarmbeispiel für ein Bayes'sches Netz (Ertel 2013)	49
3.7	Ablauf Message-Passing-Algorithmus (Pearl 1986)	50

Abbildungsverzeichnis

3.8	Darstellung von <i>weicher Evidenz</i> mit einem Hilfsknoten (Xiao u. a. 2009)	51
3.9	Transformation eines Bayes'schen Netzes in einen Junction-Tree (Sucar 2015)	52
3.10	Beispiel eines einfachen Bayes'schen Netzes und des zugehörigen Junction-Tree (Barber 2003)	53
4.1	Konzept einer Fahrerassistenzfunktion im Kontext kooperativer Fahrzeugführung	62
4.2	Freie Fahrt	68
4.3	Folgefahrt	68
4.4	Zufahrt auf eine Kreuzung	69
4.5	Stillstand an einer Haltelinie	70
4.6	Fahrstreifenwechsel	71
4.7	Transitionen der Situationen	73
4.8	Vorhandene Bedienelemente	76
4.9	Abstrakte Darstellung der Manöverschnittstelle	76
4.10	Bedienelemente mit Richtungen	77
4.11	Zuordnung von Situation und Fahrereingabe zu einem Manöver	78
4.12	Im Rahmen der Arbeit implementierte Module (grün) innerhalb der Systemarchitektur	85
4.13	Modul zur Situationsklassifikation	86
4.14	Situationsklassifikation auf Messdaten einer realen Fahrt	86
4.15	Module zur Manöverinterpretation	87
4.16	Manöverinterpretation auf Messdaten einer realen Fahrt	87
5.1	Schematische Darstellung der Funktionsarchitektur mit Erweiterung um eine Fahreradaptation	92
5.2	Bayes'sches Netz für die Situation <i>Freie Fahrt</i>	94
5.3	Junction-Tree für die Situation <i>Freie Fahrt</i>	97
5.4	Bayes'sches Netz für die Situation <i>Folgefahrt</i>	100
5.5	Bayes'sches Netz für die Situation <i>Zufahrt auf eine Kreuzung</i>	101
5.6	Bayes'sches Netz für die Situation <i>Stillstand</i>	102
5.7	Bayes'sches Netz für die Situation <i>Fahrstreifenwechsel</i>	103
5.8	Versuchsfahrzeug Audi A6 Avant mit Verbauorten der Sensorik (Kreßler 2015)	107

5.9	Visualisierung einer <i>Folgefahrt</i> im mittleren Display des Kombiinstrumentes (Petermann-Stock und Werneke 2014)	108
5.10	Anzeigebeispiel: Fahrstreifenwechsel (Volkswagen AG 2016)	109
5.11	Schematischer Ablauf der Versuchsdurchführung	112
5.12	Klassifikation der Fahrpedalstellung in drei Klassen mittels Gauß'scher Mischverteilung	114
5.13	Klassifikation der Fahrzeuggeschwindigkeit in vier Klassen mittels Gauß'scher Mischverteilung	114
5.14	Klassifikation der Fahrzeugbeschleunigung in drei Klassen mittels Gauß'scher Mischverteilung	115
5.15	Klassifikation der Geschwindigkeitsvorgabe in acht Klassen mittels Gauß'scher Mischverteilung	115
5.16	Klassifikation der aktuellen Zeitlücke in drei Klassen mittels Gauß'scher Mischverteilung	116
5.17	Klassifikation der Distanz zur Haltelinie in vier Klassen mittels Gauß'scher Mischverteilung	116
5.18	Klassifikation der Distanz zum Vorderfahrzeug in drei Klassen mittels Gauß'scher Mischverteilung	116
5.19	Klassifikation der Geschwindigkeit des Vorderfahrzeug in vier Klassen mittels Gauß'scher Mischverteilung	117
5.20	Klassifikation des Querversatz in drei Klassen mittels Gauß'scher Mischverteilung	117
5.21	Klassifikation der Quergeschwindigkeit in drei Klassen mittels Gauß'scher Mischverteilung	118
5.22	Klassifikation der Zeitlücke zum nächsten Fahrzeug auf dem Nachbarfahrstreifen in drei Klassen mittels Gauß'scher Mischverteilung	118
5.23	Klassifikation der Wunschgeschwindigkeit in neun Klassen mittels Gauß'scher Mischverteilung	119
5.24	Klassifikation der Wunschzeitlücke in vier Klassen mittels Gauß'scher Mischverteilung	119
5.25	Klassifikation der Wunschkonzession zur Haltelinie in fünf Klassen mittels Gauß'scher Mischverteilung	120
5.26	Klassifikation der Wunschkonzession eines Fahrstreifenwechsels in vier Klassen mittels Gauß'scher Mischverteilung	121

5.27 Vergleich der prädizierten Wunschgeschwindigkeit zu der Referenz der Wunschgeschwindigkeit für Testdatensatz 1, Fahrprofil C (Datensatz mit der höchsten Prädiktionsrate)	123
5.28 Vergleich der prädizierten Wunschgeschwindigkeit zu der Referenz der Wunschgeschwindigkeit für Testdatensatz 6, Fahrprofil C (Datensatz mit der niedrigsten Prädiktionsrate nach Zuordnung zum Fahrprofil)	124
5.29 Vergleich der prädizierten Wunschzeitlücke zu der Referenz der Wunschzeitlücke für Testdatensatz 3, Fahrprofil B (Datensatz mit der höchsten Prädiktionsrate)	125
5.30 Vergleich der prädizierten Wunschzeitlücke zu der Referenz der Wunschzeitlücke für Testdatensatz 1, Fahrprofil B (Testdatensatz mit der niedrigsten Prädiktionsrate nach Zuordnung zum Fahrprofil)	126
5.31 Vergleich der prädizierten Wunschanhaldedistanz zur Kreuzung zu der Referenz der Anhaldedistanz für Testdatensatz 3, Fahrprofil A oder B	128
5.32 Vergleich der prädizierten Wunschanhaldedistanz zur Kreuzung zu der Referenz der Anhaldedistanz für Testdatensatz 6, Fahrprofil A oder B	129
5.33 Vergleich des prädizierten Anfahrwunsches zu der Referenz des Anfahrwunsches für Testdatensatz 1, Fahrprofil C	131
5.34 Vergleich der prädizierten Fahrstreifenwechseldauer zu der Referenz der gewünschten Fahrstreifenwechseldauer für Testdatensatz 2, Fahrprofil A	132
C.1 Junction-Tree für die Situation <i>Folgefahrt</i>	146
C.2 Junction-Tree für die Situation <i>Zufahrt auf eine Kreuzung</i>	147
C.3 Junction-Tree für die Situation <i>Stillstand</i>	148
C.4 Junction-Tree für die Situation <i>Fahrstreifenwechsel</i>	149

Tabellenverzeichnis

2.1	Grade der Automatisierung des <i>Runden Tisches Automatisiertes Fahren</i> (Gasser u. a. 2015)	13
2.2	Vergleich ausgewählter Sensortechnologien (in Anlehnung an Aue (2014); Stiller u. a. (2012))	20
3.1	Fuzzy-Operatoren (Kluge 2006)	43
3.2	Gegenüberstellung der Methoden	58
4.1	Transitionen der Situationsklassifikation	73
4.2	Zuordnung der Fahrereingabe in der Situation <i>Freie Fahrt</i>	80
4.3	Zuordnung der Fahrereingabe in der Situation <i>Folgefahrt</i>	81
4.4	Zuordnung der Fahrereingabe in der Situation <i>Kreuzung</i>	82
4.5	Zuordnung der Fahrereingabe in der Situation <i>Stillstand</i>	83
4.6	Zuordnung der Fahrereingabe in der Situation <i>Fahrstreifenwechsel</i>	84
5.1	Unterteilung in kontinuierliche und diskrete Variablen	95
5.2	Übergangswahrscheinlichkeiten für die Zufallsvariable <i>Wunschgeschwindigkeit</i> unter der Bedingung der <i>Geschwindigkeitsbegrenzung</i>	96
5.3	Übersicht der Merkmalshäufigkeit innerhalb der Stichprobe ($N=18$)	110
5.4	Übersicht des Nutzungsverhaltens von Fahrerassistenzsystemen innerhalb der Stichprobe ($N=18$)	111
5.5	Übersicht der Prädiktionsraten r_{pred} für die Situation <i>Freie Fahrt</i> über alle sechs Testdatensätze und Fahrprofile (*markiert das Fahrprofil mit der höchsten Prädiktionsrate)	125
5.6	Übersicht der Prädiktionsraten r_{pred} für die Situation <i>Folgefahrt</i> über alle sechs Testdatensätze und Fahrprofile (*markiert das Fahrprofil mit der höchsten Prädiktionsrate)	127

5.7	Übersicht der Prädiktionsraten r_{pred} für die Situation <i>Zufahrt auf eine Kreuzung</i> über alle sechs Testdatensätze und Fahrprofile (*markiert das Fahrprofil mit der höchsten Prädiktionsrate)	130
5.8	Übersicht der Prädiktionsraten r_{pred} für die Situation <i>Stillstand</i> über alle sechs Testdatensätze und Fahrprofile (*markiert das Fahrprofil mit der höchsten Prädiktionsrate)	131
5.9	Übersicht der Prädiktionsraten r_{pred} für die Situation <i>Fahrstreifenwechsel</i> über alle sechs Testdatensätze und Fahrprofile (*markiert das Fahrprofil mit der höchsten Prädiktionsrate)	133
5.10	Übersicht der Zuordnung der Fahrprofile mit der höchsten Prädiktionsrate über alle Versuchspersonen und Situationen	134
A.1	Darstellung Grundbegriffe	140

Verzeichnis der verwendeten Symbole und Abkürzungen

Lateinische Formelzeichen

Formelzeichen	Bedeutung
a_{verz}	Verzögerung
b_l	räumliche Distanz
C	Cluster
c_0	Lichtgeschwindigkeit
c_s	Schallgeschwindigkeit
d	Abstand
$disp$	Disparität
E	Erwartungswert
f_b	Brennweite
f_d	Frequenzverschiebung
J	Kostenfunktional
\mathbf{n}_r	Hauptnormaleneinheitsvektor
P	Wahrscheinlichkeit
P'	A-posteriori-Wahrscheinlichkeit
p_i^k	Eintrittswahrscheinlichkeit
r_{pred}	Prädiktionsrate
s	Querablage
t	Signallaufzeit
\mathbf{t}_r	Tangenteneinheitsvektor
\dot{r}	Relativgeschwindigkeit
r_i	Kardinalität der i-ten Zufallsvariablen
S	Separator

Verzeichnis der verwendeten Symbole und Abkürzungen

v_i^k	k-ter Zustand der i-ten Zufallsvariable
v_{ref}	Referenz Wunschgeschwindigkeit
v_{wunsch}	Prädizierte Wunschgeschwindigkeit
v_x	Geschwindigkeit in Fahrzeuginnenrichtung
w_i^j	Konfiguration der Elternknoten von x_i
\mathbf{x}	Trajektorie
x_i	i-te Zufallsvariable

Griechische Formelzeichen

Formelzeichen	Bedeutung
δ	Distanz
λ	Wellenlänge
ψ	Potential
Π_i	Menge der Elternknoten von x_i
τ	Zeitlücke
θ	Bedingte Wahrscheinlichkeit

Abkürzungen

ABS	Antiblockiersystem
ACC	Adaptive Cruise Control
ADTF	Automotive Data and Time-Triggered Framework
BAST	Bundesanstalt für Straßenwesen
CCD	Charged Coupled Device
CMOS	Complementary Metal Oxide Semiconductor
DLC	Distance-to-Line-Crossing

EM-Algorithmus	Expectation-Maximization-Algorithmus
ESP	Electronic Stability Control
FSW	Fahrstreifenwechsel
GPS	Global Positioning System
GRA	Geschwindigkeitsregelanlage
HUD	Head-Up-Display
KNN	Künstlich neuronale Netze
Lidar	Light Detection and Ranging
MFA	Multifunktionsanzeige
MLP	Multi-Layer-Perceptron
MMS	Mensch-Maschine-Schnittstelle
MV	Mensch im Verkehr
Radar	Radio Detection and Ranging
SD	Standardabweichung (engl. standard deviation)
TLC	Time-to-Line-Crossing
UR:BAN	Urbaner Raum: Benutzergerechte Assistenzsysteme und Netzmanagement
V2X	Vehicle to X

Kapitel 1

Einleitung

Mobilität ist ein ureigenes Bedürfnis des Menschen. Sie bedeutet für den Einzelnen Freiheit und Unabhängigkeit. In der Bundesrepublik Deutschland ist bereits ein hohes Maß an persönlicher Mobilität erreicht. Auf circa 83 Millionen Einwohner kommen 45,8 Millionen Personenkraftwagen (Statistisches Bundesamt 2014). Damit lässt sich mehr als jedem zweiten Bundesbürger ein Fahrzeug zurechnen. Die Erhöhung der Mobilität ermöglicht es den Menschen, zum Beispiel ortsunabhängig einer Beschäftigung nachzugehen oder auch im hohen Alter noch flexibel und unabhängig zu bleiben. Dies sind nur zwei von zahlreichen Beispielen, in denen persönliche Mobilität in der modernen Gesellschaft zur Lebensqualität beitragen kann. Der individuellen Mobilität gegenüber stehen Verkehrsunfälle als negatives Gegenstück.

Soll der Straßenverkehr für die verschiedenen Verkehrsteilnehmer komfortabler und sicherer gestaltet werden, stehen im Allgemeinen zwei Ansätze zur Verfügung. Einerseits kann das Fahrzeugumfeld durch infrastrukturelle Maßnahmen verbessert werden, andererseits kann aber auch das Fahrzeug durch unterstützende Systeme und neue Technologien erweitert werden.

Auf vielen Straßen finden sich beispielsweise profilierte Fahrstreifenmarkierungen, um den Fahrer rechtzeitig vor einem unbeabsichtigten Verlassen des Fahrstreifens zu warnen oder es sind auf Autobahnen oder in Ballungszentren Verkehrsleitsysteme eingerichtet. Infrastrukturelle Maßnahmen finden aber selten flächendeckenden Einsatz, da deren Einrichtung und auch Unterhaltung die öffentlichen Kassen stark belasten.

Daher arbeitet die Automobilindustrie an fahrzeugeigenen Systemen, um die Menschen in ihrer Fahraufgabe zu unterstützen und sie zu entlasten.

1.1 Motivation

Die aktuelle Generation von Assistenzsystemen aus den Bereichen der Quer- und Längsführung eignet sich gut für den Einsatz auf gut ausgebauten Landstraßen und Autobahnen. In diesem Umfeld können sie einen großen Beitrag zum Komfort und Entlastung der Verkehrsteilnehmer leisten. Wird das Fahrzeug allerdings im urbanen Straßenverkehr bewegt, so stehen diese Unterstützungssysteme nur eingeschränkt oder überhaupt nicht zur Verfügung. In einem solchen Umfeld ist die fahrzeugführende Person oft mit einem hohem Verkehrsaufkommen, dynamischem Verkehr und einer Flut an verschiedenen Informationen konfrontiert. Das bedeutet, dass sie trotz hoher Beanspruchung und kurzen Entscheidungszeiten das Fahrzeug sicher für sich und andere führen muss.

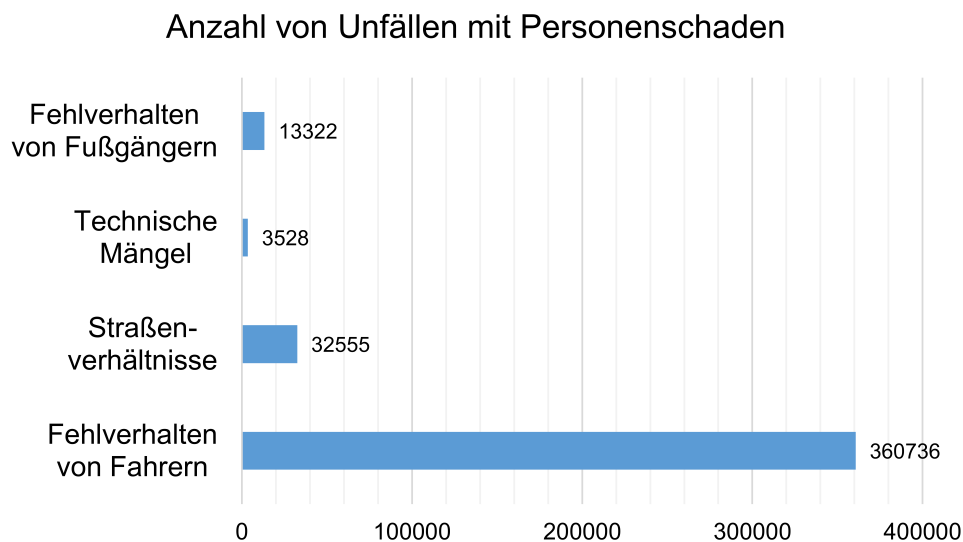


Abbildung 1.1: Unfallursachen für Unfälle mit Personenschaden im Jahr 2017 (Statistisches Bundesamt 2019)

Da dies nicht immer gelingt, treten im Straßenverkehr zahlreiche Unfälle mit sowohl Personen- als auch Sachschaden auf. Diese Zahlen sind dank technischer und infrastruktureller Entwicklungen grundsätzlich rückläufig, auch wenn im Jahr 2018 die Anzahl wieder leicht angestiegen ist. Es besteht weiterhin Potenzial, den positiven Trend zu unterstützen. Die Unfälle in der Bundesrepublik lassen sich auf vier Hauptursachen zurückführen (Statistisches Bundesamt 2019):

- Fehltragen der Fahrzeugführenden

- Straßenverhältnisse (Witterung, Sicht etc.)
- Technische Mängel
- Falsches Verhalten der Fußgänger

Im Verhältnis zu den durch das Fehlverhalten des Fahrzeugführenden verursachten Unfällen nehmen übrige Ursachen nur einen geringen Anteil an der Gesamtanzahl ein (Abbildung 1.1). Häufig liegt dieses Fehlverhalten in einer falschen Einschätzung der Geschwindigkeit und des Abstands begründet. Daher adressieren Fahrerassistenzsysteme u.a. diese Situationen, um den Fahrer darin zu unterstützen und zu entlasten.

Straßenverkehrsunfälle mit Personenschaden nach Ortslage (2018)

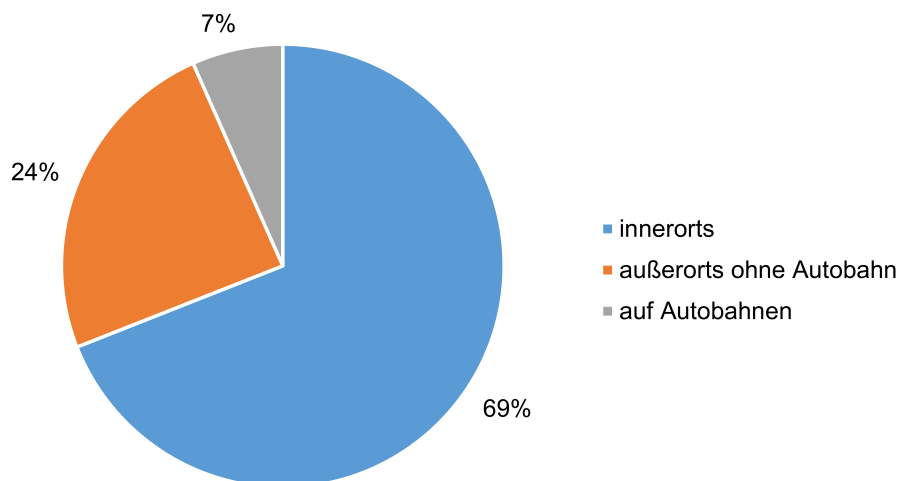


Abbildung 1.2: Unfälle mit Personenschaden nach Ortslage im Jahr 2018 (Statistisches Bundesamt 2019)

Des Weiteren zeigt die Unfallstatistik, dass sich circa zwei Drittel der Unfälle mit Personenschaden innerorts ereignen (s. Abbildung 1.2). An der Entwicklung von Systemen zur Entschärfung des Unfallschwerpunkts Kreuzung wurde bereits vor einigen Jahren in Forschungsprojekten wie *Intersafe-2* gearbeitet (Intersafe-2 2011). Durch eine gezielte Weiterentwicklung der derzeit im Markt vertretenen Fahrerassistenzsysteme im Bereich der Längs- und Querverführung mit Fokus auf den urbanen Straßenverkehr ließen sich allerdings auch viele andere Unfallarten im urbanen Umfeld adressieren.

Bei der Entwicklung von Fahrerassistenzsystemen entstanden im Laufe der Zeit eine Reihe von unabhängigen Systemen, die die fahrzeugführende Person in unterschiedlichen Situationen unterstützen. Die Situationen, in denen diese Systeme zum Einsatz kommen, können sich jedoch auch überschneiden (z.B. beim Fahrstreifenwechsel) und bieten somit Potential für Systeme, die sowohl auf die Längs- als auch Querführung wirken können. Daher wird in der vorliegenden Arbeit ein Zusammenführen der Längs- und Querführungsunterstützung angestrebt. Solche Systeme können einerseits die Bedienung für die fahrzeugführende Person erleichtern, da sie nicht mehr separate Systeme bedienen muss, andererseits können Längs- und Querführung im Zusammenspiel besser aufeinander abgestimmt werden als in unabhängigen Systemen. Beispielsweise kann im Vorfeld einer Kurve in der Längsführung verzögert werden, sodass nicht so stark quergeregelt werden muss, um mit dem Fahrzeug komfortabel um die Kurve fahren zu können. Dies erlaubt einen erweiterten Wirkungsbereich des Systems, da die Kräfte, die jeweils der Längs- und Querführung zur Verfügung stehen, durch die Synergie optimal genutzt werden können. Im genannten Beispiel wird das System im Alltag für größere Streckenanteile verfügbar und erlaubt bei Kurvenfahrten eine längere Unterstützung, bevor der Fahrer aufgrund von Systemgrenzen vollständig übernehmen muss.

Durch die Entwicklung solcher Assistenzsysteme können insbesondere im urbanen Raum die Unfallzahlen gesenkt und somit die Sicherheit der Verkehrsteilnehmenden erhöht werden. Darüber hinaus führt die Unterstützung der Fahrerin oder des Fahrers in der Längs- und Querführung zu einer Entlastung im komplexen Umfeld des innerstädtischen Verkehrs. Speziell Unerfahrene mit wenig Routine im Stadtverkehr können durch das Zusammenspiel bei der Bewegung eines Kraftfahrzeugs und der Einschätzung komplexer Situationen unterstützt werden. Eine weitere Zielgruppe, die stark von solchen Systemen profitieren könnte, ist die ältere Generation, deren Mobilität in diesem Umfeld länger erhalten bliebe. Es handelt sich dabei um eine Gruppe, die durch den demografischen Wandel immer größer werden wird, wodurch die Erhaltung der Mobilität ein unumgängliches Interesse der Gesellschaft darstellt.

1.2 Zielsetzung

Ein urbanes Umfeld stellt aufgrund der hohen Komplexität und der Vielfalt der Verkehrssituationen besondere Anforderungen an eine fahrerzentrierte Assistenzfunktion zur kontinuierlichen Längs- und Querführung. Die fahrzeugführende Person muss innerhalb kürzester Zeit Entscheidungen zur sicheren Führung ihres Fahrzeugs und zum Schutz anderer Verkehrsteilnehmer treffen. Ob die Führung eines Fahrzeugs als sicher und komfortabel empfunden wird, ist individuell sehr unterschiedlich.

Ausgehend von diesem Kontext sollen in der vorliegenden Arbeit die folgenden Forschungsfragen betrachtet werden:

- F1: Wie kann eine Fahrerin oder ein Fahrer auf dem Weg in die Stadt hinein kontinuierlich in Längs- und Querführung unterstützt werden?
- F2: Wie kann ein System zur kontinuierlichen Längs- und Querführung im urbanen Straßenverkehr für den individuellen Unterstützungsbedarf verschiedener Personen ausgelegt werden?

Dafür wird im Rahmen dieser Arbeit prototypisch ein Assistenzsystem entwickelt, welches eine fahrzeugführende Person in einem urbanen Umfeld unterstützt. Anschließend wird ein Konzept erarbeitet, mit dem sich das entwickelte System an individuelle Bedürfnisse verschiedener Menschen adaptieren lässt.

Die vorliegende Arbeit entstand im Kontext des Verbundprojekts *Urbaner Raum: Benutzergerechte Assistenzsysteme und Netzmanagement (UR:BAN)* im Teilprojekt *Kognitive Assistenz für den Schwerpunkt Sichere Quer- und Längsführung in der Stadt* (URBAN 2016).

1.3 Aufbau der Arbeit

Zu Beginn der Arbeit wird zunächst der Stand der Technik in Kapitel 2 dargelegt. Hierzu wird in Abschnitt 2.1 der Begriff Fahrerassistenz hergeleitet und die grundsätzliche Funktionsweise eines Fahrerassistenzsystems beschrieben. Es folgt die Darstellung wissenschaftlicher Ansätze zur Gliederung der Fahraufgabe und den

Fertigkeiten eines Fahrers. Des Weiteren wird der Unterschied zwischen *Automation* und *Fahrerassistenz* unter Berücksichtigung des Wiener Übereinkommens von 1968 und den Automatisierungsgraden der Bundesanstalt für Straßenwesen (BASt) herausgearbeitet. Anschließend wird in Abschnitt 2.2 die Funktionsweise der verwendeten Sensorik und die Repräsentation der Informationen in einem Umfeldmodell beschrieben. Abschnitt 2.3 stellt aktuelle Assistenzsysteme zur Längs- und Querführung sowie zur kombinierten Längs- und Querführung vor. Das Kapitel schließt mit der Darstellung wissenschaftlicher Ansätze zur kooperativen Fahrzeugführung in Abschnitt 2.4 und zur Fahrerintensionsprädiktion in Abschnitt 2.5.

Kapitel 3 stellt anschließend die notwendigen theoretischen Grundlagen der Arbeit dar. Zu Beginn wird die verwendete Trajektorienplanung zur Längs- und Querführung samt Kostenfunktional zur Auswahl der optimalen Trajektorie in Abschnitt 3.1 beschrieben. Anschließend werden in Abschnitt 3.2 verschiedene Lernverfahren erörtert und als Basis für die Wahl eines geeigneten Verfahrens für eine Fahrerintensionsprädiktion gegenübergestellt. Abschließend wird in Abschnitt 3.3 ein Verfahren zur Schätzung der Modellparameter von Gauß'schen Mischverteilungen erläutert, welches zur Aufbereitung von realen Messdaten eingesetzt wurde.

In Kapitel 4 wird die erste Forschungsfrage (F1) adressiert. Hierzu wird zunächst in Abschnitt 4.1 ein Konzept im Sinne der kooperativen Fahrzeugführung beschrieben, mit welchem sich die fahrzeugführende Person und das System in Wahrnehmung, Interpretation und Fahrzeugführung ergänzen. Dafür wird das fokussierte Umfeld in Abschnitt 4.2 näher betrachtet und Anforderungen an das System werden abgeleitet. Es folgt in Abschnitt 4.3 die Definition des Begriffs Situation und die Beschreibung, wie mithilfe von Umfeld- und Fahrzeugdaten die aktuelle Situation klassifiziert wird. Anschließend werden auf dieser Basis in Abschnitt 4.4 die Situationen *Freie Fahrt*, *Folgefahrt*, *Zufahrt auf eine Kreuzung*, *Stillstand* und *Fahrstreifenwechsel* klassifiziert. Es folgt in Abschnitt 4.5 die Beschreibung der Benutzerschnittstelle, die es der fahrzeugführenden Person erlaubt, mit ihrem Situationsbewusstsein das System zu beeinflussen. Abschnitt 4.6 beschreibt, wie die vom System klassifizierte Situation und die Fahrereingabe bezüglich des Fahrerwunsches interpretiert werden. Diesem Fahrerwunsch wird ein Manöver zugeordnet, welches unter Einbeziehung des statischen und dynamischen Umfelds sowie der Eigenbewegung des Fahrzeugs spezifiziert wird. Darauf aufbauend wird in Abschnitt 4.7 aufgezeigt, wie das Konzept im Rahmen

dieser Arbeit prototypisch implementiert und validiert wurde. Das Kapitel schließt mit einer Diskussion der Erkenntnisse in Abschnitt 4.8.

Die Bearbeitung der zweiten Forschungsfrage (F2) erfolgt in Kapitel 5. Dafür wird zu Beginn in Abschnitt 5.1 aufgezeigt, wie das zuvor entwickelte System so erweitert werden kann, dass eine Adaption auf die Fahrerintention möglich ist. In Abschnitt 5.2 folgt die Darstellung der situationsspezifischen Identifikation der Fahrerintention und der Entwurf entsprechender Bayes'scher Netze. Es wird aufgezeigt, wie diese unter Berücksichtigung kontinuierlicher Messdaten angelernt und für die Prädiktion der Fahrerintention ausgewertet werden. Folgend wird in Abschnitt 5.3 dargelegt, wie diese Netze klassifiziert werden, um Fahrprofile für verschiedene Fahrerinnen und Fahrer zu erhalten. Hierfür wurden zunächst Messdaten in der in Abschnitt 5.4 beschriebenen Realfahrstudie erhoben und gemäß der Darstellung in Abschnitt 5.5 für die Verwendung in Bayes'schen Netzen aufbereitet. Anschließend beschreibt Abschnitt 5.6, wie die Datensätze zufallsbasiert zum Anlernen der Wahrscheinlichkeitstabellen der Bayes'schen Netze und zum Validieren der Prädiktion verwendet werden. Abschließend werden die Ergebnisse in Abschnitt 5.7 diskutiert.

Kapitel 6 schließt die Arbeit mit der Zusammenfassung der durchgeführten Arbeitsschritte sowie entstandener Ergebnisse und liefert im Ausblick Impulse für künftige Forschungsarbeiten in den Bereichen Fahrerassistenz und maschinelles Lernen.

Kapitel 2

Stand der Technik

Schon vor langer Zeit hielten Fahrerassistenzsysteme, wie beispielsweise der 1902 erstmalig patentierte Tachometer (Spiegel 2002), Einzug in das Automobil. Auch der inzwischen selbstverständliche Anlasser zählt zu den ersten Fahrerassistenzsystemen. Durch diesen wird dem Fahrer das Ankurbeln des Motors erspart. Das erste Serienfahrzeug mit einer Unterstützung in der Längsführung durch eine Geschwindigkeitsregelanlage kam 1958 auf den Markt (Aström und Murray 2010). Neben diesen Beispielen wurde bis heute eine Vielzahl an Fahrerassistenzsystemen entwickelt, deren Unterstützung der Fahrer im Alltag nicht mehr missen möchte.

In diesem Kapitel wird der Stand der Technik im Kontext von Fahrerassistenzsystemen dargestellt. Dafür wird in Abschnitt 2.1 allgemein auf diese Systeme eingegangen und eine Einordnung in ein Schema verschiedener Automatisierungsgrade vorgenommen. Anschließend werden in Abschnitt 2.2 die gängigen Sensoren sowie die Zusammenführung der Informationen in einem Umfeldmodell beschrieben. In Abschnitt 2.3 werden aktuelle Seriensysteme zur Längs- und Querführungsunterstützung vorgestellt und in Abschnitt 2.4 wird auf wissenschaftliche Ansätze aus der Literatur zur ganzheitlichen Weiterentwicklung solcher Systeme eingegangen.

2.1 Fahrerassistenzsystem

Das Wort Fahrerassistenzsystem lässt sich in die drei Wortbausteine *Fahrer*, *Assistenz* und *System* zerlegen.

Fah|rer - Bedeutung: jemand, der fährt, ein Fahrzeug führt (Duden 2013)

as|sis|tie|ren - Bedeutung: jemandem nach dessen Anweisung zur Hand gehen, bei einer Arbeit oder Tätigkeit behilflich sein; Herkunft: lateinisch assistere = dabeistehen; unterstützen (Duden 2013)

Sys|tem - Bedeutung (technisch): Einheit aus technischen Anlagen, Bauelementen, die eine gemeinsame Funktion haben (Duden 2013)

Aus diesen Bestandteilen lässt sich die Bedeutung des Wortes Fahrerassistenzsystem herleiten. Demnach ist ein Fahrerassistenzsystem eine Einheit technischer Bauelemente, die den Fahrer bei einer bestimmten Tätigkeit unterstützen sollen. In diesem Kontext handelt es sich bei der Tätigkeit um die Fahraufgabe. Nach heutigem Verständnis bestehen Fahrerassistenzsysteme in der Regel aus Wahrnehmungsmodulen oder einer anderen Schnittstelle zur Informationsaufnahme, einem oder mehreren Modulen zur Verarbeitung der Informationen sowie der Möglichkeit auf die Fahrzeugbewegung einzuwirken oder mit dem Fahrer zu kommunizieren.



Abbildung 2.1: Schematischer Aufbau eines Assistenzsystems

Eine weit verbreitete Unterteilung der Fahraufgabe geht auf Donges (1982) zurück. Hier wird die Fahrzeugführung in drei Schichten unterteilt. Diese Schichten lassen sich direkt auf eine temporale Einordnung projizieren. Die Drei-Ebenen-Hierarchie besteht aus:

- **Navigationsebene**

Die Navigationsebene umfasst die Planung einer passenden Fahrtroute. Unter Einbeziehung aller als relevant angesehenen und bekannten Informationen wird der Weg von einem Start- zu einem Zielpunkt entworfen. Damit umfasst die Navigation die längerfristige Planung der Fahrtroute.

- **Bahnführungsebene**

Auf Bahnführungsebene erfolgt die Planung einer Solltrajektorie. Dies beinhaltet beispielsweise das Halten eines Abstands zum Vorderfahrzeug oder einen Fahrstreifenwechsel. Damit wird auf Bahnführungsebene eine kurzfristigere Planung der Fahrt vorgenommen.

- **Stabilisierungsebene**

Der Stabilisierungsebene werden die Aktivitäten zugeordnet, die benötigt werden, um eine Abweichung von der geplanten Solltrajektorie zu korrigieren. Damit befinden sich diese Aufgaben innerhalb eines sehr kurzen Zeithorizonts.

Wie die Verteilung zwischen der Bahnführungs- und Stabilisierungsebene gestaltet ist, hängt maßgeblich von der Erfahrung und der Routine des Fahrers ab. Dies spiegelt sich auch stark in der ingenieur-psychologischen Strukturierung des Fahrerverhaltens von Rasmussen (1983) wider. Hierbei basieren zielgerichtete Tätigkeiten des Menschen auf folgenden drei Verhaltensvarianten:

- **Wissensbasiertes Verhalten**

Wissensbasiertes Verhalten wird in unbekanntem Situationen angewendet. Die Situation wird identifiziert und es werden mental verschiedene Handlungsalternativen evaluiert. Aus diesen Alternativen wird subjektiv die beste gewählt und ausgeführt.

- **Regelbasiertes Verhalten**

Dieses Verhalten setzt voraus, dass der Betroffene vergleichbare Situationen bereits erlebt hat und aufgrund dieser Erfahrung die subjektiv beste Handlung auswählt und ausführt.

- **Fertigkeitsbasiertes Verhalten**

Dieses Verhalten entsteht durch wiederkehrende Situationen, die die betroffene Person intuitiv reflexartig bewältigt. Dies setzt eine entsprechende Lern- bzw. Übungsphase voraus.

Es gibt viele Situationen bei der Fahrzeugführung, die nur selten auftreten und daher nicht mit der letzten Kategorie von Verhalten bewältigt werden können. Zudem lässt sich den Unfallstatistiken entnehmen, dass der Fahrer nicht zuverlässig in jeder Situation die angemessene Entscheidung trifft. Es ist daher sinnvoll, den Fahrer in den beiden anderen Verhaltensvarianten zu unterstützen.

Der Fahrer kann auf verschiedene Weise vom System unterstützt werden. Die Unterstützung kann bei der Wahrnehmung und Interpretation der Umgebung oder auch bei der Ausführung seiner Fahraufgabe erfolgen. Unterstützung in diesem Zusammenhang bedeutet, dass das System dem Fahrer behilflich ist, ihm aber nicht die Verantwortung für die Fahraufgabe abnimmt. Ausnahmen, bei denen der Fahrer zeitweise nicht in der Lage ist, das System zu übersteuern, bilden sicherheitsrelevante Systeme wie beispielsweise Electronic Stability Control (ESP) oder Antiblockiersystem (ABS). Hier wird argumentiert, diese seien konform mit dem Wiener Übereinkommen über den Straßenverkehr von 1968, da der Fahrerwunsch verstärkt aber nicht übergangen wird (Christhard Gelau 2012). Die hierfür maßgebliche Vorschrift lautet:

„Every driver shall at all times be able to control his vehicle or to guide his animals.“ (Wien 1968)

In dem Übereinkommen verpflichten sich die Vertragspartner, die Verkehrsregelungen ihres Staates so zu entwerfen, dass diese mit den Inhalten dieser Vereinbarung übereinstimmen. Das Übereinkommen ist ein völkerrechtlicher Vertrag, der von 64 Staaten, einschließlich der Bundesrepublik Deutschland, ratifiziert wurde.

Im Mai 2014 wurde das Übereinkommen so ergänzt, dass „(...) Systeme, mit denen ein Pkw autonom fährt, zulässig [sind], wenn sie jederzeit vom Fahrer gestoppt werden können.“ (Welt 2014). Mit dieser Ergänzung wird der Weg zum automatisierten Fahren geebnet. Allerdings müssen bis zu einer Markteinführung noch viele Fragen, u.a. wer im Falle eines Unfalls die Haftung übernimmt, geklärt werden.

Aufgrund der zunehmenden Automatisierung der Fahrzeugführungssysteme sowie der voranschreitenden Forschung in diesem Bereich hat die Bundesanstalt für Straßenwesen (BASt) eine Projektgruppe beauftragt, die rechtlichen Fragen dieser Entwicklungen zu analysieren. Die Projektgruppe einigte sich auf eine einheitliche Definition verschiedener Automationsgrade (s. Tabelle 2.1), welche beim

Runden Tisch automatisiertes Fahren final festgelegt wurde (Gasser u. a. 2015). Der Abgrenzung zwischen Assistenz und (Teil-)Automation wird dabei vom rechtlichen Aspekt große Bedeutung beigemessen. Es stellt sich die Frage, wer die Haftung übernimmt, wenn der Fahrer nicht mehr in die Fahraufgabe involviert ist bzw. ob vom Fahrer im Falle der Teilautomation verlangt werden kann, dass er das System permanent überwacht.

Die Definitionen der Teilautomation und Assistenz weisen zu großen Teilen Überschneidungen auf. Der Unterschied besteht darin, dass im assistierten Bereich der „*Fahrer (...) dauerhaft entweder die Quer- oder die Längsführung (...)*“ ausführt (Gasser u. a. 2015). Im Rahmen der Teilautomation hingegen übernimmt das „*(...) System (...) Quer- und Längsführung (für einen gewissen Zeitraum oder/ und in spezifischen Situation)*“ (Gasser u. a. 2015). Wenn das System beispielsweise wie bei heutigen Adaptive Cruise Control (ACC)-Systemen entweder auf eine eingestellte Geschwindigkeit oder die Zeitlücke zum Vorderfahrzeug regelt, muss der Fahrer für einen gewissen Zeitraum nicht in die Längsführung eingreifen. Dem Fahrer wird abgesehen von der Parametrisierung dieser Größen nur eine Überwachungsaufgabe in der Längsführung zuteil, sofern die Systemgrenzen nicht erreicht werden und er eingreifen muss. Damit wird der Fahrer bei der Längsführung für einen gewissen Zeitraum ersetzt.

Damit ein System mit einem vergleichbaren Längsführungssystem dem assistierten Bereich zugeordnet werden kann, muss also laut dieser Definition die Querführung dauerhaft vom Fahrer übernommen werden. Daher darf hier das System den Fahrer bei der Querführung nicht parallel zur Längsführung für einen gewissen Zeitraum ersetzen. Im Folgenden wird näher betrachtet, wie eine solche Querführung gestaltet sein kann. Das Bundesministerium für Verkehr, Bau und Stadtentwicklung (2006) definiert in der ECE-R79¹ in Abschnitt 2.3.4 eine Fahrerassistenz-Lenkanlage als „*(...) eine Anlage, die (...) den Fahrzeugführer beim Lenken des Fahrzeugs unterstützt, bei der er aber immer die Hauptverantwortung für das Führen des Fahrzeugs behält (...)*“. Bei Anwendung dieser Definition auf eine mittenzentrierte Lenkunterstützung mit Hands-Off-Erkennung² lässt sich diese Form der Unterstützung der Assistenz zuordnen. Darüber hinaus wird in diesem Dokument festgelegt: „*Bei jeder Fahrerassistenz-Lenkanlage kann der Fahrzeugführer sich jederzeit dafür entscheiden, die Assistenzfunktion durch einen bewussten Eingriff zu übersteuern (...)*“. Diese Forderung wird erfüllt, wenn

¹Ergonomic Commission for Europe - Regelung 79

²Systemseitige Überprüfung, ob der Fahrer mindestens eine Hand am Lenkrad hält

Nomenklatur	Beschreibung Automatisierungsgrad
Driver only	Fahrer führt dauerhaft (während der gesamten Fahrt) die Längsführung (Beschleunigen/Verzögerung) und die Querführung (Lenken) aus
Assistiert	Fahrer führt dauerhaft entweder die Quer- oder die Längsführung aus. Die jeweils andere Teilaufgabe wird in gewissen Grenzen vom System ausgeführt Der Fahrer muss das System dauerhaft überwachen Der Fahrer muss jederzeit zur vollständigen Übernahme der Fahraufgabe bereit sein
Teilautomatisiert	Das System übernimmt Quer- und Längsführung (für einen gewissen Zeitraum oder/und in spezifischen Situationen) Der Fahrer muss das System dauerhaft überwachen Der Fahrer muss jederzeit zur vollständigen Übernahme der Fahraufgabe bereit sein
Hochautomatisiert	Das System übernimmt Quer- und Längsführung für einen gewissen Zeitraum in spezifischen Situationen Der Fahrer muss das System dabei nicht dauerhaft überwachen Bei Bedarf wird der Fahrer zur Übernahme der Fahraufgabe mit ausreichender Zeitreserve aufgefordert Systemgrenzen werden alle vom System erkannt. Das System ist nicht in der Lage, aus jeder Ausgangssituation den risikominimalen Zustand herbeizuführen
Vollautomatisiert	Das System übernimmt die Quer- und Längsführung vollständig in einem definierten Anwendungsfall Der Fahrer muss das System dabei nicht überwachen Vor dem Verlassen des Anwendungsfalles fordert das System den Fahrer mit ausreichender Zeitreserve zur Übernahme der Fahraufgabe auf Erfolgt dies nicht, wird in den risikominimalen Systemzustand zurückgeführt Systemgrenzen werden alle vom System erkannt, das System ist in allen Situationen in der Lage, in den risikominimalen Systemzustand zurückzuführen

Tabelle 2.1: Grade der Automatisierung des *Runden Tisches Automatisiertes Fahren* (Gasser u. a. 2015)

die Querreglung bei einem entsprechenden Lenkmoment vom Fahrer nachgibt. Aus diesen beiden Definitionen für Lenkanlagen lässt sich ableiten, dass es sich um Assistenz und nicht um Automation handelt, wenn der Fahrer die Hauptverantwortung trägt und er die Assistenzfunktion jederzeit durch einen bewussten Eingriff übersteuern kann.

Verglichen mit einer Längsführung wie bei ACC-Systemen, ist bei einer Querführungsunterstützung, wie zuletzt beschrieben, der Fahrer an der Fahrzeugführung beteiligt und wird nicht vom System ersetzt. Damit kann die Kombination aus einem ACC-System und einer mittenzentrierten Spurführung mit Hands-Off-Erkennung und beschriebener Übersteuerbarkeit des Systems nach dem Schema 2.1 der Assistenz zugeordnet werden. Für eine Zuordnung zur Teilautomation müsste die Querführung für einen bestimmten Zeitrahmen komplett vom System übernommen werden und dem Fahrer lediglich die Überwachungsaufgabe obliegen.

Wird der Fahrer mit einer derartigen Ausgestaltung der Querführung an der Fahraufgabe beteiligt, so wird dem Problem entgegengewirkt, dass er bei steigender Automatisierung zunehmend weniger bis überhaupt nicht mehr in die Fahraufgabe involviert ist. Ist der Fahrer nicht direkt involviert, kann das zu einem verminderten Situationsbewusstsein führen, sodass im Falle einer Notsituation, beispielsweise einem Systemausfall, der Fahrer nicht mehr in Lage ist, rechtzeitig angemessen zu intervenieren (Endsley und Kiris 1995).

2.2 Umfeldwahrnehmung für Längs- und Querführungssysteme

Um den Fahrer bei der Längs- und Querführung unterstützen zu können, muss das Umfeld gut wahrgenommen werden können. Wie groß der zu erfassende Bereich sein muss und welche weiteren Anforderungen an die Wahrnehmung gestellt werden, hängt von der Funktion des Assistenzsystems ab. Zur Umfeldwahrnehmung werden für das in dieser Arbeit entwickelte System eine Kamera, Ultraschallsensoren, Radio Detection and Ranging (Radar) sowie Light Detection and Ranging (Lidar) verwendet. Die Informationen aus diesen Sensoren werden fusioniert und in einem Umfeldmodell zusammengeführt. Zu einem besseren und

vorausschauenderem Verständnis des Umfelds kann das Umfeldmodell zusätzlich mit einer digitalen Karte unterlegt werden.

Im folgenden Abschnitt werden die verschiedenen Sensoren beschrieben und anschließend das Umfeldmodell vorgestellt.

2.2.1 Ultraschall

Für den Nahbereich (bei aktuellen Systemen etwa bis 2,5m (Kreiss 2012)) werden zur Detektion von Hindernissen Ultraschallsensoren eingesetzt. Heutzutage sind sie in vielen Serienfahrzeugen im Bereich der Einparkhilfen zu finden. Diese Sensoren senden Ultraschallwellen (mit $c_s = \text{Schallgeschwindigkeit}$) aus und über die Auswertung der Signallaufzeit t wird der Abstand zu einem Objekt bestimmt:

$$d = \frac{c_s \cdot t}{2} \quad (2.1)$$

Zur Plausibilisierung des Abstands und zur Bestimmung des Winkels zum detektierten Objekt wird das Trilaterationsprinzip³ verwendet. Dafür werden zusätzlich noch die Echosignale der benachbarten Ultraschallsensoren ausgewertet. Für das Aussenden und das Empfangen der mechanischen Wellen wird bei diesen Sensoren der piezoelektrische Effekt⁴ genutzt.

Ultraschallsensorik kann bei den meisten Witterungsverhältnissen genutzt werden und ist verhältnismäßig günstig in der Herstellung. Da im Verkehrskontext vorwiegend *schallharte* Materialien auftreten, liefern diese Sensoren für den Nahbereich gute Ergebnisse (Noll und Rapps 2012).

2.2.2 Kamerasensorik

Die Kamerasensorik hat über die Spurverlassenswarnung Einzug in die Serienfahrzeuge gehalten. Über die Auswertung von Fahrstreifenmarkierungen können Informationen über den Fahrstreifenverlauf sowie die relative Position des Fahrzeugs innerhalb des Fahrstreifens gewonnen werden. Darüber hinaus können

³Positionsbestimmung auf Basis der Abstandsmessung von drei Referenzpunkten

⁴Elektrische Spannung hervorgerufen durch elastische Verformung von Festkörpern

Kamerasysteme eingesetzt werden, um Verkehrszeichen, andere Verkehrsteilnehmer (Fußgänger, Radfahrer, PKW, etc.) oder Lichtsignale zu erkennen. Verwendung finden in diesem Kontext Kamerasensoren mit Charged Coupled Device (CCD)- oder Complementary Metal Oxide Semiconductor (CMOS)-Technologie. Die aufgenommenen Bilddaten werden in einer Matrix mit Grau- oder RGB⁵-Werten abgelegt (von Reyher 2007). Je nach Anwendung werden folgende Kamerasysteme eingesetzt:

- **Monokulare Kamerasysteme**

Bei diesen Systemen wird das Umfeld als zweidimensionale Textur abgelegt. Je nach Anwendung muss zwischen einem großen Öffnungswinkel oder einer guten Auflösung sowie der Qualität der Daten in größerer Entfernung abgewogen werden (Munz 2011). Es werden meist modellbasierte Algorithmen angewendet, um Objekte und ihre Entfernung über typische Merkmale zu erkennen (Stüker 2004).

- **Stereokamerasysteme**

Im Gegensatz zu monokularen Systemen besteht ein Stereosystem aus zwei Kameras. Damit lässt sich eine 3D-Rekonstruktion des Umfelds erzeugen. Die Entfernung r eines Bildpunktes kann über die Disparität⁶ $disp$, die räumliche Distanz b_l zwischen den beiden Kamerasensoren sowie die Brennweite f_b bestimmt werden (Aue 2014):

$$r = \frac{b_l \cdot f_b}{disp} \quad (2.2)$$

Als optischer Sensor reagiert die Kamera sensibel auf Verschmutzungen, schlechte Witterungsverhältnisse, tief stehende Sonne sowie dynamische Beleuchtungsänderungen (z. B. bei Tunneleinfahrten). Sind die entsprechenden Voraussetzungen allerdings gegeben, kann aus den Kamerasystemen eine Vielzahl an Informationen gewonnen werden.

⁵rot grün blau

⁶Versatz der Pixelkoordinaten zwischen den beiden Kamerabildern

2.2.3 Lidar

Dieser Sensor arbeitet mit einem optischen Messfahren, für das mit einer Laserdiode Lichtimpulse emittiert werden. Die Reflexion der Lichtimpulse an einem Objekt werden mit einer Photodiode empfangen (Höver u. a. 2006). Die Entfernung d zum Objekt wird über die Signallaufzeit ermittelt:

$$d = \frac{c_0 \cdot t}{2} \quad (2.3)$$

Der Lichtimpuls bewegt sich mit der Lichtgeschwindigkeit c_0 und legt in der Zeit t einmal den Weg zum Objekt und wieder zum Sensor zurück. Da eine Geschwindigkeitsmessung über den Dopplereffekt mit einem vergleichsweise höherem technischen Aufwand und Kosten verbunden ist, wird die Geschwindigkeit wie auch die Beschleunigung über die Ableitung des Abstandes über die Zeit bestimmt (Geduld 2012).

Folgende Kategorien an Lidarsensoren werden im Automobilbereich eingesetzt:

- **Scannende Sensoren**

Scannende Sensoren nutzen überwiegend einen Sender und einen Empfänger. Der Strahl wird beim Aussenden über ein Prisma oder einen rotierenden Spiegel abgelenkt. Damit werden große Erfassungsbereiche erzielt (Rasshofer und Gresser 2005).

- **Feststrahler**

Bei Feststrahlern werden mehrere Strahlen parallel ausgesendet. Die Erweiterung des Erfassungsbereiches ist über den Aufbau von zusätzlichen Dioden oder der Verwendung einer Schwenkeinrichtung möglich. Erstere werden häufig aus ökonomischen Überlegungen vernachlässigt und finden eher selten Verwendung. Bei Sensoren mit Schwenkeinrichtung kann das Strahlenbündel nach Bedarf geschwenkt und der Erfassungsbereich kostenoptimiert erweitert werden (*Multibeam Sweep*). Voraussetzung für die Verwendung von Schwenksensoren ist die Kenntnis der Fahrtrichtung (von Reyher 2007).

- **Flash-Lidarsysteme**


Es wird ein einziger Lichtstrahl ausgesendet, der das gesamte Erfassungs-

gebiet kurz erleuchtet. Die Reflexionen werden im Empfänger in einer Pixelmatrix eingefangen (Aue u. a. 2011).

Lidarsensoren bieten eine hohe horizontale Auflösung, wodurch die Position, die Breite von Objekten sowie deren Konturen gut abgeschätzt werden können. Allerdings reagieren optische Sensoren sensibel auf Verschmutzungen und Umwelteinflüsse (Höver u. a. 2006).

2.2.4 Radar

Während die ersten Radare (Abbildung 2.2a) noch groß und schwer vereinbar mit dem Design waren, können sie heute für den Kunden nicht sichtbar beispielsweise hinter dem Kühlergrill verbaut werden (Abbildung 2.2b). Für die Nutzung von Radarsensoren muss gewährleistet werden, dass diese in ihrer Einbauposition nicht durch elektrisch leitfähiges Material beeinflusst werden. Darüber hinaus sind eine kompakte Bauform sowie wirtschaftliche Herstellungskosten eine Voraussetzung für den Serieneinsatz.



(a) Forschungsfahrzeug aus den 70er Jahren (Rohling 2010)



(b) Passat B8 (vwvortex 2014)

Abbildung 2.2: Einbau von Radaren früher und heute

Bei dieser Technik werden elektromagnetische Wellen ausgesendet und die Reflexionen an Objekten werden vom Sensor wieder empfangen. Darüber kann der Abstand und die Relativgeschwindigkeit eines Objektes bestimmt werden.

Im automobilen Kontext werden vorwiegend folgende Varianten eingesetzt (Reif 2012):

- **Pulsradar**

Bei diesem System wird ein kurzer Radarimpuls ausgesendet. Mit einer Laufzeitmessung des Signals kann der Abstand zu einem Objekt bestimmt werden (s. Gleichung 2.3). Die Relativgeschwindigkeit eines Objekts \dot{r} kann auf Basis des Dopplereffekts⁷ aus der Frequenzverschiebung f_d und der Wellenlänge λ ermittelt werden:

$$f_d = \frac{2\dot{r}}{\lambda} \quad (2.4)$$

Für eine Winkelschätzung werden ein Sender und mehrere Empfänger eingesetzt. Über die unterschiedlichen Laufzeiten und die relative Anordnung der Empfänger zueinander kann der Winkel zum Objekt bestimmt werden (Stüker 2004).

- **Dauerstrichradar**

Bei einem Dauerstrichradar wird ein kontinuierliches Signal ausgesendet. Die Trägerfrequenz des Signals wird dabei z. B. linear moduliert. Durch die Auswertung der Frequenzverschiebung von Sender und Empfänger kann die Entfernung und die Relativgeschwindigkeit eines Objekts bestimmt werden (Dopplereffekt). Durch eine Erweiterung um eine stufenweise Umtastung der Modulation (engl.: *frequency shift keying*) können auch Mehrzielsituationen aufgelöst werden (Rohling 2010).

Gegenüber optischer Sensorik hat Radar den Vorteil, auch bei schwierigen Umwelteinflüssen wie Niederschlag oder schlechten Lichtverhältnissen zuverlässige Messergebnisse zu liefern.

2.2.5 Gegenüberstellung

In Tabelle 2.2 werden die relevanten Merkmale der Sensorik für die Anwendung in Fahrerassistenzsystemen bewertet.

⁷Veränderung der Frequenz bei relativer Bewegung von Sender und Beobachter

Jede Sensorart hat ihre spezifischen Stärken und Defizite. Radar ist weitestgehend wetterrobust und liefert wie Lidar gute Ergebnisse bei der Objektdetektion. Bis zu einem gewissen Grad können Kamerasysteme in diesem Bereich unterstützen. Deren große Stärke liegt allerdings in der Fahrstreifen- und auch Verkehrszeichenerkennung.

Um ein gutes Abbild der Fahrzeugumgebung zu erhalten, ist eine Kombination der unterschiedlichen Sensoren und eine Fusion der gewonnenen Daten notwendig.

	Radar	Lidar	Mono	Stereo
Reichweite	+	+	+/-	-
Öffnungswinkel	+/-	+	+	+/-
Objektabstand	+	+	-	+/-
Objektgeschwindigkeit	+	-	-	-
Objektabmessungen	-	+	+/-	+
Fahrbahnerkennung	-	-	+	+
Verkehrszeichenerkennung	-	-	+	+
Umwelteinflüsse	+	-	-	-

Tabelle 2.2: Vergleich ausgewählter Sensortechnologien (in Anlehnung an Aue (2014); Stiller u. a. (2012))

2.2.6 Umfeldmodell

Die Basis des in dieser Arbeit entwickelten Systems bildet die Kette von der Sensorik über die Fusion der Daten aus der Sensorik bis hin zu deren Interpretation zu einem Umfeldmodell. Um eine größere Vorausschau zu erhalten, werden die Informationen mit einer digitalen Karte ergänzt, auf welcher das Fahrzeug mithilfe von Global Positioning System (GPS) zugeordnet wird.

Als Sensorik werden Kamera, Ultraschallsensoren, verschiedene Radare sowie Lidare genutzt, welche in den letzten Abschnitten beschrieben wurden.

Die Informationen der verschiedenen Sensoren werden fusioniert und wie von Knaup und Homeier (2010) beschrieben zu einem graphenbasierten Modell des

Fahrzeugumfelds interpretiert. Wie in Abbildung 2.3 zu erkennen, werden dafür die dynamischen Informationen aus den verschiedenen Sensoren in der Objektfusion zusammengeführt. Die statischen Informationen werden in einem Belegungsgitter hinterlegt. Objektfusion, Belegungsgitter und Karteninformationen werden in dem Umfeldmodell zusammengeführt. Dieses Modell ist so aufgebaut, dass eine Erweiterung um einen weiteren Sensor oder auch eine Vehicle to X (V2X)-Anbindung gut möglich ist.

Es findet eine Interpretation der Informationen statt, so dass beispielsweise die erkannten Objekte mit einer gewissen Wahrscheinlichkeit bestimmten Fahrstreifen zugeordnet werden.

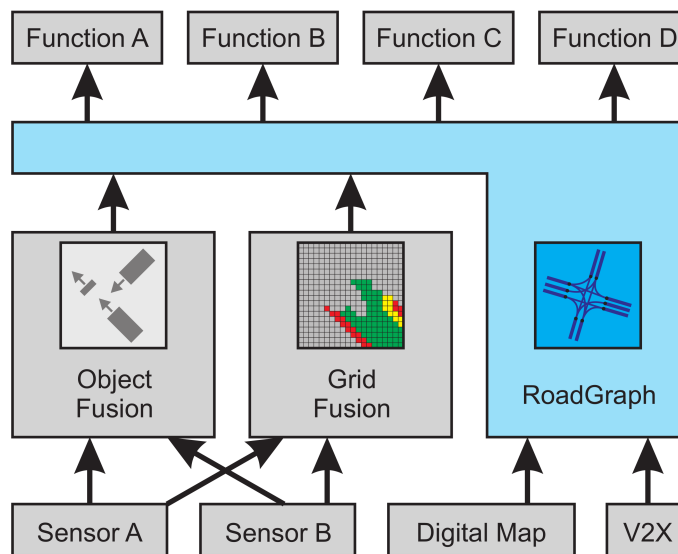


Abbildung 2.3: Umfeldmodell für Fahrerassistenzsysteme (Knaup und Homeier 2010)

2.3 Assistenzsysteme zur Längs- und Querführung

Bereits heute gibt es eine Reihe von Seriensystemen, die dem Fahrer bei der Längs- und Querführung assistieren. In den folgenden Abschnitten werden die gängigsten Systeme herstellerunabhängig vorgestellt. Die verschiedenen Hersteller entscheiden sich teilweise für unterschiedliche Sensorik oder Funktionsausprägungen. Daher werden hier exemplarisch grundsätzliche Funktionsweisen dargestellt.

Fahrerassistenzsysteme lassen sich in Komfort- und Sicherheitssysteme unterteilen. In Untersuchungen haben Wegscheider und Prokop (2005) herausgefunden, dass (s. Abbildung 2.4) der Normalfahrer nur einen gewissen Ausschnitt des Kammschen Kreises⁸ an Beschleunigungen nutzt. Bei hohen Beschleunigungen wirken starke Kräfte auf die Fahrzeuginsassen, was im Allgemeinen als unkomfortabel empfunden. Darüber hinaus ist in Abbildung 2.4 zu sehen, dass der Normalfahrer parallel hohe Längs- und Querbeschleunigungen meidet. Diese Richtwerte werden bei der Konzeption von Komfortsystemen berücksichtigt.




Abbildung 2.4: Kammscher Kreis und durch den Normalfahrer genutzter Bereich (Wegscheider und Prokop 2005)

Bei Sicherheitssystemen steht die Unfallvermeidung oder -schwereminderung im Fokus. Daher können bei diesen Systemen durchaus höhere Beschleunigungswerte eingesetzt werden.

2.3.1 Längsführungsassistenzsysteme

Die Unterstützung des Fahrers in der Längsführung erfolgt entsprechend der Anwendung durch Beschleunigung oder Verzögerung in Fahrzeuginnenrichtung. Je nach Klassifikation in Komfort- oder Sicherheitssysteme stehen hierfür unterschiedliche Wertebereiche zur Verfügung. Ein Komfortsystem nutzt deutlich geringere Beschleunigungs- bzw. Verzögerungswerte als ein Sicherheitssystem.

⁸Kammscher Kreis: fahrdynamisch theoretisch nutzbarer Bereich

Geschwindigkeitsregelanlage

Der Fahrer kann eine Wunschgeschwindigkeit einstellen und das System regelt diese ein. Das System dient dem Komfort bei Überland- und Autobahnstraßen mit wenig oder recht konstantem Verkehr. So kann der Fahrer bei monotonen Strecken entlastet werden. Zusätzliche Sensorik ist nicht notwendig, da keine Umfeldinformationen benötigt werden.

Automatische Distanzregelung

Die automatische Distanzregelung ist eine Erweiterung der Geschwindigkeitsregelanlage. Es wird auf die Wunschgeschwindigkeit des Fahrers und die Zeitlücke zum Vorderfahrzeug geregelt. Daher muss das Fahrzeug mit entsprechender Sensorik ausgestattet sein, um den Abstand zum Vorderfahrzeug und dessen Geschwindigkeit wahrnehmen zu können. Dafür wird in heutigen Serienfahrzeugen Radar oder eine Kombination aus Radar und Monokamera genutzt. Viele Systeme sind in der Lage hinter einem haltenden Fahrzeug selbstständig bis zum Stillstand zu verzögern. Je nach Systemausprägung ist ein automatisches Wiederanfahren in *Stop-and-Go-Verkehr* möglich.

Notbremsassistentz

Ist ein Fahrzeug mit einem ACC-System ausgestattet, so kann die vorhandene Sensorik auch zum Erkennen einer Notsituation genutzt werden. Wird erkannt, dass eine höhere Verzögerung notwendig ist, als im ACC-System genutzt wird, um einen Auffahrunfall zu verhindern, wird im ersten Schritt der Fahrer informiert und die Bremsen vorgefüllt. Auf diese Weise wird die Bremswirkung bei Betätigung durch den Fahrer erhöht. Reagiert der Fahrer nicht, wird eine zweite Warnung in Kombination mit einem Bremsruck erfolgen. Wird systemseitig eine eindeutige Gefahrensituation erkannt, erfolgt die Einleitung einer Notbremsung. Dieses System nutzt die gleichen Wahrnehmungskomponenten, greift aber auch bei einem inaktivem ACC-System ein.

2.3.2 Querführungsassistenzsysteme

Bei heutigen Seriensystemen aus dem Bereich der Querführungsunterstützung wird der Fahrer beim Fahren im eigenen Fahrstreifen unterstützt. Diese Assistenzsysteme benötigen daher Sensorikdaten, aus denen die Fahrstreifenmarkierungen interpretiert werden können. Dazu wird in aller Regel eine Kamera mit entsprechender Bildverarbeitung verwendet.

Spurverlassenswarnung

Systeme, die vor einem Verlassen des Fahrstreifens warnen, werden unter der englischen Bezeichnung „Lane Departure Warning“ zusammengefasst. Dabei handelt es sich nicht um Querführungssysteme im eigentlichen Sinne, da sie nicht aktiv in die Führung eingreifen. Auch sie unterstützen jedoch den Fahrer durch unterschiedlich geartete Informationen beim Führen des Fahrzeugs innerhalb eines Fahrstreifens. Es gibt infrastrukturelle Maßnahmen oder fahrzeugeigene Systeme, um den Fahrzeugführenden vor dem unbeabsichtigten Verlassen eines Fahrstreifens zu warnen.

- **Infrastrukturelle Maßnahmen**

Als infrastrukturelle Maßnahme werden profilierte Fahrstreifenmarkierungen als auch Rüttelstreifen verwendet. Beim Einsatz von Rüttelstreifen befinden sich direkt außerhalb der Fahrstreifenmarkierung rillenartige Vertiefungen. Bei profilierten Markierungen befinden sich kleine Erhebungen in der Markierung selbst (Lank und Steinauer 2009). Während bei Rüttelstreifen ein deutliches Holpern im Fahrzeuginneren zu spüren ist, führen profilierte Markierungen zu einer Vibration des Wagens. Bei beiden Varianten ist somit parallel zur haptischen auch eine akustische Warnwirkung im Fahrzeug vorhanden. Zur Warnung von Lastkraftwagenfahrern werden Rüttelstreifen bevorzugt, da profilierte Markierungen in dieser Art von Fahrzeugen kaum wahrnehmbar sind. Damit wird Fahrfehlern entgegengewirkt, denen häufig die Übermüdung oder Unaufmerksamkeit des Fahrers zugrunde liegen und ein seitliches Verlassen des Fahrstreifens zur Folge haben (Lerner und Hegewald 2009). Mithilfe von Rüttelstreifen kann das Risiko für derartige Unfälle um bis zu 70% gesenkt werden (Wood 1994).

- **Fahrzeugeigene Systeme**

Bei fahrzeugeigenen Systemen gibt es grundsätzlich zwei Varianten, wie das Auslösen einer Warnung vor dem unbeabsichtigten Verlassen des Fahrstreifens bestimmt wird. Es kann die Entfernung des Reifens zur Fahrstreifenmarkierung ausgewertet werden. Dies wird als Distance-to-Line-Crossing (DLC)-Kriterium bezeichnet. Die andere Variante hingegen wird als Time-to-Line-Crossing (TLC)-Kriterium bezeichnet. Hier wird die Zeit bis zum Überfahren der Fahrstreifenmarkierung prädiziert. Bei beiden Varianten wird bei der Unterschreitung eines Schwellwertes eine Warnung ausgelöst. Bei dem TLC-Kriterium kann der angemessene Warnzeitpunkt besser bestimmt werden. Allerdings sind hier die Anforderungen an die Qualität der Eingangsdaten deutlich höher als beim DLC-Kriterium.

Wie bei vielen anderen warnenden Assistenzsystemen werden der visuelle, akustische und haptische Warnkanal isoliert oder kombiniert genutzt. Zur Visualisierung kann beispielsweise das Kombiinstrument oder ein Head-Up-Display (HUD) genutzt werden. Wird nur die Visualisierung zur Darstellung einer Warnung verwendet, so ist es möglich, dass der Fahrer die Warnung nicht wahrnimmt. Daher wird eine visuelle Warnung häufig mit einer akustischen Warnung unterlegt. Die akustische Warnung erregt die Aufmerksamkeit und die visuelle Darstellung liefert die Erklärung für die Warnung oder die Aufforderung zu einer geeigneten Handlung. Allerdings wird die akustische Warnung zusätzlich von allen anderen Insassen wahrgenommen, sodass mancher Fahrer einen anderen Warnkanal präferiert, damit ausschließlich er selbst auf sein Fehlverhalten aufmerksam gemacht wird. Daher wird zum Warnen vor dem unbeabsichtigten Verlassen eines Fahrstreifens oftmals eine haptische Form der Rückmeldung gewählt. Hierfür werden Vibrationen in Lenkrad oder Sitz aber auch Lenkmomente verwendet.

Spurhalteassistenten

Bei diesen Systemen wird der Fahrer aktiv beim Lenken im eigenen Fahrstreifen unterstützt. Dafür wird ein unterstützendes Lenkmoment angelegt. Es gibt Unterschiede in der Funktionsauslegung und in der Gestaltung der Unterstützung. Die gängigsten Auslegungen sind in Abbildung 2.5 dargestellt. Soll ausschließlich

das Verlassen des Fahrstreifens unterbunden werden, so greift das System nur ein, wenn das Fahrzeug droht die Fahrstreifenmarkierung zu überfahren. Es wird ein Lenkimpuls in Richtung der Fahrstreifenmitte gegeben. Dies ist schematisch in Abbildung 2.5a dargestellt.

Andere Systeme unterstützen den Fahrer beim Führen des Fahrzeugs entlang der Fahrstreifenmitte. Hier wird bereits ein Hilfsmoment aufgelegt, wenn das Fahrzeug von der Fahrstreifenmitte abweicht. Je höher die Abweichung desto höher ist das aufgeschaltete Hilfsmoment. In den Abbildungen 2.5b und 2.5c sind verschiedene Auslegungen dieser Variante zu sehen. Bei der komfortbetonten Führung ist das Hilfsmoment um die Fahrstreifenmitte deutlich geringer und nimmt im Gegenzug in der Nähe der Fahrstreifenmarkierung stärker zu.

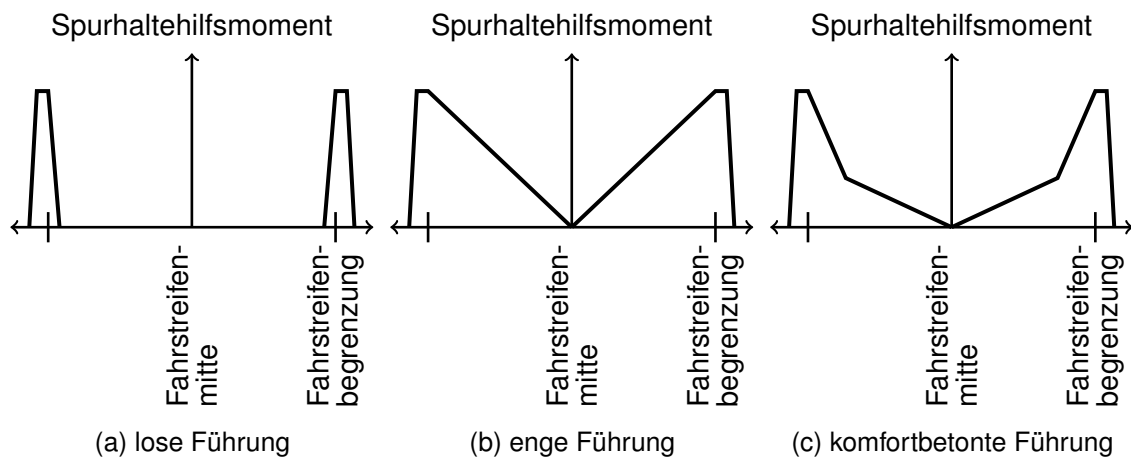


Abbildung 2.5: Exemplarische Verläufe des Betrags des Hilfsmoments in Abhängigkeit von der Querablage (schematische Darstellung) (Gayko 2012)

Da es sich hier um ein Komfortsystem handelt, ist der Wertebereich der nutzbaren Lenkmomente begrenzt. Liegt das notwendige Lenkmoment außerhalb dieses Bereichs, beispielsweise bei der Durchfahrt einer engen Kurve, so wird das System mit einer Aufforderung zur Übernahme durch den Fahrer deaktiviert. Wird durch das Setzen des Fahrtrichtungsanzeiger erkannt, dass der Fahrer einen Fahrstreifenwechsel durchführen möchte, so wird das System ausgesetzt. Das System wird ebenfalls deaktiviert, wenn deutliche Lenkmomente des Fahrers mit anderer Orientierung erkannt werden. Der Fahrer verfügt immer über die letzte Entscheidungsinstanz und ist zu jeder Zeit in der Lage, das System zu überstimmen. Um zu gewährleisten, dass sich der Fahrer nicht aus der Fahraufgabe zu-

rückzieht, sind diese Systeme mit einer Hands-Off-Erkennung ausgestattet. Wird systemseitig festgestellt, dass der Fahrer für einen gewissen Zeitraum die Hände nicht am Lenkrad hatte, wird eine Warnung ausgegeben und das System deaktiviert. Die Hands-Off-Erkennung wird über eine Beobachtung der fahrerseitigen Lenkmomente oder eine kapazitive Handerkennung realisiert.

2.3.3 Kombinierte Längs- und Querführungsassistenzsysteme

In den letzten beiden Abschnitten wurden Systeme zur Unterstützung des Fahrers in Längs- oder Querführung vorgestellt. Diese lassen sich zwar teilweise parallel aktivieren, allerdings handelt es sich um separate Systeme, die in ihrer Handlungsstrategie nicht aufeinander abgestimmt sind. Im folgenden Abschnitt werden kombinierte Unterstützungssysteme vorgestellt.

Totwinkel- und Spurwechselassistentz

Bei der Totwinkel- sowie Spurwechselassistentz handelt es sich um reine Warnsysteme und damit nicht um Führungsassistenzsysteme im herkömmlichen Sinne. Allerdings wird auch hier der Fahrer durch Warnungen vor kritischen Situationen beim sicheren Führen seines Fahrzeugs unterstützt.

Beim Totwinkelassistent wird der Fahrer über Fahrzeuge kurz vor bzw. im toten Winkel informiert. Der Spurwechselassistent überwacht einen weiteren Bereich nach hinten. Bei beiden Systemen wird der Fahrer meist über ein Leuchtsignal im entsprechenden Außenspiegel über die Anwesenheit eines relevanten Fahrzeugs informiert. Setzt der Fahrer trotz Warnleuchten den Fahrtrichtungsanzeiger in die jeweilige Richtung, so wird die Warnung verschärft. Je nach Systemauslegung erfolgt auch ein aktiver Lenkeingriff bei erkannter Gefahrensituation.

Stauassistentz

Das Ziel dieses Assistenzsystems ist, den Fahrer in einer Staufahrt zu entlasten. Dafür übernimmt das System die Fahrzeuglängsführung bis zum Stillstand und teilweise mit Wiederanfahren im Stau. Zusätzlich wird der Fahrer, sofern er mindestens eine Hand am Lenkrad hält, auch bei der Lenkung unterstützt.

Nothalteassistentz

Dieses Assistenzsystem dient dazu, bei Fahrunfähigkeit des Fahrers das Fahrzeug sicher zum Stillstand zu bringen. Übernimmt der Fahrer trotz einer Warneskalation über verschiedene Warnkanäle nicht die Lenkung, wird das Fahrzeug innerhalb des eigenen Fahrstreifens kontinuierlich bis Stillstand verzögert. Parallel wird zur Warnung des umliegenden Verkehrs die Warnblinkanlage aktiviert. Damit wird vom System die Längs- und die Querführung des Fahrzeugs vollständig übernommen.

2.4 Kooperative Fahrzeugführung

Kooperation wird in diesem Kontext verstanden als das Management individueller Aktivitäten, die sich überschneiden können. Diese Aktivitäten dienen dazu, die Teilaufgabe einzelner oder das Erfüllen einer gemeinsamen Aufgabe zu erreichen (Hoc 2001).

Die Idee der *kooperativen Fahrzeugführung* ist, dass der Fahrer gemeinsam mit dem intelligenten System die Fahrzeugführung durchführt. Das Fahrzeug und der Fahrer werden dabei als Akteure verstanden, die versuchen das gleiche Ziel zu erreichen. Die Ressourcen, die Wahrnehmung, die Strategien und die Handlungsoptionen, die zum Erreichen des Ziels zur Verfügung stehen, können dabei unterschiedlich sein. Eine gute Abstimmung zwischen den beiden Akteuren ist die Voraussetzung dafür, dass die Fahrzeugführung entsprechend der Interessen des Fahrers ausgeführt wird (Heesen u. a. 2010). Diese Abstimmung kann, wie im Folgenden beschrieben, unterschiedlich ausgestaltet werden.

2.4.1 Conduct-by-Wire und pieDrive

Bei dem Konzept *Conduct-by-wire* wird die Fahrzeugführung des Fahrers von der Stabilisierungsebene auf die Führungsebene gehoben (vgl. Donges (1982)). Es ist dem Fahrer aber weiterhin möglich, auf der Stabilisierungsebene einzugreifen, d.h. per Lenkrad, Gas und Bremse. Das Konzept des Systems sieht allerdings die Übergabe von Manöverbefehlen vor (Schreiber u. a. 2009).

Schreiber u. a. (2010) unterscheiden zwischen expliziten und impliziten Manövern. Implizite Manöver sind Manöver ohne definierten Start bzw. definiertes Ende. Diese müssen nicht explizit vom Fahrer übergeben werden. Ein Beispiel für ein solches Manöver ist das Folgen eines Fahrstreifens. Explizite Manöver hingegen bezeichnen eindeutig abgeschlossene Manöver, wie einen Fahrstreifenwechsel, welche durch den Fahrer angefordert werden müssen.




Abbildung 2.6: Ansicht der Benutzeroberfläche des Touch-Displays (Kauer u. a. 2010)

Die Schnittstelle zwischen Fahrer und System wird in dieser Ausprägung mit einem taktilen Touch-Display realisiert, welches in der Mitte des Lenkrads angebracht ist. Wie in Abbildung 2.6 zu sehen, kann der Fahrer aus neun Manöverfeldern ein konkretes Manöver auswählen. Darüber hinaus gibt es drei Parameter (z.B. Zeitlücke zum Vorderfahrzeug), die der Fahrer über das Display adaptieren kann (Kauer u. a. 2010). Die vom Fahrer übergebenen Manöver werden durch das System unter Überwachung durch den Fahrer ausgeführt.

Die Interaktion zwischen Fahrer und System wurde weiter erforscht und entwickelt. Das Ergebnis findet sich im Konzept *pieDrive* (Franz u. a. 2012). Durch ein kontaktanaloges Head-Up-Display (HUD) in der Windschutzscheibe sowie einem Touchpad in der Armlehne wird es dem Fahrer ermöglicht, bei der Manöverauswahl den Blick auf das Verkehrsgeschehen beizubehalten. Der Fahrer erhält im HUD die Auswahl verschiedener Manöver angezeigt sowie direkt eine visuelle Rückmeldung über seine Eingabe. Die Eingabe erfolgt über das Touchpad. Mit dieser Schnittstelle ist es dem Fahrer möglich, wie bei Conduct-by-wire, diskrete

Manöverwünsche oder eine Parametervariation zu übergeben.

Bei diesen Konzepten wird die Fahraufgabe zwischen Fahrer und System so aufgeteilt, dass dem Fahrer die Führung obliegt und das System die Ausführung auf Stabilisierungsebene übernimmt. Durch die Übergabe der Manöverbefehle bleibt der Fahrer in die Fahraufgabe involviert und kann bei Bedarf die Fahrzeugführung auch auf der Stabilisierungsebene übernehmen (Flemisch u. a. 2014).



Abbildung 2.7: Ansicht der Benutzeroberfläche des Touch-Displays (Albert 2018)

Diese Idee wird von Albert (2018) aufgegriffen und in einem vierstufigen Konzept untersucht. In der niedrigsten Ausprägung kann die fahrzeugführende Person aus einer automatisierten Fahrt mittels der Betätigung des Blinkers einen Fahrstreifenwechsel (FSW) anfordern, welcher allerdings manuell ausgeführt werden muss. Im nächst höheren Konzept kann über ein Touchdisplay, welches zugleich eine visuelle Rückmeldung gibt, ein FSW angefordert werden. Darauf aufbauend findet im nächsten Konzept eine Interaktion auf Manöverplanungsebene statt. Es kann eine Folge von Manövern ausgewählt werden, welche vom System umgesetzt werden. Die Nutzeroberfläche für dieses Konzept ist in Abbildung 2.7 dargestellt. Im letzten Konzept obliegt der fahrzeugführenden Person ausschließlich die Überwachung, da Manöverauserwahl und -durchführung vom System übernommen werden.

2.4.2 H-Mode

Bei dem Konzept *H(orse)-Mode* findet eine Pferd-Reiter-Designmetapher mit einer haptisch-multimodalen Bedienweise Anwendung. Das Pferd verhindert mit

seiner eigenen Wahrnehmung und Intelligenz beispielsweise den Zusammenstoß mit Hindernissen, sodass der Fahrer in die Lage versetzt wird, anderen Aufgaben mehr Aufmerksamkeit zu widmen. Durch den direkten Kontakt zum Pferd erhält er stets eine haptische Rückmeldung über dessen Bewegung. Er kann sich für eine lose oder strenge Führung des Pferdes entscheiden und dem Tier auf diese Weise unterschiedlich viel Freiheit bei der Wahl des Pfades überlassen (Flemisch u. a. 2003). Übertragen auf ein Fahrer-Fahrzeug-System liegt eine geteilte Führung zwischen einem intelligenten Fahrzeug und dem Anwender vor, welche auf einer bidirektionalen Kommunikation basiert (Goodrich u. a. 2006). Dies hat im Vergleich zu rein automatischen Systemen den Vorteil, dass der Fahrer immer aktiv eingebunden bleibt (Kienle u. a. 2009).

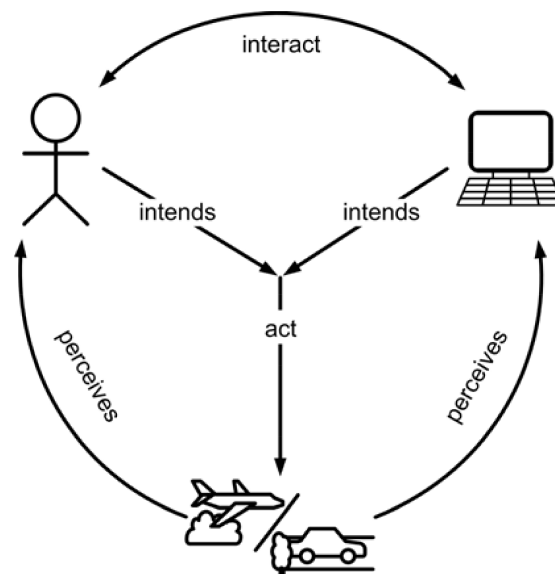


Abbildung 2.8: Geteilte und kooperative Fahrzeugsteuerung von Mensch und System (Flemisch u. a. 2008)

Flemisch u. a. (2008) haben diese Art der Kommunikation mit einem aktiven Sidestick umgesetzt. Dafür wurden der Einfluss des Systems und die Rückmeldung an den Fahrer je nach Automationsgrad unterschiedlich stark ausgeprägt umgesetzt. Solange der Fahrer die Hand am Stick hält, erzielten sie gute Ergebnisse beim Systemverständnis und der Kommunikation zwischen Fahrer und System. Insbesondere bei gezielt eingespieltem Systemversagen konnten die Fahrer schnell eingreifen und die volle Fahrverantwortung übernehmen.

Die Wahl des Automationsgrades kann fahrerseitig entweder über Knöpfe erfolgen oder dynamisch über die Ausprägung des Handkontaktes zum Sidestick (Fle-

misch u. a. 2014).

Kienle (2015) wendet den *H-mode* mittels *Yoke*-Bedienelement an. Es handelt sich dabei um ein lenkradähnliches aktives Bedienelement aus der Luftfahrttechnik mit rotatorischem und translatorischem Freiheitsgrad. Die translatorische Bewegung bildet eine Variation in der Geschwindigkeit, die rotatorische eine Veränderung der lateralen Bewegung ab. Kienle (2015) untersucht in einer Simulatorstudie den Einfluss des Bedienelements auf die Übernahmefähigkeit der fahrführenden Person im Fehlerfall einer teilautomatisierten Fahrt. In seinem Versuchsaufbau zeigt sich das konventionelle Bedienkonzept mittels Lenkrad und Pedalerie dem *Yoke* überlegen.

2.4.3 Digital driving

Bei dem Konzept *digital Driving* wird es dem Fahrer ermöglicht, mit dem System auf Manöverebene zu kommunizieren. Die Kommunikation erfolgt hier nicht mehr über analoge Eingabeelemente wie das Lenkrad und die Pedalerie. Daher bezeichnen Broggi u. a. (2013) diesen Ansatz als *digital Driving* in Abgrenzung zum klassischen *analogen* Fahren.

Hier wird der Anspruch gestellt, mit einem Manöverkatalog jede Situation angemessen behandeln zu können. Darüber hinaus soll der Fahrer den kompletten Manöverkatalog schnell erlernen können, um eine hohe Nutzerakzeptanz zu erreichen.

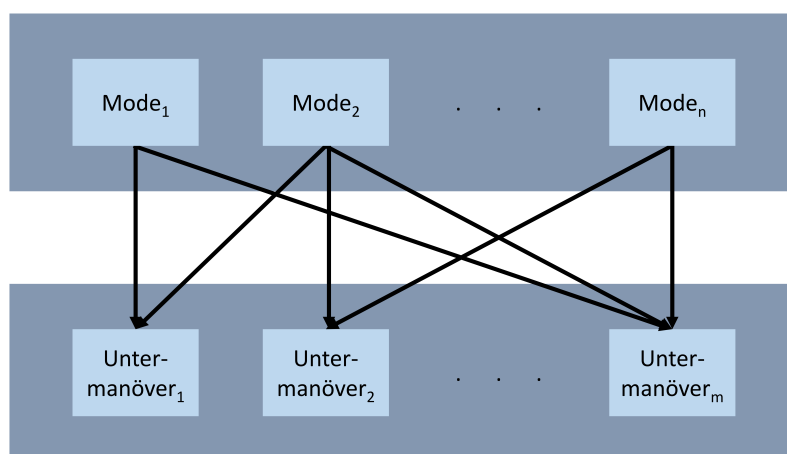


Abbildung 2.9: Zweistufige Hierarchie der Manöverebene

Daher wird der Ansatz verfolgt, die Manöverebene hierarchisch aufzubauen. Die Manöverebene wird, wie in Abbildung 2.9, in zwei Schichten strukturiert. Die erste Ebene bedient abstrahierte Ziele wie beispielsweise *Urban Mode* oder *Highway Mode*, welche der Fahrer wählen kann. In der unteren Schicht finden sich Teilmanöver wie Folgefahrt oder Fahrstreifenwechsel, welche das System für den Fahrer wählt. Je nach Modus auf der höheren Ebene steht dem System eine Teilmenge der Manöver zum Erreichen des Ziels zur Verfügung. Damit kann der Fahrer aus einem übersichtlichen Katalog an Manövern wählen. Ist der Fahrer mit der Fahrstrategie des Systems nicht einverstanden, so hat er jederzeit die Möglichkeit, auf das Lenkrad und die Pedalerie zurückzugreifen und damit das System zu überstimmen.

2.5 Fahrerintensionsprädiktion

Eine weitere Option, den Einsatz und Komfort von Fahrerassistenzsystemen zu steigern, besteht darin, die Fahrerintention zu prädizieren und das Systemverhalten damit möglichst gut zu adaptieren. In der Literatur finden sich zahlreiche Anwendungsgebiete (Bremsabsicht, Abbiegeintention, Fahrstreifenwechselabsicht, Querführungspräferenzen u.v.m) und vielfältige Verfahren für die Fahrerintensionsprädiktion, über welche im Folgenden ein Überblick gegeben wird.

Sommer und Engeln (2009) verfolgen in ihrer Arbeit das Ziel, durch eine Fahrerabsichtserkennung Notbremssysteme zu verbessern. Hierbei wird mittels Auswertung des Fahr- und Bremspedals eine Überstimmabsicht eines aktiven Notbremsvorgangs bzw. eine Vollbremsabsicht ermittelt. Bauer (2012) bestimmt auf Basis von Fuzzy-Logik eine fahreradaptive Kritikalität der aktuellen Situation, um ein Notbremssystem so zu optimieren, dass keine unnötigen Bremsengriffe erfolgen und dennoch, wenn notwendig, rechtzeitig eine automatische Notbremsung erfolgt. Um Warnungen vor Kollisionen mit Fußgängern zu bedarfsgerecht einzusetzen, wählen Diederichs u. a. (2015) Blickanalysen, um die Bremsintention der fahrzeugführenden Person zu prädizieren.

Herrmann (2013) optimiert ein Kollisionswarnungssystem, indem er die Abbiegeintention der fahrzeugführenden Person an Kreuzungen mittels Bayes'scher Netzes prädiziert. Die gleiche Anwendung adressieren Rodemerk u. a. (2015) dadurch, dass sie das beabsichtigte Manöver durch Ausschluss alternativer Manö-

ver auf Basis fahrdynamischer Daten, Kamera- u. Radarsensoren und der Kopfpose des Fahrers präzisieren. Anhand von Kostenfunktionalen für jedes Manöver bestimmt von Eichhorn (2015) eine Trajektorie und ermittelt die wahrscheinlichste Abbiegeabsicht des Fahrers durch einen Vergleich der Optimalkosten. Streubel und Hoffmann (2015) präzisieren die Fahrerabsicht an Kreuzungen mithilfe von Hidden Markov Models und Gauß'schen Mischverteilungen.

Zur Optimierung der Auswahl des aktuellen ACC-Zielobjekts setzen Schroven und Giebel (2008) ebenfalls Bayes'sche Netze ein, um zu unterscheiden, ob die Fahrerin bzw. der Fahrer ein Abbiegemanöver oder ein Überholmanöver plant. Eine andere Optimierung eines ACC-Systems wählen Kasper u. a. (2011), indem sie zur Prädiktion der Intention (Einscheren, Ausscheren, Folgen des Fahrstreifens) der weiteren Fahrzeuge objekt-orientierte Bayes'sche Netze wählen. Diese Gedanken entwickelt Weiser (2018) für den Einsatz beim automatisierten Fahren weiter, um mittels dynamischer Bayes'scher Netze eine Prädiktion über einen Fahrstreifenwechsel des eigenen als auch der weiteren Fahrzeuge vornehmen zu können. Heine (2018) hingegen versucht, mit der Prädiktion von innerstädtischen Fahrstreifenwechseln mittels Fuzzy-Logik Warnungen fahreradaptiv zu gestalten. Einen anderen Ansatz wählt Oschlies (2019). Um eine auf die Kundenbedürfnisse zugeschnittene Applikation der Querführungsassistenz zu erreichen, ermittelt er ein Gütekriterium für die menschliche Wahrnehmung der Querführung auf Basis von Korrelations- und Regressionsanalyse. Mithilfe des Gütekriteriums wird eine fahreradaptive Applikation nach objektiven Anforderungskriterien entwickelt.

Bei der Fahrerintention handelt es sich um eine weiche, nicht direkt messbare Größe. Somit machen sich viele der aktuellen Forschungsarbeiten auf diesem Gebiet Lernverfahren, wie beispielsweise Fuzzy-Logik, Hidden Markov Models, künstlich neuronale Netze und verschiedene Varianten von Bayes'schen Netzen zunutze, wie sie zum Teil auch in dieser Arbeit zur Anwendung kommen.

Kapitel 3

Theoretische Grundlagen

Im folgenden Kapitel werden die theoretischen Grundlagen der vorliegenden Arbeit beschrieben. Zuerst wird in Abschnitt 3.1 die angewendete Trajektorienplanung erläutert, mittels welcher die Fahrzeugbewegung der integrierten Längs- und Querführung geplant und vorgegeben wird. In Abschnitt 3.2 folgt eine Beschreibung und Gegenüberstellung verschiedener Lernverfahren, da im Rahmen dieser Arbeit mit einem maschinellen Lernverfahren eine Adaption des Systems auf verschiedene Fahrertypen vorgenommen wird. Zur Anwendung des Lernverfahrens wird abschließend in Abschnitt 3.3 auf ein Verfahren zur Bestimmung Gauß'scher Mischverteilungen zur Aufbereitung realer Messdaten eingegangen.

3.1 Trajektorienplanung

Generell sind für die Bestimmung einer Pfadvorgabe, welcher das Fahrzeug folgen soll, sowohl Verfahren zur Bahn- als auch Trajektorienplanung geeignet. Während sich die Bahnplanung insbesondere für statische und quasistatische¹ Umgebungen eignet, wie sie beispielsweise auf Parkplätzen zu finden sind, wird die Trajektorienplanung in der Regel dann verwendet, wenn die Zeit explizit in die Planung einbezogen werden soll. Da das innerhalb der Arbeit betrachtete Umfeld sowohl statische als auch dynamische Elemente beinhaltet, kommt eine Trajektorienplanung zur Anwendung.

In Abschnitt 3.1.1 wird zunächst das in dieser Arbeit angewendete Verfahren zur

¹Durch konservative Abschätzungen können langsame Bewegungen im Umfeld auf statische Situationen reduziert werden.

Trajektorienplanung auf Basis der Definition von getrennten Trajektorienbündeln vorgestellt. Die Beschreibung des Kostenfunktional zur Auswahl einer optimalen Trajektorie aus dieser Trajektorien­schar folgt in Abschnitt 3.1.2.

3.1.1 Verfahren zur Trajektorienplanung

Die verwendete Trajektorienplanung geht auf die Arbeit von Werling (2010) zurück. Es werden für die Längs- und Querbewegung des Fahrzeugs getrennt Trajektorienbündel entwickelt, welche unter Nutzung von Kostenfunktionen bewertet werden. Die getrennte Behandlung der Längs- und Queranteile ist möglich, da das System für den Komfortbereich ausgelegt wird und dadurch Wechselwirkungen der zu übertragenden Längs- und Querkräfte vernachlässigt werden können. Im folgenden Abschnitt wird dieses Verfahren vorgestellt.




Abbildung 3.1: Trajektorienbeschreibung in Frenet-Koordinaten der Referenzkurve (Werling 2010)

In aller Regel möchte eine Fahrerin oder ein Fahrer entweder dem Fahrstreifen folgen oder einen Fahrstreifenwechsel vornehmen und anschließend dem anderen Fahrstreifen folgen. Die Problemformulierung erfolgt in Frenet-Koordinaten $[n_r, t_r]$, damit sich die Trajektorienplanung am Fahrstreifenverlauf orientiert kann. Die Fahrstreifenmitte dient als Referenzkurve und die Querbewegung zu dieser Kurve wird als $d(t)$ beschrieben. Als zweiter Freiheitsgrad wird die Wegstrecke $s(t)$ entlang der Referenzkurve verwendet.

Damit lässt sich, wie in Abbildung 3.1 zu sehen, die Trajektorie x durch

$$x(s(t), d(t)) = r(s(t)) + d(t)n_r(s(t)) \quad (3.1)$$

beschreiben. Das Ziel der Trajektorienplanung ist, eine unter verschiedenen Kriterien optimale Trajektorie zu finden. Dafür wird das Kostenfunktional

$$J(d(t), s(t)) = J_d(d(t)) + k_s J_s(s(t)) \quad (3.2)$$

mit den über k_s gewichteten Kosten der Längs- und Querbewegung aufgestellt, welches zur Bestimmung der optimalen Trajektorie minimiert wird. Wichtig ist in diesem Zusammenhang insbesondere die Minimierung des Rucks², da ein hoher Ruck vom Fahrer als sehr unkomfortabel wahrgenommen wird. Daher formuliert Werling (2010) das Problem als Optimalsteuerungsproblem mit dem Ausgang $d(t)$ bzw. $s(t)$ und entsprechend dem Systemeingang $\ddot{d}(t)$ bzw. $\ddot{s}(t)$. Er weist nach, dass sich dieses Problem mit Polynomen fünfter Ordnung lösen lässt und zeigt auf, dass sich die Koeffizienten mit bekanntem Anfangszustand und bekanntem Endzustand zu einem bestimmten Endzeitpunkt ermitteln lassen.

In der vorliegenden Problemstellung ist nur der Anfangszustand tatsächlich bekannt. Werling (2010) fordert, dass zum Endzeitpunkt die erste und zweite zeitliche Ableitung identisch sind mit denen der Referenztrajektorie. Daher wird die Menge aller geeigneten Endzustände durch eine Zielmannigfaltigkeit beschrieben. Eine Abweichung von der Referenztrajektorie wird mit steigenden Kosten belegt. Der Zielraum wird durch verschiedene Restriktionen eingeschränkt, welche auch dynamischer Natur sein können. Außerdem sind kurze Rechenzeiten notwendig, um eine entsprechende Regelung auf die Trajektorie durchführen zu können. Daher wird die Zielmannigfaltigkeit diskretisiert. Es dürfen nur zu bestimmten Zeitpunkten bestimmte zur Referenzkurve relative Orte erreicht werden. Damit kann die Optimaltrajektorie grundsätzlich hinreichend gut berechnet werden.

Aus dieser Trajektorie werden die Sollgrößen für die Schnittstellen zu den verwendeten Aktoren abgeleitet.

3.1.2 Kosten

Im letzten Abschnitt wurde dargelegt, dass zur Bestimmung einer geeigneten Trajektorie das Kostenfunktional aus Gleichung 3.2 minimiert wird. Ein entscheidender Kostenfaktor ist der Ruck. Darüber hinaus gibt es weitere Faktoren, die gering

²Der Ruck beschreibt die temporale Ableitung der Beschleunigung

gehalten werden sollten. Es ist für die endgültige Fahrzeugbewegung relevant, welche Kosten ausgewertet und wie diese gegeneinander gewichtet werden. Die lateralen und longitudinalen Kosten werden getrennt bestimmt und anschließend über den Faktor k_s gewichtet, wie in Gleichung 3.2 zu sehen ist. Im Folgenden werden zuerst die lateralen und anschließend die longitudinalen Kosten näher erläutert.

Laterale Kosten

Als laterale Kosten werden die Einflussgrößen beschrieben, die bei der Querbewegung des Fahrzeugs möglichst gering gehalten werden sollten. Da die Kosten unterschiedlich stark in die Bestimmung der Trajektorie eingehen, werden diese über die Koeffizienten c_{di} gewichtet. Die Gesamtkosten der Querbewegung bestimmen sich aus der Summe der gewichteten Einzelkosten:

$$J_d = \sum_{i=0}^n \alpha_i \cdot c_{di}. \quad (3.3)$$

- **Querruck**

Das Komfortempfinden bei der Fahrzeugbewegung hängt stark vom Querruck ab. Es ist daher das Ziel, den Betrag des Rucks möglichst gering zu halten. Zur Auswertung wird das Integral über das Quadrat des Rucks über die komplette Zeitdauer der Trajektorie bis zum Endzeitpunkt T berechnet:

$$\int_0^T \ddot{d}(t)^2 dt. \quad (3.4)$$

- **Zeitdauer**

Ein weiteres Ziel ist, die gewünschte Querposition möglichst schnell zu erreichen. Daher geht auch die Zeitdauer in die Berechnung der Gesamtkosten ein.

- **Querabweichung**

Die Querabweichung von der Referenztrajektorie soll zum Endzeitpunkt möglichst gering sein. Daher trägt auch die Querabweichung zum Endzeitpunkt zu den Gesamtkosten bei.

- **Dichtes Passieren anderer Verkehrsteilnehmer**

Da dichtes Passieren eines Fahrzeugs auf dem Nachbarfahrstreifen von den Fahrzeuginsassen als unangenehm empfunden wird, wird ausgewertet, ob sich entlang der geplanten Trajektorie ein Fahrzeug (bei entsprechender Prädiktion des umgebenden Verkehrs) in der Komfortzone des Egofahrzeugs befindet. Zur Auswertung der Kosten wird betrachtet, wie stark ein oder mehrere Fahrzeuge in die Komfortzone eindringen.

- **Dichtes Passieren statischer Hindernisse**

Wie zuvor bei anderen Verkehrsteilnehmern wird auch bei statischen Hindernissen ausgewertet, wie stark sie sich im Verlauf der Trajektorie in der Komfortzone des Egofahrzeugs befinden.

- **Überfahren der Fahrstreifenmarkierung**

Der Fahrer möchte in aller Regel sein Fahrzeug innerhalb der Fahrstreifenmarkierung führen, sofern aktuell kein Fahrstreifenwechsel ausgeführt wird. Daher wird für die Trajektorie ausgewertet, wie lange und wie stark ggf. Markierungen überfahren werden.

- **Überschwingen**

Ein bestimmter Zielzustand kann auch nach einem Überschwingen über das Ziel hinaus erreicht werden. Ein starkes Überschwingen kann allerdings zu Irritationen beim Fahrer führen und als unangenehm empfunden werden. Daher wird hier die Weite und die Dauer des Überschwingens bei der Auswertung des Kosten berücksichtigt.

Longitudinale Kosten

Die longitudinalen Kosten beschreiben die Kosten in Längsrichtung der Fahrzeugbewegung. Wie in Gleichung 3.5 zu sehen, werden auch die longitudinalen Kosten gegeneinander gewichtet aufsummiert.

$$J_s = \sum_{j=0}^m \beta_j \cdot c_{sj} \quad (3.5)$$

- **Längsruck**

Der Längsruck beeinflusst das Komfortempfinden bei der Fahrzeugbewegung maßgeblich. Daher wird zur Bestimmung der Kosten das Ruckintegral über die komplette Zeitdauer T ausgewertet:

$$\int_0^T \ddot{s}(t)^2 dt. \quad (3.6)$$

- **Zeitdauer**

Ein Kostenfaktor, der dem Ruck entgegenwirkt, ist die Zeitdauer. Es ist eine Anforderung, die Zeitdauer bis zum Erreichen eines Zielzustandes möglichst gering zu halten.

- **Längsabweichung**

Eine Abweichung von der Zielposition ist ebenfalls ein Kostenfaktor. Je nach aktuellem Zielzustand ist ein Abweichen von der Zielposition mehr oder weniger kritisch. Beispielsweise beim Halten an einer Haltelinie ist ein starkes Abweichen von der Zielposition inakzeptabel, bei einer freien Fahrt hingegen durchaus tolerierbar.

- **Abweichung von der Zielgeschwindigkeit**

Weitere Kosten entstehen bei einem Abweichen von der Zielgeschwindigkeit. Das Erreichen und Halten einer bestimmten Zielgeschwindigkeit ist insbesondere vor dem Hintergrund wichtig, dass die Geschwindigkeit von der aktuellen Geschwindigkeitsbegrenzung abhängt.

- **Negative Geschwindigkeit**

Da Rückwärtsfahren systemseitig nicht unterstützt wird, ist es wichtig, dass mögliche negative Geschwindigkeiten im Verlauf einer Trajektorie mit deutlichen Kosten belegt werden.

- **Eintauchen in den Komfort- oder Sicherheitsabstand**

Das System berücksichtigt geschwindigkeitsabhängig einen Komfort- und einen Sicherheitsabstand und belegt das Unterschreiten jeweils mit Kosten. Das Unterschreiten des Sicherheitsabstandes wird dabei in einem höheren Maß berücksichtigt.

Durch die Wahl der einzelnen Gewichte der Kostenfaktoren und durch das Verhältnis der Gewichte zueinander wird die Auswahl der optimalen Trajektorie maßgeblich beeinflusst. Welche dieser Kosten mehr oder weniger stark gewichtet werden sollten, hängt von der gewünschten Auslegung der Fahrzeugführung ab. Daher bieten sich hier Freiheitsgrade, mittels der Gewichte fahrerindividuelle Präferenzen abzubilden.

3.2 Lernverfahren

Im letzten Abschnitt wurden die Trajektorienplanung für das System sowie die relevanten Kosten zur Auswahl einer optimalen Trajektorie dargestellt. Der gewünschte Zielzustand kann bei verschiedenen Personen unterschiedlich sein. Es ist davon auszugehen, dass der bevorzugte Komfort- und Sicherheitsabstand interindividuell unterschiedlich ist und zum Beispiel durch die eigene Fahrpraxis, Reaktionszeiten oder die Tagesform bestimmt wird. Im folgenden Abschnitt werden geeignete Verfahren betrachtet, um derartige Präferenzen zu ermitteln.

Zu Beginn des Unterkapitels werden in Abschnitt 3.2.1 Fuzzy-Mengen und -Logik beschrieben, mit deren Hilfe sich unscharfe Aspekte der Realität mathematisch abbilden lassen. Anschließend werden in Abschnitt 3.2.2 künstliche neuronale Netze betrachtet, mit welchen ohne Vorwissen komplexe Zusammenhänge gelernt werden können. In Abschnitt 3.2.3 folgt eine Darstellung von Bayes'schen Netzen, mit welchen die Komplexität einer probabilistischen Modellierung durch geschickte Konstruktion deutlich reduziert werden kann. Abschließend werden in Abschnitt 3.2.4 die spezifischen Vor- und Nachteile der Verfahren erörtert und ein Verfahren für die Fahrerintensionsprädiktion für die Anwendung in dieser Arbeit ausgewählt.

3.2.1 Fuzzy-Mengen und Fuzzy-Logik

Ein Defizit der klassischen Mathematik ist es, dass zur Modellierung oftmals eine Idealisierung der Realität vorgenommen werden muss und damit Sachverhalte verfälscht werden. Am Beispiel linguistischer Mengen lässt sich darstellen,

dass Aussagen nicht immer als eindeutig wahr oder falsch definiert werden können. Mittels der von Zadeh (1965) entwickelten Theorie der Fuzzy-Mengen und Fuzzy-Logik können solche unscharfen Aspekte der Realität mathematisch modelliert werden. Hier muss ein Objekt nicht wie in der klassischen zweiwertigen Logik eindeutig zugeordnet werden. Es kann hinsichtlich einer Eigenschaft einen Wahrheitswert aus dem Intervall $[0, 1]$ annehmen. Es ist beispielsweise schwierig, die Bewegung eines Fahrzeugs innerorts mit einer Geschwindigkeit von $45 \frac{km}{h}$ den linguistischen Werten *schnell* oder *langsam* eindeutig zuzuordnen. Die Vagheit dieser Begriffe lässt sich jedoch über Fuzzy-Mengen abbilden. Um den Grad der Zugehörigkeit darzustellen, werden häufig Dreiecks-, Trapez- oder Gaußfunktionen verwendet. Grundsätzlich können diese Funktionen beliebig komplex gestaltet werden. Diese Zugehörigkeitsfunktionen $\mu_i(x)$ bilden jeden Wert x einer Grundmenge auf das Intervall $[0, 1]$ ab (Kramer 2009).


Ein Fuzzy-System besteht im Allgemeinen aus der *Fuzzifizierung*, einem *Regelwerk* und der *Defuzzifizierung* (Halfmann und Holzmann 2003). Die Bildung der Zugehörigkeitsfunktionen wird als Fuzzifizierung bezeichnet. Mithilfe dieser Zugehörigkeitsfunktionen können komplexe Sätze formuliert werden, die die Prämissen einer Regelbasis des Systems bilden. Diese Prämissen beschreiben den WENN-Anteil einer WENN-DANN-Regel. Da die Prämissen aus mehr als einer Zugehörigkeitsfunktion bestehen können, wird in der Praxis für gewöhnlich einer der Operatoren aus der Tabelle 3.1 verwendet, um die Prämisse abzubilden.

Die Auswertung des Regelwerks wird als *Inferenz* bezeichnet. Die einzelnen Regeln an sich sind zumeist implizit mit einem *oder* verknüpft. Daher findet oft eine Maximumbildung, wie in der zweiten Zeile der Tabelle 3.1 zu sehen, der Konklusion Anwendung.


Zur Ermittlung einer diskreten Ausgangsgröße findet abschließend die *Defuzzifizierung* statt (Kluge 2006). Die gängigste Methode ist die Ermittlung des Schwerpunktes der Fläche, die von der Gesamtzugehörigkeitsfunktion und der Abszissenachse eingeschlossen wird. Weitere Methoden zur Bestimmung einer diskreten Ausgangsgröße sind beispielsweise die Max-Kriterium-Methode oder die Mittelwert-Maximum-Methode (Kramer 2009).

Fuzzy-Systeme bieten Transparenz in der Darstellung und das System kann mit Expertenwissen entworfen werden. Grundsätzlich können solche Systeme verhältnismäßig schnell implementiert werden, allerdings entstehen Schwierigkeiten, wenn eine exakte Feinabstimmung erforderlich ist.

Der Durchschnitt zweier Mengen entspricht dem sprachlichen „Und“:
 $\mu(x) = \text{Minimum}(\mu_A(x), \mu_B(x))$



Die Vereinigung zweier Mengen entspricht dem sprachlichen „Oder“:
 $\mu(x) = \text{Maximum}(\mu_A(x), \mu_B(x))$



Die einstellige Negation entspricht dem sprachlichen „Nicht“:
 $\mu(x) = 1 - \mu_B(x)$




Tabelle 3.1: Fuzzy-Operatoren (Kluge 2006)

3.2.2 Künstliche neuronale Netze

Bei künstlich neuronalen Netzen (KNN) werden die natürlichen neuronalen Netze nachgeahmt, wie sie im menschlichen Gehirn vorzufinden sind. Das menschliche Gehirn hat je nach Anwendung eine der höchsten oder die höchste Leistungsfähigkeit zur Informationsverarbeitung.




Abbildung 3.2: Schematischer Aufbau eines Neurons

Ein neuronales Netz besteht aus der Zusammenschaltung einzelner Neuronen. In Abbildung 3.2 ist ein gängiger schematischer Aufbau eines Neurons dargestellt, wobei auch vielfach andere Varianten von künstlichen Neuronen genutzt werden. Die sogenannte Aktivierungsfunktion berechnet sich aus der Summation der gewichteten Eingangssignale $w_i u_i$. Ist das Gewicht $w_i > 0$, so handelt es sich um ein anregendes Eingangssignal. Ein negativ gewichtetes Eingangssignal hingegen wirkt hemmend. Wie schon sehr früh von McCulloch und Pitts (1943) beschrieben, wird das Neuron aktiviert, wenn mit der Aktivierungsfunktion ein bestimmter Schwellwert θ überschritten wird. Das Ergebnis geht in die Ausgabefunktion γ ein, aus welcher sich der Ausgabewert des Neurons berechnet (Halfmann und Holzmann 2003). Werden die Eingänge und Ausgänge verschiedener Neuronen verknüpft, so entsteht ein neuronales Netz. In der technischen Anwendung werden oft sogenannte Multi-Layer-Perceptron (MLP)-Netze verwendet. Hier gibt es eine Eingabe- sowie Ausgabeschicht und dazwischen beliebig viele weitere Schichten aus Neuronen. Die Zwischenschichten sind verborgene Schichten, d.h. diese Schichten sind von außen nicht direkt ansprechbar. Mehrere Schichten sind notwendig, sofern komplexere Probleme als linear separierbare gelöst werden sollen.

Zur Lösung eines Problems mit einem neuronalen Netz muss dieses trainiert werden. Dabei werden die Gewichte und ggf. weitere Parameter angepasst. Prinzipiell gibt es drei verschiedene Lernarten bei neuronalen Netzen (Lippe 2006):

- **Überwachtes Lernen**

Ein Netz wird mit bekannten Ein- und Ausgangsdaten trainiert, indem mithilfe des Fehlers zwischen berechnetem Ergebnis und gewünschtem Ergebnis über eine Lernregel das Netz modifiziert wird.

- **Bestärkendes Lernen**

Ein Netz wird dadurch trainiert, indem in das Netz eingeht, ob eine berechnete Ausgabe korrekt ist oder nicht.

- **Unüberwachtes Lernen**

Ein Netz wird durch eingegebene Muster trainiert, indem es versucht, diese in Ähnlichkeitsklassen aufzuteilen.

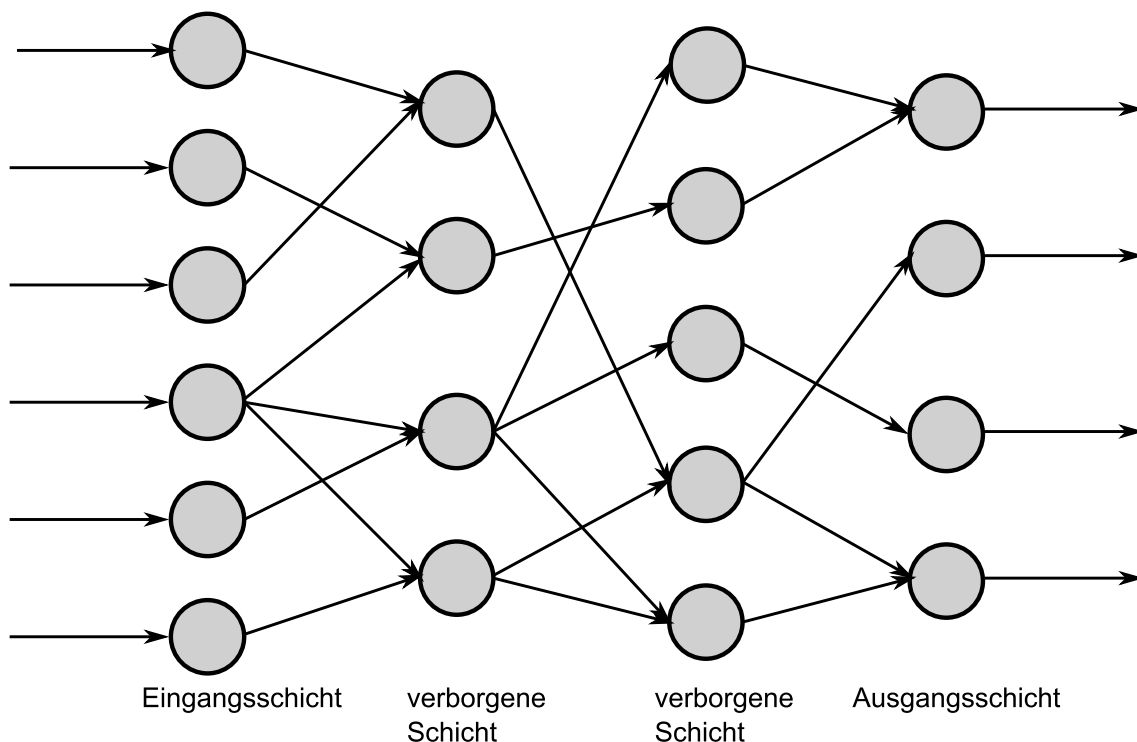


Abbildung 3.3: Beispielhafter Aufbau eines neuronalen Netzes

Neuronale Netze sind lernfähig und dabei fehlertolerant. Sie können bei fehlenden mathematischen Modellen eingesetzt werden. Wenn hingegen explizites Wissen über die Gegebenheiten bekannt ist, kann dieses nur sehr eingeschränkt beim Entwurf des Netzes eingebracht werden. Bei der gefundenen Lösung ist in aller Regel nicht klar, ob es sich um ein lokales oder globales Extremum handelt. Die innere Funktionsweise eines neuronalen Netzes ist für den Anwender

größtenteils intransparent und daher auch schwer zu erweitern.

3.2.3 Bayes'sche Netze

Der Begriff Bayes'sche Netze wurde Mitte der achtziger Jahre von Pearl (1985) geprägt. In seinen späteren Arbeiten (Pearl 2009) betonte er insbesondere die folgenden drei Eigenschaften von Bayes'schen Netzen:

- Subjektive Natur von Eingangsinformationen
- Nutzung der Bayes'schen Formel als Basis für die Verarbeitung von neuen Informationen
- Unterscheidung von kausalem und evidenzbasiertem Schließen

Laut Borth (2004) vereinen graphenbasierte Modelle die Methoden der Graphentheorie und der klassischen Wahrscheinlichkeitstheorie, um den Problemen Komplexität und Unvollständigkeit bzw. Unsicherheit der Modellbildung effektiv zu begegnen. Die Komplexität wird durch die Anwendung von Graphen adressiert. Damit können intuitiv Beziehungen und Zerlegungen abgebildet und effiziente Algorithmen abgeleitet werden. Der Unvollständigkeit bzw. Unsicherheit wird mit der Wahrscheinlichkeitstheorie begegnet.

Genauer betrachtet werden Bayes'sche Netze mit gerichteten azyklischen Graphen dargestellt, welche aus Knoten und Kanten bestehen.

- **Gerichtet:** Die Kanten verfügen über eine Richtung, d. h. es ist festgelegt, ob eine Kante E von Knoten x_i zu Knoten x_j führt oder umgekehrt.
- **Azyklisch:** Vom Knoten x_i gibt es keinen Pfad³, der zurück zu x_i führt.

Die Knoten repräsentieren Zufallsvariablen und die Kanten beschreiben die kausalen Abhängigkeiten zwischen diesen Variablen. Die Menge $\{x_1, \dots, x_n\}$ beschreibt die Menge aller diskreten Zufallsvariablen eines Bayes'schen Netzes, welche jeweils die r_i Zustände der Menge $\{v_i^1, \dots, v_i^{r_i}\}$ annehmen können. Ein Knoten x_i mit gerichteter Verbindung zu einem Knoten x_j wird als Elternknoten von x_j bezeichnet (Koski und Noble 2009). Die Menge $\Pi_i = \{w_i^1, \dots, w_i^{q_i}\}$ beschreibt die Elternknoten des Knoten x_i sowie deren möglichen Konfigurationen w_i^j . In Abbildung

³Weg entlang gerichteter Kanten

3.4 ist beispielsweise x_1 der Elternknoten von x_2 , die Knoten x_3 und x_4 sind Kindsknoten von x_2 und durch die gerichteten Kanten werden die Abhängigkeiten der Knoten untereinander beschrieben.




Abbildung 3.4: Beispiel für ein Bayes'sches Netz

Diese Strukturierung birgt eine der großen Stärken der Bayes'schen Netze. Ist die Abhängigkeit bzw. Unabhängigkeit von Variablen bekannt, so wird dies direkt durch gerichtete Kanten bzw. nicht vorhandene Verbindungen abgebildet. Damit kann durch geschickte Konstruktion des Netzes die Komplexität eines Problems signifikant reduziert werden. Für jeden Knoten existiert eine Tabelle, mit welcher die Beziehungen eines Knotens zu den Elternknoten durch bedingte Wahrscheinlichkeiten quantifiziert werden. Verfügt ein Knoten über keinen Elternknoten, so ist eine Tabelle mit A-priori-Wahrscheinlichkeiten (unbedingte Wahrscheinlichkeiten) notwendig (Ertel 2013).

Ein Bayes'sches Netz ist vollständig beschrieben, wenn die Struktur sowie die Tabellen mit den bedingten Wahrscheinlichkeiten gegeben sind.

Damit lässt sich mit dem Graphen die gemeinsame Verteilung über alle Zufallsvariablen in ein Produkt von Faktoren zerlegen, welche nur von einer Teilmenge der Variablen abhängt (Bishop u. a. 2006).

Es gibt verschiedene Möglichkeiten der Informationsverarbeitung in Bayes'schen Netzen. Inferenz⁴ wird beispielsweise angewendet für

- **Prognose**

Bei einer Prognose wird die Wirkung eines Einflusses oder einer Ursache vorhergesagt (Borth 2004).

⁴Schließen unter Unsicherheit

- **Diagnose**

Bei einer Diagnose wird eine Wirkung beobachtet und darüber ein Rückschluss auf die Ursache bzw. die Einflüsse gebildet (Borth 2004).

Es wird Evidenz, also eine Aussage über den Zustand einer oder mehrerer Variablen, in ein Bayes'sches Netz eingebracht. Dadurch werden Eltern- und Kindsknoten direkt und an diesen verbundene Knoten indirekt beeinflusst.




Abbildung 3.5: Bayes'sches Netz zur Darstellung diagnostischer und prognostischer Inferenz

Handelt es sich beispielsweise im Bayes'schen Netz aus Abbildung 3.5 beim Knoten x um einen nicht-beobachtbaren Knoten, dessen Zustand mittels der Zustände seiner Eltern- und Kindknoten bestimmt werden soll, so muss sowohl prognostische als auch diagnostische Inferenz angewendet werden. Der diagnostische Einfluss der Kindknoten n_1, n_2, \dots, n_m lässt sich beschreiben mit:

$$P(x = x_i | n_1, n_2, \dots, n_m) = \frac{P(x_i) \cdot \prod_{j=1}^m P(n_j | x_i)}{\sum_{l=1}^r P(x_l) \cdot \prod_{j=1}^m P(n_j | x_l)} \text{ mit } 1 \leq i \leq r. \quad (3.7)$$

Die Herleitung der Gleichung 3.7 kann Appendix B.1 entnommen werden. Da der Knoten x des Bayes'schen Netz aus Abbildung 3.5 allerdings über n Elternknoten verfügt, wird der Term $P(x_i)$ aus Gleichung 3.7 mithilfe prognostischer Inferenz durch $P(x_i | e_1, e_2, \dots, e_n)$ ersetzt. Bei vollständig observierten Elternknoten kann dieser Wert der entsprechenden Tabelle mit den Übergangswahrscheinlichkeiten entnommen werden.

Beispiel

In diesem Beispiel hat Bob eine Alarmanlage (Al) in seinem Haus installiert. Da Bob berufsbedingt oft außer Haus ist, hat er seine Nachbarn John (J) und Mary (M) gebeten, ihn anzurufen, wenn die Sirene der Alarmanlage ertönt. Mary ist allerdings schwerhörig und überhört teilweise die Sirene. John verwechselt manches Mal die Alarmanlage mit einer Anlage aus einem benachbarten Haus. Die Alarmanlage kann durch einen Einbruch (Ein) oder ein Erdbeben (Erd) ausgelöst werden, wobei Bob nur angerufen werden möchte, wenn es sich bei der Ursache um einen Einbruch handelt. Wie in Abbildung 3.6 zu sehen, sind all diese Zusammenhänge zum einen durch die Struktur des Netzes und zum anderen durch die jeweiligen Wahrscheinlichkeitstabellen dargestellt (Ertel 2013).

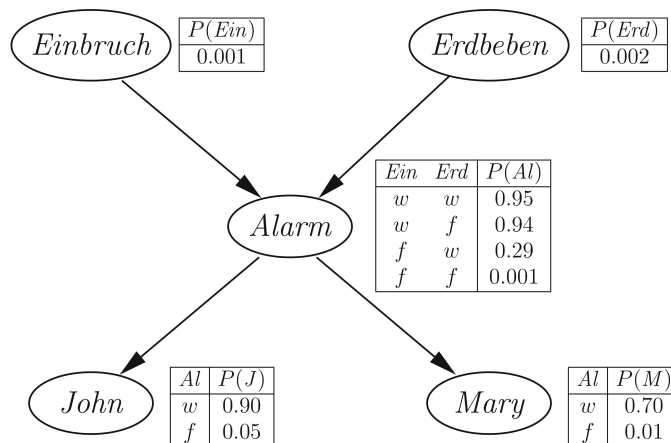


Abbildung 3.6: Alarmbeispiel für ein Bayes'sches Netz (Ertel 2013)

In diesem Beispiel kann eine prognostische Inferenz durchgeführt werden, um beispielsweise die Wahrscheinlichkeit zu bestimmen, dass Mary im Falle eines Einbruchs anruft: $P(M|Ein) \approx 66\%$ ⁵.

Eine diagnostische Inferenz kann genutzt werden, um die Wahrscheinlichkeit zu ermitteln, dass es einen Alarm gibt unter der Bedingung, dass John anruft: $P(Al|J) \approx 4.3\%$ ⁶.

Eine anschauliche Weitergabe von Informationen in einem Bayes'schen Netz ist der Message-Passing-Algorithmus von Pearl (1986). In Abbildung 3.7(a) ist das Bayes'sche Netz im Gleichgewicht dargestellt. In (b) wird neue Evidenz (DATA) in

⁵Die Berechnung kann Appendix B.2.1 entnommen werden.

⁶Die Berechnung kann Appendix B.2.2 entnommen werden.

das Netz eingebracht. Daraus lässt sich diagnostisch ein Rückschluss auf die jeweiligen Elternknoten ableiten. Durch die Veränderung dieser Knoten wird deren gemeinsamer Elternknoten, wie in (c) zu sehen, ebenfalls diagnostisch und deren bisher unberührte Kindknoten kausal beeinflusst. Dieser Prozess setzt sich fort, bis nach (f) sich das Bayes'sche Netz wieder im Gleichgewicht befindet.




Abbildung 3.7: Ablauf Message-Passing-Algorithmus (Pearl 1986)

Lässt sich einer Zufallsvariablen ein eindeutiger Wert zuordnen, so wird dies als *harte Evidenz* bezeichnet. Kann jedoch nur eine Aussage über die Wahrscheinlichkeit der aktuellen Zustände einer Zufallsvariablen getroffen werden, so wird von *weicher Evidenz*⁷ gesprochen (Bilmes 2004).

Die häufigsten Ursachen von *weicher Evidenz* sind (Xiao u. a. 2009):

- Der Zustand einer diskreten Variablen lässt sich nur mit einer Wahrscheinlichkeit angeben, da sie nicht direkt beobachtbar ist oder geschlossen werden kann.
- Eine Variable hat in der Realität unscharfe Grenzen.

⁷Engl.: soft evidence

- Beim Diskretisieren von kontinuierlichen Variablen ergeben sich Überschneidungen der Intervalle und damit keine scharfen Grenzen.

Bei *weicher Evidenz* einer Zufallsvariablen liegt für jeden möglichen Zustand v_i^k immer auch eine zugehörige Eintrittswahrscheinlichkeit p_i^k vor:

$$\bar{x}_i = \{(v_i^1, p_i^1), \dots, (v_i^{r_i}, p_i^{r_i})\} \quad (3.8)$$

mit $\sum_{k=1}^{r_i} p_i^k = 1$. Die Erzeugung eines Hilfsknotens o_i bietet eine Möglichkeit, *weiche Evidenz* in die Struktur eines Bayes'schen Netzes einzubringen. Wie in Abbildung 3.8 zu sehen, hat damit der Knoten o_i als Elternknoten nur x_i .




Abbildung 3.8: Darstellung von *weicher Evidenz* mit einem Hilfsknoten (Xiao u. a. 2009)

Die bedingte Wahrscheinlichkeit wird dann beschrieben als:

$$P(o_i = \bar{x}_i | x_i = v_i^k) = p_i^k, \quad (3.9)$$

was bedeutet, wenn die Variable x_i den Zustand v_i^k annimmt, dass $o_i = \bar{x}_i$ ist mit der Wahrscheinlichkeit p_i^k (Xiao u. a. 2009). Zur Bestimmung der A-posteriori-Wahrscheinlichkeit $P'(x_i)$ kann Jeffreys Regel angewendet werden (Bilmes 2004):

$$P'(x_i) = \sum_{k=1}^{r_i} P(o_i = \bar{x}_i) P(x_i = v_i^k | o_i = \bar{x}_i). \quad (3.10)$$

Diese Regel kann angewendet werden, wenn es im Bayes'schen Netz nur eine Variable mit Hilfsknoten für die Verarbeitung von *weicher Evidenz* gibt. Liegt für mehrere Knoten in einem Bayes'schen Netz *weiche Evidenz* vor, so kann zur Auswertung des Netzes eine Variation des Junction-Tree-Algorithmus angewendet werden (Valtorta u. a. 2002). Daher wird im Folgenden zunächst der Junction-Tree-Algorithmus beschrieben und anschließend die Erweiterung, um das Netz

mit *weicher Evidenz* aktualisieren zu können. Ein Bayes'sches Netz kann wie folgt in einen Junction-Tree transformiert werden (Sucar 2015).

Zuerst wird die Richtung der Kanten entfallen gelassen und der Graph moralisiert, d.h. eine Kante zwischen Knoten mit gemeinsamen Kindsknoten eingefügt. Dieser Schritt ist in Abbildung 3.9 von (a) originalem Bayes'schem Netz zu (b) zu sehen. Falls Zyklen mit der Länge vier oder größer existieren, müssen zusätzliche Kanten eingezeichnet werden, sodass der Graph trianguliert ist.




Abbildung 3.9: Transformation eines Bayes'schen Netzes in einen Junction-Tree (Sucar 2015)

Anschließend werden Cluster gebildet, welche wiederum Knoten in einem Junction-Tree repräsentieren. Die Cluster werden so angeordnet, dass die Running-intersection-Eigenschaft erfüllt ist.

- **Running-intersection**

Für jedes Paar von Clustern C_i und C_j , das jeweils den gleichen Knoten K enthält, muss jedes Cluster auf dem Pfad zwischen C_i und C_j ebenfalls den Knoten K enthalten (Lauritzen und Spiegelhalter 1988).

Die Running-intersection-Eigenschaft kann dadurch erreicht werden, dass den Knoten im ungerichteten Graphen mittels maximaler Kardinalitätssuche⁸ eine Reihenfolge zugeordnet wird. Werden die Cluster entsprechend der Reihenfolge ihrer Knoten anschließend in einem Junction-Tree angeordnet, ist die Running-intersection-Eigenschaft erfüllt (Lauritzen und Spiegelhalter 1988). Die Knoten,

⁸Ein beliebiger Knoten erhält Nummer eins. Die weiteren Knoten werden fortlaufend nummeriert, indem immer der Nachbarknoten gewählt wird, der die meisten bereits nummerierten Nachbarn hat. Bei einem Gleichgewicht wird zufällig der nächste Knoten gewählt (Lauritzen und Spiegelhalter 1988).

die sich sowohl in einem Cluster C_i als auch im benachbarten Cluster C_j befinden, werden als Separatoren S_{ij} bezeichnet. Ein Beispiel für einen Junction-Tree ist in Abbildung 3.9 (c) zu sehen.




Abbildung 3.10: Beispiel eines einfachen Bayes'schen Netzes und des zugehörigen Junction-Tree (Barber 2003)

Anschließend werden den Clustern und den Separatoren Potentiale zugewiesen. Die Wahrscheinlichkeitsverteilung über das Bayes'sche Netz in Abbildung 3.10 (a) lautet:

$$p(a,b,c,d) = p(a|b)p(b|c)p(c|d)p(d). \quad (3.11)$$

Initial werden den Potentialen der Cluster die Wahrscheinlichkeitstabellen der zugehörigen Knoten zugeordnet und die Potentiale der Separatoren auf eins gesetzt. Damit ergeben sich für das Beispiel aus Abbildung 3.10 die Potentiale $\psi(a,b) = p(a|b)$, $\psi(b,c) = p(b|c)$, $\psi(c,d) = p(c|d)p(d)$, $\psi(b) = 1$ und $\psi(c) = 1$. Dadurch lässt sich die Wahrscheinlichkeitsverteilung aus der Gleichung 3.11 auch wie folgt beschreiben (Barber 2003):

$$p(a,b,c,d) = \frac{\psi(a,b)\psi(b,c)\psi(c,d)}{\psi(b)\psi(c)}. \quad (3.12)$$

Es folgen eine Sammelphase und eine Verteilungsphase von Botschaften. Dafür wird zuerst ein beliebiges Root-Cluster benannt. Für die folgende Beschreibung wird das Cluster $\{C,D\}$ in Abbildung 3.10 als Root-Cluster gewählt. In der Sammelphase werden ausgehend von den entferntesten Clustern des Root-Clusters die Potentiale der Separatoren aktualisiert, indem über alle Variablen marginalisiert wird, die nicht Teil des Separators sind:

$$\psi^*(b) = \sum_a \psi(a,b). \quad (3.13)$$

Anschließend wird das Potential des benachbarten Clusters aktualisiert mit dem

Ziel, dass die Verbindung der beiden Cluster konsistent bleibt:

$$\psi^*(b, c) = \frac{\psi^*(b)}{\psi(b)} \psi(b, c). \quad (3.14)$$

Dies wird fortgesetzt, bis das Potential des Root-Clusters zu $\psi^*(c, d)$ aktualisiert wurde. Nun folgt die Verteilungsphase, indem ausgehend vom Root-Cluster zuerst die Potentiale der angeschlossenen Separatoren mittels Marginalisierung aktualisiert werden:

$$\psi^{**}(c) = \sum_d \psi^*(c, d). \quad (3.15)$$

Anschließend werden die Potentiale der benachbarten Cluster wieder angepasst:

$$\psi^{**}(b, c) = \frac{\psi^{**}(c)}{\psi^*(c)} \psi^*(b, c). \quad (3.16)$$

Die Botschaft wird auf diese Weise durch den Junction-Tree transportiert, bis alle Potentiale der Cluster und Separatoren aktualisiert wurden. Durch Einhaltung der beschriebenen Reihenfolge ist das Message-Passing-Protokoll⁹ erfüllt. Dadurch ergibt sich nicht nur lokale Konsistenz zwischen den benachbarten Clustern C_i und C_j :

$$\sum_{C_i \setminus S} \psi(C_i) = \psi(S) = \sum_{C_j \setminus S} \psi(C_j), \quad (3.17)$$

sondern globale Konsistenz für beliebige Cluster C_i und C_j im Junction-Tree.

Der Junction-Tree-Algorithmus ist gültig, wenn *harte Evidenz* im Netz vorliegt. Bei *weicher Evidenz* werden die Potentiale mit diesem Verfahren nicht konvergieren. Daher haben Valtorta u. a. (2002) den Big-Clique-Algorithmus¹⁰ entwickelt, welcher den Junction-Tree-Algorithmus so adaptiert, dass *harte* als auch *weiche Evidenz* verarbeitet werden können.

Der Big-Clique-Algorithmus wird im Folgenden beschrieben. Zuerst wird ein Junction-Tree gebildet, bei welchem sich alle Variablen $\{A_1, A_2, \dots, A_k\}$ in einem großen Cluster befinden, für die *weiche Evidenz* $P(A_j), 1 \leq j \leq k$ vorliegt. Anschließend wird der zuvor beschriebene klassische Junction-Tree-Algorithmus nur unter Verwendung der *harten Evidenz* ausgeführt. Nun wird in das große Cluster C die *weiche Evidenz* der Variablen aufgenommen, indem das iterative Verfahren zur

⁹Ein Cluster C_i kann nur eine Botschaft an seinen Nachbarn C_j schicken, wenn C_i zuvor von allen anderen Nachbar-Clustern eine Botschaft erhalten hat (Barber 2003).

¹⁰Clique und Cluster werden in dieser Arbeit synonym verwendet.

proportionalen Adaptierung nach Valtorta u. a. (2002) angewendet wird:

$$\psi_{(i)}(C) = \frac{\psi_{(i-1)}(C) \cdot P(A_j)}{\sum_{C \setminus A_j} \psi_{(i-1)}(C)}. \quad (3.18)$$

Es wird so lange über alle Variablen mit *weicher Evidenz* iteriert, bis das Verfahren konvergiert. Anschließend wird äquivalent zu der Verteilungsphase des Junction-Tree-Algorithmus das Ergebnis über die Separatoren an alle anderen Cluster übermittelt.

Mit dem hier beschriebenen Verfahren kann ein Bayes'sches Netz ausgewertet werden, wenn *harte Evidenz* und für mehr als eine Variable zusätzlich *weiche Evidenz* vorliegt.

Lernen von Bayes'schen Netzen

Zur Bestimmung der Übergangswahrscheinlichkeiten wie auch der Netztopologie existieren nach Darwiche (2009) zwei Möglichkeiten:

- Expertenwissen
- Trainingsdaten

Expertenwissen wird eingesetzt, indem ein Experte mit seiner subjektiven Erfahrung die Struktur des Netzes entwirft oder A-priori- und Übergangswahrscheinlichkeiten zuweist (Charniak 1991).

Das Lernen der Struktur eines Bayes'schen Netzes auf Basis von Trainingsdaten hat den Vorteil, dass kein Vorwissen über inhaltliche Zusammenhänge vorhanden sein muss. Allerdings können dabei sehr komplexe Strukturen mit vielfachen Verbindungen entstehen, deren Rechenaufwand erheblich ist. Zusätzlich sind so gelernte Strukturen oftmals nicht intuitiv verständlich und inhaltlich schwer nachvollziehbar (Lam und Bacchus 1994).

Allerdings kann die Struktur von Bayes'schen Netzen auch mit Expertenwissen entworfen werden, wodurch Beziehungen wie insbesondere Unabhängigkeiten direkt abgebildet werden können. Damit lässt sich die Komplexität der Modellierung gezielt reduzieren. Es entstehen Netze, die intuitiv verständlich und deren Auswertung leicht nachvollziehbar ist.

Die A-priori- bzw. bedingten Wahrscheinlichkeiten θ können insbesondere bei

großen Datenmengen gelernt werden. Unter Anwendung der folgenden Annahmen:

- Die Variablen der Datenbasis sind unabhängig.
- Die Fälle treten bei einem gegebenen Bayes'schen Netz unabhängig auf.
- Es gibt keine Fälle mit Variablen, für die keine Werte existieren.
- Die Verteilung $P(\theta_{ij1}, \dots, \theta_{ijr_i})$ ist eindeutig für $1 \leq i \leq n, 1 \leq j \leq q_i$.

lässt sich nach (Cooper und Herskovits 1992) der Erwartungswert für

$$\theta_{ijk} = P(x_i = v_i^k | w_i^j) \quad (3.19)$$

eines Bayes'schen Netzes B_s auf Basis der Datenmenge \mathbf{D} folgendermaßen schätzen:

$$E(\theta_{ijk} | B_s, \mathbf{D}) = \frac{N_{ijk} + 1}{N_{ij} + r_i}. \quad (3.20)$$

N_{ijk} beschreibt die Anzahl von Fällen in \mathbf{D} , in welchen die Variable x_i den Zustand v_i^k hat und die Elternknoten als Konfiguration w_i^j instantiiert sind. Die Kardinalität¹¹ der Wertemenge $\{v_i^1, \dots, v_i^{r_i}\}$ der Variablen x_i ist r_i und ebenfalls nach (Cooper und Herskovits 1992) ist:

$$N_{ij} = \sum_{k=1}^{r_i} N_{ijk}. \quad (3.21)$$

Im Folgenden wird das Vorgehen nach Xiao u. a. (2009) beschrieben, mit welchem das Verfahren von Cooper und Herskovits (1992) für die Anwendung beim Vorliegen von *weicher Evidenz* erweitert wird. Dafür wird die Variable E_i eingeführt, welche ein zufälliges Event beschreibt, bei welchem x_i und die Elternknoten Π_i eine unbekannte Instantiierung annehmen. Damit lässt sich N_{ijk} bestimmen als:

$$N_{ijk} = \sum_{h=1}^m P(E_i = e_{ijk} | C_h). \quad (3.22)$$

Dabei stellt e_{ijk} ein Event dar, in dem die Zufallsvariable x_i den Zustand v_i^k annimmt und w_i^j die Instantiierung der Elternknoten Π_i ist. C_h gibt an, dass es sich um den h -ten Fall aus der Datenbasis handelt und m beschreibt die Gesamtanzahl an Fällen. Wie in Formel 3.8 dargestellt, beschreibt p_i^k die Wahrscheinlichkeit, dass die Zufallsvariable x_i den Zustand v_i^k annimmt und p_{in}^{jn} entsprechend

¹¹Anzahl der Elemente einer Menge

die *weiche Evidenz* der Elternknoten. Damit lässt sich die Wahrscheinlichkeit $P(E_i = e_{ijk}|C_h)$ mit $n = 1, \dots, l$ und l als Anzahl der Elternknoten folgendermaßen berechnen:

$$P(E_i = e_{ijk}|C_h) = p_i^k \prod_{n=1}^l p_{in}^{j_n}. \quad (3.23)$$

So trägt jeder Fall C_h mit dem Faktor $P(E_i = e_{ijk}|C_h)$ zu Formel 3.22 bei und mit Einsetzen in Formel 3.20 lässt sich der Erwartungswert für θ_{ijk} bei *weicher Evidenz* schätzen.

3.2.4 Gegenüberstellung der Verfahren

Um ein geeignetes Verfahren für die Prädiktion von Fahrerintentionen zu ermitteln, welche im Rahmen der zweiten Forschungsfrage (F2) adressiert wird, wurden in den vorangegangenen Abschnitten zunächst Fuzzy-Mengen und -Logik, künstlich neuronale Netze sowie Bayes'sche Netze im Detail betrachtet. Im Folgenden werden die Vor- und Nachteile der Verfahren gegeneinander abgewogen, welche in Tabelle 3.2 zusammengefasst sind, um daraus abgeleitet ein Verfahren für den definierten Anwendungsfall auszuwählen.

Fuzzy-Systeme eignen sich sehr gut, um unscharfe Informationen abzubilden, wie sie in der Realität häufig auftreten. Durch die Anwendung von WENN-DANN-Regeln ist das erzeugte Verhalten transparent und nachvollziehbar. Allerdings ist die Feinabstimmung bei komplexen Systemen sehr aufwendig und muss bei jeder Anpassung erneut vorgenommen werden.

Künstliche neuronale Netze hingegen bieten den großen Vorteil, bei wenig Vorwissen und angemessenen Lerndaten gute Ergebnisse zu liefern. Nachteilig ist allerdings, dass kaum nachvollziehbar ist, wie das Netz gelernt hat, und welche Faktoren welchen Einfluss haben. Eine große Rolle spielt daher die Qualität und Auswahl der Trainingsdaten, um relevante Effekte lernen zu können.

Bei Bayes'schen Netzen hingegen können kausale Zusammenhänge direkt abgebildet werden, indem die Struktur vorab durch Expertenwissen entworfen wird, wodurch das Ergebnis transparent und nachvollziehbar ist. Unscharfe Informationen lassen sich zudem gut über das Konzept der *weichen Evidenz* abbilden.

Im Hinblick auf die praktische Relevanz der Ergebnisse, beispielsweise vor dem Hintergrund einer Absicherung für einen Serieneinsatz, ist unter anderem die

Transparenz der inneren Logik des Systems wichtig, insbesondere um sicherzustellen, dass keine falschen Effekte unentdeckt vom System gelernt wurden. Letzteres spricht gegen den Einsatz von künstlich neuronalen Netzen. Durch die Analyse der spezifischen Verkehrssituationen liegen Informationen über deren kausale Zusammenhänge vor. Es bietet sich daher an, diese bei einem Verfahren einzusetzen, statt ein Verfahren zu wählen, welches die Struktur des Modells schätzt. Solche kausalen Zusammenhänge lassen sich sowohl sehr gut mit Bayes'schen Netzen als auch mit Fuzzy-Logik bei vergleichsweise geringer Rechenkomplexität abbilden. Durch die geringere Rechenkomplexität kann die Echtzeitfähigkeit des Systems erreicht werden, welche eine zwingende Voraussetzung für den Einsatz eines regelnden Systems in einem Fahrzeug ist. Im Hinblick auf die Adaption an neue Einflussfaktoren, weitere Sensoren etc. erscheinen Bayes'sche Netze vielversprechender, da Fuzzy-Systeme einen erheblichen wiederkehrenden Aufwand bei der Feinabstimmung mitbringen. Im Rahmen dieser Arbeit wird dies als ein Ausschlusskriterium für Fuzzy-Systeme betrachtet. Auch Bayes'sche Netze bringen einen deutlichen Nachteil und zwar die Festlegung der A-priori-Wahrscheinlichkeiten, da diese bei Entwurf mittels Expertenwissen ebenfalls ein hohes Maß an wiederkehrender Feinabstimmung benötigen. Im vorliegenden Anwendungsfall können diese jedoch aus den Messdaten einer Realfahrstudie (s. Abschnitt 5.4) gelernt und somit wissenschaftlich transparent und objektiv festgelegt werden.

Methoden	Eigenschaften
Fuzzy	+ Transparente Darstellung + Entwurf mit Expertenwissen - schwierige Feinabstimmung
Künstliche neuronale Netze	+ Lernfähigkeit + Fehlertoleranz - Expertenwissen eingeschränkt nutzbar - intransparente innere Logik
Bayes'sche Netze	+ Entwurf mit Expertenwissen + intuitive, transparente innere Logik + einfache Struktur - Wahl von A-priori-Wahrscheinlichkeiten

Tabelle 3.2: Gegenüberstellung der Methoden

3.3 Gauß'sche Mischverteilungen

Die Verwendung von Gauß'schen Mischverteilungen als Klassifikation eignet sich für Anwendungen, in welchen die zeitliche Information der kontinuierlichen Messdaten eine untergeordnete Rolle spielt. Vielmehr wird bei geeigneter Anzahl von Messdaten die Form des Histogramms der Messdaten, insbesondere der Minima und Maxima, berücksichtigt.

Gauß'sche Mischverteilungen können für kontinuierliche Messdaten als parametrisches Modell von Wahrscheinlichkeitsverteilungen angewendet werden. Dafür wird die Wahrscheinlichkeitsverteilung als Summe von gewichteten Gaußverteilungen dargestellt (Reynolds 2015):

$$p(x, \lambda) = \sum_{i=1}^M w_i g(x|\mu_i, \Sigma_i) \quad (3.24)$$

x ist in der vorliegenden Anwendung der Vektor mit den Messdaten, M die Anzahl der Verteilungen $g(x|\mu_i, \Sigma_i)$ und w_i sind die Gewichtungsfaktoren der einzelnen Verteilungen. Die Summe aller Gewichtungsfaktoren w_i muss eins ergeben. $\lambda = \{w_i, \mu_i, \Sigma_i\}$ mit $i = 1, \dots, M$ beschreibt die Modellparameter. Da es sich in der vorliegenden Anwendung nicht um mehrdimensionale¹² Eingangsgrößen handelt, wird das Verfahren im Folgenden für einen Messdatenvektor, bestehend aus Skalaren, dargestellt. Jede einzelne Dichtefunktion ist eine Gaußverteilung der Form:

$$g(x|\mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (3.25)$$

mit dem Mittelwert μ und der Varianz σ^2 .

Zur Schätzung der Modellparameter eignet sich der Expectation-Maximization-Algorithmus (EM-Algorithmus). Dabei handelt es sich um ein iteratives Verfahren zur Schätzung der wahrscheinlichsten Parameter eines stochastischen Modells (Dempster u. a. 1977).

Im Expectation-Schritt wird die Zuordnung der Messdaten zu den einzelnen Gaußverteilungen vorgenommen und im Maximization-Schritt die Parameter des Modells mit den neuen Zuordnungen optimiert.

¹²Generell lässt sich dieses Verfahren auch auf mehrdimensionale Datensätze anwenden (Reynolds 2015).

Im Expectation-Schritt wird die A-posteriori-Wahrscheinlichkeit

$$p(i|x_j, \lambda) = \frac{w_i g(x_j | \mu_i, \sigma_i^2)}{\sum_{l=1}^M w_l g(x_j | \mu_l, \sigma_l^2)} \quad (3.26)$$

berechnet, um zu bestimmen, wie gut eine einzelne Gaußverteilung zur Gesamtverteilung der Messdaten x_j mit $j = 1, \dots, N$ passt.

Im Maximization-Schritt werden damit die Modellparameter für $i = 1, \dots, M$ angepasst:

$$w_i = \frac{1}{N} \sum_{j=1}^N p(i|x_j, \lambda) \quad (3.27)$$

$$\mu_i = \frac{\sum_{j=1}^N p(i|x_j, \lambda) \cdot x_j}{\sum_{j=1}^N p(i|x_j, \lambda)} \quad (3.28)$$

$$\sigma_i^2 = \frac{\sum_{j=1}^N p(i|x_j, \lambda) \cdot x_j^2}{\sum_{j=1}^N p(i|x_j, \lambda)} - \mu_i^2 \quad (3.29)$$

Der EM-Algorithmus hat den Vorteil, grundsätzlich zu konvergieren, jedoch je nach Wahl der Initialwerte unter Umständen auch nur in lokale Optima. Die Herausforderung liegt daher darin, geeignete Startwerte zu finden. Hierzu werden in der vorliegenden Arbeit die Initialwerte aus der Betrachtung der entsprechenden Histogramme abgeleitet und zur Vermeidung einer deutlichen Überschneidung der Wertebereiche die maximale Standardabweichung begrenzt.

Die Unwissenheit ist eine Situation, die den Menschen so hermetisch abschließt wie ein Gefängnis.

(Simone de Beauvoir)

Kapitel 4

Situationsanalyse und Manöverinterpretation

Im vorliegenden Kapitel wird zunächst in Abschnitt 4.1 das Konzept für ein situationsadaptives Längs- und Querführungssystem dargestellt. Anschließend wird in Abschnitt 4.2 das adressierte Umfeld betrachtet und die Rahmenbedingungen definiert sowie Anforderungen an das System abgeleitet. In Abschnitt 4.3 folgt zunächst die Betrachtung des Begriffs *Situation* im Allgemeinen und anschließend im spezifischen Kontext dieser Arbeit. Darauf aufbauend werden die relevanten Situationen definiert, deren eindeutige Klassifikation in Abschnitt 4.4 beschrieben wird. In Abschnitt 4.5 erfolgt die Darstellung der Bedienschnittstelle, über die der Fahrer mit seinem Situationsbewusstsein seine Intention an das System übermitteln kann. Die Interpretation des vom Fahrer gewünschten Manövers wird in Abschnitt 4.6 auf Basis der klassifizierten Situation und der Fahrereingabe erläutert. Es folgt in Abschnitt 4.7 die Validierung des Konzepts mittels der prototypischen Realisierung des Systems. Abschließend werden die Erkenntnisse in Abschnitt 4.8 diskutiert und im Kontext mit anderen wissenschaftlichen Arbeiten erörtert.

4.1 Konzept einer situationsadaptiven Fahrzeugführung

In Abschnitt 1.1 wurde das Potenzial zur Unterstützung des Fahrers durch Fahrerassistenzsysteme auf dem Weg in die Stadt über den heutigen Stand der Tech-

nik hinaus aufgezeigt. Dadurch motiviert wird im nachfolgenden Kapitel die erste Forschungsfrage (F1) dieser Arbeit adressiert:

Wie kann eine Fahrerin oder ein Fahrer auf dem Weg in die Stadt hinein kontinuierlich in Längs- und Querführung unterstützt werden?

Um der Komplexität des betrachteten Umfelds zu begegnen, wird in dieser Arbeit im Sinne der kooperativen Fahrzeugführung aus Abschnitt 2.4 ein Konzept entwickelt, mit welchem sich die fahrzeugführende Person und das System in Wahrnehmung, Interpretation und Handlung bestmöglich ergänzen.

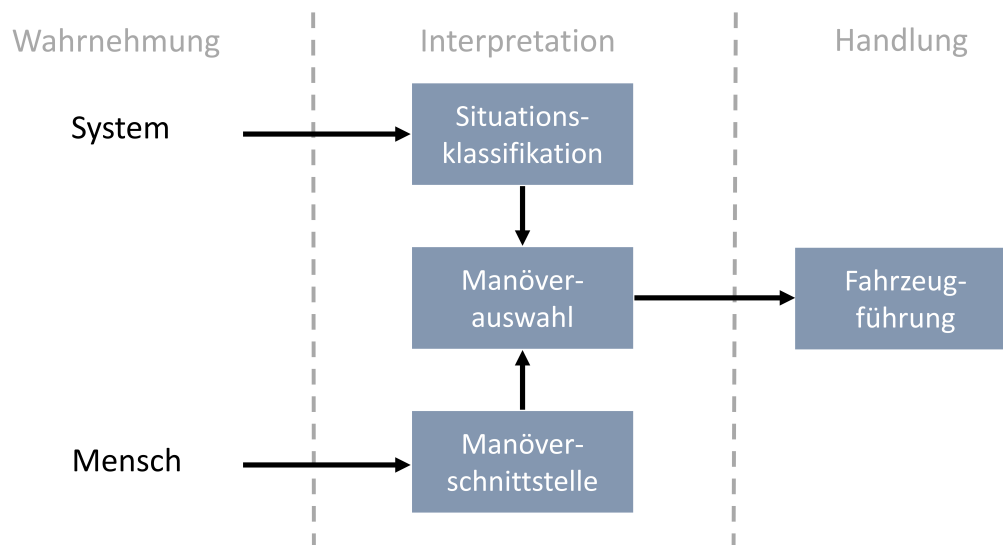


Abbildung 4.1: Konzept einer Fahrerassistenzfunktion im Kontext kooperativer Fahrzeugführung

Daher werden die Grenzen der sehr guten Perzeption des direkten Fahrzeugumfelds über die bordeigene Sensorik mit der übergreifenden Wahrnehmung der Fahrerin bzw. des Fahrers erweitert. Diese können beispielsweise sehr sicher erkennen, ob eine grüne Ampelphase dem eigenen Fahrstreifen zugeordnet ist, aber auch, dass das eigene Fahrzeug beim Weiterfahren aufgrund des sich stauenden Verkehrs voraussichtlich mitten auf der Kreuzung zum Stehen kommen würde. Die Zusammenführung von System und Fahrer erfolgt auf der Ebene der Interpretation und Verarbeitung der wahrgenommenen Informationen, wie in Abbildung 4.1 für dieses Konzept dargestellt. Systemseitig wird auf Basis der Umfeld- und Fahrzeugdaten die aktuelle Situation klassifiziert. Je nach klassifizierter Situation erhält die fahrzeugführende Person die Möglichkeit, über eine

Bedienschnittstelle verschiedene Manöverwünsche an das System zu übergeben. So kann sie mit ihrem erweiterten Situationsbewusstsein, welches sich aus Wahrnehmung, persönlicher Erfahrung und ggf. Fahrziel zusammensetzt, das System vorausschauend beeinflussen. Die Ausführung des Manövers in Längs- und Querführung erfolgt durch das System, wobei fahrzeugführende Personen auf der Stabilisierungsebene durch die Betätigung der Pedale oder des Lenkrads eingreifen können.

4.2 Umfeld

Nachfolgend wird das fokussierte Umfeld näher betrachtet, um darauf aufbauend Rahmenbedingungen aufzuzeigen und Anforderungen an das System abzuleiten.

Da bei den aktuellen Seriensystemen zur Längs- und Querführungsunterstützung nach dem Passieren der Stadtgrenze häufig der komfortable Einsatz endet, wird in dieser Arbeit ein besonderer Fokus auf urbane Ein- und Ausfallstraßen gelegt. Bei diesen Straßen handelt es sich um die Hauptverkehrsadern, die in die Städte hinein, hindurch und wieder hinaus führen. Diese zeichnen sich durch zwei oder mehr Fahrstreifen pro Fahrtrichtung aus. Für gewöhnlich sind die unterschiedlichen Fahrtrichtungen baulich getrennt oder es ist durch die Markierungen ein Befahren der Gegenrichtung untersagt. Der zulässige Geschwindigkeitsbereich liegt vorwiegend im Bereich von $0 \frac{km}{h} - 70 \frac{km}{h}$ und Änderungen der zulässigen Höchstgeschwindigkeit treten oftmals innerhalb von kürzeren Distanzen auf. Die Straßen werden regelmäßig durch Kreuzungen unterbrochen, deren Durchfahrt für gewöhnlich über Lichtsignalanlagen gesteuert wird. Auf diesen Straßen befinden sich viele Fahrzeuge, deren Fahrer verschiedenste Fahrziele ansteuern, wodurch kurzlebige Fahrmanöver entstehen, auf die der Fahrer angemessen reagieren muss.

4.2.1 Rahmenbedingungen

In dieser Arbeit wird als eine Rahmenbedingung definiert, dass es mindestens einen Fahrstreifen in der Fahrtrichtung des Egofahrzeugs¹ gibt und dass ein Befahren des Fahrstreifens der Gegenrichtung, beispielsweise für ein Überholmanöver, nicht unterstützt wird. Zur Detektion der Fahrstreifen müssen hinreichend gute Fahrstreifenmarkierungen vorhanden sein. Der Fokus wird auf den Geschwindigkeitsbereich $[0\frac{km}{h}, 70\frac{km}{h}]$ gelegt, allerdings ist das System auch bei höheren Geschwindigkeiten verfügbar. Dafür muss die aktuelle Geschwindigkeitsbegrenzung entweder von einer Kamera über eine Verkehrsschilderkennung geliefert werden oder einer digitalen Karte entnommen werden können. Rückwärtsfahren wird systemseitig nicht als Funktionalität zur Verfügung gestellt. An Kreuzungen wird die Anforderung gestellt, dass sie für die relevanten Fahrstreifen über Haltelinien verfügt. Damit diese systemseitig genutzt werden können, müssen sie entweder von einer Kamera oder aus einer digitalen Karte geliefert werden.

Außer dem Egofahrzeug können sich auf den verschiedenen Fahrstreifen noch weitere Fahrzeuge befinden. Diese Fahrzeuge müssen bestimmten Fahrstreifen zugeordnet werden können und es müssen Informationen über deren Bewegung vorliegen. Der Fremdverkehr kann, wie auch das Egofahrzeug, zwischen den Fahrstreifen wechseln. Der umgebende Verkehr kann aus anderen Personenkraftwagen, Lastwagen oder Motorrädern bestehen. Da Fußgänger auf diesen Straßen Fußgängerüberwege nutzen sollten, werden sie nicht explizit betrachtet. Dieser Aspekt ist Gegenstand anderer Arbeiten. Bei dem Egofahrzeug werden nur Manöver unterstützt, die ein Fahrverhalten innerhalb des Komfortbereichs (s. 2.3) beinhalten.

4.2.2 Anforderungen

Aus der Betrachtung der Gegebenheiten, mit denen der Fahrer hier konfrontiert wird, können die Anforderungen an eine geeignete Unterstützung abgeleitet werden.

Auf wechselnde Geschwindigkeitsbegrenzungen kann reagiert werden, indem

¹Egofahrzeug bezeichnet das systemtragende Fahrzeug

die aktuelle Begrenzung als Vorgabe für die Längsführung genutzt wird. Da allerdings die Wohlfühlgeschwindigkeit des Fahrers von dieser Vorgabe differieren kann, soll er die Geschwindigkeit variieren können. An Kreuzungen mit Lichtsignalanlagen soll der Fahrer einen Haltewunsch an das System kommunizieren können, damit das System in diesem Fall für den Fahrer an der Haltelinie anhält. So muss der Fahrer nicht, wie bei aktuellen Seriensystemen, selbstständig bremsen und damit die Systeme deaktivieren. Ist das Fahrzeug zum Stillstand gekommen, soll dem System kommuniziert werden können, dass ein Wiederanfahren gewünscht ist. Gibt es ein relevantes Vorderfahrzeug, so soll diesem mit einer vorgegebenen Zeitlücke² gefolgt werden. Bei hohem Verkehrsaufkommen ist für den allgemeinen Verkehrsfluss ein kooperatives Verhalten der Verkehrsteilnehmer hilfreich. Daher soll der Fahrer die Möglichkeit erhalten, durch ein temporäres Öffnen der Lücke zum Vorderfahrzeug andere Fahrzeuge vor sich einscheren zu lassen. In anderen Situationen kann ein temporäres Aufschließen zum Vorderfahrzeug gewünscht sein, um einen Fahrstreifenwechsel vorzubereiten oder das Einscheren anderer zu unterbinden. Um sein Fahrziel zu erreichen, muss der Fahrer sein Fahrzeug stellenweise auf bestimmten Fahrstreifen einordnen. Dabei kann er bei der Überwachung und der Durchführung von Fahrstreifenwechseln unterstützt werden.

Aus diesen Ausführungen lässt sich ableiten, dass das System in verschiedenen Situationen ein spezifisches Standardverhalten anbieten soll, welches der Fahrer entsprechend seines Situationsbewusstseins und seiner Wünsche beeinflussen kann. Da der Fahrer in einem herausfordernden Umfeld unterstützt werden soll, ist es wichtig, dass das System intuitiv verständlich und leicht zu bedienen ist. Es muss dem Fahrer jederzeit klar sein, wie das System reagieren wird und warum. Das kann zusätzlich zur Fahrzeugbewegung über eine geeignete Visualisierung und situationsabhängig auch akustisch kommuniziert werden.

4.3 Situationen

Im folgenden Abschnitt wird der Begriff Situation zunächst allgemein betrachtet und für die Verwendung innerhalb der Arbeit näher spezifiziert. Basierend darauf erfolgt die Definition der für die vorliegende Arbeit relevanten Situationen.

²Zeitlücke beschreibt den geschwindigkeitsabhängigen Abstand zum Vorderfahrzeug

Situation: Im Sinne der Existenzphilosophie der einmalige, unwiederholbare Augenblick, in dem sich für den einzelnen in der Wechselbeziehung zwischen innerer Bestimmtheit und äußerer Lage die unmittelbare, konkrete Wirklichkeit darstellt (Brockhaus 1993).

Übertragen auf das Fahrzeug kann die innere Bestimmtheit als dynamischer Zustand des Fahrzeugs sowie auch als die Intention des Fahrers interpretiert werden. Die äußere Lage kann als das statische und dynamische Umfeld betrachtet werden. Dies ist stimmig mit der Definition einer Situation nach Pellkofer (2003), welcher eine Situation als die Summe der für Verhaltensentscheidungen relevanter Sachverhalte bezeichnet. Die Subjektivität von Wahrnehmung heben Wershofen und Graefe (1996) in ihrer Beschreibung einer Situation im Kontext der Robotik hervor. Dies ist bei maschineller Wahrnehmung und Sensordatenverarbeitung ein wichtiger Aspekt, da nur eine subjektive Wahrnehmung wie auch Interpretation zur Verfügung stehen. Haag (1998) grenzt die Situation zu einem Zustand³ dadurch ab, dass eine Situation zusätzlich über einen Handlungsaspekt verfügt. Pellkofer (2003) spezifiziert diese Erweiterung als „(...) die Intentionen und Aktionen aller Subjekte in der Szene (...)“ sowie „(...) die Fähigkeiten des Eigenfahrzeugs (...)“.

Auf dieser Basis werden innerhalb der vorliegenden Arbeit zur Beschreibung einer Situation das statische und dynamische Umfeld, die Bewegung des Eigenfahrzeugs wie auch die sich ergebenden Handlungsoptionen herangezogen. Die Wahrnehmung und Interpretation des Umfelds ist wie zuvor beschrieben subjektiv und findet über die Sensorik am Fahrzeug bzw. die nachgeschaltete Datenverarbeitung statt. Das statische Umfeld wird um A-priori-Wissen aus einer digitalen Karte ergänzt.

Aus der Sicht der fahrzeugführenden Person lassen sich unter den in Abschnitt 4.2 beschriebenen Rahmenbedingungen und Anforderungen verschiedene Situationen unterscheiden. Um den genannten Handlungsspielraum zu ermöglichen, müssen die Situationen so gewählt werden, dass der Fahrerwunsch eindeutig interpretiert werden kann. Daher werden zur Klassifikation der Situationen sowohl die Szene als auch die Handlungsoptionen betrachtet. Die in den folgenden Abschnitten betrachteten Bedingungen werden für ideale Annahmen formuliert. In der technischen Realisierung werden Unsicherheiten sowie Verarbeitungszeiten der Module und Komponenten berücksichtigt werden.

³Im Kontext von Fahrerassistenzsystemen auch häufig als Szene bezeichnet.

In Anlehnung an Kerner (2009) wird die Drei-Phasen-Verkehrstheorie als Basis für die Definition der unterschiedlichen Situationen herangezogen. Demzufolge unterteilt sich der Verkehr in die Phasen *freier Verkehr*, *synchronisierter Verkehr* und *breiter sich bewegender Stau*. Aus Fahrersicht ergeben sich daraus die Situationen der *freien Fahrt* und einer *Folgefahrt*. Solange ein Vorderfahrzeug vor dem Egofahrzeug fährt, ist die Absicht des Fahrers, diesem Fahrzeug mit einer definierten Zeitlücke zu folgen. Darüber hinaus muss betrachtet werden, dass sich das Egofahrzeug im *Stillstand* befinden kann. Aus der Analyse des speziellen Umfelds ergeben sich noch zwei weitere wichtige Situationen für den Fahrer: die *Zufahrt auf eine Kreuzung* und der *Fahrstreifenwechsel*.

Im folgenden Abschnitt werden diese fünf Situationen beschrieben und definiert. In allen Situationen, abgesehen von der Situation des *Stillstands*, wird gefordert, dass sich das Egofahrzeug in einer Vorwärtsbewegung⁴ befindet:

$$v_{xego} > 0. \quad (4.1)$$

4.3.1 Freie Fahrt

Soll ausschließlich die aktuelle Geschwindigkeitsbegrenzung als Vorgabe für die Längsführung genutzt werden, so darf sich weder ein relevantes Vorderfahrzeug (VF) noch eine relevante Kreuzung (KR) vor dem Egofahrzeug befinden. Relevant ist ein Vorderfahrzeug, sofern die Zeitlücke⁵ τ_{ist} hinreichend klein ist und dessen Geschwindigkeit maximal der Regelgeschwindigkeit des Egofahrzeugs entspricht. Eine Kreuzung wird als relevant bezeichnet, wenn die Zeitlücke oder der Abstand vom Egofahrzeug zur Kreuzung einen bestimmten Schwellwert (SW) unterschreitet. Da der einzige Einflussfaktor auf die Längsführung mit der aktuellen Geschwindigkeitsbegrenzung ein sehr weicher ist, den der Fahrer befolgen oder auch ignorieren kann, wird diese Situation als *Freie Fahrt* bezeichnet. Die beschriebenen Bedingungen lassen sich wie folgt definieren:

$$\nexists VF \text{ mit } \tau_{soll} \geq \tau_{ist} \wedge v_{xsoll} \geq v_{xVF} \quad (4.2)$$

$$\nexists KR \text{ mit } \tau_{SW} \geq \tau_{ist} \vee \delta_{SW} \geq \delta_{ist} \quad (4.3)$$

⁴ v_x : Geschwindigkeit in Fahrzeuginnenrichtung

⁵Die Zeitlücke beschreibt den geschwindigkeitsabhängigen Abstand




Abbildung 4.2: Freie Fahrt

Aus der Betrachtung des Handlungsspielraums ergibt sich in der Längsrichtung eine Variation der Geschwindigkeitsvorgabe und in der Querrichtung ein Fahrstreifenwechsel, sofern dieser unter den Umfeldbedingungen möglich ist. Der gleiche Handlungsspielraum in der Querrichtung ergibt sich auch bei der *Folgefahrt* und der *Zufahrt auf eine Kreuzung*.

4.3.2 Folgefahrt

Handelt es sich bei dem entscheidenden Einflussfaktor für die Längsführung um ein Vorderfahrzeug, welches sich maximal mit der Wunschgeschwindigkeit des Egofahrzeugs bewegt, wird dies als *Folgefahrt* bezeichnet. Um relevant zu sein, muss die Zeitlücke τ_{ist} zum Vorderfahrzeug hinreichend klein sein. Zusätzlich darf sich in einem relevanten Abstand vor dem Egofahrzeug, wie bereits bei der *freien Fahrt*, keine Kreuzung befinden.

$$\exists VF \text{ mit } \tau_{soll} \geq \tau_{ist} \wedge v_{xsoll} \geq v_{xVF} \quad (4.4)$$

$$\nexists KR \text{ mit } \tau_{SW} \geq \tau_{ist} \vee \delta_{SW} \geq \delta_{ist} \quad (4.5)$$




Abbildung 4.3: Folgefahrt

Als Handlungsspielraum in Längsrichtung ergibt sich eine Variation der Zeitlücke zum Vorderfahrzeug. Damit kann ein Aufschließen zum Vorderfahrzeug oder das Öffnen einer Lücke zum Vorderfahrzeug realisiert werden.

4.3.3 Zufahrt auf eine Kreuzung mit Lichtsignalanlage

Befindet sich in einem relevanten Abstand vor dem Egofahrzeug eine Kreuzung, so ist dies für den Fahrer der entscheidende Faktor in der Längsführung. Zwar kann die aktuelle Längsführung sowohl durch ein relevantes Vorderfahrzeug als auch die aktuelle Geschwindigkeitsbegrenzung beeinflusst werden, dennoch ist entscheidend, welche Längsführung der Fahrer im Bezug auf die Kreuzung anstrebt. Sofern der Fahrer im Falle eines roten Signals der Lichtsignalanlage als führendes Fahrzeug nicht die Option hat, einen Haltewunsch an das System zu kommunizieren, ergeben sich zwei Verhaltensvarianten: der Fahrer verzögert selbst bis zum Stillstand an der Haltelinie und deaktiviert dadurch implizit die Unterstützungssysteme oder er reagiert nicht und verstößt so gegen die Straßenverkehrsordnung. Der relevante Abstand zur Kreuzung ergibt sich entweder aus der Zeitlücke oder dem Abstand zur Kreuzung:

$$\exists KR \text{ mit } \tau_{SW} \geq \tau_{ist} \vee \delta_{SW} \geq \delta_{ist} \quad (4.6)$$

$$\delta_{ist} \geq \frac{v_{x0}^2}{2 \cdot a_{verz}} \quad (4.7)$$

Es werden beide Bedingungen in 4.6 geprüft, damit der Fahrer ausreichend Zeit und Wegstrecke erhält, dem System seinen Handlungswunsch zu kommunizieren. Wurde die Situation der *Kreuzung* einmal klassifiziert, so wird diese erst wieder verlassen, wenn die Bedingung 4.7 nicht mehr erfüllt wird. Mit dieser Bedingung wird gewährleistet, dass das System in der Lage ist, bis zur Haltelinie komfortabel bis zum Stillstand zu verzögern.




Abbildung 4.4: Zufahrt auf eine Kreuzung

Der Handlungsspielraum für den Fahrer in dieser Situation besteht darin zu entscheiden, ob er an der Haltelinie der Kreuzung anhalten oder die aktuelle Längsführung beibehalten möchte.

4.3.4 Stillstand

Bei aktiver Längsführung kann ein Stillstand erreicht werden, indem das Egofahrzeug hinter einem angehaltenen Vorderfahrzeug selbst zum Stillstand kommt oder an einer Haltelinie angehalten wird.

$$|\vec{v}| = 0 \quad (4.8)$$




Abbildung 4.5: Stillstand an einer Haltelinie

In dieser Situation gibt es als Handlungsspielraum in Längsrichtung entweder ein Anfahren oder der Stillstand bleibt bestehen. Da das Fahrzeug aus dem Stillstand heraus nicht in der Lage ist, sich in Querrichtung zu bewegen, gibt es hier keinen Handlungsspielraum.

4.3.5 Fahrstreifenwechsel

Das Egofahrzeug bewegt sich vom aktuellen Fahrstreifen auf einen benachbarten Fahrstreifen gleicher Fahrtrichtung. Die Querablage s_y wächst betragsmäßig bis zum Fahrstreifenrand. Nach Überqueren des Fahrstreifenrands nimmt der Betrag wieder ab. Ist die Querablage null, so ist die Mitte des Zielfahrstreifens erreicht und der Fahrstreifenwechsel beendet.

$$|s_{y_i}| \begin{cases} > |s_{y_{i-1}}|, \text{ im Ausgangsfahrstreifen} \\ < |s_{y_{i-1}}|, \text{ im Zielfahrstreifen} \end{cases}, i = 1, 2, \dots, n; n \in \mathbb{N} \quad (4.9)$$




Abbildung 4.6: Fahrstreifenwechsel

Mit diesen Kriterien lässt sich ein begonnener Fahrstreifenwechsel erkennen. Wie später beschrieben werden wird, kann ein Fahrstreifenwechsel in diesem System durch die Übergabe eines Fahrerimpulses ausgelöst werden. Sofern zum aktuellen Zeitpunkt ein sicherer und komfortabler Fahrstreifenwechsel nicht möglich ist, wird der Wunsch für eine kurze Zeitspanne im System gehalten. Diese Vorbereitungsphase des Fahrstreifenwechsels wird im vorliegenden Konzept der Situation *Fahrstreifenwechsel* zugeordnet.

Die Situation *Fahrstreifenwechsel* wird klassifiziert, bis der Fahrstreifenwechsel beendet ist, der Fahrstreifenwechsel durch eine Fahrereingabe oder -handlung abgebrochen wurde oder die Wartezeit verstrichen ist.

Als Handlungsspielraum ergibt sich in der Längsrichtung je nach Verkehrssituation eine Variation der Geschwindigkeitsvorgabe oder der Zeitlücke. Allerdings kann aufgrund der Tatsache, dass der Fahrstreifenwechsel entweder bereits begonnen wurde oder kurz bevorsteht, angenommen werden, dass eine explizite Adaption der Zeitlücke durch den Fahrer nicht sinnvoll ist. Daher ergibt sich als Handlungsspielraum eine Variation der Geschwindigkeitsvorgabe. In Querrichtung kann der Fahrstreifenwechsel abgebrochen oder fortgesetzt werden.

4.4 Situationsklassifikation

Für die Akzeptanz der Nutzenden ist eine gute Verständlichkeit eines Assistenzsystems maßgeblich. Dafür muss sich dem Fahrer die Klassifikation bei diesem Konzept idealerweise intuitiv erschließen. Da dies unter gewissen Konstellationen schwierig ist, wird der Fahrer durch eine geeignete Visualisierung unterstützt.

Um den Fahrer nicht zu verwirren, ist immer eine Situation eindeutig klassifiziert. Damit der Fahrer ausreichend Zeit hat, dem System seinen Manöverwunsch zu kommunizieren, wird zusätzlich ein hochfrequentes Alternieren zwischen ver-

schiedenen Situationen vermieden. Dafür finden an den Übergängen zwischen den verschiedenen Situationen Hysterese Anwendung.

Die Klassifikation erfolgt grundsätzlich über die Bedingungen, die in Abschnitt 4.3 vorgestellt wurden und die einzelnen Situationen beschreiben. Allerdings ist mit diesen Bedingungen nicht in jedem Fall eine Eindeutigkeit gewährleistet. Daher wird eine Priorisierung vorgenommen, wenn die Bedingungen verschiedener Situationen zeitgleich erfüllt sind. Damit kann dem Fahrer zu jeder Zeit eindeutig eine Situation übermittelt werden.

4.4.1 Eingangsdaten

Zur Klassifikation der aktuellen Situation werden verschiedene Informationen benötigt. Vom Egofahrzeug müssen die Position sowie die Geschwindigkeit bekannt sein. Hier lassen sich die lokale und globale Position unterscheiden. Die lokale Position wird benötigt, um die Ablage im Fahrstreifen zu bestimmen. Die globale Position wird verwendet, um die Distanz zu einer Kreuzung über die Zuordnung auf einer digitalen Karte per GPS zu ermitteln.

Um die Zeitlücke zu einem Vorderfahrzeug auf dem Egofahrstreifen zu bestimmen, muss der Fremdverkehr konkreten Fahrstreifen zugeordnet werden. Wird ein Vorderfahrzeug dem Egofahrstreifen zugeordnet, muss des Weiteren der Abstand zu diesem Fahrzeug und dessen Geschwindigkeit von der Sensorik geliefert werden.

4.4.2 Transitionen

Wie in der Abbildung 4.7 zu sehen, lassen sich die Situationen *Freie Fahrt*, *Folgefahrt* und *Zufahrt auf eine Kreuzung*⁶ zu der Kategorie *längs bewegt* zusammenfassen. Aus einer *längs bewegten* Situation kann eine Transition in einen Fahrstreifenwechsel erfolgen, wie auch umgekehrt ein Fahrstreifenwechsel in jeder *längs bewegten* Situation oder einen *Stillstand* münden kann. Da aus einem *Stillstand* nicht direkt eine Querbewegung erfolgen kann, ist eine Transition vom *Stillstand* in den *Fahrstreifenwechsel* nicht möglich. Aus dem *Stillstand* kann ein Wechsel in die *Freie Fahrt* oder die *Zufahrt auf eine Kreuzung* erfolgen. In

⁶In Abbildung 4.7 und im Folgenden als *Kreuzung* bezeichnet

dem Fall, dass die Bedingungen beider Situationen zeitgleich erfüllt sind, wird die *Kreuzung* priorisiert, da es wichtiger ist, dem Fahrer die Möglichkeit zu geben, auf eine rote Signalphase zu reagieren. Der Grund für den Wechsel in den *Stillstand* kann bei einem aktiven System ein haltendes Vorderfahrzeug oder der Halt an einer Haltelinie sein.

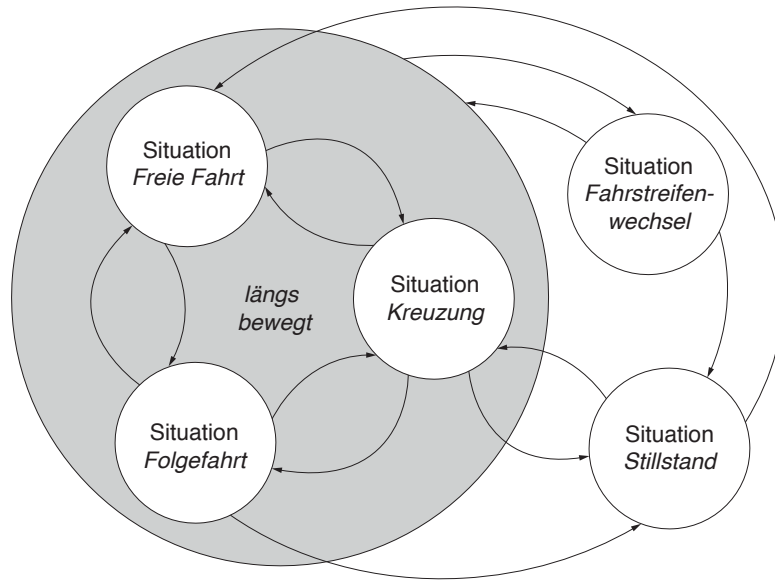


Abbildung 4.7: Transitionen der Situationen

Aus jeder der *längs bewegten* Situationen kann eine Transition in jede der anderen *längs bewegten* Situationen stattfinden. Alle Transitionsmöglichkeiten sind in der Tabelle 4.1 dargestellt.

	Freie Fahrt	Folgefahrt	Kreuzung	Stillstand	FSW
Freie Fahrt	x	x	x	o	x
Folgefahrt	x	x	x	x	x
Kreuzung	x	x	x	x	x
Stillstand	x	o	x	x	o
FSW	x	x	x	x	x

Tabelle 4.1: Transitionen der Situationsklassifikation

Der *Stillstand* ist durch den Wert null der Egogeschwindigkeit immer eindeutig. Alle anderen Situationen können sich teilweise überlagern. Höchste Priorität erhält die *Kreuzung*, damit der Fahrer in jedem Fall auf eine rote Signalphase reagieren kann. Damit der Fahrer nicht von einem plötzlich einsetzenden Fahrstreifenwechsel (FSW) überrascht wird (Wartemodus), steht diese Situation in ihrer Wichtigkeit direkt danach. Damit ergibt sich folgende Priorisierung:

1. Zufahrt auf eine Kreuzung
2. Fahrstreifenwechsel
3. Freie Fahrt oder Folgefahrt.

Ein gleichzeitiges Auftreten der *freien Fahrt* und der *Folgefahrt* ist durch ihre Definition ausgeschlossen.

4.5 Manöverschnittstelle

Damit der Fahrer innerhalb des Handlungsspielraums der jeweiligen Situation seinen Manöverwunsch dem System übermitteln kann, muss ihm eine geeignete Schnittstelle zur Verfügung stehen. Um den Fahrer in dem herausfordernden Umfeld des urbanen Straßenverkehrs möglichst gut zu unterstützen, soll hier ein einfaches und vertrautes Bedienelement gewählt werden. Der Fahrer soll bei der Fahrzeugführung entlastet und nicht durch eine komplizierte Bedienung zusätzlich gefordert werden.

4.5.1 Bedienelement

In der Literatur finden sich verschiedene Varianten für die Übergabe eines Fahrerwunsches an das System. Je nach Ausprägung und Automationsgrad werden unterschiedliche Anforderungen an eine solche Schnittstelle gestellt. Daher werden diese unterschiedlich konzipiert.

Im Konzept H-Mode wird als Bedienelement ein zusätzlicher aktiver Sidestick verwendet. Der Fahrer kann über das Bedienelement auf der Stabilisierungsebene interagieren und erhält unmittelbar über den Sidestick Rückmeldung über

die Fahrzeugreaktion (Kienle u. a. 2009). Damit findet eine eingeschränkte Abstraktion der Fahraufgabe statt, da die Steuerung des Fahrzeugs auf ein anderes Bedienelement übertragen wird. Der Fahrer erhält Vorschläge zu möglichen künftigen Trajektorien, denen er dann per Bedienelement folgen kann, sofern er sich aktiv einbringen möchte. Andernfalls übernimmt das System diese Entscheidungen und die Steuerung des Fahrzeugs. In den Konzepten Conduct-by-Wire und Pie-Drive findet eine nahezu vollständige Abstraktion der Fahraufgabe statt (Franz u. a. 2012). Dem Fahrer steht ein definierter Katalog an Manövern zur Auswahl und zusätzlich gibt es drei Parameter, die direkt adaptiert werden können. Bei beiden Konzepten wird dafür ein separates Bedienelement genutzt. Für Conduct-by-Wire wurde ein Lenkrad mit Touch-Display in der Mitte konzipiert. Das birgt den Nachteil, dass der Fahrer es nicht nicht bedienen kann, ohne den Blick vom Fahrgeschehen abzuwenden. Daher wird bei der Weiterentwicklung Pie-Drive ein Head-Up-Display (HUD) in Kombination mit einem in der Armlehne eingelassenen Touch-Display genutzt. Die Eingabe des Fahrers auf dem Bedienelement wird neben den Auswahlmöglichkeiten im HUD visualisiert. Da der Fahrer bei diesen Konzepten nicht explizit die Längs- oder Querführung übernimmt, muss er die Hände nicht am Lenkrad halten.

In der vorliegenden Arbeit wird das Konzept verfolgt, dass der Fahrer je nach Situation mit ein und dem gleichen Bedienelement unterschiedliche Manöver auswählen kann. In jeder Situation (s. 4.3) steht dem Fahrer eine begrenzte Menge an Manövern zur Auswahl. Idealerweise kann der Fahrer die Manöverschnittstelle intuitiv und ohne Blickkontakt bedienen. Voraussetzung dafür ist ein einfach gehaltenes Bedienelement, das sich in enger räumlicher Nähe zum Lenkrad befindet. Damit wird dem Fahrer die Möglichkeit gegeben, einen Manöverwunsch zu übergeben, wobei er die Hände nicht oder nur eine Hand sehr kurz vom Lenkrad entfernen muss. Diese Anforderung ergibt sich dadurch, dass in dieser Arbeit ein Fahrerassistenzsystem entwickelt wird und so der Fahrer zu jeder Zeit aktiv in die Fahraufgabe eingebunden sein soll. Damit ist die Erfolgsaussicht höher, dass der Fahrer in einer Notsituation angemessen reagieren kann. Um die Komplexität an Bedienelementen nicht weiter zu erhöhen, wird auf vorhandene Bedienelemente zurückgegriffen und deren Interpretation angepasst. Unter diesen Voraussetzungen bietet sich die Nutzung von Lenkradtasten oder von Lenkstockhebeln an. Lenkstockhebel, insbesondere der ACC⁷- sowie der Blinkerhebel, haben den Vor-

⁷Zur Nutzung der ACC-Funktionalität (in Abbildung 4.8a zu sehen)

teil, dass der Fahrer in modernen Fahrzeugen bereits damit vertraut ist und dass diese in der Verbindung mit der Längs- und Querführung genutzt werden.



(a) Lenkstockhebel (Audi AG 2015a)



(b) Lenkrad mit Knöpfen (Audi AG 2015b)

Abbildung 4.8: Vorhandene Bedienelemente

Unter Verwendung dieser Variante werden zwei separate Bedienelemente eingesetzt, die sich im verwendeten Versuchsträger auf der gleichen Seite des Lenkrads befinden. Lenkradtasten bieten den Vorteil, dass der Fahrer oder die Fahrerin sie bedienen kann, ohne eine Hand vom Lenkrad zu nehmen. Hat er oder sie sich an eines der Bedienelemente gewöhnt, kann es ohne Blickkontakt verwendet werden.

4.5.2 Fahrereingabe

In diesem Konzept wird dem Fahrer die Möglichkeit gegeben, über die Schnittstelle einen Impuls in die Richtungen *vor*, *zurück*, *links* oder *rechts* zu geben.




Abbildung 4.9: Abstrakte Darstellung der Manöverschnittstelle

Je nach aktueller Situation wird der entsprechende Manöverwunsch interpretiert. Damit bleibt das Bedienelement überschaubar und die Komplexität des Manöverkatalogs begrenzt. Das gibt dem Fahrer die Möglichkeit, die Funktionsweise des Systems schnell zu erlernen.

In Abbildung 4.9 ist eine abstrakte Darstellung der Schnittstelle zu sehen. Längsdynamisch kann der Fahrer über *vor* oder *zurück* Einfluss nehmen. In Querrichtung kann mit *links* bzw. *rechts* ein Fahrstreifenwechselwunsch in die jeweilige Richtung übermittelt werden.

Bei Verwendung der Lenkstockhebel als Bedienschnittstelle kann das Hoch- bzw. Herunterdrücken des ACC-Hebels als *vor* bzw. *zurück* interpretiert werden. Ein Antippen des Blinkerhebels nach oben oder unten kann als Impuls nach *rechts* oder *links* ausgewertet werden.



(a) Lenkstockhebel mit angedeuteter Bewegung (Schroven 2011)



(b) Lenkrad mit Knöpfen mit Pfeilen in entsprechende Richtung

Abbildung 4.10: Bedienelemente mit Richtungen

Bei einem Multifunktionslenkrad werden vorhandene Tasten genutzt. Wie in Abbildung 4.10b zu sehen, werden auf der linken Seite des Lenkrads die Pfeiltasten genutzt. Diese werden für die Impulse nach links bzw. rechts verwendet. Dies korrespondiert damit, dass der Fahrer die linke Hand auch zum Betätigen des Fahrtrichtungsanzeigers nutzt, um ein querdynamisches Manöver anzukündigen. Auf der rechten Seite des Lenkrads werden die angezeigten Tasten genutzt, wie ebenfalls in Abbildung 4.10b zu sehen. Diese wurden zur Verständlichkeit für den Fahrer mit nach vorn bzw. hinten gerichteten Pfeilen überklebt. Die rechte Seite für die längsdynamische Beeinflussung zu nutzen korrespondiert auch damit, dass der Fahrer den rechten Fuß zur Betätigung des Gas- bzw. Bremspedals nutzt.

4.6 Manöverinterpretation

Aus jeder zuvor beschriebenen Situation kann der Fahrer verschiedene Manöver anvisieren. Das Oxford Dictionary definiert ein Manöver als „a carefully planned or cunning scheme or action“. Flemisch u. a. (2014) interpretieren aus dieser Definition, dass ein Manöver eine Struktur oder eine Abstraktion der Fahrzeugbewegung im Kontext des Umfelds ist. Die Abstraktion einer wachsenden Querablage bis hin zur Mitte des Nachbarfahrstreifens ist beispielsweise ein Fahrstreifenwechsel. Für den Fahrer ist diese Form der Abstraktion hilfreich, wenn er bei der Ausführung eines Manöver unterstützt werden möchte. Für ihn ist die Übermittlung einer detaillierten Parametrisierung kaum möglich und wäre zudem aufwendig. Daher ist es hilfreich, wenn er dem System übermitteln kann, dass er den Fahrstreifen wechseln möchte. Das System kann in der Folge auf der Basis der Umfeldinformationen eine geeignete Trajektorie entwickeln und den Fahrer mit der Regelung auf diese unterstützen.

Auf Basis der aktuell klassifizierten Situation und der Fahrereingabe wird der Fahrerwunsch in der abstrakten Form eines Manövers bzw. einer Parameteradaption interpretiert. In Abbildung 4.11 ist diese Zuordnung schematisch dargestellt.




Abbildung 4.11: Zuordnung von Situation und Fahrereingabe zu einem Manöver

Da dem Fahrer nur vier unterschiedliche Eingaben zur Verfügung stehen, können pro Situation maximal fünf unterschiedliche Manöver aus der Fahrereingabe interpretiert werden. Auch die nicht vorhandene Fahrereingabe impliziert einen Fahrerwunsch. In diesem Fall wird systemseitig immer angenommen, dass der Fahrer die aktuelle Längs- und Querführung beibehalten möchte.

In allen längsbewegten Situationen, also in der *freien Fahrt*, der *Folgefahrt* und bei der *Zufahrt auf eine Kreuzung*, wird eine straffe Spurmittenführung angelegt. Übergibt der Fahrer über das Bedienelement die Eingabe *links* oder *rechts*, deutet dies darauf hin, dass er die Querführung des Fahrzeugs verändern möchte. Aufgrund des hier betrachteten Umfelds wird interpretiert, dass der Fahrer einen Fahrstreifenwechselwunsch übergeben möchte. Wenn die systemseitige Überprüfung auf Basis der Umfeldwahrnehmung ergibt, dass ein komfortabler und si-

cherer Fahrstreifenwechsel möglich ist, wird der Fahrer bei diesem in Längs- und Querführung unterstützt. Sind zum Zeitpunkt des Fahrerwunsches diese Voraussetzungen nicht gegeben, so wird der Wunsch für eine kurze Zeitspanne im System gehalten. Ergibt sich innerhalb dieser Zeitspanne eine passende Möglichkeit, wird der Fahrstreifenwechsel nachgeholt. Insbesondere bei der Zufahrt auf eine komplexere Kreuzung, wie sie im betrachteten Umfeld oft zu finden ist, hat der Fahrzeugführer häufig, den Wunsch den Fahrstreifen zu wechseln. So kann er das Fahrzeug auf dem gewünschten Richtungsfahrstreifen einordnen oder den Fahrstreifen wählen, auf welchem sich weniger wartende Fahrzeuge vor der Halteinie befinden.

Grundsätzlich wird bei der Eingabe eines *vor* bzw. *zurück* angenommen, dass eine Verstärkung bzw. Reduktion der Längsdynamik gewünscht ist. Dies wird je nach Situation unterschiedlich interpretiert, da jeweils ein unterschiedlicher längsdynamischer Handlungsspielraum vorliegt. Die Internationale Organisation für Normung (2002) gibt in der ISO 15622 Richtlinien für den Wertebereich der längsdynamischen Parameter vor, die bei der Auslegung des Systems beachtet werden müssen, wie beispielsweise für die durchschnittliche automatische Verzögerung oder die minimale Zeitlücke.

4.6.1 Freie Fahrt

In der Situation der *freien Fahrt* wird als Vorgabe für die Längsführung die aktuelle Geschwindigkeitsbegrenzung v_{limit} verwendet. Daher wird bei der Eingabe von *vor* oder *zurück* über das Bedienelement interpretiert, dass der Fahrer den Wert dieser Vorgabe variieren möchte. Eine mögliche Ursache dafür wäre, dass die Wohlfühlgeschwindigkeit des Fahrers von der Vorgabe differiert. Zudem können heutzutage weder die digitalen Karten⁸ noch eine kamerabasierte Schildererkennung⁹ in jeder Situation die Übermittlung der korrekten Geschwindigkeitsbegrenzung gewährleisten. So wird bei entsprechender Eingabe durch den Fahrer interpretiert, dass dieser die Geschwindigkeitsvorgabe erhöhen oder reduzieren möchte. Die Adaption der longitudinalen Geschwindigkeitsvorgabe v_{xsoll} erfolgt in

⁸Änderungen müssen in die Karten eingepflegt werden

⁹Schilder können verdeckt sein oder Verkehrszeichen auf LKW können fälschlicherweise erkannt werden

diskreten Werten Δv .

$$v_{xsoll} = v_{limit} \pm k \cdot \Delta v \quad (4.10)$$

vor	zurück	links	rechts
$v_{xsoll} = v_{limit} + k \cdot \Delta v$	$v_{xsoll} = v_{limit} - k \cdot \Delta v$	FSW links	FSW rechts

Tabelle 4.2: Zuordnung der Fahrereingabe in der Situation *Freie Fahrt*

Der Fahrer kann seine Eingabe beliebig oft wiederholen. Die Geschwindigkeitsvorgabe wird entsprechend weiter erhöht bzw. reduziert, bis eine Maximalgeschwindigkeit oder $0 \frac{km}{h}$ erreicht sind. Mit jeder Änderung der Geschwindigkeitsbegrenzung wird die Variation zurückgenommen. Damit wird einer unbeabsichtigten Verletzung der aktuellen Geschwindigkeitsbegrenzung entgegengewirkt.

4.6.2 Folgefahrt

In der Situation *Folgefahrt* wird als Vorgabe für das System eine Standardzeitlücke¹⁰ $\tau_{default}$ verwendet. Nimmt der Fahrer keine Eingabe über das Bedienelement vor, so wird interpretiert, dass er die aktuelle Längsführung mit dieser Zeitlücke fortführen möchte. Die Zeitlücke berechnet sich aus der Fahrzeuggeschwindigkeit und dem Abstand zum Vorderfahrzeug δ_{obj} .

$$\tau = \frac{\delta_{obj}}{v_x} \quad (4.11)$$

Das Ziel bei einer stationären Folgefahrt ist das Erreichen der Zeitlücke mit einer Differenzgeschwindigkeit $\Delta v_x = v_{xego} - v_{xobj} = 0 \frac{m}{s}$ zum Vorderfahrzeug. Bei der Eingabe *vor* wird angenommen, dass der Fahrer die Fahrzeugbewegung in Fahrtrichtung verstärken möchte. In einer Folgefahrt ist der zu beeinflussende Parameter die Zeitlücke. Die Zeitlücke kann grundsätzlich temporär oder dauerhaft verändert werden. Da der Fahrer, wenn er einmal seine präferierte Zeitlücke gefunden hat, diese für gewöhnlich nicht mehr verändert, muss der Zugriff auf diese nicht dauerhaft gegeben sein. Daher wird angenommen, dass der

¹⁰Der zulässige Bereich einer Zeitlücke wird in der ISO 15622 geregelt.

Fahrer temporär zum Vorderfahrzeug aufschließen möchte. Dies kann dazu dienen, einen Fahrstreifenwechsel vorzubereiten oder das Einscheren eines anderen Fahrzeugs vor dem Egofahrzeug zu verhindern. Erfolgt die Eingabe *zurück*, so wird die Zeitlücke zum Vorderfahrzeug temporär deutlich vergrößert. Im urbanen Straßenverkehr herrscht häufig dichter Verkehr vor. Hier kann diese Funktionsausprägung genutzt werden, um einem anderen Fahrzeug das Einscheren vor dem Egofahrzeug zu ermöglichen. Damit ergibt sich nach der Fahrereingabe als Vorgabe für die Zeitlücke τ_{soll} eine Variation der Standardzeitlücke um einen diskreten Wert $\Delta\tau$.

$$\tau_{soll} = \tau_{default} \pm \Delta\tau \quad (4.12)$$

Nimmt der Fahrer während der temporären Veränderung der Zeitlücke die inverse Bedienhandlung vor, so wird interpretiert, dass er seine vorherige Eingabe revidieren möchte. In diesem Fall wird die Zeitlücke wieder auf die Ausgangszeitlücke zurückgesetzt.

$$\tau_{soll} = \tau_{default} \quad (4.13)$$

In der Tabelle 4.3 sind die Zuordnungen der Fahrereingabe in der Situation *Folgefahrt* ausgehend vom Standardverhalten zusammengefasst.

vor	zurück	links	rechts
$\tau_{soll} = \tau_{default} - \Delta\tau$	$\tau_{soll} = \tau_{default} + \Delta\tau$	FSW links	FSW rechts

Tabelle 4.3: Zuordnung der Fahrereingabe in der Situation *Folgefahrt*

4.6.3 Zufahrt auf eine Kreuzung

Bewegt sich ein Fahrzeug auf eine Kreuzung zu, setzen derzeitige Seriensysteme die aktuelle Längsführung fort. Der Fahrer ist in der Lage, frühzeitig zu erkennen, dass eine rote Signalphase an der nächsten Kreuzung vorliegt. Hat der Fahrer daher den Wunsch, an einer Haltelinie zu halten, so muss er selbstständig bremsen und deaktiviert dadurch die Längs- und implizit auch die Querführung¹¹. Da auf urbanen Ein- und Ausfallstraßen häufig Kreuzungssituationen auftreten, kann der Komfort, die Akzeptanz und insbesondere die Verfügbarkeit eines Systems deutlich gesteigert werden, wenn das System die Möglichkeit zum Halten an der

¹¹Die Querführungsunterstützung steht bei aktuellen Seriensystemen erst ab ca. $60 \frac{km}{h}$ zur Verfügung.

Haltelinie anbietet. Um dies zu realisieren, gibt es bei dem vorliegenden System zwei sinnvolle Varianten:

- **Variante rot**

Das System hält immer an einer Haltelinie an, außer der Fahrer bestätigt innerhalb eines bestimmten Zeitfensters die Fortsetzung der aktuellen Längsführung.

- **Variante grün**

Der Fahrer setzt mittels eines *zurück* über das Bedienelement innerhalb eines bestimmten Zeitfensters einen Haltewunsch an das System ab. Dieses unterstützt ihn in der Folge beim Anhalten an der Haltelinie. Andernfalls wird die aktuelle Längsführung beibehalten.

Bei der ersten Variante muss der Fahrer an jeder Kreuzung in Aktion treten, sofern er die aktuelle Längsführung fortsetzen möchte. Hier ist zu erwarten, dass dies bei der Häufigkeit von Kreuzungen in dem betrachteten Umfeld beim Nutzer die Akzeptanz des Gesamtsystems deutlich reduzieren wird. Da der Fahrer bei der zweiten Variante nur aktiv werden muss, wenn er in dem Fahrzeug sitzt, das sich als erstes einem roten Signal annähert, muss er bei dieser Auslegung in der Summe deutlich weniger mit dem System interagieren. Daher wird in diesem Konzept die zweite Variante verwendet. Hier wird der Fahrer durch die Übergabe eines *zurück* aktiv, wenn er die aktuelle Längsführung durch einen Anhaltevorgang verändern möchte. Da eine rote Signalphase zeitlich begrenzt ist, wird die Eingabe eines *vor* als Widerruf eines zuvor gesetzten Haltewunsches interpretiert.

vor	zurück	links	rechts
Widerruf Halt	Halt an Haltelinie	FSW links	FSW rechts

Tabelle 4.4: Zuordnung der Fahrereingabe in der Situation *Kreuzung*

In dieser Situation mit den vorgestellten Manöveroptionen ist für den Fahrer eine geeignete Mensch-Maschine-Schnittstelle (MMS) von elementarer Bedeutung. Es gibt ein bestimmtes Zeitfenster, innerhalb dessen der Fahrer seine Eingabe vornehmen kann. Das System ist in den anlegbaren Verzögerungen limitiert, so dass der Bremsweg bzw. die sich daraus ergebende Bremsdauer zur Haltelinie

der nach unten begrenzende Faktor des Zeitfensters ist. Die obere Grenze des Zeitfensters ergibt sich aus dem Maximum einer Distanz und einer Zeitlücke zur Kreuzung. Ist der Fahrer mit hoher Geschwindigkeit unterwegs, so wird die Zeitlücke den Eintritt in das Zeitfenster beschreiben. Ist die Fahrzeuggeschwindigkeit hingegen eher gering, soll der Fahrer dennoch nicht erst kurz vor der Haltelinie angefragt werden, sodass in diesem Fall die Distanz zur Kreuzung greift.

Damit der Fahrer darüber informiert ist, wann er einen Haltewunsch absetzen kann und insbesondere wann er dies nicht mehr tun kann, muss ihm das Zeitfenster über das MMS eindeutig vermittelt werden. Ist das Zeitfenster verstrichen, so kann der Fahrer noch immer selbstständig bremsen, um vor der Haltelinie anzuhalten. Da es sich um ein Komfortsystem handelt, kann der Fahrer mit dem Bremspedal deutlich höhere Verzögerungswerte anfordern und hat daher einen kürzeren Bremsweg bis zum Stillstand.

4.6.4 Stillstand

In der Situation des *Stillstands* steht dem Fahrer von Seiten des Systems nur eine Handlungsoption zur Verfügung, da Rückwärtsfahren nicht unterstützt wird. So folgt auf die Eingabe eines *zurück* keine Bewegung des Fahrzeugs. Ebenso wird kein Fahrstreifenwechsel aus dem Stillstand heraus unterstützt. Ein gültiger Fahrstreifenwechselwunsch kann abgesetzt werden, sobald sich das Fahrzeug in Bewegung befindet.

vor	zurück	links	rechts
Anfahren	_____	_____	_____

Tabelle 4.5: Zuordnung der Fahrereingabe in der Situation *Stillstand*

Übergibt der Fahrer den Anfahrwunsch an das System, wird das System das Anfahren übernehmen, sofern die systemseitige Überprüfung des Umfelds auf Basis der Wahrnehmung ergibt, dass dies sicher möglich ist.

4.6.5 Fahrstreifenwechsel

Die Situation *Fahrstreifenwechsel* wird klassifiziert, sofern ein Fahrstreifenwechsel aktuell aktiv ist oder ein gültiger Fahrstreifenwechselwunsch im System vorliegt. Durch die Übergabe von *links* bzw. *rechts* in die entgegengesetzte Richtung kann der Fahrer einen zuvor gesetzten Fahrstreifenwechselwunsch widerrufen. Dies ist auch möglich, wenn die Durchführung des Fahrstreifenwechsels bereits begonnen wurde.

Wird ein *vor* oder *zurück* übergeben, so kann die unterliegende längsorientierte Situation nur eine *Freie Fahrt* oder eine *Folgefahrt* sein. Aufgrund der Priorisierung wird beim parallelen Auftreten eines *Fahrstreifenwechsels* und einer *Kreuzung* immer die *Kreuzung* klassifiziert. Da die eindeutige Klassifikation in erster Linie der Kommunikation zum Fahrer dient, schließt dies das Auslösen eines Fahrstreifenwechsels in der Situation einer *Kreuzung* nicht aus. Parallel zum *Stillstand* kann kein *Fahrstreifenwechsel* stattfinden, da sich das Fahrzeug hier nicht in Bewegung befindet. Bei einem Vorderfahrzeug wird die Zeitlücke ohnehin so gewählt, dass sich unter den angelegten Bedingungen die optimale Trajektorie ergibt. Daher wird bei der Eingabe eines *vor* bzw. *zurück* die Geschwindigkeit um einen diskreten Wert variiert.

vor	zurück	links	rechts
$v_{xsoll} = v_{limit} + \Delta v$	$v_{xsoll} = v_{limit} - \Delta v$	Widerruf FSW	Widerruf FSW

Tabelle 4.6: Zuordnung der Fahrereingabe in der Situation *Fahrstreifenwechsel*

In der Tabelle 4.6 ist die Zusammenfassung der Interpretationen möglicher Fahrereingaben in der Situation eines *Fahrstreifenwechsels* zu sehen.

4.7 Validierung des Konzepts

In den vorangegangenen Abschnitten wurde erarbeitet, wie eine situationsadaptive Längs- und Querführung im urbanen Umfeld gestaltet werden kann. Im Folgenden wird beschrieben, wie das in Abschnitt 4.1 entwickelte Konzept im Rahmen dieser Arbeit prototypisch in einem Versuchsfahrzeug implementiert und validiert wurde.

Abbildung 4.12 zeigt die systemseitig notwendigen Module zur Realisierung des Konzepts aus Abschnitt 4.1.

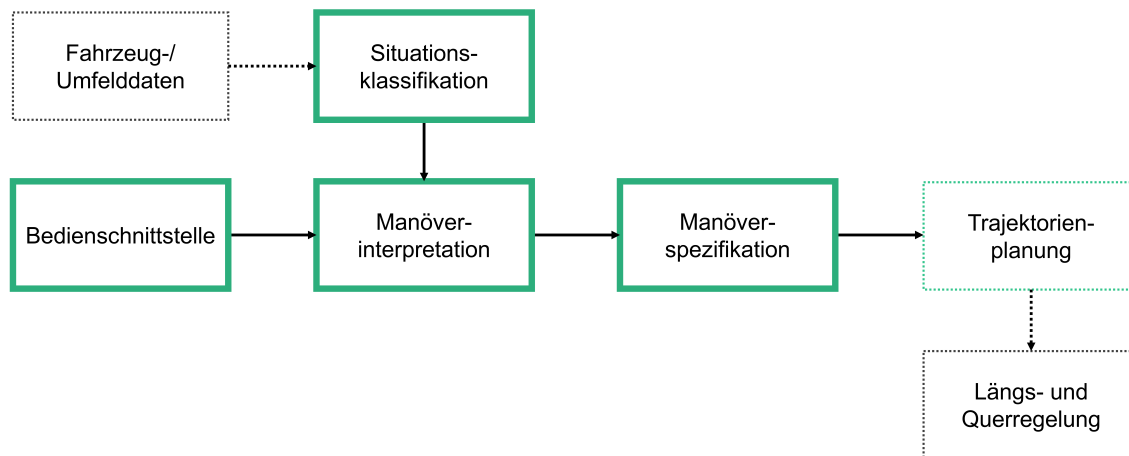


Abbildung 4.12: Im Rahmen der Arbeit implementierte Module (grün) innerhalb der Systemarchitektur

Als Entwicklungsumgebung kam das Automotive Data and Time-Triggered Framework (ADTF) der Firma Elektrobit (Elektrobit 2018) zum Einsatz. Dabei handelt es sich um eine für Fahrerassistenzsysteme spezialisierte Entwicklungsumgebung, mit der sowohl im Fahrzeug gearbeitet als auch am Arbeitsplatz simuliert werden kann. Sie bietet die Möglichkeit, Daten vom Fahrzeugbus einzulesen und auf diesen einzuspeisen. Zusätzlich sind Module für Visualisierung, Aufzeichnung und Wiedergabe von Messdaten vorhanden. Eine Applikation in ADTF setzt sich aus sog. Filtern zusammen. Jeder Filter übernimmt dabei einen bestimmten Teil der Datenverarbeitung. Einzelne Filter werden über Pins zum Datenaustausch miteinander verbunden und ergeben im Verbund die Systemlogik. Neben den Basisfiltern haben die Entwickelnden die Möglichkeit, in der Programmiersprache C++ eigene Filter für spezifische Applikationen zu programmieren.

Zuerst wurde im Rahmen dieser Arbeit das Modul Situationsklassifikation realisiert. Dafür wurde der Zustandsautomat aus Abbildung 4.7 implementiert und die Transitionen entsprechend der Situationsbeschreibungen aus Abschnitt 4.3 umgesetzt. Fahrzeug- und Umfelddaten wurden durch das Umfeldmodell (Abschnitt 2.2.6) bereitgestellt.

Um auch im urbanen Straßenverkehr eine gute Klassifikation zu erreichen, wurde die Klassifikation mittels realer Messdaten analysiert und optimiert, bis eine robuste Klassifikation erreicht war. In Abbildung 4.14 ist exemplarisch die Auswertung der Situationsklassifikation auf Messdaten aus einer realen Fahrt aufge-

tragen. Darauf aufbauend wurde die Manöverinterpretation realisiert.

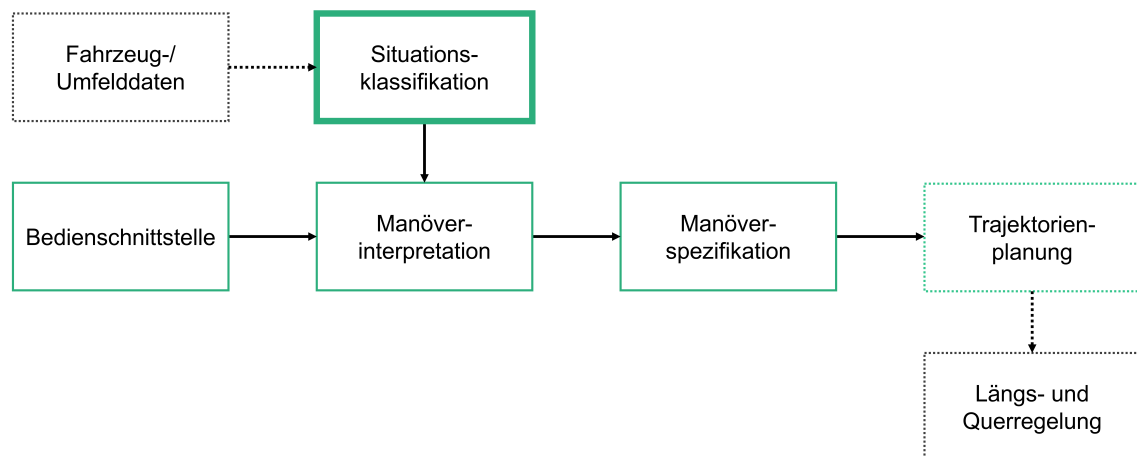


Abbildung 4.13: Modul zur Situationsklassifikation




Abbildung 4.14: Situationsklassifikation auf Messdaten einer realen Fahrt

Ziel war es, der fahrzeugführenden Person eine möglichst vertraute Bedieninteraktion zu ermöglichen. Im verwendeten Versuchsträger, einem Audi A6 (Abschnitt 5.4), adressiert die Bedienphilosophie für Fahrerassistenzsysteme Lenkstockhebel und nicht Lenkradtasten. Daher wurde die Betätigung der Lenkstockhebel als Fahrereingabe eingelesen.

Wie in Abbildung 4.15 dargestellt, wurden die Fahrereingaben über die Bedienschnittstelle sowie das Ergebnis der Situationsklassifikation in der Manöverinterpretation zusammengeführt. In diesem Modul erfolgte die Implementierung der Interpretation (Abschnitt 4.6) des von der Fahrerin bzw. von dem Fahrer angeforderten Manövers.

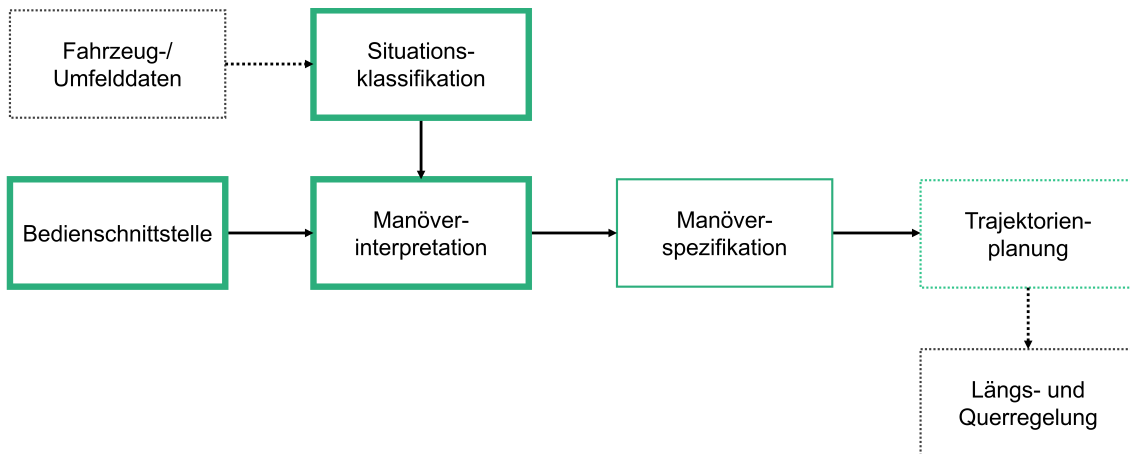


Abbildung 4.15: Module zur Manöverinterpretation

Exemplarisch zeigt Abbildung 4.16 anhand von realen Messdaten, wie aus einer Eingabe über den Blinkerhebel interpretiert wird, dass ein Fahrstreifenwechsel (FSW) erfolgen soll. Der tatsächlich durchgeführte Fahrstreifenwechsel wird durch den Verlauf der Querablage abgebildet.




Abbildung 4.16: Manöverinterpretation auf Messdaten einer realen Fahrt

Mittels des interpretierten Manöverwunsches erfolgte eine Spezifikation des jeweiligen Manövers sowie des sich dadurch ergebenden Zielzustandes, auf welchem im nachfolgenden Modul eine Trajektorie geplant wurde.

Bei der lateralen Zielposition handelte es sich entweder um die aktuelle Fahr-

streifenmitte oder bei einem Fahrstreifenwechsel um die des Zielfahrstreifens. Ein geeigneter Zielzustand der longitudinalen Bewegung war in der Regel entweder eine spezifische Geschwindigkeitsvorgabe oder eine definierte Zeitlücke zum Vorderfahrzeug. Beide Varianten wurden zusätzlich auch bei einem gewünschten Fahrstreifenwechsel bei Definition des Zielzustandes auf dem Nachbarfahrstreifen berücksichtigt. Sollte an einer Haltelinie angehalten werden, so wurde spezifiziert, dass an der entsprechenden Position sowohl die Geschwindigkeit als auch die Beschleunigung den Wert null haben.

Die so bestimmten Zielzustände aus dem Modul Manöverspezifikation (s. Abbildung 4.12) dienen als Eingangsgröße für das Modul Trajektorienplanung. Das Modul Trajektorienplanung stand zur Verfügung und konnte zur Verwendung in dieser Arbeit eingebunden werden. Innerhalb des Moduls war die Trajektorienplanung aus Abschnitt 3.1 realisiert. Aus der bestimmten Trajektorie wurden anschließend Sollgrößen für die Längs und Querregelung ermittelt (im vorliegenden System handelte es sich dabei um ein Lenkmoment und die Sollbeschleunigung). In mehreren Iterationen erfolgte mittels Expertenfahrten eine Grundapplikation des Systems.

4.8 Diskussion

Zur Beantwortung der ersten Forschungsfrage (F1) wurde in den vorangegangenen Abschnitten ein ganzheitliches Konzept zur Unterstützung der fahrzeugführenden Person auf urbanen Straßen entwickelt und validiert.

Die Fahrten mit der prototypischen Umsetzung des Systems im realen Straßenverkehr der Stadt Wolfsburg haben gezeigt, dass mit diesem System mittels der im Folgenden beschriebenen Aspekte eine kontinuierliche Unterstützung erreicht wird, indem sich Mensch und System ergänzen. In der *freien Fahrt*, d.h. es ist kein Vorderfahrzeug vorhanden, verwendet das System die aktuelle Geschwindigkeitsbegrenzung als Regelvorgabe für die Längsführung. Gleichzeitig hat die fahrzeugführende Person die Möglichkeit, diese gemäß den eigenen Präferenzen zu variieren. Zusätzlich wird ein kooperatives Fahrverhalten dadurch ermöglicht, dass bei Erkennen eines Einscherwunsches anderer Verkehrsteilnehmer auf den eigenen Fahrstreifen das Öffnen der Lücke zum Vorderfahrzeug vom System angefordert werden kann. Bei Zufahrten auf Kreuzungen, deren Vorfahrt über Licht-

signalanlagen geregelt ist, zeigt sich die besondere Stärke des Konzepts der kooperativen Fahrzeugführung. Die Fahrerin bzw. der Fahrer erkennt zum einen, ob eine rote Ampelphase dem eigenen Fahrstreifen zugeordnet ist und zum anderen, ob ein Einfahren in die Kreuzung bei hohem Verkehrsaufkommen zum aktuellen Zeitpunkt trotz grüner Phase überhaupt sinnvoll ist. Diese Einschätzung kann vorausschauend an das System übermittelt und dadurch ein Halt an der Haltelinie angefordert oder auch widerrufen werden. Darüber hinaus bietet die Option eines Fahrstreifenwechselmanövers die Möglichkeit, beispielsweise frühzeitig den notwendigen Fahrstreifen für den gewünschten Routenverlauf zu erreichen oder den Rückstau auf einem spezifischen Fahrstreifen vor einer Kreuzung zu meiden. So kann sich die fahrzeugführende Person auf die vorausschauende Planung der Fahrt fokussieren, während sie durch die assistierte Ausführung des Manövers kognitiv entlastet wird. Unterstützt wird dies zudem auch dadurch, dass in jeder Situation nur die für diese relevanten Manöveroptionen zur Auswahl stehen.

Wie bereits bei *Conduct-by-Wire* (Kauer u. a. 2010) oder *Digital Driving* (Broggi u. a. 2013) hebt somit dieses Konzept die Fahrzeugführung für die Fahrerin bzw. den Fahrer auf die Bahnführungsebene (vgl. Donges (1982)) und schafft die Möglichkeit zur Übergabe von Manöverbefehlen. Im Gegensatz zu beiden Vertretern der kooperativen Fahrzeugführung wird eine Bedienvariante gewählt, bei welcher nach kurzer Eingewöhnungsphase eine Bedienung des Systems ohne Blickabwendung vom Verkehrsgeschehen möglich ist. Zusätzlich zur Vermeidung der Blickabwendung, die beispielsweise auch von *pieDrive* (Franz u. a. 2012) verfolgt wird, bietet das vorliegende Konzept den Vorteil der Bedienung des Systems, ohne die Hände vom Lenkrad nehmen zu müssen. Durch die Wahl des Bedienelements am Lenkrad, das in seiner Grundform in praktisch jedem Fahrzeug zu finden ist, soll zudem ein schneller Gewöhnungseffekt bei den Nutzenden erreicht und die Akzeptanz gegenüber dem System begünstigt werden. Zusätzlich erhält die fahrzeugführende Person durch die Möglichkeit, die Hände am Lenkrad zu belassen, zugleich eine direkte, haptische Rückmeldung über die laterale Ausführung des Systems. Der Vorteil der haptischen Rückmeldung wird in verschiedenen Ausprägungen auch von anderen Autoren als solcher anerkannt. So zum Beispiel bei der bidirektionalen Kommunikation des H-Mode (Flemisch u. a. 2008) mittels eines aktiven Side-Sticks oder der Kombination aus aktivem Lenkrad und aktivem Fahrpedal bei Flemisch u. a. (2012).

In Abgrenzung zu den gängigen Vertretern der kooperativen Fahrzeugführung wurde in der vorliegenden Arbeit gemäß der ersten Forschungsfrage (F1) ein

System entwickelt, das die Erschließung des urbanen Straßenverkehrs durch eine kontinuierlicher Längs- und Querführung ermöglicht.

Im Hinblick auf weiterführende Forschungsarbeiten liegt es nahe, sowohl die Erweiterung eines solchen Systems um Abbiegemanöver als auch die Anbindung an Einparksysteme zu untersuchen. Beide Anwendungsfälle könnten durch die Erweiterung des Systems unter Verwendung der gleichen Bedienelemente erreicht werden. So könnte eine Unterstützung über die gesamte Fahrtroute ermöglicht werden.

Die Wahl des Bedienelements erscheint augenscheinlich valide. Die Wahl anderer Bedienelemente in vergleichbaren Anwendungsfällen der zitierten Arbeiten ist jedoch für sich betrachtet ebenfalls schlüssig begründet. Dieser Umstand deutet auf eine Forschungslücke hin, da auch nach einer zusätzlichen Recherche keine empirischen Untersuchungen gefunden werden konnten, die die Auswahl eines Bedienelementes für diese Anwendungsfälle objektivieren. Es wäre daher wünschenswert, unterschiedliche Bedienelemente einem Vergleich zu unterziehen und empirische Erkenntnisse dazu zu erhalten, welche Bedienelemente in welchem Maße für die Manöverübermittlung geeignet sind und dabei möglichst wenig Ablenkung vom Straßenverkehr fordern.

Das Gewebe dieser Welt ist
aus Notwendigkeit und Zufall
gebildet.

*(Johann Wolfgang von
Goethe)*

Kapitel 5

Fahrverhaltensanalyse

Im vorangegangenen Kapitel wurden aus dem betrachteten Umfeld die relevanten Fahrsituationen für die vorliegende Arbeit abgeleitet und aus dem Handlungsspielraum für den Fahrer eine Manöverauswahl bestimmt. Aus diesen Manövern wurden angestrebte Zielzustände identifiziert. Um die Manöver in einem Versuchsfahrzeug zu realisieren, wird auf deren Basis ein zu fahrender Pfad entwickelt, auf welchen das Fahrzeug eingeregelt wird.

Darauf aufbauend wird nachfolgend ein Verfahren entwickelt, mit dem ein auf den Fahrer angepasstes Fahrverhalten des Systems eingestellt werden kann.

Zunächst wird in Abschnitt 5.1 aufgezeigt, wie das vorliegende System für eine Adaption um die Fahrerintention erweitert werden kann. In Abschnitt 5.2 wird dargestellt, wie die Intention der Fahrerin oder des Fahrers mittels Bayes'scher Netze prädiziert wird. Anschließend wird in Abschnitt 5.3 erläutert, wie das zuvor für spezifische Fahrer angelernte Systemverhalten klassifiziert wird, damit ein für verschiedene Fahrertypen anwendbares Verhalten ermittelt werden kann. Abschnitt 5.4 beschreibt die zur Messdatengewinnung unter realen Verkehrsbedingungen durchgeführte Fahrstudie. In Abschnitt 5.5 wird die Aufbereitung dieser Daten dargestellt. Abschließend wird in Abschnitt 5.6 die Validierung der Fahrerintentionsprädiktion mit Daten aus der Fahrstudie aufgezeigt und die Ergebnisse werden in Abschnitt 5.7 diskutiert und in den Kontext weiterer wissenschaftlicher Arbeiten gesetzt.

5.1 Fahreradaptives Längs- und Querführungssystem

Im vorangegangenen Kapitel wurde ein situationsadaptives Längs- und Querführungssystem im Sinne der kooperativen Fahrzeugführung entwickelt, um den Fahrer auf dem Weg in die Stadt hinein zu unterstützen. Mittels Expertenfahrten wurde eine Grundapplikation des Systems bestimmt. Damit ein solches System von unterschiedlichen fahrzeugführenden Personen angenommen wird, sollte die Auslegung des Systems sich an individuelle Fahrpräferenzen anpassen können. Daher wird aufbauend auf dem entwickelten System die zweite Forschungsfrage (F2) dieser Arbeit adressiert:

Wie kann ein System zur kontinuierlichen Längs- und Querführung im urbanen Straßenverkehr für den individuellen Unterstützungsbedarf verschiedener Personen ausgelegt werden?

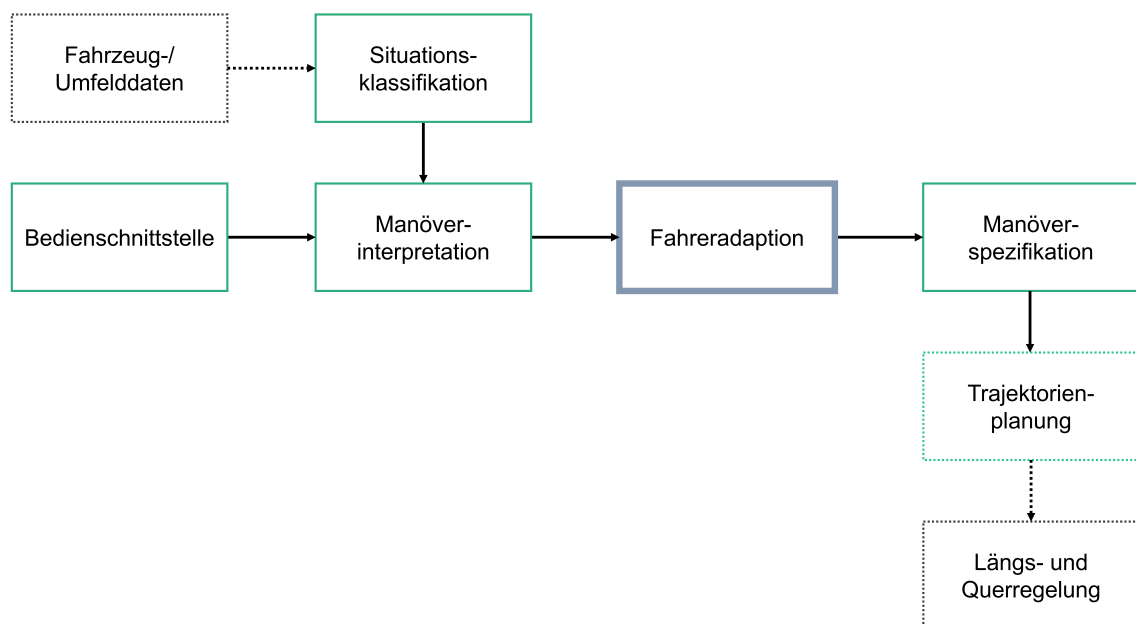


Abbildung 5.1: Schematische Darstellung der Funktionsarchitektur mit Erweiterung um eine Fahreradaptation

Um diese Frage zu beantworten, gilt es herauszufinden, wie die Fahrerintention gestaltet ist. Analog der Herleitung des vorliegenden Systems kann davon ausgegangen werden, dass die Fahrerabsicht je nach Situation verschieden ist. Die Situationsklassifikation hingegen auf Basis der Fahrzeug- und Umfelddaten als

auch die Manöverinterpretation erfolgt unabhängig der individuellen Präferenzen eines Fahrers oder einer Fahrerin.

Es ist daher sinnvoll, die Spezifikation eines Manövers fahreradaptiv zu gestalten. Dabei ordnet sich der Fahreradaptationsschritt, wie in Abbildung 5.1 zu sehen, sinnvollerweise zwischen Manöverinterpretation und Manöverspezifikation ein. Dadurch kann beispielsweise der Fahrstreifenwechsel dynamisch an individuelle Präferenzen angepasst werden und für den einen Fahrer zügig und dynamisch und für einen anderen komfortorientiert spezifiziert werden.

5.2 Fahrerintensionsprädiktion

Vor dem Hintergrund, dass Vorwissen über die kausalen Zusammenhänge vorliegt und das entwickelte System nachvollziehbar sein sollte, werden für die Fahrerintensionsprädiktion Bayes'sche Netze angewendet.

Daher wird im Folgenden mit diesem Vorwissen für jede Situation aus Abschnitt 4.3 ein Bayes'sches Netz entworfen, welches anschließend nach in Abschnitt 3.2.3 beschriebenen Verfahren angelernt wird. Abschließend wird darauf eingegangen, wie mittels eines solchen Netzes die Fahrerintention prädiziert wird.

Für die *Freie Fahrt* wird die Anwendung der Verfahren ausführlich beschrieben. Da diese Verfahren auch in den weiteren Situationen verwendet werden, werden im nachfolgenden Abschnitt nur noch die spezifischen Anteile beschrieben, die sich von der *freien Fahrt* unterscheiden und relevant für die Anwendung der Verfahren sind.

5.2.1 Freie Fahrt

Aufstellen des Bayes'schen Netzes

In einer *freien Fahrt* (vgl. 4.3.1) wird die Fahrerin oder der Fahrer durch die aktuelle Geschwindigkeitsbegrenzung im Fahrverhalten motiviert. Die Intention ist in diesem Szenario eine Wunschgeschwindigkeit in Abhängigkeit zur Geschwindigkeitsbegrenzung. Indikatoren dafür, in welchem Maße die Wunschgeschwindigkeit erreicht ist, sind die Betätigung des Gas- oder Bremspedals, die Beschleu-

nigung sowie die aktuelle Geschwindigkeit des Fahrzeugs und auch die über die Manöverschnittstelle angepasste Geschwindigkeitsvorgabe.

Unter Berücksichtigung dieser kausalen Zusammenhänge wird das Bayes'sche Netz entworfen, welches in Abbildung 5.2 zu sehen ist. Ziel dabei ist es, die Wunschgeschwindigkeit zu präzisieren, welche in dieser Situation die Fahrerintention repräsentiert.




Abbildung 5.2: Bayes'sches Netz für die Situation *Freie Fahrt*

- x_{GB} : Geschwindigkeitsbegrenzung
- x_{VW} : Wunschgeschwindigkeit
- x_{GP} : Betätigung des Gaspedals
- x_{BP} : Betätigung des Bremspedals
- x_{BL} : Aktuelle Beschleunigung
- x_{VA} : Aktuelle Geschwindigkeit
- x_{VV} : Geschwindigkeitsvorgabe

Daraus ergibt sich die gemeinsame Wahrscheinlichkeitsverteilung:

$$P(x_{GB}, x_{VW}, x_{GP}, x_{BP}, x_{BL}, x_{VA}, x_{VV}) = P(x_{GB})P(x_{VW}|x_{GB})P(x_{GP}|x_{VW})P(x_{BP}|x_{VW})P(x_{BL}|x_{VW})P(x_{VA}|x_{VW})P(x_{VV}|x_{VW}). \quad (5.1)$$

Anlernen des Bayes'schen Netzes

Um die Parameter dieses Bayes'schen Netzes anzulernen, wurde eine Fahrstudie durchgeführt, welche in Abschnitt 5.4 näher beschrieben wird. Aus dieser Studie

wurden mittels Zufallsziehung Datensätze bestimmt, welche zum Lernen verwendet werden.

Bevor auf das Lernverfahren eingegangen wird, müssen zuerst die vorliegenden Variablen des Netzes näher betrachtet werden.

Bei der *Wunschgeschwindigkeit* handelt es sich im Gegensatz zu allen anderen Variablen um eine nicht beobachtbare bzw. direkt messbare Größe. Wie die *Wunschgeschwindigkeit* für die Anwendung des Parameterschätzens aufbereitet wird, ist in Abschnitt 5.5.2 beschrieben.

Kontinuierliche Variable	Diskrete Variable
x_{GP}	x_{GB}
x_{BL}	x_{BP}
x_{VA}	
x_{VV}	

Tabelle 5.1: Unterteilung in kontinuierliche und diskrete Variablen

Alle anderen Variablen unterteilen sich, wie in Tabelle 5.1 dargestellt, in kontinuierliche und diskrete Variablen. Der Zustandsraum der kontinuierlichen Variablen wird in dieser Arbeit mittels Klassifikation mit Gauß'schen Mischverteilungen (s. Abschnitt 3.3) reduziert, um mit einem beherrschbaren Aufwand ein Bayes'sches Netz anlernen und auswerten zu können. Eine Sonderrolle hat an dieser Stelle die *Geschwindigkeitsvorgabe*, bei welcher es an sich um eine diskrete Variable handelt. Allerdings ergeben sich aus den Messdaten siebenzig mögliche Zustände. Daher wurde der Parameterraum dieser Variablen auf acht Zustände reduziert (s. Abbildung 5.15).

Durch die Anwendung von Gauß'schen Mischverteilungen ergibt sich in der Regel keine eindeutige Zuordnung eines Messwerts zu einem Zustand, sondern jeweils eine anteilige Zugehörigkeit. Für diese Variablen findet das Konzept der *weichen Evidenz* Anwendung. Die Berechnung der A-priori- sowie Übergangswahrscheinlichkeitstabellen erfolgt daher nach dem Verfahren von Xiao u. a. (2009), welches in Abschnitt 3.2.3 erläutert wurde. Exemplarisch wird im Folgenden die Bestimmung eines Eintrags $\theta_{vw_1|gb_2}$ der Übergangswahrscheinlichkeitstabelle $P(x_{VW}|x_{GB})$ beschrieben, welche in Tabelle 5.2 dargestellt ist. Da das Verfahren auf alle Einträge sowie Tabellen weiterer Variablen analog angewendet wird, wird deren Berechnung nicht explizit beschrieben.

	x_{GB_1}	x_{GB_2}	x_{GB_3}	x_{GB_4}	x_{GB_5}	x_{GB_6}	x_{GB_7}
x_{VW_1}	$\theta_{vw_1 gb_1}$	$\theta_{vw_1 gb_2}$	$\theta_{vw_1 gb_3}$	$\theta_{vw_1 gb_4}$	$\theta_{vw_1 gb_5}$	$\theta_{vw_1 gb_6}$	$\theta_{vw_1 gb_7}$
x_{VW_2}	$\theta_{vw_2 gb_1}$	$\theta_{vw_2 gb_2}$	$\theta_{vw_2 gb_3}$	$\theta_{vw_2 gb_4}$	$\theta_{vw_2 gb_5}$	$\theta_{vw_2 gb_6}$	$\theta_{vw_2 gb_7}$
x_{VW_3}	$\theta_{vw_3 gb_1}$	$\theta_{vw_3 gb_2}$	$\theta_{vw_3 gb_3}$	$\theta_{vw_3 gb_4}$	$\theta_{vw_3 gb_5}$	$\theta_{vw_3 gb_6}$	$\theta_{vw_3 gb_7}$
x_{VW_4}	$\theta_{vw_4 gb_1}$	$\theta_{vw_4 gb_2}$	$\theta_{vw_4 gb_3}$	$\theta_{vw_4 gb_4}$	$\theta_{vw_4 gb_5}$	$\theta_{vw_4 gb_6}$	$\theta_{vw_4 gb_7}$
x_{VW_5}	$\theta_{vw_5 gb_1}$	$\theta_{vw_5 gb_2}$	$\theta_{vw_5 gb_3}$	$\theta_{vw_5 gb_4}$	$\theta_{vw_5 gb_5}$	$\theta_{vw_5 gb_6}$	$\theta_{vw_5 gb_7}$
x_{VW_6}	$\theta_{vw_6 gb_1}$	$\theta_{vw_6 gb_2}$	$\theta_{vw_6 gb_3}$	$\theta_{vw_6 gb_4}$	$\theta_{vw_6 gb_5}$	$\theta_{vw_6 gb_6}$	$\theta_{vw_6 gb_7}$
x_{VW_7}	$\theta_{vw_7 gb_1}$	$\theta_{vw_7 gb_2}$	$\theta_{vw_7 gb_3}$	$\theta_{vw_7 gb_4}$	$\theta_{vw_7 gb_5}$	$\theta_{vw_7 gb_6}$	$\theta_{vw_7 gb_7}$
x_{VW_8}	$\theta_{vw_8 gb_1}$	$\theta_{vw_8 gb_2}$	$\theta_{vw_8 gb_3}$	$\theta_{vw_8 gb_4}$	$\theta_{vw_8 gb_5}$	$\theta_{vw_8 gb_6}$	$\theta_{vw_8 gb_7}$
x_{VW_9}	$\theta_{vw_9 gb_1}$	$\theta_{vw_9 gb_2}$	$\theta_{vw_9 gb_3}$	$\theta_{vw_9 gb_4}$	$\theta_{vw_9 gb_5}$	$\theta_{vw_9 gb_6}$	$\theta_{vw_9 gb_7}$

Tabelle 5.2: Übergangswahrscheinlichkeiten für die Zufallsvariable *Wunschgeschwindigkeit* unter der Bedingung der *Geschwindigkeitsbegrenzung*

Unter Anwendung der Formel 3.19 wird der Erwartungswert von $\theta_{vw_1|gb_2}$ mit

$$E(\theta_{vw_1|gb_2}|B_S, \mathbf{D}) = \frac{N_{vw_1|gb_2} + 1}{N_{vw|gb_2} + 9} \quad (5.2)$$

geschätzt. $N_{vw_1|gb_2}$ beschreibt die Anzahl der Fälle in einem Datensatz \mathbf{D} , in welchen die Variable x_{VW} den Zustand vw_1 und der Elternknoten x_{GB} mit gb_2 instanziiert ist und wird bei *harter Evidenz* mittels Gleichung 3.22 berechnet. Da die *Wunschgeschwindigkeit* mit einer Gauß'schen Mischverteilung klassifiziert wurde und nun in der Form $\overline{vw} = \{(vw_1, p_{vw_1}), (vw_2, p_{vw_2}), \dots, (vw_9, p_{vw_9})\}$ vorliegt, findet hier eine Erweiterung der Gleichung 3.22 durch Einsetzen der Formel 3.23 Anwendung:

$$N_{vw_1|gb_2} = \sum_{h=1}^m P(E_{vw} = e_{vw_1|gb_2}|C_h) = \sum_{h=1}^m p_{vw_1} p_{gb_2}. \quad (5.3)$$

Für den Elternknoten x_{GB} liegt *harte Evidenz* vor. Damit ergibt sich für p_{gb_2} in Formel 5.3:

$$p_{gb_2} = \begin{cases} 1, & \text{wenn } x_{GB} = gb_2 \\ 0, & \text{sonst.} \end{cases} \quad (5.4)$$

C_h beschreibt hier, dass es sich um das h -te Messdatum aus dem Datensatz \mathbf{D} mit m Messdaten handelt.

Durch Anwendung der Gleichung 3.21 lässt sich

$$N_{vw|gb_2} = \sum_{k=1}^9 N_{vw_k|gb_2} \quad (5.5)$$

berechnen, womit die Gleichung 5.2 vollständig bestimmt ist und der Erwartungswert von $\theta_{vw_1|gb_2}$ ermittelt werden kann.

Prädiktion mittels des Bayes'schen Netzes

Läge ausschließlich *harte Evidenz* vor, so würde unter Anwendung der Berechnungsvorschrift 3.7 auf das Bayes'sche Netz aus Abbildung 5.2 die *Wunschgeschwindigkeit* mit der folgenden Formel berechnet werden:

$$P(x_{vw_i}|x_{GB}, x_{GP}, x_{BP}, x_{BL}, x_{VA}, x_{VV}) = \frac{P(x_{vw_i}|x_{GB})P(x_{GP}|x_{vw_i})P(x_{BP}|x_{vw_i})P(x_{BL}|x_{vw_i})P(x_{VA}|x_{vw_i})P(x_{VV}|x_{vw_i})}{\sum_{l=1}^9 P(x_{vw_l}|x_{GB})P(x_{GP}|x_{vw_l})P(x_{BP}|x_{vw_l})P(x_{BL}|x_{vw_l})P(x_{VA}|x_{vw_l})P(x_{VV}|x_{vw_l})}. \quad (5.6)$$

Da bei mehr als einem Knoten *weiche Evidenz* vorliegt, wird zur Auswertung des Netzes der Big-Clique-Algorithmus aus Abschnitt 3.2.3 angewendet. Dafür wird das Bayes'sche Netz aus 5.2 in den Junction-Tree in Abbildung 5.3 transformiert, bei welchem sich alle Knoten in einem großen Cluster befinden, für die *weiche Evidenz* vorliegt.




Abbildung 5.3: Junction-Tree für die Situation *Freie Fahrt*

Die Cluster und Separatoren lassen sich entsprechend Abbildung 5.3 beschreiben als:

$$\begin{aligned} C_1 &= \{x_{GB}, x_{VW}\} \\ C_2 &= \{x_{BP}, x_{VW}\} \\ C_3 &= \{x_{GP}, x_{VW}, x_{BL}, x_{VA}, x_{VV}\} \\ S_1 &= \{x_{VW}\} \\ S_2 &= \{x_{VW}\} \end{aligned}$$

Mit diesen Clustern lässt sich die gemeinsame Wahrscheinlichkeitsverteilung aus Gleichung 5.1 mittels Potentialen wie folgt darstellen:

$$P(x_{GB}, x_{VW}, x_{GP}, x_{BP}, x_{BL}, x_{VA}, x_{VV}) = \frac{\psi(C_1)\psi(C_2)\psi(C_3)}{\psi(S_1)\psi(S_2)}. \quad (5.7)$$

Die Potentiale der Cluster werden mit den zugehörigen Wahrscheinlichkeitstabellen aus der Gleichung 5.1 und die der Separatoren jeweils mit eins initialisiert:

$$\begin{aligned} \psi(C_1) &= P(x_{GB})P(x_{VW}|x_{GB}) \\ \psi(C_2) &= P(x_{BP}|x_{VW}) \\ \psi(C_3) &= P(x_{GP}|x_{VW})P(x_{BL}|x_{VW})P(x_{VA}|x_{VW})P(x_{VV}|x_{VW}) \\ \psi(S_1) &= 1 \\ \psi(S_2) &= 1 \end{aligned}$$

Anschließend wird der Junction-Tree-Algorithmus ausgeführt, welcher in allgemeiner Form für den Junction-Tree in Abbildung 5.3 wie folgt aussieht:

$$\psi^*(C_1) = \psi(C_1) \quad (5.8)$$

$$\psi^*(S_1) = \sum_{x_{GB}} \psi^*(C_1) \quad (5.9)$$

$$\psi^*(C_2) = \frac{\psi^*(S_1)}{\psi(S_1)} \psi(C_2) \quad (5.10)$$

$$\psi^*(S_2) = \sum_{x_{BP}} \psi^*(C_2) \quad (5.11)$$

$$\psi^*(C_3) = \frac{\psi^*(S_2)}{\psi(S_2)} \psi(C_3) \quad (5.12)$$

$$\psi^{**}(C_3) = \psi^*(C_3) \quad (5.13)$$

$$\psi^{**}(S_2) = \sum_{C_3 \setminus x_{VW}} \psi^{**}(C_3) \quad (5.14)$$

$$\psi^{**}(C_2) = \frac{\psi^{**}(S_2)}{\psi^*(S_2)} \psi^*(C_2) \quad (5.15)$$

$$\psi^{**}(S_1) = \sum_{x_{BP}} \psi^{**}(C_2) \quad (5.16)$$

$$\psi^{**}(C_1) = \frac{\psi^{**}(S_1)}{\psi^*(S_1)} \psi^*(C_1) \quad (5.17)$$

Unter Einbeziehung der *harten Evidenz* $x_{GB} = gp_i$ und $x_{BP} = bp_j$ bei Ausführung des Junction-Tree-Algorithmus vereinfachen sich einige Berechnungsschritte, wie beispielsweise Gleichung 5.9, bei welcher die Summation über x_{GB} nicht ausgeführt werden muss, da der Zustand bekannt ist. Es ergibt sich direkt:

$$\psi^*(S_1) = \psi^*(x_{GB} = gb_i, x_{VW}) = P(x_{GB} = gb_i)P(x_{VW} | x_{GB} = gb_i).$$

Anschließend wird die *weiche Evidenz* $P(\overline{gp}), P(\overline{bl}), P(\overline{va})$ und $P(\overline{vv})$ unter Anwendung des iterativen Verfahrens zur proportionalen Adaptierung, welches in Abschnitt 3.2.3 und dort in Gleichung 3.18 beschrieben ist, in das Cluster C_3 absorbiert. Dafür wird $\psi_{(i-1)}(C_3)$ mit $\psi^{**}(C_3)$ initialisiert und über

$$\psi_{(i)}(C_3) = \frac{\psi_{(i-1)}(C_3) \cdot P(\overline{gp})}{\sum_{C_3 \setminus x_{GP}} \psi_{(i-1)}(C_3)} \quad (5.18)$$

$$\psi_{(i+1)}(C_3) = \frac{\psi_{(i)}(C_3) \cdot P(\overline{bl})}{\sum_{C_3 \setminus x_{BL}} \psi_{(i)}(C_3)} \quad (5.19)$$

$$\psi_{(i+2)}(C_3) = \frac{\psi_{(i+1)}(C_3) \cdot P(\overline{va})}{\sum_{C_3 \setminus x_{VA}} \psi_{(i+1)}(C_3)} \quad (5.20)$$

$$\psi_{(i+3)}(C_3) = \frac{\psi_{(i+2)}(C_3) \cdot P(\overline{vv})}{\sum_{C_3 \setminus x_{VV}} \psi_{(i+2)}(C_3)} \quad (5.21)$$

solange iteriert, bis $\psi(C_3)$ konvergiert:

$$\|(\psi_{(i+3)}(C_3) - \psi_{(i-1)}(C_3))\| < \varepsilon. \quad (5.22)$$

Nun muss noch eine Verteilung über den Junction-Tree erfolgen. Dafür wird die zweite Hälfte des Junction-Tree-Algorithmus nochmals ausgeführt (Gleichungen 5.14 bis 5.17).

Da sich die *Wunschgeschwindigkeit* als einziges Element in den Separatoren findet und durch Einhaltung der Running-Intersection-Eigenschaft und des Message-Passing-Protokolls globale Konsistenz gegeben ist, kann die *Wunschgeschwindigkeit* direkt über einen der beiden Separatoren ausgewertet werden.

5.2.2 Weitere Situationen

Für alle weiteren Situationen, d.h. *Folgefahrt*, *Zufahrt auf eine Kreuzung*, *Stillstand* und *Fahrstreifenwechsel*, wird auf vergleichbare Weise jeweils ein eigenes Bayes'sches Netz konstruiert. Das Anlernen der A-priori- und Übergangswahrscheinlichkeitstabellen sowie die Auswertung zur Prädiktion der zugehörigen Fahrerintention erfolgt nach den gleichen Verfahren wie für die Situation *Freie Fahrt*. Daher erfolgt nur eine kurze Darstellung des zugehörigen Bayes'schen Netzes und die Beschreibung der entsprechenden Junction-Trees ist in Anhang C nachzuvollziehen.

Folgefahrt

In einer Folgefahrt handelt es sich bei der Fahrerintention um die *Wunschzeitlücke*, welche zentral im Bayes'schen Netz in Abbildung 5.4 verortet ist.




Abbildung 5.4: Bayes'sches Netz für die Situation *Folgefahrt*

- x_{VA} : Aktuelle Geschwindigkeit
- x_{NF} : Fahrzeuge auf Nachbarfahrstreifen
- x_{TW} : Wunschzeitlücke
- x_{GP} : Betätigung des Gaspedals
- x_{BP} : Betätigung des Bremspedals
- x_{BL} : Aktuelle Beschleunigung
- x_{TA} : Aktuelle Zeitlücke zum Vorderfahrzeug
- x_{TV} : Zeitlückenvorgabe

Die Wahrscheinlichkeitsverteilung über das Bayes'sche Netz aus Abbildung 5.4 ist beschrieben durch:

$$P(x_{VA}, x_{NF}, x_{TW}, x_{GP}, x_{BP}, x_{BL}, x_{TA}, x_{TV}) =$$

$$P(x_{TW} | x_{VA}, x_{NF}) P(x_{VA}) P(x_{NF}) P(x_{GP} | x_{TW}) P(x_{BP} | x_{TW}) P(x_{BL} | x_{TW}) P(x_{TA} | x_{TW}) P(x_{TV} | x_{TW}).$$

(5.23)

Zufahrt auf eine Kreuzung

In der Situation *Zufahrt auf eine Kreuzung* wird die *Wunschhalte­distanz zur Halte­linie* als Fahrerintention identifiziert. Das Bayes'sche Netz zur Prädiktion dieser Intention ist in Abbildung 5.5 dargestellt.




Abbildung 5.5: Bayes'sches Netz für die Situation *Zufahrt auf eine Kreuzung*

- x_{DV} : Distanz zum Vorderfahrzeug
- x_{DA} : Aktuelle Distanz zur Halte­linie
- x_{DW} : Wunschhalte­distanz zur Halte­linie
- x_{GP} : Betätigung des Gaspedals
- x_{BP} : Betätigung des Bremspedals
- x_{BL} : Aktuelle Beschleunigung
- x_{VA} : Aktuelle Geschwindigkeit

Die Beschreibung der Wahrscheinlichkeitsverteilung über das Bayes'sche Netz in Abbildung 5.5 ist:

$$P(x_{DV}, x_{DA}, x_{DW}, x_{GP}, x_{BP}, x_{BL}, x_{VA}) = P(x_{DW}|x_{DV}, x_{DA})P(x_{DV})P(x_{DA})P(x_{GP}|x_{DW})P(x_{BP}|x_{DW})P(x_{BL}|x_{DW})P(x_{VA}|x_{DW}). \quad (5.24)$$

Stillstand

In der Situation *Stillstand* handelt sich bei der Intention der Fahrerin oder Fahrers um einen vorliegenden Anfahrwunsch bzw. nicht vorliegenden Anfahrwunsch.




Abbildung 5.6: Bayes'sches Netz für die Situation *Stillstand*

- x_{VV} : Geschwindigkeit des Vorderfahrzeugs
- x_{AN} : Anfahrwunsch
- x_{GP} : Betätigung des Gaspedals
- x_{BH} : Bedienhandlung

Für das Bayes'sche Netz in Abbildung 5.6 ergibt sich als Wahrscheinlichkeitsverteilung:

$$P(x_{VV}, x_{AN}, x_{GP}, x_{BH}) = P(x_{AN}|x_{VV})P(x_{VV})P(x_{GP}|x_{AN})P(x_{BH}|x_{AN}). \quad (5.25)$$

Fahrstreifenwechsel

In der Situation *Fahrstreifenwechsel* lässt sich die Fahrstreifenwechseldauer als Fahrerintention identifizieren, welche sich wieder zentral im zugehörigen Bayes'schen Netz in Abbildung 5.7 findet.

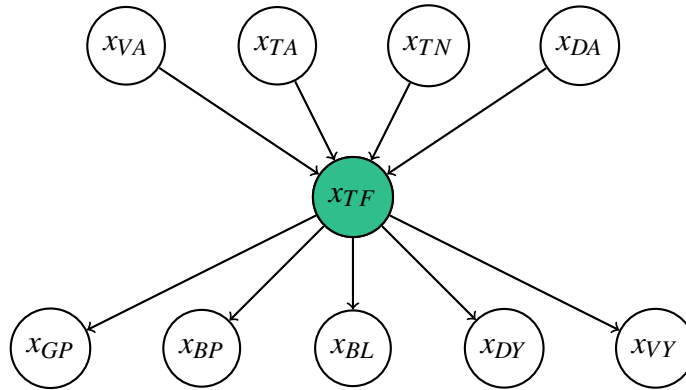


Abbildung 5.7: Bayes'sches Netz für die Situation *Fahrstreifenwechsel*

- x_{VA} : Aktuelle Geschwindigkeit
- x_{TA} : Aktuelle Zeitlücke zum Vorderfahrzeug
- x_{TN} : Aktuelle Zeitlücke zu Fahrzeugen auf Nachbarfahrstreifen
- x_{DA} : Aktuelle Distanz zur Haltelinie
- x_{TF} : Wunschzeitdauer des Fahrstreifenwechsel
- x_{GP} : Betätigung des Gaspedals
- x_{BP} : Betätigung des Bremspedals
- x_{BL} : Aktuelle Beschleunigung
- x_{DY} : Aktuelle Querablage
- x_{VY} : Aktuelle Quergeschwindigkeit

Die zugehörige Wahrscheinlichkeitsverteilung lautet:

$$\begin{aligned}
 P(x_{VA}, x_{TA}, x_{TN}, x_{DA}, x_{TF}, x_{GP}, x_{BP}, x_{BL}, x_{DY}, x_{VY}) &= P(x_{TF} | x_{VA}, x_{TA}, x_{TN}, x_{DA}) P(x_{VA}) \\
 &\cdot P(x_{TA}) P(x_{TN}) P(x_{DA}) P(x_{GP} | x_{TF}) P(x_{BP} | x_{TF}) P(x_{BL} | x_{TF}) P(x_{DY} | x_{TF}) P(x_{VY} | x_{TF}).
 \end{aligned}$$

(5.26)

5.3 Fahrertypabhängige Parameteranpassung

Im vorangegangenen Abschnitt 5.2 wurde erläutert, wie in dieser Arbeit Bayes'sche Netze erzeugt, angelernt und ausgewertet werden. Es ist allerdings nicht davon auszugehen, dass ein Netz, welches mit Daten eines Studienteilnehmenden (s. Abschnitt 5.4) angelernt wurde, eine angemessene Vorhersage für eine beliebige andere Fahrerin oder einen beliebigen anderen Fahrer machen wird.

Diesem Problem kann auf verschiedene Weise begegnet werden. Eine Option wäre, stets mit einer Grundkonfiguration zu starten und während der Fahrt mit den aktuellen Fahrzeug- und Umfelddaten das Netz anzupassen. Das hätte den großen Vorteil, dass das Netz sehr individuell auf den Fahrzeugführenden sowie dessen Tagesform angepasst ist. Dem stehen zwei große Nachteile entgegen. Zum einen könnte sich das System in der gleichen Situation verschieden verhalten, was für einen Fahrer gegebenenfalls nicht nachvollziehbar ist und zu verminderter Akzeptanz führen kann. Zum anderen steigt der Absicherungsaufwand eines Systems erheblich, welches sich stets adaptieren kann und zugleich für den Endkunden sicher ausgelegt sein muss.

Bei vielen Systemen im automobilen Kontext wird zwischen komfortbewussten, normalen und sportlichen Fahrern unterschieden. Das hat den klaren Vorteil, dass nur drei Konfigurationen abgesichert werden müssen und damit aber die meisten Fahrerinnen und Fahrer abgebildet werden können. Zusätzlich können sich diese wiederum auch selbst in einem gewissen Maße einem System anpassen, sofern es von ihrer Wunschauslegung nicht allzu weit entfernt ist und der Nutzen bzw. Komfortgewinn im Vordergrund steht. Darüber hinaus verhält sich das System für den Nutzer innerhalb eines Profils deterministisch und nachvollziehbar.

Aufgrund dieser Diskussion wird in der vorliegenden Arbeit die zweite Variante verfolgt. Mittels des in Abschnitt 5.2 beschriebenen Verfahrens wurde für die Teilnehmenden der Fahrstudie jeweils ein Bayes'sches Netz für die in Abschnitt 4.3 beschriebenen Situationen angelernt. Für die *Freie Fahrt* ergeben sich damit jeweils Wahrscheinlichkeitstabellen für $P(x_{GB})$, $P(x_{VW}|x_{GB})$, $P(x_{GP}|x_{VW})$, $P(x_{BP}|x_{VW})$, $P(x_{BL}|x_{VW})$, $P(x_{VA}|x_{VW})$ und $P(x_{VV}|x_{VW})$, welche sich von Studienteilnehmenden zu Studienteilnehmenden unterscheiden.

Ziel ist es nun, diese Daten so zu klassifizieren, dass sich drei Konfigurationen ergeben, welche die gelernten Daten bestmöglichst abbilden. Dafür wird der

k-means-Algorithmus angewendet, welcher bei geeigneter Wahl der Startwerte schnell konvergiert. Wie bereits beschrieben, sollen die Daten $k = 3$ Clustern zugeordnet werden. Für diese drei Cluster sollen Zentren gebildet werden, so dass die Summe der quadrierten Abweichung der Daten von diesen Zentren minimal ist. Formal ausgedrückt wird die Funktion

$$J = \sum_{j=1}^3 \sum_{i=1}^n \|x_{i,j} - c_j\|^2 \quad (5.27)$$

minimiert, wobei $x_{i,j}$ den Datenpunkt und c_j das Clusterzentrum j beschreibt. In jeder Iteration wird für jeden Datenpunkt der Abstand zu den Clusterzentren berechnet und der Datenpunkt dem Cluster zugeordnet, bei welchem der Abstand minimal ist. Nachdem alle Datenpunkte zugeordnet sind, wird die Position der Zentren durch Mittelung der zugeordneten Clusterdaten neu berechnet. Diese Schritte werden so oft wiederholt, bis sich die Zuordnung zu Clustern und die Zentren nicht mehr verändern (Alsabti u. a. 1997).

Hierzu werden zuerst Matrizen erzeugt, die die erlernten Wahrscheinlichkeitstabellen für alle Lerndatensätze beinhalten. Am Beispiel $P(x_{VW}|x_{GB})$ sieht dies für n Datensätze folgendermaßen aus:

$$P^n(x_{VW}|x_{GB}) = \begin{pmatrix} \theta_{vw_1|gb_1}^1 & \theta_{vw_2|gb_1}^1 & \cdots & \theta_{vw_9|gb_1}^1 & \theta_{vw_1|gb_2}^1 & \cdots & \theta_{vw_9|gb_7}^1 \\ \theta_{vw_1|gb_1}^2 & \cdots & \cdots & \cdots & \cdots & \cdots & \theta_{vw_9|gb_7}^2 \\ \cdots & \cdots & \cdots & \cdots & \cdots & \cdots & \cdots \\ \theta_{vw_1|gb_1}^n & \cdots & \cdots & \cdots & \cdots & \cdots & \theta_{vw_9|gb_7}^n \end{pmatrix}.$$

Eine Zeile dieser Matrix enthält somit alle Daten von $P(x_{VW}|x_{GB})$ für einen Lerndatensatz, d.h. die Daten für einen Teilnehmenden aus der Fahrstudie. Mit diesen Matrizen wird die Eingangsmatrix X für den *k-means*-Algorithmus gebildet:

$$\begin{pmatrix} P^n(x_{GB}) & P^n(x_{VW}|x_{GB}) & P^n(x_{GP}|x_{VW}) & P^n(x_{BP}|x_{VW}) & P^n(x_{BL}|x_{VW}) & P^n(x_{VA}|x_{VW}) \\ & & & & & & P^n(x_{VV}|x_{VW}) \end{pmatrix}. \quad (5.28)$$

Beliebige drei Zeilen von X bilden die initialen Clusterzentren. Nach Konvergenz des Algorithmus sind die Bayes'schen Netze der Lerndaten einem von drei Clustern zugeordnet. Für jedes Cluster liegt ein gemittelter Wert über die Daten vor, welcher wiederum ein Bayes'sches Netz pro Cluster repräsentiert.

Dieses Verfahren wird auf die gleiche Weise auch für die Netze für die *Folgefahrt*,

die *Zufahrt auf eine Kreuzung*, den *Stillstand* und den *Fahrstreifenwechsel* angewendet. Für alle ergeben sich jeweils drei Bayes'sche Netze, mit welchen eine Prädiktion der Fahrerintention vorgenommen werden kann.

5.4 Erhebung der Messdaten in einer Fahrstudie

Das folgende Unterkapitel beschreibt die Erhebung der Messdaten unter realen Verkehrsbedingungen. Zunächst wird der Aufbau des für die Fahrstudie verwendeten Versuchsfahrzeugs in Abschnitt 5.4.1 beschrieben. Es folgt eine Darstellung der Mensch-Maschine-Schnittstelle (MMS) in Abschnitt 5.4.2. Anschließend erfolgt die Stichprobenbeschreibung in Abschnitt 5.4.3 sowie die Beschreibung der Durchführung des Versuchs in Abschnitt 5.4.4.

5.4.1 Aufbau des Versuchsfahrzeugs

Als Versuchsfahrzeug wurde ein Audi A6 Avant verwendet, welcher im Rahmen des Projektes UR:BAN (URBAN 2016) mit einer Vielzahl an Sensoren und Fahrzeugrechnern zur Datenerhebung und -verarbeitung ausgestattet wurde. Zur Überwachung des Umfelds wurde das Fahrzeug mit diversen Sensoren ausgestattet, deren Verortung am Fahrzeug in Abbildung 5.8 dargestellt ist. Der Bereich vor dem Fahrzeug wurde über einen Doppel-Radar, einen Laserscanner und eine Monokamera überwacht. Zur Absicherung des Seitenbereichs kamen Radare sowie Ultraschallsensoren zum Einsatz. Durch die Verbauposition der Seitenradare an den Ecken des Fahrzeugs dienten diese zusätzlich zur Überwachung der benachbarten Fahrstreifen vor und hinter dem Fahrzeug. Der Bereich direkt dahinter wurde mit einem Heckradar überwacht. Die Funktionsweise sowie Vor- und Nachteile der verschiedenen Sensoren sind in Abschnitt 2.2 erläutert. Zur Unterstützung des Systems wurde die Multifunktionsanzeige (MFA) im Zentrum des Kombiinstrumentes verwendet, um den Versuchspersonen grafisch eine Rückmeldung über den aktuellen Systemzustand zu geben. Damit sollte die Verständlichkeit des Systems und der Interaktionsmöglichkeiten sowie die Nachvollziehbarkeit der Systemeingriffe erhöht werden.



Abbildung 5.8: Versuchsfahrzeug Audi A6 Avant mit Verbauorten der Sensorik (Kreßler 2015)

5.4.2 Mensch-Maschine-Schnittstelle

Das im folgenden Abschnitt dargestellte Anzeigekonzept entstand ursprünglich im Rahmen des Verbundprojektes UR:BAN (Teilprojekt: Mensch im Verkehr (MV)) und wurde mit freundlicher Genehmigung für die Durchführung der Fahrstudie wiederverwendet.

Als Mensch-Maschine-Schnittstelle (MMS) wurde das mittlere Display des Kombiinstrumentes sowie das Bedienelement am Lenkstockhebel verwendet. Die Anzeige im Kombiinstrument gab den Fahrzeugführenden eine visuelle Rückmeldung über den aktuellen Systemzustand (aktiv oder passiv), die klassifizierte Situation (*Freie Fahrt, Folgefahrt* etc.) sowie mögliche Handlungsoptionen (Anpassen der Geschwindigkeitsvorgabe, Fahrstreifenwechsel etc.). Mittels des Bedienelements am Lenkstockhebel hatte die Versuchsperson die Möglichkeit, ihren Manöverwunsch an das System zu übermitteln, über dessen Umsetzungsstatus neben der Fahrzeugreaktion in der Anzeige eine visuelle Rückmeldung gegeben wurde. Die Anzeige im Kombiinstrument gab den Fahrzeugführenden eine visuelle Rückmeldung über den aktuellen Systemzustand. Aus diesem ergaben sich die in Abschnitt 4.6 beschriebenen Handlungsoptionen. Mittels des Bedienelements konnte die Fahrerin oder der Fahrer dem System den Manöverwunsch übermitteln. Im Zentrum der Anzeige (Abbildung 5.9) befand sich stets das eigene Fahrzeug. Ein weißer Obelisk vor dem Fahrzeug signalisierte eine aktive Längsführung. War die Längsführung deaktiviert, färbte sich der Obelisk grau transparent. Mit

den kleinen Pfeilen links und rechts am Obelisk wurde die aktuell eingestellte Zeitlücke zum Vorderfahrzeug visualisiert. Die teilweise Blaufärbung stellte die gemessene Zeitlücke dar. Oberhalb vom Obelisk war das aktuelle Regelobjekt der Längsführung zu sehen, bei welchem es sich für das vorliegende System um ein Fahrzeug, ein Geschwindigkeitsbegrenzungsschild oder eine Lichtsignalanlage handeln konnte. Am unteren Rand der Anzeige war neben einem Geschwindigkeitsregelanlage (GRA)-Piktogramm die aktuell eingestellte Geschwindigkeitsvorgabe zu sehen.

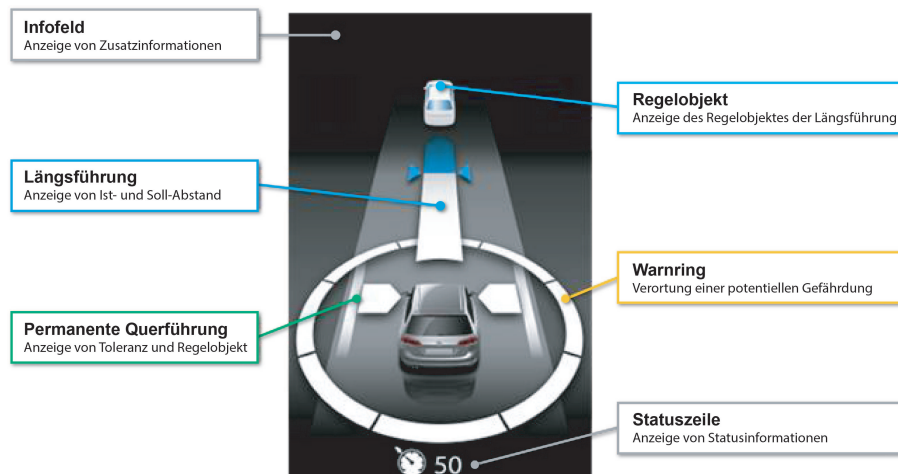


Abbildung 5.9: Visualisierung einer *Folgefahrt* im mittleren Display des Kombiinstrumentes (Petermann-Stock und Werneke 2014)

Der Status der Querführung wurde durch die weißen Balkenelemente und die weißen Pfeilelemente links und rechts neben dem Fahrzeug visualisiert. Eine aktive Querführung wurde durch eine weiße Füllung der Elemente kommuniziert und eine inaktive durch Transparenz. Bei dem Ring um das Fahrzeug handelte es sich um einen Warning. Bei erkannter potentieller Gefahr wurde das Element des Rings um das Fahrzeug gelb oder rot eingefärbt, in dessen Richtung die Gefahr verortet war.

Wurde ein von der Fahrerin oder dem Fahrer angeforderter Fahrstreifenwechsel durchgeführt, so wurde der Obelisk in eine S-Form transformiert und ein zusätzlicher Fahrstreifen eingeblendet. Dadurch wurde ein Fahrstreifenwechsel in die jeweilige Richtung dargestellt. Dies ist in der zweiten Grafik in Abbildung 5.10 zu sehen. Zusatzinformationen wurden in einem hervorgehobenen Feld am oberen Rand der Anzeige aufgezeigt. Das ist im dritten Bild der Abbildung dargestellt. Hier wurde der Fall visualisiert, dass ein angeforderter Fahrstreifenwechsel nicht

direkt durchgeführt werden konnte und eine Wartezeit aktiv wurde. Bei einem abgebrochenen Fahrstreifenwechsel wurde eine entsprechende Meldung in der Anzeige eingeblendet (viertes Bild). Des Weiteren änderte sich die Farbe des s-förmigen Obelisken in grau transparent, um die Deaktivierung der Längsführung zu signalisieren.



Abbildung 5.10: Anzeigebispiel: Fahrstreifenwechsel (Volkswagen AG 2016)

Mit diesem Anzeigekonzept konnten die Fahrzeugführenden zusätzlich zur Fahrzeugbewegung und zum Fahrzeugumfeld jederzeit erkennen, wie der aktuelle Systemzustand war und direkt oder indirekt identifizieren, welche Manöverooptionen möglich waren.

5.4.3 Stichprobenbeschreibung

Die Fahrstudie wurde mit 18 Versuchspersonen (drei Frauen und 15 Männern) durchgeführt. Das durchschnittliche Alter lag bei 34 Jahren, wobei die jüngste Person 26 Jahre und die älteste 49 Jahre alt war zum Versuchszeitpunkt. Bei allen Teilnehmenden handelte es sich um Mitarbeiterinnen und Mitarbeiter der Forschung und Entwicklung der Volkswagen AG.

Circa 83 Prozent der Versuchspersonen in der Stichprobe waren zum Versuchszeitpunkt mehr als elf Jahre im Besitz eines Führerscheins. Die jährliche Fahrleistung der Versuchspersonen in der Stichprobe zeigte eine breite Spreizung. Etwa 22 Prozent gaben an, unter 10.000 Kilometer im Jahr zu fahren.

Merkmal	<i>n</i>	%
Geschlecht		
weiblich	3	16,7
männlich	15	83,3
Alter zum Befragungszeitpunkt (in Jahren)		
26–30	8	44,4
31–35	3	16,7
36–40	3	16,7
41–45	2	11,1
46–50	2	11,1
Führerscheinbesitz (in Jahren)		
3–5	1	5,6
6–10	2	11,1
11–20	11	61,1
> 20	4	22,2
Jährliche Fahrleistung (in Kilometern)		
< 10.000	4	22,2
11.000–20.000	6	33,3
21.000–30.000	6	33,3
> 30.000	2	11,1

Tabelle 5.3: Übersicht der Merkmalshäufigkeit innerhalb der Stichprobe ($N=18$)

Jeweils 33 Prozent gaben an, 11.000-20.000 Kilometer sowie 21.000-30.000 Kilometer pro Jahr mit dem Fahrzeug zurückzulegen und 11 Prozent hatten eine jährliche Fahrleistung von mehr als 30.000 Kilometer im Jahr.

Im Bezug auf Vorerfahrungen mit relevanten Assistenzsystemen waren sowohl Personen vertreten, die solche im Alltag häufig als auch gar nicht nutzten. Die Detailbetrachtung zeigt, dass der Lane Assist (Spurhalteassistent) von 61 Prozent sehr selten eingesetzt wurde, während über 50 Prozent GRA häufig bis ständig verwendeten. ACC hatten bis auf eine Person alle bereits verwendet und knapp 45 Prozent häufig bis ständig im Gebrauch.

Nutzungsverhalten	Fahrerassistenzsysteme					
	Lane Assist		GRA		ACC	
	<i>n</i>	%	<i>n</i>	%	<i>n</i>	%
Ständige Nutzung	4	22,2	6	33,3	3	16,7
Häufige Nutzung	3	33,3	6	33,3	5	27,8
Seltene Nutzung	11	61,1	5	27,8	9	50,0
Noch nie genutzt	0	0,0	1	5,6	1	5,6

Tabelle 5.4: Übersicht des Nutzungsverhaltens von Fahrerassistenzsystemen innerhalb der Stichprobe ($N=18$)

5.4.4 Versuchsdurchführung

Die Versuchspersonen wurden zum abgestimmten Zeitpunkt am Versuchsfahrzeug in Empfang genommen. Sie wurden zunächst gebeten, sich in das Fahrzeug zu setzen und eine für sie angenehme Sitz- und Lenkradposition einzustellen. Im Anschluss wurden die Teilnehmenden mündlich über den Versuch aufgeklärt und in die Bedienung des Systems eingewiesen. Zur Erläuterung möglicher Bedienschritte sowie der Anzeigen des Systems im Kombiinstrument kam eine ausgedruckte, bebilderte Anleitung zum Einsatz. Die Versuchspersonen wurden weiterhin gebeten, ihre Eindrücke zum System, insbesondere zu dessen Auslegung in Kombination mit den eigenen Präferenzen, jederzeit während der Fahrt verbal zu kommunizieren. Sie wurden weiterhin aufgefordert, bei Missfallen der Systemauslegung mithilfe des Gaspedal, Bremspedals oder eines Lenkradeingriffs die vom System ausgeführte Fahrzeugbewegung zu überstimmen.

Zur Eingewöhnung in das Fahrzeug wurden die Versuchspersonen gebeten, zunächst mit ausgeschaltetem System zur Versuchsstrecke zu fahren. Bei Erreichen des ersten Abschnitts der Versuchsstrecke wurde die Versuchsperson gebeten, das System zu aktivieren und zunächst sich auf dem ersten Streckenabschnitt mit der Bedienung des Systems vertraut zu machen. Für diesen ersten Teil der Fahrstrecke wurde auf einer Autobahn zum nächsten Kreuz gefahren, dort gewendet und wieder zurückgefahren. Der zweite Teil der Versuchsfahrt fand auf gut ausgebauten Stadtstraßen der Stadt Wolfsburg statt. Die Strecke war so gewählt, dass nahezu der gesamte Versuch auf zweistreifigen Richtungsfahrbahnen durchgeführt werden konnte.

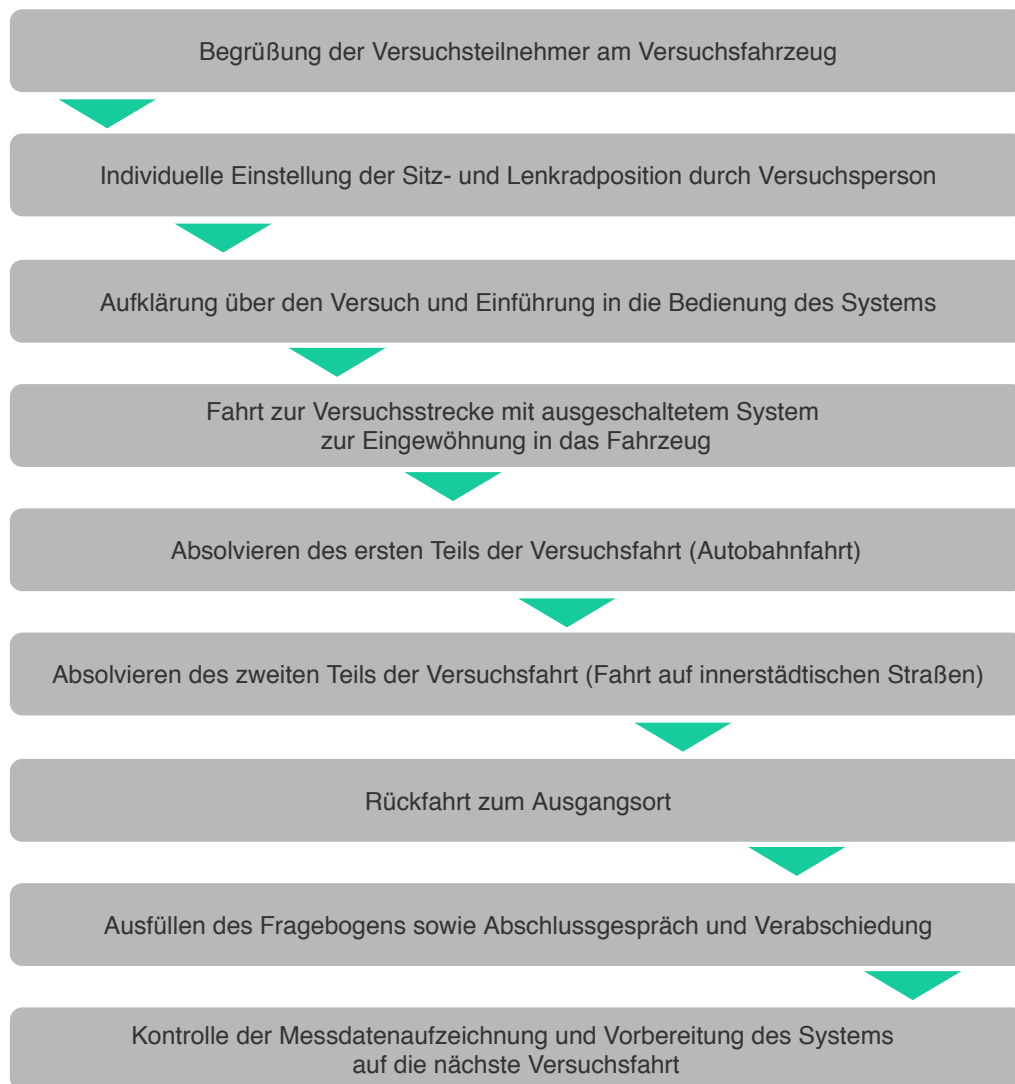


Abbildung 5.11: Schematischer Ablauf der Versuchsdurchführung

Streckenabschnitte, in denen Abbiegemanöver durchführen werden mussten, wurden von der Auswertung ausgenommen. An diesen Stellen wurden die Fahrerinnen und Fahrer aufgefordert, das System zu deaktivieren, da Abbiegemanöver und enge Kurvenfahren nicht Teil des Systems waren.

Die Fahrten fanden sowohl vormittags wie auch nachmittags statt, um eine Abdeckung über verschiedene Verkehrssituationen zu erhalten.

Nach Abschluss des zweiten Teils der Versuchsstrecke fuhren die Versuchspersonen zum Ausgangspunkt zurück und wurden gebeten, einen Fragebogen mit soziodemografischen Angaben sowie zur alltäglichen Nutzung von Fahrerassistenzsystemen auszufüllen (s. Abschnitt 5.4.3). Abschließend hatten die Teilneh-

menden die Möglichkeit, Fragen zu stellen oder Kommentare und Rückmeldungen zur Umsetzung des Systems zu geben. Diese wurden zusätzlich zu bereits notierten Anmerkungen während der Fahrt protokolliert. Es folgte eine Kontrolle und Sicherung der abgespeicherten Messdaten und Vorbereitung des Systems auf den nächsten Versuch.

Die Versuche wurden im Zeitraum vom 10.–19. März 2015 durchgeführt. Die mittlere Versuchszeit betrug 40,22 Minuten (minimal: 30 Minuten, maximal: 50 Minuten). Zehn Versuchspersonen haben die Versuchsfahrt am Vormittag absolviert und acht Personen am Nachmittag.

5.5 Aufbereitung der Messdaten

Die folgenden zwei Abschnitte beschreiben die durchgeführte Aufbereitung der Messdaten aus der Fahrstudie für das Anlernen und Auswerten der Bayes'schen Netze. Zunächst wird in Abschnitt 5.5.1 erläutert, wie kontinuierliche Messdaten (z.B. die Fahrpedalstellung) unter der Berücksichtigung der Auftretenshäufigkeit mittels Gauß'schen Mischverteilungen klassifiziert wurden. Das zugrunde liegende Verfahren zur Schätzung der Modellparameter von Gauß'schen Mischverteilungen ist in Abschnitt 3.3 erläutert. Anschließend wird in Abschnitt 5.5.2 dargestellt, wie nicht direkt beobachtbare Größen (z.B. die Wunschgeschwindigkeit) aus objektiven Messgrößen bestimmt wurden.

5.5.1 Klassifikation der Messdaten mittels Gauß'scher Mischverteilungen

Während der im vorangegangenen Abschnitt beschriebenen Fahrstudie wurden kontinuierliche Messdaten aufgezeichnet, die für die Verwendung in Bayes'schen Netzen zunächst diskretisiert werden mussten. Je geringer die Anzahl der gewählten Intervalle ist, desto beherrschbarer werden die Berechnungen der Lernschritte (Mrad u. a. 2015). Es existieren unterschiedliche Ansätze, eine Diskretisierung vorzunehmen. Beispielsweise kann eine äquidistante Einteilung vorgenommen oder eine Klassifikation auf Basis von Expertenwissen angewendet werden.

Im Rahmen dieser Arbeit wurde ein Verfahren gewählt, bei dem die Klassifikation sich an der Auftretenshäufigkeit der Messdaten orientiert und kontinuierliche Messdaten mittels Gauß'scher Mischverteilungen klassifiziert.

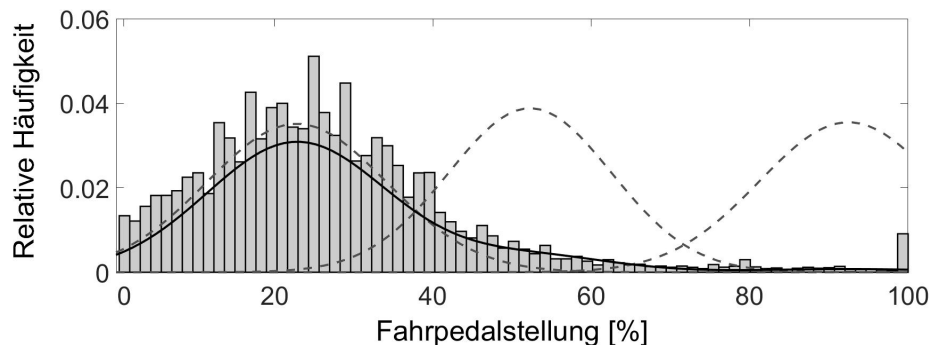


Abbildung 5.12: Klassifikation der Fahrpedalstellung in drei Klassen mittels Gauß'scher Mischverteilung

Die Abbildungen 5.12–5.14 zeigen die Daten für das Bayes'sche Netz der Situation *Freie Fahrt*. Abbildung 5.12 zeigt die Klassifikation der kontinuierlichen Eingangsgröße *Fahrpedalstellung*. Zur Erstellung der Gauß'schen Mischverteilung wurde der Wert null aufgrund des hohen Auftretens im Verhältnis zu den anderen Werten separat betrachtet. Damit ergeben sich insgesamt vier Klassen für die Fahrpedalstellung. Inhaltlich können diese als *nicht getreten*, *leicht getreten*, *mittelstark getreten* und *stark getreten* interpretiert werden.

In Abbildung 5.13 ist die Verteilung *Geschwindigkeit* im Intervall $[0 \frac{km}{h}, 150 \frac{km}{h}]$ zu sehen. Auch hier wird der Wert null aus der Bestimmung der Gauß'schen Mischverteilung ausgenommen. Es ergeben sich damit in der Summe fünf Klassen zur Beschreibung der *Geschwindigkeit*.




Abbildung 5.13: Klassifikation der Fahrzeuggeschwindigkeit in vier Klassen mittels Gauß'scher Mischverteilung

Neben dem *Stillstand*, beispielsweise bei einem Ampelhalt, gibt es vier weitere Geschwindigkeitsbereiche, von denen die ersten beiden vorwiegend im innerstädtischen und die letzten beiden im außerstädtischen Bereich zur Anwendung kommen.




Abbildung 5.14: Klassifikation der Fahrzeugbeschleunigung in drei Klassen mittels Gauß'scher Mischverteilung

Die Klassifikation der Fahrzeugbeschleunigung ist in Abbildung 5.14 dargestellt. Aufgrund des sehr häufigen Auftretens des Wertes null wurde dieser auch in diesem Fall bei der Bestimmung der Gauß'schen Mischverteilung ausgeschlossen. Die Variable *Geschwindigkeitsvorgabe* verfügt initial bereits über einen diskreten Wertebereich. Allerdings hat sich bei der Auswertung der Messdaten ergeben, dass der Wertebereich eine Menge von 70 unterschiedlichen Werten beinhaltet. Um die Komplexität des Bayes'schen Netzes zu reduzieren wurde auch auf diese Variable eine Gauß'sche Mischverteilung angewendet. Wie in Abbildung 5.15 zu sehen wurde die *Geschwindigkeitsvorgabe* auf acht Klassen reduziert.




Abbildung 5.15: Klassifikation der Geschwindigkeitsvorgabe in acht Klassen mittels Gauß'scher Mischverteilung

In der Situation *Folgefahrt* kommt die aktuelle *Zeitlücke* zum Vorderfahrzeug als

weitere kontinuierliche Variable hinzu. Deren Zustandsreduktion mittels Gauß'scher Mischverteilungen ist in Abbildung 5.16 dargestellt.




Abbildung 5.16: Klassifikation der aktuellen Zeitlücke in drei Klassen mittels Gauß'scher Mischverteilung

Für die Situation *Zufahrt auf eine Kreuzung* gibt es ebenfalls zuvor noch nicht verwendete kontinuierliche Messgrößen.




Abbildung 5.17: Klassifikation der Distanz zur Haltelinie in vier Klassen mittels Gauß'scher Mischverteilung




Abbildung 5.18: Klassifikation der Distanz zum Vorderfahrzeug in drei Klassen mittels Gauß'scher Mischverteilung

Dabei handelte es sich um die *Distanz zur nächsten Haltelinie*, deren Gauß'sche Mischverteilung in Abbildung 5.17 zu sehen ist, sowie um die *Distanz zum Vorderfahrzeug*, welche in Abbildung 5.18 dargestellt ist.

Für die Situation *Stillstand* wurde zusätzlich noch die *Geschwindigkeit des Vorderfahrzeugs* mittels Gauß'scher Mischverteilungen klassifiziert. Das Ergebnis ist in Abbildung 5.19 zu sehen.




Abbildung 5.19: Klassifikation der Geschwindigkeit des Vorderfahrzeugs in vier Klassen mittels Gauß'scher Mischverteilung

Zur Auswertung des *Fahrstreifenwechsels* wurde zusätzlich die Querbewegung des eigenen Fahrzeugs sowie auch die Fahrzeuge auf den Nachbarfahrstreifen mit betrachtet. Daher wurden sowohl der *Querversatz* (Abbildung 5.20) als auch die *Quergeschwindigkeit* (Abbildung 5.21) des eigenen Fahrzeugs mithilfe von Gauß'schen Mischverteilungen in ihrer Komplexität reduziert.




Abbildung 5.20: Klassifikation des Querversatzes in drei Klassen mittels Gauß'scher Mischverteilung

Darüber hinaus wurde die *Zeitlücke zum nächsten Fahrzeug in Fahrtrichtung auf dem Nachbarfahrstreifen* bestimmt. Dafür wurde das nächste Fahrzeug, sofern

vorhanden, auf dem für den Wechsel vorgesehenen Nachbarfahrstreifen ausgewählt (Abbildung 5.22).

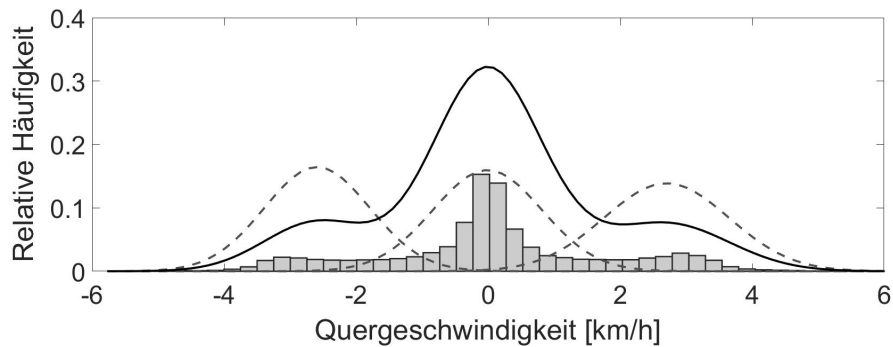


Abbildung 5.21: Klassifikation der Quergeschwindigkeit in drei Klassen mittels Gauß'scher Mischverteilung




Abbildung 5.22: Klassifikation der Zeitlücke zum nächsten Fahrzeug auf dem Nachbarfahrstreifen in drei Klassen mittels Gauß'scher Mischverteilung

5.5.2 Nicht beobachtbare Größen

Im Unterschied zu einer Sensormessgröße lässt sich die Intention der fahrzeugführenden Person nicht direkt messen. Sie kann jedoch aus objektiven Messgrößen geschätzt werden.

Wunschgeschwindigkeit

So wird zum Beispiel in der Situation *Freie Fahrt* die Wunschgeschwindigkeit als Intention des Fahrers betrachtet (s. Abschnitt 5.2.1). In dieser Arbeit wird an-

genommen, dass die *Wunschgeschwindigkeit* erreicht ist, wenn für eine hinreichend lange Zeitdauer die Beschleunigung des Fahrzeugs null beträgt. In diesem Fall wurde allen Messdaten bis zum letzten Zeitpunkt, zu dem eine andere Wunschgeschwindigkeit feststand, die ermittelte Wunschgeschwindigkeit zugewiesen. Damit ist für jeden Zeitschritt in den Messdaten eine Wunschgeschwindigkeit gegeben.




Abbildung 5.23: Klassifikation der Wunschgeschwindigkeit in neun Klassen mittels Gauß'scher Mischverteilung

Anschließend wurde die auf diese Weise bestimmte Wunschgeschwindigkeit ebenfalls mit einer Gauß'schen Mischverteilung klassifiziert (Abbildung 5.23).

Wunschzeitlücke




Abbildung 5.24: Klassifikation der Wunschzeitlücke in vier Klassen mittels Gauß'scher Mischverteilung

Bei der Intention der Fahrzeugführenden in der Situation *Folgefahrt* handelt es sich um die *Wunschzeitlücke*. Es wird angenommen, dass diese erreicht ist, also

der gemessenen Zeitlücke entspricht, wenn die Beschleunigung für eine hinreichend lange Dauer den Wert null hat. Allen Messdaten seit dem Vorliegen der letzten Wunschzeitlücke wird die neu bestimmte Zeitlücke zugewiesen. Aufgrund der vielen Zustände, die die *Wunschzeitlücke* annehmen kann, wird, wie in Abbildung 5.24 zu sehen ist, wieder eine Gauß'sche Mischverteilung auf diese Größe angewendet. Damit wird die Wunschzeitlücke auf vier Zustände reduziert.

Wunschdistanz zur Haltelinie

Bei der Wunschdistanz zu einer Haltelinie handelt es sich um die Intention der Fahrerin oder des Fahrers bei der *Zufahrt auf eine Kreuzung*. Die Ermittlung der Wunschdistanz erfolgte, indem in den Messdaten ausgewertet wurde, welche Distanz zur Haltelinie vorliegt, wenn die Geschwindigkeit des eigenen Fahrzeug null beträgt.




Abbildung 5.25: Klassifikation der Wunschdistanz zur Haltelinie in fünf Klassen mittels Gauß'scher Mischverteilung

Wie in Abbildung 5.25 dargestellt, wird auch für die *Wunschdistanz zur Haltelinie* der Zustandsraum mittels Gauß'scher Mischverteilungen auf fünf Klassen reduziert.

Anfahrwunsch

Ein Anfahrwunsch wurde angenommen, wenn die Geschwindigkeit des eigenen Fahrzeugs einen Wert größer null hatte, das Fahrpedal bedient wurde oder eine entsprechende Bedienhandlung über das Bedienelement am Lenkstockhebel vorgenommen wurde.

Wunschkdauer eines Fahrstreifenwechsels

Zur Bestimmung der *Wunschkdauer eines Fahrstreifenwechsels* wurde in den Messdaten sowohl der Beginn als auch das Ende eines Fahrstreifenwechsels markiert. Ausgenommen von der Wunschkdauer wurden abgebrochene Fahrstreifenwechsel und auch die Wartezeit, bis ein Fahrstreifenwechsel begonnen wurde, beispielsweise wenn der Nachbarfahrstreifen belegt war. Anschließend wurde der Wertebereich mittels Gauß'scher Mischverteilung reduziert (Abbildung 5.26).




Abbildung 5.26: Klassifikation der Wunschkdauer eines Fahrstreifenwechsels in vier Klassen mittels Gauß'scher Mischverteilung

5.6 Validierung der Fahrerintensionsprädiktion

Für die Auswertung des entwickelten Prädiktionsverfahrens wurden die Messdatensätze der 18 Versuchspersonen mithilfe der im vorangegangenen Abschnitt

erläuterten Verfahren aufbereitet. Im nächsten Schritt dienten zwölf der Datensätze dazu, die Wahrscheinlichkeitstabellen für die Bayes'schen Netze zu lernen (s. Abschnitt 5.2). Die übrigen sechs Datensätze dienten der Validierung der Prädiktion. Die Zuteilung der Datensätze zu der jeweiligen Gruppe erfolgte per Zufallsziehung.

Eine exemplarische Anwendung des Verfahrens auf das Bayes'sche Netz der Situation *Freie Fahrt* kann Abschnitt 5.2.1 entnommen werden. Für jeden Datensatz wurden die Wahrscheinlichkeitstabellen für jeweils ein Bayes'sches Netz pro Situation berechnet. Die Wahrscheinlichkeitstabellen wurden anschließend mittels k-Means-Algorithmus in drei Gruppen klassifiziert. Für jede dieser drei Gruppen wurden die sechs Testdatensätze eingesetzt, um zu bestimmen, wie zuverlässig die Prädiktion der Fahrerintention mit dem entwickelten Verfahren möglich war. Zur Bewertung der Vorhersagegüte kommt die Prädiktionsrate

$$r_{pred} = \frac{n_m}{N} \quad (5.29)$$

zum Einsatz. Dabei steht n_m für die Anzahl an Datenpunkten, bei denen die Wunschgeschwindigkeit korrekt prädiziert wurde und N für die Gesamtanzahl an Datenpunkten in einem Datensatz. In den folgenden Abschnitten erfolgt die Ergebnisauswertung für die Situationen *Freie Fahrt* (5.6.1), *Folgefahrt* (5.6.2), *Zufahrt auf eine Kreuzung* (5.6.3), *Stillstand* (5.6.4) und *Fahrstreifenwechsel* (5.6.5).

5.6.1 Prädiktion für die Situation *Freie Fahrt*

Vor der Betrachtung und Diskussion der erreichten Prädiktionsraten soll zunächst anhand zweier Beispiele dargelegt werden, welche Besonderheiten bei der Auswertung der Prädiktion für die Situation *Freie Fahrt* vorgefunden wurden.

Abbildung 5.27 zeigt die prädizierte Wunschgeschwindigkeit v_{wunsch} im Vergleich zu der Referenz der Wunschgeschwindigkeit v_{ref} für den Datensatz und das Fahrprofil mit der höchsten Prädiktionsrate.

Es ist zu sehen, dass die beiden Geschwindigkeiten an vielen Stellen direkt übereinander liegen oder nur geringe Abweichungen aufweisen. Intervalle mit deutlichen Abweichungen treten hier in der Regel nur punktuell auf und können somit vernachlässigt werden. So wäre eine stark abweichende Geschwindigkeitsvorgabe des Systems, wie sie bspw. bei Sekunde 552 in Abbildung 5.27 zu sehen

ist, aufgrund des punktuellen Auftretens der Abweichung und der Trägheit des Fahrzeugs für die fahrzeugführende Person kaum spürbar. Zusätzlich bestünde die Möglichkeit, derartige Ausreißer bei der Berechnung herauszufiltern. Bei Einsatz der Prädiktion in einem Fahrzeugsystem würde die Geschwindigkeitsvorgabe vom Fahrzeug auch nicht mit einem Sprung umgesetzt werden, sondern würde sich aufbauen.




Abbildung 5.27: Vergleich der prädizierten Wunschgeschwindigkeit zu der Referenz der Wunschgeschwindigkeit für Testdatensatz 1, Fahrprofil C (Datensatz mit der höchsten Prädiktionsrate)

Im Vergleich dazu ist in Abbildung 5.28 die nach Zuordnung zum Fahrprofil niedrigste Prädiktionsrate dargestellt. Im letzten Drittel des Diagramms in Abbildung 5.28 sind deutliche Abweichungen der prädizierten Wunschgeschwindigkeit über einen längeren Zeitraum zu sehen. Würden diese Werte als Geschwindigkeitsvorgabe für das System verwendet werden, würde dies mit hoher Wahrscheinlichkeit von der fahrzeugführenden Person als nicht akzeptabel beurteilt werden.

Zu beachten ist jedoch, dass die Aufzeichnung der gezeigten Daten im Fahrversuch ohne eine Wiedereinspeisung ins System stattfand. Es ist davon auszugehen, dass der Fahrer oder die Fahrerin in einem solchem Fall beispielsweise mittels des Fahrpedals eingegriffen hätte, wodurch sich wiederum die prädizierte Wunschgeschwindigkeit angepasst hätte.

Gleichwohl finden sich im übrigen Verlauf klare Übereinstimmungen bzw. geringe Abweichungen, wodurch hier auf eine sehr gute Akzeptanz geschlossen werden kann.

Die Auswertung (Tabelle 5.5) ergab, dass das Fahrprofil C für die Prädiktion am

besten geeignet war, da es in fünf von sechs Fällen die höchste Prädiktionsrate aufwies.




Abbildung 5.28: Vergleich der prädizierten Wunschgeschwindigkeit zu der Referenz der Wunschgeschwindigkeit für Testdatensatz 6, Fahrprofil C (Datensatz mit der niedrigsten Prädiktionsrate nach Zuordnung zum Fahrprofil)

Für vier Personen aus den Testdaten wurden damit sogar Prädiktionsraten von über 90 Prozent erreicht. Fahrprofil B wies die höchste Prädiktionsrate für eine der sechs Versuchspersonen aus dem Testdatensatz auf. Es fällt auf, dass Fahrprofil A in keinem der Fälle die höchste Prädiktionsrate lieferte. Dieser Befund ist so einzuordnen, dass es vermutlich aufgrund des kleinen Testdatensatzes keine Person mit diesem Fahrprofil gab. Allerdings liegt die Abweichung der Prädiktionsraten von Fahrprofil A und C bei den Versuchspersonen eins und drei lediglich 0.4 bzw. 0.2 Prozent auseinander, sodass hier davon auszugehen ist, dass beide Fahrprofile von diesen Personen akzeptiert worden wären.

Zusammenfassend zeigt die Auswertung der prädizierten Wunschgeschwindigkeit ein gutes Ergebnis. Jede der sechs Personen des Testsamples wurde in mindestens einem Fahrprofil mit einer Rate von mindestens 0.786 prädiziert. Daraus kann geschlossen werden, dass das Bayes'sche Netz für die Wunschgeschwindigkeitsprädiktion (Abschnitt 5.2.1) gut geeignet zu sein scheint.

Versuchsperson	Situation <i>Freie Fahrt</i>		
	Fahrprofil A	Fahrprofil B	Fahrprofil C
	r_{pred}	r_{pred}	r_{pred}
VP1	0,927	0,887	0,931*
VP2	0,839	0,895	0,926*
VP3	0,903	0,858	0,905*
VP4	0,611	0,694	0,786*
VP5	0,871	0,921*	0,905
VP6	0,517	0,577	0,851*
Mittelwert (SD)	0,787 (0,131)	0,805 (0,117)	0,851* (0,094)

Tabelle 5.5: Übersicht der Prädiktionsraten r_{pred} für die Situation *Freie Fahrt* über alle sechs Testdatensätze und Fahrprofile (*markiert das Fahrprofil mit der höchsten Prädiktionsrate)

5.6.2 Prädiktion für die Situation *Folgefahrt*

Auch für die Situation *Folgefahrt* sollen zunächst einige Besonderheiten der Prädiktion anhand zweier Beispiele (Datensätze mit der höchsten und niedrigsten Prädiktionsrate) erläutert werden.




Abbildung 5.29: Vergleich der prädizierten Wunschzeitlücke zu der Referenz der Wunschzeitlücke für Testdatensatz 3, Fahrprofil B (Datensatz mit der höchsten Prädiktionsrate)

Für die Situation *Folgefahrt* wird die Wunschzeitlücke prädiziert. Abbildung 5.29

zeigt das Fahrprofil C des Testdatensatzes 3. Es handelt sich dabei um die Kombination aus Testdatensatz und Fahrprofil mit der höchsten Prädiktionsrate.

In vielen Abschnitten der Messung, wie beispielsweise zwischen Sekunde 43 und 96, liegen Prädiktion und Referenz unmittelbar übereinander. Im Intervall von [96s, 118s] hingegen sind häufige Abweichungen zwischen den beiden Graphen der Referenz und der Prädiktion zu erkennen. Hier wechselt die Prädiktion verhältnismäßig häufig den Zustand, wobei die Zeiträume der Abweichungen sich überwiegend im Bereich von einer Sekunde (oder weniger) bewegen. Die überwiegend kleinen Intervalle der Abweichung zeigen, dass die Daten eine Prädiktion sehr nahe der Zustandsgrenzen ergeben. Um einem solchen Alternieren zu begegnen kommen häufig Hysteresen zum Einsatz. Das Ziel der vorliegenden Arbeit war es, die Prädiktion mit Rohdaten durchzuführen. Es wurde daher darauf verzichtet, entsprechende Glättungsmaßnahmen anzuwenden, um deren Einfluss auf das Prädiktionsergebnis auszuschließen.




Abbildung 5.30: Vergleich der prädizierten Wunschzeitlücke zu der Referenz der Wunschzeitlücke für Testdatensatz 1, Fahrprofil B (Testdatensatz mit der niedrigsten Prädiktionsrate nach Zuordnung zum Fahrprofil)

Ein weiteres interessantes Beispiel stellt der Testdatensatz 1 im Fahrprofil B dar (Abbildung 5.30). Es handelt sich dabei um den Testdatensatz mit der niedrigsten Prädiktionsrate nach Zuordnung zum kompatibelsten Fahrprofil. So zeigen sich einerseits viele Intervalle mit eindeutiger Übereinstimmung von Prädiktion zu Referenz und andererseits Abweichungen, deren Intervall nicht vernachlässigbar ist, da sich dadurch größere oder kleinere Abstände zum Vorderfahrzeug ergeben, als durch die Fahrerin oder den Fahrer angestrebt wurden. Eine Über-

steuerung oder Deaktivierung des Systems durch die fahrzeugführende Person wäre die zu erwartende Konsequenz.

Der Grund für die in Abbildung 5.30 dargestellten Abweichungen ist hinter dem Bedienkonzept zur Einstellung der Wunschzeitlücke zu vermuten. Sieben der achtzehn Versuchspersonen gaben während des Fahrversuchs an, dass sie die Bedienung der Zeitlückeneinstellung als nicht intuitiv oder als unverständlich empfanden. Des Weiteren wurde von den Versuchspersonen angemerkt, dass eine permanente Zeitlückeneinstellung, gegenüber der implementierten temporären, wünschenswert gewesen wäre.

Versuchsperson	Situation <i>Folgefahrt</i>		
	Fahrprofil A	Fahrprofil B	Fahrprofil C
	r_{pred}	r_{pred}	r_{pred}
VP1	0,505*	0,503	0,496
VP2	0,733	0,770*	0,289
VP3	0,696	0,781*	0,550
VP4	0,672	0,734*	0,407
VP5	0,455	0,615	0,668*
VP6	0,622*	0,542	0,311
Mittelwert (SD)	0,614 (0,101)	0,657* (0,110)	0,453 (0,133)

Tabelle 5.6: Übersicht der Prädiktionsraten r_{pred} für die Situation *Folgefahrt* über alle sechs Testdatensätze und Fahrprofile (*markiert das Fahrprofil mit der höchsten Prädiktionsrate)

Insgesamt zeigt die Auswertung (Tabelle 5.6), dass das Fahrprofil B für die Hälfte der Testpersonen die höchste Prädiktionsrate im Bereich von 73 bis 78 Prozent erreichte. Fahrprofil A wurde zwei Testpersonen zugeordnet und Fahrprofil C einer Versuchsperson (VP5). Bei näherer Betrachtung der Werte von Versuchsperson VP1 ist zu erkennen, dass der Unterschied zwischen Fahrprofil A und B nur 0,2 Prozent beträgt und somit eine Zuordnung zu dem einen oder anderen Profil legitim gewesen wäre.

Zusammenfassend lässt sich festhalten, dass die Auslegung der Bedienung für die Zeitlückeneinstellung nicht optimal an die Bedürfnisse der Testpersonen ausgelegt war. In der Praxis kann dies zur geringeren Akzeptanz der Benutzenden führen und es erschwert die Berechnung einer zuverlässigen Prädiktion.

5.6.3 Prädiktion für die Situation *Zufahrt auf eine Kreuzung*

Für die Situation *Zufahrt auf eine Kreuzung* soll die Anhaltedistanz bis zur Haltelinie prädiziert werden. In der durchgeführten Fahrstudie ergaben sich insgesamt nur wenige Situationen pro Versuchsperson, in denen an einer roten Lichtsignalanlage angehalten werden musste. In der Stichprobe fanden sich im Durchschnitt zwei Zufahrten pro Person. In einem Fall kam es während der Versuchsfahrt zu keinem Anhalten an einer roten Ampel. Somit ergaben sich für diese Situation insgesamt deutlich weniger verwertbare Datensätze. Die folgende Interpretation bezieht sich demnach vor allem auf die in der Stichprobe vorgefundenen Tendenzen und dient vielmehr als Anhaltspunkt für zukünftige Forschungsarbeiten als zur Validierung der Prädiktion.




Abbildung 5.31: Vergleich der prädizierten Wunschanhaltedistanz zur Kreuzung zu der Referenz der Anhaltedistanz für Testdatensatz 3, Fahrprofil A oder B

Die in Abbildung 5.31 dargestellten Daten von Versuchsperson VP3 (höchste Prädiktionsrate in der Stichprobe) zeigen eine hundertprozentige Vorhersage für die Distanz zur Haltelinie während des Anhaltevorgangs. Die Prädiktionsrate wurde dabei sowohl für Profil A als auch Profil B erreicht (Tabelle 5.7). Für diese Versuchsperson lag exakt eine Zufahrt samt Haltemanöver an einer roten Lichtsignalanlage vor, für welches die Wunschkdistance korrekt prädiziert wurde.

Für die Versuchsperson VP6 wurde eine Prädiktionsrate von 0,538 erreicht. Diese ergab sich aus der Auswertung von zwei Kreuzungszufahrten. Die erste Zufahrt wurde nicht korrekt prädiziert, wie in Abbildung 5.32 im Intervall von [0s, 15s]

zu sehen ist. Bei der zweiten Zufahrt hingegen war die Vorhersage erfolgreich. Für diese Auswertung ist davon auszugehen, dass nicht ausreichend Lerndaten vorhanden waren, die zu einer besseren Prädiktion der ersten Haltedistanz in diesem Datensatz geführt hätten (s. Abbildung 5.31).




Abbildung 5.32: Vergleich der prädizierten Wunschanhaldedistanz zur Kreuzung zu der Referenz der Anhaldedistanz für Testdatensatz 6, Fahrprofil A oder B

Die Auswertung über alle Versuchspersonen (Tabelle 5.7) ergab, dass die Fahrprofile A und B jeweils eine identische Prädiktionsrate erreichten, obgleich die zugrunde liegenden Wahrscheinlichkeitstabellen des Bayes'schen Netzes sich voneinander unterscheiden.

Dieser Sachverhalt lässt sich auf die geringe Anzahl an Lern- und Testdaten zurückführen. Vielversprechend an dieser Stelle ist, dass für die Hälfte der Versuchspersonen eine tendenziell sehr hohe (in der vorliegenden Stichprobe 100 Prozent) Vorhersagegüte erreicht werden konnte. Dies ist nicht überraschend, da in diesem Fall, wie bereits anfangs angeführt, zu wenige Trainingsdaten zur Verfügung standen, um eine ausreichende Varianz im Training abzudecken. Die niedrigeren Prädiktionsraten in der zweiten Hälfte der Stichprobe lagen zwischen 44 und 58 Prozent. Es konnte keine augenscheinliche Auffälligkeit in den ausgewerteten Datensätzen entdeckt werden, die zu tendenziell höheren oder niedrigeren Prädiktionsraten führte.

Zusammenfassend zeigt sich ein positiver Trend bezüglich der Vorhersagemöglichkeit einer Wunschanhaldedistanz an einer Kreuzung. Es ist zudem zu erwarten, dass mit einer größeren Menge an Lern- und Testdaten gute und zuverlässige

gere Prädiktionsraten erreicht werden können.

Versuchsperson	Situation <i>Zufahrt auf eine Kreuzung</i>		
	Fahrprofil A	Fahrprofil B	Fahrprofil C
	r_{pred}	r_{pred}	r_{pred}
VP1	1,000*	1,000*	0,000
VP2	0,419	0,419	0,581*
VP3	1,000*	1,000*	0,000
VP4	0,381	0,381	0,439*
VP5	1,000*	1,000*	0,000
VP6	0,538*	0,538*	0,000
Mittelwert (SD)	0,723* (0,281)	0,723* (0,281)	0,170 (0,244)

Tabelle 5.7: Übersicht der Prädiktionsraten r_{pred} für die Situation *Zufahrt auf eine Kreuzung* über alle sechs Testdatensätze und Fahrprofile (*markiert das Fahrprofil mit der höchsten Prädiktionsrate)

5.6.4 Prädiktion für die Situation *Stillstand*

In der Situation *Stillstand* war das Ziel der Prädiktion, den Anfahrwunsch vorherzusagen. Beim Anfahrwunsch handelt es sich um eine binäre Variable, d.h. es liegt ein Anfahrwunsch vor oder nicht.

Die Auswertung zeigt, dass ein Anfahrwunsch über alle Versuchspersonen sehr gut prädiziert wurde, sofern Testdaten vorlagen (Tabelle 5.8). Für Versuchsperson VP3 existierte kein Testdatensatz, da diese Person immer manuell, d.h. ohne Systemunterstützung, angefahren ist. Dieser Datensatz musste daher von der Auswertung ausgeschlossen werden.

Eine der niedrigsten Prädiktionsraten mit dem Wert 0,997 hat sich u.a. für die Versuchsperson VP1 mit dem Fahrprofil C ergeben. Die Prädiktionsrate entstand dadurch, dass bei Sekunde 14,5 ein Anfahrwunsch detektiert wurde, welcher sich in der Referenz nicht findet, wie in Abbildung 5.33 zu erkennen ist. Die Messdatenanalyse ergab, dass zu diesem Zeitpunkt eine Bedienhandlung über das Bedienelement kommuniziert wurde, ein Anfahren aufgrund der Verkehrssituation allerdings nicht stattfinden konnte.

5.6 Validierung der Fahrerintensionsprädiktion




Abbildung 5.33: Vergleich des prädizierten Anfahrwunsches zu der Referenz des Anfahrwunsches für Testdatensatz 1, Fahrprofil C

Versuchsperson	Situation <i>Stillstand</i>		
	Fahrprofil A	Fahrprofil B	Fahrprofil C
	r_{pred}	r_{pred}	r_{pred}
VP1	0,999*	0,999*	0,997
VP2	1,000*	1,000*	0,997
VP3	-	-	-
VP4	1,000*	1,000*	0,987
VP5	0,999*	0,999*	0,993
VP6	1,000*	1,000*	0,998
Mittelwert (SD)	1,000* (0,000)	1,000* (0,000)	0,994 (0,004)

Tabelle 5.8: Übersicht der Prädiktionsraten r_{pred} für die Situation *Stillstand* über alle sechs Testdatensätze und Fahrprofile (*markiert das Fahrprofil mit der höchsten Prädiktionsrate)

Zusammenfassend zeigt sich, dass ein Anfahrwunsch sehr gut prädiziert werden kann. Es ist an dieser Stelle zu erwähnen, dass aufgrund der relativ simplen Situation auch eine regelbasierte Prädiktion (unter Einbeziehung des Vorderfahrzeugs und des Fahrpedals in Kombination mit dem Bedienelement für den Anfahrwunsch) zu einer guten Prädiktionsrate geführt hätte. Für Letzteres spricht, dass kein Bayes'sches Netz mit aufwendig einzufahrenden Messdaten trainiert werden muss.

5.6.5 Prädiktion für die Situation *Fahrstreifenwechsel*

In der Situation *Fahrstreifenwechsel* sollte die präferierte Dauer eines Fahrstreifenwechsels prädiziert werden.

Grundsätzlich ließ sich die gewünschte Fahrstreifenwechselfdauer gut vorhersagen. Für die Versuchsperson VP2 gab es beispielsweise für fünf von sechs Fahrstreifenwechseln eine korrekte Prädiktion. Aus Abbildung 5.34 geht hervor, dass nur einmal eine zu kurze Dauer vorhergesagt wurde, als nach Auswertung präferiert gewesen wäre. Darüber hinaus lässt sich erkennen, dass für die Versuchsperson VP2 eine Fahrstreifenwechselfdauer von etwa sieben Sekunden in der Regel eine gute Prädiktion lieferte.

Die Auswertung (Tabelle 5.9) ergab insgesamt gute Prädiktionsraten zwischen circa 64 und 94 Prozent für die Fahrstreifenwechselfdauer.

Auffällig ist, dass sich für jede Versuchsperson jeweils die gleiche Prädiktionsrate über alle Fahrprofile ergeben hat. Zum einen ist zu vermuten, dass die Fahrstreifenwechselfdauer auf vier Klassen reduziert wurde und sich die präferierte Zeitdauer tatsächlich in der Regel um sieben Sekunden bewegt. Zum anderen kann auch an dieser Stelle davon ausgegangen werden, dass sich durch eine größere Menge an Lern- sowie Testdaten differenzierte Ergebnisse ergeben hätten.




Abbildung 5.34: Vergleich der prädizierten Fahrstreifenwechselfdauer zu der Referenz der gewünschten Fahrstreifenwechselfdauer für Testdatensatz 2, Fahrprofil A

Insgesamt zeigen die Ergebnisse ein hohes Potenzial der Prädiktion von Fahrstreifenwechselfdauern mittels Bayes'scher Netze.

Versuchsperson	Situation <i>Fahrstreifenwechsel</i>		
	Fahrprofil A	Fahrprofil B	Fahrprofil C
	r_{pred}	r_{pred}	r_{pred}
VP1	0,778*	0,778*	0,778*
VP2	0,897*	0,897*	0,897*
VP3	0,733*	0,733*	0,733*
VP4	0,638*	0,638*	0,638*
VP5	0,790*	0,790*	0,790*
VP6	0,938*	0,938*	0,938*
Mittelwert (SD)	0,796* (0,100)	0,796* (0,100)	0,796* (0,100)

Tabelle 5.9: Übersicht der Prädiktionsraten r_{pred} für die Situation *Fahrstreifenwechsel* über alle sechs Testdatensätze und Fahrprofile (*markiert das Fahrprofil mit der höchsten Prädiktionsrate)

5.6.6 Übersicht über die Fahrprofile

Wie bereits in den Abschnitten zur Situationen *Zufahrt auf eine Kreuzung*, *Stillstand* und *Fahrstreifenwechsel* (FSW) dargelegt wurde, ergaben sich aus dem Fahrversuch zu diesen Situationen zu wenige verwertbare Trainingsdatensätze. Aus diesem Grund werden die Ergebnisse im Folgenden lediglich in Bezug auf in der Stichprobe vorgefundene Tendenzen diskutiert.

Die Gesamtbetrachtung zeigt, dass innerhalb der Situationen (*Freie Fahrt*, *Folgefahrt*), die über eine solide Grundmenge an Lerndaten prädiziert wurden, jeweils mindestens ein dominantes Fahrprofil hervorgetreten ist (s. Tabelle 5.10). Weiterhin zeigt der Vergleich zwischen diesen Situationen, dass einige Versuchspersonen, und zwar die gleichen, im jeweils dominanten Fahrprofil am besten abgebildet wurden (z.B. wenn *Freie Fahrt*: C dann *Folgefahrt*: B). Die Bestätigung in einer größeren Stichprobe vorausgesetzt, könnten solche Profilpaare einem übergeordneten Fahrprofil zugeordnet werden.

Die übrigen Situationen (*Kreuzung*, *Stillstand*, *Fahrstreifenwechsel*), die mit zu wenigen Datensätzen trainiert wurden, zeigen kein eindeutiges Bild bezüglich dominanter Profile und müssten deshalb wie eingangs erwähnt anhand einer größeren Stichprobe validiert werden, um zu belastbaren Ergebnissen zu kommen.

Versuchsperson	Situation				
	<i>Freie Fahrt</i>	<i>Folgefahrt</i>	<i>Kreuzung</i>	<i>Stillstand</i>	<i>FSW</i>
	Fahrprofil	Fahrprofil	Fahrprofil	Fahrprofil	Fahrprofil
VP1	C	A	A/B	A/B	A/B/C
VP2	C	B	C	A/B	A/B/C
VP3	C	B	A/B	-	A/B/C
VP4	C	B	C	A/B	A/B/C
VP5	B	C	A/B	A/B	A/B/C
VP6	C	A	A/B	A/B	A/B/C

Tabelle 5.10: Übersicht der Zuordnung der Fahrprofile mit der höchsten Prädiktionrate über alle Versuchspersonen und Situationen

5.7 Diskussion

In den vorangegangenen Abschnitten des Kapitels wurde gemäß der zu Beginn aufgestellten Forschungsfrage (F2) eine Methode entwickelt, die es ermöglicht, ein System zur kontinuierlichen Längs- und Querführung im urbanen Straßenverkehr für den individuellen Unterstützungsbedarf verschiedener Personen mittels Fahrerintensionsprädiktion auszulegen. Hierzu wurden aus einem Teil der Daten aus der durchgeführten Realfahrstudie (Abschnitt 5.4) maschinell Fahrerprofile gelernt und anschließend mit einem weiteren Teil der Daten validiert.

Die Validierung ergab für die Situation *Freie Fahrt*, dass mit dem entworfenen Bayes'schen Netz eine sehr gute Prädiktion der Wunschgeschwindigkeit erreicht wird, da für vier von sechs Versuchspersonen Prädiktionsraten von über 90 Prozent erreicht wurden. Hierbei ist zu erwarten, dass eine größere Lerndatenmenge die Qualität der Prädiktion weiter verbessern kann und dass die ohnehin seltenen stärkeren Abweichungen sich reduzieren. In der Situation *Folgefahrt* merkten die Versuchspersonen an, dass sie eine permanente Verstellung der Zeitlücke gegenüber der implementierten temporären präferiert hätten und die Bedienlogik für diese Situation hinsichtlich Intuitivität überarbeitet werden sollte. Diese beiden Kritikpunkte scheinen sich auch in den häufigen Zustandswechseln der Prädiktion widerzuspiegeln. Es konnte zwar überwiegend die Wunschzeitlücke korrekt prädiziert werden (Prädiktionsraten zwischen 50,5 und 78,1 Prozent), dennoch ist eine Änderung im Bedienkonzept zu empfehlen, da ansonsten aufgrund der beschrie-

benen Schwierigkeiten von geringer Akzeptanz im Praxiseinsatz auszugehen ist. Eine zuverlässige Validierung der Prädiktion der gewünschten Anhaltedistanz in der Situation *Zufahrt auf eine Kreuzung* war aufgrund des geringen Auftretens im Fahrversuch nicht möglich. Die teilweise sehr hohen Prädiktionsraten in der Stichprobe deuten auf ein großes Potenzial. Eine Validierung mittels einer größeren Datenmenge wäre wünschenswert. Eine weitere Realfahrstudie, um diese Daten zu erheben, konnte im Rahmen dieser Arbeit jedoch aus forschungsökonomischen Gründen nicht durchgeführt werden. Die Validierung bleibt zukünftigen Forschungsarbeiten überlassen. In der Situation *Stillstand* konnte der Anfahrwunsch mit Prädiktionsraten über 0,99 sehr gut prädiziert werden und erweist sich damit als zuverlässig sowie praxistauglich. Ähnlich gute Ergebnisse sind aufgrund der geringen Komplexität der Situation auch mit anderen, z.B. regelbasierten Ansätzen zu erwarten. Der Aufwand der Datenerhebung für diese Situation ist demnach nur dann gerechtfertigt, wenn im gleichen Zuge auch Daten für ein umfassenderes System erhoben werden. Eine positive Tendenz zeigten ebenfalls die Vorhersagen der gewünschten Dauer eines Fahrstreifenwechsels mit Prädiktionsraten von circa 64–94 Prozent. Auch hier ist zu erwarten, dass bei einer größeren Datengrundlage gute und differenzierte Ergebnisse erzielbar wären. Es zeigt sich insgesamt, dass der gewählte Ansatz zum Einsatz von Bayes'schen Netzen zur Prädiktion von Fahrerintentionen im urbanen Umfeld großes Potenzial bietet, um damit Fahrerassistenzsysteme an die individuellen Präferenzen verschiedener Personen anzupassen und dadurch deren Einsatz und deren Akzeptanz weiter zu erhöhen.

Wie bereits bei der Situationsklassifikation und Manöverinterpretation in Kapitel 4 liegt auch hierbei der Fokus auf der kontinuierlichen Längs- und Querführungsunterstützung im urbanen Umfeld. Hier positioniert sich die Arbeit zum Beispiel neben der von Heine (2018), die die Prädiktion von Fahrstreifenwechseln zur Adaption von Fahrerwarnungen einsetzt. Methodisch differenziert sich die Arbeit durch die Verwendung von Bayes'schen Netzen anstatt Fuzzy-Systemen und bietet dadurch ein erweiterbares sowie leicht anpassbares Modell. Bayes'sche Netze fanden auch in anderen Arbeiten Anwendung, bei welchen die Prädiktion von Fahrerintentionen betrachtet wurde. Während Kasper u. a. (2011) noch aufwendig von Hand parametrisiert haben, wurden bei Weiser (2018) die Wahrscheinlichkeitstabellen wie im vorliegenden Ansatz über Daten aus einer Realfahrstudie gelernt. Im Unterschied zu Weiser (2018), welcher zusätzlich zu den A-priori-Wahrscheinlichkeiten auch die Struktur des Bayes'schen Netzes maschinell aus

den Daten bestimmte, wurde in dieser Arbeit die Struktur der Bayes'schen Netze mittels Expertenwissen durch die Analyse der einzelnen Verkehrssituationen entworfen. So konnten die kausalen Zusammenhänge bzw. Unabhängigkeiten direkt modelliert und eine interpretierbare und transparente Struktur erreicht werden. Somit grenzt sich die vorliegende Arbeit zu diesen beiden Vertretern über den Anwendungsfall als auch insbesondere über die Verfahren zur Auswertung der Bayes'schen Netze ab. Im aktuellen Stand der Technik existiert nach Kenntnisstand der Autorin keine andere Arbeit, bei der eine Fahrerintensionsprädiktion durch die Auswertung von situationsspezifischen Bayes'schen Netzen mittels Big-Clique-Algorithmus vorgenommen wird. Eine ganzheitliche Erschließung des adressierten Anwendungsbereichs konnte durch die situationsspezifischen Bayes'schen Netze erreicht werden. Mittels der Verwendung von *weicher Evidenz* wurden Unschärfen und Uneindeutigkeiten abgebildet, wie sie in der Realität zu finden sind. Damit leistet die vorliegende Arbeit einen Beitrag dazu, den Anwendungsbereich von Fahrerassistenzsystemen zu erweitern und zeigt die Eignung von Bayes'schen Netzen zur Fahrerintensionsprädiktion in verschiedenen Situationen.

Aufgrund der sehr guten Prädiktionsraten der Fahrerintention in der Situation *freien Fahrt* wäre es unabhängig von dem hier entwickelten System vorstellbar, eine solche Prädiktion für die Vorhersage der Geschwindigkeitsvorgabe beispielsweise in einem Längsführungssystem wie ACC einzusetzen.

Die grundsätzlich guten Prädiktionsraten legen es nahe, das System mit deutlich mehr Fahrdaten anzulernen und zu validieren, um differenzierte und aussagekräftigere Parameter zu bestimmen, die eine zuverlässige Fahrerintensionsprädiktion ermöglichen. Dazu könnten beispielsweise Flottenfahrzeuge, die sich überwiegend im Stadtverkehr bewegen (Taxis, Handwerker, Lieferanten etc.) über einen längeren Zeitraum Daten einfahren, die zunächst aufgezeichnet und anschließend zum Lernen und Validieren verwendet werden. Letzteres hätte gegenüber einem Einzelversuch den weiteren Vorteil, dass sich die Fahrerinnen und Fahrer noch weiter an die Systemauslegung gewöhnen könnten und ein routinierterer Umgang zu reichhaltigeren und allgemeingültigen Messdaten führen würde. Eine weitere spannende Weiterentwicklung wäre es, ein konsolidiertes Bayes'sches Netz über alle zu Beginn identifizierten Situationen zu entwerfen und zu untersuchen, ob vergleichbare Prädiktionsraten erreicht werden können.

Kapitel 6

Zusammenfassung der Arbeit und Ausblick

Fahrerassistenzsysteme leisten einen sinnvollen und deutlichen Beitrag zur persönlichen Mobilität der Menschen, indem sie Komfort und Sicherheit steigern. Aktuelle Längs- und Querführungssysteme adressieren jedoch vornehmlich die Anwendung auf Autobahnen und gut ausgebauten Landstraßen. Dabei bietet insbesondere der urbane Straßenverkehr mit für den Fahrer teils sehr komplexen Situationen ein großes Unterstützungspotenzial.

Daraus abgeleitet wurde das Ziel der Arbeit in den folgenden zwei Forschungsfragen formuliert:

- F1: Wie können fahrzeugführende Personen auf dem Weg in die Stadt hinein kontinuierlich in Längs- und Querführung unterstützt werden?
- F2: Wie kann ein System zur kontinuierlichen Längs- und Querführung im urbanen Straßenverkehr für den individuellen Unterstützungsbedarf verschiedener Personen ausgelegt werden?

Aufbauend auf den Forschungsfragen wurde zunächst in Kapitel 4 ein Konzept im Sinne der kooperativen Fahrzeugführung entworfen, um den erhöhten Anforderungen an eine Unterstützung in Längs- und Querführung im urbanen Straßenverkehr zu begegnen. Um dieses System den Bedürfnissen verschiedener Personen zugänglich zu machen, wurde in Kapitel 5 ein Verfahren entwickelt, das es ermöglicht, aus Messdaten maschinell Fahrerprofile zu lernen.

Zur Beantwortung der ersten Forschungsfrage (F1) wurde ein Konzept entwickelt,

bei welchem sich die fahrzeugführende Person und das System in Wahrnehmung, Interpretation und Fahrzeugführung bestmöglich ergänzen sollen. Hierzu war es zunächst erforderlich zu verstehen, wie eine Person im urbanen Umfeld unterstützt werden kann. Dafür wurde das urbane Umfeld theoretisch betrachtet und jene Situationen mit dem größten Unterstützungspotential aus der Sicht eines Assistenzsystems herausgearbeitet. Identifiziert wurden die Situationen *Freie Fahrt*, *Folgefahrt*, *Zufahrt auf eine Kreuzung*, *Stillstand* und *Fahrstreifenwechsel*. Für diese wurde jeweils abgeleitet, welche sinnvollen Manöveroptionen zur Verfügung stehen und eine Möglichkeit konzipiert, diese über eine Mensch-Maschine-Schnittstelle zugänglich zu machen. Beispielweise kann in der Situation *Freie Fahrt* eine Anpassung der Geschwindigkeitsvorgabe gewünscht sein oder ein Fahrstreifenwechsel anvisiert werden. Zur Validierung wurde das System prototypisch in einem Versuchsfahrzeug aufgebaut, indem die Systemlogik in ADTF umgesetzt wurde. Die Möglichkeit der Benutzereingaben wurde über ein Bedienelement am Lenkrad realisiert. Die Ausgaben des Systems wurden über das zentrale Display im Kombiinstrument angezeigt.

Mittels des Versuchsfahrzeugs wurde in Expertenfahrten überprüft, ob das vorliegende, auf kooperativer Fahrzeugführung basierende Konzept für die erhöhten Anforderungen des urbanen Straßenverkehrs geeignet ist. Die hierzu durchgeführten Fahrten im Straßenverkehr der Stadt Wolfsburg konnten die grundsätzliche Eignung des Konzepts bestätigen.

Anschließend wurde gemäß der zweiten Forschungsfrage (F2) eine Methode entwickelt, um dieses System besser an die individuellen Präferenzen verschiedener Personen anpassen zu können. Hierzu wurde ein Ansatz entwickelt, um Fahrerprofile aus Fahrdaten, in der vorliegenden Arbeit aus Messdaten der Realfahrstudie, zu lernen. Dafür war zunächst eine detaillierte Betrachtung potentiell geeigneter Methoden wie Fuzzy-Mengen und -Logik, künstlich neuronale Netze sowie Bayes'sche Netze erforderlich. Aufgrund der für den praktischen Einsatz relevanten Transparenz der inneren Logik sowie der Möglichkeit zu flexiblen Anpassungen wurden Bayes'sche Netze für besonders geeignet befunden und ausgewählt. Zur Konstruktion der situationsspezifischen Bayes'schen Netze wurden die relevanten Verkehrssituationen analysiert und anschließend mit den identifizierten kausalen Zusammenhängen die Struktur des jeweiligen Netzes entworfen. Das Lernen der Wahrscheinlichkeitstabellen erfolgte mit 12 von 18 Datensätzen der für die Konzeptprüfung zuvor durchgeführten Realfahrstudie. Die Auswertung der einzelnen Bayes'schen Netze erfolgte unter Verwendung des Big-

Clique-Algorithmus, sodass auch Unschärfen und Uneindeutigkeiten mittels *weicher Evidenz* abgebildet werden konnten.

Zur Validierung wurden weitere sechs Datensätze der Fahrstudie verwendet. Dabei konnte die grundsätzliche Eignung durch gute Prädiktionsraten nachgewiesen werden, obgleich für die Überprüfung der positiven Tendenzen der Situationen *Zufahrt auf eine Kreuzung* und *Fahrstreifenwechsel* mehr Daten benötigt werden.

Die vorliegende Arbeit unterscheidet sich besonders in zwei Punkten von anderen in der Literatur vorzufindenden Ansätzen. Zum einen steht eine universelle Betrachtung des urbanen Straßenverkehrs im Fokus und nicht die eines spezifischen Anwendungsfalls, um darauf aufbauend ein ganzheitliches Konzept zur Unterstützung zu entwerfen. Zum anderen wird in der Arbeit *weiche Evidenz* im Bayes'schen Netz zur Modellierung von Messungenauigkeiten eingesetzt und mittels des Big-Clique-Algorithmus auch in der Auswertung betrachtet anstatt die Unschärfen in den Daten zu vernachlässigen und diese in feste Grenzen zu diskretisieren.

Durch die zweistufige Betrachtung der übergeordneten Problemstellung war es im Rahmen dieser Arbeit möglich, sowohl einen Erkenntnisbeitrag dazu zu leisten, wie eine kombinierte Unterstützung in Längs- und Querführung durch die gezielte Ergänzung der Fähigkeiten von Mensch und System gestaltet werden kann, als auch dazu, wie ein solches System durch das maschinelle Lernen und Klassifizieren von Fahrerprofilen auf individuelle Fahrerpräferenzen ausgelegt werden kann. Letzteres wird vor allem als Faktor für eine hohe Akzeptanz des Gesamtsystems erachtet.

Auf folgende Forschungsarbeiten blickend bleibt die spannende Frage, ob die gezeigten Prädiktionsraten sich in einem großen Feldversuch beispielsweise mittels einer Fahrzeugflotte bestätigen ließen. Weiterhin zeigt der aktuelle Stand der Technik eine Lücke hinsichtlich empirischer Vergleiche geeigneter Bedienelemente für ähnliche Anwendungen. Auch bleibt die Weiterentwicklung des Systems hinsichtlich der Ausweitung auf alle relevanten Domänen des Straßenverkehrs wie Autobahnen, Parkhäuser etc. zu betrachten, mit dem Ziel, eine integrierte Unterstützung in Längs- und Querführung über die gesamte Fahrtroute zu erreichen.

Anhang A

Grundlagen zum Rechnen mit Wahrscheinlichkeiten

A.1 Grundbegriffe

Mengendarstellung	Beschreibung
$A \cap B$ ¹	Schnittmenge / und
$A \cup B$	Vereinigung / oder
\bar{A}	Komplement
Ω	Sicheres Ereignis
\emptyset	Unmögliches Ereignis

Tabelle A.1: Darstellung Grundbegriffe

Daraus ergeben sich folgende Zusammenhänge für die Wahrscheinlichkeit P :

$$P(\Omega) = 1 \quad (\text{A.1})$$

$$P(\emptyset) = 0 \quad (\text{A.2})$$

$$P(A) = 1 - P(\bar{A}) \quad (\text{A.3})$$

¹ A, B : Ereignisse, Zufallsvariablen

A.2 Definitionen und Regeln

Im Folgenden werden wichtige Definitionen und Regeln zum Rechnen mit Wahrscheinlichkeiten dargestellt.

Bedingte Wahrscheinlichkeit

Für die Ereignisse A, B ist die Wahrscheinlichkeit von A unter der Bedingung von B definiert durch

$$P(A|B) = \frac{P(A \cap B)}{P(B)}. \quad (\text{A.4})$$

Unabhängigkeit

Die Ereignisse A, B sind unabhängig, wenn

$$P(A|B) = P(A). \quad (\text{A.5})$$

Damit ergibt sich für unabhängige Ereignisse

$$P(A \cap B) = P(A)P(B). \quad (\text{A.6})$$

Bedingte Unabhängigkeit

Die Ereignisse A, B sind bedingt unabhängig gegeben C , wenn

$$P(A, B|C) = P(A|C)P(B|C) \quad (\text{A.7})$$

Produkt-/Kettenregel

$$P(A \cap B) = P(A|B)P(B) = P(B|A)P(A) \quad (\text{A.8})$$

Allgemein:

$$\begin{aligned} P(X_1, \dots, X_n) &= P(X_n | X_1, \dots, X_{n-1}) P(X_1, \dots, X_{n-1}) \\ &= \dots \\ &= P(X_n | X_1, \dots, X_{n-1}) \cdot \dots \cdot P(X_2 | X_1) P(X_1) \\ P(X_1, \dots, X_n) &= \prod_{i=1}^n P(X_i | X_1, \dots, X_{i-1}) \end{aligned} \quad (\text{A.9})$$

Marginalisierung

Da $A \Leftrightarrow (A \cap B) \cup (A \cap \bar{B})$, kann über die Summation der beiden Werte von B die Variable B eliminiert werden:

$$P(A) = P((A \cap B) \cup (A \cap \bar{B})) = P(A \cap B) + P(A \cap \bar{B}). \quad (\text{A.10})$$

Allgemein:

$$P(X_1 = x_1, \dots, X_{d-1} = x_{d-1}) = \sum_{x_d} P(X_1 = x_1, \dots, X_{d-1} = x_{d-1}, X_d = x_d) \quad (\text{A.11})$$

Der linke Teil der Gleichungen A.10 und A.11 wird auch als Randverteilung bezeichnet, da in diesem die Dimension im Verhältnis zur rechten Seite der Gleichung um eins reduziert ist.

Bayes-Formel

Unter Verwendung der Formeln für bedingte Wahrscheinlichkeit A.4 für A und B

$$\begin{aligned} P(A|B) &= \frac{P(A \cap B)}{P(B)} \\ P(B|A) &= \frac{P(A \cap B)}{P(A)} \end{aligned}$$

ergibt sich durch Umformen und Gleichsetzen der Formeln die Bayes-Formel

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}. \quad (\text{A.12})$$

Anhang B

Inferenz in Bayes'schen Netzen

B.1 Herleitung von Gleichung 3.7 zur diagnostischen Inferenz

Unter Anwendung der Definitionen aus Appendix A.2 kann die Berechnung von $P(x_i|N_1, N_2, \dots, N_m)$ bezogen auf Bayes'sche Netz aus Abbildung 3.5 hergeleitet werden:

$$\begin{aligned}P(X = x_i|N_1, N_2, \dots, N_m) &= \frac{P(x_i) \cdot P(N_1, N_2, \dots, N_m|x_i)}{P(N_1, N_2, \dots, N_m)} \\P(N_1, N_2, \dots, N_m|x_i) &= P(N_1|x_i) \cdot P(N_2|x_i) \cdot \dots \cdot P(N_m|x_i) \\&= \prod_{j=1}^m P(N_j|x_i) \\P(N_1, N_2, \dots, N_m) &= \sum_{l=1}^r P(N_1, N_2, \dots, N_m, x_l) \\&= \sum_{l=1}^r P(N_1, N_2, \dots, N_m|x_l) \cdot P(x_l) \\&= \sum_{l=1}^r P(x_l) \cdot \prod_{j=1}^m P(N_j|x_l) \\P(X = x_i|N_1, N_2, \dots, N_m) &= \frac{P(x_i) \cdot \prod_{j=1}^m P(N_j|x_i)}{\sum_{l=1}^r P(x_l) \cdot \prod_{j=1}^m P(N_j|x_l)} \text{ mit } 1 \leq i \leq r\end{aligned}$$

B.2 Alarmbeispiel

Im Folgenden werden die Berechnungen zum Beispiel aus Abbildung 3.6 exemplarisch detailliert beschrieben, um die Berechnung von prognostischer bzw. diagnostischer Inferenz aufzuzeigen.

B.2.1 Beispiel: Prognostische Inferenz

Unter Anwendung der Formeln aus Appendix A.2 lässt sich $P(M|Ein)$ wie folgt berechnen:

$$\begin{aligned}
 P(M|Ein) &= \frac{P(M, Ein)}{P(Ein)} \\
 &= \frac{P(M, Ein, Al) + P(M, Ein, \overline{Al})}{P(Ein)} \\
 &= \frac{P(M|Al, Ein)P(Al, Ein) + P(M|\overline{Al}, Ein)P(\overline{Al}, Ein)}{P(Ein)} \\
 &= \frac{P(M|Al)(P(Al, Ein, Erd) + P(Al, Ein, \overline{Erd}))}{P(Ein)} \\
 &\quad + \frac{P(M|\overline{Al})(P(\overline{Al}, Ein, Erd) + P(\overline{Al}, Ein, \overline{Erd}))}{P(Ein)} \\
 &= \frac{P(M|Al)(P(Al|Ein, Erd)P(Ein)P(Erd) + P(Al|Ein, \overline{Erd})P(Ein)P(\overline{Erd}))}{P(Ein)} \\
 &\quad + \frac{P(M|\overline{Al})(P(\overline{Al}|Ein, Erd)P(Ein)P(Erd) + P(\overline{Al}|Ein, \overline{Erd})P(Ein)P(\overline{Erd}))}{P(Ein)} \\
 &= P(M|Al)(P(Al|Ein, Erd)P(Erd) + P(Al|Ein, \overline{Erd})P(\overline{Erd})) \\
 &\quad + P(M|\overline{Al})(P(\overline{Al}|Ein, Erd)P(Erd) + P(\overline{Al}|Ein, \overline{Erd})P(\overline{Erd})) \\
 &= 0.7(0.95 \cdot 0.002 + 0.94 \cdot 0.998) + 0.01(0.05 \cdot 0.002 + 0.06 \cdot 0.998) \\
 &= 0.6586138 \\
 &\approx 66\%
 \end{aligned}$$

B.2.2 Beispiel: Diagnostische Inferenz

Ebenfalls unter Anwendung der Formeln aus Appendix A.2 lässt sich $P(Al|J)$ wie folgt berechnen:

$$\begin{aligned}
 P(Al|J) &= \frac{P(Al, J)}{P(J)} \\
 &= \frac{P(J|Al) \cdot P(Al)}{P(J)} \\
 P(Al) &= P(Al|Ein, Erd)P(Ein)P(Erd) + P(Al|Ein, \overline{Erd})P(Ein)P(\overline{Erd}) \\
 &\quad + P(Al|\overline{Ein}, Erd)P(\overline{Ein})P(Erd) + P(Al|\overline{Ein}, \overline{Erd})P(\overline{Ein})P(\overline{Erd}) \\
 &= 0.95 \cdot 0.001 \cdot 0.002 + 0.94 \cdot 0.001 \cdot 0.998 \\
 &\quad + 0.29 \cdot 0.999 \cdot 0.002 + 0.001 \cdot 0.999 \cdot 0.998 \\
 &= 0.002516442 \approx 0.00252 \\
 P(J) &= P(J, Al) + P(J, \overline{Al}) \\
 &= P(J|Al)P(Al) + P(J|\overline{Al})P(\overline{Al}) \\
 &= P(J|Al)P(Al) + P(J|\overline{Al})(1 - P(Al)) \\
 &= 0.9 \cdot 0.00252 + 0.05 \cdot (1 - 0.00252) \\
 &= 0.052138975 \approx 0.052 \\
 P(Al|J) &= \frac{P(J|Al) \cdot P(Al)}{P(J)} \\
 &= \frac{0.9 \cdot 0.00252}{0.052} \\
 &= 0.043615384 \approx 4.3\%
 \end{aligned}$$

Anhang C

Junction-Trees für die weiteren Situationen

C.1 Folgefahrt

Zuerst wird aus dem Bayes'schen Netz in Abbildung 5.4 ein Junction-Tree gebildet, bei welchem sich alle Variablen, für die *weiche Evidenz* vorliegt, in einem großen Cluster finden (Abbildung C.1).




Abbildung C.1: Junction-Tree für die Situation *Folgefahrt*

Die Cluster und Separatoren aus Abbildung C.1 lassen sich beschreiben als:

$$C_1 = \{x_{BP}, x_{TW}\}$$

$$C_2 = \{x_{TV}, x_{TW}\}$$

$$C_3 = \{x_{VA}, x_{NF}, x_{TW}, x_{GP}, x_{BL}, x_{TA}\}$$

$$S_1 = \{x_{TW}\}$$

$$S_2 = \{x_{TW}\}$$

Es ergibt sich daraus für die gemeinsame Wahrscheinlichkeitsverteilung mittels Potentialen:

$$P(x_{VA}, x_{NF}, x_{TW}, x_{GP}, x_{BP}, x_{BL}, x_{TA}, x_{TV}) = \frac{\psi(C_1)\psi(C_2)\psi(C_3)}{\psi(S_1)\psi(S_2)}. \quad (C.1)$$

Den Potentialen der Cluster werden zur Initialisierung die Wahrscheinlichkeitstabellen aus Gleichung 5.23 und den Potentialen der Separatoren wird der Wert eins zugeordnet:

$$\psi(C_1) = P(x_{BP}|x_{TW})$$

$$\psi(C_2) = P(x_{TV}|x_{TW})$$

$$\psi(C_3) = P(x_{VA})P(x_{NF})P(x_{TW}|x_{VA}, x_{NF})P(x_{GP}|x_{TW})P(x_{BL}|x_{TW})P(x_{TA}|x_{TW})$$

$$\psi(S_1) = 1$$

$$\psi(S_2) = 1$$

Auf dieser Basis wird der Big-Clique-Algorithmus angewendet. Die *Wunschzeitlücke* befindet sich explizit in den Separatoren und wird anschließend direkt über diese ausgewertet.

C.2 Zufahrt auf eine Kreuzung

In Abbildung C.2 ist ein Junction-Tree zu sehen, bei welchem sich alle Knoten mit *weicher Evidenz* in einem großen Cluster finden.




Abbildung C.2: Junction-Tree für die Situation *Zufahrt auf eine Kreuzung*

Anhang C Junction-Trees für die weiteren Situationen

Die Cluster und der Separator lassen sich damit beschreiben als:

$$\begin{aligned}C_1 &= \{x_{BP}, x_{DW}\} \\C_2 &= \{x_{DV}, x_{DA}, x_{DW}, x_{GP}, x_{BL}, x_{VA}\} \\S &= \{x_{DW}\}.\end{aligned}$$

Aus dem Junction-Tree in Abbildung C.2 ergibt sich die Potentialdarstellung der gemeinsamen Wahrscheinlichkeitsverteilung:

$$P(x_{DV}, x_{DA}, x_{DW}, x_{GP}, x_{BP}, x_{BL}, x_{VA}) = \frac{\psi(C_1)\psi(C_2)}{\psi(S)}. \quad (\text{C.2})$$

Wie zuvor erfolgt die Initialisierung der Potentiale mit den Wahrscheinlichkeitstabellen der gemeinsamen Wahrscheinlichkeitsverteilung (s. Gleichung 5.24) über das spezifische Bayes'sche Netz:

$$\begin{aligned}\psi(C_1) &= P(x_{BP}|x_{DW}) \\ \psi(C_2) &= P(x_{DW}|x_{DV}, x_{DA})P(x_{DV})P(x_{DA})P(x_{GP}|x_{DW})P(x_{BL}|x_{DW})P(x_{VA}|x_{DW}) \\ \psi(S) &= 1.\end{aligned}$$

Es erfolgt zunächst die Anwendung des Junction-Tree-Algorithmus, anschließend die Absorption und Verteilung der *weichen Evidenz*.

C.3 Stillstand




Abbildung C.3: Junction-Tree für die Situation *Stillstand*

Abbildung C.3 zeigt einen Junction-Tree, in dem alle Variablen mit *weicher Evidenz* einem großen Cluster zugeordnet sind. Daraus ergeben sich die Cluster

und der Separator:

$$\begin{aligned} C_1 &= \{x_{BH}, x_{AN}\} \\ C_2 &= \{x_{VV}, x_{AN}, x_{GP}\} \\ S &= \{x_{AN}\}. \end{aligned}$$

Entsprechend dieses Junction-Trees lässt sich die gemeinsame Wahrscheinlichkeitsverteilung mittels Potentialen beschreiben als:

$$P(x_{VV}, x_{AN}, x_{GP}, x_{BH}) = \frac{\psi(C_1)\psi(C_2)}{\psi(S)}. \quad (\text{C.3})$$

Die Potentiale der Cluster werden mit den Wahrscheinlichkeitstabellen und das Potential des Separators mit eins initialisiert:

$$\begin{aligned} \psi(C_1) &= P(x_{BH}|x_{AN}) \\ \psi(C_2) &= P(x_{AN}|x_{VV})P(x_{VV})P(x_{GP}|x_{AN}) \\ \psi(S) &= 1 \end{aligned}$$

Anschließend wird der Big-Clique-Algorithmus ausgeführt.

C.4 Fahrstreifenwechsel

Zuerst wird ein Junction-Tree gebildet, bei welchem sich alle Variablen mit *weicher Evidenz* in einem großen Cluster befinden. Dieser ist in Abbildung C.4 dargestellt.




Abbildung C.4: Junction-Tree für die Situation *Fahrstreifenwechsel*

Anhang C Junction-Trees für die weiteren Situationen

Aus diesem Junction-Tree ergeben sich folgende Cluster und der Separator:

$$\begin{aligned}C_1 &= \{x_{BP}, x_{TF}\} \\C_2 &= \{x_{VA}, x_{TA}, x_{TN}, x_{DA}, x_{TF}, x_{GP}, x_{BL}, x_{DY}, x_{VY}\} \\S &= \{x_{TF}\}.\end{aligned}$$

Die gemeinsame Wahrscheinlichkeitsverteilung mittels Potentialen lässt sich darstellen als:

$$P(x_{VA}, x_{TA}, x_{TN}, x_{DA}, x_{TF}, x_{GP}, x_{BP}, x_{BL}, x_{DY}, x_{VY}) = \frac{\psi(C_1)\psi(C_2)}{\psi(S)}. \quad (\text{C.4})$$

Durch die Zuordnung der zugehörigen Wahrscheinlichkeitstabellen werden die Potentiale wie folgt beschrieben:

$$\begin{aligned}\psi(C_1) &= P(x_{BP}|x_{TF}) \\ \psi(C_2) &= P(x_{TF}|x_{VA}, x_{TA}, x_{TN}, x_{DA})P(x_{VA})P(x_{TA})P(x_{TN})P(x_{DA})P(x_{GP}|x_{TF})P(x_{BL}|x_{TF}) \\ &\quad P(x_{DY}|x_{TF})P(x_{VY}|x_{TF}) \\ \psi(S) &= 1\end{aligned}$$

Anschließend wird der Big-Clique-Algorithmus ausgeführt.

Literaturverzeichnis

- Albert 2018** ALBERT, Martin: *Ergonomische Fahrerplatzgestaltung und Interaktionskonzepte für hochautomatisierte Fahrzeuge*, Technische Universität München, Dissertation, 2018
- Alsabti u. a. 1997** ALSABTI, Khaled ; RANKA, Sanjay ; SINGH, Vineet: An efficient k-means clustering algorithm. (1997)
- Aström und Murray 2010** ASTRÖM, Karl J. ; MURRAY, Richard M.: *Feedback systems: an introduction for scientists and engineers*. Kap. Introduction, S. 1 – 26, Princeton university press, 2010
- Audi AG 2015a** AUDI AG: *Geschwindigkeitsregelanlage*. 2015. – URL <http://mediaservice.audi.com/media/cdb/data/0aa16b1c-afbf-45c9-a98e-8f4b1694fae9.jpg>. – Zugriffsdatum: 2015.03.02
- Audi AG 2015b** AUDI AG: *Multifunktions-Lederlenkrad im 4-Speichen-Design*. 2015. – URL <http://mediaservice.audi.com/media/cdb/data/5723ee81-531d-44a6-a9dc-36b1098b1edd.jpg>. – Zugriffsdatum: 2015.03.02
- Aue u. a. 2011** AUE, Jan ; LANGER, Dirk ; MÜLLER-BESSLER, Bernhard ; HUHNKE, Burkhard: Efficient segmentation of 3d lidar point clouds handling partial occlusion. In: *Intelligent Vehicles Symposium (IV), 2011 IEEE*. Baden-Baden, Juni 2011, S. 423–428
- Aue 2014** AUE, Martin J.: *Detektion und Verfolgung von Objekten mit lokalen Belegungskarten basierend auf Stereokameradaten*, Technischen Universität Carolo-Wilhelmina zu Braunschweig, Dissertation, 2014
- Barber 2003** BARBER, David: Probabilistic modelling and reasoning: The junction tree algorithm. In: *Course notes 2004* (2003)

- Bauer 2012** BAUER, Colin: *A driver specific maneuver prediction model based on fuzzy logic*, Dissertation, 2012
- Bilmes 2004** BILMES, Jeff: On virtual evidence and soft evidence in Bayesian networks. (2004)
- Bishop u. a. 2006** BISHOP, Christopher M. u. a.: Pattern recognition and machine learning, vol. 1 Springer. In: *New York* (2006), Nr. 4
- Borth 2004** BORTH, Michael: *Wissensgewinnung auf Bayes-netz-mengen*, Universität Ulm, Dissertation, 2004
- Brockhaus 1993** BROCKHAUS: *Der große Brockhaus - Bd. 19*. Mannheim : Brockhaus GmbH, 1993
- Broggi u. a. 2013** BROGGI, Alberto ; DEBATTISTI, Stefano ; PANCIOLOI, Matteo ; PORTA, Pier P.: Moving from analog to digital driving. In: *Intelligent Vehicles Symposium (IV), 2013 IEEE*. Gold Coast, QLD, Juni 2013, S. 1113–1118
- Bundesministerium für Verkehr, Bau und Stadtentwicklung 2006** BUNDESMINISTERIUM FÜR VERKEHR, BAU UND STADTENTWICKLUNG: ECE-R 79 - Regelung Nr. 79 Revision 2 - Einheitliche Bedingungen für die Genehmigung der Fahrzeuge hinsichtlich der Lenkanlage. (2006)
- Charniak 1991** CHARNIAK, Eugene: Bayesian networks without tears. In: *AI magazine* 12 (1991), Nr. 4, S. 50–63
- Christhard Gelau 2012** CHRISTHARD GELAU, Andre S.: *Handbuch Fahrerassistenzsysteme: Grundlagen, Komponenten und Systeme für aktive Sicherheit und Komfort*. Kap. Fahrerassistenz und Verkehrssicherheit, S. 24–32. Wiesbaden : Vieweg+Teubner, 2012
- Cooper und Herskovits 1992** COOPER, Gregory F. ; HERSKOVITS, Edward: A Bayesian method for the induction of probabilistic networks from data. In: *Machine learning* 9 (1992), Nr. 4, S. 309–347
- Darwiche 2009** DARWICHE, Adnan: *Modeling and Reasoning with Bayesian Networks*. Kap. Introduction, S. 1 – 12, Cambridge University Press, 2009

- Dempster u. a. 1977** DEMPSTER, Arthur P. ; LAIRD, Nan M. ; RUBIN, Donald B.: Maximum likelihood from incomplete data via the EM algorithm. In: *Journal of the royal statistical society. Series B (methodological)* (1977), S. 1–38
- Diederichs u. a. 2015** DIEDERICHS, F ; SEITZ, W ; SPATH, D: Fahrerintentionserkennung auf Basis von Blickanalysen zur Vermeidung von Fußgängerkollisionen. 11. In: *Berliner Werkstatt Mensch-Maschine-Systeme (BWMMS), Berlin-Brandenburgische Akademie der Wissenschaften* (2015)
- Donges 1982** DONGES, Edmund: Aspekte der Aktiven Sicherheit bei der Führung von Personenkraftwagen. In: *Automobil Industrie* 27 (1982), S. 183–190
- Duden 2013** DUDEN: *DudenOnline*. 2013. – URL <http://www.duden.de>. – Zugriffsdatum: 13.03.2013
- Elektrobit 2018** ELEKTROBIT: *ADTF*. 2018. – URL <https://www.elektrobit.com/products/eb-assist/adtf/>. – Zugriffsdatum: 04.02.2018
- Endsley und Kiris 1995** ENDSLEY, Mica R. ; KIRIS, Esin O.: The Out-of-the-Loop Performance Problem and Level of Control in Automation. In: *Human Factors: The Journal of the Human Factors and Ergonomics Society* 37 (1995), Nr. 2, S. 381–394
- Ertel 2013** ERTEL, Wolfgang: *Grundkurs Künstliche Intelligenz - Eine praxisorientierte Einführung*. Kap. Schließen mit Unsicherheit, S. 125–176. Wiesbaden : Springer Vieweg, 2013
- Flemisch u. a. 2008** FLEMISCH, Frank ; KELSCH, Johann ; LÖPER, Christian ; SCHIEBEN, Anna ; SCHINDLER, Julian ; HEESEN, Matthias: Cooperative control and active interfaces for vehicle assistance and automation. In: *FISITA World automotive Congress*. München, 2008
- Flemisch u. a. 2003** FLEMISCH, Frank O. ; ADAMS, Catherine A. ; CONWAY, Sheila R. ; GOODRICH, Ken H. ; PALMER, Michael T. ; SCHUTTE, Paul C.: The H-Metaphor as a guideline for vehicle automation and interaction. In: *Report No. NASA/TM-2003-212672*. Hampton, 2003
- Flemisch u. a. 2012** FLEMISCH, Frank O. ; MEIER, S. ; BALTZER, M. ; ALTENDORF, E. ; HEESEN, M. ; GRIESCHE, S. ; WEISSGERBER, T. ; KIENLE, Martin ; DAMBÖCK, Daniel: Fortschrittliches Anzeige-und Interaktionskonzept für die

kooperative Führung hochautomatisierter Fahrzeuge: Ausgewählte Ergebnisse mit H-Mode 2D 1.0. In: *Fortschrittliche Anzeigesysteme für die Fahrzeug- und Prozessführung*, 2012

Flemisch u. a. 2014 FLEMISCH, Frank O. ; BENGLER, Klaus ; BUBB, Heiner ; WINNER, Hermann ; BRUDER, Ralph: Towards cooperative guidance and control of highly automated vehicles: H-Mode and Conduct-by-Wire. In: *Ergonomics* 57 (2014), Nr. 3, S. 343–360

Franz u. a. 2012 FRANZ, Benjamin ; KAUER, Michaela ; BRUDER, Ralph ; GEYER, S.: pieDrive - a New Driver-Vehicle Interaction Concept for Maneuver-Based Driving. In: *Intelligent Vehicles Symposium Workshops (IV), 2012 IEEE*, Juli 2012

Gasser u. a. 2015 GASSER, Tom ; SCHMIDT, Eike ; BENGLER, Klaus ; CHIELINO, Ulrich ; DIEDERICHS, F. ; ECKSTEIN, Lutz ; FLEMISCH, Frank ; FRAEDRICH, Eva ; FUCHS, Erich ; GUSTKE, Marko ; HOYER, Robert ; HÜTTINGER, Michael ; MEIKE, Jipp ; KÖSTER, Frank ; KUEHN, Matthias ; LENZ, Barbara ; LOTZ-KEENS, Christine ; MAURER, Markus ; MEURER, Michael ; ZEEB, Eberhard: Bericht zum Forschungsbedarf. Runder Tisch Automatisiertes Fahren - AG Forschung. (2015), August

Gayko 2012 GAYKO, Jens: *Handbuch Fahrerassistenzsysteme: Grundlagen, Komponenten und Systeme für aktive Sicherheit und Komfort*. Kap. Lane Keeping Support, S. 554–561. Wiesbaden : Vieweg+Teubner, 2012

Geduld 2012 GEDULD, Georg: *Handbuch Fahrerassistenzsysteme: Grundlagen, Komponenten und Systeme für aktive Sicherheit und Komfort*. Kap. Lidar-sensorik, S. 172–186. Wiesbaden : Vieweg+Teubner, 2012

Goodrich u. a. 2006 GOODRICH, Kenneth H. ; FLEMISCH, Frank O. ; SCHUTTE, Paul C. ; WILLIAMS, Ralph A.: Application of the H-Mode, a design and interaction concept for highly automated vehicles, to aircraft. In: *25th Digital Avionics Systems Conference, 2006 IEEE/AIAA, 2006*, S. 1–13

Haag 1998 HAAG, Michael: *Bildfolgenauswertung zur Erkennung der Absichten von Straßenverkehrsteilnehmern*, Universität Karlsruhe, Dissertation, 1998

- Halfmann und Holzmann 2003** HALFMANN, Christoph ; HOLZMANN, Henning: *Adaptive Modelle für die Kraftfahrzeugdynamik*. Kap. Hybride Modellbildung, S. 95–128, Springer-Verlag Berlin Heidelberg, 2003
- Heesen u. a. 2010** HEESEN, Matthias ; KELSCH, Johann ; LÖPER, Christian ; FLEMISCH, Frank: Haptisch-multimodale Interaktion für hochautomatisierte, kooperative Fahrzeugführung bei Fahrstreifenwechsel-, Brems- und Ausweichmanövern. In: *Braunschweiger Symposium Automatisierungs-, Assistenzsysteme und eingebettete Systeme für Transportmittel (AAET)*, Braunschweig, 2010
- Heine 2018** HEINE, Jens: *Entwicklung eines Algorithmus zur Prädiktion eines innerstädtischen Fahrstreifenwechsels*, Technische Universität Darmstadt, Dissertation, 2018
- Herrmann 2013** HERRMANN, Simon: *Kollisionswarnung im urbanen Straßenverkehr auf Basis einer probabilistischen Situationsanalyse*, Dissertation, 2013
- Hoc 2001** HOC, Jean-Michel: Towards a cognitive approach to human-machine cooperation in dynamic situations. In: *International Journal of Human-Computer Studies* 54 (2001), Nr. 4, S. 509–540
- Höver u. a. 2006** HÖVER, Norbert ; LICHTER, Bernd ; LIETAERT, Steven: Multi-beam Lidar Sensor for Active Safety Applications / SAE Technical Paper. 2006. – Forschungsbericht
- Internationale Organisation für Normung 2002** INTERNATIONALE ORGANISATION FÜR NORMUNG: ISO 15622: Transport Information and Control Systems - Adaptive Cruise Control Systems - Performance Requirements and Test Procedures. (2002)
- Intersafe-2 2011** INTERSAFE-2: *Cooperative Intersection Safety*. 2011. – URL <http://www.intersafe-2.eu/public/>. – Zugriffsdatum: 13.02.2012
- Kasper u. a. 2011** KASPER, Dietmar ; WEIDL, Galia ; DANG, Thao ; BREUEL, Gabi ; TAMKE, Andreas ; ROSENSTIEL, Wolfgang: Manövererkennung mit objekt-orientierten Bayes Netzwerken. In: *Workshop Fahrerassistenzsysteme* (2011)

- Kauer u. a. 2010** KAUER, M. ; SCHREIBER, M. ; BRUDER, R.: How to conduct a car? A design example for maneuver based driver-vehicle interaction. In: *Intelligent Vehicles Symposium (IV), 2010 IEEE*. San Diego, CA, 2010, S. 1214–1221
- Kerner 2009** KERNER, Boris S.: *Introduction to Modern Traffic Flow Theory and Control*. Kap. Definitions of The Three Traffic Phases, S. 9–40, Springer-Verlag Berlin Heidelberg, 2009
- Kienle u. a. 2009** KIENLE, Martin ; DAMBÖCK, Daniel ; KELSCH, Johann ; FLEMISCH, Frank ; BENGLER, Klaus: Towards an H-Mode for highly automated vehicles: driving with side sticks. In: *Proceedings of the 1st International Conference on Automotive User Interfaces and Interactive Vehicular Applications*. New York, NY, USA, 2009 (AutomotiveUI '09), S. 19–23
- Kienle 2015** KIENLE, Martin M.: *Kooperative Interaktionskonzepte zum Fahren eines teilautomatisierten Fahrzeugs*, Technische Universität München, Dissertation, 2015
- Kluge 2006** KLUGE, Oliver: *Praktische Informationstechnik mit C#: Anwendungen und Grundlagen*. Kap. Computational Intelligence, S. 161–221, Springer-Verlag Berlin Heidelberg, 2006
- Knaup und Homeier 2010** KNAUP, Jörn ; HOMEIER, Kai: RoadGraph - Graph based environmental modelling and function independent situation analysis for driver assistance systems. In: *Intelligent Transportation Systems (ITSC), 2010 IEEE*. Madeira Island, Portugal, 2010, S. 428–432
- Koski und Noble 2009** KOSKI, Timo ; NOBLE, John M.: *Bayesian Networks - An Introduction*. John Wiley & Sons, 2009
- Kramer 2009** KRAMER, Oliver: *Computational Intelligence*. Kap. Fuzzy-Logik, S. 75–99, Springer-Verlag Berlin Heidelberg, 2009
- Kreiss 2012** KREISS, Dennis: Ultraschallsysteme für Fahrerassistenzsysteme. In: *ATZ elektronik*, Springer Automotive Media, 2012, S. 385–385
- Kreßler 2015** KRESSLER, Dr. U.: *Projektsäule Kognitive Assistenz - KA Zwischenbericht 1. Halbjahr 2015*. Verbundprojekt UR:BAN, 2015

- Lam und Bacchus 1994** LAM, Wai ; BACCHUS, Fahiem: Learning Bayesian belief networks: An approach based on the MDL principle. In: *Computational intelligence* 10 (1994), Nr. 3, S. 269–293
- Lank und Steinauer 2009** LANK, Christian ; STEINAUER, Bernhard: Entwicklung besonderer Fahrbahnbeläge zur Beeinflussung der Geschwindigkeitswahl. In: *Berichte der Bundesanstalt für Straßenwesen, Unterreihe Verkehrstechnik* (2009), Nr. 190
- Lauritzen und Spiegelhalter 1988** LAURITZEN, Steffen L. ; SPIEGELHALTER, David J.: Local computations with probabilities on graphical structures and their application to expert systems. In: *Journal of the Royal Statistical Society: Series B (Methodological)* 50 (1988), Nr. 2, S. 157–194
- Lerner und Hegewald 2009** LERNER, Markus ; HEGEWALD, Andreas: Sicherheitswirkung eingefräster Rüttelstreifen entlang der BAB A24. In: *Berichte der Bundesanstalt für Straßenwesen, Unterreihe Verkehrstechnik* (2009), Nr. 177
- Lippe 2006** LIPPE, Wolfram-Manfred: *Self-Computing - mit Neuronalen Netzen, Fuzzy-Logic und Evolutionären Algorithmen*. Kap. Künstliche Neuronale Netze, S. 45–243, Springer-Verlag Berlin Heidelberg, 2006
- McCulloch und Pitts 1943** MCCULLOCH, Warren S. ; PITTS, Walter: A logical calculus of the ideas immanent in nervous activity. In: *The bulletin of mathematical biophysics* 5 (1943), Nr. 4, S. 115–133
- Mrad u. a. 2015** MRAD, Ali B. ; DELCROIX, Véronique ; PIECHOWIAK, Sylvain ; LEICESTER, Philip ; ABID, Mohamed: An explication of uncertain evidence in Bayesian networks: likelihood evidence and probabilistic evidence. In: *Applied Intelligence* 43 (2015), Nr. 4, S. 802–824
- Munz 2011** MUNZ, Michael: *Generisches Sensorfusionsframework zur gleichzeitigen Zustands- und Existenzschätzung für die Fahrzeugumfeldererkennung*, Universität Ulm. Fakultät für Ingenieurwissenschaften und Informatik, Dissertation, 2011
- Noll und Rapps 2012** NOLL, Martin ; RAPPS, Peter: *Handbuch Fahrerassistenzsysteme: Grundlagen, Komponenten und Systeme für aktive Sicherheit und Komfort*. Kap. Ultraschallsensorik, S. 110–122. Wiesbaden : Vieweg+Teubner, 2012

- Oschlies 2019** OSCHLIES, Hendrik: *Komfortorientierte Regelung für die automatisierte Fahrzeugquerführung*. Springer, 2019
- Pearl 1985** PEARL, Judea: *Bayesian networks: A model of self-activated memory for evidential reasoning*. University of California (Los Angeles). Computer Science Department, 1985
- Pearl 1986** PEARL, Judea: Fusion, propagation, and structuring in belief networks. In: *Artificial intelligence* 29 (1986), Nr. 3, S. 241–288
- Pearl 2009** PEARL, Judea: *Causality*. Cambridge university press, 2009
- Pellkofer 2003** PELLKOFER, Martin: *Verhaltensentscheidung für autonome Fahrzeuge mit Blickrichtungssteuerung*, Universität der Bundeswehr München, Dissertation, 2003
- Petermann-Stock und Werneke 2014** PETERMANN-STOCK, Ina ; WERNEKE, Dr. Julia: *Projekt: Mensch im Verkehr - MV 2. Meilensteinbereich (Q8) Funktionsspezifische MMI KKonzept und nuterbezogene Evaluationsergebnisse*. 2014
- Rasmussen 1983** RASMUSSEN, Jens: Skills, rules, and knowledge; signals, signs, and symbols, and other distinctions in human performance models. In: *Transactions Systems, Man and Cybernetics, IEEE 1983* Bd. SMC-13, Mai 1983, S. 257–266
- Rasshofer und Gresser 2005** RASSHOFER, R. H. ; GRESSER, K.: Automotive radar and lidar systems for next generation driver assistance functions. In: *Advances in Radio Science* Bd. 3, Copernicus GmbH, 2005, S. 205–209
- Reif 2012** REIF, Konrad: Fahrerassistenzsysteme. In: *Automobilelektronik*. Vieweg+Teubner Verlag, 2012, S. 321–367
- Reynolds 2015** REYNOLDS, Douglas: Gaussian mixture models. In: *Encyclopedia of biometrics* (2015), S. 827–832
- Rodemerck u. a. 2015** RODEMERCK, Claas ; KASTNER, Robert ; WINNER, Hermann: Manöverprädiktion an innerstädtischen Knotenpunkten durch Exklusion alternativer Manöveroptionen. In: *10 Uni-DAS eV Workshop Fahrerassistenzsysteme*, 2015

- Rohling 2010** ROHLING, Hermann: Automotive Radar - Wissenschaft und Technologietransfer. In: *VDE-Kongress 2010*, 2010
- Schreiber u. a. 2009** SCHREIBER, M. ; KAUER, M. ; BRUDER, R.: Conduct by wire-maneuver catalog for semi-autonomous vehicle guidance. In: *Intelligent Vehicles Symposium, IEEE 2009*, 2009, S. 1279–1284
- Schreiber u. a. 2010** SCHREIBER, M. ; KAUER, M. ; HAKULI, S. ; BRUDER, R.: Conduct-by-Wire: Evaluation von teilautonomer Fahrzeugführung mit Hilfe der Wizard of Oz-Technik. In: *Neue Arbeits- und Lebenswelten gestalten*, 2010, S. 161–164
- Schroven und Giebel 2008** SCHROVEN, F ; GIEBEL, T: Fahrerintentionserkennung für Fahrerassistenzsysteme/Driver intent Recognition for advanced driver assistance systems. In: *VDI-Berichte (2008)*, Nr. 2048
- Schroven 2011** SCHROVEN, Frank: *Probabilistische Situationsanalyse für eine adaptive automatisierte Fahrzeuglängsführung*, Technische Universität Carolo-Wilhelmina zu Braunschweig, Dissertation, 2011
- Sommer und Engeln 2009** SOMMER, Fanny ; ENGELN, Arnd: Fahrerabsichtserkennung für autonome Notbremssysteme-ein Untersuchungsansatz. In: *Wie realitätsnah lässt sich Fahrerverhalten messen (2009)*, S. 16–28
- Spiegel 2002** SPIEGEL: *100 Jahre Tachometer.* 2002.
– URL <http://www.spiegel.de/auto/werkstatt/100-jahre-tachometer-tempomesser-kam-nur-langsam-auf-touren-a-222464.html>. – Zugriffsdatum: 13.03.2013
- Statistisches Bundesamt 2014** STATISTISCHES BUNDESAMT: *Bestand an Kraftfahrzeugen.* 2014. – URL <https://www.destatis.de/DE/ZahlenFakten/Wirtschaftsbereiche/TransportVerkehr/UnternehmenInfrastrukturFahrzeugbestand/Tabellen/Fahrzeugbestand.html>. – Zugriffsdatum: 03.09.2014
- Statistisches Bundesamt 2019** STATISTISCHES BUNDESAMT: *Verkehrsunfälle.* 2019. – URL https://www.destatis.de/DE/Themen/Gesellschaft-Umwelt/Verkehrsunfaelle/_inhalt.html#sprg238548. – Zugriffsdatum: 26.05.2019

- Stiller u. a. 2012** STILLER, Christoph ; BACHMANN, Alexander ; DUCHOW, Christian: *Handbuch Fahrerassistenzsysteme: Grundlagen, Komponenten und Systeme für aktive Sicherheit und Komfort*. Kap. Maschinelles Sehen, S. 198–222. Wiesbaden : Vieweg+Teubner, 2012
- Streubel und Hoffmann 2015** STREUBEL, Thomas ; HOFFMANN, Karl H.: Realisierung eines Fahrtrichtungsprädiktors für Kreuzungen Realization of a Prediction of the Driving Direction at Intersections. In: *Automotive meets Electronics* (2015)
- Stüker 2004** STÜKER, Dirk: *Heterogene Sensordatenfusion zur robusten Objektverfolgung im automobilen Straßenverkehr*, Universität Oldenburg, Dissertation, 2004
- Sucar 2015** SUCAR, Luis E.: Bayesian Networks: Representation and Inference. In: *Probabilistic Graphical Models*. Springer, 2015, S. 101–136
- URBAN 2016** URBAN: *UR:BAN*. 2016. – URL <http://urban-online.org>. – Zugriffsdatum: 01.12.2019
- Valtorta u. a. 2002** VALTORTA, Marco ; KIM, Young-Gyun ; VOMLEL, Jiří: Soft evidential update for probabilistic multiagent systems. In: *International Journal of Approximate Reasoning* 29 (2002), Nr. 1, S. 71–106
- Volkswagen AG 2016** VOLKSWAGEN AG: *Forschungsprojekt UR:BAN - Kognitive Assistenz Schlussbericht*. 2016
- von Eichhorn 2015** VON EICHHORN, Andreas: *Querverkehrsassistenz unter Berücksichtigung von Unsicherheiten aus Sensorik und Prädiktion*, Dissertation, 2015
- von Reyher 2007** VON REYHER, Alexander: *Lidarbasierte Fahrstreifenzuordnung von Objekten für eine Abstandsregelung im Stop&Go-Verkehr*, TU Darmstadt, Dissertation, 2007
- vwwortex 2014** VWWORTEX: *Passat*. 2014. – URL <http://www.vwwortex.com/wp-content/uploads/2014/07/Volkswagen-Passat-Variant-VIII-MQB-630-600x375.jpg>. – Zugriffsdatum: 05.11.2014

- Wegscheider und Prokop 2005** WEGSCHEIDER, Michael ; PROKOP, Günther: Modellbasierte Komfortbewertung von Fahrerassistenzsystemen. In: *VDI-Berichte* 1900 (2005), S. 17–36
- Weiser 2018** WEISER, Andreas: *Probabilistische Vorhersage von Fahrstreifenwechseln für hochautomatisiertes Fahren auf Autobahnen*, Dissertation, 2018
- Welt 2014** WELT: *Autonomes Fahren*. 2014. – URL <http://www.welt.de/motor/news/article128190138/Autonomes-Fahren.html>. – Zugriffsdatum: 03.11.2014
- Werling 2010** WERLING, Moritz: *Ein neues Konzept für die Trajektoriengenerierung und -stabilisierung in zeitkritischen Verkehrsszenarien*, Karlsruher Institut für Technologie, Dissertation, 2010
- Wershofen und Graefe 1996** WERSHOFEN, Klaus P. ; GRAEFE, Volker: Situationserkennung als Grundlage der Verhaltenssteuerung eines mobilen Roboters. In: *Autonome Mobile Systeme 1996*. Springer, 1996, S. 170–179
- Wien 1968** WIEN: *Wiener Übereinkommen über den Straßenverkehr*. 1968
- Wood 1994** WOOD, Neal E.: Shoulder rumble strips: a method to alert drifting drivers. In: *73rd Annual Meeting of the Transportation Research Board, Washington, DC*, 1994
- Xiao u. a. 2009** XIAO, Xu H. ; LEE, Hian B. ; NG, Gee W.: Learning bayesian network parameters from soft data. In: *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems* 17 (2009), Nr. 02, S. 281–294
- Zadeh 1965** ZADEH, Lotfi A.: Fuzzy sets. In: *Information and control* 8 (1965), Nr. 3, S. 338–353