

MARTIN LIEBNER

Fahrerabsichtserkennung und Risikobewertung für warnende Fahrerassistenzsysteme

Martin Liebner

**Fahrerabsichtserkennung und Risikobewertung
für warnende Fahrerassistenzsysteme**

Schriftenreihe
Institut für Mess- und Regelungstechnik,
Karlsruher Institut für Technologie (KIT)
Band 034

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

Fahrerabsichtserkennung und Risikobewertung für warnende Fahrerassistenzsysteme

von
Martin Liebner

Dissertation, Karlsruher Institut für Technologie (KIT)
Fakultät für Maschinenbau, 2015
Tag der mündlichen Prüfung: 5. November 2015
Referenten: Prof. Dr.-Ing. C. Stiller, Prof. Dr.-Ing. K. Dietmayer

Impressum



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

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

www.ksp.kit.edu



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



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

Print on Demand 2016

ISSN 1613-4214

ISBN 978-3-7315-0508-2

DOI: 10.5445/KSP/1000053685

Fahrerabsichtserkennung und Risikobewertung für warnende Fahrerassistenzsysteme

Zur Erlangung des akademischen Grades
Doktor der Ingenieurwissenschaften
der Fakultät für Maschinenbau
Karlsruher Institut für Technologie (KIT)

genehmigte

Dissertation

von

DIPL.-ING. MARTIN LIEBNER

Tag der mündlichen Prüfung: 05.11.2015
Hauptreferent: Prof. Dr.-Ing. C. Stiller
Korreferent: Prof. Dr.-Ing. K. Dietmayer

Vorwort

Die vorliegende Arbeit wäre nicht möglich gewesen ohne die großzügige Unterstützung, die ich vor, während und nach meiner dreijährigen Doktorandenzeit bei BMW von zahlreichen Personen erhalten habe. Dank gebührt hierbei zunächst meinem Betreuer am Karlsruher Institut für Technologie, Herrn Professor Christoph Stiller, für dessen umfangreiche Beratung und die stets sehr konstruktiven Vorschläge zur Verbesserung meiner Arbeit. Herrn Professor Klaus Dietmayer danke ich für die Übernahme des Koreferats und die anregenden Diskussionen bei den Konsortialtreffen des vom Bundesministerium für Wirtschaft und Industrie geförderten Forschungsprojekts Ko-PER, in dessen Rahmen die Arbeit entstand.

Bedanken möchte ich mich darüber hinaus bei meinen Kollegen von BMW für die hervorragende Zusammenarbeit, den intensiven Austausch von Ideen und die gewährte Hilfe bei der Inbetriebnahme der Versuchsträger. Mein besonderer Dank gilt Felix Klanner für die Organisation des hervorragenden Arbeitsumfelds vor Ort, für die intensive Betreuung meiner Arbeit und nicht zuletzt für die zahlreichen gemeinsamen Bergtouren und seine Freundschaft. Ebenfalls bedanken möchte ich mich bei Reiner Wertheimer für die sorgfältige Planung des rundum erfolgreichen Forschungsprojekts und das sehr hilfreiche Feedback zur Erstversion der vorliegenden Arbeit, sowie bei Michael Baumann, Armin Bartsch, Sebastian Bayerl, Lars Kutschat, Christian Ruhhammer, Jiamin Zeng, Kamen Mihaylov und Stephan Epping für ihre wertvollen Beiträge im Rahmen von Praktika und studentischen Abschlussarbeiten.

Die Anfertigung einer Doktorarbeit erfordert mitunter viel Hingabe und harte Arbeit, während der nur wenig Zeit für anderes bleibt. Daher danke ich meiner Familie, meinen Freunden und insbesondere meiner Freundin Sonja für das entgegengebrachte Verständnis und ihre stets vorhandene Unterstützung. Ganz besonders danke ich aber meinen geliebten Eltern Cathrin und Falk, denen ich diese Arbeit widme.

München, im November 2015

Martin Liebner

Kurzfassung

Um den Fahrer rechtzeitig auf drohende Kollisionen hinzuweisen und ihn darüber hinaus nicht unnötig von der Fahraufgabe abzulenken, ist eine Risikobewertung anhand der wahrscheinlichen zukünftigen Trajektorie des eigenen Fahrzeugs, aber auch der der anderen Verkehrsteilnehmer erforderlich. Die Reaktionszeit des Fahrers erfordert hierbei eine Vorausschau von 2-3 Sekunden, die in komplexen Verkehrssituationen nur unter Berücksichtigung der Fahrerabsicht realisierbar ist. Zudem wird ein Modell für das Situationsbewusstsein benötigt, um der Interaktion zwischen den Verkehrsteilnehmern Rechnung zu tragen. Die vorliegende Arbeit diskutiert die mit der Fahrerabsichtserkennung und Risikobewertung verbundenen Herausforderungen, schlägt eine geeignete Methode vor und bewertet diese anhand von Probandenstudien im Realverkehr.

Gegenüber dem Stand der Technik besteht ein wesentlicher Vorteil der hier vorgestellten Methode in ihrer Anwendbarkeit auf beliebige Verkehrssituationen. Diese wird erreicht, indem parametrische Modelle zur Beschreibung des erwarteten Fahrerhaltens in Abhängigkeit von der Straßengeometrie und dem Verhalten der anderen Verkehrsteilnehmer eingesetzt werden. Die Wahrscheinlichkeiten für die möglichen Fahrerabsichten bzw. das Situationsbewusstsein des Fahrers werden mit Hilfe von dynamischen Bayes'schen Netzen bestimmt, die entsprechend der aktuellen Verkehrssituation in jedem Zeitschritt neu zusammengesetzt und anhand der zugehörigen Fahrerhaltensmodelle parametrisiert werden.

Für die Entwicklung und Verifikation der Fahrerhaltensmodelle wurden zahlreiche Messfahrten im Realverkehr durchgeführt. Darüber hinaus wurde experimentell untersucht, inwieweit Smartphones zur Detektion der potenziellen Konfliktpartner eingesetzt werden können. Gemeinsam mit den erzielten methodischen Fortschritten bei der Fahrerabsichtserkennung stellen die Ergebnisse dieser Untersuchungen eine wichtige Grundlage für die Entwicklung zukünftiger Fahrerassistenzsysteme dar.

Schlagworte: Fahrerabsichtserkennung, Risikobewertung, Fahrerhaltensmodell, Situationsbewusstsein, Dynamisches Bayes'sches Netz

Abstract

In order to warn the driver of potential collisions in time and to avoid driver distraction caused by unnecessary warnings, a risk assessment based on the future trajectory of the vehicle as well as that of the other traffic participants is required. The driver's reaction time leads to a prediction horizon of 2-3 seconds which, for complex traffic situations, can only be realized by taking into account the driver's intent. In addition, a model for the driver's situation awareness is needed in order to account for the interaction between individual traffic participants. The work contains a discussion of the major challenges of driver intent inference and risk assessment, proposes an appropriate method and evaluates the developed prototype based on user studies in real traffic.

Compared to the current state of the art, a major advantage of the proposed method is that it can be applied to arbitrary traffic situations. This is achieved by the use of parametric driver models for describing the expected driver behavior depending on the road geometry as well as the behavior of the other traffic participants. Based on these driver models, a dynamic Bayesian network is re-assembled and parametrized in each time-step to match the current situation and is then used to calculate the driver intent and situation awareness probabilities.

For development and verification of the driver models, a large number of user studies has been carried out in real traffic. In addition, the feasibility of using smartphones for the detection of conflicting traffic participants has been investigated by experiment. Together with the methodological advancements in driver intent inference, the results of these investigations provide a sound basis for the development of future driver assistance systems.

Keywords: Driver Intent Inference, Risk Assessment, Driver Model, Situation Awareness, Dynamic Bayesian Network

Inhaltsverzeichnis

Symbolverzeichnis	xi
1 Einführung	1
1.1 Problemstellung	2
1.1.1 Fahrerabsichtserkennung	3
1.1.2 Berücksichtigung des Situationsbewusstseins	5
1.2 Stand der Technik	6
1.2.1 Rein prädiktive Verfahren	7
1.2.2 Risikobewertung auf Basis der Fahrerabsicht	10
1.2.3 Wissensbasierte Verfahren	18
1.2.4 Zusammenfassung	19
1.3 Wissenschaftlicher Neuwert	21
1.4 Struktur der Arbeit	22
2 Umfelderkennung und Detektion verletzlicher Verkehrsteilnehmer	23
2.1 Stand der Technik	23
2.1.1 Fahrzeuglokale Sensorik	23
2.1.2 Kooperative Perzeption	25
2.2 Smartphonebasierter Radfahrschutz	27
2.2.1 Untersuchungen zur GPS-Genauigkeit	29
2.2.2 Untersuchungen zur Übertragungslatenz	37
2.2.3 Zusammenfassung und Ausblick	39

3	Fahrerabsichtserkennung auf Basis allgemeingültiger parametrischer Modelle	41
3.1	Vorhersage des zukünftigen Fahrwegs	42
3.1.1	Lokalisierung auf der digitalen Karte	44
3.1.2	Repräsentation von Handlungsalternativen	50
3.1.3	Berechnung der Pfadwahrscheinlichkeiten	51
3.2	Modellierung des Fahrtrichtungsanzeigers	53
3.2.1	Ursachen der Blinkeraktivierung	53
3.2.2	Distanz der Blinkeraktivierung	54
3.2.3	Berechnung der Likelihood	60
3.3	Modellierung der Längsbeschleunigung	62
3.3.1	Vorderfahrzeuge	64
3.3.2	Abbiegebedingte Verzögerung	65
3.3.3	Modelle für unterschiedliche Fahrertypen	66
3.3.4	Berechnung der Likelihood	73
3.3.5	Vorhersage des Geschwindigkeitsverlaufs	76
3.4	Modellierung der Kopfdrehung	77
3.4.1	Ursachen für die Blickrichtung des Fahrers	78
3.4.2	Modell für die Fahrerabsichtsvorhersage	78
3.5	Bewertung der Vorhersagequalität	81
3.5.1	Versuchsaufbau	82
3.5.2	Aussagekraft der einzelnen Merkmale	82
3.5.3	Kombination mehrerer Merkmale	83
4	Risikobewertung unter Berücksichtigung des Situationsbewusstseins	87
4.1	Motivation und Anforderungen	87
4.1.1	Vermeidung unnötiger Warnungen	88
4.1.2	Detektion nicht sichtbarer Verkehrsteilnehmer	90
4.1.3	Verbesserung der Fahrerabsichtserkennung	91
4.1.4	Vorhersage des weiteren Verkehrsgeschehens	91

4.2	Modellierung des Situationsbewusstseins	93
4.2.1	Blickverhalten	97
4.2.2	Situationsbewusstsein	105
4.2.3	Anhalteabsicht und Beschleunigung	109
4.3	Echtzeitfähige Realisierung im Fahrzeug	113
4.3.1	Warnstrategie und Risikobewertung	113
4.3.2	Softwarearchitektur	115
4.3.3	Umsetzung der Inferenz	117
4.4	Experimentelle Ergebnisse	126
4.4.1	Vermeidung unnötiger Warnungen	129
4.4.2	Detektion nicht sichtbarer Verkehrsteilnehmer	131
4.4.3	Vorhersage von Anfahrvorgängen	133
4.4.4	Berechnung der Pfadwahrscheinlichkeiten	137
5	Zusammenfassung und Ausblick	139
	Literaturverzeichnis	143
	Liste eigener Veröffentlichungen	155
	Betreute studentische Abschlussarbeiten	159

Symbolverzeichnis

Abkürzungen

ANN	Artificial Neural Network
BN	Bayesian Network
CAM	Cooperative Awareness Message
CRF	Conditional Random Field
CPM	Cooperative Perception Message
CV	Constant Velocity
DBN	Dynamic Basian Network
DT	Decision Tree
EKF	Extended Kalman Filter
GIDAS	German In Depth Accident Study
GP	Gaussian Process
GPS	Global Positioning System
HMM	Hidden Markov Model
HDOP	Horizontal Dilution of Precision
HSDPA	High Speed Downlink Packet Access
INS	Inertial Navigation System
LTE	Long Term Evolution
MEZ	Mitteleuropäische Zeit
RF	Random Forest
RRT	Rapidly Exploring Random Tree
RVM	Relevance Vector Machine
SPaT	Signal Phase and Timing
SVM	Support Vector Machine
UKF	Unscented Kalman Filter
UMTS	Universal Mobile Communication System
WLAN	Wireless Local Area Network

Notationsvereinbarungen

Schreibweisen

Skalare	kursiv, klein: a, b, c, \dots
Zufallsgrößen	kursiv, groß: A, B, C, \dots
Vektoren	fett, kursiv, klein: $\mathbf{a}, \mathbf{b}, \mathbf{c}, \dots$
Matrizen	fett, kursiv, groß: $\mathbf{A}, \mathbf{B}, \mathbf{C}, \dots$
Mengen	kalligrafisch, groß: $\mathcal{A}, \mathcal{B}, \mathcal{C}, \dots$

Nicht kursiv geschrieben werden Konstanten, Bezeichner und Operatoren.

Wahrscheinlichkeitsrechnung

Sei $(\mathcal{E}, \mathcal{Z}, P)$ ein Wahrscheinlichkeitsraum mit der Menge der Elementarereignisse \mathcal{E} , dem Ereignisfeld \mathcal{Z} und dem Wahrscheinlichkeitsmaß P , die Mengen \mathcal{A} und \mathcal{B} Elemente von \mathcal{Z} sowie $P(\mathcal{B}) > 0$. Darüber hinaus seien X und Y Zufallsgrößen, die \mathcal{E} auf die Menge der reellen Zahlen abbilden, x und y reelle Zahlen sowie \diamond ein beliebiger Vergleichsoperator. Unter diesen Voraussetzungen vereinbaren wir folgende Notation:

$P(\mathcal{A} \mathcal{B})$	Wahrscheinlichkeit des Ereignisses \mathcal{A} gegeben \mathcal{B}
$P(X \diamond x)$	Kurzschreibweise für $P(\{e \in \mathcal{E} X(e) \diamond x\})$
$F_X(x) = P(X \leq x)$	Verteilungsfunktion von X
$f_X(x) = \frac{d}{dx} F_X(x)$	Wahrscheinlichkeitsdichtefunktion von X

In Anlehnung an die allgemein übliche Schreibweise werden für das Wahrscheinlichkeitsmaß P und die Verteilungsfunktion F ausnahmsweise Großbuchstaben verwendet, obwohl es sich hierbei nicht um Zufallsgrößen handelt.

Werden anstelle ihrer Realisierungen die Zufallsgrößen selbst als Argumente des Wahrscheinlichkeitsmaßes P verwendet, bedeutet dies, dass die Aussage für beliebige (aber innerhalb der Gleichung gleich bleibende) Realisierungen gilt. Für die Definition der bedingten Wahrscheinlichkeit gilt somit formal

$$P(X | Y) = \frac{P(X, Y)}{P(Y)} \Leftrightarrow P(X = x | Y = y) = \frac{P(X = x, Y = y)}{P(Y = y)}.$$

Der Einfachheit halber wird obige Schreibweise im Rahmen der Arbeit gelegentlich auch für kontinuierlich verteilte Zufallsgrößen verwendet, obwohl der darin enthaltene Quotient für diese aufgrund von

$$\lim_{\epsilon \rightarrow 0} P(y - \epsilon < y \leq y + \epsilon) = 0$$

nicht definiert ist. Durch Anwendung der Regel von L'Hospital kann jedoch gezeigt werden, dass die Definition der bedingten Wahrscheinlichkeit bei Verwendung der zugehörigen Dichtefunktionen auch für kontinuierlich verteilte Zufallsgrößen Gültigkeit hat. Für $f_Y(y) > 0$ gilt somit beispielsweise

$$P(X = x | Y = y) = \frac{f_Y^{(x)}(y)}{f_Y(y)} P(X = x),$$

wobei $f_Y^{(x)}(y)$ die durch $X = x$ bedingte Wahrscheinlichkeitsdichte von Y repräsentiert. Schlussendlich sei vermerkt, dass alle bisherigen Vereinbarungen analog auch für mehrdimensionale Zufallsgrößen gelten.

Sub- und Superskripte

Die im Rahmen der Arbeit eingeführten Sub- und Superskripte dienen in erster Linie der Unterscheidung zwischen Variablen gleichen Typs, die unter unterschiedlichen Randbedingungen verschiedene Werte annehmen. Mögliche Superskripte sind die Zuordnung zu einem bestimmten Pfad, einer bestimmten Absicht, einem Haltepunkt oder einer Zufahrt, während spezifizierende Bezeichner, der jeweilige Zeitschritt und sonstige Variablen in der Regel als Subskripte geschrieben werden. Position und Reihenfolge der Sub- und Superskripte sind für jede der Variablen fest vereinbart, wobei das Weglassen eines solchen grundsätzlich auf eine andere Variable gleichen Typs hindeutet.

Symbole

Im Folgenden sind die wichtigsten Symbole der Arbeit aufgelistet. Der Übersichtlichkeit wegen wurden hierbei einige nur lokal verwendete Symbole ausgelassen und die Indizierung auf ein für das Verständnis erforderliches Minimum reduziert. Abweichend davon können die genannten Größen in den einzelnen Kapiteln mit zusätzlichen Indizes versehen werden.

Des Weiteren wird nachfolgend zu (fast) jeder Zufallsgröße das bevorzugt verwendete Symbol ihrer Realisierung angegeben, sodass dieses beispielsweise als Parameter einer Dichtefunktion ohne Nennung der Zufallsgröße selbst verwendet werden kann. Ungeachtet dessen ist es in den nachfolgenden Kapiteln mitunter erforderlich, zusätzliche lokale Symbole für unterschiedliche Realisierungen der gleichen Zufallsgröße zu vereinbaren.

Operatoren und Funktionen

$\ \mathbf{x}\ _2$	Euklidische Norm (Länge) von \mathbf{x}
$ a , \mathbf{A} , \mathcal{A} $	Betrag von a , Determinante von \mathbf{A} oder Anzahl der Elemente von \mathcal{A}
$\mathbf{A}^T, \mathbf{A}^{-1}$	Transponierte bzw. Inverse von \mathbf{A}
$\lambda(\mathcal{A})$	Lebesgue-Maß (Länge, Fläche, Volumen, ...) von \mathcal{A}
$\mathbb{1}(\bullet)$	Abbildung eines Booleschen Ausdrucks auf \mathbb{R} , mit $\mathbb{1}(\text{wahr}) = 1$ und $\mathbb{1}(\text{falsch}) = 0$

Eigenlokalisierung

X, \mathbf{x}	Position des Fahrzeugs
$\hat{X}, \hat{\mathbf{x}}$	GPS-Messung der Position
Σ	Kovarianzmatrix der Messung
$L, l \in \{S_1, S_2, \dots\}$	Das vom Fahrer verfolgte Fahrstreifensegment
$Q, q \in \mathbb{N}$	Flächenabschnitt, in dem sich das Fahrzeug befindet
$\mathcal{A}^{(q)}$	Zu q gehörende rechteckige Fläche
$\mathbf{m}^{(q)}$	Mittelpunkt der Fläche $\mathcal{A}^{(q)}$
$\mathbf{f}^{(q,l)}$	Lotfußpunkt von $\mathbf{m}^{(q)}$ auf Fahrstreifensegment l
σ_{LD}	Standardabweichung der Fahrzeugposition von der Mitte des befahrenen Fahrstreifens

Kontext

k	Aktueller Zeitschritt
t_k	Zu k gehörender Zeitpunkt
Δt	Länge eines Zeitschritts

H, h	Vom Fahrer verfolgter Pfad
O	Merkmalsvektor für die Bestimmung von h
$s^{(h)}$	Aktuelle Distanz des Fahrzeugs entlang von h
$nm^{(h)}$	Nächstes Manöver entlang von h
$s_T^{(h)}$	Distanz des nächsten Gabelungspunkts entlang von h
$s_L^{(h)}$	Distanz eines Fahrstreifenwechsels entlang von h
$\underline{s}_L^{(h)}, \bar{s}_L^{(h)}$	Beginn und Ende des Fahrstreifensegments aus h , auf dem der betrachtete Fahrstreifenwechsel stattfindet
$\hat{t}c, \hat{t}c^{(ap)}$	Schätzung der verbleibenden Zeit bis zum Erreichen des (zu Zufahrt ap gehörenden) Konfliktpunkts
ap	Zufahrt
yp	Haltepunkt
$\mathcal{AP}^{(h)}$	Für Pfad h relevante Zufahrten
$\mathcal{YP}^{(h)}$	Haltepunkte entlang von Pfad h
$\mathcal{AP}_{YP}^{(yp)}$	Zum Haltepunkt yp gehörende Zufahrten
$\mathcal{YP}_{TTC}^{(h,yp)}$	Menge der Haltepunkte entlang von Pfad h , deren $\hat{t}c$ kleiner ist als die von yp
$s_{YP}^{(h,yp)}$	Distanz von yp entlang von h

Fahrtrichtungsanzeiger

$IF = [IS, ID]$	Blinkermerkmal
IS, is	Blinkerstatus
IR, ir	Ursache des Blinkerstatus
p_T, p_L, p_R	Wahrscheinlichkeit einer beabsichtigten Blinkeraktivierung beim Abbiegen (p_T), einer beabsichtigten Blinkeraktivierung bei Fahrstreifenwechseln (p_L) oder eines unbeabsichtigten in eine bestimmte Richtung aktivierten Blinkers (p_R)
ID, s	Distanz der letzten Blinkeraktivierung
IDR, s	Distanz der letzten Blinkeraktivierung, falls der Blinker bei $s_T^{(h)}$ trotz einer beabsichtigten Geradeausfahrt aktiviert ist
$p_{R01}, p_{R10}, \Delta s_R$	Übergangswahrscheinlichkeiten und Schrittweite der der zufälligen Blinkeraktivierung zugrunde gelegten Markov-Kette

$\Delta\tilde{s}_R$	Charakteristische Weglänge der Exponentialverteilung
IDT, s	Distanz der letzten Blinkeraktivierung, falls der Blinker aufgrund eines Abbiegemanövers bei $s_T^{(h)}$ mit Absicht aktiviert wurde
μ_T, σ_T	Mittelwert und Standardabweichung der Blinkeraktivierung bezogen auf den relevanten Gabelungspunkt
IDL, s	Distanz der letzten Blinkeraktivierung, falls der Blinker aufgrund eines Fahrstreifenwechsels bei $s_L^{(h)}$ mit Absicht aktiviert wurde
μ_L, σ_L	Mittelwert und Standardabweichung der Blinkeraktivierung bezogen auf den Ort des Fahrstreifenwechsels
$\tilde{\mu}_L, \tilde{\sigma}_L$	Mittelwert und Standardabweichung der Blinkeraktivierung bezogen auf den Zeitpunkt des Fahrstreifenwechsels

Geschwindigkeitsverlauf

VF	Geschwindigkeits-Merkmal
A, a	Beschleunigung des Fahrzeugs
A_{IDM}, a_{IDM}	Beschleunigungsparameter des IDM
v	Geschwindigkeit des Fahrzeugs
v_d	Wunschgeschwindigkeit des Fahrers
δ_{IDM}	Parameter, der den Einfluss der Wunschgeschwindigkeit auf die erwartete Beschleunigung festlegt
b_{IDM}	Verzögerungsparameter des IDM
Δs_{PV}	Abstand zum Vorderfahrzeug
Δv_{PV}	Relativgeschwindigkeit zum Vorderfahrzeug
Δs_{PVd}	Angestrebter Abstand zum Vorderfahrzeug
Δs_{0IDM}	Abstand zum Vorderfahrzeug nach dem Anhalten
Δt_{IDM}	Zusätzliche Zeitlücke zum Vorderfahrzeug
\bar{a}_{lat}	Maximale Querbeschleunigung
\bar{v}_d	Maximale Wunschgeschwindigkeit
\underline{g}	Max. Abfall der Wunschgeschwindigkeit pro Weg
VP, vp	Wunschgeschwindigkeitsprofil

DP, dp	Fahrerprofil, Kombination aus Wunschgeschwindigkeitsprofil und Beschleunigungsparameter
\hat{a}	Auf Basis des Modells zu erwartende Beschleunigung
σ_A	Standardabweichung der als normalverteilt angenommenen Abweichung zwischen erwarteter und beobachteter Beschleunigung des Fahrzeugs
p_{A0}	Wahrscheinlichkeit dafür, dass die beobachtete Beschleunigung nicht durch das Modell zu erklären ist
n_{VF}	Anzahl der Zeitschritte, die für das Geschwindigkeitsmerkmal zu einer virtuellen Beobachtung zusammengefasst werden
$\hat{a}_{PV\ dp}^{(h)}$	Unter Berücksichtigung der Straßengeometrie zu erwartende Beschleunigung für das Abstandhalten zum Vorderfahrzeug
$\tilde{a}_{YP\ dp}^{(h,yp)}$	Für die Unterscheidung zwischen früher und später Annäherungsphase relevante Kenngröße
$\hat{a}_{YP\ dp}^{(h,yi)}$	Unter Berücksichtigung der Straßengeometrie zu erwartende Beschleunigung für das Anhalten am Haltepunkt
$\hat{a}_{YI\ dp}^{(h,yi)}$	Für Fahrerprofil dp , Anhalteabsicht yi und Pfad h zu erwartende Beschleunigung
$\tilde{\sigma}_A$	Angepasste Standardabweichung zur Berücksichtigung der Korrelation aufeinanderfolgender Beobachtungen

Kopfdrehung

GF	Blickrichtungs-Merkmal
Φ_H, φ_H	Kopfdrehung im Fahrzeugkoordinatensystem
$\alpha_{H0}, \alpha_{H1}, \beta_{H0}$	Parameter der Expected Gaze Points (Kopfdrehung)
$\hat{\varphi}_{HEGP}^{(h)}$	Auf Basis des Expected Gaze Points für Pfad h zu erwartende Kopfdrehung des Fahrers
σ_{HEGP}	Standardabweichung der als normalverteilt angenommenen Abweichung zwischen $\hat{\varphi}_{HEGP}^{(h)}$ und der tatsächlich beobachteten Kopfdrehung des Fahrers
p_{H0}	Wahrscheinlichkeit dafür, dass die beobachtete Kopfdrehung nicht durch das Modell zu erklären ist

n_{GF}	Anzahl der Zeitschritte, die für das Blickrichtungsmerkmal zu einer virtuellen Beobachtung zusammengefasst werden
α_{HG}	Proportionalitätskonstante zwischen Blickrichtung und Kopfdrehung
$\hat{\varphi}_{HG}^{(gd)}$	Aufgrund der Blickrichtung gd zu erwartende Kopfdrehung
σ_{HG}	Standardabweichung der als normalverteilt angenommenen Abweichung zwischen erwarteter und beobachteter Kopfdrehung des Fahrers

Blickrichtung

GD, gd	Diskretisierte Blickrichtung des Fahrers im Fahrzeugkoordinatensystem
n_{GD}	Zahl der betrachteten Blickrichtungsintervalle
$\bar{\varphi}_{GD}$	Maximaler Betrag des Blickwinkels
$\bar{\varphi}_{gd}$	Mittlenwinkel des Blickintervalls gd
$\varphi_{gd}, \varphi_{gd+1}$	Grenzwinkel des Blickintervalls gd
$\varphi_{M0}^{(m)}, \varphi_{M1}^{(m)}$	Grenzen des durch Spiegel m sichtbaren Bereichs
GM	Blickmodell, auf das die Blickrichtung des Fahrers zurückzuführen ist
ω_0	Anteil des Blickverhaltens des Fahrers, der weder der Bahnführungsaufgabe noch der Absicherung von Zufahrten zugeordnet werden kann
ω_{EGP}	Zeitlicher Anteil des Blickverhaltens, der für die Bewältigung der Bahnführungsaufgabe erforderlich ist
$\bar{\omega}_{EGP}$	Maximaler Anteil der Blicke, die auf die Bahnführungsaufgabe entfallen
v_{EGP}	Bezugsgeschwindigkeit für die Ermittlung des zur Bewältigung der Bahnführungsaufgabe erforderlichen Anteils am Blickverhalten des Fahrers
$\omega_{AP Cap}$	Anteil am Blickverhalten des Fahrers, der für die Absicherung von Zufahrten zur Verfügung steht
$\omega_{AP Req}^{(ap)}$	Bedarf an Sicherungsblicken zur Absicherung von Zufahrt ap

ttc_{AP}	Zeit bis zum Erreichen eines Konfliktpunkts, ab der ein Bedarf für Sicherungsblicke in Richtung der zugehörigen Zufahrt besteht
$\bar{\nu}_{AP}^{(ap)}$	Wichtungsfaktor, der die Notwendigkeit von Blicken auf Basis der Sichtbarkeit der Zufahrt ap bewertet
$\eta_{AP}^{(ap)}$	Wichtungsfaktor, der die Notwendigkeit von Blicken in Richtung der Zufahrt ap auf Basis des Situationsbewusstseins bewertet
$\omega_{AP}^{(ap)}$	Anteil des Blickverhaltens, der auf die Absicherung der Zufahrt ap entfällt
$\Phi_{G EGP}$	Blickrichtung des Fahrers, falls diese auf die Bahnführungsaufgabe zurückzuführen ist
$\alpha_{G0}, \alpha_{G1}, \beta_{G0}$	Parameter des Expected Gaze Points (Blickrichtung)
$\hat{\varphi}_{G EGP}^{(h)}$	Auf Basis des Expected Gaze Points für Pfad h zu erwartende Kopfdrehung des Fahrers
$\sigma_{G EGP}$	Standardabweichung der als normalverteilt angenommenen Abweichung zwischen erwarteter und beobachteter Blickrichtung des Fahrers
$\underline{v}_{AP}^{(ap)}, \bar{v}_{AP}^{(ap)}$	Minimal und maximal zu erwartende Geschwindigkeit von Verkehrsteilnehmern auf Zufahrt ap
\underline{tg}, \bar{tg}	Untere und obere Grenze der Zeitlücke zu anderen Fahrzeugen beim Durchfahren eines Haltepunkts, bei der sich der Fahrer für das Anhalten entscheidet
$\mathcal{U}^{(ap)}$	Abzusichernder Bereich auf Zufahrt ap
$\underline{u}^{(ap)}, \bar{u}^{(ap)}$	Beginn und Ende von $\mathcal{U}^{(ap)}$
$m \in \mathcal{M}$	Rückspiegel des Fahrzeugs
$\nu_{AP\ gd}^{(ap)}(u)$	Sichtbarkeit der Position u entlang der Zufahrt ap für Blicke in Richtung gd
$\nu_{DA\ gd}^{(ap)}(u)$	Sichtbarkeit der Position u entlang ap für direkte Blicke in Richtung gd
$\nu_{MA\ m}^{(ap)}(u)$	Sichtbarkeit der Position u entlang ap in Spiegel m
$\nu_{DM\ gd}^{(m)}$	Sichtbarkeit des Spiegels m für Blickrichtung gd
$\nu_{PERV\ gd}^{(i)}$	Sichtbarkeit des Blickintervalls gd in Abhängigkeit vom fokussierten Intervall i

Situationsbewusstsein

$AV^{(ap)}$, av	Sichtbarkeit der Zufahrt ap
$AO^{(ap)}$, ao	Belegung der Zufahrt ap
$AB^{(ap)}$, ab	Glaube des Fahrers daran, dass Zufahrt ap belegt ist
$AC^{(ap)}$, ac	Zuversicht des Fahrers, dass er mit seiner Einschätzung hinsichtlich der Belegung von Zufahrt ap richtig liegt
$AD^{(ap)}$, ad	Entscheidung des Fahrers, den zu Zufahrt ap gehörenden Haltepunkt (noch) nicht zu passieren
$YD^{(yp)}$, yd	Entscheidung des Fahrers, den Haltepunkt yp (noch) nicht zu passieren
$YI^{(h)}$, yi	Entscheidung des Fahrers, ob und an welchem der Haltepunkte er anhalten wird
$p_{AO}^{(ap)}$	Prior-Belegungswahrscheinlichkeit der Zufahrt ap
$\Delta t_{AP}^{(ap)}$	Mittlerer zeitlicher Abstand zweier Fahrzeuge auf ap
$\Delta \hat{t}c^{(ap)}$	Fehler der prognostizierten $\hat{t}c$ des letzten Zeitschritts
$\gamma^{(ap)}$	Anteil des kritischen Bereichs, dessen Belegungsstatus aufgrund von $\Delta \hat{t}c^{(ap)}$ ausgetauscht wird
$p_{AB01}^{(0)}$, $p_{AB10}^{(0)}$	Übergangswahrscheinlichkeiten von $AB^{(ap)}$ von einem Zeitschritt zum nächsten, falls die Zufahrt ap nicht sichtbar ist ($AV^{(ap)} = 0$)
$p_{ABC}^{(1)}$, $p_{ABW}^{(1)}$	Wahrscheinlichkeit, dass der Fahrer die tatsächliche Belegung von ap oder deren Gegenteil als seine eigene Einschätzung übernimmt, falls Zufahrt ap sichtbar ist
p_{AC}	Wahrscheinlichkeit für $AC^{(ap)} = 1$, wenn der Fahrer noch nie in Richtung der Zufahrt ap geschaut hat
$p_{AC01}^{(0)}$, $p_{AC10}^{(0)}$	Übergangswahrscheinlichkeiten von $AC^{(ap)}$ falls die Zufahrt ap nicht sichtbar ist
$p_{AC01}^{(1)}$, $p_{AC10}^{(1)}$	Übergangswahrscheinlichkeiten von $AC^{(ap)}$ falls die Zufahrt ap sichtbar ist

1 Einführung

Obwohl die Zahl der Verkehrstoten auf deutschen Straßen in den letzten Jahrzehnten ständig zurückgegangen ist und im Jahr 2013 mit 3340 Toten einen neuen historischen Tiefstand erreicht hat [1], besteht nach wie vor die Notwendigkeit, diese auch in Zukunft weiter zu reduzieren. Entsprechende Zielsetzungen kommen hierbei sowohl von europäischer Seite [2] als auch von Seiten der Bundesregierung [3]. Neben straßenbaulichen Maßnahmen und der Verbesserung des Insassenschutzes sind insbesondere auch Fahrerassistenzsysteme in der Lage, hierfür einen wesentlichen Beitrag zu leisten. Während frühe Systeme wie ABS und ESP auf die Unterstützung der Fahrzeugsteuerung beschränkt waren, existieren mittlerweile eine Vielzahl von Fahrerassistenzsystemen, die den Fahrer aktiv auf bestehende Gefahren hinweisen und es ihm dadurch ermöglichen, einen Großteil der Unfälle zu verhindern [4].

Besonders deutlich wird das Potenzial von Fahrerassistenzsystemen vor dem Hintergrund, dass 69% der Verkehrsunfälle mit Personenschaden innerorts stattfinden und dass es sich bei 61% der hierbei Getöteten um Fußgänger und Radfahrer handelt [5]. Im Gegensatz zu den Fahrzeuginsassen verfügen diese im Falle einer Kollision nur über minimale Schutzmöglichkeiten – die vollständige Vermeidung derartiger Unfälle oder zumindest die Reduktion der Kollisionsgeschwindigkeit stehen somit an oberster Stelle.

Hinsichtlich der Fahrerassistenzsysteme existieren hierbei zwei mögliche Ansätze: Das Ausgeben einer Warnung an den Fahrer, oder der direkte Eingriff in die Fahrzeugdynamik in Form eines Notbrems- oder Ausweichmanövers. Letzteres hat den Vorteil, dass das Einleiten des Eingriffs erst unmittelbar vor der drohenden Kollision erfolgt und die Unsicherheiten hinsichtlich der weiteren Bewegung der beteiligten Verkehrsteilnehmer somit auf ein Minimum reduziert werden. Gleichzeitig besteht hierbei jedoch das Problem der Produkthaftung im Falle einer Falschauslösung, so dass nur sehr zuverlässige und somit teure Sensoren zum Einsatz kommen können.

Im Gegensatz dazu besteht das Ziel der im Rahmen dieser Arbeit entwickelten Methoden darin, den Fahrer frühzeitig auf sich anbahnende Gefahrensituationen hinzuweisen. Im Folgenden werden die damit verbundenen Herausforderungen erläutert und ein Überblick über die relevante Literatur

zum Thema gegeben. Grundlage hierfür ist ein Beitrag des Autors zum „Handbuch Fahrerassistenzsysteme“ [6], aus dem ein Großteil der Ausführungen dieses Kapitels übernommen wurden. Im Anschluss daran wird der wissenschaftliche Neuwert der Arbeit gegenüber dem Stand der Technik ausgewiesen und ein Überblick über deren Aufbau gegeben.

1.1 Problemstellung

Im Gegensatz zu reinen Fahrunfällen, wie dem Abkommen von der Straße bei schlechtem Wetter bzw. nicht angepasster Geschwindigkeit, besteht die Unfallursache bei den meisten Unfällen innerorts darin, dass der Fahrer einen Verkehrsteilnehmer übersehen oder falsch eingeschätzt hat. Ein typisches Beispiel für ein derartiges Informationsdefizit ist die in Abb. 1.1 dargestellte Situation: Der Fahrer des orangen Fahrzeugs möchte rechts abbiegen und übersieht dabei den Radfahrer im toten Winkel.

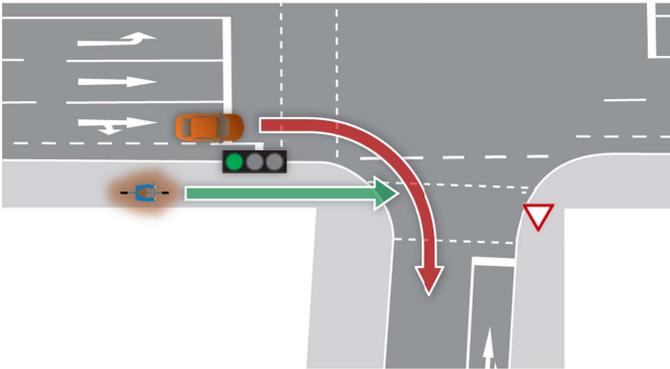


Abbildung 1.1: Rechtsabbiegen innerorts

Die Herausforderung aus Sicht eines warnenden Fahrerassistenzsystems besteht nun darin, dieses Informationsdefizit gezielt aufzulösen. Grundlage hierfür ist die Detektion der relevanten Verkehrsteilnehmer im Umfeld des Fahrzeugs. Während heutige Fahrerassistenzsysteme mangels entsprechender Sensoren in den von ihnen adressierbaren Szenarien noch sehr eingeschränkt sind, ist zu erwarten, dass sich dies zukünftig durch die Weiterentwicklung der Sensorik und die Einführung verschiedener Kommunikationstechnologien zwischen Fahrzeugen, der Straßen-Infrastruktur und zentralen Verkehrssicherheits-Servern ändern wird. Die resultierende Problematik ist

in Abb. 1.2 dargestellt: Durch die Verbesserung der Umfelderkennung kann das Fahrerassistenzsystem deutlich mehr potenzielle Konfliktsituationen vorhersagen – die Frage ist nur, ob dies dazu führen darf, dass dem Fahrer zukünftig auch deutlich mehr Hinweise und Warnungen präsentiert werden.

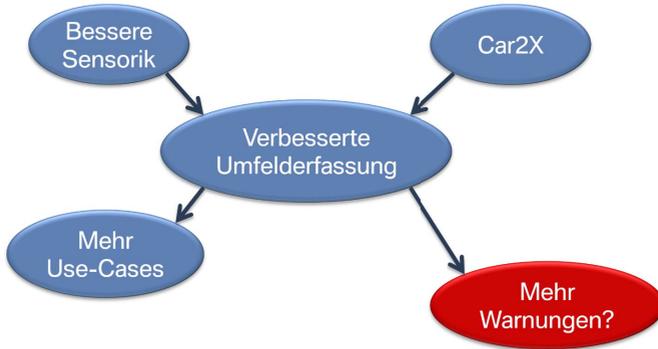


Abbildung 1.2: Herausforderung zukünftiger Fahrerassistenzsysteme

Dem entgegen stehen die Ergebnisse von Untersuchungen die belegen, dass ein Übermaß an Hinweisen und Warnungen zu einer kognitiven Überlastung des Fahrers führt und diesen sogar von der eigentlichen Fahraufgabe ablenken kann [7]. Darüber hinaus ist anzunehmen, dass sich der Fahrer bei einer Vielzahl unnötiger Warnungen von diesen gestört oder sogar in seiner Fahrkompetenz angegriffen fühlt und das System in der Folge abschaltet.

Aufgabe des Assistenzsystems ist es daher, das tatsächliche Kollisionsrisiko für jede der potenziellen Konfliktsituationen möglichst genau zu bestimmen, um auf dieser Basis über die Notwendigkeit einer Warnung zu entscheiden. Neben der aktuellen Position und Geschwindigkeit der beteiligten Verkehrsteilnehmer sind hierbei insbesondere auch die Absicht und das Situationsbewusstsein des Fahrers relevant.

1.1.1 Fahrerabsichtserkennung

Umfangreiche Untersuchungen im Fahrsimulator haben ergeben, dass Warnungen insbesondere in komplexen innerstädtischen Verkehrssituationen mindestens 2-3 Sekunden vor dem eigentlichen Konflikt ausgegeben werden sollten, um dem Fahrer eine angemessene Reaktion auf die Konfliktsituation zu ermöglichen [8]. Für eine derart lange Vorausschau ist die Prädiktion der

weiteren Bewegung des Fahrzeugs rein auf Basis seines aktuellen Bewegungszustandes oft nicht ausreichend, da der Fahrer innerhalb dieses Zeitraums den Kurs des Fahrzeugs maßgeblich beeinflusst. Ein typisches Beispiel ist die in Abb. 1.1 dargestellte Abbiegesituation: Obwohl sich aus den aktuellen Bewegungsrichtungen von Radfahrer und Fahrzeug zunächst kein Konflikt ergibt, ist dieser bei gegebener Rechtsabbiegeabsicht des Fahrers dennoch vorhanden.

Neben der des eigenen Fahrers ist mitunter auch die Absicht von anderen Verkehrsteilnehmern für die Risikobewertung relevant. In der in Abb. 1.3 links dargestellten Situation sollte der Fahrer des orangen Fahrzeugs beispielsweise nur dann auf das von links kommende graue Fahrzeug hingewiesen werden, wenn dessen Fahrer nicht gerade vor hat, rechts abzubiegen.

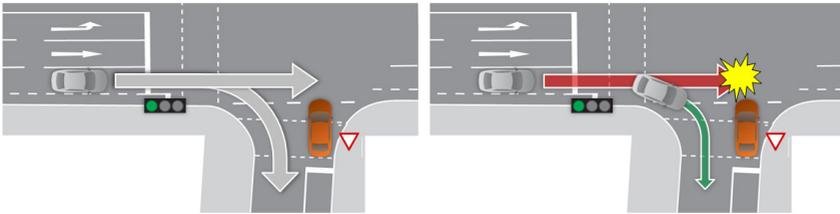


Abbildung 1.3: Herausforderungen der Fahrerabsichtsvorhersage

Die Herausforderung hierbei besteht darin, dass für die Absichtsvorhersage von anderen Verkehrsteilnehmern in der Regel deutlich weniger Merkmale zur Verfügung stehen als für die des eigenen Fahrers. Insbesondere kann nicht davon ausgegangen werden, dass der Blinkerstatus des grauen Fahrzeugs in jeder Situation beobachtet werden kann, so dass die Fahrerabsichtserkennung in diesem Fall beispielsweise auf Basis des Geschwindigkeitsverlaufs erfolgen muss. Dennoch soll der Blinkerstatus – falls beobachtbar – bei der Schätzung der Fahrerabsicht berücksichtigt werden. Darüber hinaus könnte es sein, dass das Fahrzeug weitere Informationen wie den Lenkwinkel oder die Blickrichtung des Fahrers via Funk zur Verfügung stellt. Im Hinblick auf die Entwicklung eines Verfahrens zur Fahrerabsichtsvorhersage besteht somit die Notwendigkeit, dass dieses mit einer variablen Menge beobachteter Merkmale umgehen kann.

Gleichzeitig liegt in der Situation an sich bereits ein hohes Maß an Variabilität vor: Das graue Fahrzeug könnte sich mit unterschiedlichen Anfangsgeschwindigkeiten an die Kreuzung annähern und je nach Fahrstil des Fahrers bei gegebener Abbiegeabsicht früher oder später abbremsen. Ob und wie stark dieses Abbremsen ausfällt, hängt hierbei maßgeblich von der Kreuzungsgeo-

metrie ab sowie davon, ob der Fahrer vor dem Fußgängerüberweg anhalten muss. Hinzu kommt die Interaktion mit anderen Verkehrsteilnehmern: In der in Abb. 1.3 rechts dargestellten Situation wird der Geschwindigkeitsverlauf des hinteren grauen Fahrzeugs maßgeblich durch sein Vorderfahrzeug bestimmt, so dass sein Geschwindigkeitsverlauf unabhängig von der Fahrerabsicht dem eines Rechtsabbiegers ähnelt.

Bereits in dieser verhältnismäßig einfachen Situation existiert somit eine Vielzahl von Größen, die das beobachtete Fahrerverhalten und die daraus zu ziehenden Schlüsse hinsichtlich der Fahrerabsicht beeinflussen. Dies und die Tatsache, dass sowohl von den Merkmalen des Fahrerverhaltens als auch von den Einflussgrößen oft nur ein Teil direkt beobachtbar ist, machen die Fahrerabsichtserkennung zu einem äußerst interessanten, aber auch herausfordernden Arbeitsgebiet.

1.1.2 Berücksichtigung des Situationsbewusstseins

Durch die Fahrerabsichtserkennung wird dafür gesorgt, dass der Fahrer nur auf die für seine Absicht relevanten Verkehrsteilnehmer hingewiesen wird. Darüber hinaus kann jedoch auch die Warnung vor potenziellen Konfliktpartnern, die der Fahrer selber bereits wahrgenommen hat, als störend empfunden werden. Die Situation ist prinzipiell die gleiche wie bei menschlichen Beifahrern: Während ständige Hinweise und Warnungen eher kontraproduktiv sind und im schlimmsten Fall durch Ablenkung des Fahrers sogar Gefahrensituationen herbeiführen können, beobachtet ein guter Beifahrer sowohl das Verkehrsgeschehen als auch den Fahrer und gibt Hinweise an diesen nur dann, wenn er das Gefühl hat, dass der Fahrer einen wesentlichen Aspekt der aktuellen Verkehrssituation nicht wahrgenommen hat und dass sich dadurch eine Gefährdungssituation ergibt [9].

Neben der Vermeidung unnötiger Störungen besteht unter dem Gesichtspunkt der kommunikationsbasierten Umfelderkennung noch ein weiterer Grund, die Zahl der Warnhinweise auf ein Minimum zu reduzieren: Da mit einer vollständigen Marktdurchdringung innerhalb der nächsten 20 Jahre nicht zu rechnen ist, kann allein schon prinzipiell nicht garantiert werden, dass das Assistenzsystem den Konfliktpartner in jedem Fall detektiert und den Fahrer darauf hinweisen wird. Die bspw. von Parkassistenten bekannten Gewöhnungs- und Anpassungseffekte sind daher unbedingt zu vermeiden. Auch hier gilt wieder die Analogie zum menschlichen Beifahrer, der zwar schon so manch einen Unfall verhindert hat, aber im Falle einer unterlassenen Warnung nicht für den Schaden verantwortlich gemacht werden kann.

Über seine unmittelbare Nutzung zur Unterdrückung unnötiger Warnungen hinaus stellt das Situationsbewusstsein des Fahrers auch die Grundlage seiner Interaktion mit anderen Verkehrsteilnehmern dar. Wie sich dies in konkreten Anwendungsfällen zur Erlangung eines vollständigeren Abbilds der Verkehrssituation, zur Plausibilisierung des Fahrerverhaltens und zur Vorhersage des weiteren Verkehrsgeschehens nutzen lässt, wird in Kapitel 4 ausführlich diskutiert.

1.2 Stand der Technik

Zur Bewertung des Kollisionsrisikos von Verkehrssituationen existieren bereits zahlreiche Ansätze und Methoden in der Literatur, über die im Folgenden ein möglichst systematischer Überblick gegeben werden soll. Wie in Abb. 1.4 dargestellt, kann hierbei zunächst zwischen einer reinen Prädiktion auf Basis kinematischer, dynamischer oder kartenbasierter Bewegungsmodelle, der Risikobewertung auf Basis der Fahrerabsicht sowie rein wissensbasierten Verfahren unterschieden werden.

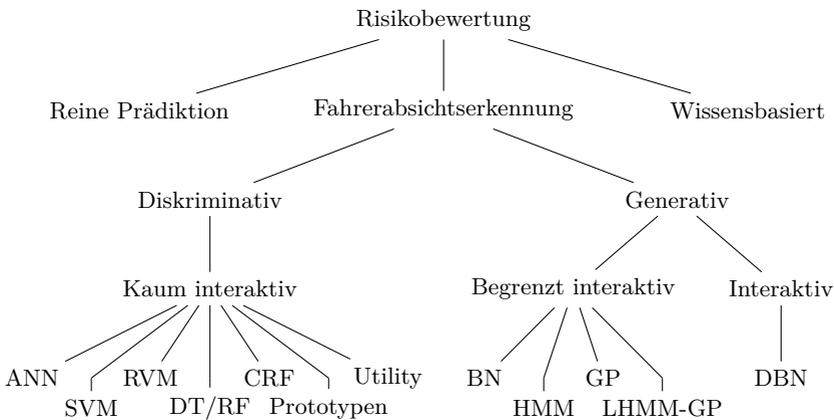


Abbildung 1.4: Bestehende Methoden der Risikobewertung

Die Risikobewertung auf Basis der Fahrerabsicht stellt die mit Abstand am häufigsten eingesetzte Methode dar. Hinsichtlich der Art der Fahrerabsichtserkennung wird daher weiterhin zwischen diskriminativen und generativen Methoden unterschieden. Die in der dritten Ebene eingeführte Gruppierung in „Kaum interaktiv“, „Begrenzt interaktiv“ und „Interaktiv“ bewertet hier-

bei die Fähigkeit der Ansätze, der in Abschnitt 1.1 beschriebenen Interaktion zwischen Verkehrsteilnehmern Rechnung zu tragen. Hierbei spielt neben der Fähigkeit der Berücksichtigung einer vorab unbekanntem Zahl von Einflüssen auf das Fahrerverhalten auch die Möglichkeit der Modellierung eines objektbezogenen Situationsbewusstseins eine Rolle. Die eigentlichen Methoden der Fahrerabsichtserkennung werden schließlich in der untersten Ebene der Taxonomie den genannten Gruppen zugeordnet.

1.2.1 Rein prädiktive Verfahren

Der Gruppe der rein prädiktiven Verfahren werden im Folgenden diejenigen Methoden zugeordnet, die ohne vorherige Bestimmung der Fahrerabsicht auskommen. Zu unterscheiden ist hierbei sowohl hinsichtlich des verwendeten Bewegungsmodells, als auch hinsichtlich der Art der Kollisionserkennung und des Umgangs mit Unsicherheiten.

Bewegungsmodelle

Typisch für rein prädiktive Verfahren ist die Verwendung dynamischer [10, 11, 12] oder auch kinematischer [13, 14, 15] Bewegungsmodelle, anhand derer die zukünftigen Trajektorien aller beteiligten Verkehrsteilnehmer bestimmt und die zugehörigen Kollisionswahrscheinlichkeiten ermittelt werden. Da das Fahrerverhalten in beiden Fällen unberücksichtigt bleibt, kann eine sinnvolle Bewertung des Kollisionsrisikos je nach Situation nur für einen sehr kurzen Vorhersagehorizont gewährleistet werden. Anwendung finden die Bewegungsmodelle somit vor allem bei Akutwarnungen und in die Fahrdynamik eingreifenden Systemen zur Kollisionsvermeidung sowie in Systemen zur Verminderung der Kollisionsfolgen. Ein typisches Anwendungsbeispiel ist in Abb. 1.5 dargestellt.

Um die Genauigkeit insbesondere bei einem Vorhersagehorizont von mehr als einer Sekunde Länge zu verbessern, wird oftmals auch die Fahrbahngeometrie im Bewegungsmodell berücksichtigt [16, 17, 18]. Grundlage hierfür ist eine hochgenaue digitale Karte der Umgebung oder zumindest die kamerabasierte Erkennung der Fahrstreifenmarkierung. Ferner wird in einigen Arbeiten auch das Fahrerverhalten als zufallsbehaftete Eingangsgröße des Systems modelliert [16, 19], um potenzielle Gefährdungen bei Kursänderung der anderen Verkehrsteilnehmer zu erkennen.

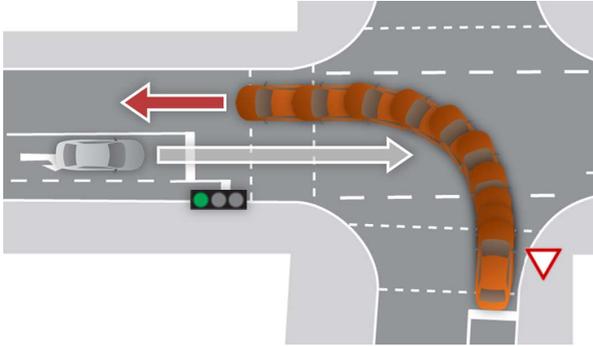


Abbildung 1.5: Prädiktion des einbiegenden Fahrzeugs mit Hilfe eines dynamischen Bewegungsmodells

Kollisionserkennung

Ein wesentlicher Bestandteil der Risikobewertung ist die Erkennung sich anbahnender Kollisionen zwischen Verkehrsteilnehmern. Eine analytische Berechnung der Kollisionspunkte wie in [10, 13] ist hierfür in der Regel nur für kinematische und dynamische Bewegungsmodelle möglich. Meist wird deshalb auf simulative Lösungen zurückgegriffen [12, 14, 15], bei denen der Bewegungszustand der Verkehrsteilnehmer in zeitlich diskreten Schritten prädiziert wird.

Zu jedem Zeitpunkt wird daraufhin die Kollisionswahrscheinlichkeit bestimmt. Anwendung finden hierbei sowohl geometrische Ansätze [20, 10, 13], die die räumliche Ausdehnung der Fahrzeuge bspw. in Form eines Rechtecks berücksichtigen und darauf abzielen, Überlappungen zwischen Fahrzeugen zu erkennen, als auch sogenannte Konfliktbereiche [21], die jeweils nur von einem Fahrzeug zur gleichen Zeit belegt werden dürfen.

Umgang mit Unsicherheiten

Ein wichtiges Unterscheidungsmerkmal für bestehende Ansätze zur Trajektorienprädiktion ist die Art, wie sie mit Unsicherheiten in der Schätzung des aktuellen Bewegungszustands sowie ihres Bewegungsmodells umgehen. Einige Ansätze vernachlässigen diese und prädizieren lediglich die jeweils wahrscheinlichste Trajektorie [15, 10], andere berechnen eine Wahrscheinlichkeitsverteilung für den Aufenthaltsort der Fahrzeuge über der Zeit. Etabliert haben sich hierfür insbesondere folgende Ansätze:

- *Rechnen mit Normalverteilungen* [12, 20, 11, 14]: Durch Annahme von normalverteilten Zufallsgrößen, wie sie bei Verwendung von Kalman-Filtern für die Objektverfolgung in der Regel ohnehin vorausgesetzt werden, können Unsicherheiten mit sehr geringem Aufwand in die Zukunft prädiziert werden. Nichtlinearitäten im Bewegungsmodell können hierbei durch entsprechende Filtererweiterungen (EKF/UKF) berücksichtigt werden. Für die Kollisionserkennung kann bspw. die Konfidenzellipse herangezogen werden [12]. Alternativ dazu wird in [20] vorgeschlagen, den minimalen Abstand zu den relevanten Konfliktpartnern wiederum als normalverteilt anzunehmen und die zugehörigen Parameter mit Hilfe der *Unscented Transformation* zu bestimmen.
- *Diskretisierung des Zustandsraums* [22]: Die Unterteilung des Zustandsraums in kleine Abschnitte erlaubt es, die Fortpflanzung der Unsicherheiten für jeden dieser Abschnitte separat durchzuführen und somit den vorhandenen Nichtlinearitäten Rechnung zu tragen. Insbesondere wird hierdurch auch die Berücksichtigung komplexerer Bewegungsmodelle und der Interaktion zwischen Verkehrsteilnehmern ermöglicht. Die Kollisionswahrscheinlichkeit wird für jede Zelle separat berechnet und im Anschluss über alle Zellen akkumuliert. Der Nachteil der Methode ist ihr vergleichsweise hoher Rechenaufwand bzw. der entstehende Diskretisierungsfehler. Bei [23] beträgt dieser bis zu 2.5 m, wenn Echtzeitbetrieb angestrebt wird.
- *Partikelbasierte Ansätze* [23, 24, 16]: Als Alternative zur Diskretisierung kann die tatsächliche Aufenthaltswahrscheinlichkeit auch durch einen Satz von Partikeln angenähert werden. Diese werden entsprechend der Wahrscheinlichkeitsverteilung des aktuellen Bewegungszustands sowie den Unsicherheiten im Bewegungsmodell zufällig gezogen und prädiziert, so dass sie jeweils einen möglichen zukünftigen Zustand des Fahrzeugs repräsentieren. Die Kollisionserkennung erfolgt für jedes der Partikel separat.

Ist für die Entscheidung des Assistenzsystems nicht die Wahrscheinlichkeit, sondern lediglich die Möglichkeit einer Kollision relevant, kann die Prädiktion auch auf Basis sogenannter Erreichbarkeitsmengen erfolgen. Diese können entweder durch die Einhüllende des erreichbaren Zustandsraums [19, 25] oder die Instanz eines *Rapidly Exploring Random Tree* (RRT) angenähert werden [26]. Anwendung finden die beiden in Abb. 1.6 visualisierten Verfahren beispielsweise bei der Absicherung automatisierter Fahrmanöver.

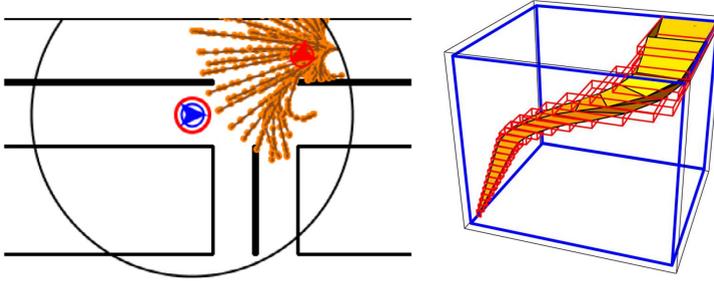


Abbildung 1.6: Charakterisierung von Erreichbarkeitsmengen durch RRT (links) und Einhüllende (rechts) [26, 25]

1.2.2 Risikobewertung auf Basis der Fahrerabsicht

Abgesehen von einigen wenigen Ausnahmen, die das Steuerverhalten des Fahrers als kontinuierliche Zufallsgröße annehmen [24, 16], ist es das Ziel der überwiegenden Anzahl von Arbeiten auf dem Gebiet, diskrete Manöver wie Fahrstreifenwechsel [27, 28, 29, 30], Überholen [31, 32], Abbiegen [33, 34, 35, 36, 37], Anhalten [38, 39] oder auch das Abstandhalten zum Vorderfahrzeug [40, 41] zu erkennen. In jüngerer Zeit ist zudem ein Trend zu beobachten, das Fahrerverhalten mit direktem Bezug zu einer hochgenauen digitalen Karte auszuwerten [42, 43, 44, 18, 45, 46], um darauf basierend die in der jeweiligen Situation möglichen Manöver zu ermitteln.

Als Merkmale für die Fahrerabsichtserkennung kommen prinzipiell eine Vielzahl von Größen in Frage. Von außen beobachtbar und somit für die Absichtserkennung von anderen Verkehrsteilnehmern verwendbar sind hierbei aber in der Regel nur die Position des Fahrzeugs, fahrdynamische Größen wie Geschwindigkeit, Längs- und Querbeschleunigung und Drehrate, sowie Kontextinformationen wie Geschwindigkeit und Abstand eines möglichen Vorderfahrzeugs. Zudem ist zu erwarten, dass zukünftig auch das mit Hilfe von Kamerasystemen beobachtete Blinkersignal für die Fahrerabsichtserkennung von anderen Verkehrsteilnehmern zur Verfügung steht. Für die Fahrerabsichtserkennung im eigenen Fahrzeug können darüber hinaus weitere Steuergößen des Fahrers wie Lenkwinkel und Pedalstellung ausgewertet werden. In den letzten Jahren ist zudem die direkte Beobachtung von Kopfdrehung, Blickrichtung und Fußstellung des Fahrers als Möglichkeit zur sehr frühen Erkennung von Fahrmanövern in den Fokus wissenschaftlicher Untersuchungen gerückt [47, 48, 37].

Eine Übersicht zu bestehenden Arbeiten auf dem Gebiet der Fahrerabsichtserkennung ist beispielsweise in [49] zu finden. Die Unterscheidung erfolgt darin hauptsächlich anhand der zu erkennenden Manöver und der verwendeten Merkmale. Im Folgenden wird ergänzend dazu ein systematischer Überblick über die bestehenden Methoden zur Fahrerabsichtserkennung gegeben.

Fahrerabsichtserkennung mit diskriminativen Methoden

Allgemein gesprochen dienen diskriminative Methoden der Unterscheidung einer Menge von Klassen anhand beobachteter Merkmale. Hierbei werden keinerlei Annahmen im Hinblick auf die statistische Unabhängigkeit der Beobachtungen getroffen, da diese durch das Anlernen mit Trainingsdaten automatisch erkannt und bei der Klassifikation berücksichtigt werden. Für die Anwendung der Manöverklassifikation werden meist folgende diskriminative Methoden angewendet:

- *Artificial Neural Networks (ANN)* [50]: Künstliche neuronale Netze repräsentieren eine der ältesten Methoden der künstlichen Intelligenz. Der bekannteste Vertreter ist das mehrlagige Perzeptron. Dieses besteht aus mehreren Lagen binärer Entscheidungsknoten, deren Aktivierung genau dann erfolgt, wenn die gewichtete Summe ihrer Eingänge einen bestimmten Schwellwert erreicht. Durch die Kaskadierung mehrerer Schichten können auch komplexe nichtlineare Entscheidungsregeln abgebildet werden. Die Gewichte der einzelnen Knoten werden hierbei auf Basis von annotierten Trainingsdaten gelernt. Hierbei ist zu beachten, dass die Modellkomplexität im Verhältnis zu der Menge der vorhandenen Trainingsdaten nicht zu hoch gewählt wird, da sonst die Gefahr der Überanpassung des Netzes besteht.
- *Support Vector Machines (SVM)* [38, 51, 52]: Bei dieser seit Ende der 90er Jahre stark verbreiteten Klassifikationsmethode wird die mehrdimensionale und i. d. R. nichtlineare Entscheidungsgrenze zwischen den Klassen durch ein Subset besonders markanter Eingangsdaten mit ihrer zugehörigen Klasse, sogenannter Supportvektoren, repräsentiert. Diese werden durch ein Optimierungsverfahren direkt aus den Trainingsdaten gewonnen. Zur Optimierung interner Parameter sind hierbei ggf. mehrere Durchläufe im Rahmen einer sog. Kreuzvalidierung erforderlich. Im Gegensatz zu künstlichen neuronalen Netzen sind SVMs sehr robust gegen Überanpassung, geben aber ebenfalls nur die wahrscheinlichste Klasse und nicht deren Eintrittswahrscheinlichkeit als Ergebnis aus.

Um dennoch eine probabilistische Vorhersage der Fahrerabsicht treffen zu können, verwenden einige Arbeiten [38, 51] einen Bayes-Filter, der die Manöverwahrscheinlichkeit unter Berücksichtigung der Sensitivität und Spezifität der SVM auf Basis der Klassifikationsergebnisse der letzten N Zeitschritte abschätzt. Die Information, wie nahe die Eingangsdaten im Einzelfall an der Entscheidungsgrenze lagen, bleibt hierbei allerdings unberücksichtigt.

- *Relevance Vector Machines (RVM)* [40, 27, 37]: Die erst 2001 von M. E. Tipping veröffentlichte Relevance Vector Machine [53] ist in ihrer Funktionsweise sehr ähnlich zu der von SVMs, gibt jedoch neben der wahrscheinlichsten Klasse auch deren Eintrittswahrscheinlichkeit aus. Die Erweiterung für die Unterscheidung von mehr als zwei Klassen ist derzeit noch ein aktives Forschungsgebiet [54].
- *Decision Trees / Random Forests (DT/RF)* [55]: Entscheidungsbäume ermitteln die zu den Eingangsdaten gehörende Klasse, indem ausgehend von der Wurzel des Baumes rekursiv bei jeder Verzweigung hinsichtlich eines Merkmals eine Entscheidung getroffen wird, bis schließlich ein mit einem Klassenlabel versehener Blattknoten des Baumes erreicht wird. Die Reihenfolge der abzufragenden Merkmale wird beim Erlernen von Entscheidungsbäumen häufig mit Hilfe informationstheoretischer Maße festgelegt. Ihrem Hauptvorteil der einfachen Interpretierbarkeit steht eine bei reellwertigen Eingangsdaten im Vergleich zu anderen Klassifikationsmethoden deutlich schlechtere Klassifikationsgüte entgegen. Dieser Nachteil kann kompensiert werden, indem statt einem einzelnen Entscheidungsbaum eine Vielzahl vereinfachter Entscheidungsbäume auf Basis einer jeweils zufälligen Untermenge der Merkmale generiert wird. Im Anschluss wird die zuzuweisende Klasse als Mehrheitsentscheidung aller Bäume gefällt. Der Vorteil der leichten Interpretierbarkeit geht hierbei allerdings verloren.
- *Conditional Random Fields (CRF)* [33]: CRFs sind ungerichtete grafische Modelle, die die statistischen Zusammenhänge zwischen den Merkmalen berücksichtigen. Im Gegensatz zu anderen diskriminativen Ansätzen kann zur Verbesserung der Generalisierbarkeit bzw. der Reduktion der benötigten Trainingsdaten bereits durch die Struktur des CRF vorgegeben werden, welche Merkmale von welchen abhängig sein können. Dieser Vorteil kommt insbesondere bei der Analyse von Zeitreihen zum Tragen, etwa bei aufeinanderfolgenden Messungen der Geschwindigkeit.

- *Prototypenbasierte Ansätze (Prototypen)* [56, 57]: Statt eines abstrakten Manövertyps kann als Fahrerabsicht auch direkt die wahrscheinlichste zukünftige Trajektorie ermittelt werden. Entsprechende Arbeiten vergleichen hierzu die aktuelle Trajektorie mit einer Vielzahl sogenannter Prototypen. Der Prototyp mit der besten Übereinstimmung wird anschließend als wahrscheinlichste Trajektorie ausgegeben. Offen ist hierbei allerdings die Frage, inwieweit der Kontext der Verkehrssituation – beispielsweise Kreuzungsgeometrie oder die Interaktion mit Vorderfahrzeugen – bei der Vorhersage der Trajektorie berücksichtigt werden kann.
- *Kostenbasierte Ansätze (Utility)* [58]: Ein sehr intuitiver Ansatz zur Fahrerabsichtserkennung besteht darin, die Plausibilität des aktuellen Fahrerverhaltens im Hinblick auf seine möglichen Ziele zu untersuchen. Hierfür werden zunächst mit Hilfe einer Kostenfunktion, einem Planungsalgorithmus und einer digitalen Karte die Kosten für das Erreichen der möglichen Ziele bestimmt. Anschließend wird untersucht, wie sich diese durch das aktuelle Fahrerverhalten verändern. Es wird angenommen, dass der Fahrer dasjenige Ziel verfolgt, dessen Kosten deutlich schneller sinken als die der anderen. Die Schwierigkeit besteht hierbei vorrangig darin, eine Kostenfunktion zu definieren, die nicht das ideale, sondern das reale Fahrerverhalten wiedergibt.

Zusammenfassend lässt sich sagen, dass diskriminative Verfahren bei geeignet gewählter Modellkomplexität und ausreichend Trainingsdaten in einfachen Verkehrssituationen sehr gut geeignet sind, die Einleitung von Fahrmanövern frühzeitig zu erkennen. Ihr Nachteil besteht darin, dass sich mit ihrer Hilfe häufig nur die wahrscheinlichste Klasse, nicht jedoch die zugehörige Eintrittswahrscheinlichkeit ermitteln lässt und nachfolgende Filterungen die tatsächliche Eintrittswahrscheinlichkeit lediglich approximieren. Dies erschwert nicht nur die Risikobewertung, sondern auch die Kombination der Ergebnisse mehrerer Klassifikatoren zur Erkennung alternativer Fahrmanöver. Hinzu kommt, dass die Merkmale als Eingangsdaten der Klassifikation bei diskriminativen Methoden fest vorgegeben sind. Für die meisten der hier vorgestellten Ansätze ist es daher problematisch, wenn zwischenzeitlich einige der Merkmale nicht beobachtbar sind – beispielsweise der von außen beobachtete Blinkerstatus anderer Fahrzeuge oder die Blickrichtung des Fahrers. Außerdem bedeutet dies, dass alle eventuell zu berücksichtigenden Einflüsse auf das Fahrerverhalten bereits in der Trainingsphase in Form von Merkmalen angelernt werden müssen. Da jedoch der Bedarf an Trainingsdaten wachsender Zahl an Merkmalen exponentiell ansteigt, kann

insbesondere der Interaktion mit anderen Verkehrsteilnehmern in komplexen Verkehrssituationen bisher nur sehr eingeschränkt Rechnung getragen werden.

Fahrerabsichtserkennung mit generativen Methoden

Generative Methoden sind dadurch gekennzeichnet, dass sie die vollständige Wahrscheinlichkeitsverteilung über alle modellierten Zufallsgrößen abbilden, und dass realitätsnahe Szenarien durch Sampling dieser Verteilung „generiert“ werden können. Wird ein Teil der Zufallsgrößen beobachtet, kann mit Hilfe der Bayes'schen Regel die Posterior-Wahrscheinlichkeit der anderen Zufallsgrößen bestimmt werden. Auf Basis der vollständigen Wahrscheinlichkeitsverteilung ist es zudem jederzeit möglich, durch Marginalisierung – also durch Aufsummieren der Wahrscheinlichkeiten von Teilereignissen – die Wahrscheinlichkeit einer beliebigen im Netz enthaltenen Zufallsgröße zu berechnen.

Für die Fahrerabsichtserkennung haben generative Methoden somit den Vorteil, dass sie zu dem wahrscheinlichsten Manöver stets auch die Eintrittswahrscheinlichkeit berechnen. Darüber hinaus sind sie sehr gut in der Lage, nur teilweise beobachtete Merkmale in die Berechnung der Manöverwahrscheinlichkeit einzubeziehen. Da jedes generative Modell eine vollständige Wahrscheinlichkeitsverteilung darstellt, können diese beliebig miteinander kombiniert werden. Im Gegensatz zu diskriminativen Methoden werden sie aus diesem Grund vorzugsweise eingesetzt, wenn zwischen mehr als zwei möglichen Manövern unterschieden werden soll [49].

Der folgende Abschnitt gibt einen Überblick über die verbreitetsten generativen Methoden auf dem Gebiet der Fahrerabsichtserkennung:

- *Bayesian Networks (BN)* [35, 41, 59, 60, 29, 46]: Bayes'sche Netze [61] nutzen gerichtete azyklische Graphen zur Repräsentation der statistischen Zusammenhänge zwischen Zufallsgrößen. Die durch die Struktur implizierten Unabhängigkeitsannahmen reduzieren die Komplexität des Modells und tragen so dazu bei, dass dieses mit weniger Trainingsdaten angelernt werden kann. Obwohl sich die Struktur auch durch die Analyse von Trainingsdaten bestimmen lässt, wird diese meist auf Basis von Expertenwissen entsprechend der kausalen Zusammenhänge zwischen den Zufallsgrößen vorgegeben. Die Parametrisierung der Knoten erfolgt daraufhin anhand von Trainingsdaten oder ebenfalls anhand von Expertenwissen.

Innerhalb eines Bayes'schen Netzes repräsentiert jeder Knoten in Kombination mit den eingehenden Kanten das Wissen über einen statistischen Zusammenhang zwischen den modellierten Zufallsgrößen. Teilmodelle können somit beliebig wiederverwendet und – im Gegensatz zu diskriminativen Methoden – sogar entsprechend der aktuellen Verkehrssituation „on-the-fly“ zusammengesetzt werden. Dies ist eine wesentliche Voraussetzung dafür, die Interaktion zwischen einer vorab unbekanntem Zahl von Verkehrsteilnehmern zu modellieren.

- *Hidden Markov Models (HMM)* [34, 32, 62]: Bei HMMs [63] handelt es sich um eine Sonderform von dynamischen Bayes'schen Netzen, bei der das Netz aus einem verborgenen Systemzustand und einer davon abhängigen, beobachtbaren Zufallsvariable besteht. Im Gegensatz zu BNs berücksichtigen sie die zeitlichen Zusammenhänge zwischen aufeinanderfolgenden Systemzuständen und können somit zur Analyse von Zeitreihen herangezogen werden. Für die Fahrerabsichtserkennung werden hierfür zunächst für jeden zu berücksichtigenden Manövertyp die Prior-, Übergangs- und Emissionswahrscheinlichkeiten ermittelt, die die zugehörigen Trainingsdaten bestmöglich erklären. Im Anschluss kann mit Hilfe der so ermittelten Parametersätze für jede neue Sequenz von Eingangsdaten die Wahrscheinlichkeit bestimmt werden, dass ein bestimmtes Manöver diese hervorbringen würde. Zur Bestimmung der Manöverwahrscheinlichkeiten können diese sogenannten Likelihoods mit den Prior-Wahrscheinlichkeiten der Manöver gewichtet und mit denen von anderen Merkmalen kombiniert werden.

Als Nachteil von HMMs gegenüber CRFs wird häufig die bei HMMs vorausgesetzte Gültigkeit der Markovbedingung angeführt. Diese besagt, dass der Folgezustand des Systems bei Kenntnis des aktuellen Zustands von allen vorangegangenen Zuständen statistisch unabhängig ist, und dass somit auch die aufeinanderfolgenden Beobachtungen gegeben dem Systemzustand voneinander unabhängig sein müssen. Im Umkehrschluss bedeutet dies, dass die Kardinalität des Zustandsknotens bei HMMs größer gewählt werden muss als bei CRFs, um die Dynamik des beobachteten zeitkontinuierlichen Signals gleich gut zu erfassen. Diesem Nachteil wirkt jedoch entgegen, dass die Berechnung der Beobachtungswahrscheinlichkeiten bei HMMs mit Hilfe des Forward-Algorithmus deutlich effizienter möglich ist als bei CRFs.

Im Hinblick auf die Berücksichtigung von Interaktion zwischen Verkehrsteilnehmern besteht der deutlich gravierendere Nachteil von HMMs darin, dass die zugrunde liegenden Modelle ähnlich wie bei

diskriminativen Verfahren als Ganzes gelernt werden. Das im Zusammenhang mit den Bayes'schen Netzen diskutierte Zusammenbauen von Modellen je nach konkreter Verkehrssituation ist daher nur begrenzt möglich.

- *Gaussian Processes (GP)* [39, 64]: Gaußprozesse stellen eine Verallgemeinerung der mehrdimensionalen Normalverteilung auf unendlich viele Dimensionen dar, die die Beschreibung der zeitlichen Entwicklung normalverteilter Zufallsgrößen mit Hilfe einer Mittelwertfunktion $m(t)$ und einer Kovarianzfunktion $k(t, t')$ erlaubt. Für die Fahrerabsichtsvorhersage erfolgt die Approximation dieser Funktionen mit Regressionsmethoden direkt auf Basis der Trainingsdaten des zugehörigen Manövers. Die Berechnung der Manöverwahrscheinlichkeit erfolgt wiederum auf Basis der Wahrscheinlichkeit, dass das jeweilige Manövermodell die Beobachtung hervorgebracht hat.

Im Vergleich zu HMMs sind GPs in vielen Fällen besser geeignet, die Dynamik kontinuierlicher Signale zu beschreiben, und können ebenso wie diese als Teil eines größeren Bayes'schen Netzes aufgefasst werden. Nachteile der Methode bestehen einerseits in ihrem vergleichsweise hohen Rechenaufwand, der kubisch mit der Zahl der Trainingspunkte ansteigt, und andererseits in der schlechten Generalisierbarkeit auf Situationen, die nicht durch die Trainingsdaten repräsentiert werden.

- *Layered-HMMs based on GPs (LHMM-GP)* [65]: Geschichtete bzw. hierarchische HMMs nutzen die Kombinierbarkeit von HMMs und GPs, um das Fahrerverhalten in unterschiedlichen Abstraktionsebenen zu beschreiben. In [65] dient die oberste Schicht der Modellierung von Übergangswahrscheinlichkeiten zwischen den Manöverarten Vorwärtsfahren, Abbiegen und Überholen. Je nach Manöverart werden in der darunterliegenden Schicht die Übergangswahrscheinlichkeiten zwischen Teilmanövern wie Abbremsen, Um-die-Kurve-Fahren und Beschleunigen abgebildet. Die konkrete Durchführung der Teilmanöver ist mit GPs modelliert.

Der Vorteil der hierarchischen Modellierung besteht ähnlich wie bei der Modellierung mit BNs darin, dass durch die stärkere Strukturierung des Modells ein effizienteres Anlernen und eine bessere Generalisierbarkeit erreicht wird. Ferner wird eine bessere Wiederverwertbarkeit der Teilmodelle erreicht, die potenziell für die Modellierung der Interaktion zwischen Verkehrsteilnehmern verwendet werden kann.

- *Dynamic Bayesian Networks (DBN)*, [28, 44, 66, 67, 68–69]: Dynamische Bayes'sche Netze kombinieren den Vorteil der Modularisierbarkeit und Kombinierbarkeit von BNs mit der von HMMs bekannten Berücksichtigung der zeitlichen Zusammenhänge zwischen Zufallsgrößen. Neben der probabilistischen Inferenz der Fahrerabsicht ermöglicht dies die Berücksichtigung des Situationsbewusstseins des Fahrers sowie die Prädiktion des weiteren Verkehrsgeschehens in Situationen mit mehreren beteiligten Verkehrsteilnehmern. Aufgrund der hohen Komplexität der resultierenden Modelle wurden DBNs bisher allerdings nur vereinzelt für die Prädiktion eingesetzt [70]. Wegen der explosionsartigen Ausdehnung des erreichbaren Zustandsraums [71] erfolgte diese auf Basis einzelner Partikel. Falls lediglich der aktuelle Zustand bzw. die Absicht des Fahrers ermittelt werden soll, kann das Verhalten der anderen Verkehrsteilnehmer in der Regel als beobachtet angenommen werden. Durch die daraus resultierenden Unabhängigkeiten verringert sich die Komplexität des Modells, so dass teilweise auch exakte Methoden zum Einsatz kommen können [68].

Die genannten Beispiele zeigen deutlich das Potenzial von generativen Methoden zur Modellierung komplexer Verkehrssituationen. Voraussetzung hierfür ist vor allem die Wiederverwendbarkeit generativer Teilmodelle, die durch Verwendung von Techniken der objektorientierten Programmierung noch verbessert werden kann [72, 29]. Als Nachteil ist die im Vergleich zu diskriminativen Methoden höhere Komplexität der Modelle zu nennen, die ein reines Lernen auf Trainingsdaten deutlich erschweren kann. Bei der Verwendung für die Fahrerabsichtserkennung wird dieser Nachteil jedoch in der Regel durch die Möglichkeit ausgeglichen, Unabhängigkeitsannahmen in Form von Expertenwissen in das Modell einzubringen.

Bewertung des Kollisionsrisikos

Ist die Fahrerabsicht bzw. die zugehörige Wahrscheinlichkeitsverteilung bekannt, kann das Risiko und somit die Notwendigkeit einer Intervention des Assistenzsystems entweder auf Basis vorgegebener Regeln oder durch Prädiktion des weiteren Verkehrsgeschehens erfolgen. Letzteres erfordert in der Regel eine hochgenaue Karte der Umgebung, anhand derer die manöverbabhängigen zukünftigen Pfade des Fahrzeugs vorhergesagt werden können [18, 42]. In einfach strukturierten Umgebungen wie auf Autobahnen und Landstraßen kann es auch ausreichend sein, die aktuelle Fahrbahngeometrie anhand der Fahrstreifenmarkierungen und dem Verhalten der umgebenden Fahrzeuge zu analysieren. Die eigentliche Prädiktion und Risikobewertung

erfolgt schließlich auf Basis eines der in Abschnitt 1.2.1 vorgestellten Verfahren oder – bei Verwendung generativer Methoden – ggf. auch auf Basis des zur Fahrerabsichtserkennung verwendeten Modells.

1.2.3 Wissensbasierte Verfahren

Unabhängig davon, ob die Fahrerabsicht zunächst explizit ermittelt wird, erfolgt die Risikobewertung bei den bisher betrachteten Methoden stets auf Basis eines Bewegungsmodells, mit dem die zukünftigen Trajektorien der relevanten Verkehrsteilnehmer präzisiert werden. Im Gegensatz dazu zielen wissensbasierte Verfahren darauf ab, Gefährdungen auf Basis der Verkehrssituation an sich zu bestimmen.

Regelsätze stellen eine sehr einfache, aber in der Praxis häufig verwendete Untergruppe der wissensbasierten Verfahren dar. Diese können sehr einfach gehalten sein, wie beispielsweise bei aktuell erhältlichen Fahrstreifenwechselassistenten: Befindet sich ein Fahrzeug im toten Winkel, liegt ein geringes Gefährdungspotential vor und der Fahrer wird unaufdringlich mit einer Leuchte im Außenspiegel darauf hingewiesen. Setzt er in dieser Situation den Blinker, ist eine Kollision bereits deutlich wahrscheinlicher und die Warnung wird bspw. durch Vibrieren des Lenkrads intensiviert. Alternative Beispiele sind die Personenwarnung auf Landstraßen oder der Hinweis, bei offensichtlicher Ermüdung des Fahrers eine Pause einzulegen. Regelbasierte Ansätze sind vor allem dann sinnvoll, wenn der Zusammenhang zwischen Risiko und relevantem Kontext einfach zu modellieren ist.

Für die Beschreibung komplexerer Zusammenhänge existieren logikbasierte Ansätze wie in [74], die in der Lage sind, Handlungspläne von Verkehrsteilnehmern zu erkennen und auf deren Basis mögliche Gefahrenquellen zu identifizieren. Alternativ kann auch eine Datenbank mit in der Vergangenheit beobachteten Verkehrssituationen herangezogen werden, um zu der aktuellen Verkehrssituation entweder das korrekte Fahrerverhalten oder die möglichen Nachfolgesituationen abzufragen [75, 76, 77]. Einen Einblick in die Funktionsweise der Methode des fallbasierten Schließens gibt Abb. 1.7.

Unter dem Gesichtspunkt der Risikobewertung besteht beim fallbasierten Schließen das Problem, dass hierfür auch Situationen erfasst werden müssen, die zu Unfällen oder Beinahe-Unfällen geführt haben und somit einen Eingriff des Assistenzsystems rechtfertigen – in der Praxis existieren hierzu nur wenige Aufzeichnungen. Darüber hinaus können aufgrund des exponentiell mit der Zahl der Merkmale wachsenden Zustandsraums nur verhältnismäßig einfache Situationen aufgelöst werden. Bei komplexeren Verkehrssituationen besteht

die Gefahr, dass wesentliche Aspekte der Verkehrssituation nicht abgebildet werden. Diesem Problem unterliegen auch die Ansätze aus [78, 79], die die zum Unfall führenden Konstellationen von Verkehrsteilnehmern direkt zu modellieren versuchen.

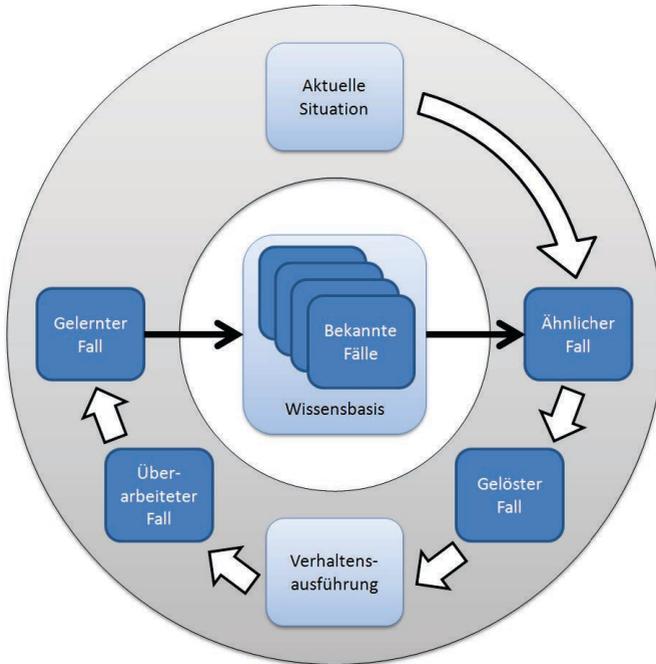


Abbildung 1.7: Verfahren des fallbasierten Schließens [73]. Hierbei wird die aktuelle Verkehrssituation anhand abstrakter Merkmale zunächst als Fall beschrieben. Aus einer Datenbank wird daraufhin ein ähnlicher Fall extrahiert und das darin hinterlegte Wissen für die Verhaltensentscheidung im aktuellen Fall herangezogen. Nach Ausführung des Verhaltens wird dieses hinsichtlich seiner Eignung für die Situation bewertet, angepasst und bei Bedarf in Form eines neuen gelernten Falls in der Datenbank abgelegt.

1.2.4 Zusammenfassung

Im Hinblick auf die in Abschnitt 1.1 definierte Problemstellung der Fahrerabsichtserkennung lassen sich somit folgende Erkenntnisse aus dem Stand der Technik festhalten:

- Eine sinnvolle Risikobewertung für warnende Fahrerassistenzsysteme ist in vielen Verkehrssituationen nur auf Basis der Fahrerabsicht möglich, da das Steuerverhalten des Fahrers innerhalb des angestrebten Prädiktionshorizonts von 2 bis 3 Sekunden einen erheblichen Einfluss auf die weitere Trajektorie des Fahrzeugs hat. Bei der direkten Risikobewertung durch wissensbasierte Verfahren besteht das Problem, dass das weitere Geschehen in innerstädtischen Verkehrssituationen von einer Vielzahl von Faktoren abhängt, die abzubilden nur auf Basis einer unrealistisch großen Menge von Trainingsdaten möglich wäre, und dass insbesondere zu dem zeitlichen Verlauf von Unfallsituationen kaum reale Messdaten verfügbar sind.
- Obwohl diskriminative Verfahren bei der Erkennung einzelner Manöver sehr gute Ergebnisse zeigen, ist es aufgrund der fehlenden Modularisierbarkeit des zugrunde liegenden probabilistischen Modells schwierig, darauf basierend mehrere alternative Manöver, nur zeitweise beobachtete Eingangsgrößen oder die Interaktion zwischen Verkehrsteilnehmern zu berücksichtigen.
- Generative Ansätze unterliegen diesem Problem nur dann, wenn sie als „Black Box“ zum Anlernen ganzer Manövermodelle (bspw. HMMs) verwendet werden. Insbesondere BNs und DBNs haben den Vorteil einer sehr guten Wiederverwendbarkeit von Teilmodellen, was der Berücksichtigung der Interaktion zwischen Verkehrsteilnehmern entgegenkommt. In der Regel wird diese mit DBNs modelliert, allerdings
- Obwohl bei generativen Modellen das Einbringen von Vorwissen und somit die Anpassung der Teilmodelle an die tatsächlich vorliegende Verkehrssituation ohne weiteres möglich ist, wird davon in bisherigen Arbeiten kaum Gebrauch gemacht. Dies hat zur Folge, dass weder die konkrete Kreuzungsgeometrie berücksichtigt wird, noch das Aufeinanderfolgen mehrerer Manöver vorhergesagt werden kann. Auch die Möglichkeit der Unterscheidung zwischen mehreren gleichartigen Manövern, beispielsweise bei zwei unmittelbar aufeinanderfolgenden Abbiegemöglichkeiten, bleibt in diesem Fall ungenutzt.

Im Gegensatz zur Fahrerabsicht wurde das Situationsbewusstsein des Fahrers im Rahmen der Risikobewertung von Verkehrssituationen bisher nur sehr selten modelliert. In der Regel wird davon ausgegangen, dass der Fahrer potenzielle Konfliktpartner übersieht, so dass bei gegebener Manöverabsicht stets eine Warnung ausgegeben wird. In Arbeiten, die das Situationsbe-

wusstsein berücksichtigen, erfolgt dies meist in der Form, dass sich durch die Existenz [27] oder die Sichtbarkeit [57, 16] eines Konfliktpartners die Wahrscheinlichkeit des risikobehafteten Manövers reduziert. Eine explizite Modellierung des Situationsbewusstseins, um auf dieser Grundlage das bisherige Fahrerverhalten erklären und zukünftige Interaktion zwischen Verkehrsteilnehmern vorhersagen zu können, wurde in keiner der betrachteten Arbeiten durchgeführt oder vorgeschlagen.

1.3 Wissenschaftlicher Neuwert

Neben der bereits vorgestellten Analyse der Problemstellung und der Systematisierung bestehender Methoden auf dem Gebiet der Risikobewertung besteht der wissenschaftliche Neuwert der vorliegenden Arbeit insbesondere in den nachfolgend genannten Beiträgen:

1. Entwicklung, Umsetzung und Evaluation einer Methode zur Fahrerabsichtserkennung in beliebigen Verkehrssituationen auf Basis von allgemeingültigen parametrischen Fahrerverhaltensmodellen.
2. Vorschlag konkreter Fahrerverhaltensmodelle für die Aktivierung des Fahrtrichtungsanzeigers, den Geschwindigkeitsverlauf in Gegenwart von Vorderfahrzeugen und die Blickrichtung des Fahrers.
3. Parametrisierung der Modelle anhand zahlreicher Probandenstudien im Realverkehr. Durch Verwendung leicht nachvollziehbarer Kenngrößen zur Beschreibung des Fahrerverhaltens lassen sich die gewonnenen Erkenntnisse ohne weiteres auch auf andere Arbeiten übertragen.
4. Analyse von Notwendigkeit und Nutzen der expliziten Modellierung des Situationsbewusstseins im Hinblick auf warnende Fahrerassistenzsysteme.
5. Prototypische Umsetzung eines entsprechenden Fahrerassistenzsystems mit Hilfe von dynamischen Bayes'schen Netzen und Nachweis des erwarteten Mehrwerts an Beispielsituationen im Realverkehr.

Darüber hinaus werden verschiedene Möglichkeiten zur Detektion verletzlicher Verkehrsteilnehmer aufgezeigt. Einen besonderen Stellenwert hat hierbei die Radfahrererkennung mit Hilfe von Smartphones, deren Potenzial anhand einer Studie zu GPS-Qualität und Übertragungslatenzen auf innerstädtischen Radwegen diskutiert wird.

1.4 Struktur der Arbeit

Die folgenden Teile der Arbeit sind wie folgt gegliedert: Kapitel 2 gibt einen Überblick zu den bestehenden Methoden der Umfelderkennung sowie eine Analyse des Potenzials von Smartphones als mobile Sensoren zur Radfahrererkennung. Die im Rahmen der Arbeit entwickelte Methode zur generischen Fahrerabsichtserkennung sowie die zugehörigen parametrischen Modelle werden in Kapitel 3 vorgestellt und erläutert, während Kapitel 4 die Notwendigkeit der Berücksichtigung des Situationsbewusstseins aufzeigt und eine beispielhafte Umsetzung auf Basis von DBNs beschreibt. Die Diskussion der Ergebnisse experimenteller Untersuchungen erfolgt für die Fahrerabsichtserkennung und die Berücksichtigung des Situationsbewusstseins separat am Ende des jeweiligen Kapitels. Schlussendlich fasst Kapitel 5 die wesentlichen Erkenntnisse der Arbeit zusammen und gibt Hinweise auf zukünftige Forschungsfelder.

2 Umfelderkennung und Detektion verletzlicher Verkehrsteilnehmer

Wie in Abschnitt 1.1 bereits dargelegt, sind die Grenzen heutiger Fahrerassistenzsysteme in erster Linie durch die Qualität und Reichweite ihrer Umfelderkennung gegeben. Dies gilt insbesondere auch im Hinblick auf die typischen Fußgänger- und Radfahrerunfälle, deren Vermeidung ein wesentliches Ziel der Arbeit darstellt. Im Anschluss an einen kurzen Überblick zum Stand der Technik wird daher diskutiert, inwieweit die Positionsdaten von Smartphones für die Detektion dieser sog. verletzlichen Verkehrsteilnehmer verwendet werden können. Grundlage hierfür sind die Ergebnisse umfangreicher Messfahrten sowie die Erfahrungen mit der prototypischen Umsetzung eines entsprechenden Systems.¹

2.1 Stand der Technik

Der folgende Abschnitt gibt einen Überblick über bestehende Sensoren zur Umfelderkennung sowie aktuelle Entwicklungen auf dem Gebiet der Fahrzeug-Fahrzeug-Kommunikation. Der Schwerpunkt liegt hierbei auf den Zielen und Methoden des vom Bundesministerium für Wirtschaft und Technologie geförderten Forschungsprojekts Ko-PER [81, 82], in dessen Rahmen die der vorliegenden Arbeit zugrunde liegenden Untersuchungen stattfanden.

2.1.1 Fahrzeuglokale Sensorik

Bereits heute können mit Hilfe von Radar-, Bild- und Ultraschallsensoren eine Vielzahl von Assistenzsystemen im Fahrzeug realisiert werden. Dass hierbei drei unterschiedliche Sensortechnologien zum Einsatz kommen, ist

¹ Die zugehörigen Ausführungen wurden größtenteils aus der früheren Veröffentlichung [80] des Autors übernommen.

durch ihre komplementären Eigenschaften zu erklären: Während Radarsensoren eine sehr gute Abstands- und sogar Geschwindigkeitsmessung von Objekten im Fahrzeugumfeld ermöglichen, liegt die Stärke von Kamerasystemen vornehmlich in ihrer hohen lateralen Auflösung und der dadurch möglichen Objektklassifikation. Durch Auswertung des optischen Flusses oder der Disparität in Stereobildern kann auch hier eine Abstandsschätzung vorgenommen werden, deren Genauigkeit mit wachsender Entfernung zum Objekt allerdings stark abnimmt. Ultraschallsensoren sind sehr preisgünstig in der Herstellung, haben jedoch nur eine geringe Reichweite und werden daher vornehmlich für Parkassistenzsysteme eingesetzt.

Zusätzlich kommen im Rahmen von Forschungsprojekten häufig auch Laserscanner zum Einsatz. Diese bieten ein sehr gutes räumliches Auflösungsvermögen, sind aber wie Kamerasysteme auf gute Sichtbedingungen angewiesen. Außerdem sind sie derzeit noch vergleichsweise teuer. Für die im Rahmen der Arbeit durchgeführten Untersuchungen wurden aktuelle BMW-Fahrzeuge der 5er-Serie eingesetzt, die zusätzlich zur Seriensensorik mit mehreren dieser Laserscanner ausgestattet waren. Abb. 2.1 zeigt schematisch die Bereiche, die mit Hilfe des Sensorsetups theoretisch abgedeckt werden können.

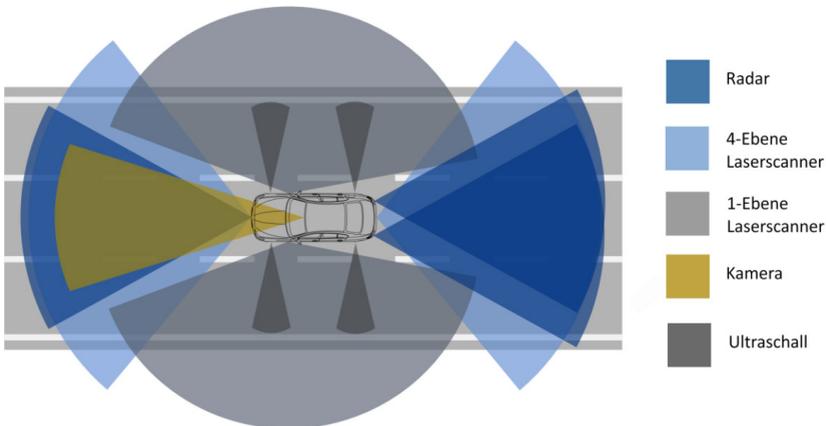


Abbildung 2.1: Sensorausstattung und Sichtbereiche der verwendeten Versuchsträger (nicht maßstabsgetreu)

Tatsächlich bereitet insbesondere die Erkennung verletzlicher Verkehrsteilnehmer in vielen Fällen noch Probleme. Neben fortschrittlichen Kamerasystemen werden daher auch transponderbasierte Systeme untersucht [83]. Diese basieren auf einer Laufzeit- und Winkelmessung zwischen dem Fahrzeug und einer

Anzahl mobiler Einheiten, die beispielsweise im Rucksack von Schulkindern verstaubt werden. Hierdurch können diese auch hinter parkenden Fahrzeugen frühzeitig erkannt werden.

2.1.2 Kooperative Perzeption

Das Ziel der kommunikationsgestützten Umfelderkennung ist es, die Schwächen der fahrzeuglokalen Sensorik insbesondere in Bezug auf Reichweite und Sichtverdeckungen durch den Austausch von Informationen zwischen den Fahrzeugen zu kompensieren. Bei Forschungsanwendungen weit verbreitet ist hierbei der WLAN-Standard IEEE 802.11p, der der direkten Kommunikation zwischen den beteiligten Verkehrsteilnehmern dient. Hierbei sind prinzipiell zwei Stufen denkbar: Während die groß angelegte Feldstudie sim^{TD} [84] lediglich den Austausch der eigenen Positions- und Geschwindigkeitsdaten betrachtet, war es das Ziel von Ko-PER, den Austausch ganzer Umfeldmodelle zu ermöglichen. Letzteres hat nicht nur den Vorteil, dass günstigere Fahrzeuge von der Sensorausstattung der Oberklassenfahrzeuge profitieren, sondern verbessert darüber hinaus auch den Schutz verletzlicher Verkehrsteilnehmer. Ein entsprechendes Beispiel ist in Abb. 2.2 dargestellt: Obwohl der Radfahrer von der hauptsächlich nach vorne gerichteten Sensorik des Linksabbiegers nicht detektiert werden kann, ermöglicht die Übertragung des Umfeldmodells des an der Ampel anhaltenden Gegenverkehrs dennoch eine frühzeitige Warnung des Linksabbiegers.

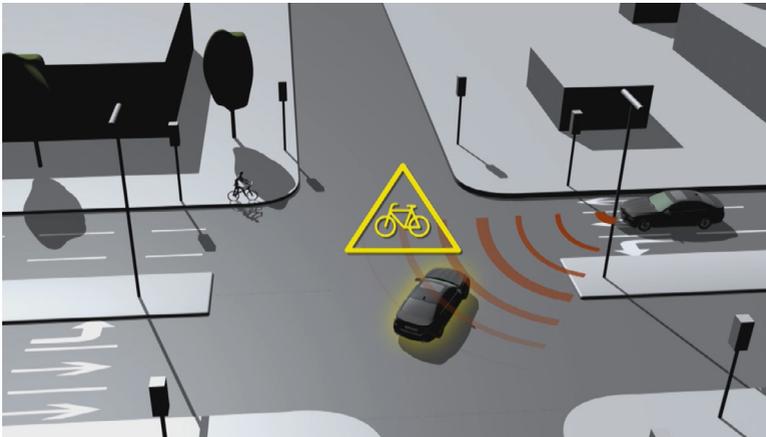


Abbildung 2.2: Kommunikation von Umfeldmodellen

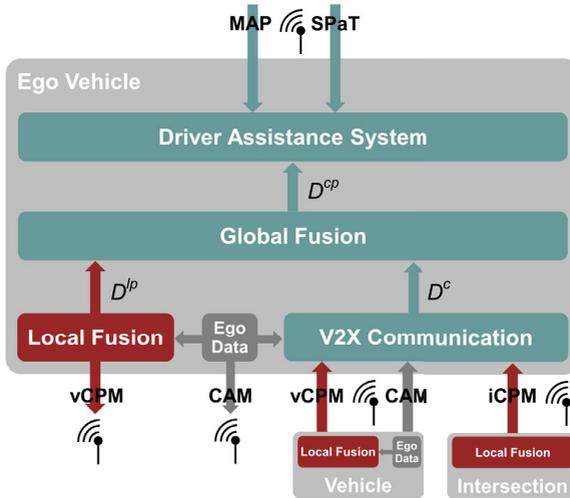


Abbildung 2.3: Architektur der kooperativen Perzeption [85]

Eine wesentliche Herausforderung besteht hierbei in der sogenannten globalen Fusion der Umfeldmodelle mehrerer Verkehrsteilnehmer. Da ein und dasselbe Objekt potenziell von mehreren Kommunikationspartnern beobachtet wird, müssen dessen Instanzen in den verschiedenen Umfeldmodellen zunächst einander zugeordnet werden. Erschwert wird dies durch den Umstand, dass sowohl Position und Orientierung der Kommunikationspartner als auch deren Umfeldmodelle fehlerbehaftet sind. Um dennoch eine korrekte Zuordnung der Objektinstanzen zu erhalten, kann beispielsweise die relative Position und Orientierung gemeinsam beobachteter Objekte als Merkmal für deren Wiedererkennung verwendet werden.

Wie in Abb. 2.3 dargestellt, wird das Ergebnis der globalen Fusion lediglich als Eingangsgröße für das lokale Fahrerassistenzsystem verwendet. Eine Weiterleitung an andere Verkehrsteilnehmer ist nicht sinnvoll, da diese sonst einige ursprünglich von ihnen stammende Informationen als unabhängige Beobachtungen interpretieren würden. Stattdessen wird das auf ein globales Koordinatensystem umgerechnete Ergebnis der lokalen Sensordatenfusion in Form sogenannter *Cooperative Perception Messages* (CPM) an andere Verkehrsteilnehmer übermittelt. Von Fahrzeugen stammende Nachrichten werden hierbei als vCPM bezeichnet, während das Umfeldmodell der Kreuzungssensorik (beispielsweise fest verbaute Laserscanner und Kameraeinheiten) als iCPM ausgesendet wird. Darüber hinaus setzen Fahrzeuge ihre eigene

Position und Geschwindigkeit als sim^{TD} -kompatible *Cooperative Awareness Message* (CAM) ab. Für die in der Kreuzung verbaute Infrastruktur sind zudem weitere Nachrichten für die Übermittlung der Kreuzungsgeometrie (Map) und der Ampelphaseninformation (SPaT) vorgesehen.

2.2 Smartphonebasierter Radfahrschutz

Das Grundproblem bei der Einführung der direkten Fahrzeug-Fahrzeug-Kommunikation über den WLAN-Standard 802.11p besteht darin, dass sich darauf basierende Assistenzfunktionen erst ab einer gewissen Marktdurchdringung sinnvoll einsetzen lassen. Dies führt zu einem Henne-Ei-Problem: Solange die Marktdurchdringung einen bestimmten Wert nicht überschreitet, gibt es für die Fahrzeughersteller aufgrund des fehlenden Kundennutzens keinen Anreiz, die Systeme einzubauen.

Eine interessante Alternative stellt die Vernetzung der Fahrzeuge über bereits bestehende Mobilfunkverbindungen dar. Bereits heute enthalten viele Fahrzeuge der Oberklasse eine SIM-Karte, um über das Internet Kartenupdates und Routeninformationen zu empfangen oder das Abrufen von E-Mails zu ermöglichen. In Fahrzeugen der Mittel- und Unterklasse hingegen werden immer häufiger Smartphones als Navigationsgeräte eingesetzt. In beiden Fällen steht die aktuelle Position und Geschwindigkeit des Fahrzeugs zur Verfügung und könnte über das Internet an andere Verkehrsteilnehmer in der Umgebung weitergeleitet werden. Im Vergleich zur Kommunikation über 802.11p hat dies die folgenden Vorteile:

- Wegfall der Einführungshürde durch Nutzung bestehender Hardware: Bereits heute besitzen 40% der Bundesbürger ein Smartphone, bei den 14- bis 29-jährigen sind es fast zwei Drittel [86].
- Möglichkeit der zentralen Datenaggregation und Auswertung, mit deren Hilfe hochaktuelle digitale Karten, Reisezeitschätzungen und individualisierte Assistenzfunktionen angeboten werden können.
- Unbegrenzte Kommunikationsreichweite zur Warnung vor lokalen Gefahren wie Unfällen und Glatteis auf Landstraßen oder dem Stauende auf Autobahnen.
- Einbeziehung von mobilen Endgeräten außerhalb von Fahrzeugen, so dass damit auch verletzte Verkehrsteilnehmer effektiv geschützt werden können.

2. Umfeldfassung

Für die Detektion verletzlicher Verkehrsteilnehmer sind vor allem der erste und letzte Punkt relevant. Allerdings kann insbesondere an eng bebauten innerstädtischen Kreuzungen oder auf Landstraßen auch die Kommunikationsreichweite eine Rolle spielen. Ist der tägliche Arbeitsweg aufgrund der Datenauswertung im Backend bekannt, erleichtert dies darüber hinaus die Absichtserkennung für die beteiligten Verkehrsteilnehmer.

Bei einer zu erwartenden Positionsunschärfe von einigen Metern ist davon auszugehen, dass ein Einsatz der Smartphone-Positionsdaten zum Fußgängerschutz zumindest in innerstädtischen Situationen nur sehr selten möglich sein wird. Der Schwerpunkt der im Folgenden beschriebenen Untersuchungen liegt daher auf dem Schutz von Radfahrern, bei denen sich die Positionsungenauigkeit aufgrund ihrer höheren Geschwindigkeit und des Umstands, dass sie meist den Radwegen folgen, deutlich weniger auswirkt.

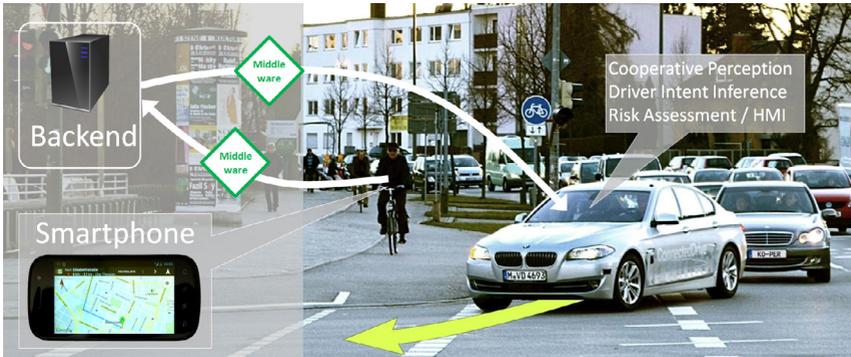


Abbildung 2.4: Schutz verletzlicher Verkehrsteilnehmer auf Basis von Smartphone-Positionsdaten

Abb. 2.4 zeigt die Funktionsweise des im Rahmen der Arbeit prototypisch umgesetzten Systems: Mit Hilfe einer Smartphone-App werden die Positionsdaten des Radfahrers über UMTS an zentralen Server übermittelt, der diese wiederum den Fahrzeugen in der Umgebung zur Verfügung stellt. Der Datenaustausch erfolgt hierbei mit Hilfe einer bei BMW entwickelten und im Rahmen von Genivi [87] veröffentlichten Middleware.

Zur Analyse des Potenzials von Smartphones für den Radfahrerschutz wird im folgenden Abschnitt die GPS-Qualität auf innerstädtischen Radwegen untersucht. Darüber hinaus beinhaltet Abschnitt 2.2.2 eine erste Abschätzung der zu erwartenden Übertragungslatenzen, während in Abschnitt 2.2.3 die wesentlichen Ergebnisse noch einmal zusammengefasst werden.

2.2.1 Untersuchungen zur GPS-Genauigkeit

Gegenstand der Untersuchungen war ein Samsung Nexus S, in dem ein Broadcom BCM4751 GPS Chip verbaut ist. Der gleiche Chip wird auch in Samsung's Galaxy S3 eingesetzt, dem in 2012 weltweit meistverkauften Smartphone [88]. Im Gegensatz zu bestehenden Studien wie [89] erfolgte die Ermittlung des Positionsfehlers nicht als Abweichung von einem vorab vermessenen Pfad, sondern mit Hilfe eines hochgenauen Referenzsystems, so dass auftretende Abweichungen nicht nur quer, sondern auch längs zur Fahrtrichtung ermittelt werden können.

Versuchsdurchführung

Der Versuchsaufbau ist in Abb. 2.5 dargestellt. Um optimale Empfangsbedingungen sowie die Unabhängigkeit von der Versuchsperson zu gewährleisten, wurde das Smartphone an der Lenkerstange des Fahrrads angebracht. Inwieweit sich die GPS-Qualität des Smartphones verschlechtert, wenn es in der Brusttasche des Radfahrers verstaut wird, war Gegenstand einer separaten Untersuchung.

Wie bereits erwähnt, erfolgte die Messdatenerfassung auf innerstädtischen Radwegen. Die konkrete Strecke ist in Abb. 2.6 dargestellt. Aufgrund gelegentlicher Ampelstopps dauerte das Abfahren der 2494 m langen Runde im Durchschnitt etwa 10 Minuten. Im Rahmen der Studie wurden 219 Runden absolviert, was einer Gesamtstrecke von 542.2 km bzw. einer Dauer von 39 Stunden entspricht. Um den Einfluss der Tageszeit auf die GPS Qualität auswerten zu können, wurde die Aufzeichnung blockweise innerhalb der in Tab. 2.1 aufgelisteten Zeitintervalle durchgeführt.

Tabelle 2.1: Messzeiten

Slot Nr.	Zeit (MEZ)
1	09:00 Uhr – 10:00 Uhr
2	10:00 Uhr – 11:00 Uhr
3	13:00 Uhr – 14:00 Uhr
4	14:00 Uhr – 15:00 Uhr
5	15:00 Uhr – 16:00 Uhr

Als Referenzsystem kam ein hochgenaues Trägerphasen-GPS von Leica zum Einsatz. Da das Smartphone vorne am Fahrrad befestigt war, die Referenzantenne jedoch in einem speziellen Rucksack auf dem Rücken getragen wurde,

2. Umfelderfassung

ist bei der Auswertung der Daten eine konstante Verschiebung von 40 cm in Fahrtrichtung berücksichtigt worden. Darüber hinaus kann die durch das Radfahren bedingte Bewegung der Antenne einen zusätzlichen Positionsfehler von bis zu 25 cm verursachen. Neben den eigentlichen Positionsdaten wurde auch die geschätzte Standardabweichung des Referenzsystems aufgezeichnet.

Während das Smartphone Positionsdaten nur mit einer Frequenz von einem Hertz bereitstellt, werden die Referenzdaten 20 mal pro Sekunde aufgezeichnet. Da sowohl das Referenzsystem als auch das Smartphone hochgenaue GPS-basierte Zeitstempel für ihre Daten zur Verfügung stellen, kann die Referenzposition zum Zeitpunkt der Smartphonemessung durch Interpolation gewonnen werden.



Abbildung 2.5: Versuchsaufbau: Das Smartphone befindet sich an der Lenkerstange, während des Referenzsystem in einem speziellen Rucksack auf dem Rücken getragen wird.

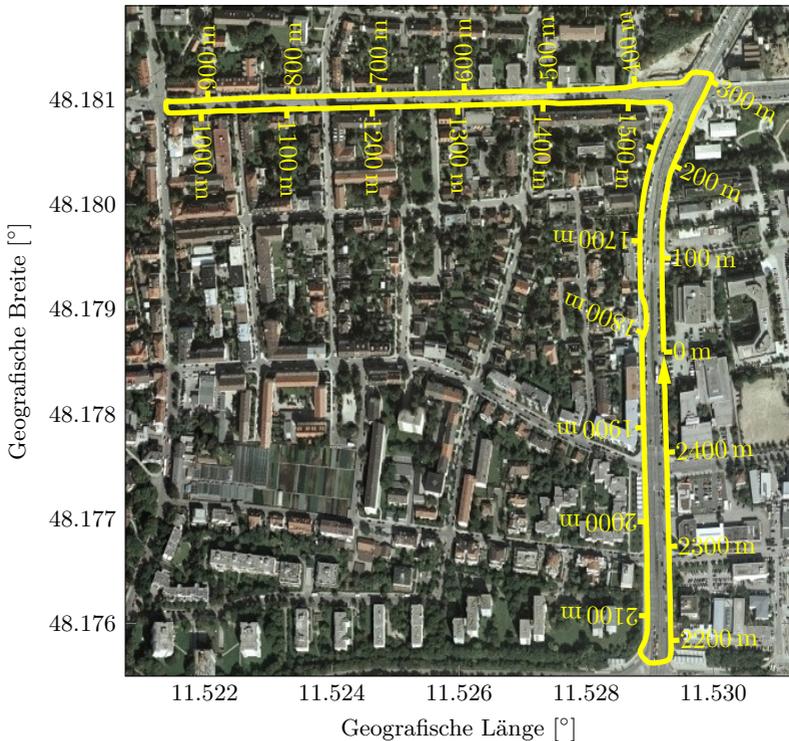


Abbildung 2.6: Strecke zur Aufzeichnung der Messdaten. Die vollständig aus Radwegen bestehende Strecke beinhaltet zwischen der 2400 m und der 100 m Marke eine Allee und zwischen 400 m und 1500 m einen Abschnitt mit sehr nahe an der südlichen Straßenseite befindlichen Häuserwänden.

Qualität der Referenzdaten

Der vollständige Datensatz umfasst 140102 Messpunkte, verteilt über einen Zeitraum von 140120 Sekunden. Dies bedeutet, dass das Smartphone während 99.99% der Zeit Positionsdaten geliefert hat. Zum Zwecke der Auswertung wurden jedoch nur Messpunkte berücksichtigt, bei denen das Referenzsystem eine Standardabweichung von weniger als einem Meter ausgegeben hat. Dies war lediglich bei 89% der Daten der Fall. Die Verteilung der geschätzten Standardabweichung des Referenzsystems innerhalb dieses reduzierten Datensatzes ist in Abb. 2.7 dargestellt. Offensichtlich bewegt sich diese bei mehr als der Hälfte der Messpunkte im einstelligen Zentimeterbereich.

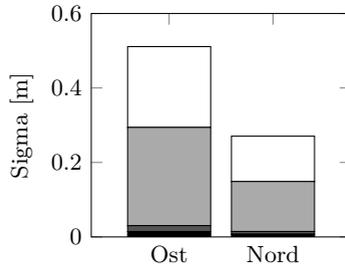


Abbildung 2.7: Geschätzte Standardabweichung der Referenzposition als 0, 25, 50, 75 und 95 % Quantil (horizontale Linien von unten nach oben)

Genauigkeit des Smartphone-GPS

Das Diagramm in Abb.2.8 zeigt die Verteilung der Abweichungen der Smartphone-Positionsdaten von denen der Referenz für die Gesamtheit der Messpunkte. Hierbei hat es den Anschein, als sei die Positionsbestimmung des Smartphones in Fahrtrichtung deutlich genauer als quer davon. Die zugehörigen 95 % Quantile liegen bei 4.68 bzw. 6.83 Metern absoluter Abweichung.

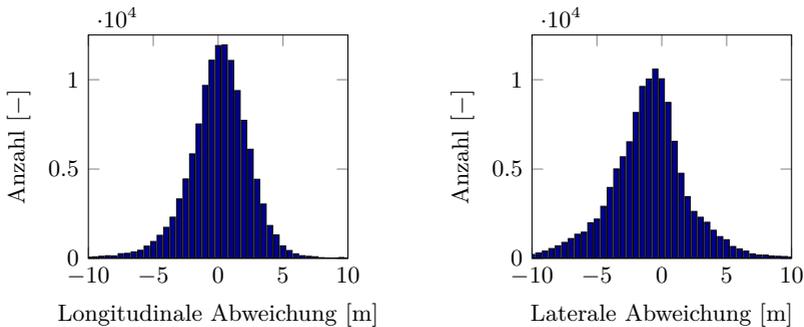


Abbildung 2.8: Verteilung der Smartphone-Positionsfehler

Positionsfehler entlang der Strecke

In städtischen Umgebungen existieren eine ganze Reihe von Faktoren, die zu einer Verschlechterung der mit dem GPS erreichbaren Positionsgenauigkeit führen können. Um den im vorangegangenen Abschnitt beobachteten Unter-

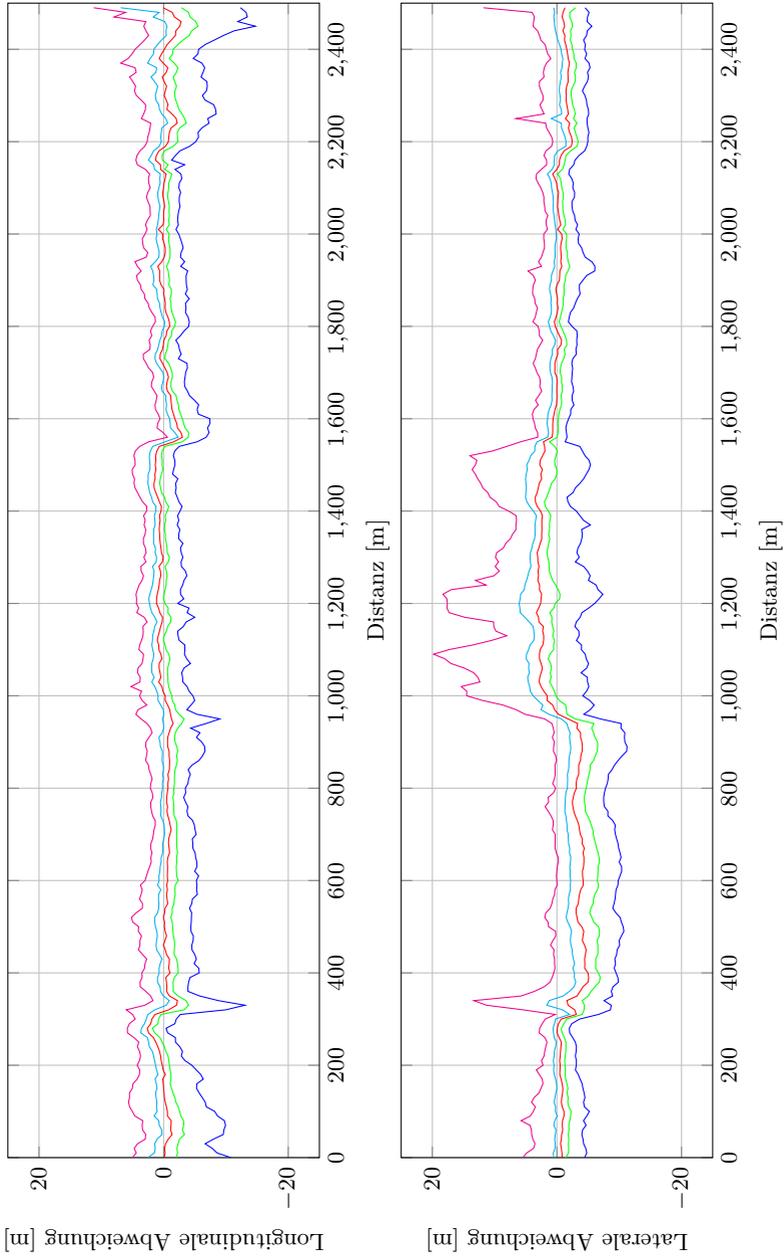


Abbildung 2.9. Abweichungen entlang der Strecke als 2.5 (blau), 25, 50, 75 und 97.5% (magenta) Quantil

schied zwischen den Fehlern längs und quer zur Fahrtrichtung zu erklären, sind diese in Abb. 2.9 über der Strecke aufgetragen.

Während der Positionsfehler in Fahrtrichtung über die gesamte Strecke hinweg eine mehr oder weniger gleichbleibende Verteilung aufweist, ändert sich die des lateralen Fehlers bei Eintritt in dem in Ost-West-Richtung orientierten Streckenabschnitt sehr deutlich. In Kombination mit der Beobachtung, dass sich das Vorzeichen des Fehlers am westlichsten Punkt der Strecke bei 950 m scheinbar umkehrt, legt dies den Schluss nahe, dass es sich hierbei um den Einfluss sog. Multipath-Effekte handelt. Diese könnten beispielsweise durch die dem Radweg sehr nahe stehenden Gebäude auf der südlichen Straßenseite verursacht werden. Da Verdeckungen und Reflektionsflächen im Allgemeinen entlang der Straße ausgerichtet sind, ist es zudem wahrscheinlich, dass Multipath-Effekte vor allem ein Problem der lateralen Genauigkeit sind.

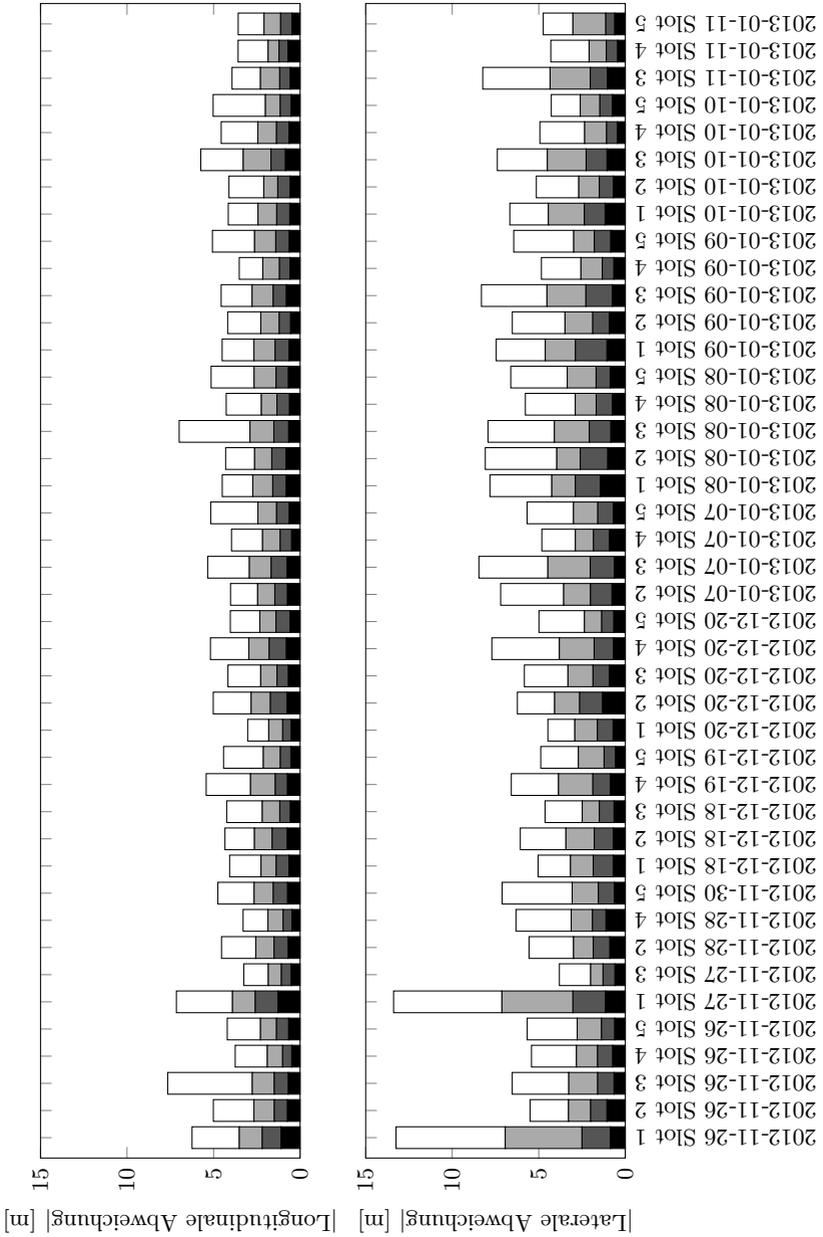
Die Allee auf dem Streckenabschnitt zwischen 2400 m und 100 m scheint dagegen vor allem einen Einfluss auf die Fehler in longitudinaler Richtung zu haben. Dies könnte auf den internen Bewegungsfiler des Smartphones zurückzuführen sein: Falls der Radfahrer an der Ampel bei 2400 m anhalten muss, wird er im darauf folgenden Streckenabschnitt tendenziell beschleunigen. Da aber die Signalstärke des GPS in diesem Abschnitt geringer ist als sonst, kann es sein, dass das Smartphone stattdessen auf sein internes CV-Modell vertraut – was im Falle einer beschleunigten Bewegung zu den beobachteten negativen Abweichungen in lateraler Richtung führen würde.

Positionsfehler je nach Messzeitpunkt

Die zeitliche Abhängigkeit der Fehler ist in Abb. 2.10 dargestellt. Auffällig ist, dass die Messfehler für das Zeitintervall 1 am 26. und 27. November 2012 erheblich größer sind als bei allen anderen Datensätzen. Da es sich hierbei um das gleiche Intervall an zwei aufeinander folgenden Tagen handelt und die restlichen 40 Datensätze deutlich geringere Fehler aufweisen, liegt die Vermutung nahe, dass die beinahe doppelt so großen Abweichungen in diesen Zeiträumen auf eine extrem ungünstige, jedoch nur selten auftretende Satellitenkonstellation zurückzuführen sind.

Qualitätsindikatoren

Für die Sensordatenfusion ist es von Vorteil, wenn neben der eigentlichen Positionsangabe auch eine Maßzahl für deren Genauigkeit vorliegt. Dazu



stellt das Smartphone gleich vier Indikatoren bereit: die Genauigkeit, den HDOP, die Zahl der verwendeten und die Zahl der insgesamt sichtbaren Satelliten. Wie aussagekräftig diese Angaben im Hinblick auf die tatsächliche Genauigkeit sind, kann anhand von Abb. 2.11 analysiert werden. Grundlage der dort dargestellten Verteilungen waren jeweils nur die Positionsmessungen, für die der jeweilige Indikator die angegebene Bedingung erfüllt. Darüber hinaus ist der Anteil der Positionsmesspunkte angegeben, der unter Einhaltung der Gültigkeitsbedingung noch verwendet werden kann.

Offenbar hat weder die Zahl der sichtbaren noch die der tatsächlich verwendeten Satelliten einen nennenswerten Einfluss auf die Messgenauigkeit.

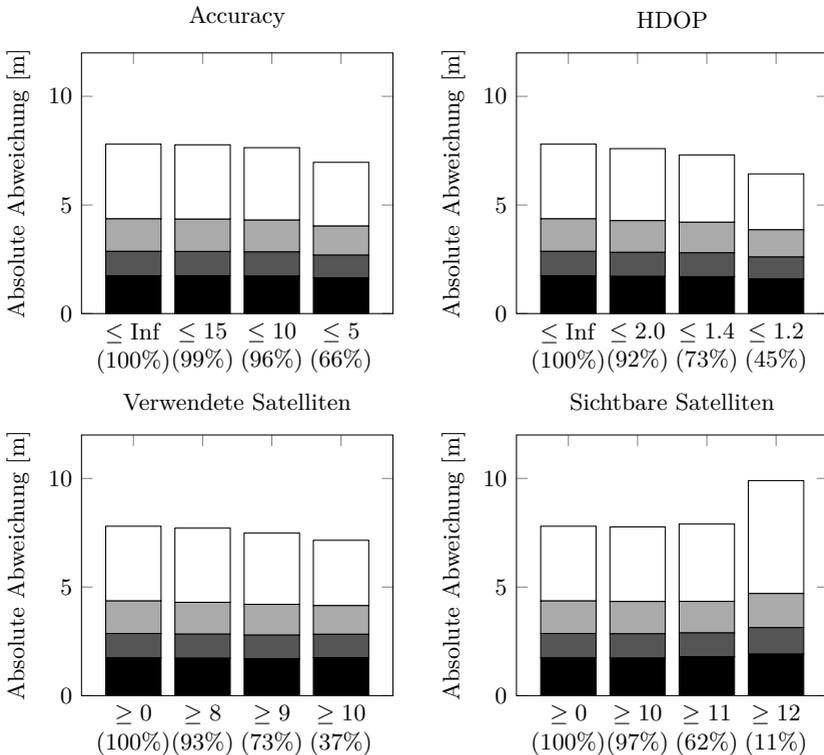


Abbildung 2.11: Fehlerverteilung bei Positionsmesspunkten in Abhängigkeit von der Gültigkeitsbedingung. Die Verteilungen sind als 0, 25, 50, 75 und 95 % Quantil in Form der horizontalen Linien angegeben. Die Zahlen in Klammern stehen für den Anteil der verwendbaren Messpunkte.

Dies könnte darauf zurückzuführen sein, dass während der Messung stets mehr als ausreichend Satelliten zur Verfügung standen. Allerdings ergibt auch die Filterung anhand der beiden anderen Qualitätsindikatoren nur eine marginale Verbesserung der Genauigkeit.

Abhängigkeit der Fehler von der Position des Smartphones

In einer Nebenstudie wurde untersucht, inwieweit sich die GPS-Qualität verschlechtert, wenn das Smartphone nicht an der Lenkerstange des Fahrrads angebracht, sondern in die Brusttasche des Radfahrers gesteckt wird. Die Untersuchungen fanden auf den ersten 100 m der Strecke während der Zeitintervalle 1–4 statt. Um den Einfluss der Satellitenkonstellation auf das Ergebnis des Vergleichs zu reduzieren, wurde das Smartphone in jedem der Intervalle zunächst 15 Minuten in der Brusttasche getragen und danach für 15 Minuten am Lenkrad befestigt. Die resultierenden Fehlerverteilungen sind in Abb. 2.12 dargestellt.

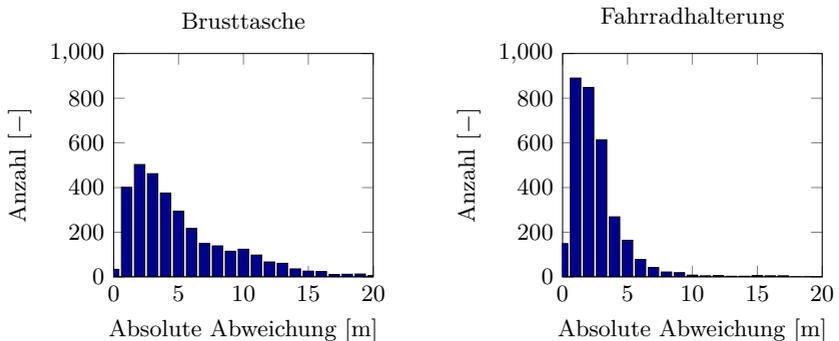


Abbildung 2.12: Messfehler in Abhängigkeit von der Smartphoneposition

Offensichtlich sind mit dem Einstecken des Smartphones in die Brusttasche erhebliche Einbußen des GPS-Empfangs verbunden.

2.2.2 Untersuchungen zur Übertragungslatenz

Da sowohl auf dem Smartphone als auch im Fahrzeug eine hochgenaue GPS-basierte Zeitbasis zur Verfügung steht, können Übertragungslatenzen durch Prädiktion mit einem CV-Modell in den meisten Fällen kompensiert werden. Relevant werden diese nur, wenn sich die zu erwartende Trajektorie des

Radfahrers beispielsweise durch Bremsen oder Abbiegen ändert. In diesem Fall kann die Übertragungslatenz zu Falsch- und Fehlwarnungen des darauf basierenden Fahrerassistenzsystems führen.

Um eine Vorstellung von den zu erwartenden Latenzen zu bekommen, wurden diese während einer Erprobung der Radfahrerschutzfunktion in der in Abb. 2.4 dargestellten Situation aufgezeichnet. Durchgeführt wurde diese an der Kreuzung Hanauer Str. / Dessauer Str. (100 m-Wegmarke in Abb. 2.6), wobei sowohl der Radfahrer als auch das Fahrzeug ständig in Bewegung waren. Insgesamt wurden 39 Rechtsabbiegemanöver aufgezeichnet. Die Internetanbindung des Fahrzeugs erfolgte hierbei lediglich mit Hilfe eines im Fahrzeuginnenraum angeschlossenen 3G HSDPA USB Sticks. Abb. 2.13 zeigt die beobachtete Verteilung der Übertragungslatenzen.

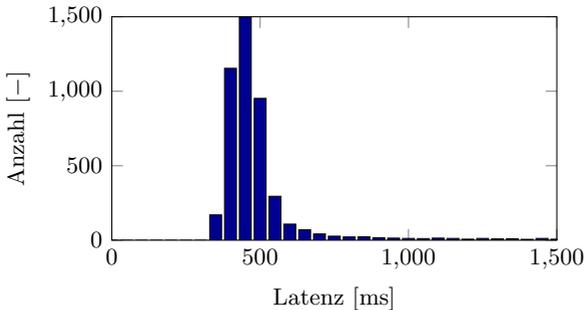


Abbildung 2.13: Beobachtete Übertragungslatenzen vom Smartphone zum Fahrzeug unter Nutzung eines 3G HSDPA USB Sticks

Zu beachten ist hierbei, dass der verwendete Server keine andere Aufgabe hatte, als die Positionsdaten des Smartphones weiterzuleiten – in der Praxis würde zusätzlich noch die Latenz des Servers hinzukommen. Andererseits besteht auch noch ein großes Verbesserungspotenzial hinsichtlich der Internetverbindung – Untersuchungen mit der neuesten Mobilfunkgeneration LTE haben ergeben, dass hiermit Latenzen von unter 100 ms möglich sind [90, 91]. Die praktische Herausforderung besteht derzeit vor allem darin, die durch die periodisch versendeten Positionsnachrichten resultierende Netzwerklast durch eine geschickte Kommunikationsarchitektur (bspw. unter Nutzung von Broadcasting und Geofiltering) auch in Ballungszentren und zur Hauptverkehrszeit handhabbar zu halten [91].

2.2.3 Zusammenfassung und Ausblick

Die in Abschnitt 2.2.1 vorgestellten Ergebnisse zeigen, dass die Position des Radfahrers in 95% der Fälle genauer als 4.68 m längs und 6.83 m quer zur Fahrtrichtung bestimmt werden kann. Obwohl eine fahrstreifen-genaue Lokalisierung bei dieser Genauigkeit nur mit einer beträchtlichen Irrtumswahrscheinlichkeit möglich ist, kann unter Berücksichtigung der Prior-Wahrscheinlichkeit in vielen Situationen dennoch eine Aussage zum wahrscheinlichsten zukünftigen Pfad des Radfahrers getroffen werden. Beispielsweise ist es bei einer innerstädtischen Hauptstraße sehr wahrscheinlich, dass der Radfahrer dem Radweg entlang der Straße folgt. Ist der Pfad bekannt, reduziert sich die Positionsungenauigkeit mittels Map-Matching auf ihre Komponente längs der Fahrtrichtung.

Neben der Fahrerabsicht sind für die Entscheidung über die Notwendigkeit einer Warnung in der in Abb. 2.4 dargestellten Situation insbesondere die Zeiten t_{Car} und t_{Bicycle} , an denen das Fahrzeug bzw. der Radfahrer am potenziellen Konfliktpunkt eintreffen, relevant. Beispielsweise könnte eine Warnung ausgegeben werden, wenn der Schätzwert \hat{t}_{Car} der verbleibenden Zeit bis zum Konfliktpunkt drei Sekunden unterschreitet und die Differenz $\hat{t}_{\text{Car}} - \hat{t}_{\text{Bicycle}}$ innerhalb des Intervalls $[-3\text{ s}, 2\text{ s}]$ liegt. Unter der Annahme, dass sich das Fahrrad mit 21.6 km/h fortbewegt und die Geschwindigkeit des Radfahrers wie auch die Zeit \hat{t}_{Car} jeweils mit einer Standardabweichung von 10% ihres tatsächlichen Werts bestimmt werden können, ergibt sich unter der Berücksichtigung der in Abb. 2.8 visualisierten Positionsfehler des Smartphones die in Abb. 2.14 dargestellte Wahrscheinlichkeit, dass das System bei einer gegebenen tatsächlichen Zeitdifferenz $t_{\text{Car}} - t_{\text{Bicycle}}$ eine Warnung ausgibt.

Anhand von Abb. 2.14 ist zu erkennen, dass die Güte der Smartphone-Positionsdaten unter den getroffenen Annahmen ausreicht, um mit hoher Wahrscheinlichkeit die korrekte Entscheidung hinsichtlich der Notwendigkeit der Warnung zu treffen. Innerhalb des spezifizierten Intervalls wurde mit 91%-iger Wahrscheinlichkeit eine Warnung ausgegeben, in sehr kritischen Situationen mit Zeitlücken zwischen -2 s und 1 s sogar mit mehr als 99%-iger Wahrscheinlichkeit. Andererseits wurden nur 8% der Warnungen außerhalb des spezifizierten Intervalls ausgegeben, und nahezu keine Warnungen bei Zeitdifferenzen außerhalb von $[-4\text{ s}, 3\text{ s}]$.

Wie die Auswertung der GIDAS-Datenbank [92] zeigt, ist die betrachtete Rechtsabbiegen-Situation eine der drei Situationen, die am häufigsten zu Fahrradunfällen führen. Bei den beiden anderen Situationen kommt das

Fahrzeug aus der Nebenstraße, während der Radfahrer dem Radweg der Hauptstraße entweder in oder entgegen der Verkehrsrichtung folgt. Aufgrund ihrer Ähnlichkeit zu der oben betrachteten Situation kann auch bei diesen davon ausgegangen werden, dass die GPS-Qualität des Smartphones für die Realisierung einer zuverlässigen Warnfunktion ausreicht. Dies bestätigt die ursprüngliche Annahme, dass bereits heutige Smartphones das Potenzial haben, einen wesentlichen Beitrag zur Sicherheit von Radfahrern zu leisten.

Ein verbleibendes Problem besteht in der starken Verschlechterung der Qualität der Smartphone-Positionsdaten, wenn dieses nicht am Lenker angebracht, sondern in die Jackentasche gesteckt wird. Durch die rapide Entwicklung des Smartphone-marktes und die herausragende Bedeutung von ortsbasierten Diensten besteht jedoch Grund zur Annahme, dass dieses Problem schon bald, möglicherweise sogar durch den bereits am Markt verfügbaren Nachfolgechip BCM4752 [93], behoben wird.

Hinsichtlich der Übertragungslatenzen können aus den im Rahmen der Arbeit angestellten Untersuchungen zwar keine belastbaren Aussagen getroffen werden, jedoch finden sich in der Literatur Hinweise darauf, dass eine flächendeckende Kommunikation der Verkehrsteilnehmer über LTE durchaus möglich wäre [90, 91]. Alternativ bestehen Bestrebungen, Smartphones mit zusätzlicher Hardware zur Kommunikation über den WLAN Standard 802.11p auszustatten [94]. In beiden Fällen ist damit zu rechnen, dass Smartphones zukünftig auch zum Schutz verletzlicher Verkehrsteilnehmer eingesetzt werden.

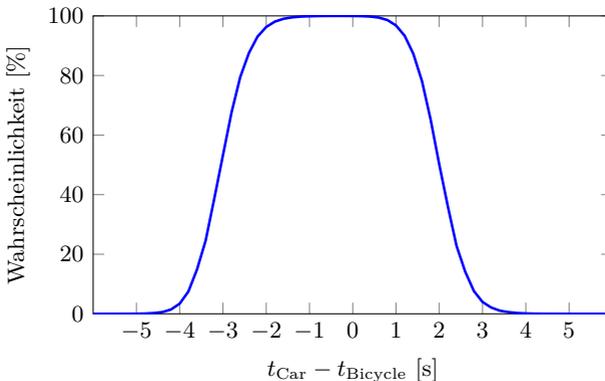


Abbildung 2.14: Wahrscheinlichkeit einer Warnung bei gegebener Zeitlücke $t_{\text{Car}} - t_{\text{Bicycle}}$ zwischen Fahrzeug und Fahrrad

3 Fahrerabsichtserkennung auf Basis allgemeingültiger parametrischer Modelle

In diesem Kapitel wird eine Methode zur Fahrerabsichtserkennung vorgeschlagen, bei der im Gegensatz zur überwältigenden Mehrheit der in Abschnitt 1.2 vorgestellten Ansätze nicht abstrakte Manövertypen, sondern konkrete Fahrwege erkannt und vorhergesagt werden. Dies ermöglicht einerseits die Unterscheidung alternativer Fahrmanöver gleichen Typs, andererseits kann dadurch auch Fahrerverhalten, das von Manöverkombinationen herrührt, korrekt interpretiert werden. Darüber hinaus kann mit Hilfe der vorgeschlagenen Methode den in Abschnitt 1.1.1 identifizierten Einflüssen auf das Fahrerverhalten Rechnung getragen werden. Insbesondere die Berücksichtigung von Vorderfahrzeugen sowie der konkreten Kreuzungsgeometrie stellen hierbei einen wesentlichen Vorteil gegenüber fast allen bestehenden



Abbildung 3.1: Wahrscheinlichste Pfade durch die Kreuzung. Breitere Pfeile repräsentieren höhere Belegungswahrscheinlichkeiten.

Arbeiten dar. Hinzu kommt, dass die Berechnung der Wahrscheinlichkeiten für mögliche Fahrwege durch die Verwendung eines generativen Modells sehr flexibel hinsichtlich der Menge der aktuell beobachtbaren Merkmale ist.

Grundlage der folgenden Abschnitte sind die bereits veröffentlichten Arbeiten [95], [96] und [97] des Autors. Abschnitt 3.1 gibt hierbei zunächst einen Überblick über die Repräsentation und Bewertung bestehender Handlungsalternativen. In den Abschnitten 3.2, 3.3 und 3.4 werden daraufhin die verwendeten Fahrerhaltensmodelle vorgestellt. Abgeschlossen wird das Kapitel durch die Bewertung der Vorhersagequalität in Abschnitt 3.5.

3.1 Vorhersage des zukünftigen Fahrwegs

Bei der Vorhersage von Fahrwegen anstelle abstrakter Manöver besteht das Problem, dass grundsätzlich unendlich viele Pfade als Fahrerabsicht in Frage kommen. Eine Möglichkeit, dennoch zu einer in Echtzeit lauffähigen Lösung zu kommen, besteht in der Diskretisierung der Handlungsalternativen unter Ausnutzung der Tatsache, dass die Bewegung der Verkehrsteilnehmer meist entlang vorgegebener Fahrstreifen erfolgt. Durch die Unterteilung der Fahrstreifen in Abschnitte endlicher Länge können alternative Fahrwege somit als Folge belegter Fahrstreifensegmente aufgefasst werden. Ein mögliches Resultat der darauf basierenden Fahrerabsichtserkennung ist die in Abb. 3.1 dargestellte Belegungswahrscheinlichkeit der Fahrstreifensegmente.

Die grundsätzliche Vorgehensweise bei der Vorhersage der Fahrerabsicht ist in Abb. 3.2 dargestellt: Ausgehend von der aktuellen Position des Fahrzeugs sowie der zugehörigen Messunsicherheit wird zunächst die Wahrscheinlichkeit berechnet, dass sich das Fahrzeug auf dem linken oder rechten Fahrstreifensegment befindet, sowie die bereits zurückgelegte Wegstrecke auf diesem Segment. Anschließend werden die möglichen zukünftigen Fahrwege des Fahrzeugs als Folge belegter Fahrstreifensegmente bis zu einem vorgegebenen Vorausschauhorizont ermittelt. Die mit der zurückgelegten Strecke zunehmende Verzweigung der Pfade wird hierbei für jede der Lokalisierungslösungen durch einen sogenannten Hypothesenbaum abgebildet. Jeder Blattknoten repräsentiert somit genau einen möglichen Pfad. Anschließend werden diese anhand der beobachteten Merkmale hinsichtlich ihrer Eintrittswahrscheinlichkeit bewertet.

Eine detaillierte Beschreibung der einzelnen Teilschritte erfolgt in den nachfolgenden Abschnitten.

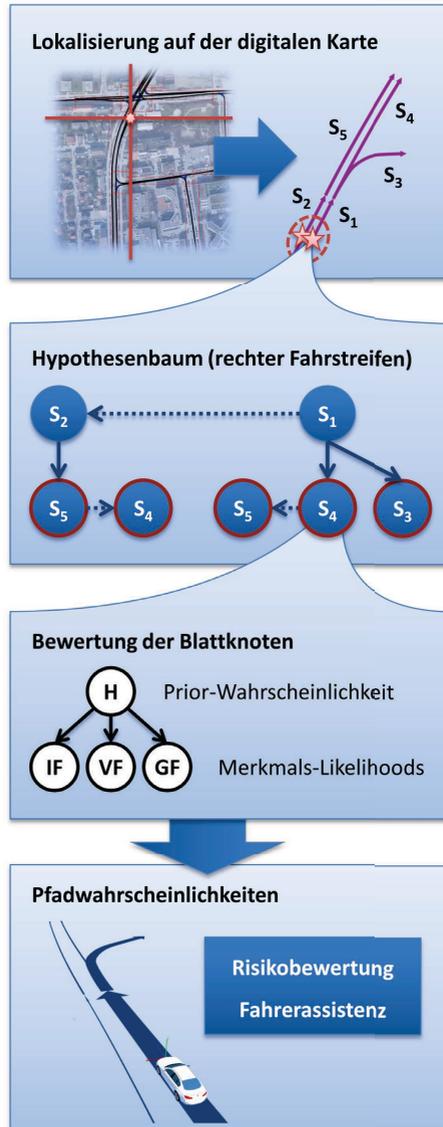


Abbildung 3.2: Methodik zur Vorhersage des zukünftigen Fahrwegs

3.1.1 Lokalisierung auf der digitalen Karte

Grundlage der Eigenlokalisierung ist neben der Positionsangabe des Fahrzeugs und der zugehörigen Messunsicherheit auch eine hochgenaue digitale Karte der Umgebung. Die darin enthaltenen Fahrstreifensegmente könnten beispielsweise durch ihre aus Satellitenbildern extrahierten Fahrstreifenmarkierungen repräsentiert werden. Da diese jedoch gerade im Kreuzungsbereich häufig nicht vorhanden sind, wurde im Rahmen der Arbeit auf eine eigene digitale Karte zurückgegriffen, bei der die Lage der Fahrstreifen durch Mittelung der GPS-Spuren von einer Vielzahl von Kreuzungsüberfahrten mit einem hochgenauen GPS-System bestimmt wurde. Ein Beispiel einer solchen Karte ist zusammen mit den GPS-Spuren der zugrunde liegenden Kreuzungsüberfahrten in Abb. 3.3 dargestellt.

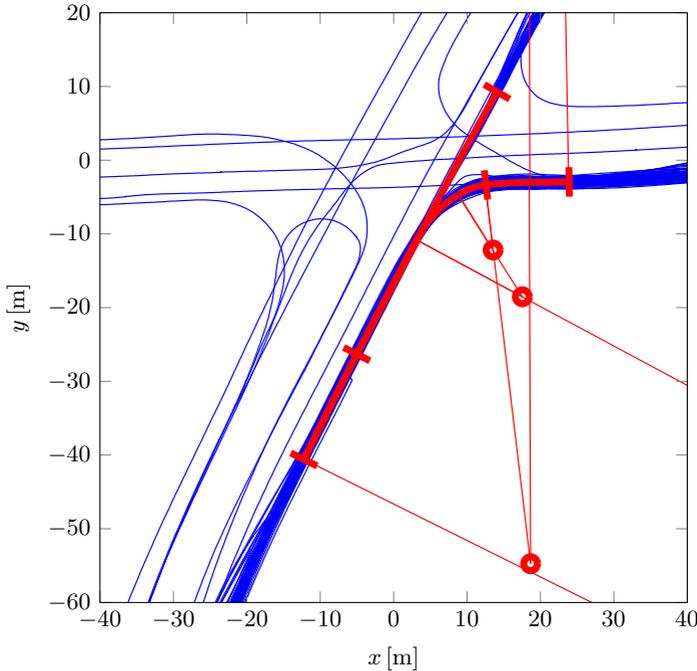


Abbildung 3.3: Kreuzungsüberfahrten und Kreisbogensplines

Der Verlauf des mittleren Pfades wird hierbei mit Hilfe glatter Kreisbogensplines beschrieben. Im Gegensatz zu der beispielsweise vom OSM-Format

verwendeten Polyline-Darstellung haben glatte Kreisbogensplines eine Reihe von Vorteilen:

- Die Abbildung von kartesischen Koordinaten auf die Koordinaten des Kreisbogensplines ist rechentechnisch sehr effizient umsetzbar.
- Bei einer vergleichsweise geringen Zahl von Parametern kann eine hohe Genauigkeit der Repräsentation erreicht werden.
- Die Abbildung eines glatten Pfades ist wiederum glatt sowohl in der Distanz als auch in der Querablage vom Kreisbogenspline.
- Die Krümmung des Pfades kann anhand des Radius der hinterlegten Kreisbögen auf triviale Weise bestimmt werden.

Nachteilig ist zu nennen, dass die Erzeugung glatter Kreisbogensplines aus einem Polygonzug mathematisch recht kompliziert ist. Ein effizienter Algorithmus wird beispielsweise in [98] beschrieben.

Obwohl die Position des Fahrzeugs sehr effizient auf die Kreisbogensplines der digitale Karte abgebildet werden kann, stellt die Transformation der zugehörigen Messunsicherheit eine nicht zu vernachlässigende Herausforderung dar. Die in Ko-PER untersuchten Methoden zur Positionsbestimmung, beispielsweise transponderbasierte Ortung, Lokalisierung mit Laserscanner-Landmarken oder Tightly-Coupled-GPS, weisen Genauigkeiten zwischen einigen Zentimetern bis hin zu 2 bis 3 Metern auf, so dass der aktuell belegte Fahrstreifen nicht in jedem Fall zweifelsfrei bestimmt werden kann. Daher ist es erforderlich, die als normalverteilt angenommene Likelihood der Positionsmessung $P(\hat{X}_k = \hat{\mathbf{x}}_k | X_k)$ in Abhängigkeit von der gemessenen Position $\hat{\mathbf{x}}_k$ und der zugehörigen Kovarianzmatrix Σ_k auf probabilistische Fahrstreifenzuordnungen $P(L_k | \hat{X}_k = \hat{\mathbf{x}}_k)$ abzubilden.



Abbildung 3.4: Probabilistisches Modell für die Eigenlokalisierung

Das probabilistische Modell für die Eigenlokalisierung ist in Abb. 3.4 dargestellt. Hierbei steht $L_k \in \mathcal{M} = \{S_1, S_2, \dots\}$ für das Fahrstreifensegment, auf dem sich das Fahrzeug aktuell befindet, X_k für dessen exakte Position und \hat{X}_k für die aktuelle Positionsmessung. Die Prior-Wahrscheinlichkeit der

Fahrstreifenzuordnung $P(L_k)$ wird als proportional zur Länge des Fahrstreifensegments angenommen, während für die Likelihood der Positionsmessung $P(\hat{X}_k = \hat{\mathbf{x}}_k | X_k)$ eine zweidimensionale Normalverteilung mit der Dichtefunktion

$$f_{\hat{X}_k}^{(\mathbf{x})}(\hat{\mathbf{x}}_k) = \frac{1}{2\pi \sqrt{|\Sigma_k|}} \exp \left[-\frac{1}{2}(\hat{\mathbf{x}}_k - \mathbf{x}_k)^T \Sigma_k^{-1} (\hat{\mathbf{x}}_k - \mathbf{x}_k) \right] \quad (3.1)$$

vorausgesetzt wird. Im Gegensatz dazu ist die Aufenthaltswahrscheinlichkeit des Fahrzeugs $P(X_k = \mathbf{x} | L_k = l)$ bzw. die zugehörige Dichtefunktion $f_{X_k}^{(l)}(\mathbf{x})$ abhängig von der Geometrie des von ihm verfolgten Fahrstreifensegments l . Hierbei wird angenommen, dass der laterale Abstand des Fahrzeugs als normalverteilt mit dem Mittelwert null und der Standardabweichung σ_{LD} modelliert werden kann, während die Position entlang des Fahrstreifensegments gleichverteilt ist. Die Likelihood der Positionsmessung und die Aufenthaltswahrscheinlichkeitsdichte des Fahrzeugs sind in Abb. 3.5 in Abhängigkeit von der tatsächlichen Fahrzeugposition \mathbf{x} für ein festes $\hat{\mathbf{x}}_k$ beispielhaft dargestellt.

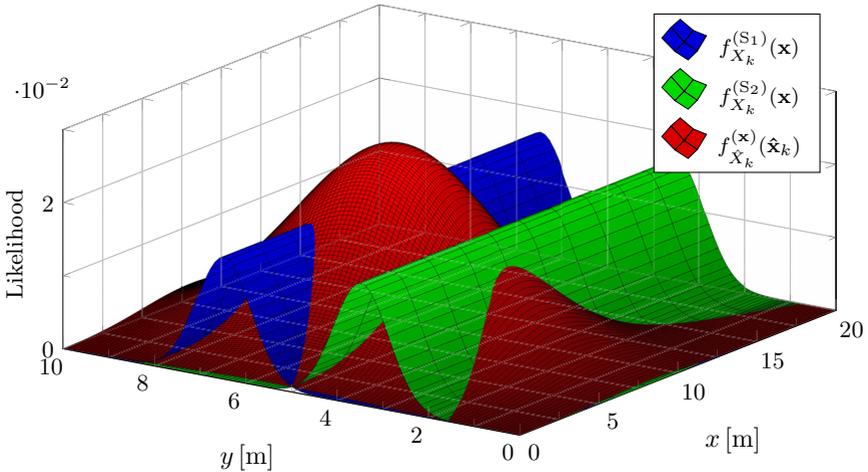


Abbildung 3.5: Likelihood der Positionsmessung und Aufenthaltswahrscheinlichkeit des Fahrzeugs für zwei parallele Fahrstreifen S_1 und S_2

Hinsichtlich der Aufenthaltswahrscheinlichkeit $f_{X_k}^{(l)}(\mathbf{x})$ liegt die Vermutung nahe, dass die darin auftretende Standardabweichung σ_{LD} von der Krümmung des Fahrstreifensegments l abhängt. Im Rahmen der Arbeit wurden hierzu entsprechende Untersuchungen durchgeführt, jedoch konnte der Zusammenhang anhand der in Abb. 3.6 dargestellten Ergebnisse nicht bestätigt

werden. Stattdessen wurde $\sigma_{LD} = 0.60$ m als konstant angenommen. Mit Blick auf die Messdaten scheint dieser Wert zunächst sehr groß, führt jedoch insbesondere bei Fahrstreifenwechseln zu einem deutlich robusteren Ergebnis der Eigenlokalisierung als dies bei kleineren Werten zu beobachten ist.

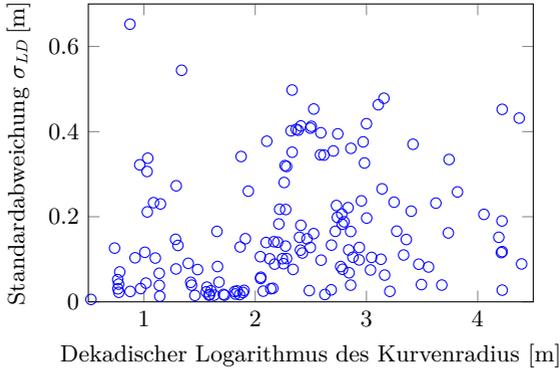


Abbildung 3.6: Standardabweichung der Querablage in Abhängigkeit vom Kurvenradius

Für die Fahrstreifenzuordnung würde sich auf Grundlage des vorgestellten Modells das Integral

$$P(L_k = l \mid \hat{X}_k = \hat{\mathbf{x}}_k) = \int_{\mathbb{R}^2} \frac{f_{\hat{X}_k}^{(\mathbf{x})}(\hat{\mathbf{x}}) f_{X_k}^{(l)}(\mathbf{x}) P(L_k = l)}{P(\hat{X}_k = \hat{\mathbf{x}}_k)} \mathbf{d}\mathbf{x} \quad (3.2)$$

ergeben, in dem die Wahrscheinlichkeitsdichtefunktion der Positionsmessung für jedes mögliche \mathbf{x} mit der der Aufenthaltswahrscheinlichkeit des Fahrzeugs in Abhängigkeit vom aktuellen Fahrstreifensegment zu multiplizieren ist. Da letztere je nach Geometrie des Fahrstreifensegments beliebig kompliziert werden kann, ist an eine allgemeingültige analytische Lösung des Integrals nicht zu denken.

Stattdessen wird die auf der rechten Seite von Abb.3.4 angegebene Näherung betrachtet. Anstelle der Wahrscheinlichkeitsdichte für den exakten Aufenthaltsort des Fahrzeugs wird hierbei zunächst die Wahrscheinlichkeit $P(Q_k = q \mid L_k)$ berechnet, mit der sich das Fahrzeug innerhalb eines diskreten Flächenabschnitts $\mathcal{A}_k^{(q)} \subset \mathbb{R}^2$ befindet. Innerhalb dieses Flächenstücks wird seine Aufenthaltswahrscheinlichkeit als gleichverteilt angenommen, so dass die Integration über diesem auf triviale Weise möglich ist. Für die

Wahrscheinlichkeit der Fahrstreifenzuordnung gilt somit

$$P(L_k | \hat{X}_k = \hat{\mathbf{x}}_k) = \sum_q \frac{P(\hat{X}_k = \hat{\mathbf{x}}_k | Q_k = q) P(Q_k = q | L_k) P(L_k)}{P(\hat{X}_k = \hat{\mathbf{x}}_k)} \quad (3.3)$$

mit

$$P(\hat{X}_k = \hat{\mathbf{x}}_k | Q_k = q) = \frac{1}{\lambda(\mathcal{A}_k^{(q)})} \int_{\mathcal{A}_k^{(q)}} f_{\hat{X}_k}^{(\mathbf{x})}(\hat{\mathbf{x}}) \mathbf{d}\mathbf{x}, \quad (3.4)$$

wobei $\lambda(\mathcal{A}_k^{(q)})$ für den Flächeninhalt von $\mathcal{A}_k^{(q)}$ steht. Für die Berechnung des Integrals aus (3.4) ist es sinnvoll, die durch die möglichen Werte von q repräsentierten Flächenabschnitte als Rechtecke aufzufassen, deren Orientierung und Größe – wie in Abb. 3.7 dargestellt – anhand der Eigenvektoren und Eigenwerte von Σ_k festgelegt werden. Dadurch sind die zugehörigen Likelihoods $P(\hat{X}_k = \hat{\mathbf{x}}_k | Q_k = q)$ unabhängig von $\hat{\mathbf{x}}_k$ und Σ_k und können zur Reduktion des Rechenaufwands als Konstanten hinterlegt werden. Konkret werden im Rahmen der Arbeit 441 Flächenabschnitte betrachtet, deren Mittelpunkte äquidistant innerhalb der doppelten Standardabweichung verteilt liegen.

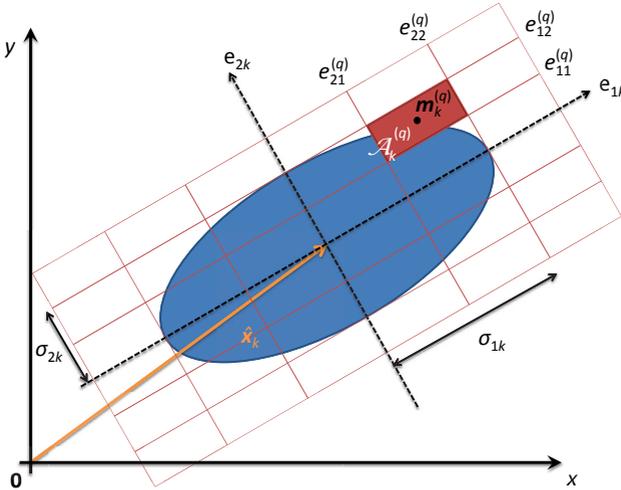


Abbildung 3.7: Reduktion des Rechenaufwands durch Diskretisierung entlang der Hauptachsen von Σ_k . Obwohl $\mathcal{A}_k^{(q)}$ im x-y-Koordinatensystem für jedes k einen anderen Flächenabschnitt beschreibt, ist das zugehörige Integral der Likelihood der Positionsmessung stets das gleiche.

Für jeden dieser Flächenabschnitte ist schlussendlich noch die Aufenthaltswahrscheinlichkeit $P(Q_k | L_k)$ zu bestimmen. Aufgrund der Ausrichtung der Flächenabschnitte in Richtung der Eigenvektoren von Σ_k sowie des Umstands, dass die Fahrstreifensegmente beliebig geformt sein können, ist eine analytische Integration auch hier nicht zweckmäßig. Stattdessen wird der Integrand durch die Aufenthaltswahrscheinlichkeit bzw. die Wahrscheinlichkeitsdichte an ihrem Flächenmittelpunkt approximiert. Für den zweiten Teil des Zählers aus (3.3) ergibt sich somit

$$P(Q_k = q | L_k = l) P(L_k = l) = \lambda(\mathcal{A}_k^{(q)}) f_{\hat{X}_k}^{(l)}(\mathbf{m}_k^{(q)}) P(L_k = l) \quad (3.5)$$

mit $\mathbf{m}_k^{(q)}$ dem Mittelpunkt des zu q gehörenden Flächenabschnitts. Unter Berücksichtigung des Umstands, dass die Prior-Wahrscheinlichkeit für das Fahrstreifensegment L_k proportional zu dessen Länge ist, vereinfacht sich Gleichung (3.5) zu

$$P(Q_k = q | L_k = l) P(L_k = l) = \frac{\lambda(\mathcal{A}_k^{(q)}) c_k}{\sqrt{2\pi} \sigma_{LD}} \exp \left[-\frac{1}{2} \left(\frac{\|\mathbf{m}_k^{(q)} - \mathbf{f}_k^{(q,l)}\|}{\sigma_{LD}} \right)^2 \right], \quad (3.6)$$

wobei c_k eine Normalisierungskonstante und $\mathbf{f}_k^{(q,l)}$ den Lotfußpunkt von $\mathbf{m}_k^{(q)}$ auf das Fahrstreifensegment l darstellt. Durch Einsetzen von (3.1), (3.4) und (3.6) in (3.3) ergibt sich schließlich die gesuchte Fahrstreifenzuordnung $P(L_k = l | \hat{X}_k = \hat{\mathbf{x}}_k)$.

Neben der Fahrstreifenzuordnung ist auch die Distanz entlang des jeweiligen Fahrstreifens für die Fahrerabsichtsvorhersage relevant. Diese wird für jede der Fahrstreifenhypothesen aus dem mit der Eintrittswahrscheinlichkeit der Flächenabschnitte gewichteten Mittelwert der Distanzwerte der zugehörigen Lotfußpunkte $\mathbf{f}_k^{(q,l)}$ entlang des Fahrstreifensegments l berechnet, wobei insbesondere auch vorangegangene und nachfolgende Fahrstreifensegmente berücksichtigt werden. Für die Eintrittswahrscheinlichkeit gilt hierbei

$$\begin{aligned} P(Q_k = q | \hat{X}_k = \hat{\mathbf{x}}_k, L_k = l) &= \frac{P(\hat{X}_k = \hat{\mathbf{x}}_k | Q_k = q) P(Q_k = q | L_k = l)}{P(\hat{X}_k = \hat{\mathbf{x}}_k)} \\ &= c_k^{(l)} \exp \left[-\frac{1}{2} \left(\frac{\|\mathbf{m}_k^{(q)} - \mathbf{f}_k^{(q,l)}\|}{\sigma_{LD}} \right)^2 \right] \int_{\mathcal{A}_k^{(q)}} f_{\hat{X}_k}^{(x)}(\hat{\mathbf{x}}) \mathbf{d}\mathbf{x}, \quad (3.7) \end{aligned}$$

wobei $c_k^{(l)}$ wiederum eine Normalisierungskonstante darstellt. Ein mögliches Ergebnis der Eigenlokalisierung ist in Abb. 3.8 beispielhaft visualisiert.

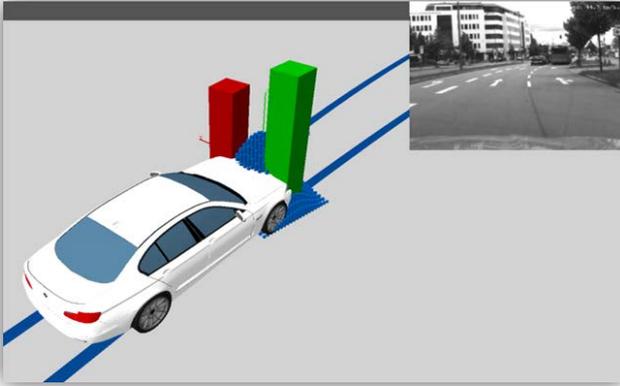


Abbildung 3.8: Ergebnis der Lokalisierung zwischen zwei Fahrstreifen. Die Höhe der roten und grünen Säule gibt die Wahrscheinlichkeit der Fahrstreifenzuordnung an, die der blauen die Likelihood der Positionsmessung gegeben der tatsächlichen Position des Fahrzeugs. Die Wahrscheinlichkeit der Zuordnung auf den dritten Fahrstreifen im Kamerabild ist verschwindend gering.

3.1.2 Repräsentation von Handlungsalternativen

Für jede der Lokalisierungslösungen wird im Anschluss ein Hypothesenbaum erzeugt, indem rekursiv benachbarte und nachfolgende Fahrstreifensegmente bis zum Erreichen eines vordefinierten Vorausschauhorizonts aus der digitalen Karte extrahiert werden. Jeder Knoten im Hypothesenbaum entspricht hierbei genau einem Fahrstreifensegment S_i . Das Fahrstreifensegment hingegen kann auch mehrfach im Baum auftauchen, falls mehrere Möglichkeiten bestehen, es zu erreichen. Nachfolgende Fahrstreifensegmente werden im Baum als Kinder des aktuellen Knotens repräsentiert, während die in Abb. 3.2 durch einen gestrichelten Pfeil gekennzeichnete Nachbarschaft von Knoten für einen Fahrstreifenwechsel steht. Hierbei wird angenommen, dass auf der Länge eines Fahrstreifensegments höchstens ein Fahrstreifenwechsel erfolgt. Unter dieser Voraussetzung ist der Hypothesenbaum ein gerichteter azyklischer Graph, bei dem jeder Blattknoten eine einzigartige Hypothese hinsichtlich des weiteren Fahrwegs darstellt.

Im Hinblick auf die Echtzeitfähigkeit der Fahrerabsichtserkennung spielt die Wiederverwendung des Hypothesenbaums aus dem vorangegangenen Zeitschritt eine wichtige Rolle. Dadurch ist es möglich, die Bewertung des Fahrerverhaltens im Hinblick auf mögliche Fahrerabsichten jeweils nur für den aktuellen Zeitschritt durchzuführen, aber dennoch das Fahrerverhalten aus vorangegangenen Zeitschritten bei der Ermittlung der Fahrerabsicht zu berücksichtigen.

Die hierfür benötigten Informationen werden in den Blattknoten des Hypothesenbaums hinterlegt. Bevor dieser neu erstellt wird, muss für jede der aktuellen Lokalisierungslösungen zunächst geprüft werden, ob das zugehörige Segment mit dem des Wurzelknotens eines bestehenden Hypothesenbaums aus dem vorangegangenen Zeitschritt übereinstimmt. Ist das der Fall, wird der entsprechende Hypothesenbaum übernommen. Falls hierbei aufgrund der Verschiebung des Vorausschauhorizonts eine Erweiterung des Hypothesenbaums erforderlich wird, werden die relevanten Informationen von den alten Blattknoten in die neuen übernommen. Im Anschluss wird für die noch nicht zugewiesenen Lokalisierungslösungen geprüft, ob es sich hierbei um Fahrstreifensegmente handelt, die durch Nachbar- oder Nachfolgeknoten der bisherigen Wurzelknoten repräsentiert werden. Indem auch diese ggf. übernommen werden, ist die Wiederverwendung eines bestehenden Hypothesenbaums in nahezu allen Verkehrssituationen sichergestellt.

3.1.3 Berechnung der Pfadwahrscheinlichkeiten

Für die Bewertung der durch den Hypothesenbaum repräsentierten Handlungsalternativen müssen zunächst die Prior-Wahrscheinlichkeiten der Blätter ermittelt werden. Ausgehend von der des Wurzelknotens, die der Lokalisierungswahrscheinlichkeit $P(L_k | \hat{X}_k = \hat{\mathbf{x}}_k)$ entspricht, werden die Prior-Wahrscheinlichkeiten zu diesem Zweck entlang der Kanten durch den Baum propagiert.

Hierbei gibt jeder Knoten zunächst einen Teil seiner Prior-Wahrscheinlichkeit an ggf. vorhandene Nachbarknoten ab. Dadurch wird die Möglichkeit berücksichtigt, dass der Fahrer bis zum Ende des zugehörigen Segments einen Fahrstreifenwechsel durchführt. Unter der Annahme hinreichend kurzer Segmente (Länge kleiner 100 m) ist die Fahrstreifenwechselwahrscheinlichkeit näherungsweise proportional zu der verbleibenden Weglänge des Segments. Im Rahmen der Arbeit wurde hierfür eine Proportionalitätskonstante angenommen, deren Wert einem Fahrstreifenwechsel pro 500 m Fahrweg entspricht. Anschließend wird der verbleibende Rest der Prior-Wahrscheinlichkeit gleich-

mäßig auf die Nachfolgeknoten aufgeteilt, um so auch die Möglichkeit des Übergangs vom aktuellen Segment auf das nachfolgende Segment ohne einen weiteren Fahrstreifenwechsel zu berücksichtigen.

Zur Bewertung der Blattknoten hinsichtlich ihrer Eintrittswahrscheinlichkeit wird neben den auf diese Weise ermittelten Prior-Wahrscheinlichkeiten auch die Likelihood des Fahrerverhaltens hinzugezogen. Im Folgenden wird dieses durch den aktuellen Status des Fahrtrichtungsanzeigers (kurz: Blinker) und den Zeitpunkt seiner letzten Aktivierung (*IF*), den Geschwindigkeits- bzw. Beschleunigungsverlauf der letzten 1.4s (*VF*) sowie die Kopfdrehung des Fahrers innerhalb der letzten 1.0s (*GF*) beschrieben. Unter der Annahme, dass die betrachteten Merkmale bei gegebener Fahrerabsicht statistisch unabhängig sind, kann die gemeinsame Wahrscheinlichkeitsverteilung über die durch die Blattknoten repräsentierte Fahrerabsicht H und die möglichen Beobachtungen $O = [IF \ VF \ GF]$ in Form des in Abb.3.2 dargestellten Bayes'schen Netzes erfolgen.

Für den aktuellen Zeitschritt k ergibt sich die Posterior-Wahrscheinlichkeit der Blattknoten somit zu

$$P(H_k | O_k) = \frac{P(IF_k | H_k) P(VF_k | H_k) P(GF_k | H_k)}{P(O_k)} P(H_k), \quad (3.8)$$

wobei der Nenner für alle möglichen Pfade der gleiche ist und somit als Normalisierungskonstante aufgefasst werden kann. Da die Beobachtungen selbst größtenteils kontinuierliche Größen sind, werden die Merkmals-Likelihoods im Folgenden in Form von Wahrscheinlichkeitsdichtefunktionen $f_{IF_k}^{(h)}$, $f_{VF_k}^{(h)}$ und $f_{GF_k}^{(h)}$ notiert, wobei sich h auf einen bestimmten Blattknoten aus einem bestimmten Hypothesenbaum bezieht und somit die Kombination aus aktuell belegtem Fahrstreifen und zukünftigem Pfad repräsentiert.

Die verbleibende Herausforderung besteht in der Ermittlung eben dieser Merkmals-Likelihoods, die ausdrücken, wie gut das beobachtete Fahrerverhalten mit dem für die jeweilige Fahrerabsicht zu erwartenden Verhalten zusammenpasst. Dies erfordert Modelle, die das typische Fahrerverhalten in beliebigen Situationen beschreiben. Obwohl hierfür im Prinzip jedes beliebige generative Modell und jede beliebige Form der Repräsentation von Wahrscheinlichkeitsverteilungen in Frage kommt, werden im Rahmen der Arbeit aus Gründen der Nachvollziehbarkeit, der Möglichkeit des Einbringens von Expertenwissen, der rechentechnischen Effizienz und nicht zuletzt der Übertragbarkeit der Parameterwerte auf zukünftige Arbeiten eine Reihe expliziter parametrischer Modelle verwendet, die in den folgenden Abschnitten im Detail vorgestellt werden.

3.2 Modellierung des Fahrtrichtungsanzeigers

Obwohl der Blinker die wohl offensichtlichste Möglichkeit zur Fahrerabsichtsvorhersage darstellt, ist seine Verwendung als Merkmal nicht unumstritten [34]. Als Gegenargument wird angeführt, dass sich Unfälle vor allem dann ereignen, wenn der Blinker trotz entsprechender Notwendigkeit nicht gesetzt wird.

Tatsächlich belegen Studien, dass der Blinker in Situationen, in denen dies eigentlich vorgeschrieben ist, häufig nicht aktiviert wird [99]. Andererseits kann der Fahrer mit Hilfe des Blinkermerkmals vor Unfällen gewarnt werden, die andernfalls nur unter inakzeptabel hohen Falschauslöseraten vorhersagbar wären. Aus diesem Grund scheint es nicht sinnvoll, den Blinker als Merkmal auszuschließen. Stattdessen werden seine Nicht- und Falschbenutzung bei der nachfolgenden Modellbildung explizit berücksichtigt.

3.2.1 Ursachen der Blinkeraktivierung

Grundsätzlich ist die Aktivierung des Fahrtrichtungsanzeigers immer dann vorgeschrieben, wenn der Fahrer einen Fahrstreifenwechsel oder ein Abbiegemanöver durchzuführen beabsichtigt. Zur Auswertung des Blinkermerkmals wird daher das jeweils nächstgelegene Manöver, das eine Blinkeraktivierung erfordert, entlang des betrachteten Pfades h ermittelt. Grundlage hierfür sind spezielle Bezugspunkte, auf die in den folgenden Abschnitten noch eingegangen wird.

Darüber hinaus ist es denkbar, dass der Fahrer den Blinker versehentlich oder aufgrund nicht in der Karte repräsentierter Gegebenheiten aktiviert. Um zu vermeiden, dass sich die Gesamtwahrscheinlichkeit eines Pfades allein aufgrund einer scheinbar unmotivierten Blinkerbetätigung zu Null ergibt, wird auch diesem Fall eine von Null verschiedene Likelihood zugeordnet.

Neben dem aktuellen Blinkerstatus IS_k beinhaltet das Blinkermerkmal IF_k auch die Distanz der letzten Aktivierung ID_k . Auf Basis dieser Information ist es möglich, den wahrscheinlichsten Zeitpunkt eines bevorstehenden Fahrstreifenwechsels vorherzusagen, zwischen mehreren Abbiegemöglichkeiten zu unterscheiden oder sogar ein versehentliches Aktivieren des Blinkers als solches zu erkennen. Die Verwendung der Distanz anstelle des Zeitpunkts ermöglicht hierbei eine höhere Robustheit in Gegenwart von Vorderfahrzeugen sowie bei Ampelstopps.

Für die Modellierung von ID_k ist es erforderlich, zwischen den oben genannten Ursachen der Blinkeraktivierung zu unterscheiden. Wie sich im Folgenden zeigen wird, ist hierfür die Einführung einer weiteren Zufallsgröße IR_k vorteilhaft, die sowohl den aktuellen Blinkerstatus als auch dessen Ursache beschreibt. Das resultierende Modell ist in Abb. 3.9 dargestellt.

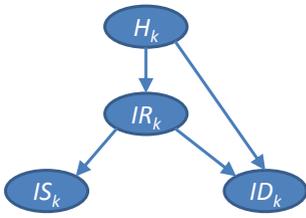
Für die in $P(IR_k | H_k)$ berücksichtigte zufällige Blinkeraktivierung wird je Richtung eine Wahrscheinlichkeit von $p_R = 0.02$ angenommen. In Anlehnung an die in [99] veröffentlichte Studie des Auto Club Europa, bei der festgestellt wurde, dass in Deutschland nur 80% der Abbiegemanöver und 70% der Fahrstreifenwechsel durch Setzen des Fahrtrichtungszeigers angekündigt werden, ergeben sich somit $p_T = 0.78$ und $p_L = 0.68$ als Wahrscheinlichkeiten einer bewussten Blinkeraktivierung.

Darüber hinaus ist zu beachten, dass die Wahrscheinlichkeit, dass der Blinker zu einem bestimmten Zeitpunkt bereits willentlich gesetzt wurde, von der Distanz zum verursachenden Abbiegemanöver oder Fahrstreifenwechsel abhängt. Die hierfür benötigten Verteilungsfunktionen von ID_k sind Gegenstand des folgenden Abschnitts.

3.2.2 Distanz der Blinkeraktivierung

Je nach Wert von IR_k gelten für die Distanz der letzten Blinkeraktivierung unterschiedliche Verteilungsfunktionen.

Für $IR_k = \text{TO}$ (Blinker ausgeschaltet) wird angenommen, dass diese unabhängig vom zukünftigen Pfad des Fahrzeugs ist. Hierbei handelt es sich um eine Vereinfachung, da ein zurückliegendes Ein- und Ausschalten des Blinkers auf einen bereits abgeschlossenen Fahrstreifenwechsel hindeuten und somit die Wahrscheinlichkeit für den aktuellen Fahrstreifen bzw. den zukünftigen Pfad des Fahrzeugs beeinflussen kann. Andererseits wäre es bei Berücksichtigung dieses Umstands erforderlich, gleichermaßen auch die Historie der GPS-Positionen des Fahrzeugs zur Bestimmung des aktuellen Fahrstreifens heranzuziehen. Da die Eigenlokalisierung zwar zur Erprobung der Algorithmen benötigt wird, darüber hinaus aber keinen Schwerpunkt der Arbeit darstellt, wird im Folgenden auf die Entwicklung derartiger Ansätze verzichtet. Daraus ergibt sich, dass die Verteilungsfunktion für die Distanz der letzten Blinkeraktivierung bei ausgeschaltetem Blinker für alle Pfadhypothesen die gleiche ist und somit für die Berechnung der Pfadwahrscheinlichkeit $P(H_k | O_k)$ keine Rolle spielt. Der Einfachheit halber wird sie daher mit der konstanten Dichte $1/s_\infty$ mit $s_\infty = 1 \text{ m}$ modelliert.



- H_k Verfolgter Pfad
- IS_k Aktueller Blinkerstatus
- IR_k Ursache des Blinkerstatus
- ID_k Distanz der letzten Aktivierung
- $nm_k^{(h)}$ Nächstes Manöver entlang h
- $s_k^{(h)}$ Aktuelle Distanz entlang h

ir	$P(IR_k = ir \mid H_k = h)$				
	$nm_k^{(h)} = \text{TL}$	$nm_k^{(h)} = \text{TR}$	$nm_k^{(h)} = \text{LL}$	$nm_k^{(h)} = \text{LR}$	$nm_k^{(h)} = \text{ST}$
TL	$p_T F_{IDT}^{(h)}(s_k^{(h)})$	0	0	0	0
TR	0	$p_T F_{IDT}^{(h)}(s_k^{(h)})$	0	0	0
LL	0	0	$p_L F_{IDL_k}^{(h)}(s_k^{(h)})$	0	0
LR	0	0	0	$p_L F_{IDL_k}^{(h)}(s_k^{(h)})$	0
RL	p_R	p_R	p_R	p_R	p_R
RR	p_R	p_R	p_R	p_R	p_R
TO	1 - Spaltensumme				

ir	$P(IS_k = is \mid IR_k = ir)$		
	$is = \text{L}$	$is = \text{O}$	$is = \text{R}$
TL	1	0	0
TR	0	0	1
LL	1	0	0
LR	0	0	1
RL	1	0	0
RR	0	0	1
TO	0	1	0

ir	Dichtefunktion $f_{ID_k}^{(h,ir)}(s)$	
	$s \leq s_k^{(h)}$	$s > s_k^{(h)}$
TL	$f_{IDT}^{(h)}(s)/F_{IDT}^{(h)}(s_k^{(h)})$	0
TR	$f_{IDT}^{(h)}(s)/F_{IDT}^{(h)}(s_k^{(h)})$	0
LL	$f_{IDL_k}^{(h)}(s)/F_{IDL_k}^{(h)}(s_k^{(h)})$	0
LR	$f_{IDL_k}^{(h)}(s)/F_{IDL_k}^{(h)}(s_k^{(h)})$	0
RL	$f_{IDR}^{(h)}(s)$	0
RR	$f_{IDR}^{(h)}(s)$	0
TO	$1/s_\infty$	0

Abbildung 3.9: Probabilistisches Modell für den Fahrtrichtungsanzeiger und Wahrscheinlichkeitsverteilung von IR_k , IS_k und ID_k . Die Werte TL und TR stehen für Abbiegemanöver, LL und LR für Fahrstreifenwechsel und RL und RR für zufällige Blinkeraktivierungen jeweils nach links oder rechts, während TO den nicht aktivierten Blinker beispielsweise aufgrund einer beabsichtigten Geradeausfahrt (ST) repräsentiert.

Anders stellt sich die Situation dar, wenn der Blinker aktiviert ist. Unter der Annahme, dass die Blinkeraktivierung in beide Richtungen mit dem gleichen Modell beschrieben werden kann, ergibt sich die zugehörige Wahrscheinlichkeitsdichte $f_{ID_k}^{(h,r)}(s)$ entsprechend der in Abb. 3.9 unten rechts dargestellten Tabelle. Die Zufallsgrößen IDT und IDL kennzeichnen hierbei die Distanz der Blinkeraktivierung für den Fall, dass der Fahrer den Blinker aufgrund eines Abbiegemanövers bei $s_T^{(h)}$ oder eines Fahrstreifenwechsels bei $s_L^{(h)}$ mit Absicht aktiviert. Im Gegensatz dazu repräsentiert die Zufallsgröße IDR die Distanz der Blinkeraktivierung für den Fall, dass der Blinker bei $s_k^{(h)}$ trotz einer beabsichtigten Geradeausfahrt aktiviert ist. Die zu IDT , IDL und IDR gehörenden Dichtefunktionen, die hierbei getroffenen Modellannahmen und deren Parametrisierung werden im Folgenden vorgestellt.

Zufällige Blinkeraktivierung

Hinsichtlich der zufälligen Blinkeraktivierungen wird angenommen, dass diese auf den in Abb. 3.10 dargestellten Markovprozess zurückzuführen sind. Hierbei wird die Möglichkeit der Aktivierung des Blinkers innerhalb des Intervalls $[s, s + \Delta s_R)$ durch eine konstante Wahrscheinlichkeit p_{R01} für jede der beiden Richtungen repräsentiert, während p_{R10} die Wahrscheinlichkeit darstellt, dass der Blinker innerhalb dieses Zeitintervalls deaktiviert wird.

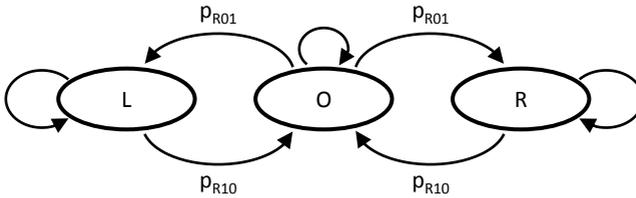


Abbildung 3.10: Markovprozess für die zufällige Blinkeraktivierung

Die Wahrscheinlichkeit, eine Blinkeraktivierung bei einem gegebenen Distanzwert s relativ zur aktuellen Distanz $s_k^{(h)}$ entlang des betrachteten Pfades h zu beobachten, ist somit durch

$$f_{IDR_k}^{(h)}(s) = \mathbf{1}(s < s_k^{(h)}) (1 - 2p_R) p_{R01} (1 - p_{R10})^{(s_k^{(h)} - s) / \Delta s_R} \quad (3.9)$$

gegeben, mit $\mathbf{1} : \mathbb{B} \mapsto \mathbb{R}$, $\mathbf{1}(\text{wahr}) = 1$, $\mathbf{1}(\text{falsch}) = 0$ und $1 - 2p_R$ der stationären Wahrscheinlichkeit des Zustands AUS. Da (3.9) eine Exponen-

tialverteilung darstellt, kann diese auch in der Form

$$f_{IDR_k}^{(h)}(s) = \mathbb{1}(s < s_k^{(h)}) \frac{p_R}{\Delta \tilde{s}_R} e^{(s - s_k^{(h)}) / \Delta \tilde{s}_R} \quad (3.10)$$

notiert werden, mit $\Delta \tilde{s}_R = -\Delta s_R / \log(1 - p_{R10})$. Im Folgenden wird $p_{R10} = 1/200$ und $\Delta s_R = 1$ m angenommen. Die resultierende Wahrscheinlichkeitsdichtefunktion ist in Abb. 3.11 schematisch dargestellt.

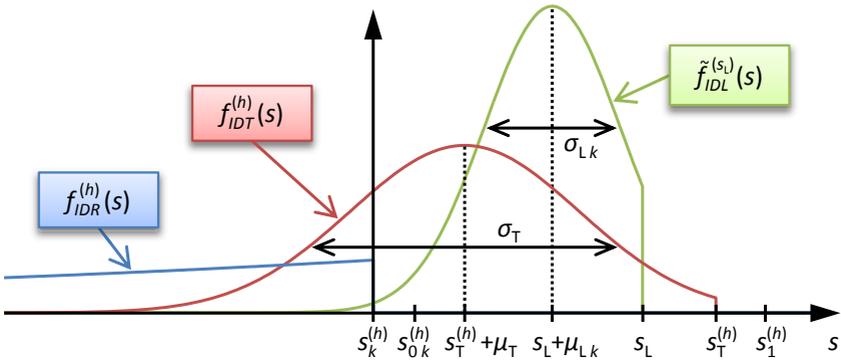


Abbildung 3.11: Parameter der Wahrscheinlichkeitsdichtefunktionen

Blinkeraktivierung beim Abbiegen

Im Gegensatz zur zufälligen Blinkerbetätigung ist die Wahrscheinlichkeit für dessen bewusste Aktivierung von der Entfernung zum Referenzpunkt des geplanten Manövers abhängig. Ist dies ein Abbiegemanöver, wird hierfür der Gabelungspunkt der Abbiegung verwendet. Dabei handelt es sich um den Distanzwert $s_T^{(h)}$ entlang des betrachteten Pfades h , zu dem sich dieser erstmalig 1.5 m von dem der zugehörigen Geradeausfahrt entfernt – der Einfachheit halber werden im Folgenden keine Situationen betrachtet, in denen eine Aktivierung des Blinker trotz fehlender Möglichkeit zur Geradeausfahrt erforderlich ist.

Zur Untersuchung des Fahrerverhaltens wurden mit 6 Probanden mehr als 200 Rechtsabbiegemanöver an 5 Kreuzungen aufgezeichnet. Die Ergebnisse zeigen, dass die Distanz der Blinkeraktivierung bezogen auf den Gabelungspunkt der Abbiegung für $s \leq s_T^{(h)}$ näherungsweise normalverteilt ist. Die entsprechenden Histogramme sowie die Annäherung durch eine Normalverteilung mit dem

3. Fahrerabsichtserkennung

Mittelwert $\mu_T = -55.6$ m und der Standardabweichung $\sigma_T = 25.3$ m sind in Abb. 3.12 dargestellt.

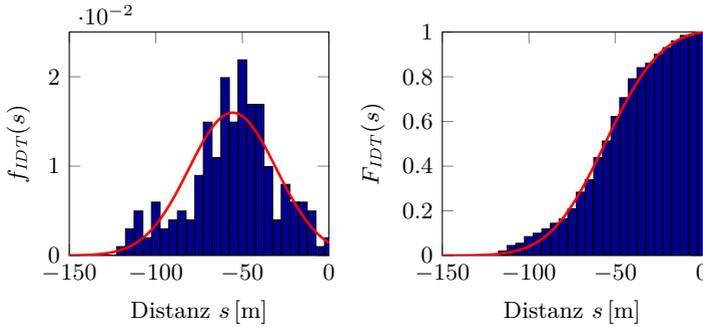


Abbildung 3.12: Wahrscheinlichkeitsdichte und Verteilungsfunktion für abbiegebedingte Blinkeraktivierungen ($s_T = 0$)

Aufgrund der Normalverteilung ergibt sich die Wahrscheinlichkeitsdichte der Blinkeraktivierung zu

$$f_{IDT}^{(h)}(s) = \mathbf{1}(s < s_T^{(h)}) \frac{c_T}{\sqrt{2\pi}\sigma_T} \exp\left[-\frac{1}{2}\left(\frac{s - s_T^{(h)} - \mu_T}{\sigma_T}\right)^2\right], \quad (3.11)$$

wobei

$$c_T^{-1} = \int_{-\infty}^{s_T^{(h)}} \frac{f_{IDT}^{(h)}(s)}{c_T} ds = \frac{1}{2} \left[1 + \operatorname{erf}\left(\frac{-\mu_T}{\sqrt{2}\sigma_T}\right) \right] \quad (3.12)$$

berücksichtigt, dass abbiegebedingte Blinkeraktivierungen nur für $s < s_T^{(h)}$ möglich sind. Grundlage der Berechnung ist die aus der Literatur bekannte Fehlerfunktion

$$\operatorname{erf}(x) = \frac{2}{\sqrt{\pi}} \int_0^x e^{-t^2} dt \quad (3.13)$$

für die sehr effiziente numerische Implementierungen existieren [100, 101]. Die Wahrscheinlichkeit, dass der Blinker bei der Distanz $s_k^{(h)}$ noch nicht gesetzt wurde obwohl der Fahrer bei $s_T^{(h)}$ abbiegen möchte, ergibt sich schließlich auf Basis der zu $f_{IDT}^{(h)}(s)$ gehörenden Verteilungsfunktion

$$F_{IDT}^{(h)}(s) = \mathbf{1}(s < s_T^{(h)}) \frac{c_T}{2} \left[1 + \operatorname{erf}\left(\frac{s - s_T^{(h)} - \mu_T}{\sqrt{2}\sigma_T}\right) \right] + \mathbf{1}(s \geq s_T^{(h)}). \quad (3.14)$$

Blinkeraktivierung bei Fahrstreifenwechseln

Analog zur Modellierung von Abbiegemanövern kann auch die Blinkerbetätigung bei Fahrstreifenwechseln durch eine absichtliche und eine zufällige Komponente modelliert werden. Allerdings zeigen die Ergebnisse der im Rahmen der Arbeit durchgeführten Untersuchungen, dass der Zeitpunkt der absichtlichen Blinkerbetätigung nicht wie bei Abbiegemanövern von der Entfernung, sondern vielmehr von der Zeit bis zur geplanten Durchführung des Fahrstreifenwechsels abhängt. Die auf mehr als 500 Fahrstreifenwechseln basierende Verteilung der Aktivierungszeitpunkte ist in Abb. 3.13 für verschiedene Geschwindigkeitsbereiche dargestellt.

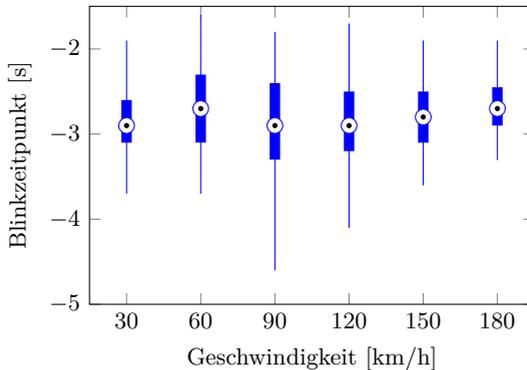


Abbildung 3.13: Zeitpunkt der Blinkeraktivierung bezogen auf das Überfahren der Fahrstreifenmarkierung (Fahrzeugmitte). Die Boxen repräsentieren den Bereich zwischen dem ersten und dritten Quartil, die Punkte innerhalb der Boxen den Median. Die Antennen haben maximal die 1.5-fache Länge der Boxen und repräsentieren in diesem Fall 99.3% der Blinkeraktivierungen unter der Annahme, dass diese normalverteilt sind.

Aus dem Diagramm lässt sich ablesen, dass der Zeitpunkt der Blinkeraktivierung weitgehend unabhängig von der aktuellen Geschwindigkeit ist, so dass dieser durch eine einzige Normalverteilung mit $\tilde{\mu}_L = -2.83\text{s}$ und $\tilde{\sigma}_L = 0.61\text{s}$ modelliert werden kann. Aus der aktuellen Geschwindigkeit v_k ergeben sich die jeweils gültigen Parameter der Wahrscheinlichkeitsdichte über der Distanz relativ zum Fahrstreifenwechsel somit zu $\mu_{Lk} = v_k \tilde{\mu}_L$ und $\sigma_{Lk} = v_k \tilde{\sigma}_L$.

Ein weiterer Unterschied zur Modellierung von Abbiegemanövern besteht darin, dass der die Blinkeraktivierung motivierende Fahrstreifenwechsel statt

an einem festen Punkt $s_T^{(h)}$ irgendwo zwischen $\underline{s}_{Lk}^{(h)}$ und $\bar{s}_L^{(h)}$ stattfinden kann. Während $\bar{s}_L^{(h)}$ hierbei stets das Ende des entsprechenden Fahrstreifensegments kennzeichnet, ist hinsichtlich $\underline{s}_{Lk}^{(h)}$ zu berücksichtigen, ob sich die aktuelle Position bereits auf dem Segment befindet. Da zurückliegende Fahrstreifenwechsel nicht betrachtet werden, kennzeichnet $\underline{s}_{Lk}^{(h)}$ in diesem Fall statt dem Anfang des Fahrstreifensegments die aktuelle Position $s_k^{(h)}$.

Unter Berücksichtigung der in Abschnitt 3.1 vorausgesetzten Gleichverteilung für die Fahrstreifenwechselwahrscheinlichkeit ergibt sich die Wahrscheinlichkeitsdichte der Blinkeraktivierung zu

$$f_{IDL_k}^{(h)}(s) = \frac{1}{\bar{s}_L^{(h)} - \underline{s}_{Lk}^{(h)}} \int_{\underline{s}_{Lk}^{(h)}}^{\bar{s}_L^{(h)}} \tilde{f}_{IDL}^{(s_L)}(s) ds_L, \quad (3.15)$$

mit $\tilde{f}_{IDL}^{(s_L)}(s)$ und c_L analog zu (3.11) und (3.12). Mit Hilfe der Fehlerfunktion kann diese für $s \leq s_k^{(h)}$ numerisch ausgewertet werden:

$$f_{IDL_k}^{(h)}(s) = \frac{c_L}{2(\bar{s}_L^{(h)} - \underline{s}_{Lk}^{(h)})} \operatorname{erf} \left(\frac{s - s' - \mu_{Lk}}{\sqrt{2} \sigma_{Lk}} \right) \Big|_{s'=\bar{s}_L^{(h)}}^{s'=\underline{s}_{Lk}^{(h)}}. \quad (3.16)$$

Nach Integration über den Weg s ergibt sich daraus die für $s \leq s_k^{(h)}$ geltende Verteilungsfunktion

$$F_{IDL_k}^{(h)}(s) = \frac{c_L}{2} \left[1 + \frac{\sqrt{2} \sigma_{Lk}}{\bar{s}_L^{(h)} - \underline{s}_{Lk}^{(h)}} g \left(\frac{s - s' - \mu_{Lk}}{\sqrt{2} \sigma_{Lk}} \right) \Big|_{s'=\bar{s}_L^{(h)}}^{s'=\underline{s}_{Lk}^{(h)}} \right], \quad (3.17)$$

mit dem unbestimmten Integral

$$g(x) = \int \operatorname{erf}(x) dx = x \operatorname{erf}(x) + \frac{1}{\sqrt{\pi}} e^{-x^2} + c. \quad (3.18)$$

3.2.3 Berechnung der Likelihood

Anhand des Blinkermodells aus Abb. 3.9 kann nun die Likelihood $f_{IF_k}^{(h)}(is, s)$ des Blinkermerkmals $IF_k = [IS_k, ID_k]$ durch Verknüpfung der Teilmodelle und Marginalisierung über die Ursache des Blinkerstatus berechnet werden. Für $IS_k = is$ und $ID_k = s$ ergibt sich diese zu

$$f_{IF_k}^{(h)}(is, s) = \sum_r P(IS_k = is | IR_k = ir) f_{ID_k}^{(h,ir)}(s) P(IR_k = ir | H = h). \quad (3.19)$$

Für konkrete Werte des aktuellen Blinkerstatus IS_k sowie des nächstgelegenen Manövers $nm^{(h)}$ entlang des betrachteten Pfades h sind die sich daraus ergebenden Terme in Tab. 3.1 zusammengefasst. Anhand ihrer in Abb. 3.14 dargestellten Logarithmen ist ersichtlich, dass die Wahrscheinlichkeit einer Blinkeraktivierung in großen Entfernungen von der Abbiegung unabhängig

Tabelle 3.1: Likelihood $f_{IF_k}^{(h)}(is, s)$ des Blinkermerkmals IF_k in Abhängigkeit vom Blinkerstatus is , der Distanz des Blinkersetzens s und dem betrachteten Pfad h . Mögliche Manöver sind das Abbiegen nach links oder rechts (TL, TR), entsprechende Fahrstreifenwechsel (LL, LR) sowie die Fahrt geradeaus (ST), während der Blinker nach links (L) oder rechts (R) gesetzt oder ausgeschaltet (O) sein kann. Die Abkürzung ζ steht für $p_R f_{IDR}^{(h)}(s)$.

$nm^{(h)}$	Blinker-Likelihood $f_{IF_k}^{(h)}(is, s)$		
	$is = L$	$is = O$	$is = R$
ST	ζ	$1 - 2 p_R$	ζ
TL	$\zeta + p_T f_{IDT}^{(h)}(s)$	$1 - 2 p_R - p_T F_{IDT}^{(h)}(s_k^{(h)})$	ζ
TR	ζ	$1 - 2 p_R - p_T F_{IDT}^{(h)}(s_k^{(h)})$	$p_T f_{IDT}^{(h)}(s) + \zeta$
LL	$\zeta + p_L f_{IDL_k}^{(h)}(s)$	$1 - 2 p_R - p_L F_{IDL_k}^{(h)}(s_k^{(h)})$	ζ
LR	ζ	$1 - 2 p_R - p_L F_{IDL_k}^{(h)}(s_k^{(h)})$	$p_L f_{IDL_k}^{(h)}(s) + \zeta$

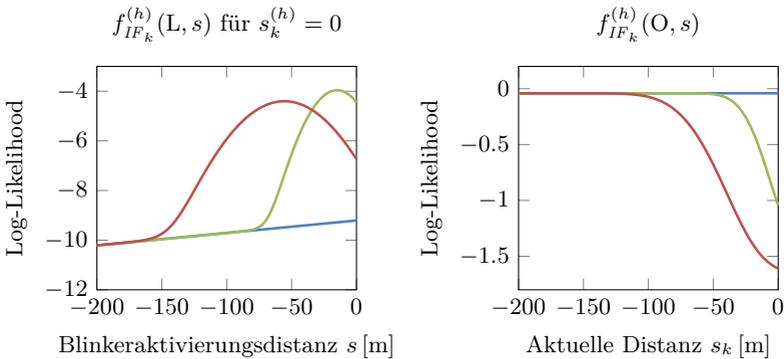


Abbildung 3.14: Log-Likelihood $f_{IF_k}^{(h)}(is, s)$ des Blinkermerkmals IF_k für verschiedene Situationen. Links: Der Fahrer befindet sich bei $s_k^{(h)} = 0$ und hat den Blinker nach links aktiviert. Rechts: Der Blinker ist deaktiviert. Rot steht für die Absicht, bei $s_T^{(h)} = 0$ links abzubiegen, grün für einen entsprechenden Fahrstreifenwechsel zwischen $s_L = 0$ und $s_L = 10$ m und blau für die Geradeausfahrt.

von der Fahrerabsicht ist. Daraus ergibt sich automatisch, dass beispielsweise ein versehentlich dauerhaft aktivierter Blinker bereits nach etwa 150 m keinen Einfluss mehr auf das Ergebnis der Fahrerabsichtserkennung hat.

3.3 Modellierung der Längsbeschleunigung

Im Hinblick auf die Erkennung von Abbiegemanövern ist der Geschwindigkeitsverlauf bzw. die Längsbeschleunigung des Fahrzeugs das wohl wichtigste, aber auch das am schwierigsten zu interpretierende Merkmal. Wichtig ist es insofern, als sich die Fahrerabsicht oft sehr frühzeitig im Geschwindigkeitsverlauf äußert, und dieser überdies ohne größeren Aufwand auch für andere Fahrzeuge beobachtbar ist; schwierig ist es hingegen aufgrund der Vielzahl der in Abschnitt 1.1.1 identifizierten Randbedingungen, die den Geschwindigkeitsverlauf beeinflussen.

Im Folgenden soll zunächst die in Abb. 3.15 dargestellte Kreuzung betrachtet werden, um ein Gefühl für die auftretenden Effekte zu bekommen. Die zugehörigen Geschwindigkeitsverläufe zeigt Abb. 3.16, wobei als zusätzliche Orientierungshilfe die Haltelinie und der Fußgängerüberweg aus Abb. 3.15 als gepunktete Linien in das Diagramm eingetragen sind.

Aus den dargestellten Geschwindigkeitsverläufen ist ersichtlich, dass sich Geradeausfahrten und Abbiegemanöver anhand des Geschwindigkeitsmerkmals mitunter bereits über 30 Meter vor dem Fußgängerüberweg unterscheiden lassen. Allerdings weisen die Verläufe der Geradeausfahrt neben Anhalteworgängen an der Haltelinie der Ampel auch noch eine Reihe weiterer Stopps oder Beinahe-Stopps auf, die höchstwahrscheinlich auf die Existenz von Vorderfahrzeugen zurückzuführen sind.

Im folgenden Abschnitt 3.3.1 wird daher zunächst ein Modell vorgestellt, mit dem das typische Verhalten von Fahrern in Gegenwart von Vorderfahrzeugen beschrieben werden kann. In Abschnitt 3.3.2 wird dieses dahingehend erweitert, dass es die abbiegebedingte Verzögerung des Fahrzeugs berücksichtigt. In diesem Zusammenhang werden in Abschnitt 3.3.3 unterschiedliche Fahrerprofile zur Berücksichtigung einer eher sportlichen oder eher defensiven Fahrweise vorgestellt. Die Berechnung der eigentlichen Beobachtungswahrscheinlichkeit für das Geschwindigkeits-Merkmal wird in Abschnitt 3.3.4 diskutiert, während Abschnitt 3.3.5 eine Möglichkeit aufzeigt, um mit Hilfe des entwickelten Modells die verbleibende Zeit bis zum Erreichen eines definierten Konfliktpunkts zu ermitteln.

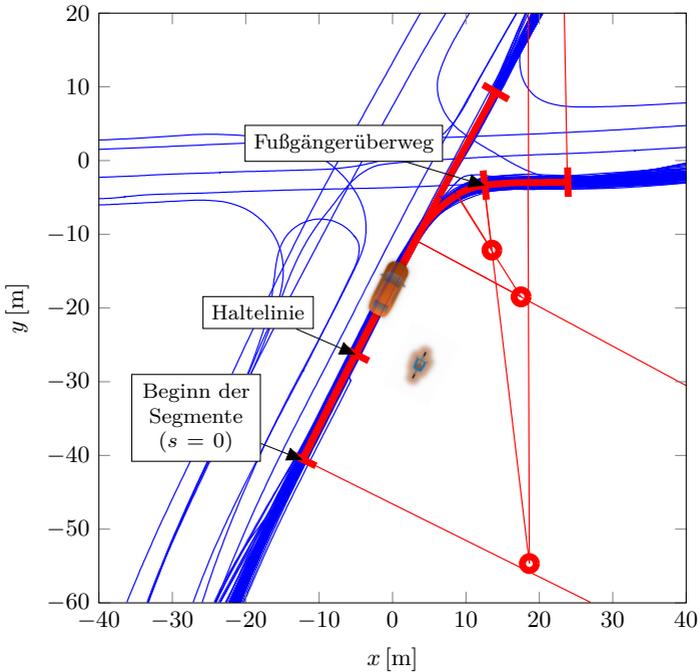


Abbildung 3.15: GPS-Spuren der Kreuzungsüberfahrten (blau) und die daraus erstellten Kreisbogensplines der digitalen Karte (rot)

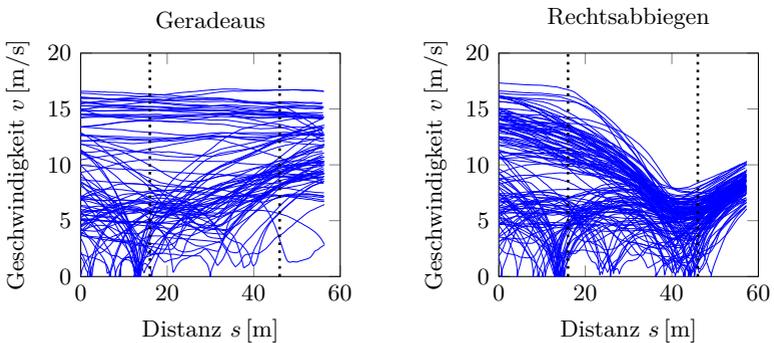


Abbildung 3.16: Geschwindigkeitsprofile für Geradeausfahrten und Abbiegemaneöver. Die Position der Haltelinie sowie die des Fußgängerüberwegs sind durch gepunktete Linien gekennzeichnet.

3.3.1 Vorderfahrzeuge

In der Literatur existieren eine ganze Reihe von Fahrzeugfolgmodellen, die zur Beschreibung des Fahrerverhaltens in Gegenwart von Vorderfahrzeugen verwendet werden können [102, 103, 104, 105, 106]. Ein besonders einfaches, aber dennoch leistungsfähiges Modell stellt das in [104] vorgeschlagene *Intelligent Driver Model* (IDM) dar:

$$\hat{a} = a_{\text{IDM}} \left[1 - \left(\frac{v}{v_d} \right)^{\delta_{\text{IDM}}} - \left(\frac{\Delta s_{\text{PVd}}}{\Delta s_{\text{PV}}} \right)^2 \right], \quad (3.20)$$

$$\Delta s_{\text{PVd}} = \Delta s_{0\text{IDM}} + v \Delta t_{\text{IDM}} + \frac{v \Delta v_{\text{PV}}}{2 \sqrt{a_{\text{IDM}} b_{\text{IDM}}}}. \quad (3.21)$$

Tabelle 3.2: Parameter des Intelligent Driver Model

Parameter	Wert	Einheit
max. Beschleunigung a_{IDM}	0..5	m/s ²
Beschleunigungsexponent δ_{IDM}	4	–
Wunschgeschwindigkeit v_d	0..60	km/h
komf. Verzögerung b_{IDM}	3.0	m/s ²
min. Abstand zum Vorderfahrzeug $\Delta s_{0\text{IDM}}$	2.0	m
Zeitlücke zum Vorderfahrzeug Δt_{IDM}	0.8	s

Grundsätzlich ergibt sich die zu erwartende Beschleunigung \hat{a} demnach aus dem Parameter für die maximale Beschleunigung a_{IDM} , der aktuellen Geschwindigkeit v , der Wunschgeschwindigkeit v_d und einem festen Beschleunigungsexponenten δ_{IDM} . Der Einfluss von Vorderfahrzeugen wird durch das Verhältnis zwischen dem angestrebten Abstand Δs_{PVd} und dem tatsächlichen Abstand Δs_{PV} zum vorausfahrenden Fahrzeug berücksichtigt. In Abwesenheit von Vorderfahrzeugen wird die Relativgeschwindigkeit Δv_{PV} auf Null und der Abstand Δs_{PV} zum Vorderfahrzeug auf unendlich gesetzt, so dass der Quotient $\Delta s_{\text{PVd}} / \Delta s_{\text{PV}}$ entfällt. Ansonsten ist das Modell kollisionsfrei, d. h. die durch das Modell berechnete Beschleunigung \hat{a} ist betragsmäßig stets hoch genug, um eine Kollision zu vermeiden. Sollten hierbei zunächst größere Verzögerungen als die komfortable Verzögerung b_{IDM} erforderlich sein, so nähert sich \hat{a} dieser anschließend asymptotisch. Die verwendeten Parameterwerte sind in Tab. 3.2 aufgelistet.

3.3.2 Abbiegebedingte Verzögerung

In der in [104] beschriebenen Ausprägung des Modells wird die Wunschgeschwindigkeit v_d als konstant angenommen. Diese Vereinfachung ist zulässig, wenn das Modell beispielsweise zur Verkehrsflussanalyse auf hinreichend geraden Autobahnstrecken verwendet werden soll. Zur Vorhersage des Geschwindigkeitsverlaufs bei Abbiegemanövern ist hingegen eine Erweiterung des Modells erforderlich, bei der die Wunschgeschwindigkeit v_d in Abhängigkeit von der Krümmung des vorausliegenden Pfades berücksichtigt wird.

Hierfür existieren verschiedene Möglichkeiten. Beispielsweise kann für einen gegebenen, von Vorderfahrzeugen unbeeinflussten Geschwindigkeitsverlauf $v_i(s)$ Gleichung (3.20) unter Vernachlässigung des Fahrzeugfolgeterms $\Delta s_{PVd} / \Delta s_{PV}$ umgeschrieben werden, um die Wunschgeschwindigkeit

$$v_{d,i}(s) = \min \left(\frac{v_i(s)}{\delta_{IDM} \sqrt{1 - a_i(s) / a_{IDM,i}}}, \bar{v}_d \right) \quad (3.22)$$

in Abhängigkeit von der Distanz s zu erhalten. Als Höchstwert \bar{v}_d der Wunschgeschwindigkeit werden hierbei 60 km/h angenommen. Um den Wunschgeschwindigkeitsverlauf zu berechnen, wird demnach der für den beobachteten Geschwindigkeitsverlauf $v_i(s)$ geltende Parameterwert der maximalen Beschleunigung $a_{IDM,i}$ benötigt. Unter der Annahme, dass die Wunschgeschwindigkeit auf der geraden Strecke nach der Abbiegung der maximalen Wunschgeschwindigkeit \bar{v}_d entspricht, kann dieser auf Basis der aus $v_i(s)$ berechneten Beschleunigung in eben diesem Intervall bestimmt werden. Dadurch lässt sich für jeden gegebenen Geschwindigkeitsverlauf $v_i(s)$ der zugehörige Wunschgeschwindigkeitsverlauf $v_{d,i}(s)$ ermitteln.

Ein beispielhafter Geschwindigkeitsverlauf und der zugehörige Wunschgeschwindigkeitsverlauf sind in Abb. 3.17 dargestellt. Der Vorteil der Repräsentation von $v_i(s)$ durch den zugehörigen Wunschgeschwindigkeitsverlauf $v_{d,i}(s)$ besteht darin, dass sich letzterer auf beliebige Situationen verallgemeinern lässt. In Abb. 3.17 wird dies beispielhaft für tatsächlich beobachtete Geschwindigkeitsverläufe demonstriert, die einen Ampelstopp bei $s \approx 13$ m aufweisen. Ausgehend von ihrer mittleren Geschwindigkeit bei $s = 0$ wird dazu eine Simulation mit dem IDM auf Basis des Wunschgeschwindigkeitsverlaufs $v_{d,i}(s)$ durchgeführt, wobei der Ampelstopp durch ein stehendes, virtuelles Vorderfahrzeug bei $s = 16$ m nachgebildet wird. Sobald der simulierte Geschwindigkeitsverlauf Null erreicht, wird das virtuelle Fahrzeug wieder entfernt. Bemerkenswert ist hierbei, dass der resultierende Geschwindigkeitsverlauf sehr gut mit den tatsächlichen Verläufen übereinstimmt, obwohl der

für die Simulation verwendete Wunschgeschwindigkeitsverlauf $v_{di}(s)$ auf einem vollkommen anderen Geschwindigkeitsverlauf basiert.

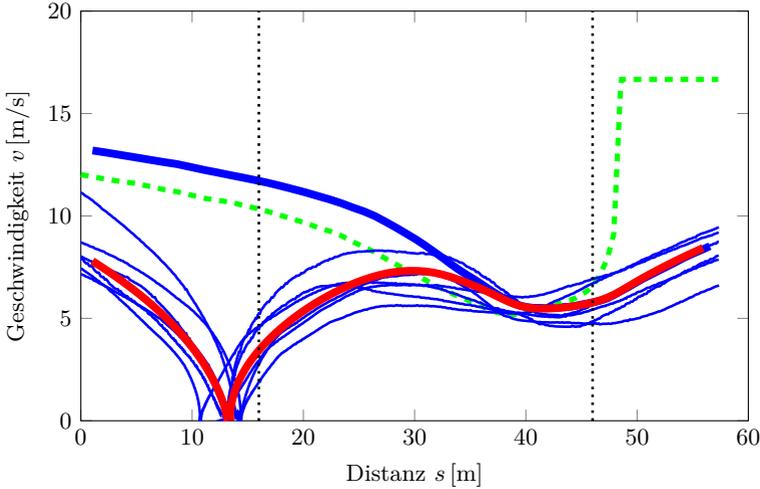


Abbildung 3.17: Verallgemeinerbarkeit des Wunschgeschwindigkeitsprofils. Dargestellt sind der ursprüngliche Geschwindigkeitsverlauf (dick blau), der berechnete Wunschgeschwindigkeitsverlauf (grün gestrichelt), beobachtete Geschwindigkeitsverläufe mit Stopp an der Haltelinie (dünn blau) sowie die auf Basis des Wunschgeschwindigkeitsverlaufs simulierte Trajektorie (dick rot) jeweils für das Abbiegen an der in Abb. 3.15 dargestellten Kreuzung.

3.3.3 Modelle für unterschiedliche Fahrertypen

Erfahrungsgemäß biegen menschliche Fahrer je nach Situation, Fahrertyp und momentaner Stimmung mit unterschiedlichen Wunschgeschwindigkeitsverläufen $v_d(s)$ und Beschleunigungsparametern a_{IDM} ab. Um dieser Variabilität im Fahrerverhalten Rechnung zu tragen, soll im Folgenden eine kleine Zahl von Parametersätzen ermittelt werden, die ein möglichst breites Spektrum des typischen Fahrerverhaltens abbildet.

In [96] werden hierzu zwei unterschiedliche Ansätze untersucht. Der erste erzeugt Wunschgeschwindigkeitsprofile durch Clustering beobachteter Überfahrten an einer bestimmten Kreuzung. Dadurch können einerseits kreuzungsspezifische Eigenheiten berücksichtigt werden, andererseits ist hierfür aber ein separates Anlernen der Wunschgeschwindigkeitsprofile für jede ein-

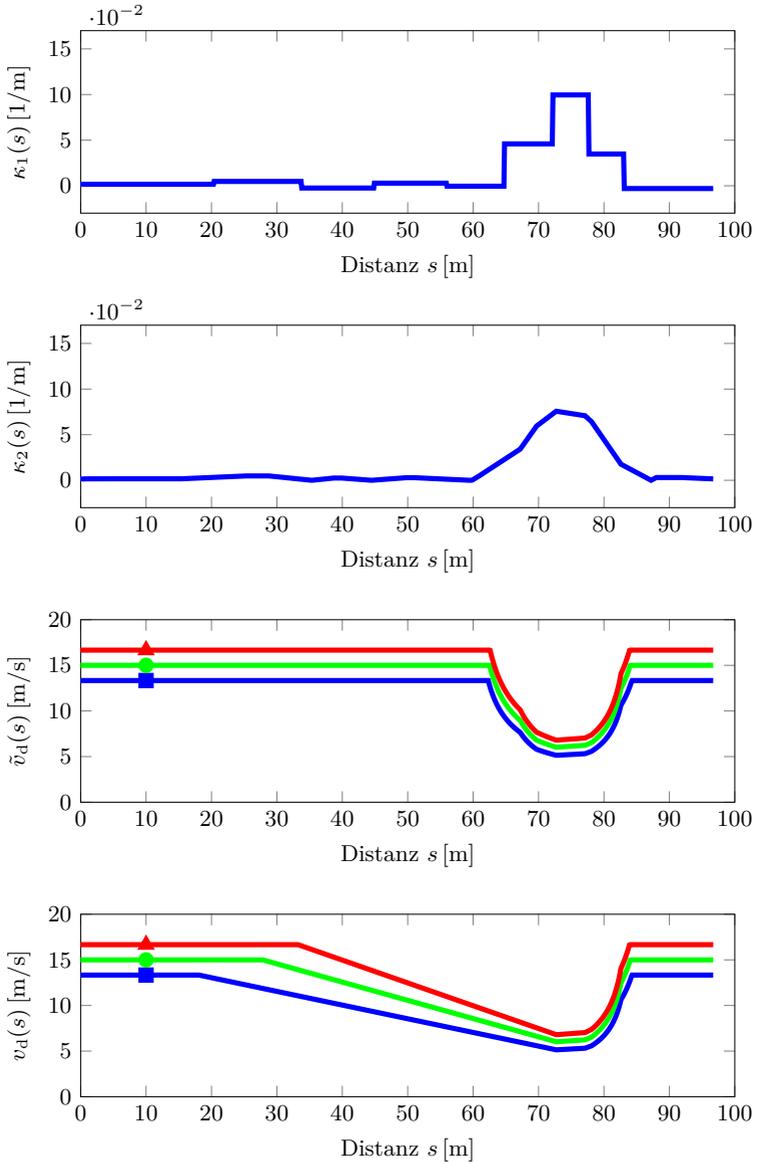


Abbildung 3.18: Erzeugung von Wunschgeschwindigkeitsprofilen auf Basis der Geometrie des vorausliegenden Pfades. In den unteren beiden Diagrammen steht blau für das Profil $VP = 1$, grün für $VP = 2$ und rot für $VP = 3$.

zelle Kreuzung erforderlich. Im Gegensatz dazu erzeugt der zweite Ansatz die Wunschgeschwindigkeitsprofile direkt auf Basis der Krümmung des vorausliegenden Pfades. Da sich die beiden Ansätze in ihren Ergebnissen nicht allzu sehr unterscheiden, wird aufgrund seiner Anwendbarkeit auf beliebige Situationen im Folgenden lediglich der zweite Ansatz vorgestellt.

Abb. 3.18 zeigt das Prinzip: Da die verwendete digitale Karte aus Kreisbogensplines besteht, kann der Krümmungsverlauf $\kappa_1(s)$ des vorausliegenden Pfades mit sehr geringem Aufwand aus den Kehrwerten der Kurvenradien bestimmt werden. Zur Ermittlung des Wunschgeschwindigkeitsprofils wird dieser zunächst mit Hilfe eines Mittelwertfilters geglättet. Da Straßen normalerweise mit sich kontinuierlich ändernden Kurvenradien gebaut werden, ist das Ergebnis ein realistischer Krümmungsverlauf, der bis zu einem gewissen Grad auch das häufig beobachtete Schneiden von Kurven abbildet. Ausgehend von unterschiedlichen Werten für die maximal akzeptierte Querbeschleunigung \bar{a}_{lat} werden auf Basis des geglätteten Krümmungsverlaufs $\kappa_2(s)$ die vorläufigen Wunschgeschwindigkeitsverläufe

$$\tilde{v}_d(s) = \min \left(\sqrt{\frac{\bar{a}_{\text{lat}}}{\kappa_2(s)}}, \bar{v}_d \right) \quad (3.23)$$

berechnet, wobei \bar{v}_d die für das jeweilige Wunschgeschwindigkeitsprofil vp angenommene maximale Wunschgeschwindigkeit darstellt. Im letzten Schritt wird der Geschwindigkeitsgradient $d\tilde{v}_d(s) / ds$ zur Berechnung des resultierenden Wunschgeschwindigkeitsprofils auf entsprechende Minimalwerte g nach unten begrenzt, um unterschiedlich starke Verzögerungen beim Abbremsen vor der Kurve zu berücksichtigen.

Tabelle 3.3: Parameter der Wunschgeschwindigkeitsprofile

	$VP = 1$	$VP = 2$	$VP = 3$
Querbeschleunigung \bar{a}_{lat}	2.00 m/s ²	2.75 m/s ²	3.50 m/s ²
Max. Wunschgeschwindigkeit \bar{v}_d	48 km/h	54 km/h	60 km/h
Geschwindigkeitsgradient g	0.15 s ⁻¹	0.20 s ⁻¹	0.25 s ⁻¹

Die im Rahmen der Arbeit verwendeten Parameterwerte sind in Tab. 3.3 für drei unterschiedliche Wunschgeschwindigkeitsprofile dargestellt. Die Parametrisierung erfolgte hierbei auf Grundlage zahlreicher Abbiegemanöver an den in Abb. 3.19, 3.20 und 3.21 dargestellten Kreuzungen. Für jede der Kreuzungsüberfahrten wurde ein Wunschgeschwindigkeitsverlauf $v_{d,i}(s)$ sowie der zugehörige Beschleunigungsparameter $a_{\text{IDM},i}$ mit Hilfe des im vorangegangenen Abschnitt beschriebenen Verfahrens ermittelt. Anschließend wurden \bar{a}_{lat} ,

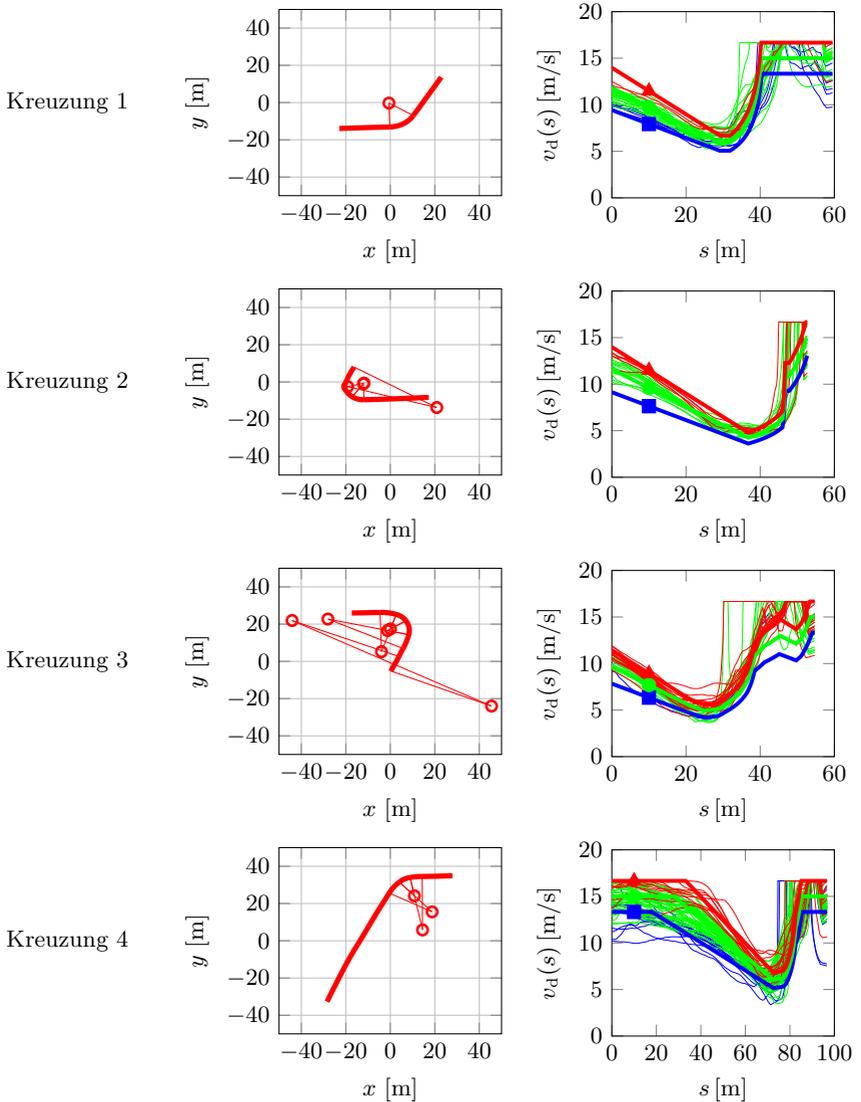


Abbildung 3.19: Kreuzungsgeometrie und Wunschgeschwindigkeitsverläufe untersuchter Kreuzungen, Teil 1. Dünne Linien repräsentieren einzelne Überfahrten, dicke Linien die ermittelten Wunschgeschwindigkeitsprofile.

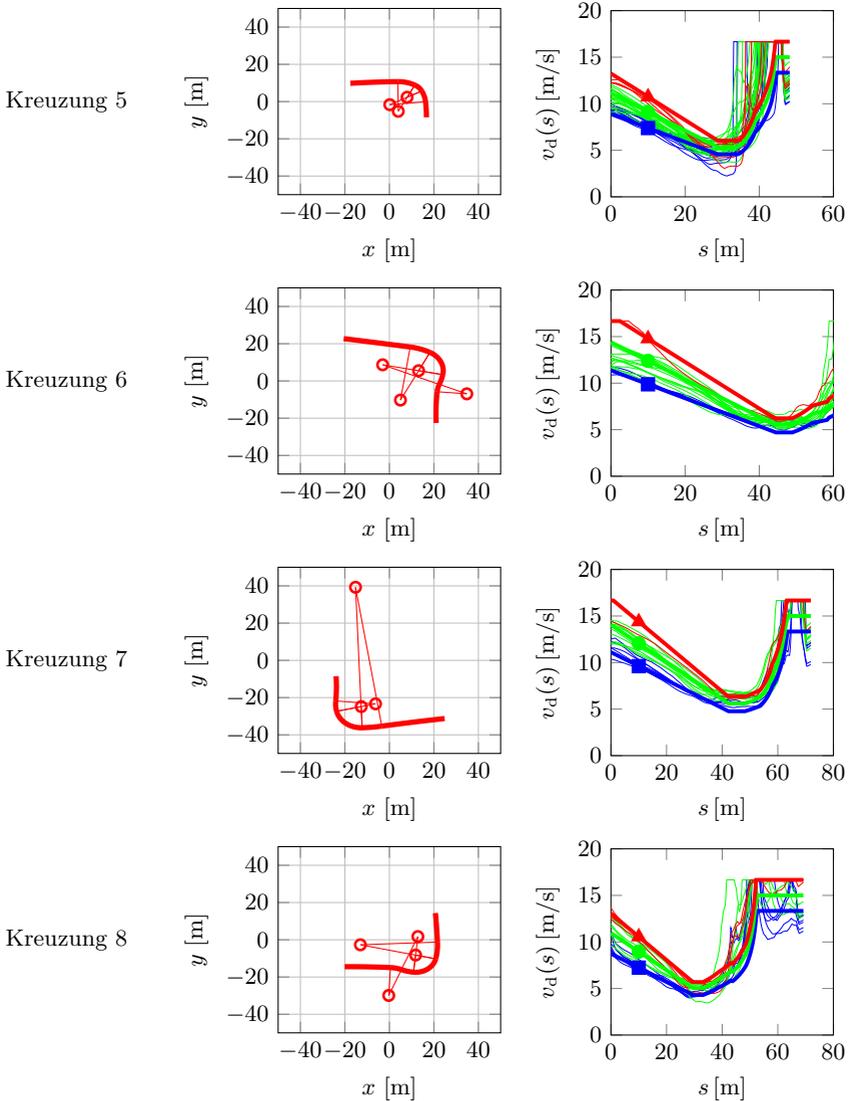


Abbildung 3.20: Kreuzungsgeometrie und Wunschgeschwindigkeitsverläufe untersuchter Kreuzungen, Teil 2. Dünne Linien repräsentieren einzelne Überfahrten, dicke Linien die ermittelten Wunschgeschwindigkeitsprofile.

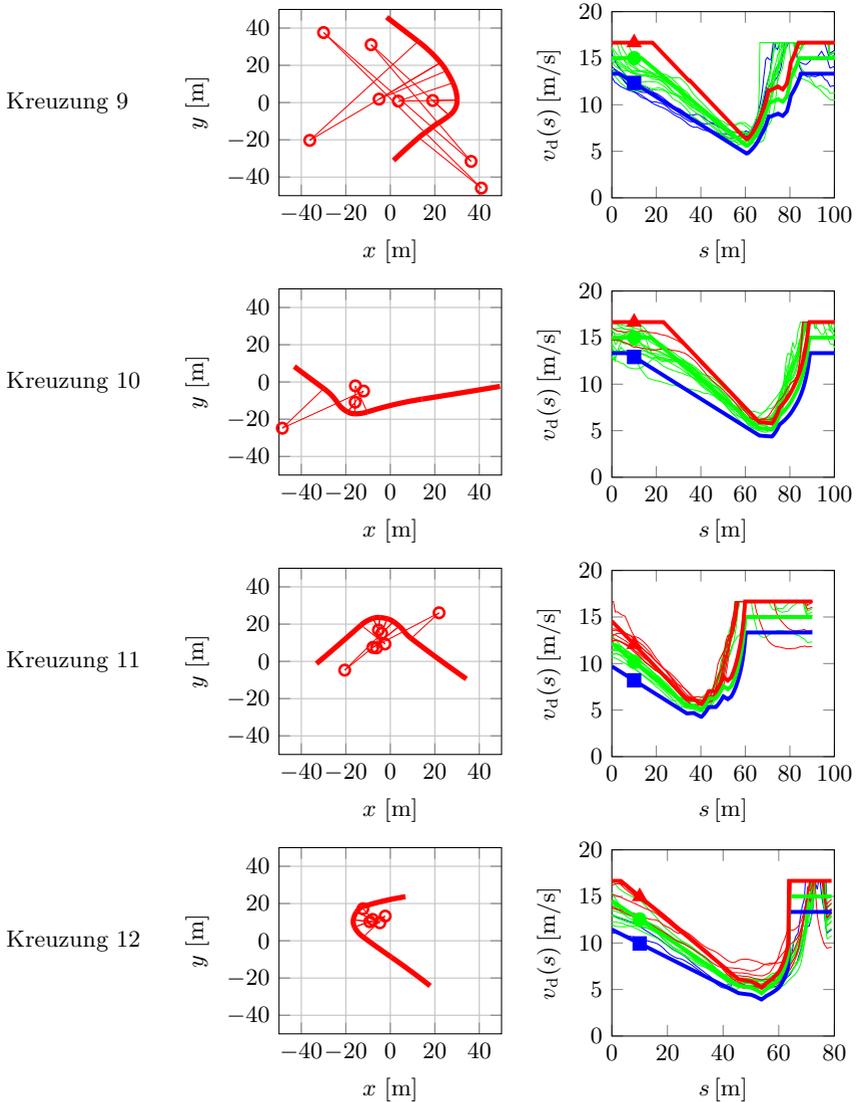


Abbildung 3.21: Kreuzungsgeometrie und Wunschgeschwindigkeitsverläufe untersuchter Kreuzungen, Teil 3. Dünne Linien repräsentieren einzelne Überfahrten, dicke Linien die ermittelten Wunschgeschwindigkeitsprofile.

\bar{v}_d und g dahingehend optimiert, dass die drei Parametersätze ein möglichst breites Spektrum der beobachteten Wunschgeschwindigkeitsverläufe abbilden. Im Ergebnis modelliert der zu $VP = 1$ gehörende Parametersatz den Wunschgeschwindigkeitsverlauf eines eher defensiven Fahrers, während $VP = 2$ den eines Normalfahrers und $VP = 3$ den eines sportlichen Fahrers repräsentiert. Die Zuordnung der beobachteten Wunschgeschwindigkeitsverläufe $v_{di}(s)$ zu je einem der drei Parametersätze erfolgte anschließend anhand ihrer mittleren quadratischen Abweichung zu den aus den Parametersätzen resultierenden Wunschgeschwindigkeitsverläufen. Die jeweilige Anzahl der Zuordnungen wird im Folgenden als Näherung für die Wahrscheinlichkeitsverteilung des durch die Zufallsgröße VP repräsentierten Wunschgeschwindigkeitsprofils verwendet.

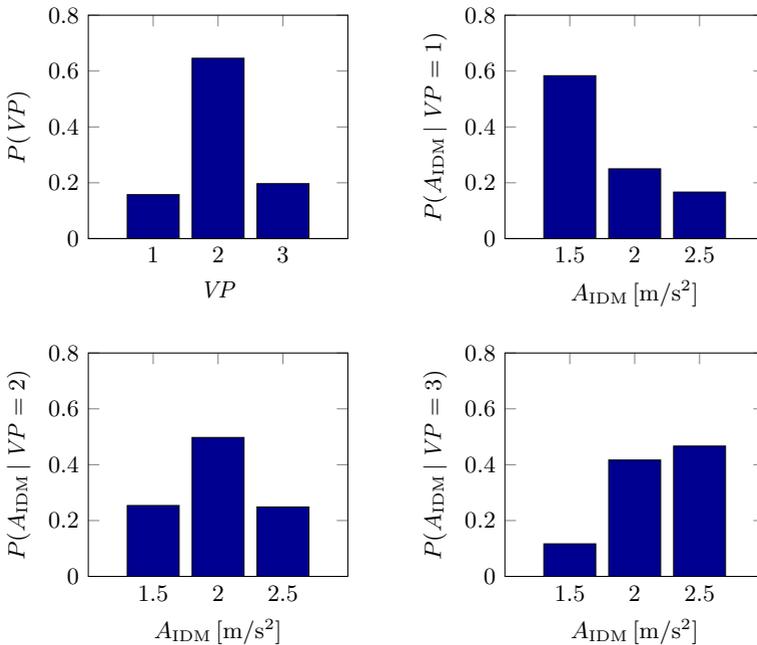


Abbildung 3.22: Wahrscheinlichkeitsverteilungen für das Wunschgeschwindigkeitsprofil VP und den Beschleunigungsparameter A_{IDM}

Neben seiner Eintrittswahrscheinlichkeit kann für jedes der Wunschgeschwindigkeitsprofile ermittelt werden, wie viele der ihm zugewiesenen Überfahr-

ten einen Beschleunigungsparameter a_{IDM} von näherungsweise 1.5 m/s^2 , 2.0 m/s^2 oder 2.5 m/s^2 aufweisen. Die sich daraus ergebende Wahrscheinlichkeitsverteilung für den derart diskretisierten Beschleunigungsparameter A_{IDM} ist zusammen mit der von VP in Abb. 3.22 dargestellt. Offenbar spiegelt sich in der Verteilung von A_{IDM} der allgemeine Fahrstil des zugehörigen Wunschgeschwindigkeitsprofils wider: Während die dem defensiven Wunschgeschwindigkeitsprofil zugewiesenen Überfahrten eher niedrige Werte für den Beschleunigungsparameter aufweisen, sind höhere Werte vor allem bei den dem sportlichen Wunschgeschwindigkeitsprofil mit $VP = 3$ zugewiesenen Überfahrten zu beobachten.

Im Folgenden wird die Kombination aus Wunschgeschwindigkeitsprofil VP und Beschleunigungsparameter A_{IDM} durch je einen von neun möglichen Werten des Fahrerprofils DP abgebildet.

3.3.4 Berechnung der Likelihood

In den vorangegangenen Abschnitten wurde ein Verhaltensmodell entwickelt, das die zu erwartende Beschleunigung des Fahrers in Abhängigkeit von seiner aktuellen Position und Geschwindigkeit, der Kreuzungsgeometrie, eventuell vorhandenen Vorderfahrzeugen sowie dem persönlichen Fahrstil des Fahrers beschreibt und somit den in Abschnitt 1.1.1 identifizierten Anforderungen genügt. Die verbleibende Herausforderung besteht nun darin, die Wahrscheinlichkeit für jede der möglichen Fahrerabsichten aus dem Vergleich zwischen erwartetem und beobachtetem Verhalten zu ermitteln.

Hierbei ist zu beachten, dass die beobachtete Beschleunigung des Fahrzeugs teilweise recht starken Schwankungen unterliegt. Die Schätzung der Fahrerabsicht auf Basis eines einzigen Messwerts ist daher wenig sinnvoll. Andererseits sind aufeinanderfolgende Messwerte miteinander korreliert, so dass diese nicht ohne weiteres als voneinander unabhängige Beobachtungen aufgefasst werden können. Zur Lösung des Problems wurden im Rahmen der Arbeit zwei verschiedene Ansätze betrachtet, um die Messwerte aus mehreren Zeitschritten zu einem einzigen, komplexen Merkmal zusammenzufassen. Im Folgenden werden beide Ansätze kurz vorgestellt:

1. *Vergleichsbasierter Ansatz:* Hierbei werden die beobachteten Beschleunigungswerte direkt mit den für die jeweilige Fahrerabsicht und den jeweiligen Fahrertyp zu erwartenden Beschleunigungswerten verglichen und die resultierenden Log-Likelihoods anschließend über den betrachteten Zeithorizont gemittelt. Für die kontinuierliche Schätzung der

Fahrerabsicht können die Likelihoods der letzten Zeitschritte wieder verwendet werden, so dass jeweils nur die Likelihood des aktuellen Zeitschritts neu zu berechnen ist.

2. *Simulationsbasierter Ansatz*: Statt die beobachteten Beschleunigungswerte direkt auszuwerten, wird für jede der potenziellen Fahrerabsichten und für jeden Fahrertyp der Geschwindigkeitsverlauf simuliert, der ausgehend von der beobachteten Anfangsposition und Anfangsgeschwindigkeit beispielsweise für die letzten 1.5s zu erwarten gewesen wäre. Die Zuordnung der Wahrscheinlichkeiten erfolgt im Anschluss durch den Vergleich der Endwerte der Simulation mit der zum aktuellen Zeitpunkt beobachteten Position und Geschwindigkeit des Fahrzeugs.

Im Gegensatz zum vergleichsbasierten Ansatz erlaubt es die Simulation des erwarteten Geschwindigkeitsverlaufs, kurzfristige Variationen des Fahrerhaltens auf natürliche Weise zu glätten. Folgt der Fahrer beispielsweise einem Vorderfahrzeug und hält dabei einen unerwartet großen Abstand, so führt dies beim vergleichsbasierten Ansatz zu einer ständigen Diskrepanz zwischen der beobachteten und der für das Aufschließen zum Vorderfahrzeug erwarteten Beschleunigung, während beim simulationsbasierten Ansatz lediglich eine Abweichung in der aktuellen Distanz, nicht jedoch in der Geschwindigkeit festgestellt wird.

Ein wesentlicher Nachteil des simulationsbasierten Ansatzes ist seine fehlende Robustheit in Bezug auf direkt vor dem Fahrzeug auftauchende Objekte, die zwar von den Sensoren ausgegeben werden, tatsächlich aber gar nicht existieren (sog. Geisterobjekte). In diesem Fall wäre das vom Fahrermodell ausgegebene Verhalten eine sofortige Vollbremsung mit maximaler Verzögerung, was natürlich nicht dem tatsächlich beobachteten Fahrerverhalten entspricht. Während der vergleichsbasierte Ansatz lediglich für die Dauer der Falscherkennung sehr niedrige Likelihoods für alle potenziellen Fahrerabsichten aufsummiert und nach Verschwinden des Geisterobjekts sofort wieder einsatzfähig ist, kommt es beim simulationsbasierten Ansatz ohne entsprechende Filterung der Sensordaten zu einer simulierten Vollbremsung des Fahrzeugs, so dass das Ergebnis der Fahrerabsichtserkennung so lange unbrauchbar ist, wie die Detektion des Geisterobjekts innerhalb des Simulationszeitraums liegt.

Dies und die Tatsache, dass der simulationsbasierte Ansatz aufgrund der fehlenden Wiederverwertbarkeit der in den einzelnen Zeitschritten gewonnenen Ergebnisse deutlich mehr Rechenleistung benötigt, sind die Gründe, warum im Folgenden lediglich der vergleichsbasierte Ansatz betrachtet wird.

Grundlage des Vergleichs sind die in der jeweiligen Situation zu erwartenden Beschleunigungswerte $\hat{a}_k^{(h)}$, die mit Hilfe des Fahrerverhaltensmodells für jede Fahrerabsicht h , jedes Fahrerprofil $DP = dp$ und die zum jeweiligen Zeitschritt k geltenden Umgebungsbedingungen ermittelt werden können. Unter der Annahme normalverteilter Abweichungen ergibt sich die durch das Fahrerprofil dp bedingte Likelihood der tatsächlich beobachteten Beschleunigung a_k zu

$$f_{A_k}^{(h, dp)}(a_k) = \frac{1}{\sqrt{2\pi}\sigma_A} \exp\left[-\frac{1}{2}\left(\frac{a_k - \hat{a}_k^{(h)} dp}{\sigma_A}\right)^2\right], \quad (3.24)$$

wobei A_k die zur Realisierung a_k gehörende Zufallsgröße und σ_A ein Maß für die verbleibende Variabilität des Fahrerverhaltens darstellt.

Zur Begrenzung des Einflusses einzelner unplausibler Beobachtungen wird zudem angenommen, dass das beobachtete Fahrerverhalten mit einer Restwahrscheinlichkeit p_{A0} auf Einflüsse zurückzuführen ist, die durch das Fahrermodell nicht berücksichtigt werden. Die zu erwartende Beschleunigung wird in diesem Fall als gleichverteilt zwischen -10 m/s^2 und 10 m/s^2 modelliert. Für die Likelihood der Beobachtung a_k gilt somit

$$f_{A_k}^{(h)}(a_k) = \frac{p_{A0}}{20 \text{ m/s}^2} + (1 - p_{A0}) \sum_{dp} f_{A_k}^{(h, dp)}(a_k) P(DP = dp), \quad (3.25)$$

mit $P(DP) = P(A_{\text{IDM}} | VP) P(VP)$ der Prior-Wahrscheinlichkeit für das jeweilige Fahrerprofil. Um den Einfluss zufälliger Abweichungen zwischen zu erwartendem und beobachtetem Fahrerverhalten zugunsten von andauernden moderaten Abweichungen zu reduzieren und dabei der Korrelation zwischen aufeinanderfolgenden Beobachtungen Rechnung zu tragen, wird die Log-Likelihood abschließend über mehrere Zeitschritte gemittelt:

$$f_{VF_k}^{(h)}(a_{k-n_{VF}+1}, \dots, a_k) = \exp\left[\frac{1}{n_{VF}} \sum_{i=0}^{n_{VF}-1} \log\left(f_{A_{k-i}}^{(h)}(a_{k-i})\right)\right]. \quad (3.26)$$

Mathematisch entspricht dies der Reduktion der Anzahl der als unabhängig modellierten Beobachtungen der Beschleunigung auf eine einzige Beobachtung der Zufallsgröße $VF_k = [A_{k-n_{VF}+1}, \dots, A_k]$, die somit gleichberechtigt zum Blinkermerkmal in die Fusion der Merkmale in (3.8) eingeht.

Im Rahmen der Arbeit wurde über $n_{VF} = 14$ Zeitschritte mit einer Dauer von je 100 ms gemittelt, wobei $\sigma_A = 1.2 \text{ m/s}^2$ und $p_{A0} = 0.01$ angenommen wurde.

3.3.5 Vorhersage des Geschwindigkeitsverlaufs

Neben der Fahrerabsicht spielt für die Risikobewertung von Verkehrssituationen auch die Zeit bis zum Erreichen des Konfliktpunkts eine entscheidende Rolle. Die Herausforderung besteht hierbei darin, dass diese im Fall von Abbiegemanövern anhand kinematischer und dynamischer Bewegungsmodelle selbst bei Vorgabe des zukünftigen Pfades nur mit unzureichender Genauigkeit abgeschätzt werden kann, da der Geschwindigkeitsverlauf maßgeblich durch das Abbremsen des Fahrers vor der Abbiegung bestimmt wird. Andererseits wurde in diesem Abschnitt ein Modell entwickelt, das ohne weiteres dazu genutzt werden kann, genau dieses Verzögerungsverhalten zu simulieren.

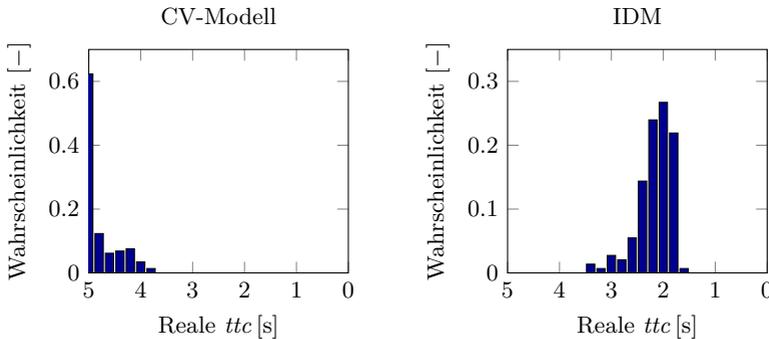


Abbildung 3.23: Genauigkeit der Vorhersage der verbleibenden Zeit bis zum Konfliktpunkt (ttc). Links: Vorhersage mit konstanter Geschwindigkeit (CV-Modell). Rechts: Vorhersage auf Basis des IDM. Die reale ttc bezieht sich auf die Zeitspanne zwischen der ersten Schätzung einer $ttc \leq 2$ s und der tatsächlichen Zeit bis zum Erreichen des Konfliktpunkts. Werte oberhalb von 5 s werden durch $ttc = 5$ s abgebildet [96].

Die erreichbare Genauigkeit ist in Abb. 3.23 anhand von 165 Rechtsabbiegemanövern an der in Abb. 3.15 abgebildeten Kreuzung dargestellt: Während das CV-Modell die verbleibende Zeit bis zum Erreichen des Konfliktpunkts am Fußgängerüberweg grundsätzlich unterschätzt, ist durch die Simulation des Geschwindigkeitsverlaufs auf Basis des IDM eine Vorhersagegenauigkeit von etwa einer halben Sekunde möglich. Darüber hinausgehende Unterschätzungen sind der Interaktion mit wartenden Vorderfahrzeugen bzw. den vorrangigen Fußgängern und Radfahrern geschuldet.

3.4 Modellierung der Kopfdrehung

Neben der nach außen gerichteten Sensorik zur Umfelderkennung werden zukünftig auch Innenraumkameras zur Fahrerbeobachtung eine wichtige Rolle bei der Entwicklung von Fahrerassistenzsystemen spielen. Getrieben wird die Technologie hierbei zunächst vom Wettbewerb um das beste und innovativste Bedienkonzept, wie etwa der Anfang 2014 auf der CES in Las Vegas vorgestellten Blicksteuerung von Continental [107]. Weitere unmittelbare Anwendungen bestehen in der Automatisierung der Sitzeinstellung sowie einer verbesserten Müdigkeits- und Ablenkungserkennung. In dem folgenden Abschnitt wird nun gezeigt, wie sich die Kameras auch zur Fahrerabsichtserkennung einsetzen lassen. Von zentraler Bedeutung sind sie darüber hinaus für die in Kapitel 4 vorgestellte Modellierung des Situationsbewusstseins zur Realisierung eines elektronischen Copiloten.

Bereits heute ist eine Vielzahl sog. Eye- und Head-Tracking-Systeme auf dem Markt. Neben teuren Entwicklungssystemen mit Preisen bis zu 100 000 Euro, die beispielsweise in Fahr- und Flugsimulatoren zur Anwendung kommen, sind mittlerweile auch Systeme für unter 200 Euro im Consumer-Bereich erhältlich. Die Herausforderung besteht derzeit vor allem in der Verbesserung der Robustheit der Systeme im Hinblick auf die im Fahrzeug auftretenden Vibrationen sowie die ständigen Beleuchtungswechsel. Bei dem in Abb. 3.24 dargestellten und im Rahmen der Arbeit verwendeten Eye-Tracking-System werden dazu Infrarot-Blitzlichter in Kombination mit entsprechenden Kamerafiltern eingesetzt.



Abbildung 3.24: Kameras und Infrarot-Blitzlichter zur kontinuierlichen Erfassung von Blickrichtung und Kopfdrehung des Fahrers

3.4.1 Ursachen für die Blickrichtung des Fahrers

Bekanntermaßen sind Autofahrer bei der Erfassung ihrer Umgebung hauptsächlich auf visuelle Informationen angewiesen. Durch Beobachtung seines Blickverhaltens lassen sich daher auch Hinweise über die Absicht des Fahrers gewinnen. Zu diesem Zweck ist zwischen zwei wichtigen Ursachen für die Blickrichtung des Fahrers zu unterscheiden: Der Notwendigkeit, den aktuellen Kurs des Fahrzeugs relativ zum beabsichtigten Pfad zu verfolgen und ggf. zu korrigieren, und der Notwendigkeit sicherzustellen, dass sich entlang dieses Pfades keine Konflikte mit anderen Verkehrsteilnehmern ergeben. Letzteres resultiert in vergleichsweise kurzen Blicken in Richtung möglicher Gefahren. In der früheren Veröffentlichung [9] des Autors wurden diese genutzt, um Fahrstreifenwechsel und Abbiegemanöver vorherzusagen. Allerdings erhöht sich durch eben diese Blicke auch die Wahrscheinlichkeit, dass der Fahrer den potenziellen Konfliktpartner wahrnimmt und aus diesem Grund sein Verhalten anpasst. Um die Sicherungsblicke im Rahmen der Risikobewertung sinnvoll berücksichtigen zu können, ist daher die Modellierung des Situationsbewusstseins des Fahrers erforderlich. Da dies jedoch Gegenstand von Kapitel 4 ist, wird an dieser Stelle lediglich jener Teil des Blickverhaltens berücksichtigt, der direkt auf die Bahnführungsaufgabe des Fahrers zurückzuführen ist.

Die Erfahrungen mit dem in Abb. 3.24 dargestellten Eye-Tracking-System haben gezeigt, dass die Kopfdrehung des Fahrers von diesem deutlich robuster erkannt werden kann als seine Blickrichtung. Im Folgenden wird daher die Kopfdrehung als Messgröße für die Fahrerabsichtserkennung verwendet.

3.4.2 Modell für die Fahrerabsichtsvorhersage

Teilnehmern von professionellen Fahrertrainings wird bei der Übung von Ausweichmanövern oft gesagt, dass sie nicht das Hindernis, sondern den freien Pfad um dieses herum fixieren sollen, da sie das Fahrzeug unbewusst in die Richtung lenken, in die sie schauen. Umgekehrt ergibt die Recherche der zugehörigen Fachliteratur, dass Fahrer ihre Blicke beim Durchfahren einer Kurve entweder auf deren inneren Tangentenpunkt [108] oder den angestrebten Pfad selbst [109] zu konzentrieren scheinen. Zur Annäherung dieses Sachverhalts definieren wir für jede Hypothese h einen sogenannten *Expected-Gaze-Point*, der sich in Abhängigkeit von der aktuellen Fahrzeuggeschwindigkeit v_k in der Entfernung $\alpha_{H0} + \alpha_{H1} v_k$ entlang des zugehörigen Pfades befindet. Zusätzlich wird eine konstante Abweichung β_{H0} in lateraler

Richtung angenommen. Ein typisches Beispiel für die Lage dieser Punkte ist in Abb. 3.25 dargestellt.

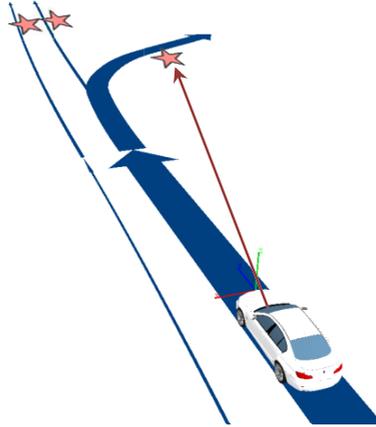


Abbildung 3.25: Expected-Gaze-Points für eine Rechtsabbiegs-Situation

Aus der Position des Expected-Gaze-Points kann somit für jede der Hypothesen h der im Zeitschritt k zu erwartende Kopfdrehungswinkel $\hat{\varphi}_{\text{HEGP}_k}^{(h)}$ des Fahrers relativ zum Fahrzeugkoordinatensystem berechnet werden. Unter Annahme normalverteilter Abweichungen ergibt sich daraus die Wahrscheinlichkeitsdichtefunktion

$$f_{\Phi_{Hk}}^{(h)}(\varphi_{Hk}) = \frac{p_{H0}}{2\pi} + \frac{1-p_{H0}}{\sqrt{2\pi}\sigma_{\text{HEGP}}} \exp\left[-\frac{1}{2}\left(\frac{\varphi_{Hk} - \hat{\varphi}_{\text{HEGP}_k}^{(h)}}{\sigma_{\text{HEGP}}}\right)^2\right] \quad (3.27)$$

für die Kopfdrehung φ_{Hk} bzw. die zugehörige Zufallsgröße Φ_{Hk} . Analog zu p_{A0} in (3.25) stellt p_{H0} hierbei die Wahrscheinlichkeit dar, dass die beobachtete Kopfdrehung auf andere Ursachen als die Bahnführungsaufgabe zurückzuführen ist. Da in diesem Fall eine Gleichverteilung über den gesamten Definitionsbereich der Kopfdrehung angenommen wird, dient p_{H0} auch der Festlegung einer unteren Grenze von $f_{\Phi_{Hk}}^{(h)}(\varphi_{Hk})$ und somit der Begrenzung des maximalen Einflusses des Kopfdrehungsmerkmals.

Sowohl die Parameter der Expected-Gaze-Points α_{H0} , α_{H1} und β_{H0} als auch die der Wahrscheinlichkeitsdichtefunktion σ_{HEGP} und p_{H0} wurden als *Maximum-Likelihood-Estimate* auf Basis von über 200 Kreuzungsüberfahrten (6 Probanden, 3 Kreuzungen) bestimmt. Die resultierenden Parameterwerte sind in Tab. 3.4 aufgelistet. Abb. 3.26 zeigt sowohl die beobachteten als

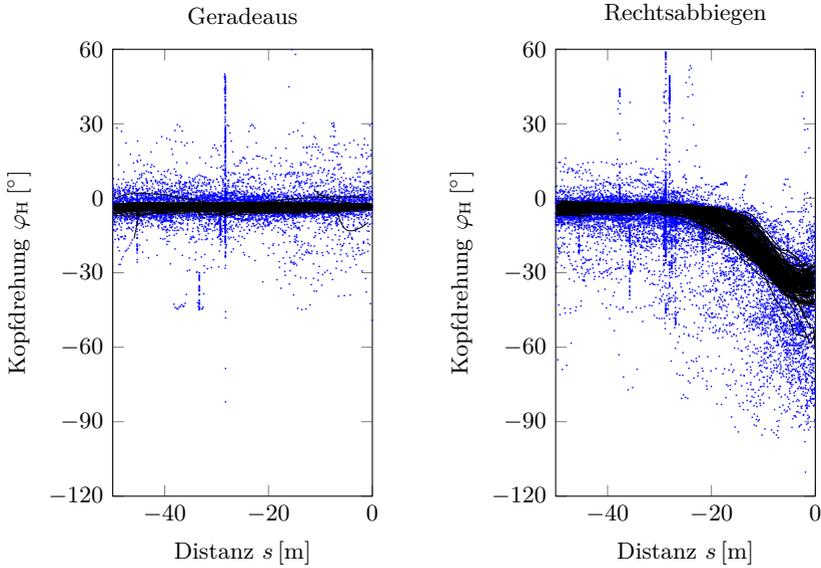


Abbildung 3.26: Tatsächliche (blaue Punkte) und vom Modell ausgegebene (schwarze Linien) Kopfdrehung des Fahrers für Geradeausfahrten (links) und Rechtsabbiege-Manöver (rechts). Die Kopfdrehung ist im mathematisch positiven Drehsinn bezogen auf die Fahrzeuglängsachse angegeben.

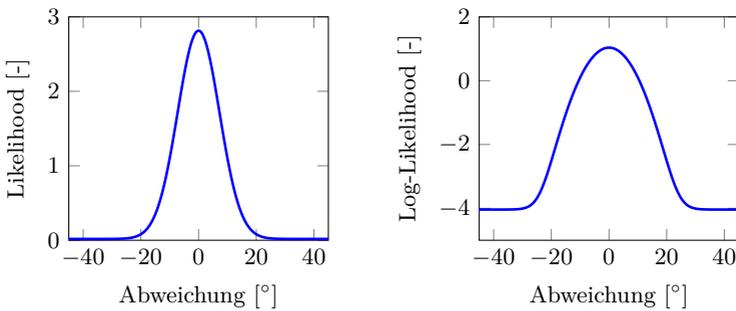


Abbildung 3.27: Wahrscheinlichkeitsdichtefunktion $f_{\Phi_H k}^{(h)}(\varphi_H k)$

Tabelle 3.4: Blickparameter

Parameter	Wert	Einheit
Vorausschauentfernung α_{H0}	6.07	m
Vorausschauzeit α_{H1}	1.05	s
Lateraler Versatz β_{H0}	-0.81	m
Standardabweichung σ_{HEGP}	0.13	—
Grundwahrscheinlichkeit p_{H0}	0.11	—

auch die vom Modell berechneten Kopfdrehungswinkel über der Distanz relativ zu den Gabelungspunkten der Kreuzungen. Die starke Streuung der beobachteten Kopfdrehungen bei $s = -30$ m ist hierbei auf das Anhalten des Fahrzeugs an der Haltelinie der in Abb. 3.15 dargestellten Kreuzung zurückzuführen. Die Wahrscheinlichkeitsdichtefunktion $f_{\Phi_{Hk}}^{(h)}(\varphi_{Hk})$ sowie deren Logarithmus sind in Abb. 3.27 dargestellt.

Allein schon aufgrund der Tatsache, dass das Modell die zu erwartenden Schulter- und Spiegelblicke des Fahrers nicht explizit abbildet, erlaubt die beobachtete Kopfdrehung des Fahrers nicht in jedem Zeitschritt einen Rückschluss auf den von ihm verfolgten Pfad. Eine Fahrerabsichtserkennung ist daher lediglich auf Basis der mittleren Übereinstimmung der beobachteten Kopfdrehung mit der für die jeweilige Hypothese erwarteten Kopfdrehung möglich. Analog zum Vorgehen in Abschnitt 3.3.4 werden die miteinander korrelierten Einzelbeobachtungen daher zu einer einzigen virtuellen Beobachtung der Zufallsgröße $GF_k = [\Phi_{Hk-n_{GF}+1}, \dots, \Phi_{Hk}]$ zusammengefasst:

$$f_{GF_k}^{(h)}(\varphi_{k-n_{Gaze}+1}, \dots, \varphi_k) = \exp \left[\frac{1}{n_{GF}} \sum_{i=0}^{n_{GF}-1} \log \left(f_{\Phi_{Hk-i}}^{(h)}(\varphi_{Hk-i}) \right) \right]. \quad (3.28)$$

Im Rahmen der nachfolgenden Auswertungen werden die Ergebnisse der Beobachtungswahrscheinlichkeit über $n_{GF} = 10$ Zeitschritte gemittelt.

3.5 Bewertung der Vorhersagequalität

Für die in den vorangegangenen Abschnitten entwickelten Fahrerverhaltensmodelle wird im Folgenden untersucht, wie gut die darauf basierenden Merkmale sowohl einzeln als auch in Kombination zur Fahrerabsichtserkennung eingesetzt werden können. Dazu ist es erforderlich, dass die zur

Bewertung herangezogenen Manöver grundsätzlich mit Hilfe jedes der hier betrachteten Merkmale erkannt werden können, während die Vorhersage anhand der Fahrzeugposition allein nicht möglich sein sollte. Um quantitativ belastbare Ergebnisse zu erhalten, müssen die betrachteten Manöver darüber hinaus in großer Zahl im realen Straßenverkehr wiederholbar sein.

Aus den genannten Gründen – und um zudem die Vergleichbarkeit mit den Ergebnissen bestehender Arbeiten zu gewährleisten – wird die Vorhersagefähigkeit der Merkmale anhand einfacher Rechtsabbiegemanöver bewertet, obwohl mit der in Abschnitt 3.1 beschriebenen Methode prinzipiell beliebig komplexe Manöverkombinationen vorhergesagt werden können.

3.5.1 Versuchsaufbau

Grundlage der Bewertung sind die Daten eines Fahrversuchs mit 12 Probanden und insgesamt 15 Stunden Fahrzeit. Jeder Proband fuhr hierbei eine vorher festgelegte Route ab, die mehrfach über 5 verschiedene Kreuzungen führte, die im Rahmen der Parametrisierung der Modelle bisher noch nicht verwendet wurden. Insgesamt wurden hierbei 155 Rechtsabbiegemanöver und 244 Geradeausfahrten aufgezeichnet. Als Bezugspunkt für die Vorhersage der Fahrerabsicht diente ein für jede der Kreuzungen manuell festgelegter Konfliktpunkt am Fußgängerüberweg direkt nach der Rechtsabbiegung, der näherungsweise dem jeweiligen Gabelungspunkt entspricht. Die verbleibende Zeit bis zum Erreichen des Konfliktpunkts (*ttc*) wurde bei Kreuzungsannäherung kontinuierlich mit der in Abschnitt 3.3.5 vorgestellten Methode bestimmt. Zur Eigenlokalisierung wurde hierbei eine hochgenaue GPS/INS Plattform verwendet, sodass Positionsfehler vernachlässigt werden können.

3.5.2 Aussagekraft der einzelnen Merkmale

Das Ergebnis der Vorhersage auf Basis der einzelnen Merkmale ist in Abb. 3.28 dargestellt. Die beste Vorhersagefähigkeit besitzt hierbei offenbar das Blinkermerkmal, wobei dies zumindest teilweise auf die Tatsache zurückzuführen ist, dass Probanden in Fahrversuchen im Gegensatz zu ihrem natürlichen Fahrverhalten fast immer den Blinker setzen. Auch der Geschwindigkeitsverlauf scheint als Merkmal sehr gut geeignet – die vorhandenen Fehlklassifikationen gehen hauptsächlich auf Situationen zurück, in denen aufgrund eines langsamen Vorderfahrzeugs oder eines Ampelstopps unmittelbar vor der Abbiegung objektiv keine Vorhersage auf Basis des Geschwindigkeitsverlaufs möglich war. Der Nachteil des Eye- und Headtracking-

Systems besteht darin, dass es bei schnellen Kopfbewegungen, wie sie beim Durchführen von Schulterblicken auftreten, mit der verwendeten Softwareversion die Kopfposition häufig für einige Sekunden verliert. Dies und die Tatsache, dass eben diese Sicherungsblicke nicht im Modell berücksichtigt werden, ist vermutlich die Ursache für die schlechte Erkennungsrate bei hohen Spezifitätswerten und $\hat{t}tc = 2$ s. Nichtsdestotrotz können allein mit dem Kopfdrehungsmerkmal noch fast 90% aller Abbiegemanöver korrekt erkannt werden. Bei $\hat{t}tc = 3$ s liegt diese Zahl allerdings deutlich niedriger.

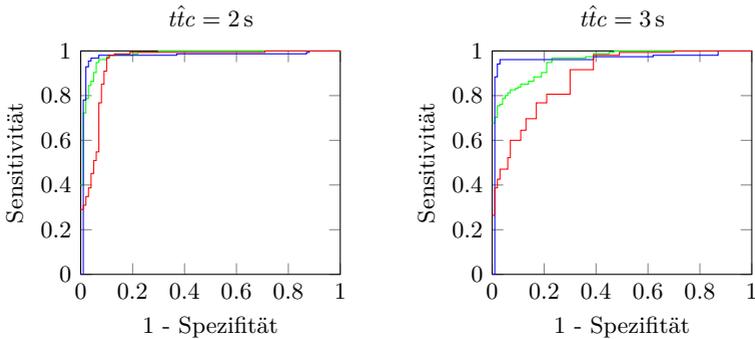


Abbildung 3.28: Vorhersagefähigkeit des Blinkermerkmals (blau), des Geschwindigkeitsmerkmals (grün) und des Kopfdrehungsmerkmals (rot) in Bezug auf die Erkennung von Rechtsabbiegemanövern

3.5.3 Kombination mehrerer Merkmale

Laut Gleichung (3.8) ergibt sich die Posterior-Wahrscheinlichkeit aus der zugehörigen Prior-Wahrscheinlichkeit und dem Produkt der Beobachtungswahrscheinlichkeiten der individuellen Merkmale. Für das logarithmierte Verhältnis der Posterior-Wahrscheinlichkeiten zweier Hypothesen h_1 und h_2 gilt demnach

$$\log \frac{P(H_k = h_1 | O_k)}{P(H_k = h_2 | O_k)} = \sum_i \Delta llh_k^{(i)}(h_1, h_2) + C, \quad (3.29)$$

mit

$$\Delta llh_k^{(i)}(h_1, h_2) = \log P(O_{k_i} | H_k = h_1) - \log P(O_{k_i} | H_k = h_2), \quad (3.30)$$

O_{k_i} je einem der drei betrachteten Merkmale und $C = 0$, falls sich die Prior-Wahrscheinlichkeiten wie in dem hier betrachteten Fall nicht unterscheiden.

In Abb. 3.29 sind die Beiträge der zu den drei Merkmalen gehörenden LLH-Differenzen für vier besonders interessante Situationen dargestellt, wobei h_1 das Abbiegemanöver und h_2 die Geradeausfahrt repräsentiert. Die Beispiele zeigen, dass sich die Merkmale gut ergänzen und dass zwei von ihnen ggf. auch ein drittes Merkmal überstimmen können. Bei der in Abb. 3.29 unten rechts dargestellten Situation führt dies dazu, dass die Rechtsabbiegeabsicht trotz Deaktivierung des Blinkers erkannt wird. Dass dies in der unten links dargestellten Situation nicht so gut funktioniert, ist allein darauf zurückzuführen, dass der Geschwindigkeitsverlauf erst sehr spät einen Rückschluss auf die Fahrerabsicht erlaubt. Die Ursache hierfür könnte beispielsweise ein

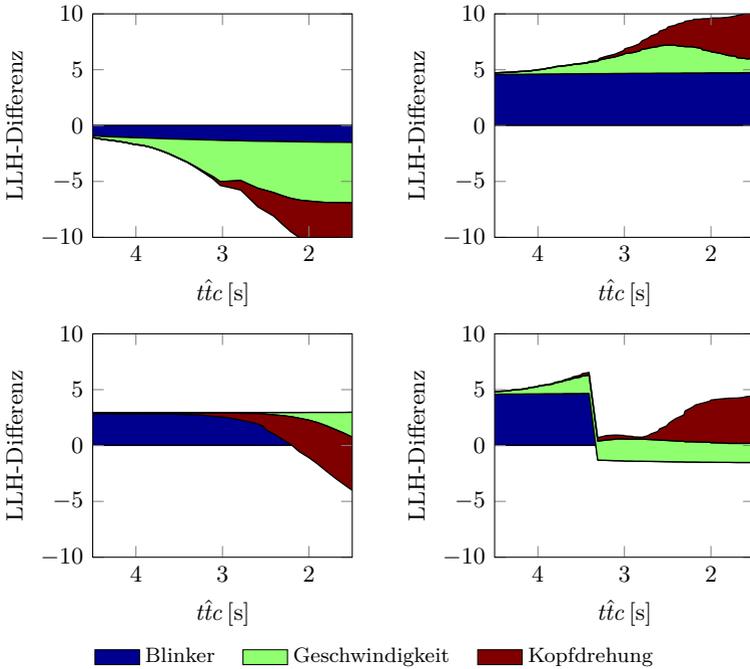


Abbildung 3.29: Beitrag der auf die drei Merkmale zurückzuführenden LLH-Differenzen $\Delta llh_k^{(i)}(h_1, h_2)$ zu dem Klassifikationsergebnis. Ausgehend von Null wird hierbei zunächst der Anteil des Blinkermerkmals aufgetragen, danach das des Geschwindigkeitsmerkmals und zuletzt das der Kopfdrehung. Oben links: Normale Geradeausfahrt. Oben rechts: Normales Abbiegemanöver. Unten links: Geradeausfahrt mit nach rechts aktiviertem Blinker. Unten rechts: Rechtsabbiegeманöver, bei dem der Blinker bei $\hat{t}c \approx 3.3$ s abgeschaltet wird.

langsamerer Vorderfahrzeug sein. Abgesehen davon bestätigen die Diagramme noch einmal die Vermutung, dass anhand der Kopfdrehung des Fahrers in vielen Fällen erst ab $t_{tc} < 2.5\text{ s}$ auf die Fahrerabsicht geschlossen werden kann.

Eine quantitative Auswertung der verschiedenen Merkmalskombinationen ist durch Tab. 3.5 gegeben. Hierbei wird angenommen, dass ein Rechtsabbiegevorgang vorhergesagt wird, wenn dessen Wahrscheinlichkeit größer als 50% ist. Es wird zwischen drei Fällen unterschieden:

1. Das Blinkersignal ist nicht verfügbar (-). Dies ist beispielsweise dann der Fall, wenn die Absicht anderer Verkehrsteilnehmer rein auf Basis ihrer Position und Geschwindigkeit ermittelt werden soll. In diesem Fall ergibt sich bei $\hat{t}_{tc} = 3\text{ s}$ sowohl für das Geschwindigkeits- und das Kopfdrehungsmerkmal als auch für deren Kombination eine hervorragende Sensitivität, allerdings nur eine moderate Spezifität.
2. Das Blinkersignal ist verfügbar (+), was entweder der Fall ist, wenn die Absicht des eigenen Fahrers vorhergesagt werden soll oder wenn der Blinkerstatus mit Hilfe von Außenkameras beobachtet bzw. mittels Fahrzeug-Fahrzeug-Kommunikation übertragen werden kann. Da der Blinker im Rahmen des Versuchs fast immer vorschriftsmäßig verwendet wurde, bringt die Kombination mit anderen Merkmalen hier kaum noch Vorteile.
3. Das Blinkersignal ist verfügbar, wird aber trotz Abbiegeabsicht nicht gesetzt (0). Diese in der Praxis bei 20% der Abbiegemanöver zu beobachtende Situation [99] wurde für die vorliegende Auswertung nachgestellt, indem das Blinkersignal in allen Datensätzen nachträglich deaktiviert wurde. Hierbei ergibt sich nun eine nahezu 100%-iger Spezifität, was dem Umstand geschuldet ist, dass durch den nicht gesetzten Blinker zunächst das Geradeausfahren wahrscheinlicher ist und Rechtsabbiegevorgänge somit nur noch bei sehr deutlichen Anzeichen im Geschwindigkeitsverlauf und der Kopfdrehung des Fahrers als solche klassifiziert werden. Die Tatsache, dass 15% aller Abbiegemanöver bereits auf Basis der Fahrstreifenzuordnung erkannt werden können, ist auf sehr langsame Abbiegevorgänge beispielsweise in Gegenwart von Vorderfahrzeugen zurückzuführen. Obwohl das Kopfdrehungsmerkmal allein nur sehr selten den Einfluss des nicht gesetzten Blinkers kompensieren kann, steigert es den Anteil der trotzdem erkannten Abbiegemanöver in Kombination mit dem Geschwindigkeitsmerkmal von 67% auf 75%.

Tabelle 3.5: Klassifikationsergebnisse bei $t_{tc} = 3$ s

<i>IF</i>	<i>VF</i>	<i>GF</i>	Sensitivität	Spezifität
–	–	–	0.56	0.69
–	–	+	0.92	0.71
–	+	–	0.97	0.70
–	+	+	0.98	0.74
+	–	–	0.96	0.98
+	–	+	0.96	0.98
+	+	–	0.97	0.98
+	+	+	0.97	0.97
0	–	–	0.15	1.00
0	–	+	0.19	1.00
0	+	–	0.67	1.00
0	+	+	0.75	0.99

Auf Basis der Ergebnisse aus Tab. 3.5 lässt sich festhalten, dass die Kombination der hier betrachteten Merkmale selbst dann noch eine recht gute Vorhersage der Fahrerabsicht erlaubt, wenn eines der Merkmale unplausible Ergebnisse liefert. Der eigentliche Mehrwert gegenüber dem Stand der Technik besteht jedoch in der Allgemeingültigkeit der betrachteten Merkmale, da diese auf einem vollständigen generativen Modell des erwarteten Fahrerverhaltens beruhen und somit auf beliebige Kreuzungsgeometrien und Verkehrssituationen angewendet werden können.

Im Hinblick auf die praktische Anwendung zur Fahrerverhaltensvorhersage wäre es durchaus sinnvoll, optimale Wichtungsfaktoren für die drei Merkmale anhand weiterer Probandenstudien zu bestimmen. Im Rahmen der vorliegenden Arbeit wird auf derartige Optimierungen jedoch verzichtet, um stattdessen im folgenden Kapitel ein Modell für das Situationsbewusstsein des Fahrers zu entwickeln und dessen Nutzen bzw. Notwendigkeit für die Risikobewertung von Verkehrssituationen aufzuzeigen.

4 Risikobewertung unter Berücksichtigung des Situationsbewusstseins

Im vorangegangenen Kapitel wurde eine Methode entwickelt, um die Fahrerabsicht in Form des wahrscheinlichsten zukünftigen Fahrweges zu ermitteln. Nicht berücksichtigt wurde hierbei jedoch die Möglichkeit, dass der Fahrer entlang des von ihm gewählten Pfades anhält, um anderen Verkehrsteilnehmern die Vorfahrt zu gewähren, oder einen geplanten Fahrstreifenwechsel aufschiebt, um ein von hinten herannahendes Fahrzeug vorbeizulassen. Beide Formen der Interaktion sind nur dann sinnvoll darstellbar, wenn das Situationsbewusstsein des Fahrers – dessen mentale Repräsentation der für ihn relevanten Verkehrsteilnehmer sowie seine Einschätzung von deren Bedeutung für die Durchführung der von ihm geplanten Manöver – bei der Modellbildung berücksichtigt wird.

Die Motivation für die Berücksichtigung der Interaktion zwischen Verkehrsteilnehmern wird in Abschnitt 4.1 zunächst an vier potenziellen Anwendungen dargelegt. Aus diesen ergeben sich eine Reihe von Anforderungen an das in Abschnitt 4.2 beschriebene Fahrermodell. Die echtzeitfähige Umsetzung im Versuchsfahrzeug ist Gegenstand von Abschnitt 4.3, während Abschnitt 4.4 eine Diskussion der mit dem Modell gewonnenen Ergebnisse anhand von Beispielsituationen im Realverkehr beinhaltet.

Grundlage der folgenden Ausführungen ist neben den bereits in [9] veröffentlichten Ergebnissen des Autors die von ihm betreute Masterarbeit von Stephan Epping [110].

4.1 Motivation und Anforderungen

Bestehende Arbeiten zur Risikobewertung gehen meist davon aus, dass der Fahrer den potenziellen Konfliktpartner übersieht. Die Notwendigkeit einer Warnung ist somit ausschließlich davon abhängig, ob es in Anbetracht des beabsichtigten Manövers und der vorhandenen Zeitlücke zu einem Konflikt

zwischen den beteiligten Verkehrsteilnehmern kommt. Gleichzeitig wird davon ausgegangen, dass das Assistenzsystem über ein umfassendes Abbild der Verkehrssituation verfügt – gemäß der in Abb. 4.1 dargestellten Einteilung berücksichtigen derartige Assistenzsysteme somit ausschließlich den Quadranten unten rechts.

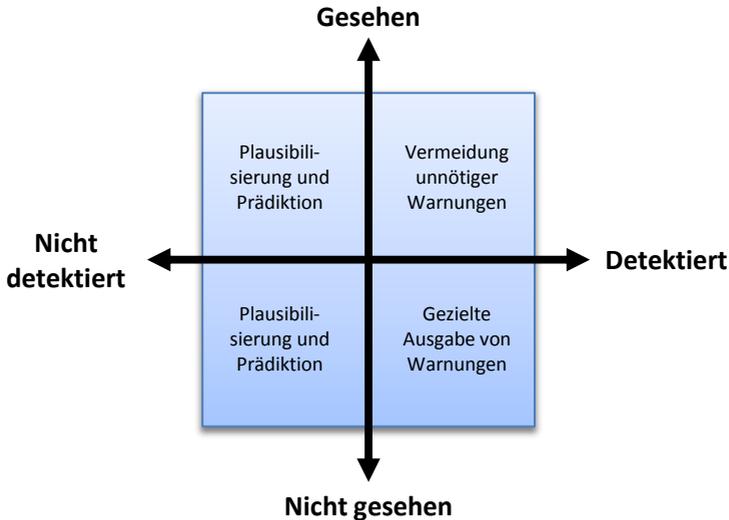


Abbildung 4.1: Nutzen der Situationsanalyse in Abhängigkeit der Wahrnehmung von System und Fahrer (horizontale bzw. vertikale Richtung)

Tatsächlich tritt jedoch häufig die Situation auf, dass der Fahrer die für ihn relevanten Verkehrsteilnehmer bereits gesehen hat und mit diesen interagiert, während das Assistenzsystem selbst nur über ein unvollkommenes Umfeldmodell verfügt. Für das bestmögliche Verständnis der Verkehrssituation und die optimale Unterstützung des Fahrers ist es daher erforderlich, sowohl sein Situationsbewusstsein als auch das des Assistenzsystems explizit zu modellieren. Die folgenden Unterabschnitte verdeutlichen diese Feststellung anhand konkreter Fallbeispiele und ermöglichen die Definition einer Reihe von Anforderungen an die in Abschnitt 4.2 betrachtete Modellbildung.

4.1.1 Vermeidung unnötiger Warnungen

Aus den in Abschnitt 1.1.2 genannten Gründen kann es insbesondere für kommunikationsbasierte Fahrerassistenzsysteme vorteilhaft sein, auf die Ausgabe

von Warnungen gezielt zu verzichten, wenn eine adäquate Fahrerreaktion auch ohne diese zu erwarten ist. Hierfür benötigt das Assistenzsystem eine Einschätzung des Situationsbewusstseins des Fahrers oder muss zumindest den Fall, dass der Fahrer den potenziellen Konfliktpartner bereits wahrgenommen hat und sein Verhalten entsprechend anpasst, als mögliche Fahrerabsicht berücksichtigen. Bei der Verwendung von diskriminativen Methoden zur Fahrerabsichtserkennung kann dies wie in [27, 59] dadurch erfolgen, dass die Gegenwart potenzieller Konfliktpartner direkt als Merkmal beim Anlernen des zugehörigen Klassifikators berücksichtigt wird. Hierbei besteht jedoch das Problem, dass ein mögliches Fehlverhalten des Fahrers in Ermangelung von Messdaten realer Konfliktsituationen nur mit Hilfe synthetischer Daten berücksichtigt werden kann.

Um die Ursachen einer möglichen Fehlentscheidung des Fahrers zu modellieren, kann die Interaktion mit potenziellen Konfliktpartnern auch in Form einer nachgelagerten Durchführbarkeitsentscheidung berücksichtigt werden. Bei den in [9] veröffentlichten Untersuchungen des Autors wird dazu beispielsweise zunächst die Fahrstreifenwechselabsicht des Fahrers unter Vernachlässigung des rückwärtigen Verkehrs ermittelt und anschließend berechnet, mit welcher Wahrscheinlichkeit der Fahrer diesen wahrgenommen und richtig eingeschätzt hat. Der Vorteil der Zweiteilung besteht darin, dass der Klassifikator zur Vorhersage der Fahrerabsicht mit Messdaten unkritischer Manöver angelernt werden kann, während die Durchführbarkeitsentscheidung auf Basis von dedizierten Studien zum Situationsbewusstsein erfolgt. Nachteilig ist hierbei jedoch, dass die Rückwirkungen der Durchführbarkeitsentscheidung auf die Erkennung nachfolgender Manöver, beispielsweise das Durchführen eines Fahrstreifenwechsels nach dem Vorbeilassen eines Fahrzeugs auf der Überholspur, nur schwer abgebildet werden können.

Wesentlich einfacher ist die Modellierung derartiger Rückwirkungen bei Verwendung von generativen Modellen zur Fahrerabsichtserkennung. Insbesondere BNs und DBNs sind aufgrund ihrer Modularisierbarkeit, der Möglichkeit der Verwendung von Fahrerverhaltensmodellen und ihrer Flexibilität hinsichtlich der zu bewertenden Hypothesen hervorragend geeignet, den Einfluss anderer Verkehrsteilnehmer je nach Situationsbewusstsein des Fahrers auf die zu erwartenden Beobachtungen abzubilden. Da die Modelle frei zusammengestellt werden können, ist ein Anlernen anhand realer oder nachgebildeter Messdaten von Konfliktsituationen nicht erforderlich. Um auch temporale Aspekte des Situationsbewusstseins wie die Reaktionszeit des Fahrers oder das Vergessen von Information nachbilden zu können, erfolgt die Modellierung des Situationsbewusstseins in Abschnitt 4.2 auf Basis von dynamischen Bayes'schen Netzen.

4.1.2 Detektion nicht sichtbarer Verkehrsteilnehmer

Wie eingangs bereits dargelegt, verfügt das Assistenzsystem selbst nur über eine unvollkommene Umfelderkennung, sodass der Fahrer mitunter bereits mit Verkehrsteilnehmern interagiert, die sensorisch noch nicht erfasst wurden. Dies ist insbesondere dann regelmäßig der Fall, wenn das Verhalten anderer Verkehrsteilnehmer ausgewertet werden soll. Durch die explizite Berücksichtigung dieses Umstands ist es möglich, das Umfeldmodell und somit das Verständnis der Verkehrssituation durch Rückschlüsse aus dem Verhalten der beobachteten Verkehrsteilnehmer gewinnbringend zu ergänzen.

Ein Beispiel ist in Abb. 4.2 dargestellt: Aus dem Warten des grauen Fahrzeugs direkt vor dem Radweg lässt sich mit hoher Wahrscheinlichkeit auf die Gegenwart eines Fußgängers oder Radfahrers schließen. Unter Berücksichtigung der Tatsache, dass die Umfelderkennung des orangenen Fahrzeugs nach links freie Sicht hat und von dort offensichtlich nichts kommt, und das graue Fahrzeug höchstwahrscheinlich nicht auf einen langsamen Fußgänger von rechts wartet, kann sogar direkt auf die Existenz eines Radfahrers von rechts geschlossen werden. In beiden Fällen kann im orangenen Fahrzeug eine mehr oder weniger spezifische Warnung beim Heranfahren an die Kreuzung ausgegeben werden, obwohl die Umfelderkennung keine direkte Detektion des Radfahrers erlaubt.

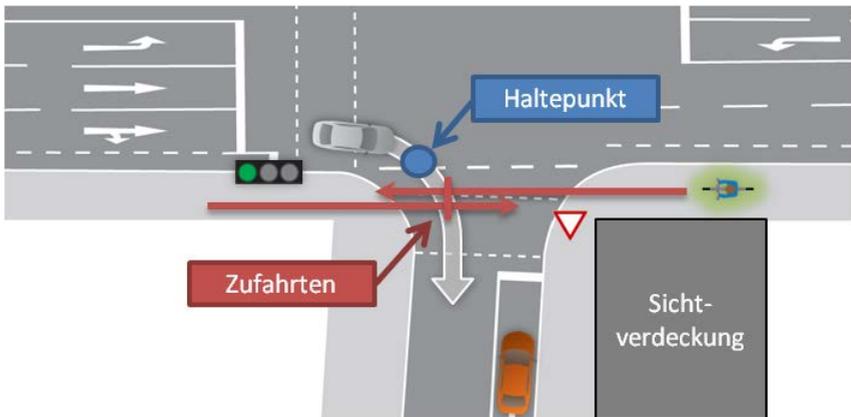


Abbildung 4.2: Detektion nicht sichtbarer Verkehrsteilnehmer aus dem Verständnis der Verkehrssituation heraus. Das orangene Fahrzeug beobachtet, wie das graue Fahrzeug am dargestellten Haltepunkt wartet und schließt daraus, dass mindestens eine der beiden Zufahrten belegt sein muss.

Da der Radfahrer selbst nicht beobachtet wird, ist für die technische Umsetzung der oben beschriebenen Inferenz eine anderweitige Beschreibung potenzieller Interaktion zwischen den Verkehrsteilnehmern erforderlich. Die im Rahmen der Arbeit favorisierte Möglichkeit besteht in der Ergänzung der digitalen Karte um die in Abb. 4.2 dargestellten Haltepunkte und Zufahrten. Jede der Zufahrten kann hierbei entweder belegt oder frei sein, während der zugehörige Haltepunkt nur dann durchfahren wird, wenn der Fahrer davon überzeugt ist, dass beide Zufahrten frei sind.

4.1.3 Verbesserung der Fahrerabsichtserkennung

Die im vorangegangenen Abschnitt beschriebene Modellierung der zum Anhalten des grauen Fahrzeugs führenden Umstände kann gleichzeitig auch zur Erkennung von dessen Abbiegeabsicht herangezogen werden: Würde er geradeaus fahren wollen, gäbe es keinen plausiblen Grund für das Anhalten.

Etwas komplizierter ist die Situation bei der Annäherung an eine Vorfahrtsstraße: In der in Abb. 4.2 dargestellten Situation kann aus dem Verzögern des orangen Fahrzeugs weder auf eine Abbiegeabsicht noch auf die Existenz von potenziellen Konfliktpartnern geschlossen werden, da sein Fahrer wahrscheinlich einfach nur deshalb abbremst, weil er nicht weiß, ob die Vorfahrtsstraße (respektive der zugehörige Haltepunkt) gerade frei ist. Neben der Modellierung von tatsächlicher und vom Fahrer wahrgenommener Belegung der zu einem Haltepunkt gehörenden Zufahrten ist es somit erforderlich, auch die Zuversicht des Fahrers im Hinblick auf die Richtigkeit seiner Einschätzung zu modellieren.

4.1.4 Vorhersage des weiteren Verkehrsgeschehens

Die Herausforderung bei der Vorhersage des weiteren Verkehrsgeschehens besteht vor allem in der kombinatorischen Vielfalt der möglichen weiteren Entwicklungen der aktuellen Verkehrssituation. In Abschnitt 1.2 wurden hierzu bereits entsprechende Ansätze vorgestellt, wobei neben der Verwendung von Markov-Ketten auch partikelbasierte Ansätze diskutiert wurden. Allerdings ergibt sich durch die Modellierung des Situationsbewusstseins ein im Vergleich zu bisherigen Arbeiten nochmals deutlich größerer Zustandsraum, da der Fahrer zu jedem Zeitpunkt neues Wissen über seine Umgebung erlangen und sein Verhalten entsprechend anpassen kann. Andererseits erfolgt die Entscheidung über die Notwendigkeit der Warnung ohnehin erst zu einem

Zeitpunkt, zu dem der Fahrer das entsprechende Situationsbewusstsein bereits haben oder spätestens (in Form der Warnung) erlangen sollte. Um die Komplexität der Vorhersage zu begrenzen, darf daher angenommen werden, dass der Fahrer sein aktuelles Situationsbewusstsein über den gesamten Vorhersagehorizont beibehält.

Nichtsdestotrotz können durch die explizite Modellierung des Situationsbewusstseins unfallverursachende Handlungen des Fahrers deutlich früher vorhergesagt werden, als dies rein durch Beobachtung des Fahrerverhaltens möglich wäre. Einen wichtigen Anwendungsfall stellt hierbei die Vorhersage von Anfahrvorgängen dar: Durch die Modellierung des Situationsbewusstseins kann der Grund des Anhaltens und somit auch der Zeitpunkt ermittelt werden, zu dem dieser Grund voraussichtlich nicht mehr gegeben ist. In der in Abb. 4.3 dargestellten Situation wartet der Fahrer des orangen Fahrzeugs beispielsweise auf das graue Fahrzeug von rechts, um nach diesem links in die Vorfahrtsstraße einzubiegen. Hierbei besteht aufgrund der Blickrichtung des Fahrers eine hohe Wahrscheinlichkeit, dass er das von links kommende Fahrzeug nicht wahrgenommen hat. Solange der Fahrer noch auf das Fahrzeug von rechts wartet, ist dies nicht relevant und sollte daher auch nicht zu einer Warnung führen. Andererseits ist es aufgrund der Reaktionszeit des Fahrers nicht möglich, mit dem Ausgeben der Warnung bis zur Betätigung des Gaspedals zu warten. Abhilfe schafft hier nur die Berücksichtigung der Tatsache, dass der voraussichtliche Anfahrzeitpunkt anhand der Trajektorie des von rechts kommenden Fahrzeugs abgeschätzt werden kann.

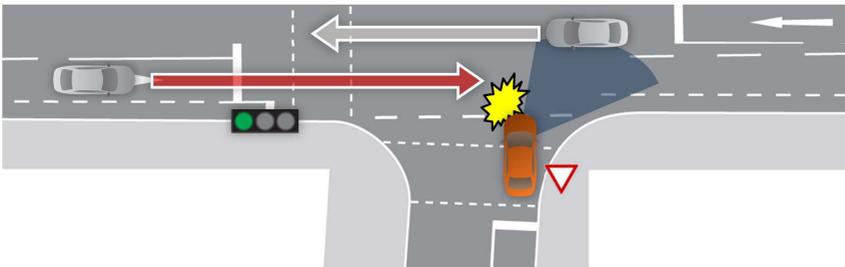


Abbildung 4.3: Vorhersage des Anfahrzeitpunkts auf Basis des Situationsbewusstseins. Durch Beobachtung der Tatsache, dass das orange Fahrzeug auf das Fahrzeug von rechts wartet, kann der nächstmögliche Anfahrzeitpunkt bestimmt werden.

4.2 Modellierung des Situationsbewusstseins

Da das Verhalten und insbesondere auch das Situationsbewusstsein des Fahrers von zahlreichen, größtenteils nicht direkt beobachtbaren Faktoren abhängt, ist eine Modellierung nur ansatzweise und unter starken Vereinfachungen möglich.

Wie schon bei der Vorhersage des wahrscheinlichsten zukünftigen Fahrwegs besteht hierbei die Herausforderung, die entwickelten Modelle so allgemeingültig zu halten, dass sie grundsätzlich auf beliebige Verkehrssituationen und Kreuzungsgeometrien angewendet werden können. Andererseits erfordert die Umsetzung der im vorangegangenen Abschnitt definierten Anwendungsfälle die Berücksichtigung zahlreicher Gegebenheiten aus dem Fahrzeugumfeld. Das Ziel dieses Abschnitts besteht daher vorrangig darin, die Machbarkeit einer derartigen Modellierung zu zeigen, während für den experimentellen Nachweis der getroffenen Annahmen sowie die Parametrisierung der Teilmodelle auf Basis von Probandenstudien auf zukünftige Arbeiten verwiesen werden muss.

Konkret lassen sich aus den Anwendungsfällen des vorangegangenen Abschnitts folgende Forderungen ableiten:

- Explizite Modellierung des Situationsbewusstseins des Fahrers, um die Interaktion mit anderen Verkehrsteilnehmern abbilden zu können.
- Berücksichtigung potenzieller Interaktion auch ohne eine konkrete Objektinstanz, bspw. mit Hilfe von Haltepunkten und Zufahrten.
- Unterscheidung zwischen tatsächlicher Belegung der Zufahrten, dem diesbezüglichen Glauben des Fahrers und der Zuversicht, die er seiner eigenen Einschätzung entgegenbringt.

Da sich die für das Situationsbewusstsein relevanten Haltepunkte und Zufahrten je nach zukünftigem Fahrweg unterscheiden, ist die diesbezügliche Fahrerabsicht ebenfalls Teil des probabilistischen Modells. Hierbei wird auf den in Abschnitt 3.1 diskutierten und in Abb. 4.4 links dargestellten Ansatz zur Vorhersage von Pfadwahrscheinlichkeiten zurückgegriffen: Anhand der GPS-Position des Fahrzeugs erfolgt die Lokalisierung auf eine fahrstreifenge-naue Karte, aus der sich mögliche Pfade durch die Kreuzung in Form eines sogenannten Hypothesenbaums ermitteln lassen. Jede Hypothese repräsentiert dabei genau einen Pfad, dessen Wahrscheinlichkeit sich danach richtet,

wie gut das für diesen Pfad zu erwartende Fahrerverhalten mit dem tatsächlichen Verhalten im Hinblick auf die beobachtete Blinkeraktivierung (IF), den Geschwindigkeitsverlauf (VF) und die Kopfdrehung (GF) des Fahrers übereinstimmt.

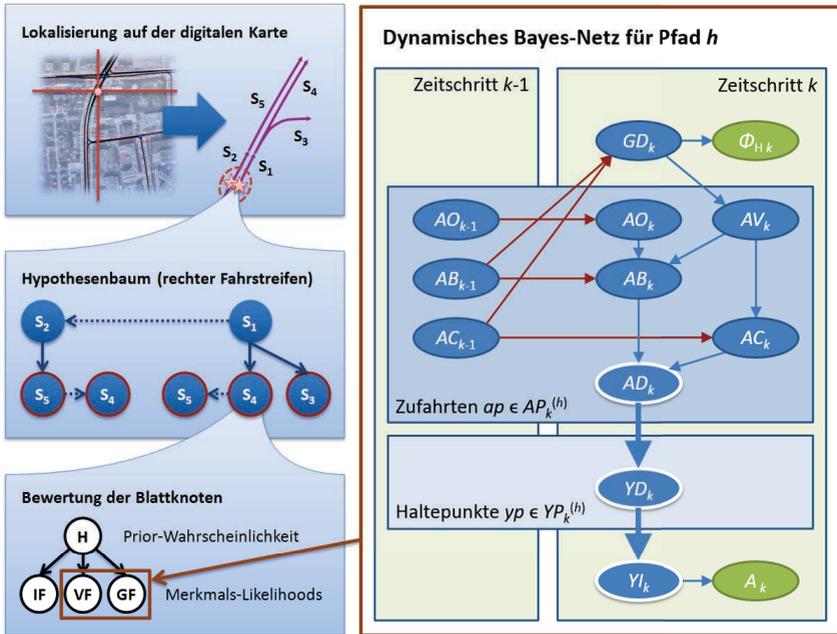


Abbildung 4.4: Modellüberblick. Links: Eigenlokalisierung, Hypothesenbaum und Bewertung potenzieller Fahrwege gemäß Kapitel 3. Rechts: Dynamisches Bayes-Netz zur Modellierung des Situationsbewusstseins, falls der Fahrer dem zu Hypothese h gehörenden Fahrweg zu folgen beabsichtigt.

Neben der Vorhersage des wahrscheinlichsten Fahrwegs ermöglicht der Geschwindigkeitsverlauf aber auch eine Aussage darüber, ob der Fahrer vor dem nächsten Haltepunkt anhalten wird, um einem anderen Verkehrsteilnehmer die Vorfahrt zu gewähren. Gleichzeitig erlaubt die Kenntnis der Blickrichtung des Fahrers Rückschlüsse auf dessen Situationsbewusstsein, welches wiederum die Grundlage für eben diese Anhalteentscheidung darstellt. Der statistische Zusammenhang zwischen den zu den beiden Merkmalen gehörenden Messgrößen, der aktuellen Kopfdrehung Φ_{Hk} und der aktuellen Beschleunigung A_k , wird durch das DBN auf der rechten Seite von Abb. 4.4 für jeweils einen konkreten Pfad h durch die Kreuzung modelliert. Da die beiden Merkmale

VF_k und GF_k bei Berücksichtigung von Anhaltvorgängen offensichtlich nicht mehr statistisch unabhängig sind, werden diese für die Berechnung der Pfadwahrscheinlichkeiten durch das jeweilige Marginal $P(\bar{A}_k, \bar{\Phi}_{H_k} | H_k = h)$ ersetzt, mit $\bar{A}_k = (A_0, A_1, \dots, A_k)$ und $\bar{\Phi}_{H_k} = (\Phi_{H_0}, \Phi_{H_1}, \dots, \Phi_{H_k})$ der Gesamtheit aller bisherigen Beobachtungen. Der Übersichtlichkeit halber wird der Bezug zum gegebenen Pfad h im Folgenden direkt in den jeweiligen Zufallsgrößen verankert.

Tabelle 4.1: Wertebereich der Zufallsgrößen

Zufallsgröße	Bezeichnung	Wertebereich
$\Phi_{H_k}^{(h)}$	Kopfdrehung	$[-\pi, \pi)$
$GD_k^{(h)}$	Blickrichtung	$\{0, \dots, n_{GD} - 1\}$
$AV_k^{(ap)}$	Sichtbarkeit	$\{0, 1\}$
$AO_k^{(ap)}$	Tatsächliche Belegung	$\{0, 1\}$
$AB_k^{(ap)}$	Subjektive Belegung	$\{0, 1\}$
$AC_k^{(ap)}$	Zuversicht	$\{0, 1\}$
$AD_k^{(ap)}$	Entscheidung Zufahrt	$\{0, 1\}$
$YD_k^{(yp)}$	Entscheidung Haltepunkt	$\{0, 1\}$
$YI_k^{(h)}$	Anhalteabsicht	$\{0\} \cup \mathcal{Y}\mathcal{P}_k^{(h)}$
$A_k^{(h)}$	Beschleunigung	$[-10 \text{ m/s}^2, 10 \text{ m/s}^2)$

Grundsätzlich können die in Tab. 4.1 aufgelisteten Zufallsgrößen jeweils einem von drei Teilmodellen zugeordnet werden:

1. *Das Blickverhalten des Fahrers* wird durch seine Blickrichtung $GD_k^{(h)}$ und die daraus resultierende Kopfdrehung $\Phi_{H_k}^{(h)}$ im jeweiligen Zeitschritt k charakterisiert. Neben den in Abschnitt 3.4 betrachteten Expected-Gaze-Points werden nun auch die Sicherungsblicke des Fahrers in Richtung der aus Abb. 4.2 bekannten Zufahrten modelliert. Hierbei wird angenommen, dass der Fahrer vorrangig in Richtung der Zufahrten schaut, die er noch nicht vollständig einsehen konnte oder von denen er weiß, dass diese aktuell belegt sind. Unter Berücksichtigung des peripheren Sichtbereichs ergibt sich daraus die Wahrscheinlichkeit, dass der Fahrer ein Objekt an einer gegebenen Position in seiner Umgebung wahrnimmt. Für jede der Zufahrten ap wird diese daraufhin über den jeweils abzusichernden Bereich der Zufahrt gemittelt, um darauf basierend die Wahrscheinlichkeit für die Sichtbarkeit $AV_k^{(ap)}$

der Zufahrt ap zu bestimmen. Dadurch werden hinsichtlich der Blickrichtung des Fahrers pro Zufahrt nur zwei Zustände unterschieden: Entweder hat der Fahrer den wesentlichen Teil der Zufahrt eingesehen, oder eben nicht. Die Zufahrt wird somit als Einheit betrachtet, was eine der Echtzeitfähigkeit des Ansatzes geschuldete Vereinfachung ist.

2. *Das Situationsbewusstsein des Fahrers* wird entsprechend den eingangs formulierten Forderungen durch die tatsächliche Belegung $AO_k^{(ap)}$, die vom Fahrer wahrgenommene Belegung $AB_k^{(ap)}$ und seine Zuversicht hinsichtlich dieser Einschätzung $AC_k^{(ap)}$ für jede der zum Pfad h gehörenden Zufahrten $ap \in \mathcal{AP}_k^{(h)}$ modelliert. Die Belegung der Zufahrt bezieht sich hierbei jeweils auf den Zeitpunkt, an dem der Fahrer den zugehörigen Haltepunkt erreichen würde, falls er nicht vor hat, anzuhalten. Erkennt die Umfelderkennung einen oder mehrere vorfahrtsberechtigten Verkehrsteilnehmer, die sich entlang der betrachteten Zufahrt bewegen und den Haltepunkt zu ungefähr dem gleichen Zeitpunkt erreichen, wird die objektive Belegung als beobachtet gesetzt. Andernfalls kann jedoch auch aufgrund des beobachteten Fahrerhaltens auf eine Belegung der Zufahrt geschlossen werden. Je nach Sichtbarkeit $AV_k^{(ap)}$ der Zufahrt besteht hierbei eine mehr oder weniger hohe Wahrscheinlichkeit dafür, dass der Fahrer den Zustand der objektiven Belegung als seine eigene subjektive Einschätzung $AB_k^{(ap)}$ übernimmt. Darüber hinaus beeinflusst die aktuelle Blickrichtung auch die Zuversicht des Fahrers im Hinblick auf diese Einschätzung.
3. *Die Anhalteabsicht des Fahrers* ergibt sich deterministisch auf Basis des Situationsbewusstseins. Der Fahrer entscheidet sich dabei genau dann für das Anhalten an einer Zufahrt, wenn er entweder glaubt, dass diese belegt ist, oder er sich in seiner Einschätzung nicht sicher ist. Die Entscheidung $YD_k^{(yp)}$ hinsichtlich des Anhaltens an einem oder mehreren Haltepunkten $yp \in \mathcal{YP}_k^{(h)}$ ergibt sich somit als Oder-Verknüpfung der Anhalteentscheidungen $AD_k^{(ap)}$ der zugehörigen Zufahrten. Für die Risikobewertung ist hierbei nur der jeweils erste Anhaltevorgang relevant, wodurch sich für die Anhalteabsicht $YI_k^{(h)}$ die Kardinalität $|\mathcal{YP}_k^{(h)}| + 1$ anstelle von $2^{|\mathcal{YP}_k^{(h)}|}$ ergibt. Da je nach Anhalteabsicht unterschiedliche Erwartungen hinsichtlich der aktuellen Beschleunigung $A_k^{(h)}$ bestehen, sind durch deren Beobachtung Rückschlüsse auf Absicht und Situationsbewusstsein des Fahrers möglich.

Aus Gründen der Übersichtlichkeit wurde darauf verzichtet, durchgängig beobachtete Einflussgrößen wie die aktuelle Position und Geschwindigkeit des Fahrzeugs, die Existenz von Vorderfahrzeugen oder sogar die Kreuzungsgeometrie als solche in Abb. 4.4 explizit darzustellen. In den folgenden Abschnitten werden diese stattdessen implizit in Form von Parametern für die bedingten Wahrscheinlichkeitsverteilungen berücksichtigt. Darüber hinaus wird formal $\mathcal{AP}_k^{(h_1)} \cap \mathcal{AP}_k^{(h_2)} = \emptyset$ und $\mathcal{YP}_k^{(h_1)} \cap \mathcal{YP}_k^{(h_2)} = \emptyset$ für sich unterscheidende Pfade h_1 und h_2 gefordert, um die Zuordnung der in Tab. 4.1 aufgelisteten Zufallsgrößen zu je genau einem Pfad zu gewährleisten. Die Möglichkeit, dass verschiedene Pfade Haltepunkte oder Zufahrten an der gleichen Position haben können, bleibt davon unberührt.

4.2.1 Blickverhalten

Entsprechend den Ausführungen des vorangegangenen Abschnitts ist das Blickverhalten des Fahrers durch seine Blickrichtung und die sich daraus ergebende Kopfdrehung charakterisiert. Im Hinblick auf die Modellierung des Situationsbewusstseins ist darüber hinaus auch die ortsabhängige Wahrnehmungswahrscheinlichkeit des Fahrers von Bedeutung, aus der sich die Relevanz der aktuellen Blickrichtung für die Absicherung der jeweiligen Zufahrt bestimmen lässt. Im Folgenden werden die hierbei getroffenen Modellannahmen diskutiert.

Ursachen für die Blickrichtung

In Abschnitt 3.4 wurde bereits festgestellt, dass sich das Blickverhalten des Fahrers aus den folgenden Bestandteilen zusammensetzt:

- Blicke entlang des Straßenverlaufs zum Zwecke der Bahnführung,
- Blicke in Richtungen, aus denen sich Konfliktpartner nähern könnten,
- Blicke, deren Ursache nicht durch das Modell abgebildet wird.

Im Gegensatz zu dem in Abschnitt 3.4 vorgestellten Modell können die Sicherungsblicke des Fahrers mit Hilfe der in der digitalen Karte hinterlegten Zufahrten nun explizit modelliert werden. Da diese aber nur in bestimmten Verkehrssituationen eine Rolle spielen, ergeben sich aus den oben genannten Blickursachen drei Teilmodelle, die je nach Situation unterschiedlich stark zu gewichten sind. Der Gewichtung liegen hierbei folgende Annahmen zugrunde:

1. Sicherungsblicke des Fahrers können maximal in einem Umfang erfolgen, der die Durchführung der Bahnführungsaufgabe noch uneingeschränkt erlaubt. Der hierfür minimal erforderliche zeitliche Anteil $\omega_{\text{EGP } k}$ ist abhängig von der aktuellen Geschwindigkeit v_k , und zwar in der Form $\omega_{\text{EGP } k} = \min(\bar{\omega}_{\text{EGP}}, v_k / v_{\text{EGP}})$ mit $\bar{\omega}_{\text{EGP}} = 0.6$ und $v_{\text{EGP}} = 20 \text{ m/s}$. Für nicht durch das Modell beschriebene Blicke ist ein konstanter zeitlicher Anteil $\omega_0 = 0.05$ vorgesehen. Die verbleibende Kapazität für Sicherungsblicke entspricht daher $\omega_{\text{AP Cap } k} = 1 - \omega_0 - \omega_{\text{EGP } k}$.

2. Der Bedarf an Sicherungsblicken

$$\omega_{\text{AP Req } k}^{(ap)} = \max(0, 1 - \text{tt}c_k^{(ap)} / \text{tt}c_{\text{AP}}) \nu_{\text{AP } k}^{(ap)} \eta_{\text{AP } k}^{(ap)} \quad (4.1)$$

für die konkrete Zufahrt ap ist durch die verbleibende Zeit $\text{tt}c_k^{(ap)}$ bis zum Erreichen des zugehörigen Haltepunkts, die Referenzzeit $\text{tt}c_{\text{AP}} = 5 \text{ s}$, den Sichtbarkeitskoeffizienten der Zufahrt $\nu_{\text{AP } k}^{(ap)}$ und den vom Situationsbewusstsein des Fahrers abhängigen Faktor $\eta_{\text{AP } k}^{(ap)}$ entsprechend Tab. 4.2 festgelegt. Der Sichtbarkeitskoeffizient $\nu_{\text{AP } k}^{(ap)}$ wird im nachfolgenden Unterabschnitt zur Modellierung der Sicherungsblicke genauer beschrieben.

3. Ist der Gesamtbedarf an Sicherungsblicken größer als die verfügbare Kapazität, teilt der Fahrer die verfügbare Kapazität proportional zu $\omega_{\text{AP Req } k}^{(ap)}$ auf die einzelnen Zufahrten auf:

$$\omega_{\text{AP } k}^{(ap)} = \frac{\omega_{\text{AP Cap } k}}{\max\left(\omega_{\text{AP Cap } k}, \sum_{i \in \mathcal{AP}_k^{(h)}} \omega_{\text{AP Req } k}^{(i)}\right)} \omega_{\text{AP Req } k}^{(ap)}. \quad (4.2)$$

Falls die verfügbare Kapazität für Sicherungsblicke den Bedarf übersteigt, werden die zeitlichen Anteile der Blickrichtungsmodelle mit

$$c_{GM_k}^{(h)} = \omega_0 + \omega_{\text{EGP } k} + \sum_{ap \in A^{(h)}} \omega_{\text{AP } k}^{(ap)} \quad (4.3)$$

entsprechend skaliert:

$$\begin{aligned} P(GM_k^{(h)} = 0 \mid \{AB_{k-1}^{(i)}, AC_{k-1}^{(i)} \mid i \in \mathcal{AP}_k^{(h)}\}) &= \omega_0 / c_{GM_k}^{(h)} \\ P(GM_k^{(h)} = \text{EGP} \mid \{AB_{k-1}^{(i)}, AC_{k-1}^{(i)} \mid i \in \mathcal{AP}_k^{(h)}\}) &= \omega_{\text{EGP } k} / c_{GM_k}^{(h)} \\ P(GM_k^{(h)} = \text{AP}_{ap} \mid \{AB_{k-1}^{(i)}, AC_{k-1}^{(i)} \mid i \in \mathcal{AP}_k^{(h)}\}) &= \omega_{\text{AP } k}^{(ap)} / c_{GM_k}^{(h)} \end{aligned} \quad (4.4)$$

Tabelle 4.2: Wichtungsfaktoren $\eta_{AP\ k}^{(ap)}$

	$AB_k^{(ap)} = 0$	$AB_k^{(ap)} = 1$
$AC_k^{(ap)} = 0$	0.65	1.00
$AC_k^{(ap)} = 1$	0.50	1.00

In den folgenden Abschnitten werden die den bedingten Wahrscheinlichkeiten $P(GD_k^{(h)} | GM_k^{(h)})$ zugrunde liegenden Modelle diskutiert. Die Gesamtblickwahrscheinlichkeit $P(GD_k^{(h)} | \{AB_{k-1}^{(i)}, AC_{k-1}^{(i)} | i \in \mathcal{AP}_k^{(h)}\})$ ergibt sich anschließend durch Wichtung mit den oben berechneten Modellwahrscheinlichkeiten.

Zufällige Blicke

Falls die Ursache der aktuellen Blickrichtung weder in der Bahnführungsaufgabe noch in der Absicherung von Zufahrten besteht, ist die Umsetzung des Blickmodells denkbar einfach: Unter Annahme einer Gleichverteilung ergibt sich für jedes der n_{GD} Blickintervalle eine bedingte Wahrscheinlichkeit

$$P(GD_k^{(h)} = gd | GM_k^{(h)} = 0) = 1 / n_{GD}. \quad (4.5)$$

Blicke entlang des geplanten Fahrwegs

Für den Fall, dass die aktuelle Blickrichtung auf die Bahnführungsaufgabe zurückzuführen ist, wird diese mit Hilfe der aus Abschnitt 3.4 bekannten Expected-Gaze-Points beschrieben. Unter Annahme normalverteilter Abweichungen von der erwarteten Blickrichtung ergibt sich die Wahrscheinlichkeitsdichte für den Blickwinkel $\Phi_{G\ EGP\ k}^{(h)}$ zu

$$f_{\Phi_{G\ EGP\ k}^{(h)}}(\varphi) = \frac{1}{\sqrt{2\pi}\sigma_{G\ EGP}} \exp\left[-\frac{1}{2}\left(\frac{\varphi - \hat{\varphi}_{G\ EGP\ k}^{(h)}}{\sigma_{G\ EGP}}\right)^2\right]. \quad (4.6)$$

Zugunsten der rechentechnischen Effizienz und einer höheren Flexibilität im Hinblick auf die Auswahl des Inferenzalgorithmus wird die Blickrichtung $\Phi_{G\ EGP\ k}^{(h)}$ als Zufallsgröße $GD_k^{(h)}$ durch $n_{GD} = 21$ diskrete Intervalle repräsentiert. Für ein beliebiges Intervall $gd \in \mathcal{GD} = \{0, \dots, n_{GD} - 1\}$ ergibt sich

somit die Wahrscheinlichkeit

$$P(GD_k^{(h)} = gd \mid GM_k^{(h)} = \text{EGP}) = \int_{\varphi_{gd}}^{\varphi_{gd+1}} f_{\Phi_{\text{G EGP } k}^{(h)}}(\varphi) \, d\varphi, \quad (4.7)$$

wobei $\varphi_i = (2i/n_{GD} - 1)\overline{\varphi}_{GD}$ mit $i \in \{0, \dots, n_{GD}\}$ die Intervallgrenzen des Blickbereichs $[-\overline{\varphi}_{GD}, \overline{\varphi}_{GD}]$ darstellen. Das Koordinatensystem ist fahrzeugfest, d. h. ein Blick in Fahrtrichtung entspricht dem Winkel $\varphi = 0$. Für die Auswertungen in Abschnitt 4.4 wurde $\overline{\varphi}_{GD} = 5/8\pi$ angenommen. Die Parameter des Expected-Gaze-Points Models sind in Tab. 4.3 gegeben.

Tabelle 4.3: Parameter der Expected-Gaze-Points

Parameter	Wert	Einheit
Vorausschauentfernung a_{G0}	6.07	m
Vorausschauzeit a_{G1}	1.05	s
Lateraler Versatz b_{G0}	-0.81	m
Standardabweichung σ_{Φ_G}	0.13	-

Sicherungsblicke in Richtung der Zufahrten

Der Zweck von Sicherungsblicken ist es, die gefahrlose Passierbarkeit der für den angestrebten Pfad relevanten Konfliktpunkte sicherzustellen. Dazu dürfen sich auf den zugehörigen Zufahrten keine Verkehrsteilnehmer befinden, die den Konfliktpunkt etwa zur selben Zeit erreichen wie der Fahrer. Je nach Art der Zufahrt sind für die darauf zu erwartenden Verkehrsteilnehmer minimal und maximal anzunehmende Geschwindigkeiten $\underline{v}_{AP}^{(ap)}$ und $\overline{v}_{AP}^{(ap)}$ in der Karte hinterlegt, mit deren Hilfe der darauf abzusi- chernde Bereich $\mathcal{U}_k^{(ap)} = [\underline{u}_k^{(ap)}, \overline{u}_k^{(ap)}]$ mit $\underline{u}_k^{(ap)} = -\overline{v}_{AP}^{(ap)}(ttc_k^{(ap)} - \underline{tg})$ und $\overline{u}_k^{(ap)} = -\underline{v}_{AP}^{(ap)}(ttc_k^{(ap)} - \overline{tg})$ in Abhängigkeit von der verbleibenden Zeit bis zum Erreichen des Konfliktpunkts $ttc_k^{(ap)}$ und den minimal einzuhalten- den Zeitlücken $\underline{tg} = -2\text{ s}$ und $\overline{tg} = 1\text{ s}$ berechnet wird. Für die bereits bekannte Rechtsabbiegen-Situation sind die geometrischen Zusammenhänge in Abb. 4.5 dargestellt.

Hinsichtlich der Blickrichtungsverteilung $P(GD_k^{(h)} \mid GM_k^{(h)} = \text{AP}_{ap})$ wird angenommen, dass diese proportional zu der Wahrscheinlichkeit ist, durch einen Blick in Richtung des jeweiligen Blickrichtungsintervalls die Position des relevanten Verkehrsteilnehmers entlang des abzusichernden Bereichs

einsehen zu können. Um welche Position es sich dabei konkret handelt ist vorab jedoch nicht bekannt, weshalb zur Bestimmung des Wichtungsfaktors

$$\bar{\nu}_{AP\ k\ gd}^{(ap)} = \frac{1}{\lambda(\mathcal{U}_k^{(ap)})} \int_{\underline{u}_k^{(ap)}}^{\bar{u}_k^{(ap)}} \nu_{AP\ k\ gd}^{(ap)}(u) du \quad (4.8)$$

von einer Gleichverteilung entlang des abzusichernden Bereichs ausgegangen wird. Der Sichtbarkeitskoeffizient

$$\nu_{AP\ k\ gd}^{(ap)}(u) = 1 - \left(1 - \nu_{DA\ k\ gd}^{(ap)}(u)\right) \prod_{m \in \mathcal{M}} \left(1 - \nu_{DM\ gd}^{(m)} \nu_{MA\ k\ m}^{(ap)}(u)\right) \quad (4.9)$$

modelliert hierbei die Wahrscheinlichkeit, eine bestimmte Position u entlang der Zufahrt einsehen zu können, mit $\nu_{DA\ k\ gd}^{(ap)}(u)$ der Sichtbarkeit der Position für Blickrichtungen im Intervall gd , $\nu_{MA\ k\ m}^{(ap)}(u)$ der Sichtbarkeit der Position unter Verwendung des Spiegels $m \in \mathcal{M} = \{\text{Links, Mitte, Rechts}\}$ und $\nu_{DM\ gd}^{(m)}$ der Sichtbarkeit des Spiegels m für Blickwinkel im Intervall gd .

Befindet sich der Spiegel an der Grenze zwischen zwei Winkelintervallen, kann es sinnvoll sein, diesen anteilig beiden Intervallen zuzuordnen, wobei $\sum_{gd} \nu_{DM\ gd}^{(m)} = 1$ gefordert wird. Die Sichtbarkeitsfunktionen $\nu_{DA\ k\ gd}^{(ap)}(u)$ und $\nu_{MA\ k\ m}^{(ap)}(u)$ haben jeweils einen kontinuierlichen Wertebereich $[0, 1]$. Dadurch können bei der Abbildung von Winkelintervallen auf Abschnitte auf der Zufahrt insbesondere auch in der Karte hinterlegte Sichtverdeckungen mit teilweiser Durchlässigkeit (parkende Autos, Bäume) berücksichtigt werden.

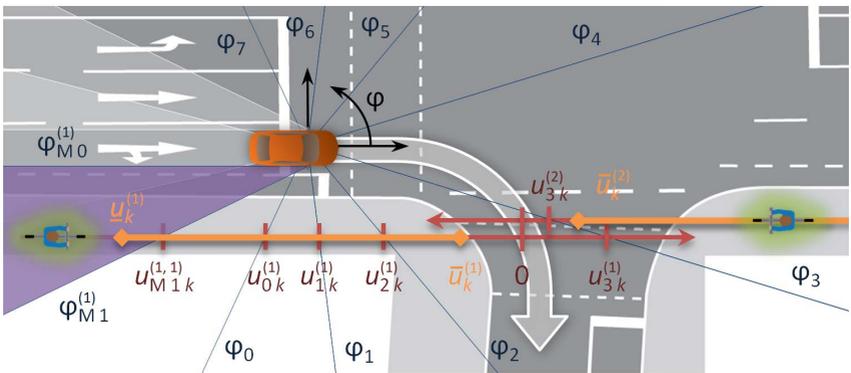


Abbildung 4.5: Abbildung der direkten Blickrichtungsintervalle sowie der Öffnungswinkel der Spiegel auf die im Zeitschritt k abzusichernden Bereiche

Hierbei wird angenommen, dass die Wahrnehmungswahrscheinlichkeiten für direkte Blicke und Spiegelblicke statistisch unabhängig sind, sodass die Wahrscheinlichkeiten der Gegenereignisse bei ihrer Verundung einfach miteinander multipliziert werden können. Die anschließende Normalisierung ergibt

$$P(GD_k^{(h)} = gd | GM_k^{(h)} = AP_{ap}) = \begin{cases} \bar{\nu}_{k\ gd}^{(ap)} / \sum_{gd} \bar{\nu}_{k\ gd}^{(ap)} & \text{falls } \sum_{gd} \bar{\nu}_{k\ gd}^{(ap)} > 0 \\ 0 & \text{sonst.} \end{cases} \quad (4.10)$$

Auf Basis der Sichtbarkeitswahrscheinlichkeiten der einzelnen Blickrichtungsintervalle kann nun auch der für die Gewichtung der Blickmodelle eingeführte Sichtbarkeitskoeffizient

$$\bar{\nu}_{AP\ k}^{(ap)} = \frac{1}{\lambda(\mathcal{U}_k^{(ap)})} \int_{\underline{u}_k^{(ap)}}^{\bar{u}_k^{(ap)}} 1 - \prod_{gd \in \mathcal{GD}} (1 - \nu_{AP\ k\ gd}^{(ap)}(u)) \, du \quad (4.11)$$

bestimmt werden. Dieser repräsentiert die Wahrscheinlichkeit, dass der Fahrer die (unbekannte) Position eines relevanten Verkehrsteilnehmers entlang des abzusichernden Bereichs mit Blicken innerhalb eines beliebigen Blickintervalls einsehen kann. Dadurch wird erreicht, dass verfrühten Sicherungsblicken in Richtung von aktuell noch nicht einsehbaren Zufahrten eine vergleichsweise geringe Wahrscheinlichkeit zugeordnet wird.

Zusammenhang zwischen Blickrichtung und Kopfdrehung

Die in den vorangegangenen Abschnitten vorgestellten Modelle erlauben die Vorhersage der wahrscheinlichsten Blickrichtung des Fahrers in Abhängigkeit von seinem Situationsbewusstsein und der Verkehrssituation an sich. Gleichzeitig kann die Blickrichtung jedoch auch anhand der Kopfdrehung des Fahrers geschätzt werden. Eine statistische Auswertung der Probandenstudie aus Abschnitt 3.4 ergibt hierbei den in Abb. 4.6 dargestellten, näherungsweise linearen Zusammenhang zwischen Blickrichtung und Kopfdrehung des Fahrers.

Aufgrund dieser Beobachtung wird die erwartete Kopfdrehung des Fahrers im Folgenden durch

$$\hat{\varphi}_{HG}^{(gd)} = \alpha_{HG} \bar{\varphi}_{gd} \quad (4.12)$$

mit $\alpha_H = 0.6$ und dem Mittenwinkel $\bar{\varphi}_{gd} = \bar{\varphi}_{GD} (2\ gd + 1) / n_{GD}$ des Intervalls modelliert. Unter Annahme normalverteilter Abweichungen ergibt sich die

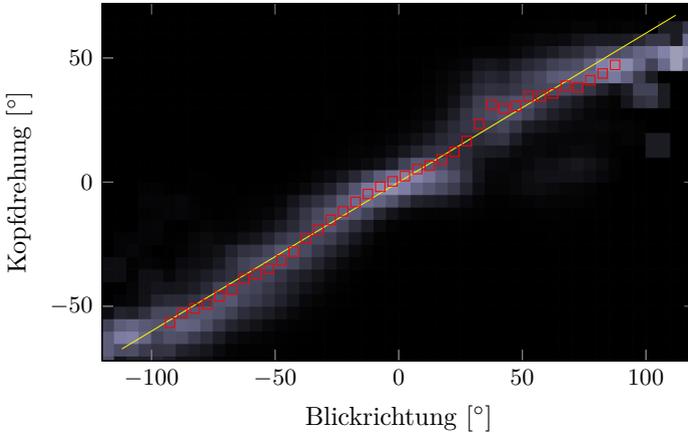


Abbildung 4.6: Empirische Verteilung, Mittelwert und lineare Näherung der Kopfdrehung in Abhängigkeit von der Blickrichtung

Beobachtungswahrscheinlichkeit für die Kopfdrehung somit zu

$$f_{\Phi_{Hk}^{(h)}}^{(gd)}(\varphi_H) = \frac{1}{\sqrt{2\pi} \sigma_{HG}} \exp \left[-\frac{1}{2} \left(\frac{\varphi_H - \hat{\varphi}_{HG}^{(gd)}}{\sigma_{HG}} \right)^2 \right], \quad (4.13)$$

wobei die Standardabweichung $\sigma_{HG} = 0.25$ neben der Variabilität des Fahrerhaltens auch dem Diskretisierungsfehler der Blickrichtung Rechnung trägt.

Wahrnehmungswahrscheinlichkeit des Fahrers

Bei der Absicherung von Zufahrten spielt neben dem bewussten fovealen Sehen auch das periphere Blickfeld des Fahrers eine wesentliche Rolle. Im Vergleich zum zentralen Sichtbereich werden darin befindliche Objekte zwar deutlich unschärfer, dafür aber zeitlich hoch aufgelöst wahrgenommen.

Um die Komplexität des betrachteten Modells zu begrenzen, wird im Folgenden auf die Modellierung dieser Feinheiten verzichtet. Stattdessen wird angenommen, dass die Sichtbarkeit von Objekten exponentiell mit ihrer Abweichung von der Sichtachse des Fahrers abfällt. Die Sichtbarkeit des

4. Risikobewertung

Blickrichtungsintervalls i ist in Abhängigkeit vom fokussierten Intervall gd somit durch

$$\nu_{\text{PERV } i}^{(gd)} = \exp \left[- \left(\frac{\bar{\varphi}_i - \bar{\varphi}_{gd}}{\sigma_{\text{PERV}}} \right)^2 \right] \quad (4.14)$$

mit $\sigma_{\text{PERV}} = 0.43$ und $\bar{\varphi}_{gd}$ dem Mittenwinkel des Blickintervalls gd gegeben. Unter Berücksichtigung der Tatsache, dass sich die Blickrichtung des Fahrers durch Auswertung seiner Kopfdrehung nur ungefähr bestimmen lässt, ergibt sich eine recht breit verteilte Wahrnehmungswahrscheinlichkeit. Für eine konkrete Kopfdrehung ist diese beispielhaft in Abb. 4.7 dargestellt.

Die Wahrscheinlichkeit, dass der Fahrer mit einem Blick im Intervall gd den relevanten Teil des abzusichernden Bereichs einsehen kann, ergibt sich somit zu

$$P(AV_k^{(ap)} = 1 \mid GD_k^{(h)} = gd) = 1 - \frac{1}{\lambda(\mathcal{U}_k^{(ap)})} \int_{\underline{u}_k^{(ap)}}^{\bar{u}_k^{(ap)}} \prod_{i \in \mathcal{GD}} \left(1 - \nu_{\text{PERV } i}^{(gd)} \nu_{\text{DA } k i}^{(ap)}(u) \right) \prod_{m \in \mathcal{M}} \left(1 - \nu_{\text{PERV } i}^{(gd)} \nu_{\text{DM } i}^{(m)} \nu_{\text{MA } k m}^{(ap)}(u) \right) du. \quad (4.15)$$

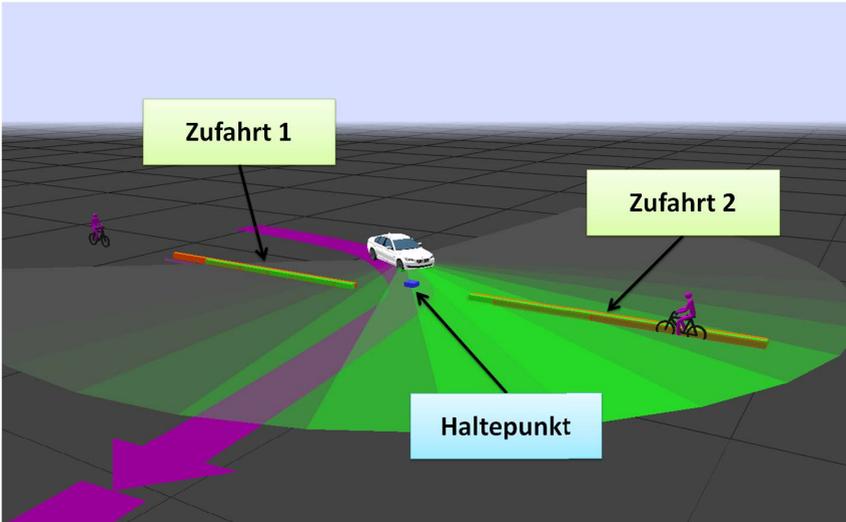


Abbildung 4.7: Wahrnehmungswahrscheinlichkeit des Fahrers

4.2.2 Situationsbewusstsein

Entsprechend den eingangs formulierten Forderungen wird hinsichtlich des Situationsbewusstseins des Fahrers zwischen der tatsächlichen Belegung der Zufahrten, dem diesbezüglichen Glauben des Fahrers und der Zuversicht, die er seiner Einschätzung entgegenbringt, unterschieden. Um die Risikobewertung grundsätzlich auch mittels exakter Inferenz durchführen zu können, wurden für deren Modellierung – wie auch schon für die Sichtbarkeit der einzelnen Zufahrten – lediglich binäre Zufallsgrößen verwendet.

Tatsächliche Belegung

Aufgrund der Verwendung binärer Zufallsgrößen kann jede der Zufahrten entweder frei oder belegt sein. Ausschlaggebend für die Belegung einer Zufahrt ist hierbei der Zeitpunkt, an dem der Fahrer den zugehörigen Haltepunkt erreicht, falls er nicht beabsichtigt, davor anzuhalten. Wie schon bei der Berechnung des abzusichernden Bereichs gilt die Zufahrt genau dann als belegt, wenn mindestens ein anderes Fahrzeug den Konfliktpunkt innerhalb des Zeitintervalls $[ttc_k^{(ap)} + \underline{tg}, ttc_k^{(ap)} + \overline{tg}]$ ebenfalls erreicht.

Um die Belegung der relevanten Zufahrten zu beobachten, verfügt das Fahrzeug über umfangreiche Sensorik zur Umfelderkennung (s. Kapitel 2). Hierbei sind folgende Fälle zu unterscheiden:

1. Es wird kein relevantes Fahrzeug detektiert. Unter der Annahme, dass die Umfelderkennung in den betrachteten Anwendungsfällen kommunikationsbasiert funktioniert, kann aufgrund der derzeitigen Ausstattungsrate aus der Abwesenheit einer entsprechenden Beobachtung nur mit einer geringen Zuverlässigkeit darauf geschlossen werden, dass die Zufahrt tatsächlich frei ist. Der Einfachheit halber wird diese vollständig vernachlässigt, so dass die Wahrscheinlichkeit der tatsächlichen Belegung lediglich von ihrer Prior-Wahrscheinlichkeit und ihrer tatsächlichen Belegung im vorangegangenen Zeitschritt abhängt.

Die Prior-Wahrscheinlichkeit für die Belegung der Zufahrt ap beträgt

$$p_{AO}^{(ap)} = 1 - \exp\left(-h^{(ap)}(\overline{tg} - \underline{tg})\right) \quad (4.16)$$

mit $h^{(ap)}$ der in der Karte hinterlegten Frequenz von Verkehrsteilnehmern auf der Zufahrt. Wie schon bei der Festlegung des abzusichernden Bereichs wird angenommen, dass sich die Verkehrsteilnehmer mit einer

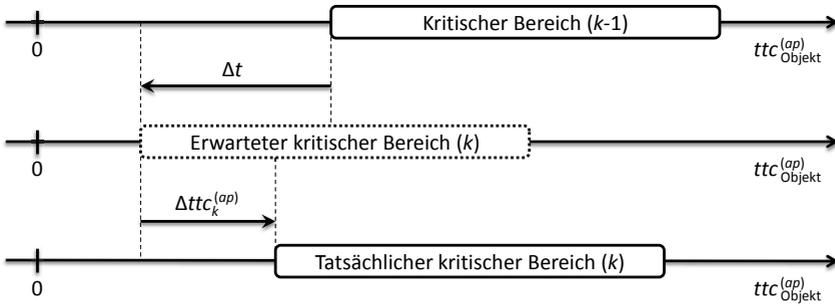


Abbildung 4.8: Überführung des kritischen Zeitbereichs, in dem auf der Zufahrt ap befindliche Objekte den Konfliktpunkt nicht passieren dürfen, vom vorangegangenen Zeitschritt $k - 1$ auf den aktuellen Zeitschritt k

beliebigen, aber konstanten Geschwindigkeit $v \in [\underline{v}_{AP}^{(ap)}, \bar{v}_{AP}^{(ap)}]$ entlang der Zufahrt bewegen. Daraus folgt, dass sich die tatsächliche Belegung der Zufahrt von einem Zeitschritt auf den anderen nur dann ändern kann, wenn die Änderung der prognostizierten Zeit bis zum Erreichen des Konfliktpunkts von der Zeitdifferenz Δt zwischen den beiden Zeitschritten abweicht. Dieser Zusammenhang ist in Abb. 4.8 für den Fall, dass der Fahrer stärker abbremst als dies beim Durchfahren des Haltepunkts zu erwarten wäre, dargestellt.

Abhängig vom Prognosefehler $\Delta ttc_k^{(ap)} = ttc_{k-1}^{(ap)} - \Delta t - ttc_k^{(ap)}$ ergibt sich der Anteil des kritischen Bereichs, der seit dem letzten Zeitschritt ausgetauscht wurde und dessen Belegung demnach von der des vorangegangenen Zeitschritts abweichen kann, zu $\gamma = |\Delta ttc_k^{(ap)}| / (\bar{t}g - \underline{t}g)$. Für die Belegungswahrscheinlichkeit gilt somit

$$P(AO_k^{(ap)} = 1 | AO_{k-1}^{(ap)} = ao) = \gamma p_{AO}^{(ap)} + (1 - \gamma) ao. \quad (4.17)$$

2. Es wird mindestens ein relevantes Fahrzeug detektiert. Der Einfachheit halber werden Falscherkennungen ausgeschlossen. Für die Belegungswahrscheinlichkeit gilt daher

$$P(AO_k^{(ap)} = 1 | AO_{k-1}^{(ap)} = ao) = 1. \quad (4.18)$$

3. Es wird beobachtet, wie das letzte für die Zufahrt relevante Fahrzeug entweder den Konfliktpunkt passiert oder anderweitig die Zufahrt verlässt. Da sich potenziell noch weitere, nicht beobachtete Fahrzeuge auf

der Zufahrt befinden können, entspricht die Belegungswahrscheinlichkeit in diesem Fall der Prior-Wahrscheinlichkeit:

$$P(AO_k^{(ap)} = 1 \mid AO_{k-1}^{(ap)} = a_0) = p_{AO}^{(ap)}. \quad (4.19)$$

Die Belegung im vorangegangenen Zeitschritt $k - 1$ wird somit nur dann zur Berechnung der aktuellen Belegungswahrscheinlichkeit herangezogen, wenn durch die Umfelderkennung keine Fahrzeuge auf der Zufahrt detektiert werden.

Subjektive Belegung

Die Tatsache, dass eine Zufahrt belegt ist, bedeutet nicht notwendigerweise, dass der Fahrer dies selber bereits erkannt hat. Aus diesem Grund wird die subjektive Wahrnehmung des Fahrers durch eine separate Zufallsgröße modelliert, die zwar von der tatsächlichen Belegung beeinflusst wird, jedoch auch im Widerspruch zu dieser stehen kann. Eine Übernahme des tatsächlichen Sachverhalts in die subjektive Einschätzung des Fahrers erfolgt hierbei nur dann, wenn der Fahrer den relevanten Bereich der Zufahrt einsehen kann bzw. die Sichtbarkeit $AV_k^{(ap)}$ der zugehörigen Zufahrt ap den Wert 1 annimmt.

Für $AV_k^{(ap)} = 0$ hingegen wird modelliert, dass der Fahrer seinen Glauben an eine vorhandene Belegung der Zufahrt ap mit einer Wahrscheinlichkeit von $p_{AB10}^{(0)}$ von einem Zeitschritt auf den anderen verliert. Außerdem wird angenommen, dass der initiale Glaube des Fahrers an eine Belegung der Zufahrt der Prior-Wahrscheinlichkeit $p_{AO}^{(ap)}$ der tatsächlichen Belegung entspricht. Da es sich hierbei um das stationäre Gleichgewicht eines durch die zeitlichen Übergangswahrscheinlichkeiten definierten Markov-Prozesses handelt, ergibt sich die komplementäre Übergangswahrscheinlichkeit $p_{AB01}^{(0)}$ zu

$$p_{AB01}^{(0)} = \frac{p_{AO}^{(ap)} p_{AB10}^{(0)}}{1 - p_{AO}^{(ap)}}. \quad (4.20)$$

Kann der Fahrer die Zufahrt hingegen einsehen, wird davon ausgegangen, dass er die tatsächliche Belegung mit einer Wahrscheinlichkeit von $p_{ABC}^{(1)}$ als seine subjektive Einschätzung übernimmt, falls letztere von der tatsächlichen Belegung unterscheidet. Andererseits wird eine verschwindend geringe Wahrscheinlichkeit $p_{ABW}^{(1)}$ für den Fall vorgesehen, dass der Fahrer seine Einschätzung ändert, obwohl diese bereits mit der tatsächlichen Belegung

übereinstimmt. Insbesondere durch die Wahl von $p_{ABC}^{(1)}$ kann daher der tatsächliche Zeitbedarf für die Absicherung von Zufahrten festgelegt werden. Für die Wahrscheinlichkeit der subjektiven Belegung gilt demnach

$$\begin{aligned}
 P(AB_k^{(ap)} = 1 | AV_k^{(ap)} = av, AO_k^{(ap)} = ao, AB_{k-1}^{(ap)} = ab) = \\
 av \left[ab + p_{ABW}^{(1)} (1 - ab - ao) + p_{ABC}^{(1)} (ao - ab) \right] \\
 + (1 - av) \left[ab (1 - p_{AB10}^{(0)}) + (1 - ab) p_{AB01}^{(0)} \right]. \quad (4.21)
 \end{aligned}$$

Zuversicht

Um die Komplexität des Modells so gering wie möglich zu halten, ist der Wertebereich für die Belegung von Zufahrten auf Werte für „frei“ und „belegt“ beschränkt. Tatsächlich ist es jedoch so, dass menschliche Fahrer zunächst die Restwahrscheinlichkeit eines Konflikts mit Hilfe von Sicherungsblicken auf einen für sie akzeptablen Wert absenken, bevor sie sich für das Passieren des zugehörigen Haltepunkts entscheiden. Die einfachste Möglichkeit, diesen Sachverhalt nachzubilden, besteht in der Verwendung einer binären Zufallsgröße für die Zuversicht des Fahrers in Bezug auf seine Einschätzung hinsichtlich der Belegung der Zufahrt, sodass sich ein kombinierter Wertebereich mit Werten für „sicher frei“, „möglicherweise frei“, „möglicherweise belegt“ und „sicher belegt“ ergibt.

Indem für das Passieren von Haltepunkten die subjektive Einschätzung „sicher frei“ gefordert wird, kann zu einem gewissen Grad sichergestellt werden, dass ein auf Basis dieses Modells simulierter Fahrer Zufahrten vorher explizit absichert. Bei schlecht einsehbaren Kreuzungen führt dies dazu, dass sich der Fahrer dem zugehörigen Haltepunkt zunächst stets mit der Absicht nähert, an diesem anzuhalten, und diese erst bei erfolgter Absicherung situationsbedingt anpasst. Im Umkehrschluss ist es dadurch möglich, ein entsprechendes Verhalten des tatsächlichen Fahrers richtig zu interpretieren und so beispielsweise zu vermeiden, dass aus dem Abbremsen bei geringer Prior-Wahrscheinlichkeit für die Belegung der Zufahrt voreilig auf eine Abbiegeabsicht des Fahrers geschlossen wird.

Bei der Modellierung der zeitlichen Übergangswahrscheinlichkeiten sind grundsätzlich zwei Fälle zu unterscheiden:

1. Der relevante Bereich der Zufahrt ist für den Fahrer sichtbar, d. h. $AV_k^{(ap)} = 1$. Hatte er vorher noch keine Zuversicht, erhält er diese nun

mit der Wahrscheinlichkeit $p_{AC01}^{(1)}$. Durch die Wahl von $p_{AC01}^{(1)}$ lässt sich somit der Zeitbedarf für die Absicherung modellieren: Nach n Zeitschritten wäre der Fahrer demnach mit einer Wahrscheinlichkeit von $1 - (1 - p_{AC01}^{(1)})^n$ der Meinung, die Situation richtig eingeschätzt zu haben. Allerdings besteht gleichzeitig eine geringe Wahrscheinlichkeit $p_{AC10}^{(1)}$ dafür, dass er seine Zuversicht in einem beliebigen Zeitschritt wieder verliert, sodass sich eine von 1 verschiedene Wahrscheinlichkeit als stationäres Gleichgewicht einstellt.

2. Der relevante Bereich der Zufahrt ist für den Fahrer nicht sichtbar, d. h. $AV_k^{(ap)} = 0$. In diesem Fall verfällt die bisher vorhandene Zuversicht mit einer Wahrscheinlichkeit von $p_{AC10}^{(0)}$. Gleichzeitig kann es jedoch vorkommen, dass der Fahrer die Zufahrt vollständig übersieht und somit – im Sinne des Modells – Zuversicht in die Einschätzung „frei“ hat, obwohl er die Zufahrt nie abgesichert hat. Die Wahrscheinlichkeit hierfür wird durch die stationären Wahrscheinlichkeit p_{AC} des der Zuversicht zugrunde liegenden Markov-Prozesses nachgebildet. Die verbleibende Übergangswahrscheinlichkeit für einen spontanen Zuversichtsgewinn ergibt sich daher zu

$$p_{AC01}^{(0)} = \frac{p_{AC} p_{AC10}^{(0)}}{1 - p_{AC}}. \quad (4.22)$$

Auf Grundlage der obigen Überlegungen ergibt sich die bedingte Wahrscheinlichkeit für die Zuversicht des Fahrers zu

$$\begin{aligned} P(AC_k^{(ap)} = 1 \mid AV_k^{(ap)} = av, AC_{k-1}^{(ap)} = ac) = \\ av \left[ac(1 - p_{AC10}^{(1)}) + (1 - ac)p_{AC01}^{(1)} \right] \\ + (1 - av) \left[ac(1 - p_{AC10}^{(0)}) + (1 - ac)p_{AC01}^{(0)} \right]. \end{aligned} \quad (4.23)$$

4.2.3 Anhalteabsicht und Beschleunigung

Zur Vorhersage des weiteren Verhaltens wie auch zur Plausibilisierung des beobachteten Geschwindigkeitsverlaufs ist es erforderlich, jedem möglichen Situationsbewusstsein des Fahrers zunächst eine konkrete Handlungsabsicht zuzuordnen und darauf basierend die für diese Absicht zu erwartende Beschleunigung bzw. Verzögerung des Fahrzeugs zu ermitteln. Im folgenden Abschnitt werden hierfür entsprechende Teilmodelle vorgeschlagen.

Anhalteabsicht

Bei der Modellierung des Situationsbewusstseins wurde vorausgesetzt, dass der Fahrer an dem zur Zufahrt ap gehörenden Haltepunkt nur dann nicht anhält, wenn er die Zufahrt als „sicher frei“ einschätzt. Formal bedeutet dies für die Entscheidung $AD_k^{(ap)}$ hinsichtlich Zufahrt ap

$$P(AD_k^{(ap)} = 0 \mid AB_k^{(ap)} = ab, AC_k^{(ap)} = ac) = (1 - ab) ac \quad (4.24)$$

und für die Entscheidung $YD_k^{(yp)}$ zum Haltepunkt yp

$$P(YD_k^{(yp)} = 0 \mid \{AD_k^{(i)} = ad^{(i)} \mid i \in \mathcal{AP}_{YP}^{(yp)}\}) = \prod_{ap \in \mathcal{AP}_{YP}^{(yp)}} (1 - ad^{(ap)}), \quad (4.25)$$

mit $\mathcal{AP}_{YP}^{(yp)}$ der Menge der zum Haltepunkt gehörenden Zufahrten. Für den Geschwindigkeitsverlauf des Fahrzeugs ist hierbei lediglich die zeitlich nächstgelegene Anhalteabsicht relevant. Für einen bestimmten Haltepunkt yp und Pfad h ergibt die Wahrscheinlichkeit

$$P(YI_k^{(h)} = yp \mid \{YD_k^{(i)} = yd^{(i)} \mid i \in \mathcal{YP}^{(h)}\}) = yd^{(yp)} \prod_{i \in \mathcal{YP}_{TTC k}^{(h, yp)}} (1 - yd^{(i)}), \quad (4.26)$$

mit $\mathcal{YP}_{TTC k}^{(h, yp)}$ der Menge der Haltepunkte, deren prognostizierte ttc im Zeitschritt k kleiner ist als die von yp . Für die Wahrscheinlichkeit, an keinem der Haltepunkte anzuhalten, gilt dementsprechend

$$P(YI_k^{(h)} = 0 \mid \{YD_k^{(i)} = yd^{(i)} \mid i \in \mathcal{YP}^{(h)}\}) = \prod_{i \in \mathcal{YP}^{(h)}} (1 - yd^{(i)}). \quad (4.27)$$

Beschleunigung

Obwohl die Absicht des Fahrers kausal von dessen Situationsbewusstsein abhängt, lässt sie sich auch aus dem beobachteten Geschwindigkeitsverlauf des Fahrzeugs ableiten. Hierzu wird auf das bereits in Abschnitt 3.3 vorgeschlagene Fahrerverhaltensmodell zurückgegriffen, mit dessen Hilfe sich die für das Fahrerprofil dp zu erwartete Beschleunigung in Abhängigkeit von der aktuellen Position $s_k^{(h)}$, der aktuellen Geschwindigkeit v_k , der aus der Geometrie des Pfades h resultierenden Wunschgeschwindigkeit $v_{d dp}^{(h)}(s_k^{(h)})$

sowie dem Abstand $\Delta s_{\text{PV}k}^{(h)}$ und der Relativgeschwindigkeit $\Delta v_{\text{PV}k}^{(h)}$ zum Vorderfahrzeug mit Hilfe von (3.20) und (3.21) berechnen lässt:

$$\hat{a}_{k dp}^{(h)}(s_k^{(h)}, v_k, \Delta s_{\text{PV}k}^{(h)}, \Delta v_{\text{PV}k}^{(h)}) = a_{\text{IDM} dp} \left[1 - \left(\frac{v_k}{v_d^{(h)}(s_k^{(h)})} \right)^{\delta_{\text{IDM}}} - \left(\frac{\Delta s_{\text{PV}d}(v_k, \Delta v_{\text{PV}k}^{(h)})}{\Delta s_{\text{PV}k}^{(h)}} \right)^2 \right],$$

wobei

$$\Delta s_{\text{PV}d}(v_k, \Delta v_{\text{PV}k}^{(h)}) = \Delta s_{0\text{IDM}} + v_k \Delta t_{\text{IDM}} + \frac{v_k \Delta v_{\text{PV}k}^{(h)}}{2\sqrt{a_{\text{IDM} dp} b_{\text{IDM}}}}.$$

Das Beispiel aus Abb. 3.17 zeigt, dass mit Hilfe des Modells auch Anhaltévorgänge abgebildet werden können, wenn statt des Abstands zum Vorderfahrzeug die Entfernung zum Haltepunkt und statt der Relativgeschwindigkeit zum Vorderfahrzeug die Absolutgeschwindigkeit des eigenen Fahrzeugs in die Gleichung eingesetzt werden. Die im Rahmen der Untersuchungen zum Situationsbewusstsein gesammelten Messdaten deuten allerdings darauf hin, dass sich der Fahrer anders verhält, wenn die Notwendigkeit für das Anhalten nicht von vornherein feststeht. In derartigen Situationen scheint der Fahrer eine Art Kompromiss zwischen den optimalen Verhaltensweisen für den Fall, dass er nicht anhalten muss, und den Fall, dass er erst einem anderen Verkehrsteilnehmer Vorfahrt gewähren muss, einzugehen. Infolgedessen fährt er zunächst zügiger an die Kreuzung heran und bremst bei entsprechender Notwendigkeit stärker als dies beispielsweise bei einem Ampelstopp der Fall wäre.

Um diese Verhaltensweise abzubilden, wird beim Anhalten an einen Haltepunkt zwischen drei Phasen mit jeweils unterschiedlichen Verhaltensmodellen unterschieden:

1. Der frühen Phase der Annäherung. Hierbei wird der Haltepunkt zunächst vollständig ignoriert und die erwartete Beschleunigung rein auf Basis des Abstands und der Relativgeschwindigkeit zum Vorderfahrzeug berechnet.
2. Der späten Phase der Annäherung, deren Eintritt durch die Bedingung

$$\tilde{a}_{\text{YP} dp k}^{(h, yp)} < -1.2 a_{\text{IDM} dp} \quad \text{mit} \quad \tilde{a}_{\text{YP} dp k}^{(h, yp)} = -\frac{v_d^{(h)}(s_k^{(h)})^2}{2 \Delta s_{\text{YP}}^{(h, yp)}} \quad (4.28)$$

für jeden der Fahrertypen dp in Abhängigkeit von der Distanz des Haltepunkts yp geprüft wird. Die negative Beschleunigung $\hat{a}_{YP\ dp\ k}^{(h,yp)}$ kennzeichnet hierbei die minimal benötigte Verzögerung, um in der verbleibenden Entfernung bis zum Haltepunkt ausgehend von der für die aktuelle Position geltenden Wunschgeschwindigkeit noch zum Stehen zu kommen. Die Wunschgeschwindigkeit wird hierbei anstelle der tatsächlichen Geschwindigkeit verwendet, um für jede Kombination aus Pfad, Haltepunkt und Fahrerprofil eine feste Distanz für den Modellwechsel zu definieren.

3. Der Wartephase. Hält der Fahrer nicht direkt am Haltepunkt sondern ein Stück davor, ergibt sich nach dem durch (3.20) und (3.21) definierten Modell ein positiver Wert für die zu erwartende Beschleunigung des Fahrzeugs. Um daraus resultierende Störeffekte zu vermeiden, wird die zu erwartende Beschleunigung bei gegebener Anhalteabsicht und einer Entfernung zum Haltepunkt von weniger als 5 Metern auf Null nach oben begrenzt.

Für die zu erwartende Fahrzeugbeschleunigung gilt demnach

$$\hat{a}_{YI\ k\ dp}^{(h,yi)} = \begin{cases} \hat{a}_{PV\ k\ dp}^{(h)} & \text{(Frühe Annäherung)} \\ \min(\hat{a}_{PV\ k\ dp}^{(h)}, \hat{a}_{YP\ k\ dp}^{(h,yi)}) & \text{(Späte Annäherung)} \\ \min(0, \min(\hat{a}_{PV\ k\ dp}^{(h)}, \hat{a}_{YP\ k\ dp}^{(h,yi)})) & \text{(Wartephase)} \end{cases} \quad (4.29)$$

mit

$$\hat{a}_{PV\ k\ dp}^{(h)} = \hat{a}_k^{(h)}(s_k^{(h)}, v_k, \Delta s_{PV\ k}^{(h)}, \Delta v_{PV\ k}^{(h)}), \quad (4.30)$$

$$\hat{a}_{YP\ k\ dp}^{(h,yi)} = \hat{a}_k^{(h)}(s_k^{(h)}, v_k, s_k^{(h)} - s_{YP}^{(h,yi)}, v_k) \quad (4.31)$$

und $s_{YP}^{(h,0)} = \infty$ für den Fall, dass an keinem der Haltepunkte angehalten werden soll. Analog zu (3.24) und (3.25) kann somit für jede der möglichen Fahrerabsichten $yi \in \{0\} \cup \mathcal{Y}\mathcal{P}_k^{(h)}$ die Likelihood der tatsächlich beobachteten Beschleunigung $a_k^{(h)}$ bestimmt werden:

$$f_{A_k^{(h)}}^{(yi,dp)}(a_k^{(h)}) = \frac{1}{\sqrt{2\pi}\tilde{\sigma}_A} \exp\left[-\frac{1}{2}\left(\frac{a_k^{(h)} - \hat{a}_{YI\ k\ dp}^{(h,yi)}}{\tilde{\sigma}_A}\right)^2\right], \quad (4.32)$$

$$f_{A_k^{(h)}}^{(yi)}(a_k^{(h)}) = \frac{p_{A0}}{20\text{ m/s}^2} + (1 - p_{A0}) \sum_{dp} f_{A_k^{(h)}}^{(yi,dp)}(a_k^{(h)}) P(DP = dp). \quad (4.33)$$

Hierbei besteht allerdings das Problem, dass zeitlich aufeinanderfolgende Werte der Beschleunigung keine unabhängigen Beobachtungen in Bezug auf die Fahrerabsicht darstellen. Um dies zu berücksichtigen, wurde die Standardabweichung in (4.32) von 1.2 m/s^2 auf $\tilde{\sigma}_A = 4\text{ m/s}^2$ vergrößert. Unter Vernachlässigung des gleichverteilten Anteils in (4.33) entspricht dies näherungsweise einer (geometrischen) Mittelung der Log-Likelihood über 11 Zeitschritte.

4.3 Echtzeitfähige Realisierung im Fahrzeug

Aufbauend auf dem im vorangegangenen Abschnitt entwickelten Modell für das Situationsbewusstsein des Fahrers sowie der bereits in Kapitel 3 diskutierten Methode zur Vorhersage des wahrscheinlichsten Fahrwegs wird in diesem Abschnitt deren konkrete Umsetzung als Assistenzsystem im Fahrzeug beschrieben. Schwerpunkte sind hierbei die Warnstrategie des Assistenzsystems, dessen Softwarearchitektur sowie der zur Ermittlung des Situationsbewusstseins eingesetzte Inferenzalgorithmus.

4.3.1 Warnstrategie und Risikobewertung

Zur Reduktion der Zahl von Falschauslösungen werden Warnungen in den betrachteten innerstädtischen Situationen frühestens 2.5s vor Erreichen des zugehörigen Haltepunkts yp ausgegeben. Dies steht in Einklang mit den Ergebnissen aus [8], nach denen Hinweise an den Fahrer in komplexen Verkehrssituationen mindestens zwei Sekunden vor dem letztmöglichen Bremszeitpunkt ausgegeben werden sollten. Die verbleibende Zeit bis zum Erreichen des Haltepunkts wird dabei simulationsbasiert mit Hilfe der in Abschnitt 3.3.5 diskutierten Methode bestimmt.

Beabsichtigt der Fahrer an einem Haltepunkt anzuhalten, so ergibt sich die ttc der nachfolgenden Haltepunkte auf Basis des voraussichtlichen Zeitpunkts des Wiederlosfahrens. Hierbei ist zu unterscheiden, ob die Belegung der Zufahrt sensoruell erfasst oder lediglich aufgrund eines beobachteten Anhaltevorgangs auf diese geschlossen wurde. Nur im erstgenannten Fall ist eine Prädiktion der weiteren Bewegung des Verkehrsteilnehmers und die darauf basierende Vorhersage des Anfahrzeitpunkts möglich. Andernfalls muss davon ausgegangen werden, dass der Fahrer seine Anhalteabsicht bereits im nächsten Zeitschritt wieder aufgibt.



Abbildung 4.9: Anzeige im Fahrzeug: Dreidimensionales Warnsymbol an der Stelle des erwarteten Konflikts beim Linksabbiegen.

Für jeden Haltepunkt yp , dessen so berechnete $\tilde{ttc}_k^{(yp)}$ unterhalb der Grenze $\overline{ttc}_W = 2.5$ s liegt, erfolgt die Berechnung des zugehörigen Kollisionsrisikos anschließend auf Basis der Wahrscheinlichkeit $P(YO_k^{(yp)} = 1, YD_k^{(yp)} = 0)$ mit

$$YO_k^{(yp)} = 1 - \prod_{ap \in \mathcal{AP}_{YP}^{(yp)}} (1 - AO_k^{(ap)}) \quad (4.34)$$

der tatsächlichen Notwendigkeit für ein Anhalten am Haltepunkt yp . Unter Berücksichtigung der Wahrscheinlichkeit für den zu yp gehörenden Pfad h ergibt sich das Kollisionsrisiko

$$r_k^{(yp)} = P(YO_k^{(yp)} = 1, YD_k^{(yp)} = 0) P(H_k = h | IF_k, \bar{A}_k, \bar{\Phi}_{H_k}) \quad (4.35)$$

für Haltepunkte mit $\tilde{ttc}_k^{(yp)} < \overline{ttc}_W = 2.5$ s bzw. $r_k^{(yp)} = 0$ für alle anderen Haltepunkte. Hierbei ist zu beachten, dass jeder Haltepunkt definitionsgemäß zwar nur auf genau einem Pfad existiert (dies ist notwendig, um die Eindeutigkeit der damit assoziierten Zufallsgrößen zu gewährleisten), jedoch mehrere Pfade das gleiche Fahrstreifensegment beinhalten können. Dadurch ergibt sich, dass mehrere unterschiedliche Haltepunkte die gleiche Position haben können. In diesem Fall sind die Kollisionsrisiken der einander entsprechenden Haltepunkte zur Bestimmung des aggregierten Kollisionsrisikos zu summieren.

Die Ausgabe der Warnung erfolgt anschließend für alle Haltepunkte, deren aggregiertes Kollisionsrisiko $\underline{r} = 20\%$ überschreitet. Im Rahmen der Ko-PER

Abschlusspräsentation am 19. September 2013 wurde hierfür sowohl ein akustisches Signal als auch das in Abb. 4.9 dargestellte Warnsymbol verwendet. Durch Positionierung des Warnsymbols an der Stelle des erwarteten Konflikts soll dem Fahrer die Zuordnung und Verarbeitung der Information erleichtert werden. Da kontaktanaloge Displays im Fahrzeug derzeit noch nicht verfügbar sind, wurde das Warnsymbol stattdessen in einem dreidimensionalen Modell der Kreuzung auf dem Bildschirm der Mittelkonsole des Fahrzeugs eingeblendet.

4.3.2 Softwarearchitektur

Zur Umsetzung der im vorangegangenen Abschnitt beschriebenen Warnstrategie werden die aktuelle Fahrzeugposition, eine Repräsentation der möglichen zukünftigen Pfade des Fahrzeugs, die zugehörigen Pfadwahrscheinlichkeiten und nicht zuletzt die gemeinsame Wahrscheinlichkeitsverteilung über die zur Modellierung des Situationsbewusstseins herangezogenen Zufallsgrößen benötigt. Außerdem sind die Informationen der in Kapitel 2 beschriebenen Umfelderkennungssensorik auszuwerten, um Hinweise zur tatsächlichen Belegung der relevanten Zufahrten zu sammeln.

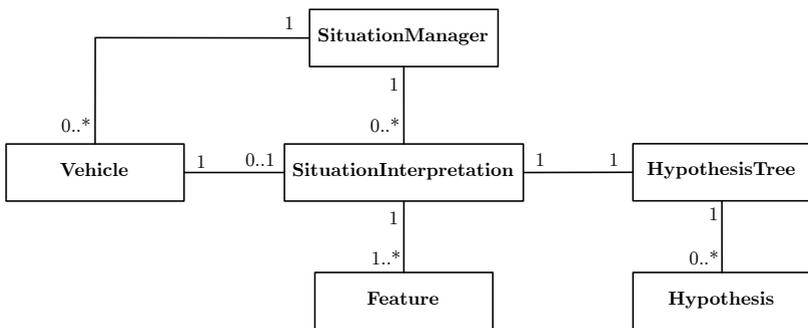


Abbildung 4.10: Softwarestruktur der Risikobewertung

Die Bereitstellung der benötigten Informationen erfolgt durch den zyklischen Aufruf einer Softwarekomponente, deren grundlegende Struktur in Abb. 4.10 dargestellt ist. Ausgangspunkt ist hierbei eine in jedem Zeitschritt aktualisierte Liste von *Vehicle*-Objekten, die neben den durch die Umfelderkennung bereitgestellten Umgebungsobjekten auch die Daten des eigenen Fahrzeugs als spezielles *Vehicle*-Objekt enthält.

Teil der Vorverarbeitung der zu den *Vehicle*-Objekten gehörenden Daten ist die in Abschnitt 3.1 beschriebene Fahrstreifenzuordnung. Diese stellt die Grundlage für den Aufbau des Hypothesenbaums dar, der alle möglichen zukünftigen Pfade innerhalb eines Vorausschauhorizonts von 50 m abbildet. Zur probabilistischen Bewertung der durch die Hypothesen repräsentierten Pfade wird eine Reihe von Merkmalen bzw. Instanzen der Klasse *Feature* verwendet, die ebenso wie die Instanz von *HypothesisTree* in der zum jeweiligen *Vehicle*-Objekt gehörenden Instanz von *SituationInterpretation* hinterlegt werden.

Welche Merkmale konkret zum Einsatz kommen, hängt von den durch das jeweilige *Vehicle*-Objekt bereitgestellten Messgrößen ab. Im eigenen Fahrzeug werden zudem das Geschwindigkeits- und Blickrichtungsmerkmal durch das in Abschnitt 4.2 beschriebene DBN für das Situationsbewusstsein des Fahrers ersetzt. Da im Rahmen der Arbeit ausschließlich Merkmale zur Vorhersage des zukünftigen Verhaltens von Kraftfahrzeugen untersucht wurden, erhalten Verkehrsteilnehmer, die von der Umfelderkennung als Fußgänger oder Radfahrer klassifiziert werden, keine Instanz von *SituationInterpretation* und werden stattdessen für die Vorhersage der Belegung von Zufahrten mit einem einfachen CV-Modell prädiziert. Bei Kraftfahrzeugen hingegen kann über das entsprechende *Vehicle*-Objekt auf deren Hypothesenbaum zurückgegriffen werden, um so die Wahrscheinlichkeit für die Belegung der für das eigene Fahrzeug relevanten Zufahrt zu ermitteln. Um eine Verflechtung der probabilistischen Modelle der einzelnen Verkehrsteilnehmer zu vermeiden, wird hierbei angenommen, dass eine Belegung der Zufahrt genau dann vorliegt, wenn die Summe der Wahrscheinlichkeiten der Pfade, die das zur Zufahrt gehörende Fahrstreifensegment enthalten, größer als 30% ist.

Sowohl für die Berechnung der Pfadwahrscheinlichkeiten als auch für die des Situationsbewusstseins werden Fahrzeugdaten bzw. Berechnungsergebnisse zurückliegender Zeitschritte benötigt, die sich je nach betrachtetem Pfad voneinander unterscheiden und daher direkt der jeweiligen Instanz von *Hypothesis* beigefügt werden. Um im darauffolgenden Zeitschritt auf diese Daten zugreifen zu können, ist eine zeitschrittübergreifende Zuordnung der Fahrzeuge zu jeweils ein und derselben Instanz der Klasse *SituationInterpretation* erforderlich. Die Verwaltung bestehender Situationsinterpretationen sowie deren Zuordnung zu den *Vehicle*-Objekten des aktuellen Zeitschritts wird dabei von einer Instanz der Klasse *SituationManager* übernommen. Neben der Erzeugung neuer Instanzen von *SituationInterpretation* hat diese insbesondere die Aufgabe, bestehende Instanzen, bei denen das zugehörige Fahrzeug seit einiger Zeit nicht mehr beobachtet wurde, zu löschen.

4.3.3 Umsetzung der Inferenz

Grundlage für die Schätzung des Situationsbewusstseins ist das in Abschnitt 4.2 beschriebene Modell, das entsprechend den Ausführungen des vorangegangenen Abschnitts als eines der Merkmale zur Fahrerabsichtserkennung instanziiert wird. Hierbei ist zu beachten, dass es sich bei dem Modell nicht direkt um das DBN selbst, sondern vielmehr um eine Schablone für dessen Struktur in Abhängigkeit von den aktuell relevanten Haltepunkten und Zufahrten handelt. Treten neue Haltepunkte in den Vorhersagehorizont von 50 m ein oder passiert das Fahrzeug einen der Haltepunkte, ändert sich die Struktur des Netzes des aktuellen Zeitschritts im Vergleich zu der der vorangegangenen Zeitschritte. Daher ist es erforderlich, das Netz in Abhängigkeit von den jeweils relevanten Haltepunkten und den zugehörigen Zufahrten in jedem Zeitschritt neu aufzubauen.

Der *Belief-State* des vorangegangenen Zeitschritts wird hierbei durch die tatsächliche Belegung $AO_{k-1}^{(ap)}$, die subjektive Belegung $AB_{k-1}^{(ap)}$ sowie die Zuversicht des Fahrers in seine Einschätzung $AC_{k-1}^{(ap)}$ der zu diesem Zeitpunkt relevanten Zufahrten $ap \in \mathcal{AP}_{k-1}^{(h)}$ repräsentiert. Eventuell vorhandene zeitliche Zusammenhänge der Sichtbarkeit der Zufahrt sowie der diese bedingenden Blickrichtung werden hierbei vernachlässigt. Alle anderen nicht beobachteten Knoten des Netzes ergeben sich deterministisch aus den genannten Zufallsgrößen. Für die Zufahrten, die bereits im letzten Zeitschritt relevant waren, kann der Belief-State somit direkt übernommen werden, während neu hinzugekommene Zufahrten mit Hilfe der Prior-Wahrscheinlichkeit $p_{AO}^{(h)}$ für die objektive und subjektive Belegung sowie der stationären Wahrscheinlichkeit p_{AC} für die Zuversicht des Fahrers initialisiert werden.

Bei dem in Abb. 4.4 dargestellten DBN ist es möglich, alle nicht beobachteten Knoten von Zeitschritt k und Pfad h zu dem *Hidden State* $Z_k^{(h)}$ des in Abb. 4.11 dargestellten HMMs zusammenzufassen. Die Kombination aus Kopfdrehung und Beschleunigung wird dabei durch die *Evidenzgröße* $E_k^{(h)}$ repräsentiert. Der Einfachheit der Darstellung wegen wird für den Rest des Abschnitts vereinbart, dass die Zuweisung einer konkreten Realisierung $\mathbf{e}_k^{(h)}$ zu $E_k^{(h)}$ durch die Realisierung selbst abgekürzt werden darf. In diesem Fall bildet

$$P(Z_k^{(h)} | \mathbf{e}_{1:k}^{(h)}) = \frac{P(\mathbf{e}_k^{(h)} | Z_k^{(h)})}{P(\mathbf{e}_k^{(h)} | \mathbf{e}_{1:k-1}^{(h)})} \sum_z P(Z_k^{(h)} | Z_{k-1}^{(h)} = z) P(Z_{k-1}^{(h)} = z | \mathbf{e}_{1:k-1}^{(h)}) \quad (4.36)$$

die rekursive Vorschrift zur Überführung der Posterior-Wahrscheinlichkeiten von $Z_k^{(h)}$ von einem Zeitschritt zum nächsten. Die Abkürzung $\mathbf{e}_{1:k}^{(h)}$ repräsentiert hierbei eine Realisierung der Gesamtheit aller zum Pfad h gehörenden Evidenzen bis zum Zeitschritt k . Die Wahrscheinlichkeitsverteilung über den oben definierten Belief-State sowie die für die Umsetzung der Warnstrategie benötigten Wahrscheinlichkeiten $P(YO_k^{(yp)} = 1, YD_k^{(yp)} = 0)$ können anschließend durch Marginalisierung aus $Z_k^{(h)}$ gewonnen werden. Zudem ist leicht ersichtlich, dass $P(\mathbf{e}_k^{(h)} | \mathbf{e}_{1:k-1}^{(h)})$ die Normalisierungskonstante für $P(Z_k^{(h)} | \mathbf{e}_{1:k}^{(h)})$ darstellt. Das Produkt über alle bisherigen Normalisierungskonstanten

$$P(\mathbf{e}_{1:k}^{(h)}) = P(\mathbf{e}_1^{(h)}) \prod_{i=2}^k P(\mathbf{e}_i^{(h)} | \mathbf{e}_{1:i-1}^{(h)}) \tag{4.37}$$

repräsentiert die Likelihood $P(\bar{A}_k^{(h)}, \bar{\Phi}_{H_k}^{(h)} | H_k = h)$ gegeben dem zu dem DBN gehörenden Pfad h und kann somit gemäß (3.8) zur Bestimmung der Pfadwahrscheinlichkeiten verwendet werden.

Obwohl theoretisch möglich, ist die oben beschriebene naive Vorgehensweise praktisch nicht anwendbar, da $Z_k^{(h)}$ bereits in einer einfachen Situation mit nur einem Haltepunkt und zwei Zufahrten $21 \times (2^5)^{n_{AP}} \times 2^{n_{YP}} \times (n_{YP} + 1) = 86.016$ Zustände aufweist und $P(Z_k^{(h)} | Z_{k-1}^{(h)})$ somit mehr als 7 Milliarden Einträge umfassen würde. Durch Beschränkung auf die tatsächlich benötigten Zufallsgrößen des letzten Zeitschritts kann die Zahl der Einträge zwar auf etwa 6 Millionen gesenkt werden, jedoch scheint auch diese Zahl zumindest im Hinblick auf komplexere Verkehrssituationen deutlich zu hoch für eine echtzeitfähige Umsetzung der Inferenz. Im Folgenden werden deshalb Methoden diskutiert, die eine deutlich effizientere Bestimmung des Belief-States sowie der Likelihood der bisherigen Beobachtungen erlauben.

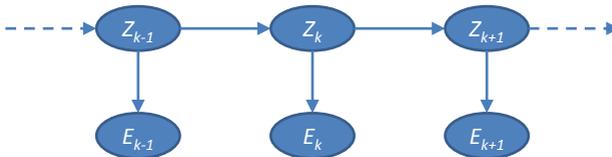


Abbildung 4.11: Grundstruktur des Hidden Markov Modells

Exakte Inferenz

Wie eingangs erwähnt, ist das aktuelle Situationsbewusstsein des Fahrers durch die tatsächlichen Belegung $AO_k^{(ap)}$, die subjektive Belegung $AB_k^{(ap)}$ sowie die Zuversicht des Fahrers in seine Einschätzung $AC_k^{(ap)}$ der zu diesem Zeitpunkt relevanten Zufahrten $ap \in \mathcal{AP}_k^{(h)}$ bereits vollständig beschrieben. Dies bedeutet, dass auf Basis der genannten Größen sowohl die Wahrscheinlichkeiten der nachfolgenden Belief-States als auch die für die Warnstrategie relevanten Wahrscheinlichkeiten $P(YO_k^{(yp)} = 1, YD_k^{(yp)} = 0)$ ermittelt werden können.

Anstatt wie oben beschrieben zunächst die gemeinsame Wahrscheinlichkeitsverteilung über alle beteiligten Zufallsgrößen $Z_k^{(h)}$ zu ermitteln und den Belief-State anschließend durch Marginalisierung der überflüssigen Zufallsgrößen zu berechnen, ist es deutlich effizienter, unter Ausnutzung der durch die Struktur des Netzes implizierten Unabhängigkeitsannahmen einige der Zufallsgrößen bereits vorzeitig zu eliminieren. Beispielsweise besteht keine Notwendigkeit, in dem genannten Beispiel mit zwei Zufahrten und einem Haltepunkt die Wahrscheinlichkeitsverteilung für die Zufallsgrößen aus dem unteren Teil des Netzes in Abb. 4.4,

$$\begin{aligned} P(A_k^{(h)}, YI_k^{(h)}, YD_k^{(1)} | AD_k^{(1)}, AD_k^{(2)}) = \\ P(A_k^{(h)} | YI_k^{(h)}) P(YI_k^{(h)} | YD_k^{(1)}) P(YD_k^{(1)} | AD_k^{(1)}, AD_k^{(2)}), \end{aligned} \quad (4.38)$$

als solche in die gemeinsame Wahrscheinlichkeitsverteilung aufzunehmen. Durch Marginalisierung von $YI_k^{(h)}$ und $YD_k^{(1)}$ ergibt sich stattdessen

$$\begin{aligned} P(A_k^{(h)} | AD_k^{(1)}, AD_k^{(2)}) = \\ \sum_{yd} P(A_k^{(h)} | YD_k^{(1)} = yd) P(YD_k^{(1)} = yd | AD_k^{(1)}, AD_k^{(2)}) \end{aligned} \quad (4.39)$$

mit

$$P(A_k^{(h)} | YD_k^{(1)}) = \sum_{yi} P(A_k^{(h)} | YI_k^{(h)} = yi) P(YI_k^{(h)} = yi | YD_k^{(1)}). \quad (4.40)$$

Offensichtlich enthält die resultierende Verteilung $P(A_k^{(h)} | AD_k^{(1)}, AD_k^{(2)})$ gegenüber $P(A_k^{(h)}, YI_k^{(h)}, YD_k^{(1)} | AD_k^{(1)}, AD_k^{(2)})$ bereits nur noch ein Viertel der Einträge. Aus naheliegenden Gründen wird der Algorithmus, der das hier an einem Beispiel beschriebene Vorgehen abbildet, auch als *Variable-Elimination-Algorithm* [72] bezeichnet.

Eine weitere Möglichkeit zur effizienten Berechnung des Belief-States besteht in dem ebenfalls in [72] beschriebenen *Message-Passing-Algorithm*. Hierbei wird auf Basis der Struktur des Netzes zunächst ein sog. *Clique-Tree* aufgebaut. Die darin enthaltenen Cliques repräsentieren Marginale der gemeinsamen Wahrscheinlichkeitsverteilung, die während der Kalibration des Clique-Trees durch den Austausch von Nachrichten zwischen den Cliques berechnet werden. Gegenüber dem Variable-Elimination-Algorithm besteht der Vorteil dieser Methode vor allem darin, dass auf Basis des kalibrierten Clique-Trees grundsätzlich beliebige Marginale ausgegeben werden können (insbesondere, wenn das Marginal bereits in einer der Cliques enthalten ist), während der Variable-Elimination-Algorithm für jedes zu berechnende Marginal neu gestartet werden muss.

Obwohl beide Methoden im Hinblick auf die benötigte Rechenleistung bereits deutlich effizienter als der ursprüngliche naive Ansatz sind, ergeben sich für Situationen mit mehreren Haltepunkten und Zufahrten immer noch zu viele Einträge bei den zur Bestimmung des Belief-States zu multiplizierenden Faktoren bzw. den beim Message-Passing verwendeten Cliques, um diese schritthaltend auswerten zu können. Dies ist darauf zurückzuführen, dass Methoden der exakten Inferenz die rechentechnische Komplexität lediglich auf Basis der durch das DBN implizierten Unabhängigkeitsannahmen reduzieren können. In dem für das Situationsbewusstsein verwendeten Netz besteht jedoch ein vergleichsweise hoher Vernetzungsgrad zwischen den einzelnen Knoten, da sowohl die Blickrichtung *GD* als auch die Anhalteentscheidung *YD* letztlich von der subjektiven Belegung *AB* und der Zuversicht *AC* sämtlicher relevanter Zufahrten abhängen.

Approximative Inferenz

Um trotz des hohen Vernetzungsgrades der im DBN enthaltenen Knoten eine echtzeitfähige Schätzung des Situationsbewusstseins zu erreichen, wird für die Realisierung im Fahrzeug auf einen Partikelfilter zurückgegriffen. Dieser bildet die gemeinsame Wahrscheinlichkeitsverteilung der relevanten Zufallsgrößen durch eine Vielzahl einzelner Partikel ab. Jedes dieser Partikel repräsentiert eine konkrete Realisierung der Zufallsgrößen, wobei die relative Häufigkeit der Realisierungen näherungsweise der gemeinsamen Wahrscheinlichkeitsverteilung der Zufallsgrößen entspricht.

Der große Vorteil des Partikelfilters besteht darin, dass die Übergangswahrscheinlichkeit des HMMs mit Hilfe einzelner Partikel auch für hochdimensionale Zustandsräume mit vergleichsweise geringem Aufwand ausgewertet werden kann. Zur Berechnung von

$$P(Z_k^{(h)} = z | \mathbf{e}_{1:k-1}^{(h)}) = \sum_z P(Z_k^{(h)} | Z_{k-1}^{(h)} = z) P(Z_{k-1}^{(h)} = z | \mathbf{e}_{1:k-1}^{(h)}) \quad (4.41)$$

wird hierfür zunächst ein neuer Satz von Partikeln $\zeta_{k,i}^{(h)}$ angelegt, dessen Realisierungen $\zeta_{k,i}^{(h)} \langle Z_{k-1}^{(h)} \rangle$ mit Wahrscheinlichkeiten gemäß der Verteilung $P(Z_{k-1}^{(h)} | \mathbf{e}_{1:k-1}^{(h)})$ zufällig festgelegt werden. Die Festlegung der Realisierungen $\zeta_{k,i}^{(h)} \langle Z_k^{(h)} \rangle$ erfolgt anschließend sukzessive als zufällige Zuordnung auf Basis der durch das Netz repräsentierten bedingten Wahrscheinlichkeitsverteilungen. Indem die Zufallsgrößen im Rahmen des als *Forward-Sampling* bezeichneten Verfahrens in der Reihenfolge ihrer topologischen Ordnung abgearbeitet werden, kann sichergestellt werden, dass bei jeder Festlegung die für die Auswertung der bedingten Wahrscheinlichkeitsverteilung benötigten Realisierungen der Elternknoten bereits feststehen. Für das oben betrachtete Beispiel mit zwei Zufahrten und einem Haltepunkt könnten die Realisierungen beispielsweise in der Reihenfolge $HD_k^{(h)}, AV_k^{(1)}, AC_k^{(1)}, AO_k^{(1)}, AB_k^{(1)}, AD_k^{(1)}, AV_k^{(2)}, AC_k^{(2)}, AO_k^{(2)}, AB_k^{(2)}, AD_k^{(2)}, YD_k^{(1)}, YI_k^{(h)}$ zugewiesen werden. Die empirische Näherung der gesuchten Wahrscheinlichkeitsverteilung ergibt sich anschließend durch einfaches Auszählen der zu den Partikeln gehörenden Realisierungen. Mit $\mathbf{1} : \mathbb{B} \mapsto \mathbb{R}$, $\mathbf{1}(\text{wahr}) = 1$ und $\mathbf{1}(\text{falsch}) = 0$ gilt somit

$$P(Z_k^{(h)} = z | \mathbf{e}_{1:k-1}^{(h)}) \approx \frac{1}{n_{\text{PF}}} \sum_{i=1}^{n_{\text{PF}}} \mathbf{1}(\zeta_{k,i}^{(h)} \langle Z_k^{(h)} \rangle = z). \quad (4.42)$$

Für die Bestimmung des aktuellen Belief-States bzw. der für die Erzeugung der Partikel $\zeta_{k+1,i}^{(h)}$ benötigten Verteilung $P(Z_k^{(h)} | \mathbf{e}_{1:k}^{(h)})$ ist es darüber hinaus erforderlich, die Evidenz des aktuellen Zeitschritts gemäß

$$P(Z_k^{(h)} | \mathbf{e}_{1:k}^{(h)}) = \frac{P(\mathbf{e}_k^{(h)} | Z_k^{(h)}) P(Z_k^{(h)} = z | \mathbf{e}_{1:k-1}^{(h)})}{P(\mathbf{e}_k^{(h)} | \mathbf{e}_{1:k-1}^{(h)})} \quad (4.43)$$

in die Wahrscheinlichkeitsverteilung des Hidden States $Z_k^{(h)}$ einfließen zu lassen. Der Nenner stellt hierbei die bereits aus (4.36) bekannte Normalisierungskonstante dar, die zur Bestimmung der Pfadwahrscheinlichkeiten benötigt wird. Durch Einsetzen der empirischen Wahrscheinlichkeitsverteilung

lung aus (4.42) ergibt sich diese zu

$$\begin{aligned}
 P(\mathbf{e}_k^{(h)} | \mathbf{e}_{1:k-1}^{(h)}) &= \sum_z P(\mathbf{e}_k^{(h)} | Z_k^{(h)} = z) P(Z_k^{(h)} = z | \mathbf{e}_{1:k-1}^{(h)}) \\
 &\approx \frac{1}{n_{\text{PF}}} \sum_{i=1}^{n_{\text{PF}}} \sum_z \mathbb{1}(\zeta_{k i}^{(h)} \langle Z_k^{(h)} \rangle = z) P(\mathbf{e}_k^{(h)} | Z_k^{(h)} = z) \\
 &\approx \frac{1}{n_{\text{PF}}} \sum_{i=1}^{n_{\text{PF}}} P(\mathbf{e}_k^{(h)} | Z_k^{(h)} = \zeta_{k i}^{(h)} \langle Z_k^{(h)} \rangle) \\
 &\approx \frac{1}{n_{\text{PF}}} \sum_{i=1}^{n_{\text{PF}}} \omega_{k i}^{(h)}, \tag{4.44}
 \end{aligned}$$

wobei $\omega_{k i}^{(h)}$ im Folgenden als Wichtungsfaktor des Partikels $\zeta_{k i}^{(h)}$ bezeichnet wird. Durch Einsetzen von (4.42) und (4.44) in (4.43) kann schließlich die Wahrscheinlichkeitsverteilung

$$\begin{aligned}
 P(Z_k^{(h)} = z | \mathbf{e}_{1:k}^{(h)}) &\approx \frac{\frac{1}{n_{\text{PF}}} \sum_{i=1}^{n_{\text{PF}}} P(\mathbf{e}_k^{(h)} | Z_k^{(h)} = z) \mathbb{1}(\zeta_{k i}^{(h)} \langle Z_k^{(h)} \rangle = z)}{\frac{1}{n_{\text{PF}}} \sum_{i=1}^{n_{\text{PF}}} \omega_{k i}^{(h)}} \\
 &\approx \frac{\sum_{i=1}^{n_{\text{PF}}} P(\mathbf{e}_k^{(h)} | Z_k^{(h)} = \zeta_{k i}^{(h)} \langle Z_k^{(h)} \rangle) \mathbb{1}(\zeta_{k i}^{(h)} \langle Z_k^{(h)} \rangle = z)}{\sum_{i=1}^{n_{\text{PF}}} \omega_{k i}^{(h)}} \\
 &\approx \frac{\sum_{i=1}^{n_{\text{PF}}} \omega_{k i}^{(h)} \mathbb{1}(\zeta_{k i}^{(h)} \langle Z_k^{(h)} \rangle = z)}{\sum_{i=1}^{n_{\text{PF}}} \omega_{k i}^{(h)}} \tag{4.45}
 \end{aligned}$$

gewonnen werden, die sämtliche bis zu diesem Zeitpunkt bekannte Evidenzen berücksichtigt. Zur Bestimmung der Wahrscheinlichkeit einer bestimmten Realisierung von $Z_k^{(h)}$ werden die entsprechenden Partikel hierbei mit der zugehörigen Likelihood der Beobachtung gewichtet. Aus diesem Grund wird die Verallgemeinerung des hier beschriebenen Vorgehens auf beliebige Netzstrukturen auch als *Likelihood-Weighting-Particle-Filter* bezeichnet.

Wie bereits erwähnt, besteht der wesentliche Vorteil des Partikelfilters in seiner Fähigkeit, auch komplexe Übergangswahrscheinlichkeiten mit vergleichsweise geringem Aufwand auszuwerten. Bei Anwendung des oben beschriebenen Forward-Samplings wächst die rechtechnische Komplexität der Propagation eines einzelnen Partikels im schlimmsten Fall quadratisch mit der Zahl der im Netzwerk vorhandenen Zufallsgrößen: linear aufgrund der wachsenden Zahl der festzulegenden Realisierungen, und quadratisch, da zur Ermittlung der jeweiligen bedingten Wahrscheinlichkeitsverteilung eine wachsende Zahl bereits festgelegter Realisierungen zu berücksichtigen ist.

Die einzige noch verbleibende Quelle rechentechnischer Komplexität besteht somit in der Zahl der Partikel, die zum Erreichen der benötigten Genauigkeit für die empirische Näherung der abzuschätzenden Verteilung erforderlich ist. Genau hier kommt auch der Nachteil der beschriebenen Methode zum Tragen: Da die Knoten des Netzwerks in der Reihenfolge ihrer topologischen Ordnung mit Zuweisungen versehen werden, wird die Evidenz in dem hier betrachteten DBN erst ganz am Ende in Form von Wichtungsfaktoren berücksichtigt. Dadurch ist es nicht unwahrscheinlich, dass eine mit dem Evidenzknoten eng korrelierte Zufallsgröße zunächst eine Realisierung zugewiesen bekommt, für die sich im Nachhinein herausstellt, dass diese nur sehr schlecht mit der beobachteten Realisierung des Evidenzknotens vereinbar ist. Das Resultat sind Partikel mit geringem Wichtungsfaktor, die kaum einen Beitrag zur Approximation der tatsächlich vorliegenden Verteilung leisten können und somit durch weitere Partikel ergänzt werden müssen, um die Wahrscheinlichkeitsverteilung über die mit der Evidenz kompatiblen Realisierungen trotzdem mit hinreichender Genauigkeit abbilden zu können.

Optimierung der Inferenz

Besonders deutlich tritt das oben beschriebene Phänomen bei der Auswertung der durch die Kopfdrehung des Fahrers gegebenen Evidenz zutage. Aufgrund der topologischen Ordnung des in Abb. 4.12 links dargestellten Teilmodells wird dabei zunächst die Blickrichtung des Fahrers als Attribut des jeweiligen Partikels festgelegt, bevor die tatsächlich beobachtete Kopfdrehung in Form eines Wichtungsfaktors berücksichtigt wird. Um dennoch möglichst viele Partikel mit einer plausiblen Realisierung für die Blickrichtung zu erhalten, kann beispielsweise mit Hilfe einer sogenannten *Proposal-Distribution* direkt in den Sampling-Prozess eingegriffen werden. Die im Rahmen der Arbeit favorisierte Möglichkeit besteht jedoch darin, das Netz selbst mit der aus dem Variable-Elimination-Algorithm bekannten Vorgehensweise anzupassen und so dafür zu sorgen, dass die Evidenz möglichst frühzeitig berücksichtigt wird.

Hierfür ist es erforderlich, den Blickrichtungsknoten aus dem in Abb. 4.12 links dargestellten Subnetz zu eliminieren. Ausgehend von der gemeinsamen Wahrscheinlichkeitsverteilung

$$\begin{aligned} & P(GD_k^{(h)}, \Phi_{Hk}^{(h)}, \{AV_k^{(ap)} \mid ap \in \mathcal{AP}_k^{(h)}\} \mid BS_{k-1}^{(h)}) \\ &= P(\Phi_{Hk}^{(h)} \mid GD_k^{(h)}) P(GD_k^{(h)} \mid BS_{k-1}^{(h)}) \prod_{ap \in \mathcal{AP}_k^{(h)}} P(AV_k^{(ap)} \mid GD_k^{(h)}), \end{aligned}$$

4. Risikobewertung

mit $BS_{k-1}^{(h)} = \{AB_{k-1}^{(ap)}, AO_{k-1}^{(ap)}, AC_{k-1}^{(ap)} \mid ap \in \mathcal{AP}_k^{(h)}\}$ dem relevanten Belief-State des vorangegangenen Zeitschritts, ergeben sich durch Marginalisierung der Blickrichtung und Weglassen der jeweils nicht benötigten Faktoren $P(AV_k^{(ap)} \mid GD_k^{(h)})$ die Likelihood der Kopfdrehung

$$P(\Phi_{Hk}^{(h)} \mid BS_{k-1}^{(h)}) = \sum_{gd} P(GD_k^{(h)} = gd, \Phi_{Hk}^{(h)} \mid BS_{k-1}^{(h)}), \quad (4.46)$$

die Sichtbarkeiten des folgenden Zeitschritts

$$P(AV_k^{(ap)} \mid \Phi_{Hk}^{(h)}, BS_{k-1}^{(h)}) = \frac{\sum_{gd} P(GD_k^{(h)} = gd, \Phi_{Hk}^{(h)}, AV_k^{(ap)} \mid BS_{k-1}^{(h)})}{P(\Phi_{Hk}^{(h)} \mid BS_{k-1}^{(h)})} \quad (4.47)$$

bzw. das in Abb. 4.12 rechts dargestellte Subnetz. Dieses unterscheidet sich in zweierlei Hinsicht von dem ursprünglichen Subnetz: Zum einen wird die Plausibilität bzw. der Wichtungsfaktor der Partikel direkt auf Basis des Belief-States des vorangegangenen Zeitschritts festgelegt, wobei eine deutlich geringere Korrelation zwischen dem Belief-State und der Kopfdrehung vorliegt als dies vorher zwischen Blickrichtung und Kopfdrehung der Fall war. Dadurch ergibt sich eine gleichmäßigere Gewichtung der Partikel. Zum anderen wird das Wissen über die aktuelle Kopfdrehung nun bereits bei der Festlegung der Attribute der Partikel berücksichtigt, so dass die Häufigkeit einer bestimmten Realisierung direkt vom Grad ihrer Plausibilität hinsichtlich der beobachteten Kopfdrehung abhängt. Somit wird die verfügbare Rechenleistung stärker auf den wahrscheinlichen Lösungsraum fokussiert.

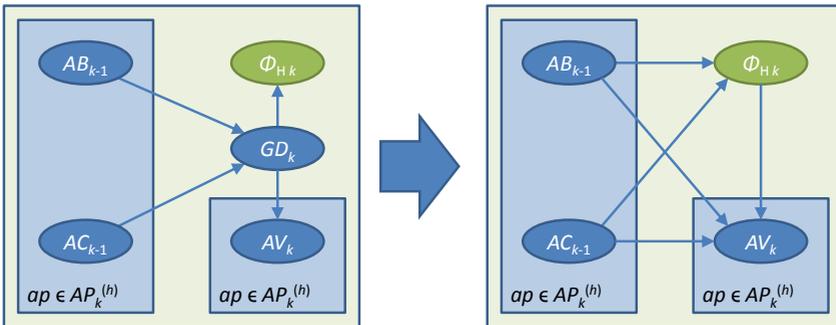


Abbildung 4.12: Ursprüngliches (links) und optimiertes Blickmodell (rechts) für einen bestimmten Pfad $h \in H$

Schlussendlich sei bemerkt, dass die Veränderung in der Häufigkeit der einzelnen Realisierungen keine Auswirkungen auf die Ermittlung der zur Berechnung der Pfadwahrscheinlichkeit benötigten Likelihood $P(\mathbf{e}_k^{(h)} | \mathbf{e}_{1:k-1}^{(h)})$ hat, da diese ohnehin durch Marginalisierung der gemeinsamen Wahrscheinlichkeitsverteilung

$$\begin{aligned} &P(A_k^{(h)}, \Phi_{Hk}^{(h)}, Z_k^{(h)} | \mathbf{e}_{1:k-1}^{(h)}) \\ &= P(A_k^{(h)} | Z_k^{(h)}) P(Z_k^{(h)} | \Phi_{Hk}^{(h)}, \mathbf{e}_{1:k-1}^{(h)}) P(\Phi_{Hk}^{(h)} | \mathbf{e}_{1:k-1}^{(h)}) \end{aligned} \quad (4.48)$$

gewonnen wird und $P(Z_k^{(h)} | \Phi_{Hk}^{(h)}, \mathbf{e}_{1:k-1}^{(h)})$ hierbei explizit eine Abhängigkeit der Partikel von $\Phi_{Hk}^{(h)}$ erlaubt.

Echtzeitfähigkeit der Umsetzung

In der Fachsprache bezeichnet die Echtzeitfähigkeit eines Systems dessen Möglichkeit, die Ausgabe eines korrekten Ergebnisses innerhalb einer vorgegebenen Zeitschranke garantieren zu können (harte Echtzeit) oder diese zumindest im Regelfall einzuhalten (weiche Echtzeit). Ein System ist somit immer nur im Hinblick auf die die Zeitschranke festlegende Anwendung echtzeitfähig.

Im vorliegenden Fall soll das Situationsbewusstsein des Fahrers schritthalte analysiert und bei vorliegender Gefährdung eine Warnung ausgegeben werden. Dazu wird der in diesem Abschnitt vorgestellte Partikelfilter als Komponente innerhalb eines zyklisch arbeitenden Frameworks gestartet. Der Einfachheit halber wird angenommen, dass die komplette Zykluszeit als Rechenzeit auf einem CPU-Kern zur Verfügung steht. Demnach ist der Partikelfilter echtzeitfähig, wenn seine Rechenzeit in allen denkbaren Situationen unterhalb der Zykluszeit des Frameworks liegt. Da die rechentechnische Komplexität des Forward-Samplings schlimmstenfalls quadratisch mit der Zahl der relevanten Zufahrten zunimmt, kann eine derartige Garantie jedoch nur dann gegeben werden, wenn hinsichtlich der Anzahl relevanter Zufahrten eine obere Schranke angenommen wird.

Erste praktische Untersuchungen haben ergeben, dass die Laufzeit des Partikelfilters mit 500 Partikeln für das hier betrachtete Netz mit zwei Zufahrten und einem Haltepunkt pro Zeitschritt maximal 18 ms beträgt (i5-3360M Prozessor mit 2.6 GHz). Dies entspricht der Konfiguration, wie sie auch für die folgenden qualitativen Untersuchungen der Inferenzergebnisse verwendet wurde. Im Hinblick auf die angestrebte Zykluszeit von 100 ms ist der Algorithmus in der betrachteten Situation somit echtzeitfähig. Um zukünftig auch

komplexere Situationen adressieren zu können, sind hingegen softwareseitige Verbesserungen erforderlich. Eine besonders vielversprechende Möglichkeit stellt hierbei die Parallelisierung der Berechnung auf der Grafikkarte dar, durch die bei vergleichbaren Problemstellungen bereits Rechenzeitersparnisse von ein bis zwei Größenordnungen nachgewiesen wurden [111, 112].

4.4 Experimentelle Ergebnisse

Zur qualitativen Bewertung der Ergebnisse der im letzten Abschnitt beschriebenen Echtzeit-Inferenz des Situationsbewusstseins sowie der darauf basierenden Warnstrategie wurden im Rahmen der Masterarbeit von Stephan Epping 120 Situationen im realen Straßenverkehr aufgezeichnet. Gegenstand der Untersuchung war die Frage, inwieweit der betrachtete Ansatz die eingangs beschriebenen Vorteile der Modellierung des Situationsbewusstseins tatsächlich leisten kann. Neben der Vermeidung unnötiger Warnungen, der Detektion nicht sichtbarer Verkehrsteilnehmer sowie der Vorhersage von Anfahrvorgängen, die jeweils an drei verschiedenen Kreuzungen evaluiert wurden, war auch die Fähigkeit des Modells, den vom Fahrer verfolgten Pfad korrekt vorherzusagen, Teil der Auswertung.

Aus Gründen der Übersichtlichkeit wird im Folgenden lediglich auf eine einzige Situation eingegangen, anhand derer sämtliche genannten Punkte diskutiert werden. Hierbei biegt der Fahrer entlang des in Abb. 4.13 dargestellten Pfades rechts ab. Da zu diesem Zeitpunkt gerade ein Fußgänger die Nebenstraße entlang der Zufahrt ap_1 überquert, ist der Fahrer gezwungen, an dem blau gekennzeichneten Haltepunkt anzuhalten. Während er dort steht, kreuzt zudem noch ein Radfahrer die Nebenstraße entlang der gleichen Zufahrt ap_1 – die Situation ist im Detail in Abb. 4.14 dargestellt. Gut zu erkennen ist darin auch die Übereinstimmung des groß dargestellten Umfeldmodells mit dem oben rechts eingeblendeten Videobild der Frontkamera.

Das Verhalten des Fahrers lässt sich aus dem Verlauf der in Abb. 4.15 dargestellten Größen entnehmen: Während er sich zunächst zügig der Kreuzung annähert, bremst er bei $t \approx 1.5$ s stark ab, kommt bei $t \approx 6$ s nahezu zum Stillstand und beschleunigt erst wieder, als der Fußgänger bei $t \approx 11$ s die Straße verlässt. Anhand der Likelihood der beobachteten Beschleunigung kann hierbei frühestens ab $t \approx 4$ s auf eine Anhalteabsicht des Fahrers geschlossen werden – bis zu diesem Zeitpunkt hätte das Abbremsen auch allein dem bevorstehenden Abbiegemanöver geschuldet sein können. Im Hinblick auf die angestrebte zeitliche Warnschwelle von 2.5 s ist dies als kritisch zu be-

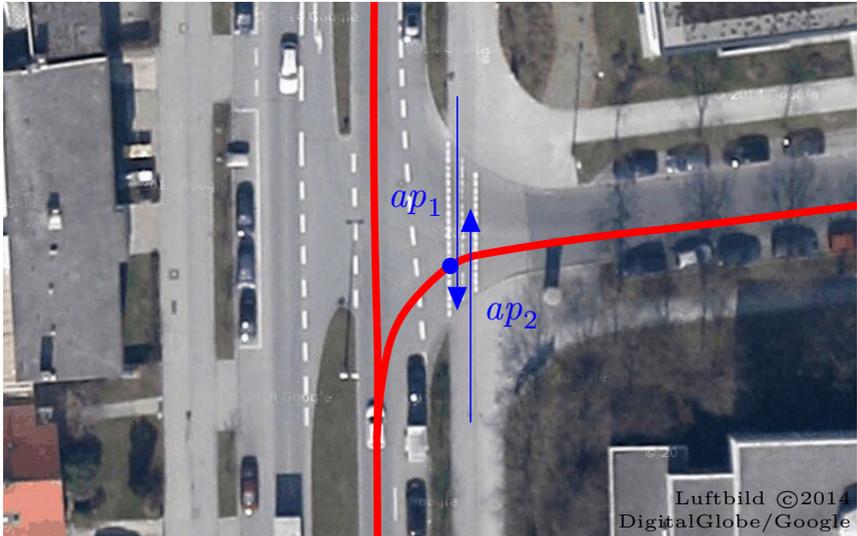


Abbildung 4.13: Mögliche Pfade, Haltepunkt und relevante Zufahrten in der betrachteten Abbiegesituation

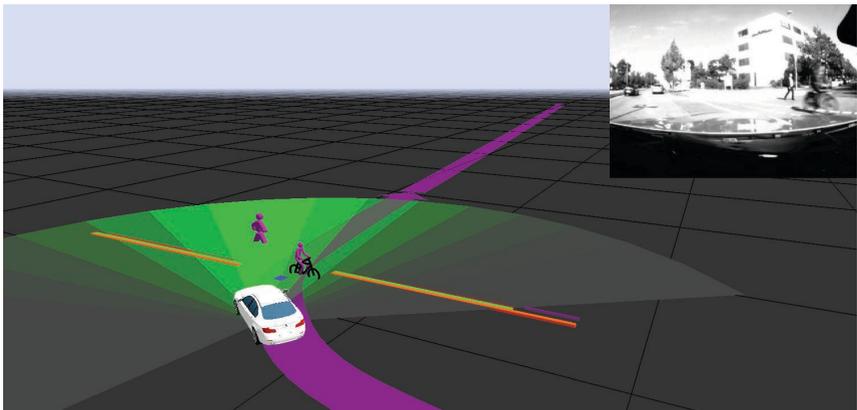


Abbildung 4.14: Rechtsabbiegesituation: Der Fahrer wartet am Haltepunkt, bis sowohl der Radfahrer als auch der Fußgänger die zugehörige Zufahrt ap_1 verlassen haben.

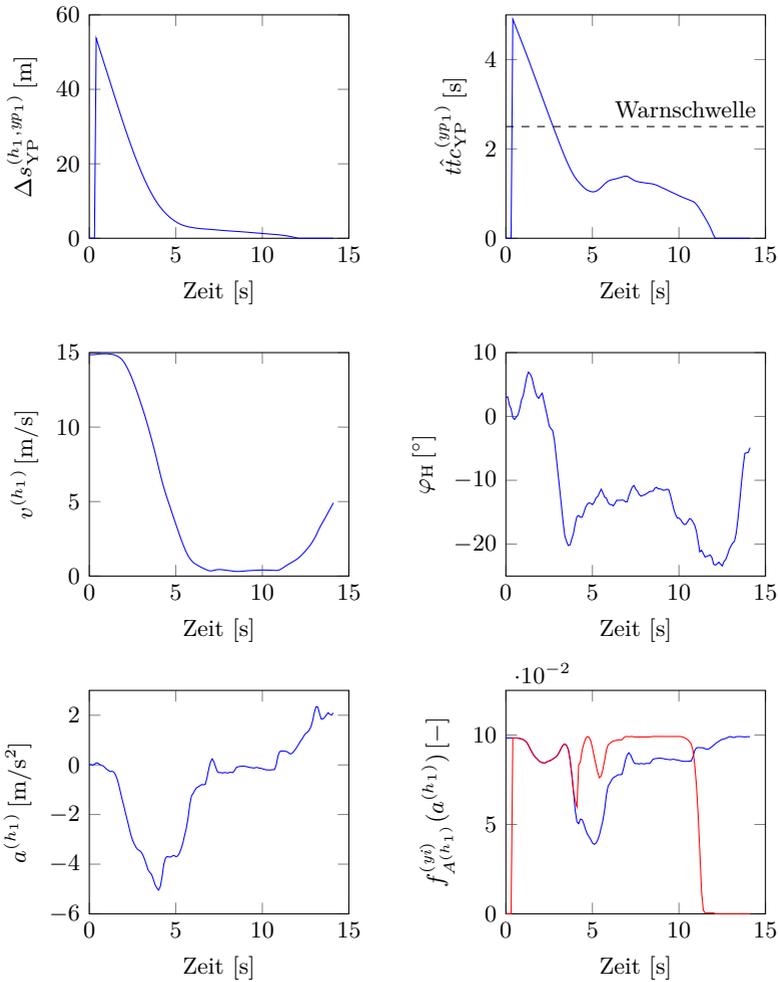


Abbildung 4.15: Eingangsgrößen des Modells für den Rechtsabbiegepfad h_1 während des Abbiegemanövers. Links: Abstand zum Haltepunkt, Geschwindigkeit und Beschleunigung. Rechts: Geschätzte Zeit bis zum Haltepunkt, Kopfdrehung des Fahrers und Likelihood der beobachteten Geschwindigkeit für die Absicht am Haltepunkt anzuhalten (rot) oder durchzufahren (blau).

werten, da diese bereits bei $t \approx 2.7\text{ s}$ von der simulierten Zeit $\hat{t}tc_{\text{YP}}^{(yp_1)}$ bis zum Erreichen des Haltepunkts unterschritten wird. Ohne Berücksichtigung des Situationsbewusstseins würde demnach eine Warnung ausgegeben werden, obwohl der Fußgänger für den Fahrer sehr gut sichtbar und die Warnung aus diesem Grund unnötig ist.

4.4.1 Vermeidung unnötiger Warnungen

Das Situationsbewusstsein des Fahrers, seine Anhalteentscheidung in Bezug auf die beiden Zufahrten und das daraus resultierende Kollisionsrisiko sind in Abb. 4.16 dargestellt. Gut ersichtlich ist hierbei zunächst der Zusammenhang zwischen der Sichtbarkeit der beiden Zufahrten und der in Abb. 4.15 dargestellten Kopfdrehung des Fahrers: Während ap_1 aufgrund der Geometrie des vom Fahrer verfolgten Pfades kontinuierlich von diesem beobachtet werden kann, lässt die Sichtbarkeit von ap_2 während der Kreuzungsannäherung stark nach, da sich ein wachsender Teil des abzusichernden Bereichs hinter dem Fahrzeug befindet und der Fahrer den Kopf erst direkt vor dem Losfahren bei $t \approx 11\text{ s}$ wieder weit genug dreht, um den abzusichernden Bereich auf ap_2 mit Hilfe des Spiegels zumindest teilweise einsehen zu können.¹

Während sich die beobachtete Belegung der Zufahrten anhand der ttc deterministisch aus dem Bewegungszustand von Fußgänger und Radfahrer ergibt, berücksichtigt die objektive Belegung darüber hinaus auch die Möglichkeit, dass sich noch weitere (nicht beobachtete) Verkehrsteilnehmer dem Konfliktpunkt nähern. Je nach Sichtbarkeit der Zufahrt wird diese mehr oder weniger schnell als subjektive Einschätzung des Fahrers übernommen. Erkennbar ist zudem der Zusammenhang zwischen der Sichtbarkeit der Zufahrt und der Zuversicht des Fahrers in seine Einschätzung: Während bei ap_1 eine sehr hohe Wahrscheinlichkeit besteht, dass sich der Fahrer seiner Sache sicher ist, lässt diese für ap_2 aufgrund der schlechten Sichtbarkeit der Zufahrt allmählich nach. Dies bedingt auch den leichten Anstieg der Wahrscheinlichkeit, dass der Fahrer aufgrund von ap_2 am Haltepunkt anzuhalten beabsichtigt. Im Hinblick auf die Risikobewertung der Verkehrssituation ist diese allerdings irrelevant, da bereits durch die subjektive Belegung von ap_1 eine sehr hohe Wahrscheinlichkeit für das Anhalten am Haltepunkt gegeben ist. Das gemäß Abschnitt 4.3.1 berechnete Kollisionsrisiko erreicht aus diesem Grund richti-

¹ Die beschriebene Nachlässigkeit im Fahrerverhalten wurde absichtlich so aufgezeichnet, um mit der gleichen Fahrt auch die kritische Situation aus Abschnitt 4.4.3 darstellen zu können. Die tatsächliche Absicherung des Manövers erfolgte hierbei durch den Beifahrer.

4. Risikobewertung

gerweise für keine der beiden Zufahrten die für das Auslösen der Warnung erforderliche Schwelle von 20 Prozent.

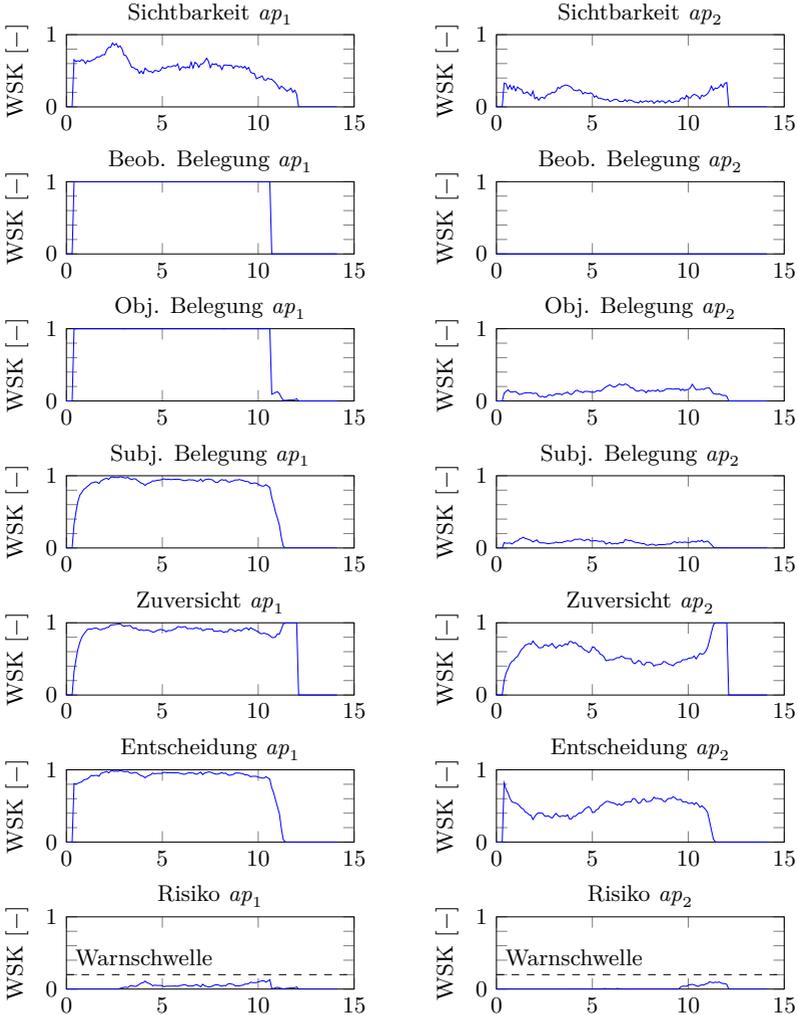


Abbildung 4.16: Situationsbewusstsein und Kollisionsrisiko beim Rechtsabbiegen unter der Annahme, dass alle beteiligten Verkehrsteilnehmer frühzeitig detektiert werden können. Dargestellt sind die Marginalen der Zufallsgrößen des Abbiegepfads unter Berücksichtigung aller bisherigen Beobachtungen über der Zeit in Sekunden.

4.4.2 Detektion nicht sichtbarer Verkehrsteilnehmer

In Abschnitt 4.1 wurde gezeigt, wie anhand des Verhaltens eines vor dem Radweg wartenden Fahrzeugs auf die Existenz des durch ein Gebäude verdeckten Radfahrers geschlossen werden kann, um den Fahrer eines aus der Nebenstraße kommenden Fahrzeugs vor diesem zu warnen. Im Folgenden wird nun nachgewiesen, dass die hier beschriebene Inferenzmethode genau dies zu leisten imstande ist, wenn sie zur Analyse des Verhaltens des wartenden Fahrers eingesetzt wird. Grundsätzlich entspricht die Trajektorie des wartenden Fahrzeugs nämlich genau der des Fahrzeugs in der oben beschriebenen Situation. Die Beobachtung des Fahrzeugs von außen wird dadurch nachgestellt, dass die Ergebnisse von dessen Umfelderkennung ausgeblendet werden. Dadurch ergeben sich die in Abb. 4.17 dargestellten Marginale für das Situationsbewusstsein des Fahrers sowie die tatsächliche Belegung der Zufahrt.

Aufgrund der bereits in Abb. 4.15 dargestellten Likelihood für die Beschleunigung des Fahrzeugs ist es ab $t = 5$ s sehr wahrscheinlich, dass der Fahrer aufgrund mindestens einer der beiden Zufahrten anzuhalten beabsichtigt. Hierbei ist es vergleichsweise unwahrscheinlich, dass die Anhalteabsicht auf fehlende Zuversicht im Hinblick auf eine der Zufahrten zurückzuführen ist.

Dies ist darauf zurückzuführen, dass anhand der beobachteten Kopfdrehung eine gewisse Wahrscheinlichkeit besteht, dass der Fahrer beide Zufahrten bereits einsehen konnte. Zudem würde es das verwendete Blickrichtungsmodell als unplausibel werten, wenn er in diesem Fall nicht bereits stärker in Richtung der Zufahrt geschaut hätte, für die er zunächst keine Zuversicht hatte.

Aufgrund der beobachteten Kopfdrehung des Fahrers entscheidet das Modell, dass eine Belegung von ap_1 deutlich wahrscheinlicher ist als die von ap_2 , da der Fahrer höchstwahrscheinlich den herannahenden Verkehrsteilnehmer beobachtet. Falls die Kopfdrehung des Fahrers von außen nicht beobachtbar wäre, würde sich die Wahrscheinlichkeit der tatsächlichen Belegung zu gleichen Teilen auf die Zufahrten verteilen. In beiden Fällen könnte der Fahrer eines aus der Nebenstraße herannahenden Fahrzeugs, dessen Assistenzsystem diese Betrachtungen anstellt, mehr oder weniger spezifisch vor einem Konfliktpartner auf einer der beiden Zufahrten gewarnt werden.

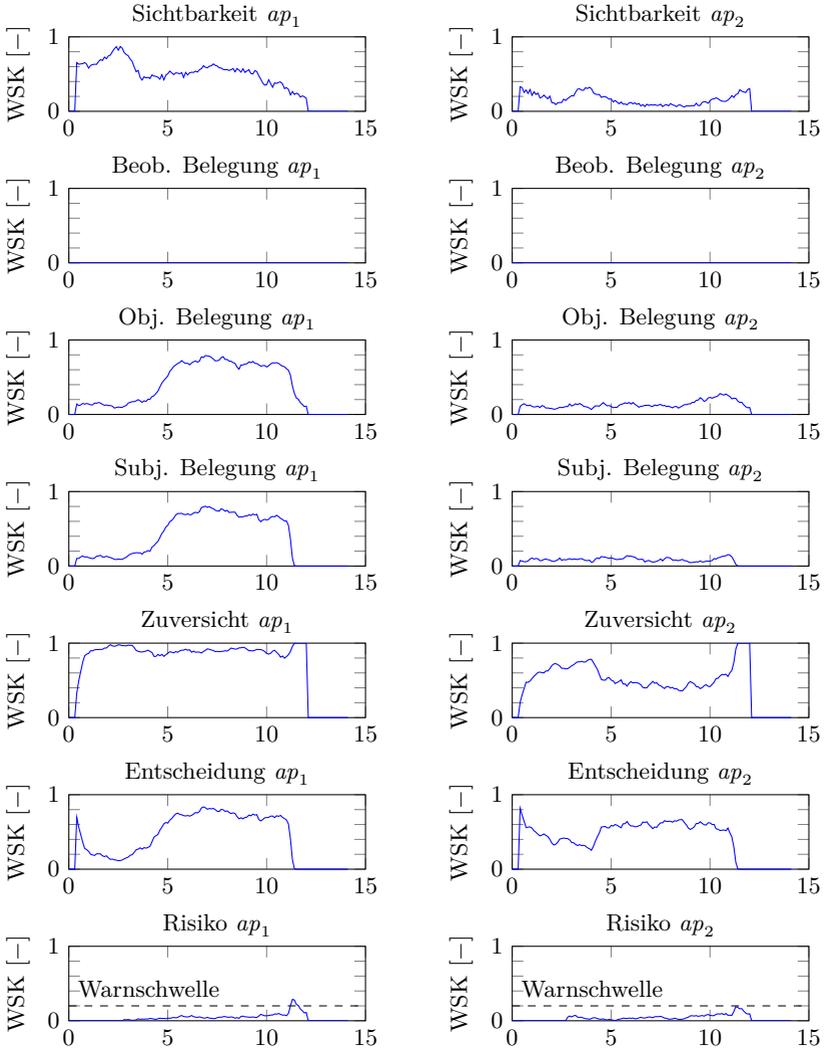


Abbildung 4.17: Situationsbewusstsein und Kollisionsrisiko beim Rechtsabbiegen für den Fall, dass die Ergebnisse der Umfelderkassung nicht zur Verfügung stehen. Dargestellt sind die Marginale der Zufallsgrößen des Abbiegepfads unter Berücksichtigung aller bisherigen Beobachtungen über der Zeit in Sekunden.

4.4.3 Vorhersage von Anfahrvorgängen

Im vorangegangenen Abschnitt wurde von dem Warten des Fahrers am Haltepunkt auf das Herannahen eines Verkehrsteilnehmers geschlossen. Umgekehrt bedeutet dies jedoch auch, dass der Fahrer mindestens noch bis zu dem Zeitpunkt warten wird, an dem der Verkehrsteilnehmer den für den Haltepunkt relevanten Bereich der Zufahrt verlässt. Wird der Verkehrsteilnehmer hierbei durch die Umfelderkennung detektiert, kann die minimal verbleibende Wartezeit des Fahrers anhand des aktuellen Bewegungszustandes des Verkehrsteilnehmers vorhergesagt werden. Indem diese bei der Berechnung der verbleibenden Zeit bis zum Erreichen des Konfliktpunkts berücksichtigt wird, können einerseits unnötige Warnungen während der Wartezeit vermieden, andererseits aber notwendige Warnungen bereits kurz vor dem Wiederanfahren ausgegeben werden.

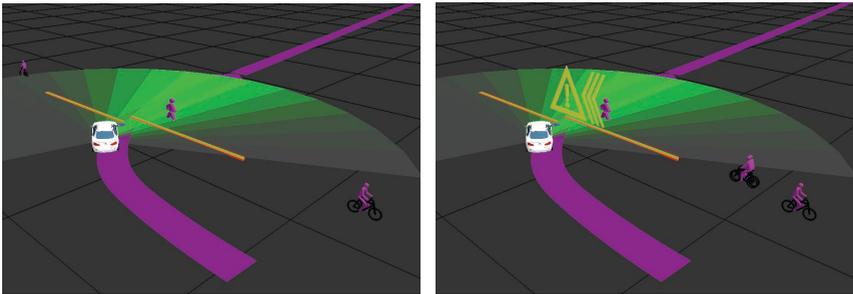


Abbildung 4.18: Erweiterung der Situation um einen virtuellen Radfahrer. Links: Der Radfahrer passiert den Konfliktpunkt noch während der Fahrer auf den Fußgänger wartet (unkritisch). Rechts: Der Radfahrer passiert den Konfliktpunkt erst nachdem der Fußgänger die Straße verlassen hat (kritisch).

Um dies anhand der Abbiegesituation zu demonstrieren, wurde den aufgezeichneten Messdaten ein zusätzlicher Radfahrer künstlich hinzugefügt. Dieser nähert sich dem Konfliktpunkt in entgegengesetzter Richtung entlang der Zufahrt ap_2 . Wie in Abb. 4.18 dargestellt, werden hierbei zwei Situationen unterschieden: In der ersten passiert der virtuelle Radfahrer den Konfliktpunkt noch während der Fahrer ohnehin auf den Fußgänger wartet – die Situation ist somit unkritisch und erfordert keine Warnung. In der zweiten würde es zwischen Fahrzeug und Radfahrer zur Kollision kommen, falls der Fahrer sofort losfährt, sobald der Fußgänger die andere Straßenseite erreicht. Aufgrund der geringen Wahrscheinlichkeit, dass der

Fahrer den Radfahrer entlang ap_2 gesehen hat, ist hier eine Warnung 2.5 s vor dem potenziellen Konflikt und somit noch vor dem Wiederanfahrzeitpunkt erforderlich.

Inwieweit dies durch das verwendete Modell und die in Abschnitt 4.3.1 vorgestellte Warnstrategie erreicht wird, ist anhand der in Abb. 4.19 und Abb. 4.20 dargestellten Marginale des Situationsbewusstseins sowie der jeweiligen Risikobewertung zu erkennen. Hinsichtlich der Sichtbarkeit besteht kein Unterschied zu den vorangegangenen Situationen. Erkennbar ist die Existenz des virtuellen Radfahrers vor allem in der beobachteten, aber auch der objektiven und subjektiven Belegung von ap_2 .

In der unkritischen Situation ist der Radfahrer bereits von Anfang an für das Abbiegemanöver relevant und wird daher bei Kreuzungsannäherung vom Fahrer mit einer Wahrscheinlichkeit von nahezu 80% wahrgenommen. Allerdings besteht durch das anschließende Wartemanöver und die vergleichsweise schlechte Sichtbarkeit von ap_2 eine Wahrscheinlichkeit von etwa 50%, dass im dieser zu dem relevanten Warnzeitpunkt von $t \approx 7$ s wieder entfallen ist. Obwohl gleichzeitig auch die Zuversicht des Fahrer im Hinblick auf seine Einschätzung sinkt, besteht zu diesem Zeitpunkt immer noch ein Risiko von etwa 25%, dass er die Zufahrt als gefahrlos passierbar wertet (s. Anhalteentscheidung ap_2). Dies wäre genug, um eine Warnung auszulösen – wenn er nicht ohnehin noch auf das Passieren des Fußgängers warten würde.

In der kritischen Situation ist der Radfahrer während der Annäherung an die Kreuzung noch nicht relevant, da er diese erst deutlich nach dem Abbiegen des Fahrzeugs erreichen würde. Durch den anhaltenden Wartevorgang ändert sich dies, sodass er bei $t \approx 8$ s in den für den Haltepunkt relevanten Bereich eintritt. Da die Zufahrt hinsichtlich ihrer Sichtbarkeit als Einheit behandelt wird, besteht trotz der ungünstigen Blickrichtung des Fahrers eine gewisse Chance, dass er den Radfahrer auf ap_2 in der Folge wahrnimmt. Zudem besteht wiederum lediglich eine Wahrscheinlichkeit von 50%, dass er sein Informationsdefizit hinsichtlich ap_2 nicht selbst bemerkt. Dennoch verbleibt ein Risiko von stets mehr als 25%, dass er die Zufahrt als gefahrlos passierbar wertet, was eine Warnung aufgrund der Überschreitung der Warnschwelle von 20% erforderlich macht. Aufgrund des anhaltenden Wartevorgangs wird diese nicht unmittelbar nach Eintritt des Radfahrers in den abzusichernden Bereich, sondern erst 2.5 s vor dem frühestmöglichen Erreichen des Konfliktpunkts durch den Fahrer ausgegeben. Hätte der Fahrer rechtzeitig vor dem Wiederlosfahren noch einmal nach rechts geschaut, hätte die Warnung demzufolge noch unterdrückt werden können.

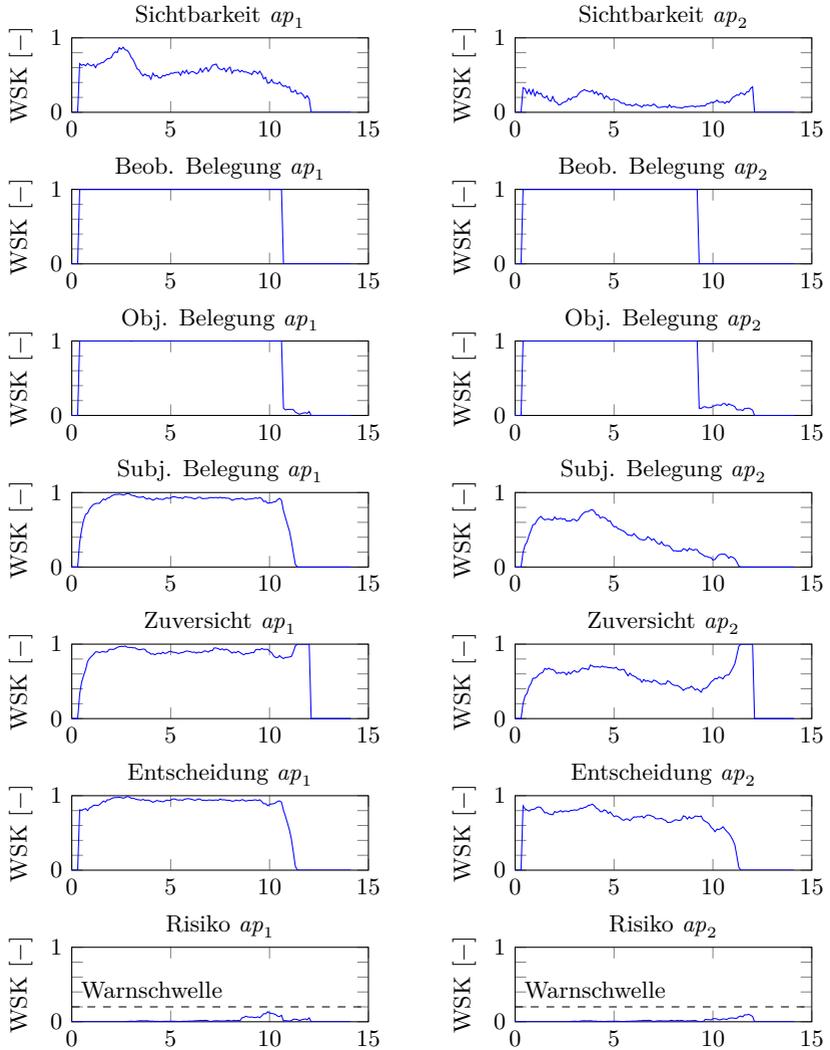


Abbildung 4.19: Situationsbewusstsein und Kollisionsrisiko beim Rechtsabbiegen für den Fall, dass der zusätzlich eingefügte Radfahrer den Konfliktpunkt passiert während dieser noch durch den Fußgänger belegt wird. Dargestellt sind die Marginalen der Zufallsgrößen des Abbiegepfads unter Berücksichtigung aller bisherigen Beobachtungen über der Zeit in Sekunden.

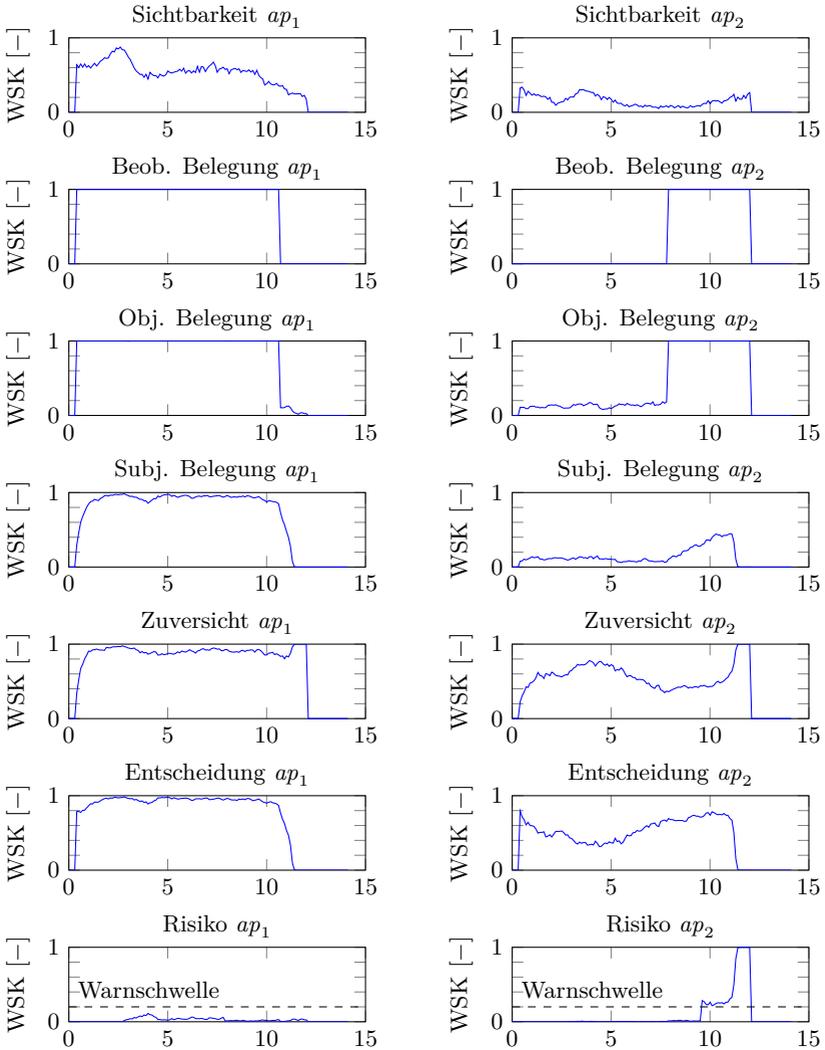


Abbildung 4.20: Situationsbewusstsein und Kollisionsrisiko beim Rechtsabbiegen für den Fall, dass der zusätzlich eingefügte Radfahrer den Konfliktpunkt erst deutlich nach dem Fußgänger passiert. Dargestellt sind die Marginalen der Zufallsgrößen des Abbiegepfads unter Berücksichtigung aller bisherigen Beobachtungen über der Zeit in Sekunden.

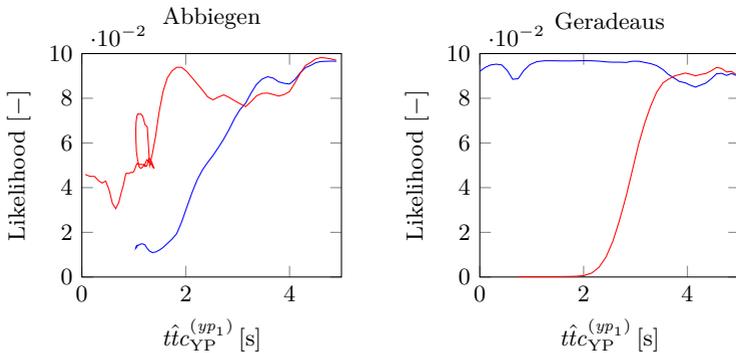


Abbildung 4.21: Netzwerk-Likelihood $P(A_k, \Phi_{Hk} | H_k)$ für die Hypothesen $H = h_1$ (Abbiegen, rot) und $H = h_2$ (Geradeaus, blau) bei dem betrachteten Abbiegevorgang (links) sowie einer Geradeausfahrt (rechts)

4.4.4 Berechnung der Pfadwahrscheinlichkeiten

Neben der Frage, ob der Fahrer den potenziellen Konfliktpartner gesehen hat und daher am zugehörigen Haltepunkt anhalten wird, spielen bei der Risikobewertung gemäß der in Abschnitt 4.3.1 vorgestellten Warnstrategie auch die Pfadwahrscheinlichkeiten aus Kapitel 3 eine Rolle. Da die Kopfdrehung des Fahrers und die Beschleunigung des Fahrzeugs gemäß dem in diesem Kapitel entwickelten Modell keine unabhängigen Beobachtungen mehr darstellen, wird anstelle der zugehörigen Merkmale nun die Gesamt-Likelihood $P(A_k, \Phi_{Hk} | H_k)$ des DBN ausgewertet.

Wie bereits erwähnt und aus Abb. 4.15 ersichtlich, ist der Fahrer in der betrachteten Abbiegesituation ungewöhnlich zügig an die Kreuzung herangefahren. Hinsichtlich der Vorhersage der Pfadwahrscheinlichkeiten führt dies dazu, dass die Geradeausfahrt zwischen 3 und 4 Sekunden vor Erreichen des Konfliktpunkts wahrscheinlicher ist als das Abbiegemanöver – zumindest im Hinblick auf den beobachteten Geschwindigkeitsverlauf und die Kopfdrehung des Fahrers. Der Verlauf der Gesamt-Likelihood des DBN ist in Abb. 4.21 links dargestellt. Das rechte Diagramm zeigt zum Vergleich den Verlauf für eine Geradeausfahrt. In beiden Fällen ist eine Vorhersage des wahrscheinlichsten Pfades bei Erreichen der Warnschwelle von 2.5 s möglich, zumal die über die Zeit kumulierte Likelihood hierfür noch durch die des Blinkermerkmals aus Abschnitt 3.2 ergänzt wird. Bei der Risikobewertung der vorangegangenen Abschnitte wurden die Pfadwahrscheinlichkeiten bereits berücksichtigt.

5 Zusammenfassung und Ausblick

Das Ziel der Arbeit war die Entwicklung von Methoden zur Fahrerabsichtserkennung und Risikobewertung, die eine frühzeitige Warnung des Fahrers vor potenziellen Konfliktsituationen ermöglichen. Im Fokus lagen hierbei insbesondere innerstädtische Situationen, die auf Grund der hohen Dichte verletzlicher Verkehrsteilnehmer einen erheblichen Anteil an der Zahl der Verkehrstoten in Deutschland haben. Angesichts der ohnehin schon beachtlichen Komplexität dieser Situationen besteht die Notwendigkeit, die Zahl der ausgegebenen Warnungen auf das zur Unfallvermeidung erforderliche Minimum zu begrenzen. An die Risikobewertung eines entsprechenden Assistenzsystems sind daher die folgenden Anforderungen zu stellen:

1. Vorhersage der möglichen weiteren Entwicklungen der Verkehrssituation und Detektion potenzieller Konflikte,
2. Erkennung der Absicht der beteiligten Verkehrsteilnehmer, um Warnungen vor nicht relevanten Konfliktpartnern zu vermeiden,
3. Modellierung des Situationsbewusstseins, um die Interaktion zwischen Verkehrsteilnehmern bei der Risikobewertung zu berücksichtigen.

Ausgangspunkt der im Rahmen dieser Arbeit angestellten Untersuchungen war eine Literaturrecherche zum aktuellen Stand der Technik. Hierbei stellte sich heraus, dass zwar eine Vielzahl von Ansätzen zur Erkennung von je einem bestimmten Manöver existieren, aber nur vergleichsweise wenige die Unterscheidung zwischen mehr als zwei alternativen Manövern erlauben. Zudem existieren nur sehr wenige Arbeiten, die die tatsächliche Straßengeometrie oder die Interaktion mit anderen Verkehrsteilnehmern bei der Fahrerabsichtserkennung berücksichtigen. Da beide einen erheblichen Einfluss auf das Fahrerverhalten haben, stellt dies einen wesentlichen Nachteil der bestehenden Methoden zur Fahrerabsichtserkennung dar.

Als Voraussetzung für die Bewältigung der genannten Herausforderungen wurde die Wiederverwendbarkeit von Teilmodellen identifiziert, die vor allem

generativen Modellen eigen ist, sowie deren dynamische Parametrisierbarkeit in Abhängigkeit von der Kreuzungsgeometrie und dem kinematischen Zustand der Verkehrsteilnehmer. Letzteres wurde im Rahmen dieser Arbeit erstmals durch Verwendung allgemeingültiger parametrischer Fahrerverhaltensmodelle realisiert, die im Gegensatz zu fast allen bestehenden Ansätzen zur Fahrerabsichtserkennung auf beliebige Verkehrssituationen anwendbar sind. Dazu wurden drei Modelle entwickelt:

- Ein Modell für die zu erwartende Beschleunigung des Fahrzeugs in Abhängigkeit von der Straßengeometrie, etwaigen Vorderfahrzeugen und vorausliegenden Haltepunkten. Da die Vorderfahrzeuge dynamisch auf Basis des vom Fahrer verfolgten Pfades ermittelt werden, können mit Hilfe des Modells auch unmittelbar bevorstehende Überholvorgänge vorhergesagt werden. Darüber hinaus erlaubt das Modell die Prädiktion der weiteren Trajektorie des Fahrzeugs auch im Verlauf von Kurvenfahrten, Abbiegemanövern und Anhaltevorgängen.
- Ein Modell für den Fahrtrichtungsanzeiger, das neben dem Blinkerstatus auch den Zeitpunkt von dessen Aktivierung berücksichtigt. Im Gegensatz zu bestehenden Modellen ist es damit möglich, zwischen mehreren alternativen Abbiegemöglichkeiten in der gleichen Richtung zu unterscheiden, den Zeitpunkt eines bevorstehenden Fahrstreifenwechsels vorherzusagen und sogar ein unbeabsichtigtes Aktivieren des Fahrtrichtungsanzeigers als solches zu erkennen.
- Ein Modell für die zu erwartende Kopfdrehung des Fahrers in Abhängigkeit von dem von ihm verfolgten Pfad sowie seiner aktuellen Geschwindigkeit. Nach bestem Wissen des Autors ist dies das erste für die Fahrerabsichtserkennung eingesetzte Kopfdrehungsmodell, das die tatsächliche Fahrbahngeometrie berücksichtigt.

Die drei Fahrerverhaltensmodelle wurden anhand von insgesamt 1149 Kreuzungsüberfahrten und 523 Fahrstreifenwechsel im Realverkehr parametrisiert und bewertet. Letzteres erfolgte zugunsten der Vergleichbarkeit der Ergebnisse anhand einfacher Abbiegevorgänge an innerstädtischen Kreuzungen, wobei als Konfliktpunkt der Schnittpunkt des Fahrwegs mit dem Fuß- oder Radweg parallel zur Straße angenommen wurde. Dabei stellte sich heraus, dass bei einer Fehlerrate von 5% allein mit dem Blinkermerkmal 96% der Abbiegevorgänge 3s vor Erreichen des Konfliktpunkts vorhergesagt werden können. Die Vorhersage allein anhand des Geschwindigkeitsverlaufs ergab eine Sensitivität von 80%, während mit Hilfe des Kopfdrehungsmerkmals

nur knapp die Hälfte der Abbiegemanöver vorhergesagt werden. Die Fehlerkennungen beim Geschwindigkeitsmerkmal sind im Wesentlichen auf die Existenz langsamer Vorderfahrzeuge zurückzuführen, die eine Vorhersage im Stop-and-go-Verkehr objektiv unmöglich machen. Hinsichtlich der Kopfdrehung wurde beobachtet, dass sich diese in vielen Fällen erst ab etwa 1.5 s vor Erreichen des Konfliktpunkts von der des Geradeausfahrens unterscheidet und daher nur gelegentlich eine frühzeitige Aussage hinsichtlich der Fahrerabsicht erlaubt.

Da der Fahrtrichtungsanzeiger außerhalb von Probandenstudien in Deutschland nur bei etwa 80% aller Abbiegemanöver aktiviert wird, wurde zudem untersucht, inwieweit die Kombination der betrachteten Merkmale auch in diesem Fall eine verlässliche Vorhersage der Abbiegeabsicht ermöglicht. Der nicht aktivierte Blinker beeinflusst die Vorhersage dabei zunächst in Richtung der Geradeausfahrt, weshalb sich nun nahezu keine Falscherkennungen von Abbiegemanövern mehr ergeben. Nichtsdestotrotz werden bei Einbeziehung des Geschwindigkeitsmerkmals noch 67% der Abbiegemanöver 3 s vor Erreichen des Konfliktpunkts erkannt. Wird zusätzlich noch die Kopfdrehung des Fahrers berücksichtigt, steigt dieser Anteil sogar auf 75%.

Die Notwendigkeit einer expliziten Modellierung des Situationsbewusstseins wird im Rahmen der Arbeit anhand von Situationen diskutiert, bei denen die Interaktion mit vorhandenen oder möglicherweise vorhandenen Verkehrsteilnehmern das beobachtete Fahrerverhalten maßgeblich beeinflusst. Neben der Verbesserung der Fahrerabsichtserkennung zählen insbesondere

- die Vermeidung von Warnungen vor Konfliktpartnern, die der Fahrer selbst bereits wahrgenommen hat,
- das Ziehen von Rückschlüssen auf die Existenz sensorisch nicht erfasster Verkehrsteilnehmer hinter Sichtverdeckungen sowie
- die Vorhersage von Anfahrvorgängen, noch bevor sich diese in einer Pedalbetätigung durch den Fahrer äußern

zu den vorteilhaften Anwendungen des erweiterten Modells. Um zu zeigen, dass die echtzeitfähige Inferenz des Situationsbewusstseins technisch möglich ist, wurde ein entsprechendes Fahrerassistenzsystem mit Hilfe von dynamischen Bayes'schen Netzen und den oben beschriebenen Fahrerverhaltensmodellen prototypisch umgesetzt und der erwartete Mehrwert anhand von Beispielsituationen im realen Straßenverkehr nachgewiesen.

Für die praktische Anwendbarkeit der im Rahmen der Arbeit entwickelten Methoden wurden darüber hinaus Möglichkeiten aufgezeigt, wie verletzliche

Verkehrsteilnehmer im innerstädtischen Verkehr detektiert werden können, da dies mit aktuellen fahrzeuglokalen Sensoren in vielen Situationen nicht möglich ist. Nachgewiesen wurde hierbei insbesondere das Potenzial von Smartphones zur Detektion von Radfahrern. Grundlage waren umfangreiche Untersuchungen zur GPS-Qualität eines Samsung Nexus S, sowie die prototypische Umsetzung eines backendbasierten Systems zur Bereitstellung der entsprechenden Positionsdaten an Fahrzeuge in der Umgebung. Angesichts der starken Verbreitung von Smartphones und der zunehmenden Vernetzung der Fahrzeuge erscheint die Umsetzbarkeit eines derartigen Systems in der Praxis durchaus gegeben. Hinzu kommt, dass sich Radfahrer innerorts meist entlang von Radwegen bewegen – dadurch besteht die Möglichkeit, die bei der Kommunikation auftretende Latenzen durch eine einfache kartenbasierte Prädiktion zu kompensieren. Die dafür benötigten Kartenattribute, bspw. den Verlauf und die Frequentierung von Radwegen, könnten bei der Kommunikation über ein zentrales Backend direkt durch Aggregation der anonymisierten Positionsdaten der Verkehrsteilnehmer gewonnen werden. Dies und die Tatsache, dass für den Datentransport bereits existierende Kommunikationskanäle genutzt werden können, stellen einen erheblichen Vorteil gegenüber der lokalen Kommunikation über dedizierte WLAN-Standards wie dem IEEE 802.11p dar.

Zukünftige Arbeiten sollten insbesondere die Weiterentwicklung des bestehenden Modells für das Situationsbewusstsein des Fahrers zum Gegenstand haben. Unter der Maßgabe, die Inferenz mit exakten Methoden durchführen zu können, wurden die für das Situationsbewusstsein relevanten Zufahrten bisher jeweils als Einheit betrachtet, die jeweils nur entweder frei oder belegt bzw. sichtbar oder nicht sichtbar sein konnte. Dies kann dazu führen, dass die Sichtbarkeit eines einzelnen Verkehrsteilnehmers falsch eingeschätzt wird. Zudem erfordern die zeitinvariante Formulierung der Übergangswahrscheinlichkeiten des DBN sowie die niedrige Kardinalität seiner Zustandsgrößen eine starke Vereinfachung der kognitiven Prozesse des Fahrers. Wird von vornherein von einem Partikelfilter als Inferenzmethode ausgegangen, können diese Vereinfachungen vermutlich fallengelassen werden, wodurch einerseits die explizite Modellierung von Reaktionszeiten und andererseits eine deutlich genauere Berücksichtigung der Sichtbarkeit der einzelnen Zufahrten möglich wird. Schlussendlich sollten die zugehörigen Teilmodelle anhand von Probandenstudien oder sonstigen Flottendaten parametrisiert und quantitativ bewertet werden.

Literaturverzeichnis

- [1] Statistisches Bundesamt, “7,2% weniger Todesopfer auf deutschen Straßen im Jahr 2013,” 2014.
- [2] Euroean Transport Safety Council, “Road Safety Manifesto for the European Parliament Elections May 2014,” 2013. URL: www.etsc.eu
- [3] Bundesministerium für Verkehr, Bau und Stadtentwicklung, “Verkehrssicherheitsprogramm 2011 vom 28.10.2011,” 2011.
- [4] Deutscher Verkehrssicherheitsrat e. V., “Was leisten Fahrerassistenzsysteme?” 2009. URL: www.bester-beifahrer.de
- [5] Statistisches Bundesamt, “Verkehrsunfälle Fachserie 8 Reihe 7 Jahr 2013,” 2014.
- [6] M. Liebner und F. Klanner, “Fahrerabsichtserkennung und Risikobewertung,” in *Handbuch Fahrerassistenzsysteme*, 3. Auflage. Springer Fachmedien Wiesbaden, 2015.
- [7] M. R. Endsley, “Toward a theory of situation awareness in dynamic systems,” *Human Factors: The Journal of the Human Factors and Ergonomics Society*, Heft 37, Seiten 32–64, 1995.
- [8] F. Naujoks, H. Grattenthaler, und A. Neukum, “Zeitliche Gestaltung effektiver Fahrerinformationen zur Kollisionsvermeidung auf der Basis kooperativer Perzeption,” in *8. Workshop Fahrerassistenzsysteme*, 2012, Seiten 107–117.
- [9] M. Liebner, F. Klanner, und C. Stiller, “Der Fahrer im Mittelpunkt - Eye Tracking als Schlüssel zum mitdenkenden Fahrzeug?” in *8. Workshop Fahrerassistenzsysteme*. Walting: UniDAS e.V., 2012, Seiten 87–96.
- [10] M. Brännström, E. Coelingh, und J. Sjöberg, “Model-Based Threat Assessment for Avoiding Arbitrary Vehicle Collisions,” *IEEE Transactions on Intelligent Transportation Systems*, Band 11, Heft 3, Seiten 658–669, Sept. 2010.

- [11] M. Brännström, F. Sandblom, und L. Hammarstrand, “A probabilistic framework for decision-making in collision avoidance systems,” *IEEE Transactions on Intelligent Transportation Systems*, Band 14, Heft 2, Seiten 637–648, 2013.
- [12] S. Ammoun und F. Nashashibi, “Real time trajectory prediction for collision risk estimation between vehicles,” *2009 IEEE 5th International Conference on Intelligent Computer Communication and Processing (ICCP)*, Seiten 417–422, Aug. 2009.
- [13] J. Hillenbrand, A. M. Spieker, und K. Kroschel, “A Multilevel Collision Mitigation Approach – Its Situation Assessment, Decision Making, and Performance Tradeoffs,” *IEEE Transactions on Intelligent Transportation Systems*, Band 7, Heft 4, Seiten 528–540, Dez. 2006.
- [14] P. Lytrivis, G. Thomaidis, M. Tsogas, und a. Amditis, “An Advanced Cooperative Path Prediction Algorithm for Safety Applications in Vehicular Networks,” *IEEE Transactions on Intelligent Transportation Systems*, Band 12, Heft 3, Seiten 669–679, Sept. 2011.
- [15] A. Tamke, T. Dang, und G. Breuel, “A Flexible Method for Criticality Assessment in Driver Assistance Systems,” in *2011 IEEE Intelligent Vehicles Symposium (IV)*, 2011, Seiten 697–702.
- [16] A. Eidehall und L. Petersson, “Statistical Threat Assessment for General Road Scenes Using Monte Carlo Sampling,” *IEEE Transactions on Intelligent Transportation Systems*, Band 9, Heft 1, Seiten 137–147, Mar. 2008.
- [17] M. Althoff, O. Stursberg, und M. Buss, “Safety Assessment of Autonomous Cars using Verification Techniques,” *2007 American Control Conference*, Seiten 4154–4159, Juli 2007.
- [18] D. Petrich, T. Dang, D. Kasper, G. Breuel, und C. Stiller, “Map-based long term motion prediction for vehicles in traffic environments,” in *2013 16th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, Okt. 2013, Seiten 2166–2172.
- [19] M. Althoff und D. Althoff, “Safety verification of autonomous vehicles for coordinated evasive maneuvers,” in *2009 IEEE Intelligent Vehicles Symposium (IV)*, 2010.
- [20] A. Berthelot, A. Tamke, T. Dang, und G. Breuel, “Handling Uncertainties in Criticality Assessment,” in *2011 IEEE Intelligent Vehicles Symposium (IV)*, 2011, Seiten 571–576.

- [21] G. Weidl, V. Singhal, D. Petrich, D. Kasper, A. Wedel, und G. Breuel, “Collision Detection and Warning at Road Intersections using an Object Oriented Bayesian Network,” in *2013 IEEE 9th International Conference on Intelligent Computer Communication and Processing (ICCP)*, 2013.
- [22] M. Althoff, O. Stursberg, und M. Buss, “Model-Based Probabilistic Collision Detection in Autonomous Driving,” *IEEE Transactions on Intelligent Transportation Systems*, Band 10, Heft 2, Seiten 299–310, Juni 2009.
- [23] M. Althoff und A. Mergel, “Comparison of Markov Chain Abstraction and Monte Carlo Simulation for the Safety Assessment of Autonomous Cars,” *IEEE Transactions on Intelligent Transportation Systems*, Band 12, Heft 4, Seiten 1237–1247, Dez. 2011.
- [24] A. Broadhurst, S. Baker, und T. Kanade, “Monte Carlo road safety reasoning,” in *2005 IEEE Intelligent Vehicles Symposium (IV)*, 2005, Seiten 319–324.
- [25] D. Greene, J. Liu, J. Reich, Y. Hirokawa, A. Shinagawa, H. Ito, und T. Mikami, “An Efficient Computational Architecture for a Collision Early-Warning System for Vehicles, Pedestrians, and Bicyclists,” *IEEE Transactions on Intelligent Transportation Systems*, Band 12, Heft 4, Seiten 942–953, Dez. 2011.
- [26] G. S. Aoude, B. D. Luders, K. K. H. Lee, D. S. Levine, und J. P. How, “Threat Assessment Design for Driver Assistance System at Intersections,” in *2010 13th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, 2010, Seiten 1855–1862.
- [27] B. Morris, A. Doshi, und M. Trivedi, “Lane Change Intent Prediction for Driver Assistance : On-Road Design and Evaluation,” in *2011 IEEE Intelligent Vehicles Symposium (IV)*, 2011, Seiten 895–901.
- [28] T. Gindele, S. Brechtel, und R. Dillmann, “A probabilistic model for estimating driver behaviors and vehicle trajectories in traffic environments,” in *2010 13th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, 2010, Seiten 1625–1631.
- [29] D. Kasper, G. Weidl, T. Dang, G. Breuel, A. Tamke, und W. Rosenstiel, “Object-Oriented Bayesian Networks for Detection of Lane Change Maneuvers,” in *2011 IEEE Intelligent Vehicles Symposium (IV)*, 2011, Seiten 673–678.

- [30] G. Ortiz, F. Kummert, und J. Schm, “Prediction of driver behavior on a limited sensory setting,” in *Intelligent Transportation Systems (ITSC), 2012 15th International Conference on*, 2012, Seiten 638–643.
- [31] M. Kretschmer, L. König, J. Neubeck, und J. Wiedemann, “Erkennung und Prädiktion des Fahrerverhaltens während eines Überholvorgangs,” in *2. Tagung Aktive Sicherheit durch Fahrerassistenz*, Garching, 2006.
- [32] J. Firl, “Probabilistic Maneuver Prediction in Traffic Scenarios,” in *European Conference on Mobile Robots (ECMR)*, 2011.
- [33] Q. Tran und J. Firl, “A probabilistic discriminative approach for situation recognition in traffic scenarios,” in *2012 IEEE Intelligent Vehicles Symposium (IV)*, Juni 2012, Seiten 147–152.
- [34] H. Berndt und K. Dietmayer, “Driver intention inference with vehicle onboard sensors,” in *2009 IEEE International Conference on Vehicular Electronics and Safety (ICVES)*, 2009, Seiten 102–107.
- [35] F. Klanner, “Entwicklung eines kommunikationsbasierten Querverkehrsassistenten im Fahrzeug,” Dissertation, Technische Universität Darmstadt, 2008.
- [36] K. Lidström und T. Larsson, “Model-based Estimation of Driver Intentions Using Particle Filtering,” in *2008 11th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, Okt. 2008, Seiten 1177–1182.
- [37] S. Cheng und M. Trivedi, “Turn-intent analysis using body pose for intelligent driver assistance,” *Pervasive Computing, IEEE*, Band 5, Heft 4, Seiten 28–37, 2006.
- [38] G. Aoude und V. Desaraju, “Driver behavior classification at intersections and validation on large naturalistic data set,” *IEEE Transactions on Intelligent Transportation Systems*, Band 13, Heft 2, Seiten 724–736, 2012.
- [39] A. Armand, D. Filliat, und J. Ibanez-Guzmán, “Modelling Stop Intersection Approaches using Gaussian Processes,” in *2013 16th International Conference on Intelligent Transportation Systems (ITSC)*, 2013, Seiten 1650–1655.
- [40] J. McCall und M. Trivedi, “Driver behavior and situation aware brake assistance for intelligent vehicles,” *Proceedings of the IEEE*, Band 95, Heft 2, Seiten 374–387, 2007.

- [41] J. Schneider, A. Wilde, und K. Naab, “Probabilistic approach for modeling and identifying driving situations,” in *2008 IEEE Intelligent Vehicles Symposium (IV)*, Juni 2008, Seiten 343–348.
- [42] S. Lefèvre und C. Laugier, “Exploiting Map Information for Driver Intention Estimation at Road Intersections,” in *2011 IEEE Intelligent Vehicles Symposium (IV)*, 2011, Seiten 583–588.
- [43] T. Schendzielorz, P. Mathias, und F. Busch, “Infrastructure-based Vehicle Maneuver Estimation at Urban Intersections,” in *Intelligent Transportation Systems (ITSC), 16th International IEEE Annual Conference on*, 2013, Seiten 1442–1447.
- [44] T. Gindele, S. Brechtel, und R. Dillmann, “Learning context sensitive behavior models from observations for predicting traffic situations,” in *2013 16th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, Okt. 2013, Seiten 1764–1771.
- [45] J. Zhang und B. Roessler, “Situation analysis and adaptive risk assessment for intersection safety systems in advanced assisted driving,” in *Autonome Mobile Systeme*, R. Dillmann, J. Beyerer, C. Stiller, J. M. Zöllner, und T. Gindele, Eds. Springer, 2009, Seiten 249–258.
- [46] S. Herrmann und F. Schroven, “Situation analysis for driver assistance systems at urban intersections,” in *Vehicular Electronics and Safety (ICVES), 2012 IEEE International Conference on*, Juli 2012, Seiten 151–156.
- [47] A. Doshi und M. Trivedi, “A comparative exploration of eye gaze and head motion cues for lane change intent prediction,” in *2008 IEEE Intelligent Vehicles Symposium (IV)*, Juni 2008, Seiten 49–54.
- [48] J. McCall, D. Wipf, M. Trivedi, und B. Rao, “Lane Change Intent Analysis Using Robust Operators and Sparse Bayesian Learning,” *IEEE Transactions on Intelligent Transportation Systems*, Band 8, Heft 3, Seiten 431–440, Sept. 2007.
- [49] A. Doshi und M. Trivedi, “Tactical driver behavior prediction and intent inference: A review,” in *2011 14th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, 2011, Seiten 1892–1897.

- [50] G. Ortiz, J. Fritsch, F. Kummert, und A. Gepperth, “Behavior prediction at multiple time-scales in inner-city scenarios,” in *2011 IEEE Intelligent Vehicles Symposium (IV)*, 2011, Seiten 1066–1071.
- [51] P. Kumar, M. Perrollaz, und C. Laugier, “Learning-Based Approach for Online Lane Change Intention Prediction,” in *2013 IEEE Intelligent Vehicles Symposium (IV)*, 2013.
- [52] R. Mabuchi und K. Yamada, “Study on Driver-Intent Estimation at Yellow Traffic Signal by Using Driving Simulator,” in *2011 IEEE Intelligent Vehicles Symposium (IV)*, 2011, Seiten 0–5.
- [53] M. Tipping, “Sparse Bayesian learning and the relevance vector machine,” *The Journal of Machine Learning Research*, Band 1, Seiten 211–244, 2001.
- [54] I. Psorakis, T. Damoulas, und M. a. Girolami, “Multiclass relevance vector machines: sparsity and accuracy.” *IEEE transactions on neural networks / a publication of the IEEE Neural Networks Council*, Band 21, Heft 10, Seiten 1588–98, Okt. 2010.
- [55] M. Reichel, M. Botsch, R. Rauschecker, K.-h. Siedersberger, und M. Maurer, “Situation aspect modelling and classification using the Scenario Based Random Forest algorithm for convoy merging situations,” in *2010 13th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, 2010, Seiten 360–366.
- [56] C. Hermes, C. Wöhler, K. Schenk, und F. Kummert, “Long-term vehicle motion prediction,” in *2009 IEEE Intelligent Vehicles Symposium (IV)*, 2009, Seiten 652–657.
- [57] E. Käfer, C. Hermes, C. Wöhler, H. Ritter, und F. Kummert, “Recognition of situation classes at road intersections,” in *Robotics and Automation (ICRA), 2010 IEEE International Conference on*, Mai 2010, Seiten 3960–3965.
- [58] A. von Eichhorn, M. Werling, P. Zahn, und D. Schramm, “Maneuver prediction at intersections using cost-to-go gradients,” in *2013 16th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, Okt. 2013, Seiten 112–117.
- [59] F. Schroven und T. Giebel, “Fahrerintentionserkennung für Fahrerassistenzsysteme,” in *VDI-FVT-Jahrbuch*, 2009, Seiten 54–58.

- [60] S. Lefèvre, C. Laugier, J. Ibañez guzmán, und J. Ibanez-Guzman, “Context-based Estimation of Driver Intent at Road Intersections,” in *Computational Intelligence in Vehicles and Transportation Systems, 2011 IEEE Symposium on*, 2011, Seiten 583–588.
- [61] J. Perl, *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*. Morgan Kaufmann Publishers San Francisco, 1988.
- [62] D. Meyer-Delius, “Probabilistic situation recognition for vehicular traffic scenarios,” in *Robotics and Automation (ICRA), 2009 IEEE International Conference on*, 2009, Seiten 459–464.
- [63] L. Rabiner, “A tutorial on hidden Markov models and selected applications in speech recognition,” *Proceedings of the IEEE*, Band 77, Heft 2, Seiten 257–286, 1989.
- [64] Q. Tran und J. Firl, “Modelling of traffic situations at urban intersections with probabilistic non-parametric regression,” in *2013 IEEE Intelligent Vehicles Symposium (IV)*, Juni 2013, Seiten 334–339.
- [65] C. Laugier, I. E. Paromtchik, M. Perrollaz, M. Yong, J.-D. Yoder, C. Tay, K. Mekhnacha, und Amaury Nègre, “Probabilistic Analysis of Dynamic Scenes and Collision Risks Assessment to Improve Driving Safety,” *IEEE Intelligent Transportation Systems Magazine*, Seiten 4–19, Okt. 2011.
- [66] I. Dagi, M. Brost, und G. Breuel, “Action Recognition And Prediction For Driver Assistance Systems Using Dynamic Belief Networks,” in *Agent Technologies, Infrastructures, Tools, and Applications for E-Services*. Springer, 2003, Seiten 179–194.
- [67] N. Oliver und A. Pentland, “Graphical models for driver behavior recognition in a SmartCar,” in *2000 IEEE Intelligent Vehicles Symposium (IV)*, 2000, Seiten 7–12.
- [68] S. Lefèvre, C. Laugier, und J. Ibanez-Guzmán, “Risk assessment at road intersections: Comparing intention and expectation,” in *2012 IEEE Intelligent Vehicles Symposium (IV)*, 2012, Seiten 165 – 171.
- [69] G. Agamennoni, J. I. Nieto, und E. M. Nebot, “A Bayesian Approach For Driving Behavior Inference,” in *2011 IEEE Intelligent Vehicles Symposium (IV)*, 2011, Seiten 595–600.

- [70] S. Brechtel, T. Gindele, und R. Dillmann, “Probabilistic MDP-behavior planning for cars,” in *2011 14th International IEEE Annual Conference on Intelligent Transportation Systems (ITSC)*, 2011, Seiten 1537–1542.
- [71] I. Dagli und D. Reichardt, “Motivation-based approach to behavior prediction,” in *2002 IEEE Intelligent Vehicles Symposium (IV)*, 2002, Seiten 227–233.
- [72] D. Koller, “Object-Oriented Bayesian Networks,” in *1997 13th Annual Conference on Uncertainty in Artificial Intelligence (UAI)*, 1997, Seiten 302–313.
- [73] S. Vacek, “Videogestützte Umfelderkennung zur Interpretation von Verkehrssituationen für kognitive Automobile,” Dissertation, Universität Karlsruhe (TH), 2008.
- [74] C. Schwering und G. Lakemeyer, “Spatio-Temporal Reasoning about Traffic Scenarios,” in *2013 11th International Symposium on Logical Formalizations of Commonsense Reasoning*, 2013.
- [75] A.-C. Boury-Brisset und N. Tourigny, “Knowledge capitalisation through case bases and knowledge engineering for road safety analysis,” *Knowledge-Based Systems*, Band 13, Heft 5, Seiten 297–305, Okt. 2000.
- [76] S. Vacek, T. Gindele, J. M. Zollner, und R. Dillmann, “Situation classification for cognitive automobiles using case-based reasoning,” in *2007 IEEE Intelligent Vehicles Symposium (IV)*, Juni 2007, Seiten 704–709.
- [77] R. Graf, H. Deusch, M. Fritzsche, und K. Dietmayer, “A learning concept for behavior prediction in traffic situations,” in *2013 IEEE Intelligent Vehicles Symposium (IV)*, Juni 2013, Seiten 672–677.
- [78] A. Chinae und M. Parent, “Risk Assessment Algorithms Based on Recursive Neural Networks,” in *2007 International Joint Conference on Neural Networks*, Aug. 2007, Seiten 1434–1440.
- [79] F. D. Salim, S. W. Loke, A. Rakotonirainy, B. Srinivasan, und S. Krishnaswamy, “Collision Pattern Modeling and Real-Time Collision Detection at Road Intersections,” in *2007 IEEE Intelligent Transportation Systems Conference*, Sept. 2007, Seiten 161–166.

- [80] M. Liebner, F. Klanner, und C. Stiller, “Active safety for vulnerable road users based on smartphone position data,” in *2013 IEEE Intelligent Vehicles Symposium (IV)*, Juni 2013, Seiten 256–261.
- [81] “Forschungsprojekt Kooperative Perzeption (Ko-PER),” 2013. URL: <http://ko-fas.de/deutsch/ko-per---kooperative-perzeption.html>
- [82] R. Wertheimer und F. Klanner, “Cooperative Perception to Promote Driver Assistance and Preventive Safety,” in *8th International Workshop on Intelligent Transportation (WIT)*, 2011.
- [83] D. Schwarz, H. Kloeden, und R. Rasshofer, “Ko-TAG - Cooperative Sensor Technology for Traffic Safety Applications,” in *8th International Workshop on Intelligent Transportation (WIT)*, 2011.
- [84] H. Stübing, M. Bechler, D. Heussner, T. May, I. Radusch, H. Rechner, und P. Vogel, “sim TD: a car-to-x system architecture for field operational tests,” *IEEE Communications*, Seiten 148–154, Mai 2010.
- [85] A. Rauch, F. Klanner, und K. Dietmayer, “Analysis of V2X communication parameters for the development of a fusion architecture for cooperative perception systems,” in *2011 IEEE Intelligent Vehicles Symposium (IV)*, 2011.
- [86] Bundesverband Informationswirtschaft, Telekommunikation und neue Medien e.V., “Neuer Rekord bei Smartphones,” 2013. URL: www.bitkom.org
- [87] “Genivi Alliance,” 2013. URL: <http://www.genivi.org/>
- [88] Strategy Analytics, “Samsung Galaxy S3 Becomes World’s Best-Selling Smartphone Model in Q3 2012,” 2012. URL: www.StrategyAnalytics.com
- [89] D. Thielen, T. Lorenz, M. Hannibal, F. Koster, und J. Plattner, “A feasibility study on a cooperative safety application for cyclists crossing intersections,” in *2012 15th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, 2012, Seiten 1197–1204.
- [90] C. Lottermann, M. Botsov, P. Fertl, und R. Mullner, “Performance evaluation of automotive off-board applications in LTE deployments,” in *2012 IEEE Vehicular Networking Conference (VNC)*, Nov. 2012, Seiten 211–218.

- [91] G. Araniti und C. Campolo, “LTE for vehicular networking: A survey,” *IEEE Communications Magazine*, Band 51, Heft May, Seiten 148–157, 2013.
- [92] “GIDAS - German In-Depth Accident Study,” 2011. URL: www.gidas.org
- [93] Broadcom Corporation, “Smartphone Location Platform Delivers 10X Improved Acquisition Performance and Leverages Broadcom Wireless Connectivity for Indoor Positioning,” 2012. URL: www.broadcom.com
- [94] K. Buchholz, “Honda works to prevent vehicle-to-pedestrian accidents,” Sept. 2013. URL: <http://articles.sae.org/12408/>
- [95] M. Liebner, M. Baumann, F. Klanner, und C. Stiller, “Driver intent inference at urban intersections using the intelligent driver model,” in *2012 IEEE Intelligent Vehicles Symposium (IV)*, 2012, Seiten 1162–1167.
- [96] M. Liebner, F. Klanner, M. Baumann, C. Ruhhammer, und C. Stiller, “Velocity-Based Driver Intent Inference at Urban Intersections in the Presence of Preceding Vehicles,” *IEEE Intelligent Transportation Systems Magazine*, Band 5, Heft 2, Seiten 10–21, 2013.
- [97] M. Liebner, C. Ruhhammer, F. Klanner, und C. Stiller, “Generic driver intent inference based on parametric models,” in *2013 16th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, Okt. 2013, Seiten 268–275.
- [98] G. Maier, “Smooth Minimum Arc Paths,” Dissertation, Universität Passau, 2010.
- [99] Auto Club Europa, “Reviere der Blinkmuffel,” Seite 2008, 2008. URL: www.ace-online.de/fileadmin/user_uploads/Der_Club/Dokumente/10.07.2008_Grafik_Blinkmuffel_1.pdf
- [100] “BOOST C++ Libraries,” 2014. URL: www.boost.org/
- [101] “Commons Math: The Apache Commons Mathematics Library,” 2014. URL: <http://commons.apache.org/>
- [102] P. Gipps, “A behavioural car-following model for computer simulation,” *Transportation Research Part B: Methodological*, Band I, Heft 2, 1981.

- [103] R. Wiedemann, *Simulation des Verkehrsflusses*. Karlsruhe: Schriftenreihe des Instituts für Verkehrswesen der Universität Karlsruhe, 1974, Band 8.
- [104] M. Treiber und D. Helbing, “Realistische Mikrosimulation von Straßenverkehr mit einem einfachen Modell,” in *16th Symposium Simulationstechnik ASIM*, Band 2002, 2002, Seite 80.
- [105] P. Angkitittrakul, “Modeling and adaptation of stochastic driver-behavior model with application to car following,” in *2011 IEEE Intelligent Vehicles Symposium (IV)*, 2011, Seiten 814–819.
- [106] J. Sörstedt, L. Svensson, F. Sandblom, und L. Hammarstrand, “A New Vehicle Motion Model for Improved Predictions and Situation Assessment,” *IEEE Transactions on Intelligent Transportation Systems*, Band 12, Heft 4, Seiten 1209–1219, 2011.
- [107] C. Stockburger und S. Sperber, “Da guckst du - Steuerung per Augenkontakt,” *Spiegel Online*, Jan. 2014.
- [108] M. Land und D. Lee, “Where do we look when we steer.” *Nature*, Band 369, Seiten 742 – 744, 1994.
- [109] J. P. Wann und D. K. Swapp, “Where do we look when we steer and how does it matter?” *Journal of Vision*, Band 1, Heft 3, Seiten 185–185, 2001.
- [110] S. Epping, “Fahrerverhaltensvorhersage unter Berücksichtigung des Situationsbewusstseins,” Masterarbeit, Technische Universität München, 2014.
- [111] M. A. Goodrum, M. J. Trotter, A. Aksel, S. T. Acton, und K. Skadron, “Parallelization of particle filter algorithms,” in *Proceedings of the 2010 International Conference on Computer Architecture*, Folge ISCA’10. Berlin, Heidelberg: Springer-Verlag, 2012, Seiten 139–149.
- [112] A. Lee, C. Yau, M. B. Giles, A. Doucet, und C. C. Holmes, “On the utility of graphics cards to perform massively parallel simulation of advanced monte carlo methods,” *Journal of computational and graphical statistics*, Band 19, Heft 4, Seiten 769–789, 2010.

Liste eigener Veröffentlichungen

Konferenzbeiträge

1. M. Liebner, M. Baumann, F. Klanner und C. Stiller, “Driver intent inference at urban intersections using the intelligent driver model,” in *2012 IEEE Intelligent Vehicles Symposium (IV)*, IEEE, 2012, pp. 1162–1167 (Best Paper Award).
2. M. Liebner, F. Klanner und C. Stiller, “Der Fahrer im Mittelpunkt - Eye Tracking als Schlüssel zum mitdenkenden Fahrzeug?” in *8. Workshop Fahrerassistenzsysteme*, UniDAS e.V., 2012, pp. 87–96.
3. M. Liebner, F. Klanner und C. Stiller, “Active safety for vulnerable road users based on smartphone position data,” in *2013 IEEE Intelligent Vehicles Symposium (IV)*, IEEE, June 2013, pp. 256–261.
4. M. Liebner, C. Ruhhammer, F. Klanner und C. Stiller, “Generic driver intent inference based on parametric models,” in *2013 16th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, IEEE, Oct. 2013, pp. 268–275.

Fachzeitschriften

1. F. Klanner, R. Rasshofer und M. Liebner, “Eine neue Dimension der Fahrzeugsicherheit,” *Elektronik Automotive*, no. 10, pp. 20–25, 2012.
2. M. Liebner, F. Klanner, M. Baumann, C. Ruhhammer und C. Stiller, “Velocity-Based Driver Intent Inference at Urban Intersections in the Presence of Preceding Vehicles,” *IEEE Intelligent Transportation Systems Magazine*, vol. 5, no. 2, pp. 10–21, 2013.

Buchkapitel

1. M. Liebner und F. Klanner, "Fahrerabsichtserkennung und Risikobewertung," in *Handbuch Fahrerassistenzsysteme*, 3. Auflage. Springer Fachmedien Wiesbaden, 2015.
2. M. Liebner und F. Klanner, "Driver Intent Inference and Risk Assessment," in *Handbook of Driver Assistance Systems*, 1. Auflage. Springer, 2016.

Patentanmeldungen

1. M. Liebner, F. Klanner, und Klöden, „Verfahren zur Vorhersage des Geschwindigkeitsverlaufs“, März 2013, AZ 102013200724.8.
2. M. Liebner, C. Ruhhammer, F. Klanner und H. Klöden, „Verfahren zur Vorhersage des Geschwindigkeitsverlaufs“, März 2013, AZ 102013203908.5.
3. M. Liebner, C. Ruhhammer, F. Klanner und H. Klöden, „Verfahren zur Vorhersage der Fahrerabsicht“, April 2013, AZ 102013207456.5.
4. M. Liebner, C. Ruhhammer, F. Klanner und H. Klöden, „Verwendung Generischer Fahrerverhaltensmodelle zur Vorhersage der Fahrerabsicht“, Juni 2013, AZ 102013212359.0.
5. M. Liebner, C. Ruhhammer, F. Klanner und H. Klöden, „Verwendung des Fahrtrichtungsanzeigers zur Vorhersage der Fahrerabsicht“, Juni 2013, AZ 102013212360.4.
6. M. Liebner, C. Ruhhammer, F. Klanner und H. Klöden, „Verwendung der Blickrichtung des Fahrers zur Vorhersage der Fahrerabsicht“, Juni 2013, AZ 102013212360.4.
7. M. Liebner, C. Ruhhammer, F. Klanner und H. Klöden, „Verfahren zur Verbesserung der Zuverlässigkeit von Fahrerassistenzsystemen“, Sept. 2013, AZ 102013218497.2.
8. M. Liebner, S. Epping, F. Klanner und H. Klöden, „Fahrerassistenzsystem zur Erkennung eines sensorisch nicht erfassbaren Kollisionspartners“, März 2014, AZ 102014203805.7.

9. M. Liebner, S. Epping, F. Klanner und H. Klöden, „Verfahren zur Vorhersage eines voraussichtlichen Anfahrzeitpunktes eines Fahrzeugs“, März 2014, AZ 102014203806.5.
10. M. Liebner, S. Epping, F. Klanner und H. Klöden, „Fahrerassistenzsystem und Verfahren zum Verzögern oder Unterdrücken einer Ausgabe einer Warnung durch ein Assistenzsystem eines Fahrzeugs“, März 2014, AZ 102014203807.3.
11. M. Liebner, F. Klanner und H. Klöden, „Fahrerassistenzsystem und Verfahren zum Unterdrücken einer Ausgabe einer Warnung eines Assistenzsystems eines Fortbewegungsmittels“, März 2014, AZ 102014203808.1.

Betreute studentische Abschlussarbeiten

1. S. Bayerl, "Kontextbasierte Vorhersage von kritischen Fahrstreifenwechseln," Masterarbeit, Fachhochschule Deggendorf, 2012.
2. L. Kutschat, "Situationsinterpretation und probabilistische Risikobewertung von Fahrstreifenwechseln auf der Autobahn," Bachelorarbeit, Hochschule München, 2012.
3. M. Baumann, "Bachelorarbeit Trajektorienbasierte Intentionserkennung im Kreuzungsbereich," Bachelorarbeit, Hochschule München, 2012.
4. C. Ruhhammer, "Fahrerintentionserkennung im Kreuzungsbereich," Masterarbeit, Technische Universität München, 2012.
5. S. Epping, "Fahrerverhaltensvorhersage unter Berücksichtigung des Situationsbewusstseins," Masterarbeit, Technische Universität München, 2014.

Schriftenreihe

Institut für Mess- und Regelungstechnik

Karlsruher Institut für Technologie

(1613-4214)

Die Bände sind unter www.ksp.kit.edu als PDF frei verfügbar
oder als Druckausgabe bestellbar.

- Band 001** Hans, Annegret
**Entwicklung eines Inline-Viskosimeters
auf Basis eines magnetisch-induktiven
Durchflussmessers. 2004**
ISBN 3-937300-02-3
- Band 002** Heizmann, Michael
**Auswertung von forensischen Riefenspuren
mittels automatischer Sichtprüfung. 2004**
ISBN 3-937300-05-8
- Band 003** Herbst, Jürgen
**Zerstörungsfreie Prüfung von Abwasserkanälen
mit Klopfeschall. 2004**
ISBN 3-937300-23-6
- Band 004** Kammel, Sören
**Deflektometrische Untersuchung spiegelnd
reflektierender Freiformflächen. 2005**
ISBN 3-937300-28-7
- Band 005** Geistler, Alexander
**Bordautonome Ortung von Schienenfahrzeugen
mit Wirbelstrom-Sensoren. 2007**
ISBN 978-3-86644-123-1
- Band 006** Horn, Jan
**Zweidimensionale Geschwindigkeitsmessung
texturierter Oberflächen mit flächenhaften
bildgebenden Sensoren. 2007**
ISBN 978-3-86644-076-0

- Band 007** Hoffmann, Christian
Fahrzeuginnenraumdetektion durch Fusion monoskopischer
Videomerkmale. 2007
ISBN 978-3-86644-139-2
- Band 008** Dang, Thao
Kontinuierliche Selbstkalibrierung von
Stereokameras. 2007
ISBN 978-3-86644-164-4
- Band 009** Kapp, Andreas
Ein Beitrag zur Verbesserung und Erweiterung
der Lidar-Signalverarbeitung für Fahrzeuge. 2007
ISBN 978-3-86644-174-3
- Band 010** Horbach, Jan
Verfahren zur optischen 3D-Vermessung
spiegelnder Oberflächen. 2008
ISBN 978-3-86644-202-3
- Band 011** Böhringer, Frank
Gleisselektive Ortung von Schienenfahrzeugen
mit bordautonomer Sensorik. 2008
ISBN 978-3-86644-196-5
- Band 012** Xin, Binjian
Auswertung und Charakterisierung
dreidimensionaler Messdaten technischer
Oberflächen mit Riefentexturen. 2009
ISBN 978-3-86644-326-6
- Band 013** Cech, Markus
Fahrspurschätzung aus monokularen Bildfolgen für
innerstädtische Fahrerassistenzanwendungen. 2009
ISBN 978-3-86644-351-8
- Band 014** Speck, Christoph
Automatisierte Auswertung forensischer Spuren
auf Patronenhülsen. 2009
ISBN 978-3-86644-365-5

- Band 015** Bachmann, Alexander
Dichte Objektsegmentierung in Stereobildfolgen. 2010
ISBN 978-3-86644-541-3
- Band 016** Duchow, Christian
Videobasierte Wahrnehmung markierter Kreuzungen mit lokalem Markierungstest und Bayes'scher Modellierung. 2011
ISBN 978-3-86644-630-4
- Band 017** Pink, Oliver
Bildbasierte Selbstlokalisierung von Straßenfahrzeugen. 2011
ISBN 978-3-86644-708-0
- Band 018** Hensel, Stefan
Wirbelstromsensorbasierte Lokalisierung von Schienenfahrzeugen in topologischen Karten. 2011
ISBN 978-3-86644-749-3
- Band 019** Carsten Hasberg
Simultane Lokalisierung und Kartierung spurgeführter Systeme. 2012
ISBN 978-3-86644-831-5
- Band 020** Pitzer, Benjamin
Automatic Reconstruction of Textured 3D Models. 2012
ISBN 978-3-86644-805-6
- Band 021** Roser, Martin
Modellbasierte und positionsgenaue Erkennung von Regentropfen in Bildfolgen zur Verbesserung von videobasierten Fahrerassistenzfunktionen. 2012
ISBN 978-3-86644-926-8
- Band 022** Loose, Heidi
Dreidimensionale Straßenmodelle für Fahrerassistenzsysteme auf Landstraßen. 2013
ISBN 978-3-86644-942-8

- Band 023** Rapp, Holger
Reconstruction of Specular Reflective Surfaces using Auto-Calibrating Deflectometry. 2013
ISBN 978-3-86644-966-4
- Band 024** Moosmann, Frank
Interlacing Self-Localization, Moving Object Tracking and Mapping for 3D Range Sensors. 2013
ISBN 978-3-86644-977-0
- Band 025** Geiger, Andreas
Probabilistic Models for 3D Urban Scene Understanding from Movable Platforms. 2013
ISBN 978-3-7315-0081-0
- Band 026** Hörter, Marko
Entwicklung und vergleichende Bewertung einer bildbasierten Markierungslichtsteuerung für Kraftfahrzeuge. 2013
ISBN 978-3-7315-0091-9
- Band 027** Kitt, Bernd
Effiziente Schätzung dichter Bewegungsvektorfelder unter Berücksichtigung der Epipolargeometrie zwischen unterschiedlichen Ansichten einer Szene. 2013
ISBN 978-3-7315-0105-3
- Band 028** Lategahn, Henning
Mapping and Localization in Urban Environments Using Cameras. 2013
ISBN 978-3-7315-0135-0
- Band 029** Tischler, Karin
Informationsfusion für die kooperative Umfeldwahrnehmung vernetzter Fahrzeuge. 2014
ISBN 978-3-7315-0166-4
- Band 030** Schmidt, Christian
Fahrstrategien zur Unfallvermeidung im Straßenverkehr für Einzel- und Mehrobjektszenarien. 2014
ISBN 978-3-7315-0198-5

- Band 031** Firl, Jonas
**Probabilistic Maneuver Recognition
in Traffic Scenarios.** 2014
ISBN 978-3-7315-0287-6
- Band 032** Schönbein, Miriam
**Omnidirectional Stereo Vision
for Autonomous Vehicles.** 2015
ISBN 978-3-7315-0357-6
- Band 033** Strauß, Tobias
**Kalibrierung von Multi-Kamera-Systemen.
Kombinierte Schätzung von intrinsischem
Abbildungsverhalten der einzelnen Kameras
und deren relativer Lage zueinander ohne
Erfordernis sich überlappender Sichtbereiche.** 2016
Nicht erschienen
- Band 034** Liebner, Martin
**Fahrerabsichtserkennung und Risikobewertung für
warnende Fahrerassistenzsysteme.** 2016
ISBN 978-3-7315-0508-2

Um den Fahrer rechtzeitig auf drohende Kollisionen hinzuweisen und ihn darüber hinaus nicht mit unnötigen Warnungen von der Fahraufgabe abzulenken, benötigen warnende Fahrerassistenzsysteme eine kontinuierliche Bewertung des aktuellen Kollisionsrisikos anhand möglichen zukünftigen Trajektorien des eigenen Fahrzeugs, aber auch der der anderen Verkehrsteilnehmer. Aufgrund der Reaktionszeit des Fahrers ist hierbei eine Vorausschau von 2-3 Sekunden erforderlich, die in komplexen Verkehrssituationen nur unter Berücksichtigung der Fahrerabsicht realisierbar ist. Die vorliegende Arbeit diskutiert die mit der Fahrerabsichtserkennung und Risikobewertung verbundenen Herausforderungen, schlägt eine geeignete Methode vor und bewertet diese anhand von Probandenstudien im Realverkehr.

Gegenüber dem bisherigen Stand der Technik besteht der Vorteil der hier vorgestellten Methode in ihrer Anwendbarkeit auf beliebige Verkehrssituationen. Diese wird erreicht, indem generative Modelle zur Beschreibung des erwarteten Fahrerverhaltens in Abhängigkeit von der Straßengeometrie und dem Verhalten der anderen Verkehrsteilnehmer eingesetzt werden. Die Wahrscheinlichkeiten für die möglichen Fahrerabsichten, das Situationsbewusstsein des Fahrers und das sich daraus ergebende Kollisionsrisiko werden mit Hilfe von dynamischen Bayes'schen Netzen bestimmt, die entsprechend der aktuellen Verkehrssituation in jedem Zeitschritt neu zusammengesetzt werden.

Die zugehörigen experimentellen Untersuchungen zeigen vielversprechende Ergebnisse selbst unter Berücksichtigung von Echtzeitanforderungen.

