




CHRISTIAN RUHHAMMER

Inferenz von Kreuzungsinformationen aus Flottendaten



Christian Ruhhammer

**Inferenz von Kreuzungsinformationen
aus Flottendaten**

Schriftenreihe
Institut für Mess- und Regelungstechnik,
Karlsruher Institut für Technologie (KIT)
Band 037

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

Inferenz von Kreuzungsinformationen aus Flottendaten

von
Christian Ruhhammer

Dissertation, Karlsruher Institut für Technologie
KIT-Fakultät für Maschinenbau

Tag der mündlichen Prüfung: 22. Juni 2017
Referenten: Prof. Dr.-Ing. Christoph Stiller
Prof. Dr.-Ing. Klaus 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 a Creative Commons Attribution-Share Alike 4.0 International License
(CC BY-SA 4.0): <https://creativecommons.org/licenses/by-sa/4.0/deed.en>*



*The cover page is licensed under a Creative Commons
Attribution-No Derivatives 4.0 International License (CC BY-ND 4.0):
<https://creativecommons.org/licenses/by-nd/4.0/deed.en>*

Print on Demand 2017 – Gedruckt auf FSC-zertifiziertem Papier

ISSN 1613-4214
ISBN 978-3-7315-0721-5
DOI 10.5445/KSP/1000073704

Inferenz von Kreuzungsinformationen aus Flottendaten

Zur Erlangung des akademischen Grades

Doktor der Ingenieurwissenschaften

der Fakultät für Maschinenbau

Karlsruher Institut für Technologie (KIT)

genehmigte

Dissertation

von

M. Sc. Christian Ruhhammer

Tag der mündlichen Prüfung: 22. Juni 2017

Referent: Prof. Dr.-Ing. Christoph Stiller

Korreferent: Prof. Dr.-Ing. Klaus Dietmayer

Kurzfassung

Künftige Fahrerassistenzsysteme und hochautomatisierte Fahrfunktionen basieren auf digitalen Karten. Damit werden hohe Anforderungen an die Korrektheit und Aktualität der enthaltenen Informationen gestellt. In der vorliegenden Arbeit werden dafür neuartige automatisierte Verfahren zur Extraktion aktueller Karteninformationen aus Flottendaten vorgestellt. Aufgrund der hohen Komplexität und Variabilität innerstädtischer Szenarien stellen die Umsetzung von Assistenzsystemen und das Erstellen von Karten im urbanen Bereich eine besondere Herausforderung dar. Die Arbeit richtet ihren Fokus auf die Inferenz von statischen Kreuzungsinformationen aus Flottendaten. Mittels maschinellen Lernens und statistischer Verfahren werden Kreuzungstopologie und -geometrie, Vorfahrtsregel, Haltlinienposition und statische Informationen über die Signalgebung an Kreuzungen mit einer Lichtsignalanlage ermittelt.

Ein automatisiertes Verteilen der generierten Informationen an Fahrzeuge über das Internet ermöglicht eine wesentliche Verbesserung der Aktualität digitaler Karten, beispielsweise durch eine zeitnahe Detektion von baulichen Änderungen. Als Anwendungsbeispiel wird ein System zur automatisierten Längsregelung an Kreuzungen mit Lichtsignalanlage entwickelt. Grundlage des Systems sind automatisiert ermittelte Kreuzungsinformationen aus Flottendaten. Der Mehrwert dieser Informationen zeigt sich in einer erweiterten Vorausschau und der damit einhergehenden Erhöhung des Komforts, sowie einer Verbesserung der Detektion des relevanten Lichtsignals und damit einer Erhöhung der Sicherheit.

Schlagerworte: Automatisierte Kartenerstellung, Flottendaten, Kreuzungsinformationen, Lichtsignalanlage, Maschinelles Lernen

Abstract

The next generation of driver assistance systems and highly automated driving functions are based on digital maps. This implies that there are high requirements on the correctness and up-to-dateness of this information. This work presents new automated methods to extract up-to-date map information from fleet data. Concerning the high complexity and variability of inner city scenarios, the implementation of assistance systems and digital map creation in urban areas is especially challenging. This work focuses on the inference of static intersection information from fleet data. The topology and geometry of intersections, priority regulation, stop line position and information on the signaling at intersections with traffic lights are determined through machine learning and statistical methods.

The generated map information is distributed automatically to vehicles over the internet and consequently allows substantial improvements in the up-to-dateness of digital maps, like e.g. the immediate detection of changes of the street course. This work introduces a new driver assistance system, which enhances an adaptive cruise control with automatic deceleration at red traffic lights. The system is based on automatically extracted intersection information from fleet data. The information facilitates enhanced foresight capabilities and thus an increase in driving comfort. Furthermore, it allows a more robust detection of the relevant traffic light, which leads to an increase in safety.

Keywords: Automated Map Creation, Fleet Data, Intersection Information, Traffic Light, Machine Learning

Danksagung

Die vorliegende Arbeit entstand im Rahmen meiner Tätigkeit bei der BMW Group und als Doktorand am Institut für Mess- und Regelungstechnik am Karlsruher Institut für Technologie (KIT). In dieser Zeit haben mich zahlreiche Personen unterstützt, wodurch die Arbeit erst möglich wurde. Zunächst möchte ich mich herzlich bei Herrn Prof. Christoph Stiller für die Betreuung, die vielen fachlichen Diskussionen und konstruktiven Vorschläge zur Verbesserung der Arbeit bedanken. Herrn Prof. Klaus Dietmayer danke ich für die Übernahme des Koreferats und das Interesse an meiner Arbeit.

Bei meinen Kollegen von BMW möchte ich mich für die hervorragende Zusammenarbeit in sehr angenehmer Arbeitsatmosphäre, für die zahlreichen Diskussionen und Unterstützung meiner Projekte bedanken. Besonders bedanken möchte ich mich bei Dr. Felix Klanner für seinen Einsatz zur Ermöglichung meiner Arbeit, die Spaziergänge mit vertiefenden Diskussionen und die ständige Unterstützung meiner Projekte. Ebenfalls möchte ich mich bei Dr. Horst Klöden und Klaus Dollinger für die großartige fachliche und persönliche Unterstützung bedanken. Auch meinen Kollegen Justus Jordan, Dr. Martin Liebner und Dr. Andreas Rauch möchte ich besonderen Dank für die vielen Diskussionen beim Kaffee und für das Feedback zu meiner Arbeit aussprechen. Nicht zuletzt möchte ich Sonja Steker, Atanasko Atanasov, Timo Rokitte, Nils Hirsenkorn, Sascha Moecker, Ekaterina Mikaeva, Vitali Kaiser, Thoralf Reis und Michael Baumann für ihre Beiträge im Rahmen von Praktika und studentischen Abschlussarbeiten danken.

Ganz besonderer Dank gilt meiner Familie, meinen Freunden und vor allem meinen Eltern Elfriede und Josef, die mit ihrer permanenten Unterstützung maßgeblich zum Erfolg dieser Arbeit beigetragen haben.

München, im Juli 2017

Christian Ruhhammer

Inhaltsverzeichnis

Abkürzungs- und Symbolverzeichnis	xi
1 Einführung	1
1.1 Kreuzungsinformationen für Fahrerassistenzsysteme	4
1.2 Stand der Technik zur Kartenerstellung	9
1.3 Problemstellung	15
1.4 Struktur der Arbeit	17
2 Grundlagen	19
2.1 Kreuzungsmittelpunkte	19
2.2 Maße für die Unterschiedlichkeit	24
2.3 Datengrundlage	26
3 Repräsentation einer Straßenkreuzung	29
3.1 Kreuzungsein- und -ausfahrten	32
3.2 Mittlere Kreuzungspfade	36
4 Vorfahrtsregeln an Straßenkreuzungen	43
4.1 Überwachtes Lernen von Vorfahrtsregeln	43
4.2 Extraktion von Klassifikationsmerkmalen	45
4.3 Evaluation	51
4.3.1 Vergleich von Klassifikationsverfahren	52
4.3.2 Aufteilung der Vorfahrtsregeln in Klassen	55
4.3.3 Anzahl an Überfahrten	57

4.3.4	Relevanz der Merkmale	57
4.4	Diskussion	61
5	Haltelinienpositionen an Straßenkreuzungen mit Lichtsignalanlage	65
5.1	Schätzung der Haltelinienposition durch die Dichte von Haltepunkten	66
5.2	Schätzung der Haltelinienposition durch eine mikroskopische Verkehrssimulation	69
5.3	Evaluation	73
5.3.1	Genauigkeit der Haltelinien-schätzung durch das Maximum der Dichte der Haltepositionen	75
5.3.2	Genauigkeit der Haltelinien-schätzung durch das Minimum des Gradienten der Dichte der Haltepositionen in Fahrtrichtung	75
5.3.3	Genauigkeit der Haltelinien-schätzung durch eine mikroskopische Verkehrssimulation	77
5.3.4	Vergleich der entwickelten Methoden zur Schätzung der Haltelinienposition	79
5.4	Diskussion	81
6	Lichtsignalgruppen an Kreuzungseinfahrten	85
6.1	Parameter von Lichtsignalanlagen	87
6.2	Zustand von Lichtsignalen aus Fahrzeugbewegungsdaten	91
6.3	Umlaufdauer von Lichtsignalanlagen	95
6.3.1	Bisherige Arbeiten	96
6.3.2	Umlaufdauerschätzung auf Basis der zirkulären Varianz der Grünbeginnzeitpunkte	97
6.3.3	Erweiterte Ansätze zur Umlaufdauerschätzung	100

6.4	Vergleich von Lichtsignalprogrammen zur Bestimmung von Signalgruppen	101
6.5	Programmwechsel von Lichtsignalanlagen	114
6.6	Evaluation	124
6.7	Diskussion	133
7	Längsregelung an Kreuzungen mit Lichtsignalanlage	135
7.1	Anforderungen an das System	135
7.2	Detektion des relevanten Lichtsignals	137
7.3	Prototypische Umsetzung des Systems	147
8	Zusammenfassung und Ausblick	151
8.1	Offene Herausforderungen	154
8.2	Ausblick	158
	Literaturverzeichnis	159

Abkürzungs- und Symbolverzeichnis

Abkürzungen

ACC	Adaptive Cruise Control
AUC	Area Under Curve
DBSCAN	Density-Based Spatial Clustering of Applications with Noise
DGPS	Differential GPS
ELM	Extreme Learning Machine
EMD	Earth Movers Distanz
EM	Expectation Maximization
GIS	Geoinformationssystem
GMM	Gaussian Mixture Model
GPS	Global Positioning System
HMM	Hidden Markov Model
KL	Kullback-Leibler-Divergenz
KS	Kolmogorov-Smirnov Distanz
L1	L1-Distanz
LSA	Lichtsignalanlage
OOB	Out Of Bag
OSM	OpenStreetMap
RiLSA	Richtlinien für Lichtsignalanlagen
ROC	Receiver Operating Characteristic

SLAM	Simultaneous Localization and Mapping
StVO	Straßenverkehrsordnung
SUMO	Simulation of Urban Mobility
SVM	Support Vector Machine
TTC	Time To Collision
UTC	Universal Time Coordinated
VGI	Volunteered Geographic Information
WGS84	World Geodetic System 1984

Notationsvereinbarungen

Skalare	kursiv, klein: 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: $\mathcal{A}, \mathcal{B}, \mathcal{C}, \dots$

Symbole

Im Folgenden sind die wichtigsten Symbole der einzelnen Kapitel dieser Arbeit aufgelistet. Indizierte Symbole werden mit einem exemplarischen Index angeführt.

Operatoren

$\ \mathbf{x}\ _2$	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} .

Kapitelübergreifende Symbole

μ	Mittelwert
σ	Standardabweichung
t	Absolute Zeit
Q_x	x -Quantil, z.B. 0.1-Quantil: $Q_{0.1}$
\mathcal{T}	Menge der Überfahrten für eine Kreuzung als GPS Spuren
ξ_i	Überfahrt aus der Menge \mathcal{T}
\mathcal{A}	Menge an Kreuzungsausfahrten
\mathcal{E}	Menge an Kreuzungseinfahrten
\mathcal{T}_{ea}	Menge der Überfahrten eines Pfades mit e -ter Einfahrt und a -ter Ausfahrt
$\kappa_j^{(i)}$	Einzelmessung aus einer Überfahrt ξ_i
N_i	Anzahl an Einzelmessungen einer Überfahrt ξ_i
$\mathbf{x}_j^{(i)}$	Zweidimensionale Position von einer Einzelmessung
$v_j^{(i)}$	Geschwindigkeit in Fahrtrichtung von einer Einzelmessung
$a_j^{(i)}$	Beschleunigung in Fahrtrichtung von einer Einzelmessung
$\varphi_j^{(i)}$	Orientierung des Fahrzeugs gegen Osten von einer Einzelmessung
$t_j^{(i)}$	Absolute UTC-Zeit einer Einzelmessung
ρ_{ea}	Mittlerer Kreuzungspfad mit e -ter Einfahrt und a -ter Ausfahrt
s	Eindimensionale Positionskoordinate entlang eines mittleren Kreuzungspfades
s_{Stopp}	Eindimensionale Positionskoordinate bei einem Haltevorgang

$\mathcal{I}_{\text{Stopp}}^{(i)}$	Menge der Indizes der Datenpunkte einer Überfahrt ξ_i in einem Haltevorgang
$S^{(i)}$	Menge der Haltevorgänge einer Überfahrt ξ_i
s_H	Haltelinienposition

Repräsentation einer Straßenkreuzung

N_E	Anzahl an Kreuzungseinfahrten
N_A	Anzahl an Kreuzungsausfahrten
p_e	e -te Einfahrt
p_a	a -te Ausfahrt
$f(\varphi)$	Wahrscheinlichkeitsdichte der Fahrtrichtung
B	Bandbreite des Kerndichteschätzers für die Ein- und Ausfahrtrichtung
$\mathbf{e}^{(i)}$	Merkmalsvektor einer Überfahrt zur Bestimmung der Kreuzungseinfahrten \mathcal{E}
\mathcal{T}_e	Menge der Überfahrten der e -ten Einfahrt
\mathcal{T}_a	Menge der Überfahrten der a -ten Ausfahrt
N_{ea}	Anzahl an Punkten eines Pfades ρ_{ea}
\mathbf{x}_{Pl}	Punkt eines mittleren Kreuzungspfades
\mathcal{X}_{ea}	Menge der Positionswerte sämtlicher Überfahrten eines Pfades ρ_{ea}
$\mathbf{c}_j^{(n)}$	Zentrum j bei der n -ten Anwendung der Mean-Shift Gruppierung auf der Menge von Positionswerten \mathcal{X}_{ea}
$\bar{\mathbf{x}}(\mathbf{c}_j^{(n)})$	Mittelwert der Positionen um das Zentrum $\mathbf{c}_j^{(n)}$
$\mathbf{c}_{\max}^{(n)}$	Konvergiertes Zentrum bei der n -ten Anwendung der Mean-Shift Gruppierung auf der Menge von Positionswerten \mathcal{X}_{ea}

λ	Distanzparameter des flachen Kerns bei der Mean-Shift Gruppierung
$\mathbf{o}^{(n)}$	Orientierungsvektor ermittelt aus zwei Zentren aus der Mean-Shift Gruppierung
\mathcal{P}	Menge der Pfade

Vorfahrtsregelklassifikation

$\mathcal{U}_j^{(i)}$	Menge an Umfeldobjekten einer Einzelmessung $\kappa_j^{(i)}$ der Überfahrt ξ_i
v	Ein Umfeldobjekt $v \in \mathcal{U}_j^{(i)}$
\mathbf{x}_{rel}	Relative Position eines Umfeldobjektes
v_{rel}	Relative Geschwindigkeit eines Umfeldobjektes
Δt_{Stopp}	Dauer eines Haltevorgangs
v_{min}	Minimale Überfahrtsgeschwindigkeit
N_{Vfz}	Anzahl an Vorderfahrzeugen bei einem Haltevorgang
a_{Start}	Lokales Maximum der Beschleunigung nach einem Haltevorgang
p_{Stopp}	Verhältnis der Anzahl an Überfahrten mit Haltevorgängen zur gesamten Anzahl an Überfahrten (Relative Anzahl an Haltevorgängen)
δ_{ea}	Differenz zwischen der Ein- und Ausfahrtrichtung (Fahrtrichtung)
$\hat{k}^{(i)}$	Erster Index des längsten Haltevorgangs einer Überfahrt ξ_i
$\hat{l}^{(i)}$	Letzter Index des längsten Haltevorgangs einer Überfahrt ξ_i
m_i	Beliebiger Merkmalswert
\hat{m}_i	Standardisierter Merkmalswert
\mathbf{f}_{VF}	Merkmalsvektor für die Vorfahrtsregelklassifikation

N_{Pfade}	Anzahl verfügbarer Kreuzungspfade mit mindestens 30 Überfahrten
N_{Tree}	Anzahl an Bäumen einer Random Forest Klassifikation
N_{minInst}	Minimale Instanzen im Blattknoten einer Random Forest Klassifikation
N_{Var}	Anzahl der Variablen pro Baum n_{Var} einer Random Forest Klassifikation
$N_{\text{Neur}}^{\text{NN}}$	Anzahl an Neuronen eines Neuronalen Netzes
γ	Parameter des Gauß-Kerns einer SVM
C	Gewicht des Trainingsfehlers einer SVM
$N_{\text{Neur}}^{\text{ELM}}$	Anzahl der Neuronen einer ELM
α	Signifikanzniveau bei Anwendung des Welch-Tests
\mathcal{D}	Menge an Trainingsdaten
β_j	Ein Trainingsbeispiel aus der Menge \mathcal{D} an Trainingsdaten

Haltelinienposition

$\mathcal{SP}^{(i)}$	Menge der Haltepositionen einer Überfahrt ξ_i
\mathcal{SP}	Menge der Haltepositionen sämtlicher Überfahrten eines Kreuzungspfades
$f_{ea}(s_{\text{Stopp}})$	Dichte der eindimensionalen Halteposition s_{Stopp} entlang des Pfades von der Einfahrt e zur Ausfahrt a
q	Verkehrsfluss
σ_s	Standardabweichung des künstlichen weißen Rauschens auf den simulierten Positionsdaten
$\theta^{(k)}$	Parameter des k -ten Simulationsdurchlaufs
ς	Diskrete Haltelinienposition

$P(\zeta)$	Diskretisierte Wahrscheinlichkeitsdichteverteilung der Haltepositionen
N_{SP}	Anzahl an Haltepositionen

Lichtsignalgruppen

T	Umlaufdauer einer Lichtsignalanlage
τ	Relative Zeit innerhalb eines Umlaufs
\mathcal{G}	Menge der Beobachtungen eines grünen Signalzustandes einer Lichtsignalanlage
N	Anzahl an Beobachtungen eines grünen Signalzustandes
$t_j^{(i)}$	Absoluter Zeitpunkt einer Grünbeobachtung
$t_{\text{H}}^{(i)}$	Absoluter Zeitpunkt der Überquerung der Haltelinie für die Überfahrt ξ_i
$\mathcal{T}_{ea}^{\text{oS}}$	Menge an Kreuzungsüberfahrten ohne Stopp (oS)
$\mathcal{T}_{ea}^{\text{mS}}$	Menge an Kreuzungsüberfahrten mit Stopp (mS)
$d_{\text{H}}^{(i)}$	Distanz zur Haltelinie beim letzten Stopp einer Überfahrt ξ_i
$t_{\text{Start}}^{(i)}$	Absoluter Zeitpunkt der Wiederanfahrt nach dem letzten Stopp der Überfahrt ξ_i
$\Delta t_i^{(i)}$	Zeitraum vom Umschaltvorgang eines Lichtsignals von Rot auf Grün bis zur Wiederanfahrt
T_{R_1}	Reaktionszeit erster Fahrer vor einem Lichtsignal
T_{R_f}	Reaktionszeit weiterer Fahrer vor einem Lichtsignal
D_{H_1}	Mittlere Distanz des ersten Fahrzeugs von der Haltelinie
L_{H}	Mittlere Länge von Fahrzeugspitze zu Fahrzeugspitze
$t_{\text{G}}^{(i)}$	Geschätzter absoluter Grünbeginnzeitpunkt
$t_{\text{W}}^{(i)}$	Tatsächlicher absoluter Grünbeginnzeitpunkt
$\alpha^{(i)}(T)$	Relativer Grünbeginnzeitpunkt als Winkel

$r^{(i)}(T)$	Richtungsvektor des relativen Grünbeginnzeitpunkts
$\bar{r}(T)$	Mittlerer Richtungsvektor über die relativen Grünbeginnzeitpunkte aller Überfahrten
$S(T)$	Zirkuläre Varianz der Grünbeginnzeitpunkte
T_{res}	Geschätzte Umlaufdauer
R_j	Fahrtrichtung bzw. Abbiegerichtung
$z_{j,\tau}$	Anzahl an Überfahrten mit Grünbeobachtung für eine Fahrtrichtung
N_j	Gesamtanzahl an Überfahrten für die Fahrtrichtung R_j
\mathbf{z}_τ	Beobachtungsvektor der Anzahl an Überfahrten mit Grünbeobachtung für zwei Fahrtrichtungen
$\theta_{j,\tau}$	Wahrscheinlichkeit einer Grünbeobachtung für die Fahrtrichtung R_j zur Umlaufsekunde τ
H_{null}	Nullhypothese: Synchrone Signalgebung für zwei Fahrtrichtungen
H_{alt}	Alternative Hypothese: Keine synchrone Signalgebung für zwei Fahrtrichtungen
p	Initiales Wissen positiver Beobachtungen bzw. Anzahl an Überfahrten mit Grünbeobachtung
q	Initiales Wissen negativer Beobachtungen bzw. Anzahl an Überfahrten ohne Grünbeobachtung
BF	Bayesfaktor
$g(\tau)$	Geglättetes Ergebnis des Modellvergleichs nach Bayes über einen Umlauf
d	Abstandsmaß ermittelt über den probabilistischen Vergleich der Verteilungen nach Bayes
t_m	Geschätzter absoluter Grünzeitpunkt

M	Anzahl aller absoluten Grünzeitpunkte für alle Überfahrten einer Fahrtrichtung
ρ_{mn}	Geschätzter relativer Grünzeitpunkt für die Umlaufdauer T_n
N_T	Anzahl unterschiedlicher Umlaufdauern
N_{EM}	Anzahl an Iterationen des EM-Algorithmus
k	Aktuelle Iteration des EM-Algorithmus
δ_{xy}	Kronecker-Delta
T_n	Eine Umlaufdauer aus der Menge an unterschiedlichen Umlaufdauern einer Kreuzung
T_m	Zugeordnete Umlaufdauer für eine Grünbeobachtung m nach N_{EM} Iterationen des EM-Algorithmus
A	Transitionsmatrix der Wahrscheinlichkeiten für einen Wechsel der Umlaufdauer
a_{nm*}	Element der Transitionsmatrix bzw. Wahrscheinlichkeit für einen Wechsel der Umlaufdauer T_n nach T_{n*}

1 Einführung

Die Umgebung eines Fahrzeugs im Straßenverkehr beeinflusst das Verhalten eines menschlichen Fahrers sowie das erwartete Verhalten weiterer Verkehrsteilnehmer maßgeblich. Hochautomatisierte Fahrzeuge sollten so agieren, dass das Verhalten dem eines menschlichen Fahrers möglichst nahe kommt. Dazu gehört eine hinreichend vollständige und genaue Erkennung sowie Interpretation der Fahrzeugumgebung. Hierfür verwenden aktuelle Fahrerassistenzsysteme lokale Erfassungssysteme wie Radar-, Kamera-, Ultraschall- und künftig auch Lasersensoren. Die Wahrnehmungsbereichweite dieser Systeme ist allerdings beschränkt und zusätzlich stellt die Interpretation der Daten bei komplexen, unstrukturierten Szenarien wie im innerstädtischen Bereich eine große Herausforderung dar. Die erhöhte Komplexität ergibt sich durch die Kombination der möglichen Aktionen anderer Verkehrsteilnehmer, wie Fußgänger und Radfahrer, mit den übrigen Randbedingungen, wie teilweise schlecht sichtbaren oder nicht vorhandenen Fahrstreifenmarkierungen, Querverkehr und Lichtsignalanlagen. Zur Erfassung und Interpretation der möglichen Szenarien ist eine Weiterentwicklung der aktuellen Sensorik und der darauf aufbauenden Situationsinterpretation von Assistenzsystemen nötig.

Zur Erhöhung der Wahrnehmungsbereichweite wurden erste kartenbasierte Assistenzsysteme, wie der Vorausschauassistent, entwickelt, welcher den in [1] vorgestellten elektronischen Horizont verwendet. Der Vorausschauassistent verwendet Karteninformationen wie Geschwindigkeitsbegrenzungen und Steigungsprofile. Mit diesen Informationen werden Hinweise an den Fahrer für eine vorausschauende Fahrweise generiert, die eine Reduzierung des Kraftstoffverbrauchs bewirken. Die erforderlichen Karteninformationen für den Vorausschauassistent

sind bereits in aktuell verfügbaren digitalen Karten vorhanden, da sie zusätzlich auch für die Navigation als Eingangsgrößen verwendet werden. Eine Vielzahl weiterer relevanter Umgebungseigenschaften fehlt in aktuellen Karten. Ein Beispiel hierfür sind Informationen über Kreuzungen, welche die Umsetzung und Erweiterung urbaner Fahrerassistenz und hochautomatisierter Fahrfunktionen ermöglichen.

Neben dem Vorausschauassistent, der auf statischen Informationen in einer digitalen Karte basiert, wird aktuell an neuartigen Systemen zur Erkennung von dynamischen Gefahrenstellen anhand von Verkehrs- und Fahrzeugdaten über das Internet geforscht. Ein Beispiel hierfür sind harte Stauenden [2]. Aktuelle Fernbereichsradare erlauben eine Erfassung von Fahrzeugen bis zu einer maximalen Distanz von 250 m [3]. Im Falle eines nahenden Stauendes erfordert eine komfortable Bremsung mit einer Verzögerung von durchschnittlich 2 m/s^2 [4] aus 130 km/h die Einleitung des Verzögerungsvorganges in etwa 326 m Entfernung. Zur Steigerung des Komforts und damit zur Vermeidung harter Bremsungen bei hochautomatisierter Fahrt gibt es erste Ansätze, die Wahrnehmungsreichweite des Fahrzeugs durch eine Anbindung an ein Backendsystem zu erweitern [2]. Unter einem Backendsystem wird ein Client-Server-System verstanden, wobei der Server einem zentralen Rechensystem entspricht und die Menge an Clients in diesem Kontext einer Fahrzeugflotte entsprechen, die mit dem Backend verbunden sind. Das Backend erhält unter anderem Daten von Verkehrsleitsystemen sowie anonymisierte Daten angebundener Fahrzeuge. Daraus werden Informationen extrahiert, fusioniert und den Fahrzeugen wiederum zur Verfügung gestellt. Zusätzlich zu harten Stauenden existiert eine Reihe weiterer lokaler Gefahren, wie Glätte, Unfall, Wildwechsel, Personen auf der Fahrbahn oder Falschfahrer, zu denen Informationen vorab bereitgestellt werden können [5, 6, 7, 8]. Damit werden Warnsysteme mit hoher Vorausschau für den Fahrer bzw. für ein automatisiert fahrendes Fahrzeug ermöglicht.

Grundlage derartiger Systeme sind Daten mit Positionsreferenz. Diese Informationen werden auch als georeferenzierte Daten bezeichnet. Ein rechnergestütztes System, das derartige raumbezogene Daten erfasst, verwaltet, analysiert

und präsentiert, wird Geoinformationssystem (GIS) genannt [9]. Die dargelegten Beispiele des harten Stauendes und lokaler Gefahren zeigen, dass Fahrerassistenzsysteme durch eine Anbindung von Fahrzeugflotten an Backendsysteme von einer erweiterten Wahrnehmungsreichweite profitieren.

Im Rahmen dieser Arbeit wird die Methodik der Extraktion von Informationen aus Flottendaten mit Positions- und Zeitreferenz angewendet, um statische Eigenschaften von Straßenkreuzungen automatisiert zu ermitteln. Die Informationen unterstützen bestehende und künftige Fahrerassistenzsysteme bei der Interpretation lokaler Sensordaten in komplexen unstrukturierten Kreuzungsszenarien. Im Speziellen richtet die vorliegende Arbeit ihren Fokus auf die Kreuzungseigenschaften

- Topologie und Geometrie einer Straßenkreuzung,
- Vorfahrtsregel,
- Haltelinienposition
- und Gruppen von Fahrrichtungen mit Lichtsignalanlage und synchroner Signalgebung (Signalgruppen).

Die Informationen über Signalgruppen beinhalten z.B. das Wissen über separate Linksabbiegesignale, bzw. synchrone Geradeaus- und Rechtsabbiegepfade an Kreuzungen. Basierend auf diesen Informationen wird im Rahmen der Arbeit ein Konzept zur Verbesserung der kamerabasierten Detektion des relevanten Lichtsignals erarbeitet. Zusammen mit den weiteren Eigenschaften Kreuzungstopologie und -geometrie, Vorfahrtsregel und Haltelinienposition ermöglicht das Konzept die prototypische Umsetzung eines Fahrerassistenzsystems zur automatisierten Längsregelung an Kreuzungen mit Lichtsignalanlage.

1.1 Kreuzungsinformationen für Fahrerassistenzsysteme

Derzeit verfügbare digitale Karten enthalten nur wenige Informationen über Kreuzungen. Dabei gibt es mehrere bestehende und zukünftige Assistenzsysteme, die von Kreuzungsinformationen in digitalen Karten profitieren. Im Folgenden werden Möglichkeiten der Funktionserweiterung für einige dieser Systeme aufgezeigt.

Motor-Start-Stopp System

Ziel des in Neufahrzeugen größtenteils serienmäßig verbauten Motor-Start-Stopp Systems ist es, den Verbrauch durch automatisiertes Abstellen des Motors zu senken. Voraussetzung für die Effizienz des Systems ist eine Mindeststandzeit von einigen Sekunden. Die derzeit auf dem Markt erhältlichen Systeme führen jedoch keine Schätzung der erwarteten Standzeit durch. Der Motor wird sofort bei jedem Stillstand abgestellt, falls damit zusammenhängende Vorbedingungen von fahrzeuginternen Zuständen erfüllt sind, wie z.B. ein ausreichender Batterieladestatus. Dieses Verhalten führt teilweise zu ineffizienten Stopp-Start Zyklen, vor allem an innerstädtischen Kreuzungen mit Stoppschildern und daher mit häufig auftretenden kurzen Anhaltevorgängen.

Eine Möglichkeit, die Effizienz der Systeme zu erhöhen, ist das Einbeziehen von Kontextwissen durch Informationen über Kreuzungen in digitalen Karten, wie z.B. Vorfahrtsregeln [10]. Die Dauer eines Stillstandes ist an einer Kreuzung mit Lichtsignalanlage durchschnittlich höher als bei Kreuzungseinfahrten mit einem Stoppschild. Zudem existiert bei Kreuzungen mit einer Lichtsignalanlage eine Abhängigkeit zwischen der Standzeit und der Position in Bezug auf die Haltelinie. Anhaltevorgänge nach dem Überqueren der Haltelinie im inneren Bereich der Kreuzung, häufig bedingt durch Gegenverkehr beim Linksabbiegen, sind größtenteils von kürzerer Dauer als Anhaltevorgänge vor der Haltelinie bedingt durch ein rotes Lichtsignal. Die Verwendung von Kreuzungsinforma-

tionen, wie die Vorfahrtsregeln und Haltelinienpositionen, in Motor-Start-Stopp Systemen ermöglichen eine Steigerung der Effizienz und damit eine Verringerung von Kraftstoffverbrauch und CO₂-Ausstoß.

Automatisierte Längsregelung in urbanen Gebieten

Bereits seit 1999 wird die radarbasierte Abstandsregelautomatik Adaptive Cruise Control (ACC) [11, 12] in Fahrzeugen als Sonderausstattung angeboten, welche den Tempomaten situationsabhängig um die Regelung des Abstandes zu einem vorausfahrenden Fahrzeug erweitert. Zusätzlich enthalten aktuelle Systeme eine automatisierte Wiederanfahrtsfunktion innerhalb von drei Sekunden nach einem Stopp, um die Automatisierung und damit den Komfort im Stop-and-Go-Verkehr zu erhöhen [13, 14]. Trotzdem sind besonders in urbanen Gebieten und auf gut ausgebauten Überlandstraßen oder Stadtmagistralen mit Lichtsignalanlagen die Grenzen des Systems bemerkbar. Eine Reaktion auf rote Lichtsignale wird aktuell beispielsweise nicht angeboten.

Dazu werden Assistenzsysteme erforscht, die den Fahrer bei einer drohenden Verletzung der Vorfahrt warnen [15, 16, 17]. Eine zusätzliche Erhöhung des Kundenmehrwerts ist die Erweiterung der bestehenden ACC Komfort-Funktion um die automatisierte Verzögerung an roten Lichtsignalen. Dazu ist eine zuverlässige Erkennung des relevanten Lichtsignals durch die lokale Fahrzeugsensorik erforderlich. Die Aufgabe, das relevante Signal bei Mehrdeutigkeiten wie separaten Linksabbiegesignalen zu erkennen, ist insbesondere bei größeren Distanzen eine Herausforderung. In Deutschland sind Lichtsignalanlagen bis zu einer maximalen Geschwindigkeit von 70km/h erlaubt. Bei einer komfortablen mittleren Verzögerung von 2m/s^2 [4] ist mit der erlaubten maximalen Geschwindigkeit ein Bremsweg von 95m erforderlich. Karteninformationen über Lichtsignalanlagen unterstützen die Zuordnung der durch das Fahrzeug erkannten Lichtsignale zu den durch sie geregelten Fahrtrichtungen. Dazu wird in Kapitel 7 ein Konzept vorgestellt, welches die Informationen über Gruppen von Fahrtrichtungen mit synchroner Signalgebung aus digitalen Karten und der ka-

merabasierten Erkennung von Lichtsignalen fusioniert, um das relevante Signal aus großen Distanzen zu erfassen.

Zusätzlich zur Detektion des relevanten Lichtsignals muss die Haltelinienposition als Bremsziel schon zu Beginn der Verzögerung bekannt sein, um komfortabel abbremsen zu können. Eine Möglichkeit ist eine kamerabasierte Detektion der Linie, welche in mehreren vorangegangenen Arbeiten vorgestellt wurde [18, 19, 20]. Ein zuverlässiges Ergebnis aus einer kamerabasierten Erkennung der Haltelinie ist mit aktuellen Systemen allerdings erst bei einer Entfernung von ca. 20m zu erwarten [18]. Zusätzlich ist eine durchgezogene Linienmarkierung nicht immer vorhanden. Gemäß der in Deutschland gültigen Straßenverkehrsordnung (StVO) können Linien durch gleichmäßig dichte Markierungsknopffreien ersetzt werden (§39 Abs. 5 StVO), was beispielsweise bei Straßen mit Kopfsteinpflaster häufig der Fall ist. In verkehrsberuhigten Bereichen ist es zudem möglich, dass Haltelinien mit anderen Mitteln, wie z.B. Pflasterlinien, gekennzeichnet werden. Die konkrete Ausführung ist nicht genormt, was die Realisierung einer hoch verfügbaren kamerabasierten Detektion von Haltelinien erschwert. Aufgrund der Perspektive ist es auch für den Menschen schwierig, Haltelinien in größeren Entfernungen zu erkennen. Der Mensch ist jedoch in der Lage, den Kontext an einer Kreuzung zu erfassen und damit unter anderem die Entfernung zum Mittelpunkt abzuschätzen. Des Weiteren erfasst der Mensch, auf welcher Seite der Kreuzung die Lichtsignale installiert sind, eine Information, die vor allem in den USA relevant ist. Basierend auf diesem Wissen leitet ein menschlicher Fahrer frühzeitig ein Bremsmanöver ein. Erst auf den letzten Metern vor einer Haltelinie wird eine exakte Verzögerung bis zum Stillstand ausgeführt.

Haltelinienpositionen in digitalen Karten liefern die nötigen Informationen für die automatisierte Längsregelung in urbanen Gebieten. Anhand der geschätzten absoluten Position des Fahrzeugs sowie der Haltelinienposition der digitalen Karte ist es möglich, die Distanz zu Haltelinien bereits während der Annäherung zu schätzen. Unter der Berücksichtigung von Toleranzen wird damit eine frühzeitige Verzögerung eingeleitet. Eine zusätzliche kamerabasierte Detektion

der Haltelinie unterstützt eine exakte Zielbremsung auf den letzten Metern. Im Rahmen dieser Arbeit wird in Kapitel 7 dieses Konzept für die automatisierte Längsregelung in urbanen Gebieten entwickelt und prototypisch umgesetzt. Damit wird die automatisierte Längsregelung auf Vorderfahrzeuge um Kreuzungen mit einer Lichtsignalanlage erweitert.

Hochautomatisiertes Fahren in urbanen Gebieten

Das hochautomatisierte Fahren in urbanen Gebieten ist für die Umgebungserfassung eine besondere Herausforderung. Frühe Arbeiten [21] basieren zur Erfassung des Fahrzeugumfelds ausschließlich auf lokaler Sensorik, wie z.B. Kamerasysteme. In aktuellen Forschungsarbeiten [22, 23, 24, 25, 26] wird die lokale Sensorik ergänzt mit Informationen aus digitalen Karten. Die Karten bilden die Grundlage für Lokalisierung, Intentionserkennung weiterer Verkehrsteilnehmer, Navigation und Manöverplanung. Zur Lokalisierung werden Straßenkarten mit Landmarken angereichert. Anhand der Detektion dieser Landmarken durch Sensorik im Fahrzeug wird die relative Position des Fahrzeugs zu den Landmarken geschätzt und damit die Position in der digitalen Karte bestimmt [27, 28, 29]. Grundlage für die Navigation und Manöverplanung in [26] ist ein digitales Modell der Straße unter anderem mit Fahrstreifentopologie und -geometrie, Vorfahrtsregeln an Kreuzungen, Fußgängerüberwegen und Haltelinien. Derartige Karten enthalten mehr Informationen als aktuell verfügbare Navigationskarten und werden daher im Rahmen der zitierten Arbeiten durch Messfahrten und manuelle Korrekturen semiautomatisiert für definierte Strecken erstellt. Dieses Vorgehen zum Erstellen digitaler Karten ist sehr aufwändig, vor allem im Hinblick auf die nötige Aktualität der Inhalte.

Durch eine automatisierte Erstellung werden Änderungen der Kartenattribute im Gegensatz zur manuellen bzw. semiautomatisierten Erstellung, schneller erkannt und in die Karte eingetragen. Trotzdem ist es nicht möglich, fehlerfreie Karten zu garantieren. Die Erkennung von Abweichungen der Karte zur Realität muss in jedem Fall durch die lokale Fahrzeugsensorik gewährleistet sein und die Ein-

leitung eines sicheren Manövers zur Folge haben. In diesen Fällen reagiert das hochautomatisierte Fahrzeug jedoch möglicherweise unkomfortabel. Korrekte und aktuelle digitale Karten erhöhen daher den Komfort bei hochautomatisierten Fahrten in urbanen Gebieten. Damit unterstützt die automatisierte Erstellung von Karteninformationen die Entwicklung des hochautomatisierten Fahrens in urbanen Gebieten.

1.2 Stand der Technik zur Kartenerstellung

Nach dem aktuellen Stand der Technik zur Generierung von digitalen Karten werden die Attribute durch Messfahrten kartiert und aktualisiert. Der Aufwand für die manuelle Vermessung durch speziell ausgerüstete Fahrzeuge ist sehr hoch. Aufgrund der breiten Verwendung von digitalen Navigationskarten wird der Aufwand jedoch über die Vielzahl der Anwender finanziert. Aktualisierte Karten erscheinen zum derzeitigen Stand bis zu vierteljährlich. Die Entwicklung automatisierter Updates von Karten und Software im Fahrzeug über das Internet [30, 31, 32] trägt dazu bei, dass Aktualisierungen häufiger durchgeführt werden. Änderungen, die durch Messfahrzeuge erfasst werden, sind in die Karte einzuarbeiten und semiautomatisiert zu überprüfen, was die Auslieferung von aktuellen Kartenattributen verzögert. Zudem wird nicht bei jeder Aktualisierung das komplette Kartenmaterial erneuert. Aus diesen Gründen ist es möglich, dass bauliche Änderungen erst mit einiger Verzögerung in die Karten aufgenommen werden.

Erstellung digitaler Karten durch die Anwender

Um die Zeit für die Aufnahme von baulichen Änderungen in digitalen Karten zu verkürzen, wird die Verwendung von Crowdsourcing zum Sammeln geographischer Informationen in unterschiedlichen Projekten untersucht. Das übergreifende Ziel der Ansätze ist es, die Nutzer selbst in die Erstellung und Verbesserung digitaler Karten einzubeziehen. Dazu werden Daten gesammelt und den Karten-

lieferanten zur Verfügung gestellt. Der Begriff „Volunteered Geographic Information“ (VGI) [33, 34] hat sich für dieses Vorgehen etabliert. Der Unterschied zum bisherigen Ansatz der manuellen Kartengenerierung durch professionelle Organisationen besteht hauptsächlich darin, dass die Nutzer Karteninformationen erstellen, ohne dafür speziell geschult zu sein und häufig ohne finanzielle Gegenleistung [35]. Die daraus entstehenden Karten sind kostengünstig, jedoch variieren die Zuverlässigkeit und Vollständigkeit der Informationen in Abhängigkeit von der kartierten Region. Der Grund hierfür liegt zum einen darin, dass die verwendeten kostengünstigen Global Positioning System (GPS) Geräte eine niedrige Genauigkeit in innerstädtischen Gebieten, Wäldern oder Gebirgen aufweisen. Des Weiteren variiert die Aktivität der freiwilligen Kartenersteller ortsabhängig.

Ein Beispiel für die Erstellung einer digitalen Karte durch Freiwillige ist das internationale Projekt OpenStreetMap (OSM) [36], welches das Ziel verfolgt, eine freie Weltkarte zu erstellen. Im Rahmen des Projekts werden unter anderem Daten über Straßen, Eisenbahnen, Flüsse, Wälder und Häuser gesammelt. Die Teilnehmer erfassen Straßen und Wege über eigene GPS-Geräte oder zeichnen Gebäude in Luftbildern nach. Im Rahmen des Projekts wird aus den Daten eine Karte erstellt und über das Internet sowie für weitere Anwendungen frei zur Verfügung gestellt. Durch den Crowdsourcing-Ansatz wird eine Steigerung der Aktualität der Karte im Vergleich zu kommerziell erhältlichen, manuell erstellten Karten erzielt. Ein Nachteil von OSM ist die bereits erläuterte variierende ortsabhängige Qualität der Karte, die zudem durch einzelne Nutzer beeinflusst werden kann. Dadurch sind die Informationen nur bedingt zuverlässig.

Ein weiterer Ansatz, Karten durch die Nutzer zu verbessern, wird vom Kartenlieferanten TomTom mit der „Map Share“ [37] Plattform verfolgt. Über diese Austauschplattform haben Anwender die Möglichkeit, Änderungen selbst in ihre Karte einzutragen und diese mit weiteren Nutzern zu teilen. Über die Plattform sind täglich Aktualisierungen verfügbar. Folgende manuelle Anpassungen der Karte sind möglich:

- Geänderte Geschwindigkeitsbegrenzungen,
- neue Straßennamen,
- blockierte Straßen,
- neue Verkehrsrichtungen
- und geänderte Abbiegebeschränkungen.

Änderungen werden erst verfügbar, nachdem diese durch TomTom Mitarbeiter manuell geprüft wurden. Allerdings wird dabei ausschließlich die Plausibilität sichergestellt. Es erfolgt keine Verifikation, da die tatsächliche Grundwahrheit der Information nicht vorliegt. Durch mehrere konsistente Meldungen derselben Information steigt jedoch die Wahrscheinlichkeit für ihre Korrektheit.

Neben TomTom „Map Share“ und OSM hat sich Waze als weitere Community-basierende Verkehrs- und Navigations-App [38] etabliert. Über die Waze-App werden zum einen passiv Verkehrs- und Straßendaten der Nutzer gesammelt, um unter anderem Informationen über den Verkehrsfluss zu ermitteln. Darüber hinaus melden die Anwender aktiv Informationen über Unfälle und weitere Gefahren. Zusätzlich haben sie die Möglichkeit, die digitale Kartenbasis selbst zu aktualisieren. Waze ist auf die Gemeinschaft der Nutzer fokussiert. So ist es möglich, sich mit Freunden über Facebook zu verbinden und deren aktuellen Standort bei einer Fahrt zum gleichen Ziel auf der Karte zu verfolgen.

Erstellung von Straßenmodellen aus Positionsdaten

Zusätzlich zur manuellen Erfassung und Kartierung durch Nutzer wurde die Idee, Straßenmodelle aus einer Vielzahl aufgezeichneter GPS-Trajektorien zu erstellen, ebenfalls in vorangehenden Arbeiten aufgegriffen [39, 40, 41, 42, 43]. Dabei werden Positionsdaten von mehreren Messfahrzeugen mit hochgenauen differentiellen GPS-Systemen (DGPS) aufgezeichnet, um daraus fahrstreifengenaue Modelle der Fahrbahn zu erstellen. Die fahrstreifengenaue Repräsentation von Kreuzungen wird in [40] behandelt. Dazu wird der Bereich einer Kreuzung

über eine verfügbare digitale Karte, wie zum Beispiel OSM, bestimmt. Für die einzelnen Segmente im Kreuzungsbereich werden mittlere Pfade mit B-Splines interpoliert. Die Anzahl der Fahrstreifen für einzelne eingehende und ausgehende Segmente wird über das Gruppierungsverfahren K-means ermittelt. Zur Bestimmung der Anzahl der Gruppen bzw. Fahrstreifen wird das Verfahren mehrfach mit unterschiedlichen Gruppenzahlen angewendet und die korrekte Anzahl über eine Metrik ermittelt. Die einzelnen Fahrstreifen werden äquivalent zu den mittleren Pfaden der Segmente mit B-Splines interpoliert. Der Nachteil der Methode ist die Anforderung an die Genauigkeit der verwendeten Positionswerte. Für die Entwicklung und Evaluierung in [40] wird ein hochgenaues GPS-System verwendet, welches hohe Kosten verursacht.

In [42] wird ein Framework zur Erstellung digitaler Karten von Autobahnen vorgestellt, welches mehrere Überfahrten mit hochgenauem GPS-System und Umgebungssensorik verwendet. Das Verfahren verfolgt einen iterativen Graphenbasierten „Simultaneous Localization and Mapping“ (SLAM) Ansatz. Damit werden von der Umgebungssensorik erkannte Landmarken zwischen den Fahrten assoziiert und die Positionierung des Fahrzeugs gleichzeitig verbessert.

In den Arbeiten [44, 45, 46, 47, 48, 49, 50, 51, 52, 53] werden Positionsdaten aus handelsüblichen GPS-Empfängern verwendet um ein Straßennetzwerk zu extrahieren, bzw. bestehende digitale Karten zu erweitern. Die meisten Arbeiten erzeugen dazu mittlere Pfade für Fahrbahnen und Richtungsfahrbahnen. Zusätzlich werden in [47, 48, 49] Attribute wie die Anzahl an Fahrstreifen und Abbiegebeschränkungen ermittelt. Die in [47] angewendete Methode zur Bestimmung einzelner Fahrstreifen basiert auf der Modellierung physikalischer Anziehungskräfte zwischen einzelnen GPS-Spuren. Die GPS-Spuren ziehen sich abhängig von der Distanz der zugehörigen Positionswerte äquivalent zu einer Potentialekraft an. Zusätzlich werden die GPS-Spuren äquivalent zu einer Federkraft an ihrer ursprünglichen Position zurückgehalten. Durch die Berechnung eines Gleichgewichts dieser entgegengesetzten Kräfte ergibt sich eine Segmentierung der Spuren entsprechend der Fahrstreifen. Eine digitale Karte wird über Gra-

phen repräsentiert, welche durch iteratives Gruppieren einzelner Positionsdaten der Spuren für jeden Fahrstreifen separat generiert werden.

Eine andere Möglichkeit Fahrstreifen zu ermitteln ist das Lernen eines *Gaussian Mixture Models* (GMM) [49]. Für jeden Fahrstreifen werden an unterschiedlichen Positionen die Parameter einer Gaußverteilung für die Positionsdaten lateral zur Fahrtrichtung ermittelt. Die Anzahl der Fahrstreifen wird anhand einer Heuristik bestimmt. Die Heuristik basiert auf dem Vergleich der lateralen Streuung der Positionsdaten mit der erwarteten Streuung innerhalb eines Fahrstreifens. Nachteile sind dabei der starke Einfluss von Ausreißern sowie der fehlende Zusammenhang konsekutiver Positionen entlang der Fahrtrichtung und damit potentiell instabilen Ergebnissen.

In [54] werden ebenfalls Standard GPS-Empfänger und mehrere Überfahrten verwendet um digitale Straßenbeschreibungen für autonome Fahrzeuge automatisiert zu erstellen. Zusätzlich zu den Positionsdaten werden eine Schätzung der Eigenbewegung sowie Fahrstreifenmarkierungen aufgezeichnet. Die Eigenbewegung wird mittels visueller Odometrie über eine Stereokamera ermittelt. Durch die exakte Schätzung der Eigenbewegung wird eine hohe relative Genauigkeit der Straßenbeschreibung erreicht.

In [52] werden aus ungenauen GPS-Positionsdaten die mittleren Pfade für jede Fahrbahn bzw. Richtungsfahrbahn über eine zweidimensionale Kerndichteschätzung ermittelt. Zusätzlich werden die Bereiche komplexer Kreuzungen mit mehreren Knotenpunkten modelliert und die Abbiegepfade separat ermittelt. Für diese Pfade werden jedoch innerhalb einer Kreuzung nur maximal zwei Stützpunkte modelliert, was in einer ungenauen Repräsentation des Kreuzungsinnenraums resultiert.

Neben der Erstellung von digitalen Karten wird in [55] die Methode „MapCorrect“ vorgestellt, um bestehende digitale Karten automatisiert zu korrigieren und zu validieren. Im Rahmen der Arbeit werden Positionsdaten von mobilen Endgeräten gesammelt und einzelne Straßenzüge einer gegebenen digitalen Karte verbessert. Um den Energiebedarf der Endgeräte zu verringern, wird die Posi-

tionsvermessung adaptiv ausschließlich in Gebieten aktiviert, in denen aktuelle Daten benötigt werden.

Klassifikation der Vorfahrtsregel mittels Trajektorien

Im Rahmen dieser Arbeit wird in Kapitel 4 ein Ansatz zur Klassifikation von Vorfahrtsregeln vorgestellt, welcher Trajektorien als Eingangsdaten verwendet. Dazu existieren in der Literatur erste Vorarbeiten. In [56] werden Kreuzungsüberfahrten mit einem DGPS-Signal aufgezeichnet und Überfahrten, die eine Kreuzung geradeaus queren, zur weiteren Auswertung verwendet. Aus den Überfahrten werden statistische Merkmale generiert, wie zum Beispiel der Mittelwert und die Standardabweichung der Anzahl an Haltevorgängen für jede Überfahrt. Anhand dieser Merkmale und einem bekannten Trainingsdatensatz wird ein Neuronales Netz antrainiert. Das Klassifikationsergebnis wird im Anschluss regelbasiert auf Plausibilität bzw. Konflikte zwischen kreuzenden Pfaden geprüft. Dabei wird bei einem Test mit 50 Kreuzungspfaden eine Genauigkeit von 100 % erreicht.

In [57] wird ein regelbasierter Ansatz zur Erkennung von Stoppschildern und Lichtsignalanlagen vorgestellt. Als Datengrundlage dienen die aufgezeichneten Positionsdaten aus dem OSM-Projekt [36] und ein eigens gesammelter Datensatz aus GPS-Spuren. Für die Klassifikation wird auf die Überfahrten eine einfache Heuristik angewendet, die auf Schwellwerten für die relative Anzahl an Stopps und der Dauer der Stopps basiert. Zur Evaluierung werden 61 Kreuzungen in Los Angeles mit bekannter Vorfahrtsregel ausgewählt. 25 dieser Kreuzungen werden durch Stoppschilder geregelt, 36 durch eine Lichtsignalanlage. Der Fokus der Arbeit liegt darauf, eine akzeptable Güte bei einer geringen Anzahl verwendeter Kreuzungsüberfahrten zu erzielen. Die Auswertung ergibt eine Genauigkeit von über 90 % bei Stoppschildern mit fünf Überfahrten und bei Lichtsignalanlagen mit sieben Überfahrten.

Das in [58] vorgestellte System „SmartRoad“ basiert auf gesammelten Positionsdaten von Smartphones und klassifiziert die Vorfahrtsregeln *Stoppschild*,

Lichtsignalanlage und *ungeregelt*. Die Lage von Kreuzungen wird dabei aus OSM extrahiert. Die Klassifikation wird ausschließlich für Kreuzungspfade ohne Abbiegung durchgeführt. Die eingeführte Kreuzungsrepräsentation besteht damit aus einem Mittelpunkt und Kreuzungseinfahrten. Aus den Überfahrten werden die Merkmale

- Haltedauer des letzten Stopps,
- Distanz zum Kreuzungsmittelpunkt am letzten Stopp,
- minimale Überfahrtsgeschwindigkeit,
- Anzahl an Verzögerungen
- und Anzahl an Haltevorgängen

extrahiert. Anhand des Mittelwerts und der Varianz dieser Werte ergeben sich statistische Merkmale für jede Kreuzungseinfahrt. Basierend darauf sowie auf einer manuell erstellten Grundwahrheit für eine Untermenge der vorhandenen Einfahrten, wird ein Random Forest Klassifikator trainiert. Zum Training und zur Evaluierung liegt ein Datensatz von ca. 6500km mit 158 Lichtsignalanlagen, 77 Stoppschildern und 228 unregelmäßigen Kreuzungseinfahrten vor. Unter Verwendung von 40 % der Daten zum Training wird eine Richtig-Positiv-Rate von 96 % bei einer Falsch-Positiv-Rate von 3 % auf dem Testdatensatz erreicht.

1.3 Problemstellung

Zukünftige Assistenzsysteme fordern Informationen aus digitalen Karten zur Erhöhung der Robustheit und Verfügbarkeit. Die aktuell verwendeten Methoden der manuellen Vermessung für die Erstellung digitaler Karten verursachen hohe Latenzzeiten zwischen einer Änderung der Umgebung und der Herausgabe des aktualisierten Kartenmaterials. Der Grund hierfür liegt darin, dass nicht bei jeder Kartenaktualisierung der komplette abgedeckte Bereich neu vermessen wird, sondern jeweils nur Ausschnitte. Außerdem sind manuelle Nacharbeiten nötig.

Insbesondere im Hinblick auf hochautomatisierte Fahrfunktionen müssen Kartenattribute aktuell und hinreichend genau sein. Die Anforderung an die Aktualität der Attribute wird durch die Methode der manuellen Erstellung von Karten größtenteils nicht erfüllt. Deshalb wird an Methoden geforscht, die eine automatisierte Erzeugung und Aktualisierung digitaler Karten anhand von Flottendaten ermöglichen. Der Fokus bisheriger Arbeiten liegt in der Erstellung von Fahrbahnbeschreibungen. Dazu zählen die Schätzung des Straßen- und Fahrstreifenverlaufs, die Ermittlung der Anzahl von Fahrstreifen und die Bestimmung von Abbiegebeschränkungen. Die weitestgehend unerforschte automatisierte Erstellung von Kreuzungsmerkmalen ist das Ziel der vorliegenden Arbeit.

Ein Grund dafür, dass der Fokus bisheriger Arbeiten auf der Erstellung von Fahrbahnbeschreibungen liegt, ist die Tatsache, dass die Navigation aktuell die Hauptanwendung für digitale Karten darstellt. Daher sind nur wenige Informationen, die für Fahrerassistenzsysteme relevant sind, in den Karten enthalten, wie beispielsweise Eigenschaften von Verkehrsknotenpunkten bzw. Kreuzungen. Zur Abbildung dieser Eigenschaften ist ein Modell nötig, welches die Topologie der Kreuzung beschreibt. Für die präzise Verortung von Attributen wie der Position von Haltelinien ist eine exakte Geometrie der Kreuzung gefordert. Neben der Kreuzungsrepräsentation ist die automatisierte Extraktion von Vorfahrtsregeln aus Flottendaten ein weiteres wichtiges Forschungsfeld. Die dazu in [56, 57, 58] vorgestellten Methoden zur Klassifikation von Vorfahrtsregeln beschränken sich auf die Bestimmung für ganze Kreuzungen und lassen separate Abbiegepfade außer Acht. Da Kreuzungen mit unterschiedlichen Vorfahrtsregeln für einzelne Abbiegepfade einer Kreuzungseinfahrt existieren, ist die Klassifikation der bisherigen Methoden in diesen Situationen fehlerbehaftet. Außerdem sind die betrachteten Klassen an Vorfahrtsregeln jeweils beschränkt auf *Stoppschild*, *Lichtsignalanlage* und *ungeregelt*. Die Klassen *Vorfahrt* und *Vorfahrt gewähren* werden ignoriert. Die Daten dieser Kreuzungsklassen müssen durch manuelle Vorfilterung entfernt werden, was eine vollautomatisierte Auswertung verhindert. Zudem ist damit nur eine lückenhafte Beschreibung urbaner Gebiete hinsichtlich der Kreuzungseigenschaften möglich. Im Rahmen

dieser Arbeit werden Methoden zur automatisierten Extraktion der Vorfahrtsregeln *Lichtsignalanlage*, *Vorfahrt*, *Vorfahrt gewähren*, *Stoppschild* und *ungeregelt* eingeführt. Die Regeln werden separat für unterschiedliche Abbiegerichtungen ermittelt.

Hochautomatisierte Fahrfunktionen in urbanen Bereichen benötigen außerdem weitere Informationen über Kreuzungen. Eine große Herausforderung bei der automatisierten Überfahrt von Kreuzungen mit einer Lichtsignalanlage ist die Bestimmung des relevanten Lichtsignals aus großen Distanzen. Es existieren bereits Kamerasysteme mit einer Ersterkennungsdistanz einzelner Signale von 150m [59]. Die Auswahl des relevanten Signals bei Mehrdeutigkeiten, beispielsweise bei separaten Linksabbiegesignalen, bleibt jedoch eine Herausforderung. Bisherige Forschungsarbeiten im Bereich des automatisierten Fahrens im urbanen Bereich verwenden dafür manuell bzw. semiautomatisiert erstellte digitale Karten [26]. Neben dem relevanten Signal ist zudem die Detektion der Haltelinie eine weitere Herausforderung. Aktuelle Systeme detektieren Haltelinien bis zu einer Distanz von etwa 20m. Auch ein menschlicher Fahrer erkennt die Haltelinie nur in unwesentlich größeren Entfernungen. Die Verzögerung bei der Anfahrt an ein rotes Lichtsignal erfolgt durch den Menschen auf Basis weiterer Kontextinformationen des Szenarios. Die verfügbaren Kamerasysteme liefern neben dem Signalzustand ebenfalls eine Schätzung der Distanz zu den Signalen. Für ein automatisiertes Fahrzeug ist es jedoch nicht möglich, daraus bei rotem Lichtsignal eine Verzögerungstrajektorie zu bestimmen, da die Position des Signalgebers beispielsweise in anderen Ländern nicht festgelegt ist. Daher wird in dieser Arbeit die Haltelinienposition als ein weiteres wichtiges Kartenattribut einer Straßenkreuzung ermittelt.

1.4 Struktur der Arbeit

Der weitere Teil der Arbeit gliedert sich wie folgt: Kapitel 2 fasst die übergreifenden methodischen Grundlagen zusammen und beschreibt die Details der verwendeten Flottendaten zur Entwicklung und Evaluierung der Methoden. In

Kapitel 3 wird eine generische Repräsentation für die Topologie und Geometrie von Kreuzungen erarbeitet und Methoden zur automatisierten Erstellung der Repräsentation aus Flottendaten eingeführt. Die vorgestellten Verfahren zur Klassifikation der Vorfahrtsregel in Kapitel 4 basieren auf der erarbeiteten Repräsentation. Dazu werden aus den Daten Merkmale extrahiert und überwachte maschinelle Lernverfahren darauf angewendet. Kapitel 5 führt unterschiedliche Methoden zur Bestimmung der Haltelinienposition an Kreuzungspfaden mit einer Lichtsignalanlage ein. Dazu wird ein neuartiges Verfahren entwickelt, welches auf einer mikroskopischen Verkehrssimulation basiert. Des Weiteren werden in Kapitel 6 Methoden zur Ermittlung von Gruppen von Kreuzungspfaden mit synchroner Signalgebung an Kreuzungen mit einer Lichtsignalanlage vorgestellt. Die Gruppierungsinformation wird in Kapitel 7 verwendet, um eine kamerabasierte Erkennung relevanter Lichtsignale zu unterstützen. Das Verfahren wird in einem prototypischen Fahrerassistenzsystem zur automatisierten Längsregelung an Kreuzungen mit Lichtsignalanlage verwendet. Abschließend fasst Kapitel 8 die Erkenntnisse und Ergebnisse der Arbeit zusammen und gibt einen Ausblick auf weitere mögliche Forschungsarbeiten.

2 Grundlagen

Im folgenden Kapitel werden die erforderlichen Grundlagen für die vorliegende Arbeit erläutert. Dazu zählt die Ermittlung von Kreuzungsmittelpunkten aus einer digitalen Navigationskarte. Die Mittelpunkte einer Kreuzung bilden die Grundlage für die Zuordnung von Fahrzeugbewegungsdaten zu einer Kreuzung und damit zur Erstellung einer Kreuzungsrepräsentation. Zusätzlich werden unterschiedliche Distanzmaße für den Vergleich diskreter Wahrscheinlichkeitsdichten erläutert. Die Distanzmaße werden für die Ermittlung der Haltelinienposition sowie der Signalgruppen verwendet. Zudem werden in diesem Kapitel die für diese Arbeit zu Grunde liegenden Fahrzeugdaten beschrieben.

2.1 Kreuzungsmittelpunkte

Aktuelle Karten, wie die OSM [36], bestehen aus Kanten die durch Knoten verknüpft werden. Durch Kanten werden unter anderem Straßen, Flüsse, Eisenbahnlinien, Gehwege und Gebäudeumrisse modelliert. Höhengleiche Straßenkreuzungen (§1, Bundesfernstraßenkreuzungsverordnung - FStrKrV) und deren Attribute sind nicht explizit repräsentiert. An höhengleichen Kreuzungen kreuzen sich mindestens drei Straßen ohne Unterführung. Damit sind beispielsweise Autobahnkreuze und Kreisverkehre ausgeschlossen. An komplexen Kreuzungen ist es möglich, dass eine Kreuzung durch eine Menge von Knoten beschrieben wird. Im Rahmen dieser Arbeit werden Eigenschaften von höhengleichen Kreuzungen aus Überfahrten, das heißt zeitlich zusammenhängenden Positionsmessungen, und weiteren Daten der Fahrzeugsensoren ermittelt.

Der Mittelpunkt einer Kreuzung ist die Grundlage zur Extraktion von Kreuzungsüberfahrten aus dem vorliegenden Datensatz. Da Straßen mit Richtungsfahrbahnen durch zwei Kanten repräsentiert werden, bestehen größere Kreuzungen aus mehreren Knoten. Der Mittelpunkt wird nicht explizit repräsentiert. Aus diesem Grund wird im Folgenden eine Methode zur Ermittlung der Mittelpunkte aus digitalen Karten vorgestellt. Die Methode umfasst die folgenden Schritte:

1. Filtern der OSM-Karte - nur Straßen sind relevant,
2. Filtern aller Knoten - mindestens drei verknüpfte Kanten ohne Konflikt sind vorhanden,
3. Gruppierung der Knoten mit großem Radius,
4. Plausibilisierung der Gruppen - Auftrennen von Gruppen basierend auf Straßennamen
5. und zweite Gruppierung mit kleinem Radius.

Im ersten Schritt wird die OSM-Karte gefiltert indem ausschließlich Kanten weiter verwendet werden, welche in OSM als *highway*, *primary*, *secondary*, *tertiary*, *unclassified* und *residential* gekennzeichnet sind. Dadurch werden Autobahnen, autobahnähnliche Straßen und Erschließungswege zu Einrichtungen aus der Karte entfernt. Übrig bleiben Bundesstraßen (*highway*), Staats- und Kreisstraßen (*secondary*, *tertiary*), Gemeindestraßen (*unclassified*) und Straßen in Wohngebieten (*residential*). Im Rahmen dieser Arbeit werden Daten im Raum München anhand eines entsprechenden Ausschnitts der OSM ausgewertet. Nach der ersten Filterung der Karte bleiben in diesem Ausschnitt 24214 Knoten.

In einem weiteren Schritt werden diese Knoten dahingehend überprüft, ob mindestens drei Kanten verbunden werden. Zudem muss sich aus den möglichen Fahrrichtungen der Kanten mindestens ein potentieller Konflikt der Fahrrichtungen ergeben, bzw. eine Regelung der Vorfahrt muss nötig sein. Damit werden Knoten entfernt, an denen sich beispielsweise eine Richtungsfahrbahn oder Einbahnstraße aufgabelt, da in diesen Fällen keine Verkehrsströme in Konflikt

geraten können und damit keine Vorfahrtsregel nötig ist. Nach diesem Schritt sind noch 22508 Knoten in dem Kartenausschnitt vorhanden.

Im dritten Schritt werden die Knoten gruppiert. Dazu wird die parametrische Gruppierungsmethode Density-Based Spatial Clustering of Applications with Noise (DBSCAN) [60] angewendet. Der DBSCAN-Algorithmus ist für beliebige dimensionale Datenpunkte wie folgt definiert:

- Ein Punkt p ist ein Kernpunkt, wenn sich mindestens $minPts$ Punkte innerhalb einer Distanz ε des Punktes befinden. Diese Punkte werden als direkt erreichbar bezeichnet.
- Ein Punkt q ist durch p erreichbar, wenn ein Pfad p_1, \dots, p_n existiert mit $p_1 = p$ und $p_n = q$, wobei jeder Punkt p_{i+1} direkt erreichbar von p_i ist. Jeder Punkt des Pfades ist somit ein Kernpunkt, mit Ausnahme von q ,
- Sämtliche weiteren Punkte sind Ausreißer.

Voraussetzung ist ein definiertes Distanzmaß zwischen zwei Datenpunkten. Für die Gruppierung von zweidimensionalen Knoten wird die euklidische Distanz verwendet. Abbildung 2.1 zeigt eine beispielhafte Gruppierung einer Menge von Knoten. Auf den gefilterten Knoten des Ausschnitts aus OSM um München wird eine DBSCAN-Gruppierung mit $\varepsilon = 60\text{m}$ und $minPts = 0$ durchgeführt. Eine empirische Untersuchung der größten Kreuzungen in München ergab, dass die Knoten einer Kreuzung maximal 50m vom Kreuzungsmittelpunkt entfernt sind. Daher wird die Distanz der ersten Gruppierung mit 10m Puffer zu 60m gesetzt. Gruppierete Knoten werden durch ihren Mittelpunkt repräsentiert.

Die entstandenen Gruppen werden im vierten Schritt der Methode plausibilisiert, basierend auf den Straßennamen aller Kanten, die mit einem Knoten der Gruppe verknüpft sind. Knüpfen an die gruppierten Knoten mehr als zwei unterschiedliche Straßennamen an, so wird die Gruppe wieder aufgetrennt. Dies ist der Fall, wenn Kreuzungen weniger als 60m voneinander entfernt sind. Im Anschluss an die Gruppierung und Plausibilisierung existieren 21712 Gruppen von Knoten.




Bild 2.1: Beispiel für eine Gruppierung von zweidimensionalen Punkten mit dem DBSCAN-Verfahren. Der Parameter $minPts$ wird in diesem Beispiel zu $minPts = 2$ gesetzt. Als Distanzmaß wird die euklidische Distanz mit dem Distanzparameter ϵ verwendet. Die Gruppe A entspricht einer Menge von Kernpunkten, da jeweils mindestens zwei weitere Punkte der Gruppe innerhalb der Distanz ϵ erreichbar sind. Die Punkte B und C sind keine Kernpunkte, jedoch über Punkte aus der Gruppe A erreichbar. Der Punkt N ist ein Ausreißer.

Im fünften und letzten Schritt wird erneut eine Gruppierung mit einer geringeren Distanz von $\epsilon = 30$ m durchgeführt. Für den OSM-Ausschnitt um München ergeben sich 18713 Kreuzungsmittelpunkte. Abbildung 2.2 zeigt vier beispielhafte Kreuzungen mit den zugehörigen Knoten aus der OSM als blaue Punkte sowie den sich ergebenden Kreuzungsmittelpunkten, welche als rote Kreuze dargestellt sind.

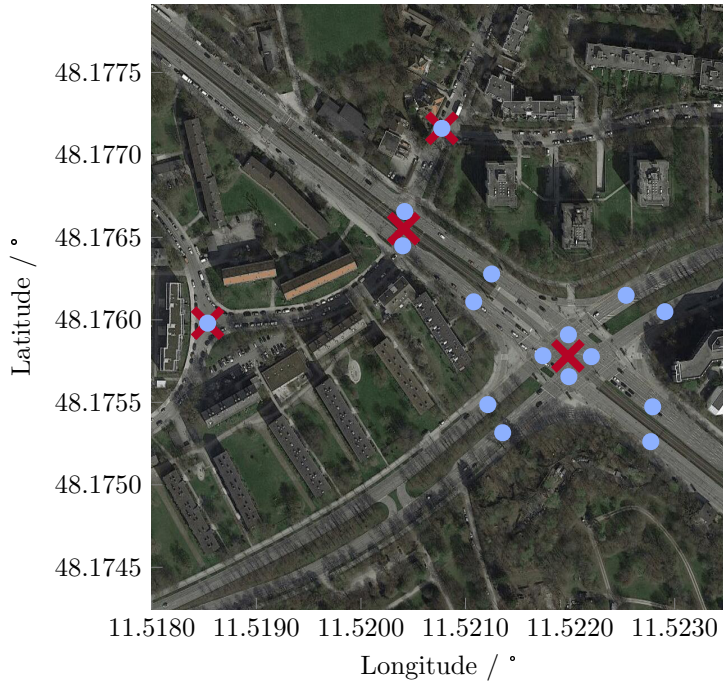


Bild 2.2: Gruppierung von Knoten aus OSM zur Ermittlung von Kreuzungsmittelpunkten. Die blauen Punkte repräsentieren vorgefilterte Knoten aus der OSM. Die roten Kreuze entsprechen den Kreuzungsmittelpunkten, die sich durch die Anwendung der vorgestellten Methode ergeben. Eine komplexe Kreuzung mit 12 Knoten wird auf einen Mittelpunkt reduziert. Bilder ©2016, DigitalGlobe, GeoBasis-DE/BKG, GeoContent.

Tabelle 2.1: Verwendete Maße für die Unterschiedlichkeit zwischen diskreter Wahrscheinlichkeitsdichten

Klasse	Maß	Abkürzung
Heuristisches Distanzmaß	L1-Distanz	L1
parameterfreie Teststatistik	Kolmogorov-Smirnov Distanz [62]	KS
informationstheoretisches Maß	Kullback-Leibler-Divergenz [63]	KL
Grunddistanzmaß	Earth Movers Distanz [64]	EMD

2.2 Maße für die Unterschiedlichkeit

Zur Berechnung des Unterschieds zwischen diskreten Wahrscheinlichkeitsdichten werden in der vorliegenden Arbeit unterschiedliche Maße verwendet und ihre Eignung für die gegebenen Anwendungen untersucht. In [61] werden Klassen von Maßen für die Unterschiedlichkeit vorgestellt:

- Heuristische Distanzmaße,
- parameterfreie Teststatistiken,
- informationstheoretische Maße
- und Grunddistanzmaße.

In dieser Arbeit wird entsprechend Tabelle 2.1 aus jeder Klasse ein repräsentatives Maß für die Anwendung auf diskrete Wahrscheinlichkeitsverteilungen gewählt. Nachfolgend werden die genannten Maße auf den diskreten Verteilungen $P(x)$ und $Q(x)$ eingeführt. Die Verteilungen sind in einem diskreten Intervall $a \leq x \leq b$ mit $x \in \mathbb{Z}$ definiert.

L1-Distanz Die L1-Distanz (L1) ergibt sich aus der Summe der Beträge der Differenz zwischen den jeweiligen Werten der Wahrscheinlichkeitsverteilungen für den gesamten Definitionsbereich:

$$L1(P(x), Q(x)) = \sum_{i=a}^b |P(i) - Q(i)|. \quad (2.1)$$

Kolmogorov-Smirnov Distanz Die Kolmogorov-Smirnov Distanz (KS) entspricht dem maximalen Unterschied der kumulativen Verteilungen:

$$KS(P(x), Q(x)) = \max_{i \in [a,b]} |F_P(i) - F_Q(i)| \quad (2.2)$$

mit

$$F_P(i) = \sum_{j=a}^i P(j) \quad (2.3)$$

und

$$F_Q(i) = \sum_{j=a}^i Q(j). \quad (2.4)$$

Kullback-Leibler-Divergenz Die Kullback-Leibler-Divergenz (KL) der Verteilungen $P(x)$ und $Q(x)$ entspricht aus informationstheoretischer Sicht dem Anteil an verlorener Information falls $Q(x)$ verwendet wird um $P(x)$ anzunähern [65]. Der Unterschied zwischen zwei Verteilungen ergibt sich zu:

$$KL(P(x), Q(x)) = \sum_{i=a}^b P(i) \cdot \log \frac{P(i)}{Q(i)}. \quad (2.5)$$

Earth Movers Distanz Die Earth Movers Distanz (EMD) zwischen zwei Verteilungen entspricht den minimalen Kosten, die nötig sind, um die eine Verteilung so zu konvertieren, dass sie gleich zur zweiten Verteilung ist. Die Kosten entsprechen dabei den zu verschiebenden Wahrscheinlichkeitsmassen gewichtet mit der Distanz der Verschiebung. Die EMD zwischen den eindimensionalen

Verteilungen $P(x)$ und $Q(x)$ wird basierend auf [66] anhand des folgenden iterativen Algorithmus bestimmt:

Algorithmus 2.1 : Earth Movers Distanz (EMD)

- 1: $e_{a-1} = 0$
 - 2: $e_i = P(i) + e_{i-1} - Q(i)$
 - 3: $\text{EMD}(P(x), Q(x)) = \sum_{i=a}^b |e_i|$.
-

2.3 Datengrundlage

Grundlage dieser Arbeit sind aufgezeichnete Fahrzeugbusdaten von seriennahen BMW Testfahrzeugen. Die Daten werden mit Loggern aufgezeichnet. Eine relevante Untermenge der verfügbaren Signale wird in einer Datenbank gespeichert, die im Rahmen dieser Arbeit entstanden ist. Die Daten sind logisch entsprechend dem Diagramm in Abbildung 2.3 strukturiert. Jede Fahrt wird als Spur mit einer zugehörigen ID und einer beliebigen Anzahl an Messungen abgelegt, welche einmal pro Sekunde abgespeichert werden. Jede Messung besteht aus:

- Position,
- Geschwindigkeit in m/s,
- Beschleunigung in m/s^2 ,
- Orientierung in rad,
- Zeit in s
- und einer beliebigen Anzahl an Umfeldobjekten.

Die Position wird dabei über GPS gemessen. Die eingesetzte Technik aus den aktuellen Navigationssystemen besitzt laut „GPS SPS Performance Standard“ [67, S. 22] Messabweichungen unter 7.8 m mit 95 % und unter 30 m mit 99.94 % Konfidenz. Die Positionsdaten werden im geodätischen Referenzsystem World

Geodetic System 1984 (WGS84) angegeben. Die Zeit wird entsprechend einem Unix-Zeitstempel als Anzahl der Sekunden seit dem 1. Januar 1970 um 00:00 Uhr Universal Time Coordinated (UTC) angegeben.

Die Umfeldobjekte werden durch ein Radarsystem erfasst, wobei von jedem erfassten Objekt folgende Daten abgespeichert werden:

- Relative Position in m,
- relative Position in m
- und eine relative Geschwindigkeit in m/s.

Die einzelnen Messungen werden zusammen mit der zugehörigen ID der Spur georeferenziert über die jeweilige Position in die Datenbank gespeichert. Dabei wird die objektrelationale Open Source Datenbank PostgreSQL mit der Erweiterung PostGIS [68] für räumliche Objekte und Abfragen verwendet. In einer PostGIS Datenbank ist es möglich, unterschiedliche Geometrien wie Punkte, Linienzüge oder Flächen, sowie weitere daraus abgeleitete Typen, zu repräsentieren. Zusätzlich zur Speicherung von Objekten bietet PostGIS die Möglichkeit, geometrische Abfragen zu erstellen. Beispielsweise können sämtliche Punkte innerhalb einer definierten geometrischen Box abgefragt werden. Zur Beschleunigung derartiger Abfragen wird in PostGIS ein Index auf den gespeicherten geometrischen Objekten angelegt [8].

Insgesamt sind in der Datenbank 31000h Fahrt, bzw. 271458 Kreuzungsüberfahrten, durch BMW Testfahrzeuge vorhanden. Diese Datenbasis wird im weiteren Verlauf dieser Arbeit als Grundlage für die Entwicklung und Evaluierung der Methoden zur Extraktion von Fahrzeugumgebungsinformationen verwendet.

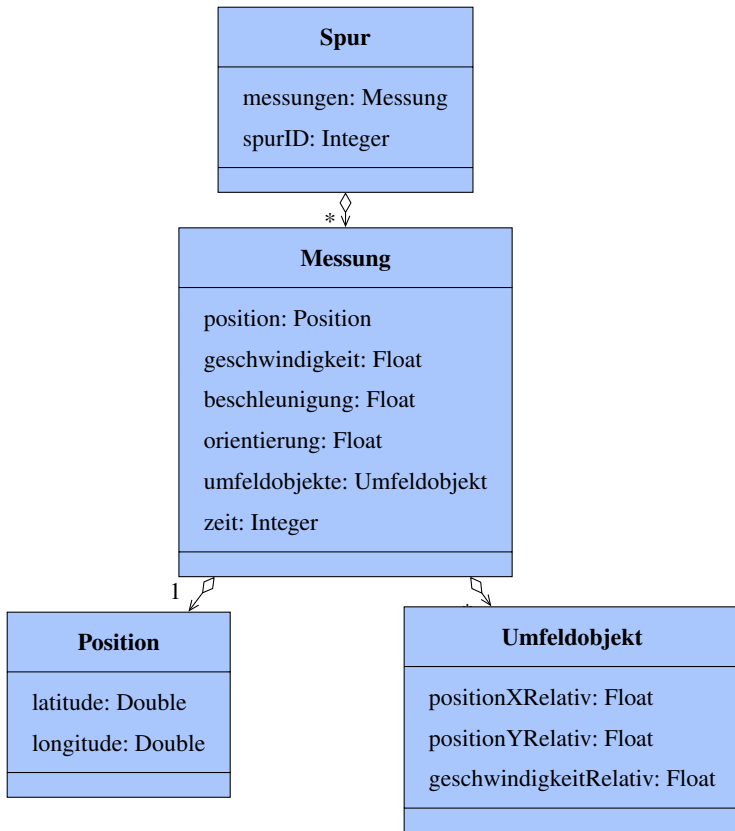


Bild 2.3: Datenstruktur der aufgezeichneten Spuren von seriennahen Erprobungsfahrzeugen.

3 Repräsentation einer Straßenkreuzung

Wie bereits in Abschnitt 2.1 angesprochen, verfügen heutige digitale Karten nicht über eine explizite Modellierung von Straßenkreuzungen. Zur Beschreibung kreuzungsspezifischer Eigenschaften wird daher in diesem Kapitel eine Repräsentation einer Straßenkreuzung zur Abstraktion von der Kreuzungsgeometrie erarbeitet. Dadurch ist es möglich, generische Ansätze zur Ermittlung von Kreuzungseigenschaften zu entwickeln, welche unabhängig von den geometrischen Eigenschaften einer Kreuzung sind. In den folgenden Kapiteln wird die Repräsentation um zusätzliche Kreuzungseigenschaften erweitert.

Ein Bestandteil der vorgestellten Repräsentation von Kreuzungen sind unterschiedliche Ein- und Ausfahrten. Eine Kreuzungseinfahrt entspricht im Rahmen dieser Arbeit einer Einfahrtrichtung in Kombination mit einer Position. Dabei werden mehrere Fahrstreifen, falls vorhanden, zu einer Einfahrt zusammengefasst. Einfahrten werden entsprechend den nachfolgenden Methoden aus den ersten Datenpunkten der Kreuzungsüberfahrten ermittelt. Äquivalent dazu sind Ausfahrten als Kombination einer Ausfahrtrichtung mit einer Position definiert und werden aus den jeweils letzten Datenpunkten der Überfahrten ermittelt. Die Kombination einer Ein- und Ausfahrt wird nachfolgend als Kreuzungspfad bezeichnet. Anhand der Kreuzungspfade werden alle möglichen Überfahrtswege einer Kreuzung beschrieben, die von einem Fahrer gewählt werden können. Im Hinblick auf die Beschreibung von Kreuzungen ist die Betrachtung einzelner Überfahrtswege wichtig, da beispielsweise für unterschiedliche Abbiegemanöver der gleichen Kreuzungseinfahrt unterschiedliche Vorfahrtsregeln existieren können. Die Bestimmung der Ein- und Ausfahrten sowie die Kombination zu

Kreuzungspfaden und damit die Erstellung einer Kreuzungsrepräsentation sind Gegenstand dieses Kapitels.

Grundlage der im Folgenden beschriebenen Methoden sind Kreuzungsmittelpunkte, welche anhand des in Abschnitt 2.1 beschriebenen Verfahrens aus OSM ermittelt werden, und eine Menge von GPS-Spuren \mathcal{T} , die den aufgezeichneten Überfahrten der jeweiligen Kreuzung entsprechen. Von jeder Überfahrt werden nur die Daten verwendet, deren Position weniger als 70m vom jeweiligen Kreuzungsmittelpunkt entfernt ist. Jede Überfahrt $\xi_i \in \mathcal{T}$ entspricht einem Tupel von N_i Messungen $\kappa_j^{(i)}$. Jede einzelne Messung $\kappa_j^{(i)}$ entspricht wiederum einem Tupel aus einer zweidimensionalen Position $\mathbf{x}_j^{(i)} \in \mathbb{R}^2$, einer Geschwindigkeit $v_j^{(i)} \in \mathbb{R}$, einer Beschleunigung $a_j^{(i)} \in \mathbb{R}$, einer Orientierung $\varphi_j^{(i)} \in [0, 2\pi)$ und einer absoluten Zeitangabe $t_j^{(i)} \in \mathbb{R}$, damit gilt $\xi_i = (\kappa_1^{(i)}, \kappa_2^{(i)}, \dots, \kappa_{N_i}^{(i)})$ mit $\kappa_j^{(i)} = (\mathbf{x}_j^{(i)}, v_j^{(i)}, a_j^{(i)}, \varphi_j^{(i)}, t_j^{(i)})$. Die zeitliche Differenz zwischen zwei Messdaten beträgt in den vorliegenden Daten eine Sekunde, $t_{j+1}^{(i)} - t_j^{(i)} = 1$ s. In Abbildung 3.1 sind exemplarisch Positionsdaten von 451 Überfahrten einer Fahrzeugflotte über eine Kreuzung in München dargestellt. Die Positionsdaten sind in dem vorliegenden Datensatz teilweise auf eine digitale Karte projiziert, weshalb eine größere Anzahl an Überfahrten deckungsgleich übereinander liegt. Für die restlichen Überfahrten ohne Karteneinpassung wird im Fahrzeug eine Fusion mit der Inertialsensorik durchgeführt zur Verbesserung der Qualität des Rohsignals. Die nachfolgend beschriebenen Schritte werden jeweils auf Basis dieser Daten erläutert.

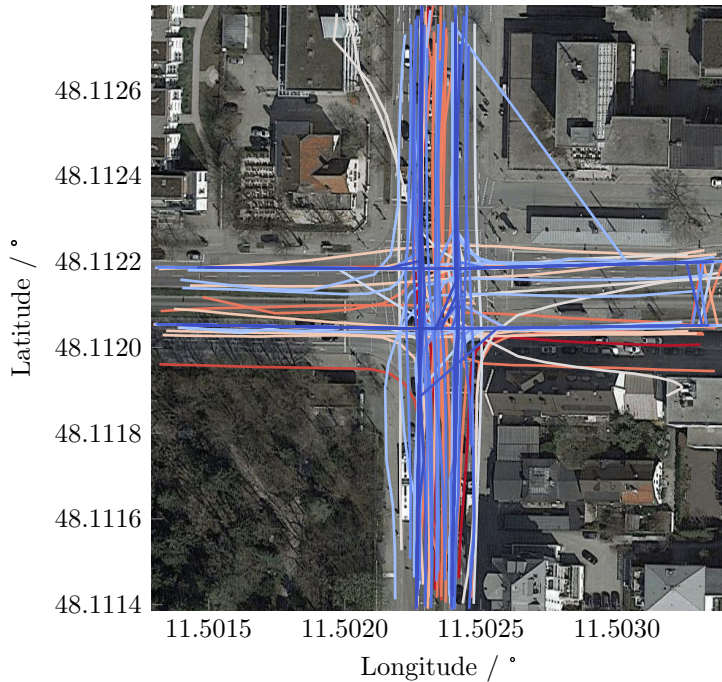


Bild 3.1: Positionsdaten von 451 Überfahrten einer Fahrzeugflotte über eine Kreuzung in München. Die Überfahrten sind in dem vorliegenden Datensatz teilweise auf eine digitale Karte projiziert und liegen daher zum Teil übereinander. Die GPS-Daten werden innerhalb eines Radius von 70 m um den Kreuzungsmittelpunkt abgeschnitten. Aufgrund der sekundenweisen zeitlichen Diskretisierung der Messungen befinden sich die Eintritts- und Austrittspunkte der Überfahrten abhängig von der Geschwindigkeit teilweise näher als 70 m am Kreuzungsmittelpunkt. Kartendaten ©2015 GeoBasis-DE/BKG (©2009), Google Bilder ©2015 DigitalGlobe, GeoBasis-DE/BKG, GeoContent.

3.1 Kreuzungsein- und -ausfahrten

Die Mengen der Einfahrten \mathcal{E} und Ausfahrten \mathcal{A} einer Kreuzung sind jeweils definiert als ein Tupel aus einer zweidimensionalen Position $\mathbf{x} \in \mathbb{R}^2$ und einer Richtung $0 \leq \varphi < 2\pi$. Es gilt also $\mathcal{E} = \{p_1, p_2, \dots, p_{N_E}\}$ mit insgesamt $N_E \in \mathbb{N}$ Einfahrten $p_e = (\mathbf{x}_e, \varphi_e)$, wobei $\mathbf{x}_e \in \mathbb{R}^2$ und $1 \leq e \leq N_E$ gilt. Die Menge \mathcal{A} mit einer Anzahl $N_A = |\mathcal{A}|$ an Ausfahrten ist dabei entsprechend definiert. Die unterschiedlichen Kreuzungsein- und -ausfahrten werden auf Basis der ersten Messungen $\kappa_1^{(i)}$, bzw. der letzten Messungen $\kappa_{N_i}^{(i)}$, aus jeder Überfahrt $\xi_i \in \mathcal{T}$ bestimmt, indem ein Gruppierungsverfahren auf diese Messungen angewendet wird. Die einzelnen Ein- und Ausfahrten ergeben sich aus den resultierenden Gruppenzentren, also dem Mittelwert der Position und Orientierung der gruppierten Messungen.

Abhängig von den verwendeten Eingangsdaten unterliegen die Positionswerte erheblichen Messabweichungen. Die Höhe der Messabweichungen ist neben dem verwendeten Sensor und Positionsfiler auch abhängig von der Lage der Kreuzung. Innerstädtische GPS-Positionsdaten unterliegen tendenziell größeren Messabweichungen als Daten von ländlichen Gegenden, da es im Stadtbereich häufig zu Mehrwegeausbreitungen des Satellitensignals kommt. Zusätzlich existieren weitere Einflüsse auf die Genauigkeit, wie z.B. die Wetterlage oder die Sonnenaktivität, wodurch sich eine zeitliche Variation der Genauigkeit ergibt. Aufgrund der hohen Zeit- und Ortsabhängigkeit des Rauschanteils der Eingangsdaten ist es nicht möglich, allgemeingültige Hyperparameter für parametrische dichtebasierte Gruppierungsmethoden wie DBSCAN [60] zu schätzen, weshalb diese Methoden nicht angewendet werden.

Aus diesem Grund wird die Anzahl an Kreuzungsein- und -ausfahrten basierend auf der Wahrscheinlichkeitsdichte der Fahrtrichtung beim Eintritt $f_1(\varphi)$ bzw. beim Austritt $f_{N_i}(\varphi)$ aus der Kreuzung bestimmt. Die nachfolgende Methodik zur Ermittlung von Ein- und Ausfahrten wird ausschließlich für Einfahrten erläutert. Für Kreuzungsausfahrten werden sämtliche Schritte äquivalent angewendet. Basierend auf der Anzahl an Einfahrten wird das K-means Grup-

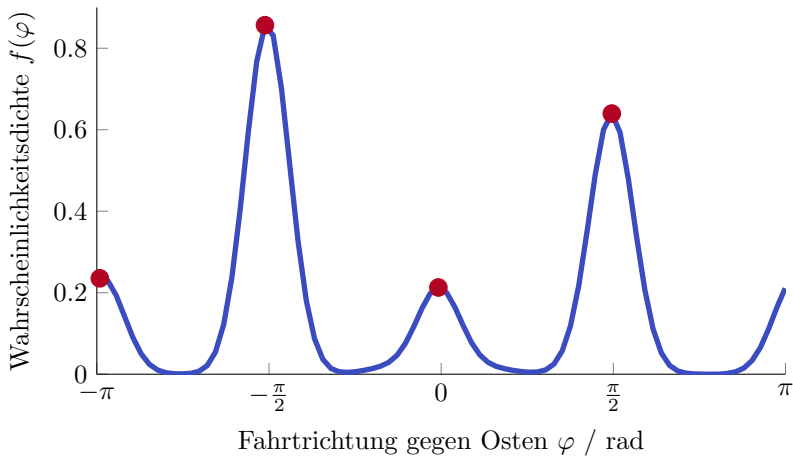


Bild 3.2: Wahrscheinlichkeitsdichte der Fahrtrichtung beim Eintritt in die Kreuzung aus Abbildung 3.1. Die Dichtefunktion wird über einen Kerndichteschätzer angenähert. Die vier Maxima entsprechen den Fahrtrichtungen der einzelnen Kreuzungseinfahrten.

pierungsverfahren angewendet. Abbildung 3.2 zeigt die Verteilung der Fahrtrichtungen für die exemplarische Kreuzung aus Abbildung 3.1. Da die Fahrtrichtung mit Ungenauigkeiten behaftet ist, wird die Wahrscheinlichkeitsdichte $f(\varphi)$ über einen Kerndichteschätzer mit einer Bandbreite $B = 10^\circ$ angenähert. Die Anzahl der Kreuzungseinfahrten entspricht der Anzahl an Maxima $N_E = |\{\varphi_k | f'(\varphi_k) = 0 \wedge f''(\varphi_k) < 0\}|$ mit der ersten und zweiten Ableitung, f' bzw. f'' der jeweiligen Verteilungsdichte f der Fahrtrichtungen beim Eintritt. Bei der Ermittlung der Maxima wird die Zirkularität der Winkelwerte berücksichtigt. Aus der Verteilung in Abbildung 3.2 ergeben sich dadurch vier Kreuzungseinfahrten.

Entsprechend der ermittelten Anzahl von N_E Gruppen wird auf die zugehörigen Messdaten eine K-means Gruppierung angewendet. Die zweidimensionale Position und die Orientierung dienen dabei als Merkmalswerte. Zur Berücksichtigung der zirkulären Eigenschaften der Fahrtrichtung wird dieses Merkmal aufgeteilt in einen Sinus- und einen Kosinusanteil. Dadurch besitzen Winkel im

Bereich des Übergangs von $-\pi$ zu π eine geringe numerische Distanz. Es ergibt sich ein Merkmalsvektor $\mathbf{e}^{(i)} = (\mathbf{x}_1^{(i)}, \sin(\varphi_1^{(i)}), \cos(\varphi_1^{(i)}))$ für die K-means Gruppierung der Einfahrten \mathcal{E} , welcher aus den ersten Messdaten $\kappa_1^{(i)}$ jeder Überfahrt $\xi_i \in \mathcal{T}$ extrahiert wird.

Zur Filterung von Ausreißern wird auf den Positionswerten, die einer Kreuzungseinfahrt zugeordnet sind, eine Multivariate Ausreißererkenkung nach [69] durchgeführt. Dabei wird die zweidimensionale Verteilung der Einfahrtspositionen geschätzt und für jede Position die Mahalanobisdistanz zum Mittelwert aller Positionen bestimmt. Die Mahalanobisdistanzen einer mehrdimensionalen Normalverteilung folgen einer Chi-Quadrat Verteilung mit der Anzahl an Dimensionen als Freiheitsgrad. Nach [69] wird die Grenze der Mahalanobisdistanz für Ausreißer anhand einem beliebig gewählten Quantil der Chi-Quadrat Verteilung gewählt. Für die vorliegende Problemstellung erwies sich basierend auf experimentellen Untersuchungen ein Quantil von 95 % als passend. Datenpunkte, deren Mahalanobisdistanz zum Mittelpunkt größer das 95 % Quantil ist, werden als Ausreißer gekennzeichnet. Aus den restlichen Positionswerten der Gruppe werden die Position \mathbf{x} und die Richtung φ der Kreuzungseinfahrt durch Mittelwertbildung berechnet. Da jeder Positionswert aus einer Überfahrt entnommen wird, ist es möglich, nach der Filterung jeder Kreuzungseinfahrt einzelne Überfahrten zuzuordnen und Ausreißer zu identifizieren. Für die exemplarische Kreuzung ist die Menge an Einfahrten \mathcal{E} und Ausfahrten \mathcal{A} in Abbildung 3.3 dargestellt. Jeder Kreuzungseinfahrt $p_e \in \mathcal{E}$ und jeder Kreuzungsausfahrt $p_a \in \mathcal{A}$ ist eine Untermenge an Überfahrten $\mathcal{T}_e \subseteq \mathcal{T}$, bzw. $\mathcal{T}_a \subseteq \mathcal{T}$ aus sämtlichen Überfahrten \mathcal{T} zugeordnet.




Bild 3.3: Gruppierte Kreuzungsein- und -ausfahrten für eine exemplarische Kreuzung. Die Einfahrten und deren Orientierung werden durch blaue Kreise und zugehörigen Strich gekennzeichnet, die Ausgänge mit roten Kreisen. Dazu werden jeweils die gruppierten Ein- und Ausfahrtspositionen dargestellt, wobei gefilterte Positionen grau eingezeichnet sind. Die GPS-Daten werden innerhalb eines Radius von 70 m um den Kreuzungsmittelpunkt abgeschnitten. Aufgrund der sekundenweisen zeitlichen Diskretisierung der Messungen befinden sich die Ein- und Austrittspunkte der Überfahrten abhängig von der Geschwindigkeit teilweise näher als 70 m am Kreuzungsmittelpunkt. Kartendaten ©2015 GeoBasis-DE/BKG (©2009), Google Bilder ©2015 DigitalGlobe, GeoBasis-DE/BKG, GeoContent.

3.2 Mittlere Kreuzungspfade

Jede Kombination aus einer Kreuzungseinfahrt und einer Kreuzungsausfahrt, für welche mindestens eine gemeinsame Überfahrt aus den jeweils zugeordneten Überfahrten $\mathcal{T}_e \subseteq \mathcal{T}$ und $\mathcal{T}_a \subseteq \mathcal{T}$ existiert, wird als Kreuzungspfad bezeichnet. Ein Pfad ρ_{ea} ist damit durch die Kombination der e -ten Einfahrt $p_e \in \mathcal{E}$ und der a -ten Ausfahrt $p_a \in \mathcal{A}$ definiert.

Für jede mögliche Ein-/Ausfahrtskombination (e, a) einer Kreuzung werden mittlere Pfade aus den einzelnen Überfahrten erzeugt. Ein mittlerer Pfad ρ_{ea} entspricht einem Polygonzug mit N_{ea} Punkten und ist definiert als Tupel aus Positionswerten $\rho_{ea} = (\mathbf{x}_{p_1}, \dots, \mathbf{x}_{p_{N_{ea}}})$, $N_{ea} > 1$. Nachfolgend wird das entwickelte Vorgehen zum Bestimmen des mittleren Pfades basierend auf dem Mean Shift Verfahren [70] erläutert.

Der erste Punkt entspricht dabei der Position der zugehörigen Einfahrt $\mathbf{x}_{p_1} = \mathbf{x}_e$ und der letzte Punkt der Position der entsprechenden Ausfahrt $\mathbf{x}_{p_{N_{ea}}} = \mathbf{x}_a$. Für eine strenge Ordnung der Punkte wird definiert, dass die euklidische Distanz zwischen zwei aufeinanderfolgenden Punkten kleiner ist als zu sämtlichen weiteren folgenden Punkten der Sequenz:

$$\|\mathbf{x}_{p_{l+1}} - \mathbf{x}_{p_l}\|_2 \leq \|\mathbf{x}_{p_{l+m}} - \mathbf{x}_{p_l}\|_2, \quad (3.1)$$

wobei $1 \leq l \leq N_{ea} - 2$ und $2 \leq m \leq N_{ea} - l$.

Durch die Projektion eines Positionswerts auf den resultierenden mittleren Pfad ρ_{ea} ergibt sich ein longitudinaler Offset entlang des Pfades und damit eine eindimensionale Positionskoordinate. Als Ursprung der Positionskordinaten wird der projizierte Kreuzungsmittelpunkt für jeden Pfad verwendet. Durch die Reduktion der Positionsdimensionen nimmt die Komplexität der Verarbeitung der Positionsdaten ab. Zudem ermöglicht die Projektion eine Abstraktion von der Kreuzungsgeometrie. Dadurch können Methoden zur Inferenz von Kreuzungsparametern unabhängig von der Geometrie entwickelt werden.

Zur Erzeugung der mittleren Pfade wird das Mean Shift Verfahren [70] auf der Menge der Positionswerte \mathcal{X}_{ea} sämtlicher Überfahrten mit e -ter Einfahrt und a -ter Ausfahrt angewendet. Dieses Verfahren schätzt den lokalen Gradienten einer beliebigen Verteilung von Daten. In einem ersten Schritt des Ansatzes wird der Mittelwert $\bar{\mathbf{x}}$ auf einer Untermenge der zweidimensionalen Positionsdaten \mathcal{X}_{ea} aller Überfahrten $\mathcal{T}_{ea} = \mathcal{T}_a \cap \mathcal{T}_e$ eines Pfades ρ_{ea} bestimmt. Die Untermenge wird über die Anwendung eines flachen Kerns $K(\mathbf{x}_j - \mathbf{c}_1^{(n)})$ auf allen Positionswerten $\mathbf{x}_j \in \mathcal{X}_{ea}$ an einem beliebigen ersten Zentrum $\mathbf{c}_1^{(n)} \in \mathcal{X}_{ea}$ gebildet. Damit ergibt sich der Mittelwert $\bar{\mathbf{x}}(\mathbf{c}_1^{(n)})$ zu

$$\bar{\mathbf{x}}(\mathbf{c}_1^{(n)}) = \frac{\sum_{\mathbf{x}_j \in \mathcal{X}_{ea}} \mathbf{x}_j \cdot K(\mathbf{x}_j - \mathbf{c}_1^{(n)})}{\sum_{\mathbf{x}_j \in \mathcal{X}_{ea}} K(\mathbf{x}_j - \mathbf{c}_1^{(n)})} \quad (3.2)$$

mit

$$K(\mathbf{y}) = \begin{cases} 1 & \text{für } \|\mathbf{y}\|_2 \leq \lambda \\ 0 & \text{für } \|\mathbf{y}\|_2 > \lambda \end{cases}. \quad (3.3)$$

Die Anwendung des flachen Kerns ergibt einen Mittelwert, bei dessen Berechnung ausschließlich Datenpunkte berücksichtigt werden, deren Position sich innerhalb einer Distanz $\lambda \in \mathbb{R}$ um das Zentrum $\mathbf{c}_1^{(n)}$ befindet. Der Vektor $\bar{\mathbf{x}}(\mathbf{c}_1^{(n)}) - \mathbf{c}_1^{(n)}$ entspricht einer Näherung des Gradienten der Verteilung am Zentrum $\mathbf{c}_1^{(n)}$. Durch iterative Anwendung der Methode mit $\mathbf{c}_{j+1}^{(n)} = \bar{\mathbf{x}}(\mathbf{c}_j^{(n)})$ konvergiert die Verschiebung des Zentrums in einem lokalen Maximum $\mathbf{c}_{\max}^{(n)}$ der Dichte der Verteilung. Sämtliche besuchten Punkte werden für die weitere Suche nach Maxima ausgeschlossen. Ein erneuter Start mit einer weiteren Position $\mathbf{c}_1^{(n+1)} \in \mathcal{X}_{ea} \setminus \{\mathbf{c}_1^{(1)}, \dots, \mathbf{c}_{\max}^{(1)}, \dots, \mathbf{c}_1^{(n)}, \dots, \mathbf{c}_{\max}^{(n)}\}$ aus den noch nicht besuchten Positionen als Startwert ergibt ein weiteres Maximum $\mathbf{c}_{\max}^{(n+1)}$. Die sich ergebende Menge an lokalen Maxima wird entsprechend Gleichung (3.1) sortiert. Zur Filtrierung von Ausreißern wird die Plausibilität eines jeden lokalen Maximums basierend auf der Änderung der Orientierung in Bezug auf das vorangehende Ma-

ximum überprüft. Mit den Orientierungsvektoren $\mathbf{o}^{(n-1)} = \mathbf{c}_{\max}^{(n)} - \mathbf{c}_{\max}^{(n-1)}$ und $\mathbf{o}^{(n)} = \mathbf{c}_{\max}^{(n+1)} - \mathbf{c}_{\max}^{(n)}$ wird $\mathbf{c}_{\max}^{(n)}$ als Ausreißer definiert, falls der Unterschied der Orientierungen größer ist als $\frac{\pi}{2}$, $\angle(\mathbf{o}^{(n-1)}; \mathbf{o}^{(n)}) > \frac{\pi}{2}$. Eine diskretisierte kubische Interpolation der verbleibenden Maxima ergibt einen mittleren Pfad $\rho_{ea}(\lambda) = (\mathbf{x}_{P1}, \mathbf{x}_{P2}, \dots, \mathbf{x}_{P_{N_{ea}}})$ abhängig vom Distanzparameter λ des flachen Kerns.

Die Vorteile dieser nichtparametrischen Methode gegenüber einer parametrischen Regression liegen darin, dass keine Annahmen über die Geometrie des Pfades nötig sind und λ der einzige zu bestimmende Parameter ist. Die Positionswerte besitzen bei verschiedenen Kreuzungen unterschiedlich hohe Rausch- und Ausreißeranteile. Daher ist der optimale Wert des Parameters λ des flachen Kerns spezifisch für jede Kreuzung. Der λ Parameter legt den Durchmesser des Kerns fest, welcher so niedrig wie möglich sein sollte um eine ideale Schätzung der realen mittleren Pfade zu erhalten. Bei verrauschten Daten führt ein niedriger Wert für λ allerdings zu einer größeren Anzahl an Ausreißern unter den gefundenen lokalen Maxima. Daher wird der Parameter λ über die Lösung eines Optimierungsproblems ermittelt, indem die aggregierte laterale Distanz sämtlicher Positionswerte zum mittleren Kreuzungspfad minimiert wird. Eine gegebene Distanzfunktion

$$\text{dist}: \mathbb{R}^2 \times \mathcal{P} \rightarrow \mathbb{R} \tag{3.4}$$

berechnet die laterale Distanz einer Position zu einem Kreuzungspfad. Eingangsgrößen in die Funktion sind ein Positionswert $\mathbf{x}_j \in \mathbb{R}^2$ und ein Linienzug $\rho_{ea}(\lambda) \in \mathcal{P}$ aus der Menge der Pfade \mathcal{P} . Der optimale Parameter λ_{opt} ergibt sich damit zu

$$\lambda_{\text{opt}} = \arg \min_{\lambda \in \mathbb{R}} \sum_{\mathbf{x}_j \in \mathcal{X}_{ea}} \text{dist}(\mathbf{x}_j, \rho_{ea}(\lambda)). \tag{3.5}$$

Die Berechnung des Abstandes einer Position $\mathbf{x}_j \in \mathcal{X}_{ea}$ zu einem Linienzug $\rho_{ea}(\lambda) = (\mathbf{x}_{P_1}, \dots, \mathbf{x}_{P_l}, \dots, \mathbf{x}_{P_{N_{ea}}})$ erfolgt durch

$$\text{dist}(\mathbf{x}_j, \rho_{ea}(\lambda)) = \min_{l \in \{1, \dots, N_{ea}-1\}} \frac{\|(\mathbf{x}_{P_{l+1}} - \mathbf{x}_{P_l}) \times (\mathbf{x}_j - \mathbf{x}_{P_l})\|_2}{\|(\mathbf{x}_{P_{l+1}} - \mathbf{x}_{P_l})\|_2}. \quad (3.6)$$

Zur Erhöhung der Robustheit gegenüber Ausreißern werden Datenpunkte gefiltert, deren Position eine größere Distanz zur ersten Schätzung des mittleren Pfades aufweisen als der Median sämtlicher Distanzen. Ein verbesserter zweiter mittlerer Pfad wird basierend auf den übrigen Datenpunkten mit dem optimierten Parameter λ_{opt} generiert. In Abbildung 3.4 ist ein erzeugter mittlerer Pfad für Rechtsabbieger von Westen nach Süden der exemplarischen Kreuzung dargestellt. Die schwarzen Kreise entsprechen den gefundenen Maxima durch das Mean Shift Verfahren.

Das Ergebnis der mittleren Pfade sämtlicher möglicher Kreuzungspfade der exemplarischen Kreuzung ist in Abbildung 3.5 zu sehen. Unter Verwendung der mittleren Pfade ist es damit möglich, Positionsdaten aus einem absoluten Koordinatensystem in ein lokales eindimensionales Koordinatensystem für einen Kreuzungspfad zu transformieren und umgekehrt. Damit werden zweidimensionale Positionsdaten \mathbf{x} in eindimensionale Strecken s entlang des mittleren Pfades transformiert.

Im Rahmen dieser Arbeit wird eine Kreuzung durch folgende Bestandteile repräsentiert:

- Kreuzungsmittelpunkt,
- Einfahrten,
- Ausfahrten
- und mittlere Kreuzungspfade.

In den folgenden drei Kapiteln werden Methoden für die automatisierte Ermittlung weiterer Kreuzungseigenschaften vorgestellt. Grundlage der Verfahren ist die beschriebene Repräsentation einer Kreuzung.




Bild 3.4: Ergebnis der Anwendung des Mean Shift Verfahrens zur Generierung eines mittleren Kreuzungspfades. Die gefundenen lokalen Maxima werden durch schwarze Kreise dargestellt. Über eine kubische Interpolation ergibt sich ein mittlerer Pfad (schwarze Linie). Grundlage der Abbildung ist die Schätzung der Dichte sämtlicher Positionswerte der Überfahrten über einen Kerndichteschätzer mit Gaußkern und einer Bandbreite von 4m. Die Kerndichteschätzung wird nur zur Visualisierung der Daten verwendet und ist nicht Teil des Verfahrens.




Bild 3.5: Mittlere Pfade für eine exemplarische Kreuzung. Das rote Kreuz repräsentiert den aus OSM extrahierten Kreuzungsmittelpunkt. Kartendaten ©2015 GeoBasis-DE/BKG (©2009), Google Bilder ©2015 DigitalGlobe, GeoBasis-DE/BKG, GeoContent.

4 Vorfahrtsregeln an Straßenkreuzungen

Eine wichtige Eigenschaft von Straßenkreuzungen ist die gültige Vorfahrtsregelung. Aktuell verfügbare digitale Karten enthalten diese Information nur zum Teil. Beispielsweise sind Lichtsignalanlagen nicht flächendeckend kartiert und nur eingeschränkt aktuell. Weitere Vorfahrtsregeln fehlen vollständig. In diesem Abschnitt wird eine Methodik vorgestellt, die aus Flottendaten automatisiert Vorfahrtsregeln an Kreuzungen klassifiziert. Im Rahmen dieser Arbeit wird zwischen den folgenden Vorfahrtsregeln unterschieden:

- Vorfahrt,
- Vorfahrt gewähren,
- Halt! Vorfahrt gewähren (Stoppschild),
- Rechts vor Links
- und Lichtsignalanlage (LSA).

4.1 Überwachtes Lernen von Vorfahrtsregeln

Im Rahmen dieser Arbeit wird die Anwendung überwachter Lernverfahren zur Klassifikation von Vorfahrtsregeln an Kreuzungen untersucht. Dazu werden die in Abschnitt 2.3 beschriebenen Versuchsträgerdaten verwendet. Neuartige Merkmale, welche die Umfeldsensorik des Fahrzeugs einbeziehen, werden zusätzlich zu den vorgestellten Arbeiten in Abschnitt 1.2 eingeführt. Des Weiteren wird aus einzelnen Kreuzungsüberfahrten eine Kreuzungsrepräsentation

entsprechend Abschnitt 3 erstellt. Die in Abschnitt 1.2 vorgestellten bisherigen Arbeiten zur Klassifikation von Vorfahrtsregeln werden anhand dieser Repräsentation dahingehend erweitert, dass sämtliche Kreuzungspfade und damit zusätzlich auch Abbiegepfade separat klassifiziert werden. Der Grund hierfür liegt darin, dass die Pfade einer Kreuzung teils unterschiedlich reguliert sind. Beispielsweise ist es möglich, dass Rechtsabbiegepfade an Kreuzungen mit einer Lichtsignalanlage existieren, für die *Vorfahrt gewähren* gültig ist.

Aus der vorhandenen Datenbasis werden insgesamt $N_{\text{Pfade}} = 637$ Kreuzungspfade extrahiert und diesen manuell die korrekte Vorfahrtsregel zugeordnet. Dabei sind für jeden Kreuzungspfad mindestens 30 aufgezeichnete Überfahrten vorhanden. Die manuelle Zuordnung der korrekten Vorfahrtsregel erfolgt anhand von Straßenbildern aus Google Streetview und Satellitenaufnahmen aus Google Maps. Es ist davon auszugehen, dass die durch dieses Vorgehen erstellte Grundwahrheit fehlerbehaftet ist, da die Aufnahmen teilweise mehrere Jahre alt sind und daher straßenbauliche Änderungen nicht berücksichtigt werden. Die entstehenden Abweichungen der Grundwahrheit von der Realität und die damit verbundene potentielle Verschlechterung des Ergebnisses werden im Rahmen dieser Arbeit akzeptiert.

Abbildung 4.1 zeigt die Verteilung der Vorfahrtsregeln für sämtliche Kreuzungspfade. Dabei existieren auffallend viele Kreuzungen, die durch eine Lichtsignalanlage geregelt werden. Dies folgt daraus, dass Kreuzungen mit höherem Verkehrsaufkommen meist durch eine Lichtsignalanlage geregelt werden. Damit ist die Wahrscheinlichkeit für diese Kreuzungen höher, dass Pfade mit einer ausreichenden Anzahl an aufgezeichneten Kreuzungsüberfahrten existieren. In dem Datensatz sind die Klassen *Rechts vor Links* und *Stoppsschild* mit nur elf, respektive zwei Beispielen unterrepräsentiert.

Auf diese Daten werden die folgenden überwachten Klassifikationsverfahren angewendet und in Unterabschnitt 4.3 gegeneinander evaluiert:

- Random Forest,
- Support Vector Machine (SVM),

- Neuronales Netz
- und Extreme Learning Machine (ELM) [71].




Bild 4.1: Verteilung der Vorfahrtsregeln für die in Summe 637 manuell klassifizierten Kreuzungspfade. Für jeden Kreuzungspfad sind mindestens 30 Überfahrten in den Daten vorhanden.

4.2 Extraktion von Klassifikationsmerkmalen

Als Merkmale für die überwachten Klassifikationsverfahren werden ähnlich zu [58] statistische Maßzahlen aus definierten Eigenschaften der einzelnen Kreuzungsüberfahrten $\xi_i \in \mathcal{T}_{ea}$ eines Pfades mit der Einfahrt e und der Ausfahrt a berechnet. Dabei enthält jeder Messwert einer Überfahrt neben Position, Geschwindigkeit, Beschleunigung, Orientierung und Zeit ebenfalls Informationen über Umfeldobjekte basierend auf Radarsensoren. Zu jedem Datenpunkt $\kappa_j^{(i)}$ einer Überfahrt ξ_i existiert daher eine Menge $\mathcal{U}_j^{(i)}$ von Umfeldobjekten. Ein Um-

feldobjekt $v \in \mathcal{U}_j^{(i)}$ ist definiert über die relative Position \mathbf{x}_{rel} und eine relative Geschwindigkeit in Fahrtrichtung des eigenen Fahrzeugs v_{rel} , $v = (\mathbf{x}_{\text{rel}}, v_{\text{rel}})$.

Aus den einzelnen Überfahrten werden Merkmale extrahiert. Für jeden Pfad ergeben sich aus den Merkmalen sämtlicher Überfahrten die statistischen Eigenschaften Mittelwert μ , Standardabweichung σ , 0.1-Quantil $Q_{0.1}$ und 0.9-Quantil $Q_{0.9}$. Anhand dieser Eigenschaften der einzelnen Merkmale wird eine Klassifikation der Vorfahrtsregel für einen Kreuzungspfad durchgeführt. Die folgenden Merkmale werden aus den Daten berechnet:

- Dauer eines Haltevorgangs $\Delta t_{\text{Stopp}} (\mu, \sigma, Q_{0.1}, Q_{0.9})$
- Distanz zum Kreuzungsmittelpunkt bei einem Haltevorgang $s_{\text{Stopp}} (\mu, \sigma, Q_{0.1}, Q_{0.9})$
- Minimale Überfahrtsgeschwindigkeit $v_{\text{min}} (\mu, \sigma, Q_{0.1}, Q_{0.9})$
- Anzahl an Vorderfahrzeugen bei einem Haltevorgang $N_{\text{Vfz}} (\mu, \sigma, Q_{0.1}, Q_{0.9})$
- Lokales Maximum der Beschleunigung nach einem Haltevorgang $a_{\text{Start}} (\mu, \sigma, Q_{0.1}, Q_{0.9})$
- Verhältnis der Anzahl an Überfahrten mit Haltevorgängen zur gesamten Anzahl an Überfahrten (Relative Anzahl an Haltevorgängen) p_{Stopp}
- Differenz zwischen der Ein- und Ausfahrtrichtung (Fahrtrichtung) δ_{ea}

Grundlage für die Merkmale Δt_{Stopp} , s_{Stopp} , N_{Vfz} , a_{Start} und p_{Stopp} sind jeweils Haltevorgänge in den Überfahrten $\xi_i \in \mathcal{T}_{ea}$. Für den Fall, dass mehrere Haltevorgänge in einer Überfahrt aufgetreten sind, wird ausschließlich der längste Halt berücksichtigt. Überfahrten ohne Haltevorgang werden für die statistischen Merkmale Δt_{Stopp} , s_{Stopp} , N_{Vfz} , a_{Start} ignoriert. Die Datenpunkte $\kappa_j^{(i)}$ einer Kreuzung

zungsüberfahrt $\xi_i = (\kappa_1^{(i)}, \kappa_2^{(i)}, \dots, \kappa_{N_i}^{(i)})$ mit $\kappa_j^{(i)} = (\mathbf{x}_j^{(i)}, v_j^{(i)}, a_j^{(i)}, \phi_j^{(i)}, t_j^{(i)})$ in einem Haltevorgang werden über die Indexmenge $\mathcal{I}_{\text{Stopp}}^{(i)}$ definiert:

$$\mathcal{I}_{\text{Stopp}}^{(i)} = \{j \mid 1 \leq j \leq N_i \wedge |v_j^{(i)}| < 1 \text{ m/s}\}. \quad (4.1)$$

Ein Haltevorgang entspricht einem zusammenhängenden Intervall an Indizes der Datenpunkte einer Überfahrt $[k, l] \subseteq \mathcal{I}_{\text{Stopp}}^{(i)}$. Die Menge $\mathcal{S}^{(i)}$ der Haltevorgänge einer Überfahrt ξ_i ist definiert zu

$$\mathcal{S}^{(i)} = \{[b, c] \mid [b, c] \subseteq \mathcal{I}_{\text{Stopp}}^{(i)} \wedge (b-1), (c+1) \notin \mathcal{I}_{\text{Stopp}}^{(i)}\}. \quad (4.2)$$

Enthält eine Überfahrt mehrere Haltevorgänge $|\mathcal{S}^{(i)}| > 1$, ergibt sich die Indexmenge des längsten Stopps zu

$$\mathcal{I}_{\text{Stopp,max}}^{(i)} = [\hat{k}^{(i)}, \hat{l}^{(i)}] \quad (4.3)$$

mit

$$\forall [b, c] \in \mathcal{S}^{(i)} : t_{\hat{l}}^{(i)} - t_{\hat{k}}^{(i)} \geq t_c^{(i)} - t_b^{(i)} \text{ mit } [\hat{k}^{(i)}, \hat{l}^{(i)}] \in \mathcal{S}^{(i)}. \quad (4.4)$$

Beschreibung der Merkmale

Im Folgenden werden die einzelnen Eigenschaften von Überfahrten und die daraus generierten Merkmale zur Klassifikation der Vorfahrtsregel eines Kreuzungspfades motiviert und mathematisch beschrieben. Dabei entspricht $\hat{k}^{(i)} = \min(\mathcal{I}_{\text{Stopp,max}}^{(i)})$ der unteren und $\hat{l}^{(i)} = \max(\mathcal{I}_{\text{Stopp,max}}^{(i)})$ der oberen Grenze der Indizes des längsten Haltevorgangs einer Überfahrt.

Dauer eines Haltevorgangs Diese Eigenschaft einer Überfahrt entspricht der Dauer des längsten Haltevorgangs der Überfahrt. Ist kein Haltevorgang in einer Überfahrt enthalten, geht die Überfahrt nicht in die Statistik über die Dauer des Haltevorgangs ein. Die Motivation für dieses Merkmal ist der erwartete signifikante Unterschied der Dauer von Haltevorgängen, z.B. zwischen Stopp-

schildern und Lichtsignalanlagen. Die längste Dauer sämtlicher Haltevorgänge einer Überfahrt ξ_i ist definiert zu

$$\Delta t_{\text{Stopp}}^{(i)} = t_{\hat{l}}^{(i)} - t_{\hat{k}}^{(i)}. \quad (4.5)$$

Distanz zum Kreuzungsmittelpunkt bei einem Haltevorgang Die Distanz zum Kreuzungsmittelpunkt bei einem Haltevorgang wird durch Transformation der Positionsdaten entsprechend der in Abschnitt 3 vorgestellten Kreuzungsrepräsentation als eindimensionale Positionskoordinate s_{Stopp} bestimmt:

$$s_{\text{Stopp}}^{(i)} = s_{\hat{l}}^{(i)}. \quad (4.6)$$

Dabei wird der letzte Datenpunkt des Haltevorgangs mit dem Index \hat{l} verwendet, da die GPS-Position während eines Stillstands durch die Mittelung mehrerer Messungen präziser wird. Die Motivation für die Verwendung der Distanz bei einem Haltevorgang als Merkmal liegt darin, dass die Größe einer Kreuzung damit indirekt abgebildet wird. Der Grundgedanke hinter diesem Merkmal ist, dass flächenmäßig größere Kreuzungen tendenziell häufiger durch eine Lichtsignalanlage reguliert werden, da die Größe mit der Anzahl an Fahrstreifen und damit mit dem erwarteten Verkehrsaufkommen zusammenhängt.

Minimale Überfahrtsgeschwindigkeit Die statistischen Eigenschaften der minimalen Geschwindigkeit $v_{\min}^{(i)}$ der Überfahrten $\xi_i \in \mathcal{T}_{ea}$ eines Pfades werden ebenfalls für die Klassifikation der Vorfahrtsregel verwendet. Beispielsweise wird bei der Vorfahrtsregel *Lichtsignalanlage* eine hohe Varianz $\sigma(v_{\min})$ erwartet, da der Geschwindigkeitsverlauf einer Kreuzungsüberfahrt sehr stark vom aktuellen Lichtsignal abhängt. Im Gegensatz dazu ist die Varianz der minimalen Überfahrtsgeschwindigkeit bei *Vorfahrt* tendenziell geringer, wobei der Mittelwert $\mu(v_{\min})$ höher ist.

Anzahl an Vorderfahrzeugen bei einem Haltevorgang Im Rahmen dieser Arbeit wird basierend auf den erfassten Objekten vor einem Fahrzeug durch den Radarsensor ein neuartiges Merkmal zur Klassifikation von Vorfahrtsregeln an Kreuzungen eingeführt. Aufgrund der Eigenschaften und der Verbauposition des Radarsensors ist es möglich, mehrere Objekte vor dem Ego-Fahrzeug zu erfassen. Basierend darauf wird das Verkehrsaufkommen in der Umgebung des Fahrzeugs abgeschätzt, wodurch sich Hinweise auf die Art der Vorfahrtsregel ergeben. Beispielsweise ist das erwartete Verkehrsaufkommen an kleineren Kreuzungen, welche durch *Rechts vor Links* reguliert werden, geringer als an Kreuzungen mit einer Lichtsignalanlage. Für die Ermittlung der Anzahl N_{Vfz} an Vorderfahrzeugen wird eine Filterung der Querablage y aus der relativen Position $\mathbf{x}_{rel} = (x, y)$ der Objekte durchgeführt:

$$N_{Vfz}^{(i)} = |\{v_j \in \mathcal{U}_k^{(i)} \mid v_j = (\mathbf{x}_{rel,j}, v_{rel,j}) \wedge \mathbf{x}_{rel,j} = (x_j, y_j) \wedge -2\text{m} \leq y_j \leq 2\text{m}\}|. \quad (4.7)$$

Beschleunigung nach einem Haltevorgang Das lokale Maximum der Beschleunigung nach einem Haltevorgang ist ein weiteres Merkmal zur Klassifikation von Vorfahrtsregeln, das in bestehenden Ansätzen in dieser Form bisher nicht verwendet wurde. Die Motivation für dieses Merkmal ist der erwartete Unterschied des Wiederanfahrverhaltens bei unterschiedlichen Vorfahrtsregeln aufgrund der Beeinflussung durch weitere Verkehrsteilnehmer. Beispielsweise werden an Kreuzungspfaden mit der Regel *Vorfahrt gewähren* oder mit einem Stoppschild häufiger höhere positive Beschleunigungen beim Anfahrvorgang beobachtet im Vergleich zu Kreuzungen mit Lichtsignalanlage. Der Grund hierfür liegt darin, dass durch die höhere Beschleunigung ein Sicherheitspuffer zu möglichen Konflikten mit dem Querverkehr aufgebaut wird. Dies ist an Kreuzungspfaden mit Lichtsignalanlage nicht nötig. Das lokale Maximum der

Beschleunigung nach einem Haltevorgang $a_{\text{Start}}^{(i)}$ wird für eine Überfahrt ξ_i mit $N_i = |\xi_i|$ Datenpunkten berechnet zu

$$a_{\text{Start}}^{(i)} = \max(\{a_j^{(i)} \mid \hat{l}^{(i)} \leq j \leq N_i\}). \quad (4.8)$$

Relative Anzahl an Haltevorgängen Das Verhältnis der Anzahl an Überfahrten mit Haltevorgängen zur gesamten Anzahl an Überfahrten bildet ein zusätzliches Merkmal eines Kreuzungspfades für die Klassifikation von Vorfahrtsregeln. Bei Kreuzungspfaden mit der Regel *Vorfahrt* ist diese relative Anzahl an Haltevorgängen beispielsweise niedrig im Vergleich zu Pfaden mit einem Stoppchild. Das Verhältnis wird aus der Menge \mathcal{T}_{ea} der Überfahrten gebildet:

$$p_{\text{Stopp}} = \frac{|\{\xi_i \in \mathcal{T}_{ea} \mid \mathcal{T}_{\text{Stopp}}^{(i)} \neq \emptyset\}|}{|\mathcal{T}_{ea}|}. \quad (4.9)$$

Fahrtrichtung Die Differenz δ_{ea} zwischen der Ein- und Ausfahrtrichtung entspricht der Fahrtrichtung und liefert damit eine Aussage über die Abbiegerichtung des Pfades. Motivation für dieses Merkmal ist der mögliche Einfluss der Abbiegerichtung auf die übrigen Merkmale. Beispielsweise existiert bei Linksabbiegepfaden mit der Regel *Vorfahrt* eine vergleichsweise hohe relative Anzahl an Haltevorgängen, im Gegensatz zu Geradeauspfaden mit *Vorfahrt*. Die Differenz der Orientierungen wird berechnet gemäß:

$$\delta_{ea} = \text{atan2}(\sin(\varphi_a - \varphi_e), \cos(\varphi_a - \varphi_e)). \quad (4.10)$$

Die Umrechnung mit den trigonometrischen Funktionen dient zur Umgehung der Fallunterscheidung am Übergang zwischen 0 und 2π .

Standardisierung der Merkmale

Bei den meisten maschinellen Lernverfahren werden Metriken angewendet, um Distanzen zwischen unterschiedlichen Instanzen, in diesem Fall Kreuzungspfaden,

den, berechnen zu können. Eingangsgrößen in die Metriken sind die extrahierten Merkmale einer Instanz. Die sich ergebenden Distanzen sind dabei abhängig von der Skalierung und damit der Einheit einzelner Merkmale. Aus diesem Grund wird jeder einzelne Merkmalswert m_i durch den Mittelwert μ und die Standardabweichung σ über sämtliche Instanzen hinweg standardisiert gemäß

$$\hat{m}_i = \frac{m_i - \mu}{\sigma}. \quad (4.11)$$

Die resultierenden standardisierten Merkmale \hat{m}_i sind dadurch über alle Instanzen mittelwertfrei und besitzen eine Standardabweichung von Eins. In dem vorhandenen manuell klassifizierten realen Datensatz entsprechend Abbildung 4.1 sind die Standardabweichungen der beiden vorgestellten Merkmale $Q_{0.1}(N_{Vfz})$ und $Q_{0.1}(a_{Start})$ jeweils gleich Null. Das heißt, dass der Wert des Merkmals über alle Instanzen hinweg konstant ist, weshalb diese Merkmale für die Klassifikation nicht verwendet werden. Damit ergibt sich der Merkmalsvektor

$$\begin{aligned} \mathbf{f}_{VF} = \{ & \mu(\Delta t_{Stopp}), \sigma(\Delta t_{Stopp}), Q_{0.1}(\Delta t_{Stopp}), Q_{0.9}(\Delta t_{Stopp}), \\ & \mu(s_{Stopp}), \sigma(s_{Stopp}), Q_{0.1}(s_{Stopp}), Q_{0.9}(s_{Stopp}), \\ & \mu(v_{min}), \sigma(v_{min}), Q_{0.1}(v_{min}), Q_{0.9}(v_{min}), \\ & \mu(N_{Vfz}), \sigma(N_{Vfz}), Q_{0.9}(N_{Vfz}), \\ & \mu(a_{Start}), \sigma(a_{Start}), Q_{0.9}(a_{Start}), \\ & p_{Stopp}, \delta_{ea} \} \end{aligned} \quad (4.12)$$

für die Vorfahrtsregelklassifikation mit $|\mathbf{f}_{VF}| = 20$ Merkmalen.

4.3 Evaluation

Im folgenden Abschnitt wird eine Evaluation basierend auf einem manuell klassifizierten realen Datensatz entsprechend Abbildung 4.1 durchgeführt. Im Rahmen der Evaluation werden unterschiedliche Klassifikationsverfahren verglichen, verschiedene Aufteilungen der Vorfahrtsregeln in Klassen untersucht, die

Abhängigkeit der Klassifikationsgüte von der verwendeten Anzahl an Überfahrten dargestellt, die Relevanz der extrahierten Merkmale bestimmt, sowie der Mehrwert der neuartigen Merkmale aufgezeigt.

4.3.1 Vergleich von Klassifikationsverfahren

Auf den gegebenen Datensatz mit den beschriebenen 20 Merkmalen werden die bereits genannten Verfahren Random Forest¹, SVM², Neuronales Netz³ und ELM angewendet. Bei der SVM wird ein Gauß-Kern eingesetzt. Für das Neuronale Netz wird ein Feed-Forward-Netz mit zwei Schichten verwendet. Dabei besitzt die versteckte Schicht eine Sigmoid Übertragungsfunktion und die Ausgangsschicht eine Softmax Übertragungsfunktion. Für die versteckte Schicht der ELM wird ebenfalls eine Sigmoid Übertragungsfunktion gewählt. Basierend auf dem kompletten Datensatz werden die Hyperparameter der einzelnen Verfahren unter Anwendung einer Rastersuche optimiert. Tabelle 4.1 zeigt das Ergebnis dieser Optimierung.

Der folgende Vergleich der Klassifikationsverfahren basiert auf einer Kreuzvalidierung, wobei $N_{\text{Pfade}} = 637$ Validierungen durchgeführt werden. In jedem Validierungsschritt wird aus dem verfügbaren Datensatz ein Kreuzungspfad extrahiert, ein Klassifikator mit den restlichen Kreuzungspfaden trainiert und auf den extrahierten Kreuzungspfad angewendet. Das Gesamtergebnis wird über sämtliche Durchläufe hinweg ermittelt. Bei sämtlichen Verfahren bis auf die SVM werden Zufallsgeneratoren während der Trainingsphase angewendet. Daher wird die Kreuzvalidierung bei sämtlichen Verfahren mit Zufallsgenerator 50-mal wiederholt um die Stabilität und die Signifikanz der Unterschiede zwischen den Klassifikatoren zu beurteilen. Für den Vergleich der Performanz wird der verfügbare Datensatz in zwei Klassen aufgeteilt: LSA (positive Klasse) / keine LSA. Für jeden Durchlauf der Kreuzvalidierung eines Klassifikators wird als Güte-

¹ *TreeBagger* - MATLAB „Statistics and Machine Learning Toolbox“

² *svmtrain* - MATLAB „Statistics and Machine Learning Toolbox“

³ *patternnet* - MATLAB „Neuronal Network Toolbox“

Tabelle 4.1: Optimierte Hyperparameter der Klassifikationsverfahren

Verfahren	Hyperparameter	Wert
Random Forest	Anzahl an Bäumen N_{Tree}	100
	Minimale Instanzen im Blattknoten N_{minInst}	1
	Anzahl Variablen pro Baum N_{Var}	4
Neuronales Netz	Anzahl der Neuronen $N_{\text{Neur}}^{\text{NN}}$	96
SVM	Gauß-Kern Parameter γ	0.05
	Gewicht des Trainingsfehlers C	1
ELM	Anzahl der Neuronen $N_{\text{Neur}}^{\text{ELM}}$	100

maß die „Area Under Curve“ (AUC), also die Fläche unterhalb der zugehörigen Receiver-Operating-Characteristic-Kurve (ROC-Kurve) [72], berechnet. Zusätzlich wird für jede Kreuzvalidierung die mittlere Trainings- und Testdauer auf einem Rechner mit einer Intel Xeon CPU E5-1620, 3.60GHz und 32GB Arbeitsspeicher gemessen. Tabelle 4.2 zeigt die mittleren Ergebnisse und Abbildung 4.2 stellt die Streuung des AUC-Wertes aus 50 Durchläufen der Kreuzvalidierung dar. Die Ergebnisse der Klassifikatoren unterscheiden sich dabei jeweils statistisch signifikant unter Anwendung eines Welch-Tests und einem Signifikanzniveau von $\alpha = 0.1\%$. Abbildung 4.3 zeigt für die binäre Klassifikation die ROC-Kurven der verwendeten Klassifikatoren.




Bild 4.2: Vergleich der Klassifikatoren basierend auf 50 Kreuzvalidierungsdurchläufen. Die blaue Box kennzeichnet oberes und unteres Quartil, der senkrechte Strich innerhalb der Box markiert den Median. Die Antennen enden jeweils am letzten Wert der Daten, welcher innerhalb des 1.5-fachen des Interquartilsabstands liegt.

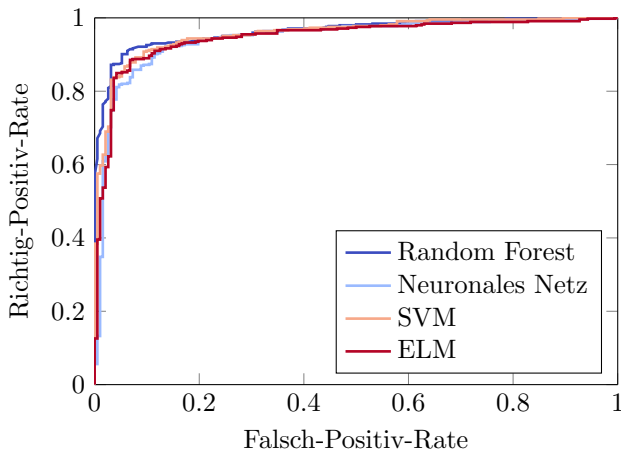


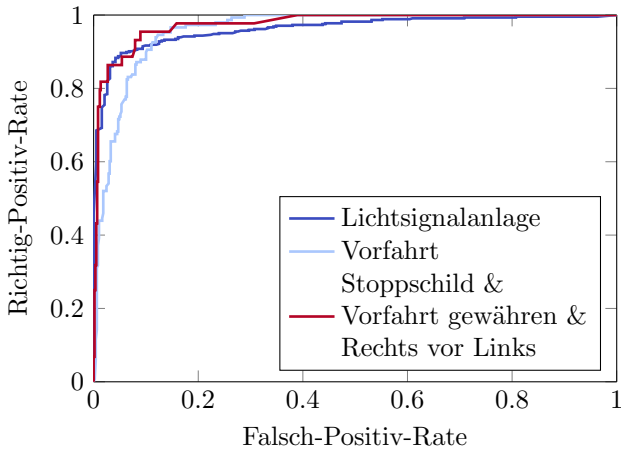
Bild 4.3: ROC-Kurven für den Vergleich unterschiedlicher Klassifikationsverfahren für die binäre Klassifikation LSA (positive Klasse) / keine LSA, basierend auf einer Kreuzvalidierung.

Tabelle 4.2: Vergleich Klassifikationsverfahren


Verfahren	AUC	Trainingsdauer / ms	Testdauer / ms
Random Forest	0.96267	709	248
SVM	0.95671	50	< 1
Neuronales Netz	0.94278	312	8
ELM	0.93703	20	< 1

4.3.2 Aufteilung der Vorfahrtsregeln in Klassen

Zusätzlich zur binären Klassenaufteilung der Vorfahrtsregeln werden diese in drei bzw. fünf Klassen unterteilt und jeweils die Klassifikationsgüte evaluiert. Dazu wird die Random Forest Methode verwendet. Abbildung 4.4 zeigt die resultierenden ROC-Kurven. Für die Erzeugung der ROC-Kurven wird für jede Klasse eine Auswertung einer binären Klassifikation durchgeführt, bei der sämtliche weiteren Vorfahrtsregeln einer gemeinsamen Klasse zugeordnet werden. Dabei ist zu berücksichtigen, dass die Vorfahrtsregeln in den vorhandenen Daten entsprechend Abbildung 4.1 verteilt sind. Für *Rechts vor Links* und *Stopp-schild* sind nur wenige manuell klassifizierte Beispielpfade vorhanden, weshalb die zugehörigen ROC-Kurven nur bedingt repräsentativ sind.



(a) Drei Klassen



(b) Fünf Klassen

Bild 4.4: „Receiver Operator Characteristic“ (ROC) Kurven für die Klassifikation von drei bzw. fünf Vorfahrtsregelklassen. Die Auswertung basiert auf einer Kreuzvalidierung. Zur Erzeugung der Kurven wird für jede einzelne Klasse ein binärer Klassifikator gegen alle anderen Klassen evaluiert („One versus all“).

4.3.3 Anzahl an Überfahrten

Zur Analyse der benötigten Anzahl an Überfahrten ist in Abbildung 4.5 der AUC-Wert für eine binäre Klassifikation mit der Methode Random Forest in Abhängigkeit von der verwendeten Anzahl an Überfahrten dargestellt. Dazu wurden 168 Kreuzungspfade mit einem Minimum von 60 Überfahrten aus den vorhandenen 637 Pfaden ausgewählt. Für jeden dieser Pfade wird eine Anzahl an Überfahrten insgesamt 30-mal zufällig ausgewählt und die beschriebenen Merkmale extrahiert. Eine Kreuzvalidierung auf den ausgewählten Pfaden ergibt für jeden Durchlauf und jede untersuchte Anzahl verwendeter Überfahrten eine Klassifikationsgüte. Die blauen Punkte in Abbildung 4.5 zeigen die jeweiligen AUC-Werte für die zufällige Auswahl an Überfahrten. Der rote Verlauf entspricht dem Mittel dieser Ergebnisse. Unter Anwendung eines Welch-Tests mit einem Signifikanzniveau von $\alpha = 0.1\%$ werden die AUC-Werte für unterschiedliche Anzahlen verwendeter Überfahrten paarweise verglichen. Dabei unterscheiden sich einzig die Ergebnisse für 30 Überfahrten signifikant von allen weiteren Ergebnissen.

4.3.4 Relevanz der Merkmale

Abbildung 4.6 zeigt die Relevanz der einzelnen verwendeten Merkmale. Für die Auswertung wurde eine binäre Klassifikation für die Klassen LSA / keine LSA mit der Random Forest Methode durchgeführt. Bei der Random Forest Methode wird üblicherweise das sogenannte *Bagging* angewendet, um die Stabilität des Modells zu verbessern und Überanpassung zu vermeiden [73]. Beim *Bagging* wird aus der vorhandenen Menge \mathcal{D} an Trainingsdaten mehrmals eine zufällige Untermenge \mathcal{D}_i extrahiert und darauf ein Klassifikator antrainiert. Bei der Random Forest Methode wird für jede Untermenge ein Entscheidungsbaum trainiert. Die vorgegebene Anzahl an Bäumen bestimmt damit die Anzahl an zufälligen Untermengen der Trainingsdaten. Die Menge der trainierten Entscheidungsbäume wird zu einem Ensemble zusammengefasst und ergibt den Random Forest.




Bild 4.5: AUC-Wert in Abhängigkeit von der verwendeten Anzahl an Überfahrten. Insgesamt wurden 168 Kreuzungspfade mit jeweils mindestens 60 Überfahrten verwendet. Die Punkte entsprechen den AUC-Werten von 30 einzelnen Kreuzvalidierungsdurchläufen für die entsprechende Anzahl verwendeter Überfahrten. Die rote Kurve zeigt den Verlauf des Mittelwerts der AUC-Werte.

Durch das Bagging ergibt sich bereits während des Trainings eines Random Forests die Möglichkeit, über den sogenannten Out-of-Bag-Fehler (OOB-Fehler) den Klassifikationsfehler zu schätzen. Dabei wird jedes einzelne Trainingsbeispiel $\beta_j \in \mathcal{D}$ mit einem Ensemble aus einer Untermenge aller Bäume klassifiziert, wobei in der Untermenge nur Entscheidungsbäume enthalten sind, bei deren Erzeugung das Trainingsbeispiel $\beta_j \in \mathcal{D}$ nicht verwendet wurde. Daraus ergibt sich über alle Trainingsdaten \mathcal{D} ein mittlerer Klassifikationsfehler, der OOB-Fehler.

Zur Bestimmung der Relevanz eines Merkmals werden die Merkmalswerte in sämtlichen Trainingsbeispielen permutiert und damit nutzlos für den Klassifikator. Anschließend wird der Random Forest Klassifikator auf die modifizierten Trainingsdaten angewendet und der OOB-Fehler bestimmt. Das Relevanzmaß ergibt sich aus der mittleren Zunahme des Klassifikationsfehlers normalisiert mit der Standardabweichung des Fehlers über sämtliche Bäume. Je höher die Zunahme des Klassifikationsfehlers, umso relevanter ist das entsprechende Merkmal. Diese Auswertung wurde insgesamt in 50 Trainingsläufen durchgeführt. In Ab-

bildung 4.6 ist die Verteilung der Ergebnisse für jedes Merkmal als Boxplot dargestellt, wobei die Merkmale nach dem Median der Ergebnisse sortiert sind. Zusätzlich zur relativen Relevanz der einzelnen Merkmale wird der Mehrwert der neuartigen Merkmale untersucht. Dazu wird die Klassifikationsgüte einer Klassifikation mit sämtlichen Merkmalen verglichen mit der Güte bei Verwendung von beschränkten Merkmalsmengen. Abbildung 4.7 zeigt die Verbesserung des AUC-Wertes durch die Verwendung neuartiger Merkmale. Dabei werden unterschiedliche Merkmalskonfigurationen verwendet und jeweils 50 Durchläufe der Kreuzvalidierung ausgeführt. Unter Anwendung des Welch-Tests ergibt die Verwendung der Vorderfahrzeug- und Beschleunigungsmerkmale einen statistisch signifikant besseren AUC-Wert mit einem Signifikanzniveau von $\alpha = 2\%$.




Bild 4.6: Relevanz der einzelnen Merkmale, gemessen über die mittlere Zunahme des Klassifikationsfehlers bei der Auswertung von Entscheidungsbäumen durch Permutation der Werte für das jeweilige Merkmal. Werte außerhalb der Antennen werden als Ausreißer (Kreuze) markiert.

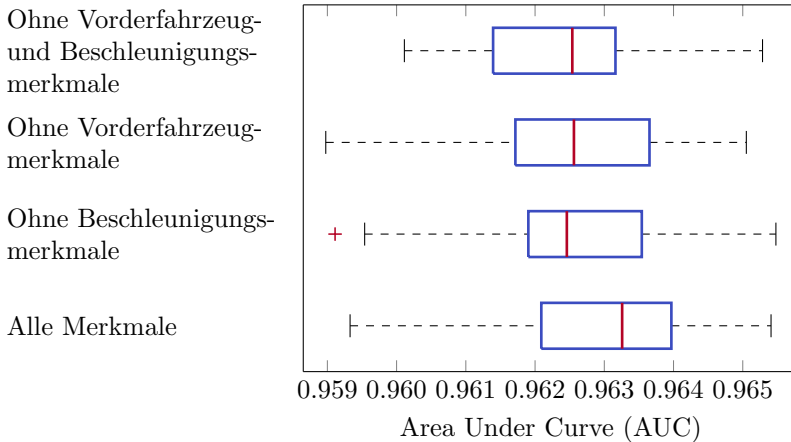


Bild 4.7: Vergleich des AUC-Wertes für unterschiedliche Merkmalskombinationen. Durch die Verwendung aller Merkmale werden die Ergebnisse im Mittel verbessert. Der Unterschied ist statistisch signifikant unter Anwendung des Welch-Tests mit $\alpha = 2\%$.

4.4 Diskussion

Die Evaluation der Klassifikation von Vorfahrtsregeln für Kreuzungspfade basierend auf realen Trajektorien- und Daten führt zu unterschiedlichen Schlussfolgerungen. Die Untersuchung unterschiedlicher Klassifikationsverfahren für eine binäre Klassifikation der Klassen LSA / keine LSA zeigt, dass für das gegebene Problem die Random Forest Methode die besten Ergebnisse liefert. Allerdings ist die Trainings- und Testdauer für diese Methode unter den angewendeten Verfahren am Längsten. Die Extreme Learning Maschine liefert eine deutlich kürzere Trainings- und Testdauer, wobei die Güte der Klassifikation niedriger ist im Vergleich zu den anderen Verfahren. Die Wahl eines geeigneten Verfahrens ist damit abhängig von den Anforderungen des Zielsystems.

Die ROC-Kurve der Random Forest Methode für die binäre Klassifikation in Abbildung 4.3 zeigt, dass mit den vorhandenen Daten beispielsweise eine Richtig-Positiv-Rate von 90% bei einer Falsch-Positiv-Rate von 5% erreicht wird. Damit liegt die Performanz des entwickelten Systems unterhalb den Werten aus der

in Abschnitt 1.2 vorgestellten Arbeit [58], in welcher eine Richtig-Positiv-Rate von 96 % bei einer Falsch-Positiv-Rate von 3 % erreicht wird. In der Arbeit [58] werden Vorfahrtsregeln mittels überwachtem Lernen unter Verwendung von gesammelten Bewegungsdaten von Smartphones klassifiziert. Dabei werden ausschließlich die Vorfahrtsregeln *LSA*, *Stoppschild* und Kreuzungen ohne explizite Regelung berücksichtigt. Dies setzt eine Vorfilterung der Beispielpfade und damit Vorwissen voraus. Die in der vorliegenden Arbeit zusätzlich verwendeten Regeln *Vorfahrt* und *Vorfahrt gewähren* verursachen aufgrund der höheren Ähnlichkeit des Fahrerverhaltens im Vergleich zu Lichtsignalanlagen eine niedrigere Performanz. Des Weiteren werden in dieser Arbeit Kreuzungspfade mit sämtlichen Fahrtrichtungen klassifiziert, im Gegensatz zur ausschließlichen Betrachtung von Kreuzungspfaden ohne Abbiegungen in [58]. Zusammengefasst bietet die in dieser Arbeit vorgestellte Klassifikation der Vorfahrtsregel an Kreuzungen im Vergleich zu dem Ansatz in [58] einen höheren Funktionsumfang bei niedrigerer Performanz.

Das Ergebnis der Auswertung der Klassifikation von Vorfahrtsregeln in Abbildung 4.4 zeigt, dass es möglich ist, mehrere Klassen zu unterscheiden. Allerdings ist dabei zu beachten, dass die Regeln *Vorfahrt gewähren*, *Rechts vor Links* und *Stoppschild* im vorhandenen Datensatz unterrepräsentiert sind, was aus der Verteilung in Abbildung 4.1 ersichtlich ist.

Zur Untersuchung der Abhängigkeit der Klassifikationsgüte von der verwendeten Anzahl an Überfahrten dient eine Untermenge an 168 Kreuzungspfaden mit mindestens 60 Überfahrten aus dem vorhandenen Datensatz als Grundlage. In dem vorgestellten Verfahren werden statistische Merkmale verwendet. Eine höhere Anzahl an Überfahrten liefert aus diesem Grund eine exaktere Schätzung der Merkmalswerte, weshalb eine höhere Klassifikationsgüte erwartet wird. Die Auswertung in Abbildung 4.5 zeigt, dass sich die Klassifikationsgüte mit der Verwendung von mehr als 40 Überfahrten nicht mehr signifikant ändert. Dabei ist zu berücksichtigen, dass die Klassifikationsgüte insgesamt geringer ist im Vergleich zu den vorangehenden Auswertungen. Der Grund hierfür liegt darin,

dass mit 168 Kreuzungspfaden nur etwa ein Viertel aller Kreuzungspfade für die Auswertung verwendet wurde.

Die Auswertung der Merkmalsrelevanz in Abbildung 4.6 ergibt, dass die Wahrscheinlichkeit für einen Haltevorgang während einer Kreuzungsüberfahrt p_{Stopp} das wichtigste Merkmal für die binäre Klassifikation LSA / keine LSA ist. Des Weiteren zählen die statistischen Werte der Dauer eines Haltevorgangs, das 90 %-Quantil $Q_{0.9}(\Delta t_{\text{Stopp}})$, der Mittelwert $\mu(\Delta t_{\text{Stopp}})$ und die Standardabweichung $\sigma(\Delta t_{\text{Stopp}})$ zu den wichtigsten Merkmalen. Zusätzlich ist das 90 %-Quantil $Q_{0.9}(N_{\text{Vfz}})$ der Anzahl an Vorderfahrzeugen bei einem Stopp eines der wichtigsten fünf Merkmale. Die Relevanz der neuartigen Merkmale wird durch die Auswertung in Abbildung 4.7 bestätigt. Durch die Verwendung der Statistiken über die Beschleunigung beim Anfahrvorgang und die Zahl der Vorderfahrzeuge beim Stopp steigt die Klassifikationsgüte statistisch signifikant. Allerdings ist der absolute Unterschied mit einer Zunahme der AUC von 0.01 gering.

Die aus diesem Kapitel erzeugten Informationen über Vorfahrtsregeln an Kreuzungen werden in Kapitel 7 verwendet für die Umsetzung des Systems zur automatisierten Längsregelung an Kreuzungen mit einer Lichtsignalanlage. Zur Erhöhung der Verfügbarkeit eines derartigen Systems muss in nachfolgenden Arbeiten eine größere Anzahl an Daten gesammelt werden. Damit wird die Güte der Klassifikation erhöht, vor allem für Klassen die im vorliegenden Datensatz unterrepräsentiert sind.

5 Haltlinienpositionen an Straßenkreuzungen mit Lichtsignalanlage

An Kreuzungspfaden mit der Vorfahrtsregel *Lichtsignalanlage* oder *Stoppschild* existiert eine definierte Position entlang der zugehörigen Fahrstreifen, an welcher der Fahrer bei entsprechendem Gebot anhalten muss. Diese Position ist meistens anhand einer durchgezogenen Straßenmarkierung quer zur Fahrtrichtung gekennzeichnet. Für urbane Fahrerassistenzsysteme wie eine innerstädtische automatisierte Längsregelung, siehe Abschnitt 1.1, ist für automatische Haltevorgänge eine relative Positionierung zur Haltelinie nötig. In diesem Kapitel werden Methoden zur Schätzung der Haltelinienposition anhand Positions- und Geschwindigkeitsdaten von Fahrzeugflotten entwickelt. Dabei liegt der Fokus auf Kreuzungspfaden mit einer Lichtsignalanlage. Grundsätzlich sind die Verfahren allerdings auch auf andere Haltelinien wie an Stoppschildern oder Fußgängerüberwegen übertragbar.

Basis für die folgenden Methoden sind Haltepositionen, die aus den Überfahrten $\xi_i \in \mathcal{T}_{ea}$ eines Kreuzungspfades mit e -ter Einfahrt und a -ter Ausfahrt extrahiert werden. Für jede Kreuzungsüberfahrt $\xi_i = (\kappa_1^{(i)}, \kappa_2^{(i)}, \dots, \kappa_{N_i}^{(i)})$ sind die Datenpunkte $\kappa_j^{(i)} = (\mathbf{x}_j^{(i)}, v_j^{(i)}, a_j^{(i)}, \varphi_j^{(i)}, t_j^{(i)})$ der Haltevorgänge definiert über die Indexmenge

$$\mathcal{I}_{\text{Stopp}}^{(i)} = \{j \mid 1 \leq j \leq N_i \wedge |v_j^{(i)}| < 1 \text{ m/s}\}. \quad (5.1)$$

Ein Haltevorgang entspricht einem zusammenhängenden Intervall $[k, l] \subseteq \mathcal{I}_{\text{Stopp}}^{(i)}$ an Indizes der Datenpunkte einer Überfahrt. Zur Bestimmung der Haltelinienposition werden dabei ausschließlich Haltevorgänge mit einer Mindestlänge von

$t_l^{(i)} - t_k^{(i)} \geq 10\text{s}$ verwendet. Die Menge $\mathcal{SP}^{(i)}$ der Haltepositionen einer Überfahrt ξ_i ist definiert als Menge der jeweils letzten Positionen $\mathbf{x}_c^{(i)}$ der Haltevorgänge $\mathcal{S}^{(i)}$ (Gleichung 4.2) mit den linear geordneten Indizes $[b, c]$:

$$\mathcal{SP}^{(i)} = \{\mathbf{x}_c^{(i)} \mid [b, c] \in \mathcal{S}^{(i)} \wedge t_c^{(i)} - t_b^{(i)} \geq 10\text{s}\}. \quad (5.2)$$

Für einen Kreuzungspfad ergibt sich eine Menge

$$\mathcal{SP} = \bigcup_i \mathcal{SP}^{(i)} \quad (5.3)$$

aus den Mengen $\mathcal{SP}^{(i)}$ der Haltepositionen sämtlicher Überfahrten $\xi_i \in \mathcal{T}_{ea}$ eines Kreuzungspfades.

5.1 Schätzung der Haltelinienposition durch die Dichte von Haltepunkten

Eine Möglichkeit, die Haltelinienposition eines Kreuzungspfades zu schätzen, ist die Verwendung von Merkmalen der Dichte der Haltepunkte. Abbildung 5.1 zeigt eine zweidimensionale Dichteschätzung von 180 Haltepositionen an einer exemplarischen Kreuzungseinfahrt. Im Rahmen der entwickelten Methode werden die zweidimensionalen Haltepositionen \mathcal{SP} auf den ermittelten mittleren Kreuzungspfad entsprechend Abschnitt 3.2 projiziert. Die Dichte $f_{ea}(s_{\text{Stopp}})$ der eindimensionalen Haltepositionen s_{Stopp} entlang des Pfades von der Einfahrt e zur Ausfahrt a wird über einen Kerndichteschätzer mit Gaußkern und einer Bandbreite von 2m angenähert.

Ein mögliches Merkmal zur Schätzung der Haltelinienposition s_H ist das Maximum der geschätzten Dichte. Das Maximum entspricht der Position an welcher die meisten Fahrzeuge anhalten:

$$s_H = \arg \max f_{ea}(s_{\text{Stopp}}). \quad (5.4)$$

Bei jeder Rotphase einer Lichtsignalanlage mit wartenden Fahrzeugen hält mindestens ein Fahrzeug an der Haltelinie an. Die Wahrscheinlichkeit für haltende Fahrzeuge in folgenden Positionen der Warteschlange sinkt. Wird eine hinreichende Anzahl zufälliger Fahrzeuge aus der Warteschlange beobachtet, liegt das Maximum der Dichte der beobachteten Haltepunkte im Mittelwert der Positionen der beobachteten ersten Fahrzeuge in der Schlange. Da die meisten Fahrzeuge nicht direkt an der Haltelinie halten, ist von einer systematischen Abweichung des Maximums der Dichte zur Haltelinienposition auszugehen.

Neben dem Maximum der Dichte bietet die Verwendung der Position des höchsten negativen bzw. des minimalen Gradienten der geschätzten Dichte in Fahrtrichtung eine weitere Möglichkeit für die Schätzung der Haltelinienposition:

$$s_H = \arg \min f'_{ea}(s_{\text{Stopp}}). \quad (5.5)$$

Dieser Methode liegt die Annahme zu Grunde, dass nur sehr wenige Fahrzeuge direkt nach der Haltelinie anhalten. Deshalb ist ein hoher negativer Gradient der Verteilung der Haltepositionen direkt nach der Haltelinienposition zu erwarten.




Bild 5.1: Kerndichteschätzung für 180 Haltepositionen an einer exemplarischen Kreuzungseinfahrt. Die grauen Kreuze entsprechen den einzelnen Haltepositionen. Die weiße Linie markiert die tatsächliche Haltelinie. Der schwarze Kreis kennzeichnet die Position mit der höchsten geschätzten Dichte der Haltepositionen. Bilder ©2015, DigitalGlobe, GeoBasis-DE/BKG, GeoContent.

5.2 Schätzung der Haltelinienposition durch eine mikroskopische Verkehrssimulation

Ein Nachteil der Schätzung der Haltelinienposition anhand des Maximums oder des minimalen Gradienten ist die geringe Robustheit gegenüber Ausreißern der Positionsmessungen. An Kreuzungspfaden mit einer geringen Anzahl an Beobachtungen steigt die Wahrscheinlichkeit, dass das Maximum oder der minimale Gradient durch Ausreißer bestimmt werden. In diesem Abschnitt wird eine robuste Methode gegenüber Ausreißern vorgestellt, welche auf der mikroskopischen Verkehrssimulation *Simulation of Urban Mobility* (SUMO) [74] basiert und an die entwickelten Methoden der eigenen Veröffentlichungen [10, 75] angelehnt ist.

Mit Hilfe der mikroskopischen Verkehrssimulation SUMO ist es möglich, Warteschlangen an Kreuzungen mit Lichtsignalanlage zu simulieren. Dazu wird die Topologie und Geometrie von realen Kreuzungen aus OSM importiert. Eine Kreuzung wird im Rahmen der Methode mit unterschiedlichen Parametern simuliert. Für verschiedene Kreuzungstopologien werden dabei Werte für den Verkehrsfluss q pro Kreuzungsarm angenommen. Außerdem werden die Positionen der Haltelinie s_H für den jeweiligen Kreuzungspfad variiert. Zusätzlich wird die Ungenauigkeit der Positionsschätzungen der realen Daten mit einem weißen Rauschen auf den simulierten Positionsdaten mit dem Parameter σ_S angenähert. Für einen Simulationsdurchlauf k wird damit ein Parametersatz $\theta^{(k)} = (s_H^{(k)}, q^{(k)}, \sigma_S^{(k)})$ gewählt.

Aus den Bewegungsdaten der simulierten Fahrzeuge wird anschließend die Menge an Haltepositionen $\mathcal{SP}_{\text{Sim}}^{(k)}$ entsprechend Gleichung (5.3) extrahiert. Daran wird anhand der Kreuzungsgeometrie die jeweilige Entfernung s_{Stopp} der Haltepositionen zum Kreuzungsmittelpunkt sowie deren Verteilung $f_{\text{Sim}}^{(k)}(s_{\text{Stopp}})$ bestimmt. Ebenso wird die Verteilung $f_{\text{Real}}(s_{\text{Stopp}})$ aus den tatsächlich beobachteten Daten erzeugt. Die Verteilung aus der Simulation, die der tatsächlich beobachteten Verteilung basierend auf einem Maß für die Unterschiedlichkeit am ähnlichsten ist, wird einschließlich der ihr zugeordneten Parameter

$\theta^{(k_{\text{opt}})} = (s_{\text{H}}^{\text{opt}}, q^{\text{opt}}, \sigma_{\text{S}}^{\text{opt}})$ als zutreffend ausgewählt. Durch Ermittlung der wahrscheinlichsten Verschiebung zwischen den beiden Verteilungen wird anhand der in der Simulation gewählten Haltelinienposition s_{H} auf die tatsächliche Haltelinienposition geschlossen.

Zur Berechnung der Unterschiedlichkeit zwischen den Wahrscheinlichkeitsdichten werden unterschiedliche Maße entsprechend Abschnitt 2.2 verwendet und gegeneinander evaluiert. Die Maße werden jeweils auf diskretisierten Wahrscheinlichkeitsdichteverteilungen $P(\zeta)$ der Haltepositionen angewendet. Die Diskretisierung erfolgt in 1 m Intervallen:

$$P(\zeta) = \int_{s_{\text{Stopp}}=\zeta-0.5\text{ m}}^{\zeta+0.5\text{ m}} f(s_{\text{Stopp}}) ds_{\text{Stopp}}. \quad (5.6)$$

Der Wertebereich der diskreten Positionsvariable $\zeta \in \mathbb{N}$ wird relativ zum Kreuzungsmittelpunkt zu $\zeta \in [-100, 50]\text{ m}$ gewählt. Es werden die diskreten Verteilungen $P_{\text{Real}}(\zeta)$ für die realen Daten sowie $P_{\text{Sim}}^{(k)}(\zeta)$ für jeden Simulationsdurchlauf k gebildet.

Unter Verwendung der Maße für die Unterschiedlichkeit ergibt sich die Schätzung der optimalen Parameter $\theta^{(k_{\text{opt}})} = (s_{\text{H}}^{\text{opt}}, q^{\text{opt}}, \sigma_{\text{S}}^{\text{opt}})$ durch Minimierung des Unterschieds zwischen den Verteilungen der simulierten Haltepositionen und den realen Haltepositionen. Die Minimierung ergibt den optimalen Simulationsdurchlauf k_{opt} und den zugehörigen Parametersatz

$$k_{\text{opt}} = \arg \min_k \text{dist}(P_{\text{Real}}(\zeta), P_{\text{Sim}}^{(k)}(\zeta)). \quad (5.7)$$


Zur Bestimmung des Unterschieds werden die in Abschnitt 2.2 eingeführten Maße *L1-Distanz* (L1), *Kolmogorov-Smirnov Distanz* (KS), *Kullback-Leibler-Divergenz* (KL) und *Earth Movers Distanz* (EMD) verwendet.

Abbildung 5.2 zeigt ein Beispiel für die Bestimmung der Haltelinienposition durch einen simulierten Kreuzungspfad. Die Verteilung der Haltepositionen relativ zum Kreuzungsmittelpunkt in Abbildung 5.2a wird aus 68 realen Haltevorgängen erstellt. Es ist ersichtlich, dass sich bei der Wahl einer Balkenbreite


von einem Meter etwa 10m vor der tatsächlichen Haltelinienposition zufällig ein Maximum ergibt. Unter Anwendung des Ansatzes, der auf dem Maximum der Dichte der Haltepositionen basiert, ist das Ergebnis der Schätzung der Haltelinienposition für diese Eingangsdaten fehlerhaft. Durch den Vergleich mit simulierten Verteilungen dient die gesamte Verteilung der realen Daten als Informationsgrundlage, wodurch die Robustheit gegenüber Ausreißern erhöht wird. Diese Aussage wird durch die Verteilung der simulierten Haltepositionen mit dem geringsten Unterschied in Abbildung 5.2b bestätigt. Trotz der ungünstigen Verteilung aus den realen Daten ist eine robuste Haltelinien-schätzung mit einem Fehler von unter einem Meter möglich.

Zusätzlich ist in Abbildung 5.2c eine simulierte Verteilung mit großem Unterschied zu den realen Daten dargestellt. Die Breite der Verteilung vor der Haltelinie ist im Vergleich zu den realen Daten geringer, was auf zu kurze Warteschlangen und damit einen zu niedrigen Verkehrsfluss hindeutet. Das Maximum der Verteilung ist außerdem lateral verschoben zum Maximum der realen Daten. Die Ursache darin liegt in der um 20m abweichenden Haltelinienposition. Zusätzlich deuten die Form der Verteilung und der hohe Anteil an Haltepositionen hinter der Haltelinie darauf hin, dass die Positionen stark verrauscht sind. Auch diese Eigenschaft ist in den realen Daten nicht zu erkennen. Die simulierten Parameter weichen von den realen Parametern ab. Daraus ergibt sich ein großer Unterschied der simulierten Verteilung zur Verteilung der realen Daten.


Die Simulation des Verkehrs an einer Kreuzung ist sehr zeitaufwändig. Aus diesem Grund wird im Rahmen dieser Arbeit nur eine prototypische Kreuzung mit unterschiedlichen Parametern simuliert. Das Ergebnis ist eine Menge an Wahrscheinlichkeitsdichten der simulierten Haltepositionen $P_{\text{Sim}}^{(k)}(\zeta)$ und die zugehörigen Parametersätze $\theta^{(k)} = (s_{\text{H}}^{(k)}, q^{(k)}, \sigma_{\text{S}}^{(k)})$. Die prototypischen Verteilungen der Haltepositionen für diese bestimmte Kreuzung werden jeweils zur Schätzung der Haltelinienposition für unbekannte Kreuzungspfade verwendet.



(a) Verteilung der Haltepositionen aus den realen Überfahrten



(b) Verteilung der Haltepositionen des Prototyps mit geringstem Unterschied



(c) Verteilung der Haltepositionen eines beliebigen Prototyps

Bild 5.2: Beispiel für eine Schätzung der Haltelinienposition durch die mikroskopische Verkehrssimulation eines Kreuzungspfades. Die Haltelinie befindet sich in der Realität bei $\zeta = -20.98$ m, entsprechend der schwarzen gestrichelten Linie. Die verwendeten Parameter der Simulation wurden zu $\theta^{(k_{\text{opt}})} = (s_{\text{H}}^{\text{opt}} = -20.00$ m, $q^{\text{opt}} = 940$ Fzg/h, $\sigma_{\text{S}}^{\text{opt}} = 2$ m) und $\theta^{(k)} = (s_{\text{H}}^{(k)} = -40.00$ m, $q^{(k)} = 480$ Fzg/h, $\sigma_{\text{S}}^{(k)} = 8$ m) gesetzt. Die jeweilige Haltelinienposition ist als schwarze gestrichelte Linie dargestellt.

Tabelle 5.1: Anzahl Kreuzungspfade für die Auswertung der Schätzung der Haltelinienposition

N_{SP}	≥ 10	≥ 20	≥ 30	≥ 40	≥ 50	≥ 60
Anzahl Pfade	233	99	47	24	16	12

5.3 Evaluation

In diesem Abschnitt werden die vorgestellten Ansätze zur Schätzung der Haltelinienposition

- Maximum der Dichte der Haltepositionen,
- minimaler Gradient der Dichte der Haltepositionen
- und mikroskopische Verkehrssimulation

evaluiert. Grundlage für die Evaluierung sind 233 Kreuzungspfade, für die mindestens 10 Haltevorgänge in der Datenbasis vorhanden sind. Wird eine größere Menge an Haltepositionen vorausgesetzt, verringert sich die Anzahl verfügbarer Kreuzungspfade entsprechend Tabelle 5.1.

Zudem wird für jeden Kreuzungspfad eine Haltelinienposition aus Google Maps Luftbildern als Referenz für die Auswertung manuell ermittelt. Dabei ist zu erwarten, dass die ermittelten Referenzpositionen fehlerbehaftet sind, da die von Google zur Verfügung gestellten Luftbilder nicht exakt absolut referenziert sind. Im Raum München wurde der Fehler stichprobenartig durch Messungen mit einer hochgenauen Referenzplattform mittels DGPS zur absoluten Positionsmessung¹ überprüft.

Abbildung 5.3 zeigt vier Referenzmessungen einer Kreuzung in München. Eine Auswertung des Fehlers des georeferenzierten Abbilds der Haltelinie im Satellitenbild ergibt in diesem Fall eine Abweichung von etwa 0.7 m nach Norden und

¹ Die Genauigkeit des Systems ist mit $\sigma = 0.02$ m angegeben.

etwa 0.1 m nach Osten. Weitere Stichproben im Raum München ergeben ähnliche Abweichungen. Zur Evaluierung der im Rahmen dieser Arbeit ermittelten Haltelinienpositionen ist die Genauigkeit der Satellitenbilder ausreichend.




Bild 5.3: Referenzmessungen von Haltelinienpositionen zur Bewertung der Eignung von Google Satellitenbildern zur manuellen Ermittlung einer Grundwahrheit. Die gemessenen Haltelinienpositionen sind jeweils als weißes Kreuz umrahmt von einem weißen Kreis dargestellt. Bilder ©2015, DigitalGlobe, GeoBasis-DE/BKG, GeoContent.

5.3.1 Genauigkeit der Haltelinien­schätzung durch das Maximum der Dichte der Haltepositionen

Abbildung 5.4 zeigt die Genauigkeit der Schätzung der Haltelinienposition anhand des Maximums der Dichte sämtlicher Haltepositionen eines Kreuzungspfades in Form eines Boxplots. Die Abbildung enthält mehrere Evaluierungen mit unterschiedlicher Anzahl verwendeter Haltepositionen. Für jede einzelne Box werden sämtliche Kreuzungspfade mit mehr als N_{SP} Haltepositionen, unter Verwendung aller verfügbaren Haltepositionen, ausgewertet. Dadurch ergibt sich für jede Box eine unterschiedliche Anzahl an Kreuzungspfaden entsprechend Tabelle 5.1.

Die Auswertung zeigt, dass sich der Fehler ab einer Anzahl von mehr als 30 Haltepositionen innerhalb eines Intervalls von etwa $[-20, 0]$ m stabilisiert. Dabei liegt der Median des Fehlers nahezu konstant bei -5 m, was zum einen darin begründet liegt, dass eine Vielzahl der Fahrzeuge mit einem gewissen Puffer vor der Haltelinie anhält. Zum anderen ist das Maximum der Dichte weiter verschoben, da mehr Haltepositionen von Fahrzeugen in zweiter Reihe existieren als Haltepositionen nach der Haltelinie. Durch die entsprechend Abschnitt 5.1 gewählte Bandbreite von 2 m wirken sich auch Fahrzeuge in zweiter Reihe auf das Ergebnis aus. Zur Verbesserung der Haltelinienpositionsschätzung ist es möglich, eine konstante Abweichung zu schätzen und dadurch die Haltelinienposition zu korrigieren.

5.3.2 Genauigkeit der Haltelinien­schätzung durch das Minimum des Gradienten der Dichte der Haltepositionen in Fahrtrichtung

Abbildung 5.5 zeigt die Genauigkeit der Schätzung der Haltelinienposition anhand des minimalen Gradienten der Dichte der Haltepositionen in Fahrtrichtung eines Kreuzungspfades als Boxplot. Die Auswertung erfolgt äquivalent zur vorhergehenden Auswertung unter Verwendung der gleichen Datenbasis. Damit ist Tabelle 5.1 auch für diese Auswertung gültig.




Bild 5.4: Fehler der Haltelinienpositionsschätzung anhand des Maximums der Wahrscheinlichkeitsdichte der Haltepositionen abhängig von der Anzahl verwendeter Haltepositionen N_{SP} . Der rote Strich markiert den Median, die blaue Box kennzeichnet oberes und unteres Quartil. Die Antennen enden jeweils am letzten Wert der Daten, welcher innerhalb des 1.5-fachen des Interquartilsabstands liegt. Werte außerhalb der Antennen werden als Ausreißer (rote Kreuze) markiert.

Die Ergebnisse zeigen, dass sich der Fehler auch bei dieser Methode ab einer Anzahl von mehr als 30 Haltepositionen stabilisiert. Allerdings ist das Intervall des Fehlers mit etwa $[-4,5]$ m kleiner. Der Median des Fehlers liegt nahezu konstant bei 1 m. Dabei ist es wiederum möglich, die konstante Abweichung des Fehlers zu schätzen und die Haltelinienpositionsschätzung damit zu korrigieren.

5.3.3 Genauigkeit der Haltelinien-schätzung durch eine mikroskopische Verkehrssimulation

Der dritte Ansatz basiert auf dem Vergleich der Verteilung der Haltepositionen aus den gesammelten Positionsdaten mit Verteilungen aus einer mikroskopischen Verkehrssimulation entsprechend dem in Abschnitt 5.2 vorgestellten Verfahren. Abbildung 5.6 zeigt die erreichten Genauigkeiten unter Anwendung der verschiedenen Maße. Es ist ersichtlich, dass sich die Ergebnisse für unterschiedliche Maße nicht signifikant unterscheiden. Das beste Ergebnis wird jedoch unter Verwendung der Kolmogorov-Smirnov Distanz erreicht. Aus diesem Grund wird dieses Distanzmaß für die weiteren Auswertungen verwendet. Abbildung 5.7 zeigt die Auswertung der Genauigkeit für die Schätzung der Haltelinienposition für den Ansatz der mikroskopischen Verkehrssimulation. Auch für diese Auswertung entspricht die Anzahl an Kreuzungspfaden den Werten in Tabelle 5.1. Die Ergebnisse zeigen, dass die Ausreißer ebenfalls ab einer Anzahl von mehr als 30 verwendeten Haltepositionen signifikant abnehmen. Der Interquartilbereich des Fehlers ist mit etwa $[-3.5, 5]$ m vergleichbar mit dem entsprechenden Intervall des Ansatzes, der auf dem Gradienten der Dichte an Haltelinienpositionen in Fahrtrichtung basiert. Der Median des Fehlers liegt im Durchschnitt bei etwa 1 m. Zur Verbesserung des Ergebnisses ist es äquivalent zum vorherigen Ansatz möglich, die Haltelinienpositionsschätzung um diese geschätzte konstante Abweichung zu korrigieren.




Bild 5.5: Fehler der Haltelinienpositionsschätzung anhand des minimalen Gradienten der Wahrscheinlichkeitsdichte der Haltepositionen in Fahrtrichtung abhängig von der Anzahl verwendeter Haltepositionen N_{SP} .

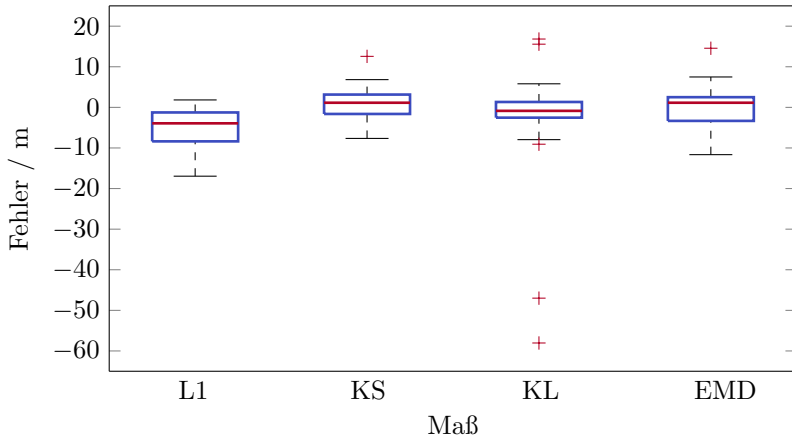


Bild 5.6: Fehler der Haltelinienpositionsschätzung unter Verwendung des Ansatzes der mikroskopischen Verkehrssimulation mit den unterschiedlichen Maßen *L1-Distanz* (L1), *Kolmogorov-Smirnov Distanz* (KS), *Kullback-Leibler-Divergenz* (KL) und *Earth Movers Distanz* (EMD). Grundlage für die Auswertung sind 47 Kreuzungspfade mit mehr als 30 Haltepositionen, $N_{SP} \geq 30$.

5.3.4 Vergleich der entwickelten Methoden zur Schätzung der Haltelinienposition

Abbildung 5.8 zeigt einen direkten Vergleich der Genauigkeiten der drei vorgestellten Ansätze. Für den Ansatz mit Verwendung einer mikroskopischen Verkehrssimulation wird die *Kolmogorov-Smirnov Distanz* verwendet. Grundlage für die Auswertung sind insgesamt 99 Kreuzungspfade, für die jeweils mindestens 20 Haltepositionen im vorliegenden Datensatz vorhanden sind. Zum Test der Robustheit der Ansätze gegenüber einer geringen Datengrundlage werden für jeden Kreuzungspfad nur 10 Haltepositionen zufällig ausgewählt und verwendet. Tabelle 5.2 zeigt die Anzahl der Ausreißer, den Interquartilsabstand und die mittlere Ausführzeit für die unterschiedlichen Verfahren zur Schätzung einer Haltelinienposition. Die Laufzeitmessung wurde auf einem Rechner mit einer Intel Xeon CPU E5-1620, 3.60GHz und 32GB Arbeitsspeicher durchgeführt.




Bild 5.7: Fehler der Haltelinienpositionsschätzung unter Verwendung des Ansatzes der mikroskopischen Verkehrssimulation abhängig von der Anzahl verwendeter Haltepositionen N_{SP} .




Bild 5.8: Vergleich der Ansätze zur Schätzung der Haltelinienposition. Grundlage der Auswertung sind 99 Kreuzungspfade, für die mindestens 20 Haltepositionen vorhanden sind. Aus allen Haltepositionen werden jeweils 10 zufällig gewählt und zur Schätzung verwendet.

Tabelle 5.2: Vergleich der Ansätze

Verfahren	Anzahl Ausreißer	Interquartilsabstand / m	Ausführzeit / ms
Maximum der Dichte	7	9.45	2
Minimaler Gradient	15	6.48	2
Mikroskopische Verkehrssimulation	4	9.86	11020

5.4 Diskussion

Der direkte Vergleich der Ansätze zur Bestimmung der Haltelinienposition in Abbildung 5.8 und Tabelle 5.2 ergibt, dass sich die Verfahren in ihrer Genauigkeit nicht signifikant unterscheiden. Der Ansatz, der auf dem Maximum der Dichte der Haltepositionen basiert, weist mit 6.8m die größte Abweichung des Medians der Schätzungen zur Grundwahrheit auf. Es ist jedoch möglich, diese Abweichung für weitere Schätzungen zu berücksichtigen und damit zu korri-

gieren. Außerdem besitzt der Ansatz einen größeren Interquartilsabstand von 9.45m im Vergleich zum Ansatz des minimalen Gradienten.

Der Ansatz, der auf einer mikroskopischen Verkehrssimulation basiert, ist im Vergleich zu den anderen Ansätzen robuster, da nur vier Ausreißer vorhanden sind. Im Gegensatz sind bei dem Ansatz, der auf dem Maximum der Dichte von Haltepositionen basiert, sieben Ausreißer und bei dem Ansatz der auf dem minimalen Gradienten der Dichte basiert, 15 Ausreißer vorhanden. Allerdings ergibt der Ansatz des minimalen Gradienten in Fahrtrichtung mit 6.48m einen kleineren Interquartilsabstand im Vergleich zu den 9.86m der mikroskopischen Verkehrssimulation und somit eine niedrigere Streuung der Ergebnisse. Die vorangehenden Auswertungen der einzelnen Ansätze zeigen, dass die Ausreißer, unabhängig vom gewählten Ansatz, ab etwa mindestens 30 verwendeten Haltepositionen signifikant abnehmen.

Neben dem Nachteil der geringeren Robustheit der dichtebasierten Ansätze haben diese jedoch die Vorteile einer einfacheren Umsetzung sowie einer deutlich kürzeren Ausführzeit. Für die Schätzung einer Haltelinienposition sind bei den dichtebasierten Ansätzen jeweils nur 2ms nötig, wohingegen der Ansatz, der auf einer mikroskopischen Verkehrssimulation basiert, eine Laufzeit von 11020ms benötigt.

Die Auswertungen ergeben, dass die Wahl des Ansatzes zur Bestimmung von Haltelinienpositionen abhängig von den Anforderungen des Systems ist. Für eine robuste Schätzung mit wenigen Ausreißern ist das Verfahren, das auf einer mikroskopischen Verkehrssimulation basiert, eine geeignete Wahl. Für den Fall, dass die Laufzeit der Schätzung im Vordergrund steht, sind die Verfahren, die auf den Dichten der Haltepositionen basieren, bevorzugt zu wählen. Der Ansatz, der auf dem Maximum der Dichte an Haltepositionen basiert, hat gegenüber dem gradientenbasierten Verfahren den Vorteil einer geringeren Anzahl an Ausreißern. Allerdings geht damit der Nachteil einer höheren Streuung der Ergebnisse einher, was anhand des Interquartilsabstands ersichtlich ist.

Zusammenfassend wurde in dieser Arbeit gezeigt, dass die Bestimmung von Haltelinienpositionen aus Flottendaten durch unterschiedliche Methoden mög-

lich ist. Abhängig von der verfügbaren Anzahl an Haltepositionen, wird mit der Verwendung von herkömmlichen GPS-Systemen zur Positionsmessung eine Genauigkeit von bis zu $[-3.5, 5]$ m erreicht. Im Vergleich zum aktuellen Stand der Technik, stellt die automatisierte Ermittlung von Haltelinienpositionen eine neuartige Anwendung für die Kartenerstellung aus Flottendaten dar.

6 Lichtsignalgruppen an Kreuzungseinfahrten

Für Assistenzsysteme mit einer höheren Automatisierung der Fahraufgabe im urbanen Bereich ist die Kenntnis des Zustandes von Lichtsignalanlagen ein wichtiger Bestandteil. Dazu existieren in der Literatur bereits unterschiedliche Ansätze. Eine Möglichkeit ist die Ausrüstung von Lichtsignalanlagen mit Kommunikationseinheiten wie in [76] und [77] vorgeschlagen wird. Diese Methode erfordert hohe Investitionen in die Infrastruktur. Des Weiteren beschäftigten sich bereits mehrere Arbeiten mit der kamerabasierten Erkennung des Signalzustandes von Lichtsignalanlagen [78, 79, 80, 81, 82, 59, 83, 84, 85]. Zusätzlich zum Signalzustand ist es ebenfalls möglich die relative Position der einzelnen erkannten Lichtsignale kamerabasiert zu schätzen [86].

Eine Herausforderung bei einer kamerabasierten Lichtsignalzustandserkennung ist die korrekte Zuordnung des aktuell relevanten Signals für den Fall, dass mehrere unterschiedliche Signale im Sichtbereich liegen, beispielsweise ein separates Signal für Linksabbieger. In [26] wurden für diese Aufgabe Karteninformationen auf Basis von Messfahrten generiert. Im vorgestellten Verfahren werden für einzelne Lichtsignale distinkte Merkmale aus einer Videoaufzeichnung extrahiert und mit einem Ortsbezug auf zugehörige Fahrstreifen in einer digitalen Karte abgelegt. Im Fahrzeug werden extrahierte Merkmale während der Anwendung aus dem aktuellen Kamerabild mit den Karteninformationen abgeglichen. Durch diesen Ansatz wird das relevante Lichtsignal aus mehreren unterschiedlichen Signalen mit hoher Wahrscheinlichkeit korrekt ausgewählt. Allerdings ist ein großer manueller Aufwand für die Erstellung der digitalen Karte nötig.




Bild 6.1: Beispielhafte Fahrstreifen-topologie an einer Kreuzungseinfahrt mit separater Lichtsignalgruppe für Linksabbieger.




Bild 6.2: Beispielhafte Fahrstreifen-topologie an einer Kreuzungseinfahrt mit separater Lichtsignalgruppe für Rechtsabbieger.

Im Rahmen dieser Arbeit wird die Verwendung des Wissens über Lichtsignalgruppen an Kreuzungseinfahrten vorgeschlagen, um die Erkennung des relevanten Lichtsignals zu verbessern. Dabei werden die benötigten Karteninformationen automatisiert aus Fahrzeugbewegungsdaten generiert. Die vorgestellten Methoden sind angelehnt an die eigene Arbeit in [87]. Lichtsignalgruppen sind laut den RiLSA [88] Gruppen von unterschiedlichen Kreuzungspfaden, welche durch dasselbe Signal geregelt werden. Als Beispiel ist es möglich, dass zwei entgegengesetzte Geradeauspfade vom selben Signal geregelt werden und damit eine Signalgruppe bilden. Im Rahmen dieser Arbeit werden die Signalgruppen

jeweils für eine Kreuzungseinfahrt separat betrachtet, unabhängig von weiteren Kreuzungseinfahrten. Eine Signalgruppe beinhaltet dabei sämtliche Fahrtrichtungen ausgehend von einer Kreuzungseinfahrt, für welche zu jeder Zeit dasselbe Signal gültig ist.

An größeren Kreuzungen existiert eine unterschiedliche Signalgebung für die einzelnen Fahrtrichtungen. Beispiele hierfür sind in den Abbildungen 6.1 und 6.2 dargestellt. Anhand der Information über synchrone Signale für unterschiedliche Fahrtrichtungen ist es möglich, Mehrdeutigkeiten einer kamerabasierten Lichtsignalerkennung aufzulösen. Die konkrete Anwendung der Information über Lichtsignalgruppen zur Auswahl des relevanten Lichtsignals wird in Kapitel 7 näher erläutert.

Dieses Kapitel beschreibt die Methodik zur automatisierten Identifikation von Lichtsignalgruppen der Fahrtrichtungen an Kreuzungseinfahrten basierend auf Fahrzeugbewegungsdaten bzw. Trajektorien. Das Verfahren verwendet keinerlei Informationen aus einer kamerabasierten Lichtsignalerkennung, sondern ausschließlich bereits verfügbare Daten aus einer Flotte von seriennahen Testfahrzeugen. Auf Basis von aufgezeichneten Trajektorien im Kreuzungsbereich werden Informationen über die Signalgebung für unterschiedliche Fahrtrichtungen extrahiert. Über den Vergleich sich daraus ergebender Muster werden Signalgruppen identifiziert.

6.1 Parameter von Lichtsignalanlagen

Die Programme von Lichtsignalanlagen werden mit unterschiedlichen Parametern konfiguriert, um die Anlage an die örtlichen Anforderungen anzupassen. Unterschiedliche Arten von Lichtsignalanlagen und deren mögliche Parameter sind in den RiLSA [88] definiert. Die in dieser Arbeit verwendeten Parameternamen und Begriffe werden nachfolgend eingeführt.

Lichtsignalanlage

Eine Lichtsignalanlage umfasst die gesamte Einrichtung zur Regulierung des Verkehrs an einer Kreuzung durch Lichtsignale.

Signalgeber

Ein Signalgeber ist eine einzelne Einheit zur Anzeige eines Lichtsignals. Eine Lichtsignalanlage besteht aus einer Menge von Signalgebern.

Signalgruppe

Eine Signalgruppe umfasst einen oder mehrere Verkehrsströme, die gemeinsam gesteuert werden indem die zugehörigen Signalgeber zu jeder Zeit das gleiche Signalbild zeigen.

Signalphase

Eine Signalphase ist ein Zeitfenster während dem das Lichtsignal eines Signalgebers konstant ist. Dabei existieren Grün-, Gelb- und Rotphasen.

Phasenfolge

Die Phasenfolge legt die Reihenfolge der Grünphasen unterschiedlicher Signalgruppen fest.

Signalprogramm

Das Signalprogramm einer Lichtsignalanlage besteht aus der Phasenfolge sowie den Zeiten des Phasenwechsels sämtlicher Signalgruppen.

Umlaufdauer

Die Umlaufdauer ist die Zeit nach der das Signalprogramm einer Lichtsignalanlage wiederholt wird. Der absolute Zeitpunkt des Beginns eines Umlaufs einer Lichtsignalanlage ist festgelegt durch eine Vielfache der Umlaufdauer ausgehend von einem Startzeitpunkt. Im Rahmen dieser Arbeit wird dazu die Startzeit 00:00 Uhr am 1. Januar 1970 entsprechend UTC gewählt. Eine absolute Zeit t wird als Differenz zu dieser Startzeit in Sekunden repräsentiert. Dabei wird die ortsabhängige Zeitverschiebung

berücksichtigt. Die relative Zeit $\tau(T) \in \mathbb{N}$ mit $\tau(T) \in [1, T]$ innerhalb eines Umlaufs mit der Dauer T wird dann über eine einfache Modulo Rechnung bestimmt:

$$\tau(T) = \text{mod}(t, T). \quad (6.1)$$

Gemäß den RiLSA beträgt die Umlaufdauer einer Lichtsignalanlage in Deutschland zwischen 30s und 120s, wobei nur ganzzahlige Werte erlaubt sind, $T \in \mathbb{N}$ und $T \in [30\text{s}, 120\text{s}]$.

Grünbeginn

Der Grünbeginn ist der relative Zeitpunkt des Beginns einer Grünphase für einen Verkehrsstrom innerhalb eines Umlaufs.

Gründauer

Die Gründauer ist die Dauer einer Grünphase innerhalb eines Umlaufs für eine Signalgruppe.

Makroskopische Steuerungsebene

Die makroskopische Steuerungsebene beschreibt die Änderungen der Parameter über den Tag hinweg. Dadurch werden die Parameter von Lichtsignalanlagen an Schwankungen der Verkehrsbelastung [89] angepasst, wie zum Beispiel dem erhöhten Verkehrsaufkommen während des Berufsverkehrs. Die Programmänderungen können abhängig von Wochentag und Uhrzeit erfolgen, falls die Schwankungen vorhersehbar sind. Des Weiteren werden die Programme zum Teil auch über Detektoren in der Straße verkehrsabhängig angepasst.




Bild 6.3: Parameter der mikroskopischen Steuerungsebene einer Signalgruppe für einen Umlauf.

Mikroskopische Steuerungsebene

Die mikroskopische Steuerungsebene beschreibt einen Umlauf einer Signalgruppe und ist somit definiert durch die Parameter Umlaufdauer, Grünbeginn und Gründauer. Zusätzlich ist auch die Länge der Gelbphasen Teil der mikroskopischen Steuerungsebene. Die Länge der Gelbphase ist abhängig von der erlaubten Geschwindigkeit sowie von der Kreuzungsgeometrie. Abbildung 6.3 zeigt einen beispielhaften Umlauf auf mikroskopischer Steuerungsebene. Ein Signalprogramm besteht aus den Parametern der mikroskopischen Steuerungsebene sämtlicher Signalgruppen.

Festzeitsteuerung

Bei einer Lichtsignalanlage mit Festzeitsteuerung sind die Parameter der mikroskopischen Steuerungsebene fest definiert. Ausschließlich Parameter auf makroskopischer Steuerungsebene, wie die Umlaufdauer oder die Gründauer, werden für unterschiedliche Signalgruppen abhängig von der Tageszeit entsprechend dem erwarteten Verkehrsaufkommen angepasst.

Verkehrsabhängige Steuerung

Lichtsignalanlagen mit verkehrsabhängiger Steuerung besitzen variable Parameter sowohl auf makroskopischer als auch auf mikroskopischer

Steuerungsebene. Beispiele sind der Beginn und die Dauer der Grünphasen einzelner Signalgruppen. Diese werden entsprechend dem aktuellen Verkehrsaufkommen jeweils dynamisch angepasst. Zusätzlich ist es möglich, dass auch die Umlaufdauer adaptiv ist. Neben der aktuellen Verkehrslage besitzen Lichtsignalanlagen mit verkehrabhängiger Steuerung zeitabhängige Programme auf makroskopischer Steuerungsebene.

6.2 Zustand von Lichtsignalen aus Fahrzeugbewegungsdaten

Auf Basis von Daten aus Kreuzungsüberfahrten $\xi_i \in \mathcal{T}_{ea}$ mit Einfahrt e und Ausfahrt a sowie der Position von Haltelinien ist es möglich, eine Menge von N Beobachtungen eines grünen Signalzustands einer Lichtsignalanlage $\mathcal{G}_i = \{t_1^{(i)}, \dots, t_N^{(i)}\}$ aus einer Überfahrt zu erzeugen, wobei die Zeitstempel $t_j^{(i)} \in \mathbb{N}$ gemäß der UTC-Epoche mit der Einheit Sekunde definiert sind. Ziel ist es, Grünbeobachtungen \mathcal{G}_{ea} für jeden Pfad ρ_{ea} einer Kreuzung zu ermitteln. Diese Beobachtungen sind als Vereinigung

$$\mathcal{G}_{ea} = \bigsqcup_i \mathcal{G}_i \quad (6.2)$$

der Beobachtungen sämtlicher Überfahrten $\xi_i \in \mathcal{T}_{ea}$ des Pfades definiert. Die weiteren Signalzustände, Gelb und Rot, werden nicht explizit beobachtet. Für die folgenden Verfahren wird für jeden Pfad ausschließlich die Menge der Grünbeobachtungen \mathcal{G}_{ea} verwendet.

Aus den Überfahrten eines Kreuzungspfades wird zunächst jeweils der absolute Zeitpunkt $t_H^{(i)}$ der Überquerung der Haltelinie extrahiert. Die Strecken $s_j^{(i)}$ und $s_{j+1}^{(i)}$ sind die eindimensionalen Positionsdaten entlang des Kreuzungspfades, welche direkt vor bzw. nach der Haltelinienposition s_H liegen, $s_j^{(i)} < s_H$ und

$s_{j+1}^{(i)} > s_H$. Der Zeitpunkt der Haltelinienüberquerung wird daraus über lineare Interpolation der zugehörigen Zeitstempel ermittelt:

$$t_H^{(i)} = t_j^{(i)} + \frac{s_H - s_j^{(i)}}{s_{j+1}^{(i)} - s_j^{(i)}} \cdot (t_{j+1}^{(i)} - t_j^{(i)}). \quad (6.3)$$

Unter der Annahme, dass der Fahrer die Verkehrsregeln einhält, ergibt sich für den Zeitstempel $t_H^{(i)}$ die Beobachtung eines grünen Signalzustandes des der Fahrtrichtung zugeordneten Lichtsignals. Abhängig davon, ob die Überfahrt ξ_i einen Anhaltevorgang enthält oder nicht, werden unterschiedliche Modellannahmen getroffen um weitere Grünbeobachtungen zu erzeugen.

Zustandsschätzung von Lichtsignalen für Überfahrten ohne Stopp

Gemäß den in Deutschland gültigen RiLSA [88] beträgt die Mindestlänge für eine Grünphase fünf Sekunden. Für den Fall, dass eine Kreuzungsüberfahrt keinen Stopp vor der Haltelinie enthält, wird die Beobachtung um fünf Sekunden vor Überquerung der Haltelinie erweitert. Entsprechend der Darstellung in Abbildung 6.4 ergibt sich eine Beobachtungsmenge $\mathcal{G}_i = \{t_H^{(i)} - 4\text{s}, t_H^{(i)} - 3\text{s}, \dots, t_H^{(i)}\}$ für jede Kreuzungsüberfahrt $\xi_i \in \mathcal{T}_{ea}^{\text{oS}}$ ohne Stopp (oS).




Bild 6.4: Sekundensweise Grünbeobachtungen für Kreuzungsüberfahrten ohne Stopp bei Überquerung der Haltelinie zum Zeitpunkt $t_H^{(i)}$. Die grünen Kreise entsprechen den einzelnen sekundlich diskreten Beobachtungen $\mathcal{G}_i = \{t_H^{(i)} - 4\text{s}, t_H^{(i)} - 3\text{s}, \dots, t_H^{(i)}\}$.

Zustandsschätzung von Lichtsignalen für Überfahrten mit Stopp

Bei Überfahrten mit Stopp ist die Anwendung des bisher vorgestellten Modells nur eingeschränkt gültig. Beispielsweise überfahren Fahrzeuge an den vorderen Positionen der Warteschlange die Haltelinie bereits in weniger als fünf Sekunden nach dem Grünbeginn. Für Kreuzungsüberfahrten $\xi_i \in \mathcal{T}_{ea}^{mS}$ mit Stopp (mS) wird daher ein separates Beobachtungsmodell eingeführt. Ziel des separaten Modells ist es, den Grünbeginn des Lichtsignals auf Basis des Zeitpunkts der Wiederanfahrt nach einem Stopp zu schätzen. Das in [90] vorgeschlagene Warteschlangenmodell dient als Grundlage für diese Schätzung. Ein Stopp vor der Haltelinie ist charakterisiert durch die Distanz $d_H^{(i)}$ zur Haltelinie sowie dem absoluten Zeitpunkt $t_{\text{Start}}^{(i)}$ der Wiederanfahrt nach dem Stopp. Der Zeitpunkt der Wiederanfahrt wird über den Geschwindigkeitsverlauf ermittelt und wird damit direkt aus den Daten entnommen.

Die Länge des Zeitraums $\Delta t^{(i)}$ vom Umschaltvorgang des Lichtsignals von Rot auf Grün zum Zeitpunkt der Wiederanfahrt ist abhängig von der Position des beobachteten Fahrzeugs in der Warteschlange. Beim Anfahrvorgang addieren sich die Reaktionszeiten der Fahrer vor dem beobachteten Fahrzeug in der Schlange auf. Gemäß der Untersuchungen in [91] ist die Reaktionszeit T_{R_1} des Fahrers an erster Stelle im Mittel etwas höher als die Reaktionszeit T_{R_f} folgender Fahrer f . Die Ursache hierfür liegt darin, dass sich Fahrer an hinteren Positionen durch Beobachtung des Lichtsignals bereits vorab auf die Anfahrt vorbereiten. Die Anzahl der Fahrzeuge in der Warteschlange vor dem beobachteten Fahrzeug bei einem Stopp wird anhand der mittleren Distanz D_{H_1} des ersten Fahrzeugs von der Haltelinie sowie der mittleren Gesamtlänge L_H von Fahrzeugspitze zu Fahrzeugspitze berechnet. Auf Basis der Untersuchungen in [91] über das Verhalten der Fahrer an Kreuzungen mit Lichtsignalanlagen, werden die Parameter

des Modells entsprechend Tabelle 6.1 gewählt. Mit der zeitlichen Differenz $\Delta t^{(i)}$ zwischen dem Umschaltvorgang des Lichtsignals und dem Anfahrtszeitpunkt

$$\Delta t^{(i)} = T_{R_1} + \frac{d_H^{(i)} - D_{H_1}}{L_H} \cdot T_{R_f} \quad (6.4)$$

wird der absolute Grünbeginnzeitpunkt $t_G^{(i)}$ berechnet gemäß

$$t_G^{(i)} = t_{\text{Start}}^{(i)} - \Delta t^{(i)}. \quad (6.5)$$

Anhand des Grünbeginnzeitpunkts $t_G^{(i)}$ und des Zeitpunkts $t_H^{(i)}$ des Überquerens der Haltelinie wird für jede Kreuzungsüberfahrt mit Stopp $\xi_i \in \mathcal{T}_{ea}^{\text{mS}}$ die Beobachtungsmenge $\mathcal{G}_i = \{t_G^{(i)}, \dots, t_H^{(i)}\}$ eines grünen Signalzustandes generiert, was in Abbildung 6.5 dargestellt wird.

Tabelle 6.1: Parameter des Warteschlangenmodells an Haltelinien

Parameter	T_{R_1}	T_{R_f}	D_{H_1}	L_H
Wert	1.3 s	1.0 s	1.0 m	6.5 m




Bild 6.5: Sekundenweise Grünbeobachtungen für Kreuzungsüberfahrten mit Stopp bei Überquerung der Haltelinie zum Zeitpunkt $t_H^{(i)}$. Die grünen Kreise entsprechen den einzeln sekundlich diskreten Beobachtungen $\mathcal{G}_i = \{t_G^{(i)}, \dots, t_H^{(i)}\}$. Der Zeitraum $[t_G^{(i)}, t_{\text{Start}}^{(i)}]$ entspricht der Wartezeit in der Warteschlange vom geschätzten Umschaltzeitpunkt der Lichtsignalanlage bis zum Anfahrtszeitpunkt. Der Zeitraum $[t_{\text{Start}}^{(i)}, t_H^{(i)}]$ entspricht der Fahrzeit vom Anfahren bis zum Überqueren der Haltelinie.




Bild 6.6: Statistik über die Fehler der Umschaltzeitpunktschätzung $t_G^{(i)} - t_W^{(i)}$ basierend auf einer manuell erstellten Grundwahrheit $t_W^{(i)}$ aus Kameraaufzeichnungen. Die blaue Box kennzeichnet oberes und unteres Quartil, der senkrechte Strich innerhalb der Box markiert den Median. Die Antennen enden jeweils am letzten Wert der Daten, welcher innerhalb des 1.5-fachen des Interquartilsabstands liegt. Sämtliche Werte außerhalb werden als Ausreißer (Kreuze) markiert. Drei Ausreißer bei -19.5 s, 19.0 s und 25.0 s werden aufgrund der Achsenskalierung nicht dargestellt. Diese sind allerdings in die Berechnung des Medians und der Quantile miteingeflossen.

Anhand von aufgezeichneten Überfahrten mit Kamerabild und Positionsdaten wird die Genauigkeit der Schätzung des Grünbeginnzeitpunktes $t_G^{(i)}$ untersucht. Über das Kamerabild wird der tatsächliche absolute Grünbeginnzeitpunkt $t_W^{(i)}$ aus 96 Umschaltvorgängen bei Überfahrten mit Haltevorgang manuell ermittelt. Abbildung 6.6 zeigt, dass die Hälfte der Abweichungen des geschätzten Grünbeginnzeitpunkts im Intervall $[-0.8\text{ s}, 0.8\text{ s}]$ liegen. Abgesehen von wenigen Ausreißern streuen die weiteren Messwerte im Intervall $[-3.2\text{ s}, 3.4\text{ s}]$. Die Streuung der Schätzungen ist um ein Vielfaches kleiner als die minimal mögliche Umlaufdauer von 30 s. Damit ist die Methode ausreichend genau zur Verwendung für die im Folgenden beschriebenen Verfahren zur automatisierten Extraktion bestimmter Eigenschaften von Lichtsignalanlagen.

6.3 Umlaufdauer von Lichtsignalanlagen

Für die Bestimmung von Signalgruppen werden die Grünphasen der einzelnen Fahrtrichtungen auf Basis der erzeugten Beobachtungen probabilistisch ermittelt und verglichen. Die Grünbeobachtungen der Versuchsträgerflotte sind zeit-

lich gesehen spärlich. Das heißt, dass die Beobachtungen bzw. Überfahrten über einen großen Zeitbereich von bis zu zwei Jahren verstreut sind. Bei einer Anzahl von 50 Überfahrten für einen Kreuzungspfad ergibt dies eine Überfahrt in zwei Wochen im Durchschnitt und damit nur selten mehrere Überfahrten während desselben Umlaufs.

Unter der Annahme, dass die Umlaufdauer für alle Grünbeobachtungen einer Kreuzung konstant ist, werden alle Beobachtungen eines Kreuzungspfades entsprechend Gleichung (6.1) in einen relativen Umlauf transformiert. Basierend auf dem Ergebnis wird eine probabilistische Schätzung der Grünphase für einen Umlauf durchgeführt. Für die Transformation der absoluten Beobachtungszeiten in Zeiten relativ zum Umlauf wird das Wissen der Umlaufdauer vorausgesetzt.

6.3.1 Bisherige Arbeiten

Zur Bestimmung der Umlaufdauer wurden bereits Ansätze in der Literatur vorgestellt. In [92] werden aus den Fahrzeugbewegungsdaten, ebenfalls zunächst unter Verwendung von Geradeausfahrten an Kreuzungen, Schätzungen über den Grünbeginn ermittelt und zeitlich geordnet. Die Umlaufdauer wird auf Basis eines Optimierungsproblems unter Verwendung der Differenzen von aufeinanderfolgenden Zeitpunkten ermittelt. Dies ist möglich, da die zeitlichen Differenzen bei idealer Beobachtung jeweils ein ganzzahliges Vielfaches der Umlaufdauer sind. Damit ist die Umlaufdauer die Zeit, für welche die Differenz aus den Zeitintervallen zwischen den geschätzten Grünbeginnzeitpunkten und jeweils einem ganzzahligen Vielfachen der Umlaufdauer minimal ist. Bei Anwendung dieser Methode ist es allerdings nicht möglich, ganzzahlige Vielfache der korrekten Umlaufdauer zu unterscheiden. Dadurch treten falsche Schätzungen der Umlaufdauer auf.

In [93] wird die Annahme getroffen, dass es bei einer korrekten Schätzung der Umlaufdauer keine zeitlich-räumlichen Überschneidungen von Kreuzungsüberfahrten geben darf. Für jeden Wert im Wertebereich der Umlaufdauer wird überprüft, ob mindestens ein Konflikt auftritt. Sämtliche Umlaufdauern mit Konflik-

ten werden verworfen. Falls genügend Kreuzungsüberfahrten vorliegen, entstehen ausschließlich bei der korrekten Umlaufdauer keine Konflikte. Allerdings ist das Verfahren daher nur bedingt robust gegenüber Messungenauigkeiten der Position und der Zeit.

6.3.2 Umlaufdauerschätzung auf Basis der zirkulären Varianz der Grünbeginnzeitpunkte

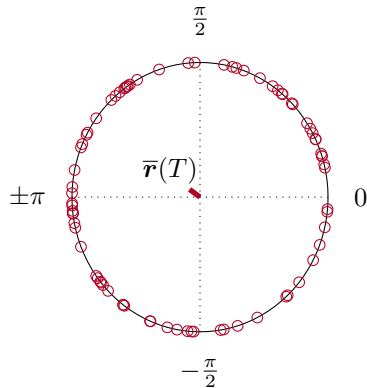

In der vorliegenden Arbeit wird ein neuer Ansatz zur Schätzung der Umlaufdauer T entwickelt. Der Ansatz basiert auf der Minimierung der zirkulären Varianz der geschätzten Grünbeginnzeitpunkte $t_G^{(i)}$ mit $i = 1 \dots N$ aus N Kreuzungsüberfahrten mit Stopp entsprechend Gleichung (6.5). Dabei wird zunächst die Annahme getroffen, dass die Umlaufdauer über den gesamten Beobachtungszeitraum konstant ist.

In der zirkulären bzw. gerichteten Statistik werden Daten als Winkel α auf einen Einheitskreis projiziert [94]. Die ermittelten absoluten Grünbeginnzeitpunkte $t_G^{(i)}$ aus den einzelnen Überfahrten werden daher zunächst gemäß Gleichung (6.1) in Zeitpunkte $\tau^{(i)}(T)$ relativ zum Beginn des Umlaufs der Dauer T umgewandelt. Mit diesen relativen Zeitpunkten erfolgt eine Transformation in einen Winkel

$$\alpha^{(i)}(T) = 2\pi \frac{\tau^{(i)}(T)}{T}. \quad (6.6)$$

Korrekte Umlaufdauer $T = 90$ s

Falsche Umlaufdauer $T = 91$ s



(a) Auf den Einheitskreis projizierte Grünbeginnzeitpunkte für die korrekte Umlaufdauer $T = 90$ s.

(b) Auf den Einheitskreis projizierte Grünbeginnzeitpunkte für eine falsche Umlaufdauer $T = 91$ s.

Bild 6.7: Projektion der Grünbeginnzeitpunkte $t_G^{(i)}$ auf einen Einheitskreis durch Transformation in Winkel $\alpha^{(i)}(T)$. Repräsentation der Streuung der transformierten Winkel über die mittlere Richtung $\bar{r}(T)$.

Zur Bestimmung der Varianz der zirkulären Daten wird die mittlere Richtung

$$\bar{r}(T) = \frac{1}{n} \sum_{i=1}^n r^{(i)}(T), \text{ mit } r^{(i)}(T) = \begin{bmatrix} \cos(\alpha^{(i)}(T)) \\ \sin(\alpha^{(i)}(T)) \end{bmatrix} \quad (6.7)$$

aus n Datenpunkten bestimmt. Abbildung 6.7a zeigt die projizierten Grünbeginnzeitpunkte und die resultierende mittlere Richtung für die in diesem Beispiel korrekte Schätzung der Umlaufdauer $T = 90$ s anhand von Daten einer realen Kreuzung. Die einzelnen transformierten Beobachtungen $\alpha^{(i)}(T)$ konzentrieren sich hauptsächlich auf einen Abschnitt des Kreises. Trotzdem existieren Ausreißer aufgrund von Messungenauigkeiten oder nicht berücksichtigter Programmwechsel. Bei Verwendung einer falschen Umlaufdauer, wie in Abbildung 6.7b,

streuen die Beobachtungen über den gesamten Kreis, wodurch der Betrag der mittleren Richtung abnimmt.

Aus der mittleren Richtung wird die zirkuläre Varianz

$$S(T) = 1 - \|\bar{r}(T)\|_2 \quad (6.8)$$

der Grünbeginnzeitpunkte geschätzt [94]. Abbildung 6.8 zeigt die beispielhaften Daten der realen Kreuzung für die zirkuläre Varianz $S(T)$ abhängig von der gewählten Umlaufdauer. Entsprechend den RiLSA [88] ist die Menge der erlaubten Umlaufdauern definiert zu $\{T \in \mathbb{N} | 30\text{s} \leq T \leq 120\text{s}\}$. Für eine korrekte Wahl der Umlaufdauer $T_{\text{res}} = 90\text{s}$, ergibt sich eine minimale Varianz. Die Umlaufdauer wird daher geschätzt zu

$$T_{\text{res}} = \arg \min_{\{T \in \mathbb{N} | 30\text{s} \leq T \leq 120\text{s}\}} S(T). \quad (6.9)$$

Bestimmte Arten von Lichtsignalanlagen adaptieren allerdings auch die Umlaufdauer entsprechend dem Verkehrsaufkommen. Daher ist es für ein zuverlässiges Ergebnis nötig zu überprüfen, ob das Minimum der zirkulären Varianz signifikant ist. Zur Überprüfung, ob es sich um ein signifikantes Minimum handelt, wird der Hodges-Ajne Test [95] mit $p = 0.001$ angewendet. Die Nullhypothese dieses Signifikanztests geht von einer zirkulären Gleichverteilung der Daten aus. Im Beispiel in Abbildung 6.8 wird die Nullhypothese ausschließlich für die korrekte Umlaufdauer von 90s abgelehnt.




Bild 6.8: Zirkuläre Varianz $S(T)$ abhängig von diskreten Werten für die Umlaufdauer T . Das Minimum liegt bei der korrekten Umlaufdauer $T_{\text{res}} = 90$ s. Ausschließlich unter Verwendung der korrekten Umlaufdauer unterscheidet sich die zirkuläre Verteilung signifikant von einer Gleichverteilung nach dem Hodges-Ajne Test mit $p = 0.001$.

6.3.3 Erweiterte Ansätze zur Umlaufdauerschätzung

Aufbauend auf den Erkenntnissen des Ansatzes der zirkulären Varianz werden in [96] drei weitere Methoden zur Schätzung der Umlaufdauer untersucht. Der erste Ansatz basiert auf den Varianzen der zeitlichen Differenzen von markanten Merkmalspunkten innerhalb eines Umlaufs. Die Merkmalspunkte sind Zeitpunkte von Anhalte- und Beschleunigungsvorgängen sowie Überfahrten über die Haltelinie. Ein weiterer Ansatz optimiert den Korrelationskoeffizient zwischen den räumlich-zeitlichen Verläufen der Kreuzungsüberfahrten. Bei einer korrekten Umlaufdauer korrelieren ähnliche Verläufe der Kreuzungsüberfahrten stark. Zum Beispiel treten freie Überfahrten ohne Haltepunkt in zeitlicher Nähe zueinander auf, bezogen auf die relative Zeit innerhalb des Umlaufs.

Eine weitere Methode in [96] betrachtet das Koordinatensystem der gefahrenen Strecke über der Zykluszeit als zweidimensionales Bild. Die einzelnen räumlich zeitlichen Verläufe ergeben dabei jeweils Linien in diesem Bild. Für eine korrekte Schätzung der Umlaufdauer konzentrieren sich die Verläufe nach dem

Grünbeginn, andernfalls streuen sie über den gesamten Umlauf. Dadurch ergeben sich bei korrekter Umlaufdauer größere Bildbereiche mit freien Regionen. Diese Bereiche werden über ein regionenorientiertes Segmentierungsverfahren ermittelt. Die Größe dieser freien Bereiche wird als Merkmal für einen linearen Klassifikator zur Bestimmung der korrekten Umlaufdauer verwendet.

Die Auswertungsergebnisse in [96] deuten darauf hin, dass die Fusion mehrerer Methoden mit einer Genauigkeit von 99%, bei einem Minimum von 30 Überfahrten, das beste Ergebnis zur Bestimmung der Umlaufdauer ergibt. Die vorgestellten Methoden sind im Vergleich zur Berechnung der zirkulären Varianz rechenaufwändiger, wobei die zirkuläre Varianz mit 95% ebenfalls robuste Schätzungen liefert.

6.4 Vergleich von Lichtsignalprogrammen zur Bestimmung von Signalgruppen

Unter Verwendung der korrekt bestimmten Umlaufdauer T , werden die absoluten Zeitpunkte der einzelnen Grünbeobachtungen in relative Zeitpunkte $\tau \in [1, T]$ mit $\tau \in \mathbb{N}$ anhand Gleichung (6.1) transformiert. Da die transformierten Beobachtungen jeder Fahrtrichtung einer Kreuzungseinfahrt über die relative Zeit τ diskret und auf die Umlaufdauer T beschränkt sind, wird jeweils eine Multinomialverteilung gebildet. Die Verteilung repräsentiert die Wahrscheinlichkeit $P(\tau|R_j)$ für eine Grünbeobachtung zum relativen Zeitpunkt τ innerhalb eines Umlaufs bei einer gegebenen Fahrtrichtung $R_j \in \{\text{Links, Geradeaus, Rechts}\}$. Zur Bestimmung von Signalgruppen werden diese Verteilungen dann paarweise verglichen und als synchron bzw. nicht synchron klassifiziert. In diesem Abschnitt wird die entwickelte Methodik zur Klassifikation synchron geregelter Fahrtrichtungen eingeführt.

Zur Entwicklung der Algorithmen wird eine Kreuzung beispielhaft unter Verwendung der mikroskopischen Verkehrssimulation SUMO [74] simuliert. Der Einsatz einer Simulation hat den Vorteil, dass Parameter wie die Anzahl an Überfahrten und das Rauschen der Positions- bzw. Zeitmessungen einfach zu adaptie-

ren sind. Damit ist es möglich, für die entwickelte Methodik Anforderungen an die Eingangsdaten abzuleiten. In der Simulation wird eine einzelne Kreuzungseinfahrt modelliert. Dabei ist für Geradeaus- und Rechtsfahrer eine synchrone Signalgebung gültig. Für Linksabbieger ist im Vergleich zu Geradeausfahrern eine gesonderte Signalgebung relevant. Die simulierte Kreuzungseinfahrt ist in Abbildung 6.9 dargestellt.

Abbildung 6.10 zeigt die Simulationsparameter auf mikroskopischer Steuerungsebene für die einzelnen Fahrtrichtungen. Der Verkehr an der Kreuzungseinfahrt wird für eine Stunde mit einem Verkehrsfluss von 350 Fahrzeugen pro Stunde für jede Fahrtrichtung simuliert. Aus den aufgezeichneten Überfahrten werden 50 Überfahrten zufällig ausgewählt und ausgewertet. Bei einer simulierten Umlaufdauer von $T = 85$ s werden gemäß Abschnitt 6.2 relative Zeitpunkte der Grünbeobachtungen extrahiert. Es ergeben sich durchschnittlich 494 Beobachtungen eines grünen Lichtsignals für jede Fahrtrichtung. Da die Beobachtungen in der Realität einem Rauschen unterliegen, werden zufällig ausgewählte 20% davon über einen Tag gleich verteilt. Dadurch ergeben diese Grünbeobachtungen zufällige relative Zeitpunkte innerhalb eines Umlaufs.




Bild 6.9: Grafische Darstellung der simulierten Kreuzungseinfahrt als konfigurierbares Beispiel für die Entwicklung der Methodik zur Bestimmung von Signalgruppen.






Bild 6.10: Signalprogramm der einzelnen Fahrrichtungen bei einer Umlaufdauer $T = 85$ s.

Abbildung 6.11 zeigt die Multinomialverteilungen der relativen Zeitpunkte der Grünbeobachtungen aller drei Fahrrichtungen für eine simulierte Umlaufdauer von $T = 85$ s. Auf Basis der Verteilungen wird über ein Vergleichsmaß bestimmt, ob für jeweils zwei Fahrrichtungen dieselbe Signalgebung gültig ist. Dazu werden die aus der Literatur bekannten Distanzmaße *L1-Distanz*, *Kullback-Leibler-Divergenz*, *Kolmogorov-Smirnov Distanz* und *Earth Movers Distanz* angewendet wie in Abschnitt 2.2 definiert. Zusätzlich wird nachfolgend ein eigenes Abstandsmaß basierend auf den Regeln von Bayes eingeführt, welches problemspezifische Eigenschaften der Verteilungen berücksichtigt. Sämtliche Vergleichsmaße werden auf einen Testdatensatz angewendet und kontrastiv evaluiert.


Die Eigenschaften nicht synchroner Signalgebungen sind zum Teil sehr unterschiedlich. In dem Beispiel in Abbildung 6.10 überlappen sich die Grünphasen über einen Zeitraum von 23 s. Der Grünbeginnzeitpunkt unterscheidet sich aber signifikant zwischen den Fahrrichtungen. Derartige zusätzliche Grünzeiten werden laut RiLSA [88] Zugabezeit bzw. Vorgabezeit genannt. Zudem ist es auch möglich, dass sich sowohl der Beginn als auch das Ende der Grünphasen unterscheiden und zusätzlich keine Überlappung vorhanden ist.



(a) Fahrrichtung: Links



(b) Fahrrichtung: Gerade



(c) Fahrrichtung: Rechts

Bild 6.11: Simulierte Multinomialverteilungen der relativen Zeitpunkte der Grünbeobachtungen für unterschiedliche Fahrrichtungen der simulierten Kreuzungseinfahrt bei einer Umlaufdauer von $T = 85$ s. Die simulierten Daten werden zur Entwicklung des Algorithmus zur Bestimmung von Signalgruppen verwendet um die Robustheit bei unterschiedlichen Parametern der Signalgebung zu testen.

Wie die nachfolgende Auswertung zeigt, ergeben die aus der Literatur bekannten Distanzmaße bei überlappenden Grünphasen mit geringen Unterschieden von wenigen Sekunden, einen ähnlichen Wert im Vergleich zu gleichen Grünphasen. Daher wird für die vorliegende Problemstellung ein neues Abstandsmaß eingeführt, welches auf einem probabilistischen Modellvergleich nach Bayes gemäß [97, Kapitel 12] basiert. Die entwickelte Methode zur Bestimmung des Abstandsmaßes umfasst die folgenden Schritte:

- probabilistischer Vergleich der Verteilungen der Grünbeobachtungen für jede Umlaufsekunde anhand des Bayes-Faktors,
- zirkuläre Glättung des Vergleichsergebnisses
- und Bestimmung des Abstandsmaßes anhand des Minimums des geglätteten Vergleichsergebnisses.

Probabilistischer Vergleich der Verteilungen der Grünbeobachtungen für jede Umlaufsekunde anhand des Bayes-Faktors

In einem ersten Schritt zur Bestimmung des in dieser Arbeit vorgeschlagenen Abstandsmaßes werden die Grünbeobachtungen zwischen den Fahrtrichtungen für jede Umlaufsekunde τ unabhängig voneinander verglichen. Dazu wird für jede Fahrtrichtung R_j mit $j \in \{1, 2\}$ zu einer Umlaufsekunde τ eine Binomialverteilung aus dem Verhältnis der Anzahl an Überfahrten mit Grünbeobachtungen $z_{j,\tau} \in \mathbb{N}$ zur gesamten Anzahl an Überfahrten $N_j \in \mathbb{N}$ gebildet. Für zwei Fahrtrichtungen ergibt sich damit für jede Umlaufsekunde τ der Beobachtungsvektor $\mathbf{z}_\tau = \{z_{1,\tau}, z_{2,\tau}\}$. Im Folgenden bezeichnet $\theta_{j,\tau} \in \mathbb{R}$ mit $0 \leq \theta_{j,\tau} \leq 1$ den Wert für die Wahrscheinlichkeit einer Grünbeobachtung für die Fahrtrichtung R_j zur Umlaufsekunde τ für eine Überfahrt. Der vorgestellte Ansatz des probabilistischen Vergleichs der Signalgebung zweier Fahrtrichtungen basiert auf einer Modellauswahl nach Bayes. Dazu wird der Vergleich der Binomialverteilungen

für jede Umlaufsekunde τ als Hypothesentest formuliert. Die beiden Hypothesen besagen, dass die Verteilungen der beiden Fahrrichtungen und damit die Parameter $\theta_{1,\tau}$ und $\theta_{2,\tau}$

- gleich, $\theta_{1,\tau} = \theta_{2,\tau}$ (Nullhypothese H_{null})
- oder ungleich sind, $\theta_{1,\tau} \neq \theta_{2,\tau}$ (alternative Hypothese H_{alt}).

Nachfolgend werden für beide Hypothesen die Wahrscheinlichkeiten $P(\mathbf{z}_\tau | H_{\text{null}})$ bzw. $P(\mathbf{z}_\tau | H_{\text{alt}})$ der Beobachtungen \mathbf{z}_τ hergeleitet. Dazu wird initial die Wahrscheinlichkeit der Beobachtungen \mathbf{z}_τ unter der Annahme, dass die Parameter $\theta_{j,\tau}$ gegeben sind, bestimmt:

$$P(\mathbf{z}_\tau | \theta_{1,\tau}, \theta_{2,\tau}) = \prod_{j=1}^2 \binom{N_j}{z_{j,\tau}} (\theta_{j,\tau})^{z_{j,\tau}} \cdot (1 - \theta_{j,\tau})^{N_j - z_{j,\tau}}. \quad (6.10)$$

Die Wahrscheinlichkeit des Beobachtungsvektors \mathbf{z}_τ zur Umlaufsekunde τ ergibt sich durch Multiplizieren der Wahrscheinlichkeiten für das Ereignis einer Grünbeobachtung mit der Wahrscheinlichkeit des Gegenereignisses, das heißt einer Überfahrt ohne Grünbeobachtung zu diesem Zeitpunkt. Dabei werden die Wahrscheinlichkeiten jeweils entsprechend der Häufigkeiten der Beobachtungen potenziert.

Unter Anwendung der Regel von Bayes auf Gleichung (6.10) ergibt sich die Wahrscheinlichkeit für die unbekannt Parameter $\theta_{1,\tau}$ und $\theta_{2,\tau}$ zu

$$P(\theta_{1,\tau}, \theta_{2,\tau} | \mathbf{z}_\tau) = \frac{P(\mathbf{z}_\tau | \theta_{1,\tau}, \theta_{2,\tau}) \cdot P(\theta_{1,\tau}) \cdot P(\theta_{2,\tau})}{P(\mathbf{z}_\tau)}. \quad (6.11)$$

Zur Modellierung der Wahrscheinlichkeiten $P(\theta_{j,\tau})$ wird die Betaverteilung als nichtinformative A-priori-Verteilung verwendet. Die Verwendung einer Betaverteilung vereinfacht die Repräsentation der beiden Hypothesen und zudem ist die Betaverteilung eine konjugierte A-priori-Verteilung der Binomialverteilung. Das heißt, dass A-priori- und A-posteriori-Verteilung derselben Familie von Verteilungen

lungen angehören, weshalb die Betaverteilung bevorzugt als A-priori-Verteilung für die Binomialverteilung verwendet wird. Die Betaverteilung $Beta(p, q)$ ist gegeben zu:

$$P(\theta) = \begin{cases} \frac{\theta^{p-1}(1-\theta)^{q-1}}{B(p,q)} & \text{für } 0 \leq \theta \leq 1 \\ 0 & \text{sonst} \end{cases} = \text{Beta}(p, q), \quad (6.12)$$

mit den Variablen $p, q \in \mathbb{N}$ und der Betafunktion

$$B(p, q) = \int_0^1 \theta^{p-1}(1-\theta)^{q-1} d\theta = \frac{\Gamma(p)\Gamma(q)}{\Gamma(p+q)} \quad (6.13)$$

als Normalisierungskonstante, wobei Γ die Gamma Funktion bezeichnet. Die Variablen p und q repräsentieren initiales Wissen über positive und negative Beobachtungen. Unter Anwendung der Betaverteilung mit den Parametern $p_{j,\tau}, q_{j,\tau}$ ergibt sich Gleichung (6.11) zu

$$P(\theta_{1,\tau}, \theta_{2,\tau} | \mathbf{z}_\tau) = \frac{\prod_{j=1}^2 \binom{N_j}{z_{j,\tau}} (\theta_{j,\tau})^{z_{j,\tau} + p_{j,\tau} - 1} \cdot (1 - \theta_{j,\tau})^{N_j - z_{j,\tau} + q_{j,\tau} - 1}}{P(\mathbf{z}_\tau) \cdot B(p_{1,\tau}, q_{1,\tau}) \cdot B(p_{2,\tau}, q_{2,\tau})}. \quad (6.14)$$

Durch einen Vergleich der Zähler in Gleichung (6.14) mit dem Zähler der Betaverteilung in Gleichung (6.12) lässt sich ableiten, dass die Wahrscheinlichkeit $P(\theta_{1,\tau}, \theta_{2,\tau} | \mathbf{z}_\tau)$ auch über eine Multiplikation der Betaverteilungen $Beta(z_{j,\tau} + p_{j,\tau}, N_j - z_{j,\tau} + q_{j,\tau})$ ausgedrückt werden kann. In diesem Fall ist der Nenner gleich dem Produkt der Betafunktionen zur Normalisierung, gemäß

$$P(\mathbf{z}_\tau) \cdot B(p_{1,\tau}, q_{1,\tau}) \cdot B(p_{2,\tau}, q_{2,\tau}) = \prod_{j=1}^2 \binom{N_j}{z_{j,\tau}} B(z_{j,\tau} + p_{j,\tau}, N_j - z_{j,\tau} + q_{j,\tau}) \quad (6.15)$$

und die Wahrscheinlichkeit der Beobachtungen ergibt sich zu

$$P(\mathbf{z}_\tau) = \frac{\prod_{j=1}^2 \binom{N_j}{z_{j,\tau}} B(z_{j,\tau} + p_{j,\tau}, N_j - z_{j,\tau} + q_{j,\tau})}{B(p_{1,\tau}, q_{1,\tau}) \cdot B(p_{2,\tau}, q_{2,\tau})}. \quad (6.16)$$

Der Binomialfaktor wird im Nenner zum Kürzen mitgeführt. Durch die Anwendung des Modellvergleichs nach Bayes [98, Abschnitt 7.4] werden die Fahrrichtungen R_j für jede Umlaufsekunde τ verglichen basierend auf den Wahrscheinlichkeiten der Beobachtungen für gegebene Hypothesen. Für die Nullhypothese H_{null} gilt, dass die Parameter $\theta_{1,\tau}$ und $\theta_{2,\tau}$ der beiden Fahrrichtungen gleich sind:

$$H_{\text{null}} \rightarrow \theta_{1,\tau} = \theta_{2,\tau}. \quad (6.17)$$

Für die alternative Hypothese H_{alt} gilt, dass die Parameter $\theta_{1,\tau}$ und $\theta_{2,\tau}$ unterschiedlich sind:

$$H_{\text{alt}} \rightarrow \theta_{1,\tau} \neq \theta_{2,\tau}. \quad (6.18)$$

Zunächst wird die alternative Hypothese betrachtet. Unter der Annahme einer gleichverteilten A-priori-Betaverteilung mit $p = q = 1$ für die Parameter θ ergibt sich die Wahrscheinlichkeit der Daten für die alternative Hypothese zu

$$\begin{aligned} P(\mathbf{z}_\tau | H_{\text{alt}}) &= \frac{\prod_{j=1}^2 \binom{N_j}{z_{j,\tau}} B(z_{j,\tau} + 1, N_j - z_{j,\tau} + 1)}{B(1, 1) \cdot B(1, 1)} \\ &= \prod_{j=1}^2 \binom{N_j}{z_{j,\tau}} B(z_{j,\tau} + 1, N_j - z_{j,\tau} + 1), \end{aligned} \quad (6.19)$$

mit $B(1, 1) = 1$.

Unter der Nullhypothese sind die Parameter $\theta_{1,\tau}$ und $\theta_{2,\tau}$ gleich für beide Fahr-richtungen. Daher gilt in diesem Fall $P(\theta_{1,\tau}, \theta_{2,\tau}) = 0$ für $\theta_{1,\tau} \neq \theta_{2,\tau}$. Mit $\theta_{1,\tau} = \theta_{2,\tau} = \theta_\tau$ wird die Wahrscheinlichkeit der Daten für die Nullhypothese analytisch über das Integral

$$\begin{aligned} P(\mathbf{z}_\tau | H_{\text{null}}) &= \int_0^1 P(\mathbf{z}_\tau | \theta_\tau) d\theta_\tau \\ &= \int_0^1 \prod_{j=1}^2 \binom{N_j}{z_{j,\tau}} (\theta_\tau)^{z_{j,\tau}} \cdot (1 - \theta_\tau)^{N_j - z_{j,\tau}} d\theta_\tau \end{aligned} \quad (6.20)$$

bestimmt. Entsprechend der Definition des Normalisierungsfaktors $B(p, q)$ lässt sich die Wahrscheinlichkeit der beobachteten Daten unter Annahme der Nullhypothese berechnen gemäß

$$\begin{aligned} P(\mathbf{z}_\tau | H_{\text{null}}) &= \\ &= \binom{N_1}{z_{1,\tau}} \binom{N_2}{z_{2,\tau}} \cdot B(z_{1,\tau} + z_{2,\tau} + 1, N_1 - z_{1,\tau} + N_2 - z_{2,\tau} + 1). \end{aligned} \quad (6.21)$$

Der Modellvergleich nach Bayes [98, Abschnitt 7.4] ist definiert zu

$$\frac{P(H_{\text{alt}} | \mathbf{z}_\tau)}{P(H_{\text{null}} | \mathbf{z}_\tau)} = \frac{P(\mathbf{z}_\tau | H_{\text{alt}})}{P(\mathbf{z}_\tau | H_{\text{null}})} \cdot \frac{P(H_{\text{alt}})}{P(H_{\text{null}})}. \quad (6.22)$$

Unter der Annahme, dass die beiden Modelle a priori gleich wahrscheinlich sind, also $P(H_{\text{alt}}) = P(H_{\text{null}}) = 0.5$ gilt, ergibt sich anhand Gleichungen (6.19) und (6.21) der sogenannte Bayes-Faktor [99]

$$\begin{aligned} BF &= \frac{P(H_{\text{alt}} | \mathbf{z}_\tau)}{P(H_{\text{null}} | \mathbf{z}_\tau)} = \\ &= \frac{\prod_{j=1}^2 B(z_{j,\tau} + 1, N_j - z_{j,\tau} + 1)}{B(z_{1,\tau} + z_{2,\tau} + 1, n_1 - z_{1,\tau} + n_2 - z_{2,\tau} + 1)} \end{aligned} \quad (6.23)$$

Da vorausgesetzt wird, dass genau eines der beiden Modelle gültig ist, gilt $P(H_{\text{alt}}|\mathbf{z}_\tau) + P(H_{\text{null}}|\mathbf{z}_\tau) = 1$. Damit ergibt sich die Wahrscheinlichkeit für die Nullhypothese H_{null} , also die Wahrscheinlichkeit, dass die Parameter der beiden zu vergleichenden Fahrtrichtungen für eine Umlaufsekunde τ gleich sind, zu

$$P(H_{\text{null}}|\mathbf{z}_\tau) = \frac{1}{1 + BF}. \quad (6.24)$$

Zirkuläre Glättung des Vergleichsergebnisses und Bestimmung des Abstandsmaßes

Zur Erhöhung der Robustheit gegenüber Ausreißern werden die Ergebnisse des Modellvergleichs nach Bayes, also die Wahrscheinlichkeit $P(H_{\text{null}}|\mathbf{z}_\tau)$ der Nullhypothese für jede Umlaufsekunde τ , über eine zirkuläre Faltung mit Gaußkern $K_\sigma(x)$ geglättet. Der Gaußkern besitzt einen diskreten und beschränkten Definitionsbereich $\mathbb{D}_K = \{x \in \mathbb{Z} | -\frac{w}{2} \leq x \leq \frac{w}{2}\}$ und wird berechnet zu

$$K_\sigma(x) = \frac{e^{-\frac{1}{2}\left(\frac{x}{\sigma}\right)^2}}{N_K}, \text{ mit } N_K = \sum_{x=-\frac{w}{2}}^{\frac{w}{2}} e^{-\frac{1}{2}\left(\frac{x}{\sigma}\right)^2}. \quad (6.25)$$

Die Anwendung eines gleitenden Mittelwerts als Tiefpassfilter zeigt im Rahmen einer Auswertung, dass die Wahl des Kerns keinen signifikanten Einfluss auf das Klassifikationsergebnis hat. Der Gaußkern wird in diesem Fall verwendet, da er den Vorteil einer streng monoton fallenden Frequenzantwort besitzt. Es ergibt sich die zirkulär über einen Umlauf geglättete Funktion

$$g(\tau) = \sum_{t=1}^T K_\sigma(\tau - t) \cdot P(H_{\text{null}}|\mathbf{z}_t). \quad (6.26)$$

Der Parameter σ wurde mit $\sigma = 2.5\text{s}$ so gewählt, dass ein minimaler Unterschied der Grünphasen, bzw. eine minimale Zu- oder Vorgabezeit von fünf Sekunden, erkannt wird. Dadurch wirkt sich ein Unterschied der Verteilungen für ein Zeitintervall von fünf Sekunden prägnant auf das geglättete Ergebnis aus.

Abbildung 6.12 zeigt den geglätteten Verlauf in Form einer durchgezogenen Linie. Der Verlauf in Abbildung 6.12a weist ein signifikantes Absinken der Wahrscheinlichkeit im fünf Sekunden Zeitintervall $\tau \in [21 \text{ s}, 25 \text{ s}]$ auf, was die korrekte Wahl des Parameters Sigma für dieses Beispiel bestätigt.

Das in dieser Arbeit eingeführte Abstandsmaß d ergibt sich aus dem Minimum des geglätteten Verlaufs $g(\tau)$ der Wahrscheinlichkeit für die Gleichheit beider Verteilungen:

$$d = \min(g(\tau)). \quad (6.27)$$

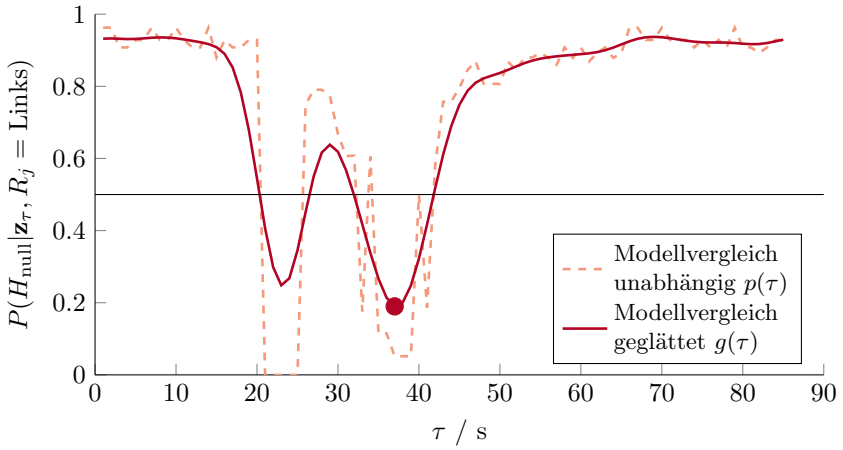
Abbildung 6.12 zeigt das Ergebnis des Abstandsmaßes für synchrone und nicht synchrone Signalgruppen. Die gestrichelten Linien entsprechen dabei den Ergebnissen des Modellvergleichs für jede Umlaufsekunde unabhängig voneinander. Für die Fahrtrichtung Rechts beträgt die durchschnittliche Wahrscheinlichkeit für die Nullhypothese 0.86. Damit ist es wahrscheinlicher, dass für die Fahrtrichtungen Rechts und Geradeaus eine synchrone Signalgebung gültig ist. Allerdings existiert zur Umlaufsekunde $\tau = 26 \text{ s}$ ein Ausreißer mit einer sehr geringen Wahrscheinlichkeit für dieselbe Signalgebung. Dieser ist durch eine Ungenauigkeit in der Schätzung der Haltelinienposition für den Rechtsabbiegepfad zu erklären. Durch die Ungenauigkeit ergibt sich eine zeitliche Verschiebung der geschätzten Grünbeobachtungen, weshalb der Vergleich der Verteilungen zu einem Unterschied bei einer Umlaufsekunde führt.

Der Vergleich der Fahrtrichtungen Links und Geradeaus zeigt, dass die Verteilungen in den Zeitfenstern $\tau \in [21 \text{ s}, 25 \text{ s}]$ und $\tau \in [33 \text{ s}, 41 \text{ s}]$ sehr unterschiedlich sind. Der Unterschied im ersten Zeitfenster ergibt sich aus dem früheren Start der Grünphase bei Linksabbiegern. Im zweiten Zeitfenster ergibt sich ein Unterschied in der Mitte der Grünphase. Der Grund ist, dass Linksabbieger mit Stopp vor der Haltelinie diese aufgrund der Signalgebung früher überqueren als Geradeausfahrer. Bei gleichem Verkehrsfluss ergibt sich damit für die letzten Fahrzeuge mit Stopp in einem Umlauf ein Unterschied in den Grünbeobachtungen zwischen den Fahrtrichtungen. Da die Grünphase für beide Fahrtrichtungen


zum selben Zeitpunkt endet, weisen die Verteilungen der Grünbeobachtungen gegen Ende der Phase keinen Unterschied auf.

Die durchgezogenen Linien ergeben sich durch die zirkuläre Glättung der Vergleichsergebnisse über den gesamten Umlauf. Darauf basierend sind die jeweiligen sich ergebenden Abstandsmaße über einen runden Marker gekennzeichnet. Je kleiner diese Wahrscheinlichkeit ist, umso größer ist der Abstand der Verteilungen. Da es sich bei dem Abstandsmaß um eine Wahrscheinlichkeit handelt, ergibt sich ein Wertebereich von $[0, 1]$. Aufgrund der Eigenschaften des Modellvergleichs nach Bayes wird jedoch der Wert 1 selbst bei exakt gleichen Verteilungen nur für eine unendlich große Anzahl an Samples erreicht. Daher handelt es sich bei dem definierten Abstandsmaß um keine Metrik.

Durch die Wahl des Minimums ergibt sich gegenüber den Abstandsmaßen aus der Literatur der Vorteil, dass bereits kleinere Unterschiede in den Verteilungen zu einer geringen Wahrscheinlichkeit der Gleichheit führen. Zusätzlich trägt die Glättung dazu bei, dass einzelne Ausreißer toleriert werden. Die festzulegenden Parameter des Distanzmaßes entsprechen dem Parameter σ sowie dem Kern der Glättung. Damit kann das Distanzmaß problemspezifisch angepasst werden.



(a) Fahrtrichtung: Links



(b) Fahrtrichtung: Rechts

Bild 6.12: Ergebnisse des Vergleichs der Verteilungen anhand des Bayes-Faktors. Die Wahrscheinlichkeit für die Nullhypothese entspricht der Wahrscheinlichkeit, dass die Verteilung der jeweiligen Abbiegerichtung mit der Verteilung der Geradeausfahrten übereinstimmt. Die gestrichelten Linien sind das Ergebnis des Vergleichs für jede Umlaufsekunde unabhängig voneinander. Die durchgezogene Linie ergibt sich durch zirkuläre Glättung der Vergleichsergebnisse über den gesamten Umlauf.

Tabelle 6.2: Zeitabhängige Umlaufdauer einer Lichtsignalanlage

Tageszeit	Umlaufdauer T / s
00:00 - 05:59	70
06:00 - 08:59	90
09:00 - 14:59	70
15:00 - 20:59	90
21:00 - 23:59	70

6.5 Programmwechsel von Lichtsignalanlagen

Wie bereits in Abschnitt 6.1 beschrieben, existieren Lichtsignalanlagen, die zur Anpassung an Schwankungen der Verkehrsbelastung unterschiedliche Parameter zeitgesteuert ändern. Diese Adaptionen werden in der mikroskopischen Steuerungsebene der Lichtsignalanlage durchgeführt. Neben weiteren Parametern ist es auch möglich, dass sich auf makroskopischer Steuerungsebene über den Tagesverlauf hinweg die Umlaufdauer einer Lichtsignalanlage ändert. Ein Beispiel für die zeitlich gesteuerte Änderung der Umlaufdauer an einem Werktag für eine reale Kreuzung wird in Tabelle 6.2 angeführt. Eine längere Umlaufdauer ermöglicht es, eine längere Grünphase für die Hauptrichtung zu gewähren. Damit wird in den Hauptverkehrszeiten ein flüssigerer Verkehr erreicht. Bei geringerem Verkehrsaufkommen werden kürzere Umlaufdauern gewählt, um die Wartezeiten bei rotem Signal zu verkürzen.

Eine Voraussetzung für die Identifikation von Signalgruppen unterschiedlicher Fahrtrichtungen gemäß Abschnitt 6.4 ist ein konstantes Signalprogramm mit einer bekannten Umlaufdauer. Aus diesem Grund ist es erforderlich, zeitlich abhängige Veränderungen der Umlaufdauer zu ermitteln und das Verfahren auf ein Zeitintervall mit konstanter Umlaufdauer anzuwenden. Die Existenz von Programmen mit mehreren unterschiedlichen Umlaufdauern an einer Lichtsignalanlage wird durch das Verfahren in Abschnitt 6.3 detektiert. Für jede Umlaufdauer

Tabelle 6.3: Zeitabhängiger Verkehrsfluss der simulierten Lichtsignalanlage

Tageszeit	Verkehrsfluss / $\frac{\text{Fahrzeuge}}{\text{Stunde}}$
00:00 - 05:59	100
06:00 - 08:59	360
09:00 - 14:59	100
15:00 - 20:59	160
21:00 - 23:59	100

tritt ein signifikantes Minimum der zirkulären Varianz der geschätzten Grünbeginnzeitpunkte auf.

Die Methodik zur Detektion von Programmwechseln wird basierend auf der in Abschnitt 6.4 beschriebenen simulierten Kreuzung entwickelt. Die Simulation wird um das Tagesprogramm entsprechend Tabelle 6.2 ergänzt. Neben der Umlaufdauer wird der Verkehrsfluss ebenfalls abhängig von der Tageszeit variiert wie in Tabelle 6.3 angegeben. Unter Verwendung dieser Parameter werden 3419 Kreuzungsüberfahrten simuliert, woraus 23312 Grünbeobachtungen extrahiert werden. Entsprechend zur vorangehenden Simulation werden ebenfalls 20% der Beobachtungen zufällig gewählt um repräsentative Daten mit Ungenauigkeiten nahe an realen Messungen zu erhalten.

Zur Schätzung der Umlaufdauer wird das Verfahren aus Abschnitt 6.3 auf die simulierten Daten angewendet. Abbildung 6.13 zeigt die zirkuläre Varianz der geschätzten Grünbeginnzeitpunkte für die simulierte Kreuzung. In dem Programm werden die zwei unterschiedlichen Umlaufdauern 70s und 90s verwendet, welche als signifikante Minima detektiert werden. Die Existenz von zwei signifikanten Minima deutet darauf hin, dass eine Lichtsignalanlage mit unterschiedlichen Umlaufdauern auf makroskopischer Steuerungsebene vorliegt. Die zusätzlichen signifikanten Minima bei 35s und 45s werden ignoriert, da bei 70s und 90s

Vielfache der Umlaufzeiten mit geringeren Varianzen existieren. Dieser Effekt ist durch die zirkulären Eigenschaften der Daten begründet.

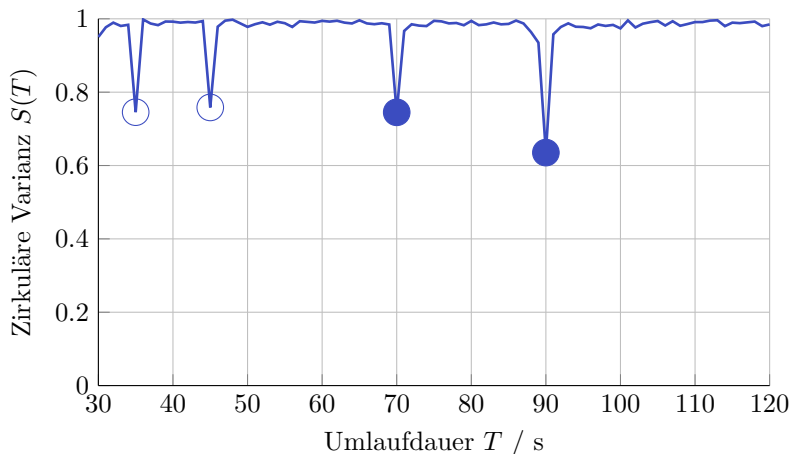


Bild 6.13: Die Zirkuläre Varianz $S(T)$ abhängig von diskreten Werten für die Umlaufdauer T für eine simulierte Kreuzung mit den Parametern der makroskopischen Steuerungsebene aus Tabelle 6.2. In diesem Beispiel treten insgesamt vier signifikante Minima auf. Zwei Minima bei 35 s und 45 s werden aufgrund von Vielfachen mit niedrigeren Varianzen ignoriert. Die weiteren Minima bei 70 s und 90 s sind signifikant, was Änderungen der Umlaufdauer auf makroskopischer Steuerungsebene bedeutet.

Für den Fall, dass an einer Kreuzung eine hohe Anzahl an Überfahrten über den gesamten Tag hinweg vorhanden sind, ist es möglich die Umlaufdauerbestimmung für kleinere Zeitfenster unabhängig voneinander durchzuführen. Damit werden Änderungen der Umlaufdauer erkannt und auf deren Basis wird die makroskopische Steuerungsebene der Lichtsignalanlage rekonstruiert. Die realen Testdaten, welche die Basis für diese Arbeit bilden sind jedoch zeitlich spärlich. Aus diesem Grund werden nachfolgend weitere Methoden zur Erkennung der Änderung von Parametern der makroskopischen Steuerungsebene eingeführt.

Maximum Likelihood Zuordnung der Überfahrten zu den Umlaufdauern und Schätzung der Parameter auf makroskopischer Steuerungsebene

Eine Möglichkeit zeitlich abhängige Wechsel basierend auf zeitlich spärlichen Kreuzungsüberfahrten zu detektieren ist die Zuordnung der einzelnen Beobachtungen zu den Umlaufdauerhypothesen über die maximale Likelihood aus den zugehörigen Multinomialverteilungen der Grünbeobachtungen. Die Grundannahme dabei ist, dass sich die Beobachtungen bei korrekter Zuordnung zur Umlaufdauer während des Grünzeitraums innerhalb eines Umlaufs konzentrieren. Bei einer falschen Zuordnung zur Umlaufdauer streuen die Beobachtungen gleichverteilt über den gesamten Umlauf. Nachdem die einzelnen Beobachtungen und damit die Überfahrten einer Umlaufdauer zugeordnet werden, ist es möglich die Umlaufdauern entsprechend der Tageszeit der Beobachtungen zu ermitteln. Daraus wird eine Schätzung der Parameter auf makroskopischer Steuerungsebene abgeleitet.

Zur Schätzung der Multinomialverteilungen der Grünbeobachtungen wird der Expectation-Maximization (EM) -Algorithmus [100, Abschnitt 20.3] angewendet. Die Gewichtungen der einzelnen Beobachtungen werden entsprechend der Multinomialverteilungen für die Umlaufdauerhypothesen bestimmt. Auf Basis der gewichteten Beobachtungen ergibt sich wiederum eine neue Schätzung der Multinomialverteilung. Entsprechend dem EM-Algorithmus werden diese Schritte iterativ bis zum Erreichen eines Abbruchkriteriums durchgeführt.

Entsprechend dem Beobachtungsmodell aus Abschnitt 6.2 ergibt sich für einen Pfad die Gesamtmenge an Grünbeobachtungen \mathcal{G}_{ea} über alle Überfahrten. Zur Initialisierung des EM-Algorithmus werden sämtliche absoluten Zeitpunkte der Grünbeobachtungen $t_m \in \mathcal{G}_{ea}$ mit $m \in [1, M]$ und $M = |\mathcal{G}_{ea}|$ in einzelne relative Zeitpunkte ρ_{mn} mit $n \in [1, N_T]$ entsprechend der $N_T \in \mathbb{N}$ unterschiedlichen Umlaufdauern T_n mit $\rho_{mn} \in [1, T_n]$ unter Verwendung von Gleichung (6.1) konvertiert. Die initiale Schätzung entspricht der Multinomialverteilung $P^{(0)}(\tau|T_n)$

über die relative Umlaufsekunde $\tau \in \mathbb{N}$, welche auf Basis der relativen Zeitpunkt ρ_{mn} der Grünbeobachtungen gebildet wird:

$$P^{(0)}(\tau|T_n) = \frac{|\{\rho_{mn}|\rho_{mn} = \tau\}|}{M}. \quad (6.28)$$

Die Verteilungen sind in Abbildung 6.14 dargestellt. Durch die Vermischung der Beobachtungen aus den unterschiedlichen Umlaufdauern ist jeweils ein Rauschanteil von Beobachtungen über den gesamten Umlauf ersichtlich. Die Grünphasen sind anhand der erhöhten Wahrscheinlichkeiten erkennbar.

Nach der Initialisierung führt der Algorithmus die folgenden beiden Schritte iterativ aus. In einem ersten Schritt werden die Wahrscheinlichkeiten $P^{(k)}(T_n|\rho_{mn})$ für die unterschiedlichen Umlaufdauern T_n für jede einzelne Beobachtung ρ_{mn} in der Iteration $k \in \{1, \dots, N_{EM}\}$ bestimmt:

$$P^{(k)}(T_n|\rho_{mn}) = \frac{P^{(k-1)}(\tau = \rho_{mn}|T_n) \cdot P(T_n)}{\sum_{n'=1}^{N_T} P^{(k-1)}(\tau = \rho_{mn'}|T_{n'}) \cdot P(T_{n'})}. \quad (6.29)$$

Die A-Priori-Wahrscheinlichkeiten $P(T_n)$ werden als gleichverteilt angenommen. Die Ergebnisse der einzelnen Beobachtungen ρ_{mn} aus Gleichung (6.29) werden als Gewichte zur Aktualisierung der Multinomialverteilung über der relativen Umlaufsekunde τ verwendet:

$$P^{(k)}(\tau|T_n) = \frac{\sum_{m=1}^M P^{(k)}(T_n|\rho_{mn}) \cdot \delta_{\rho_{mn} \tau}}{\sum_{m'=1}^M P^{(k)}(T_n|\rho_{m'n})}. \quad (6.30)$$



(a) Umlaufdauer: $T_1 = 70 \text{ s}$ (b) Umlaufdauer: $T_2 = 90 \text{ s}$

Bild 6.14: Initiale Multinomialverteilungen sämtlicher Beobachtungen für die zwei signifikanten Umlaufdauerhypothesen $T_1 = 70 \text{ s}$ und $T_2 = 90 \text{ s}$. Die Beobachtungen, welche nicht während einem Programm mit der entsprechenden Umlaufdauer generiert wurden, bilden ein Grundrauschen zusätzlich zu den verrauschten Beobachtungen.

Das Kronecker-Delta

$$\delta_{xy} = \begin{cases} 1 & \text{für } x = y \\ 0 & \text{für } x \neq y \end{cases} \quad (6.31)$$

wird dabei zum Filtern der relevanten Beobachtungen $\rho_{mn} = \tau$ für die Berechnung der Multinomialverteilung an einer bestimmten Umlaufsekunde $\tau \in \mathbb{N}$ verwendet. Abbildung 6.15 zeigt das Ergebnis des EM-Algorithmus. Das Rauschen wird durch den Algorithmus verringert, wodurch eine bessere Zuordnung einzelner Grünbeobachtungen zur Umlaufdauer möglich ist.

Abbildung 6.16 zeigt sämtliche Grünbeobachtungen als blaue Markierungen, sortiert nach der Tageszeit und zugeordnet zu einer Umlaufdauer. Die Zuordnung zu einer Umlaufdauer T_n für jede Grünbeobachtung m erfolgt entsprechend der maximalen Wahrscheinlichkeit $P^{(N_{EM})}(\tau = \rho_{mn} | T_n)$:

$$T_m = \arg \max_{T_n} P^{(N_{EM})}(\tau = \rho_{mn} | T_n). \quad (6.32)$$

Die Umlaufdauer T_n wird auf der makroskopischen Steuerungsebene angepasst. Die makroskopische Steuerungsebene dient laut den RiLSA [88] dazu, langfristige Änderungen der Verkehrsbelastung zum Beispiel zu Stoßverkehrszeiten auszugleichen. Aus diesem Grund dauern Phasen mit konstanten Parametern jeweils mindestens eine Stunde, weshalb ein gleitender Medianfilter mit einer Stunde Fenstergröße auf die zugeordneten Grünbeobachtungen angewendet wird. Die somit detektierten Programmwechsel sind in Abbildung 6.16 als rote Rechteckfunktion abgebildet. Obwohl die erkannten Programmwechsel mit dem tatsächlichen Programm übereinstimmen, werden die einzelnen Grünbeobachtungen vor der Anwendung des gleitenden Medianfilters häufig der falschen Umlaufdauer zugeordnet. Insgesamt werden in diesem simulierten Szenario nur 73.3% der Beobachtungen korrekt zugeordnet, wobei 20% der Beobachtungen zufällig gewählt wurden.



(a) Umlaufdauer: $T_1 = 70 \text{ s}$ (b) Umlaufdauer: $T_2 = 90 \text{ s}$

Bild 6.15: Multinomialverteilungen sämtlicher Beobachtungen für die zwei signifikanten Umlaufdauerhypothesen 70 s und 90 s nach N_{EM} Iterationen des EM-Algorithmus.




Bild 6.16: Schätzung der Umlaufdauer abhängig von der Tageszeit unter Verwendung des EM-Algorithmus. Das tatsächliche Programm der Lichtsignalanlage ist entsprechend Tabelle 6.2 in Grau dargestellt. Die einzelnen Grünbeobachtungen sind blau markiert den Umlaufdauern zugeordnet. Über einen gleitenden Medianfilter werden die Umlaufdauern abhängig von der Tageszeit ermittelt entsprechend der roten Rechteckfunktion.

Hidden Markov Model zur Schätzung der Parameter auf makroskopischer Steuerungsebene

Zur Erhöhung der Robustheit wird zusätzlich zum EM-Algorithmus ein Hidden Markov Modell (HMM) mit den unterschiedlichen erkannten Umlaufdauern T_n als verborgene Zustände trainiert. Das Training erfolgt unter Verwendung des Baum-Welch-Algorithmus. Die einzelnen Beobachtungen werden durch den Viterbi Algorithmus den Umlaufdauern zugeordnet.

Für die Initialisierung des Modells wird die Annahme getroffen, dass die Anzahl der Beobachtungen viel höher ist als die Anzahl der Programmwechsel an einem Tag. Damit sind die Übergangswahrscheinlichkeiten für einen Wechsel der Umlaufdauer von einer Beobachtung zur nächsten Beobachtung sehr gering. Diese Wahrscheinlichkeiten werden bei einem HMM in einer Transitionsmatrix

\mathbf{A} repräsentiert. Dabei entspricht jedes Element a_{m^*n} der Wahrscheinlichkeit eines Wechsels der Umlaufdauer von T_n nach T_{n^*} . Die initiale Transitionsmatrix $\mathbf{A}^{(0)}$ wird gewählt zu

$$\mathbf{A}^{(0)} = \begin{bmatrix} 0.99 & 0.01 \\ 0.01 & 0.99 \end{bmatrix}. \quad (6.33)$$

Da diese Transitionsmatrix während des Trainings des Modells gelernt wird, sind Schätzwerte für die Initialisierung ausreichend. Zusätzlich wird das Ergebnis des EM-Algorithmus zur Initialisierung der Beobachtungswahrscheinlichkeiten $P^{(N_{EM})}(\tau = \rho_{mn}|T_n)$ verwendet [101]. Die Beobachtungen ρ_{mn} sind abhängig von der Umlaufdauer T_n und damit vom versteckten Zustand des Modells. Aus diesem Grund wird das HMM problemspezifisch erweitert indem jede Beobachtung spezifisch für die unterschiedlichen versteckten Zustände umgerechnet wird.

Das Modell wird mit dem Baum-Welch-Algorithmus trainiert. Es ergeben sich die Übergangswahrscheinlichkeiten entsprechend Abbildung 6.17 und die Beobachtungswahrscheinlichkeiten $P^{(N_{EM})}(\tau|T_n)$ entsprechend Abbildung 6.18. Anhand der resultierenden Beobachtungswahrscheinlichkeiten ist ersichtlich, dass die verrauschten Daten der Simulation ausschließlich der Umlaufdauer $T_1 = 70$ s zugeordnet werden. Der Grund hierfür liegt darin, dass bei Tageszeiten mit kleineren Umlaufdauern ein niedrigerer Verkehrsfluss vorhanden ist. Dies hat zur Folge, dass insgesamt weniger Überfahrten zur Umlaufdauer $T_1 = 70$ s aufgezeichnet bzw. simuliert werden. Das gleichverteilte Rauschen der Beobachtungswahrscheinlichkeit für eine bestimmte Umlaufdauer beinhaltet die Beobachtungen der jeweils anderen Umlaufdauer sowie die verrauschten Beobachtungen. Der Rauschanteil der niedrigeren Umlaufdauer $T_1 = 70$ s ist relativ gesehen höher, was in Abbildung 6.14 ersichtlich ist. Dies hat wiederum zur Folge, dass diese Umlaufdauer unter Anwendung der Maximum Likelihood Schätzung bei verrauschten Beobachtungen bevorzugt wird. Damit werden nahezu sämtliche verrauschten Beobachtungen dieser Umlaufzeit zugeordnet.




Bild 6.17: Trainiertes Hidden Markov Modell zur Schätzung der zeitabhängigen Umlaufdauer auf makroskopischer Steuerungsebene.

Nach Anwendung des Viterbi Algorithmus ergibt sich die Zuordnung der Beobachtungen zu den Umlaufdauern entsprechend den blauen Punkten in Abbildung 6.19. Die Zuordnung erfolgt mit 76.3 % Genauigkeit und damit um 3 % robuster im Vergleich zu dem Ergebnis des EM-Algorithmus. Ein gleitender Medianfilter wird zur Bestimmung der Änderungszeitpunkte der Umlaufdauer verwendet. Die Detektion der Signalgruppen entsprechend dem Verfahren aus Abschnitt 6.4 wird für jedes Zeitfenster mit konstanter Umlaufdauer separat durchgeführt. Die Ergebnisse werden im Anschluss zu einem Klassifikationsergebnis fusioniert. Dabei wird die jeweilige Anzahl an Überfahrten in dem verwendeten Zeitfenster zur Bildung einer A-priori-Wahrscheinlichkeit für die Fusion verwendet.

6.6 Evaluation

Die Entwicklung der vorgestellten Methoden basiert auf simulierten Testdaten. In diesem Abschnitt wird das Ergebnis einer Evaluation auf einem realen Datensatz von Versuchsträgern in München, wie in Abschnitt 2.3 beschrieben, gezeigt. Als Grundlage für die Evaluierung werden jeweils manuell die korrekten Parameterwerte als Grundwahrheit ermittelt. Auf Basis dieser Daten werden die Verfahren zur Detektion von Änderungen der Umlaufdauer auf makroskopischer Steuerungsebene und die Bestimmung von Signalgruppen evaluiert.



(a) Umlaufdauer: $T_1 = 70$ s(b) Umlaufdauer: $T_2 = 90$ s

Bild 6.18: Multinomialverteilungen sämtlicher Beobachtungen für die zwei signifikanten Umlaufdauerhypothesen $T_1 = 70$ s und $T_2 = 90$ s nach Training eines Hidden Markov Modells mit dem Baum-Welch-Algorithmus.




Bild 6.19: Schätzung der Umlaufdauer abhängig von der Tageszeit unter Verwendung des Hidden Markov Modells für eine simulierte Kreuzung. Das tatsächliche Programm der Lichtsignalanlage ist entsprechend Tabelle 6.2 in Grau dargestellt. Die einzelnen Grünbeobachtungen sind blau markiert den Umlaufdauern zugeordnet. Über einen gleitenden Medianfilter werden die Umlaufdauern abhängig von der Tageszeit ermittelt entsprechend der roten Rechteckfunktion.

Programmwechsel von Lichtsignalanlagen

Zur Evaluation der Erkennung von Programmwechseln wird vorausgesetzt, dass mindestens zwei unterschiedliche Umlaufdauern als signifikant erkannt werden und ausreichend Daten über den Verlauf eines Tages hinweg vorhanden sind. Die Daten der Testfahrzeugflotte liegen an einer Vielzahl von Kreuzungen in Bezug auf die Tageszeit sehr konzentriert vor. Daher werden die angeführten Bedingungen ausschließlich von genau einer Kreuzung mit Lichtsignalanlage erfüllt. Für diese Lichtsignalanlage wurden die Informationen über die Parameter der makroskopischen Steuerungsebene von der Stadt München eingeholt. Für einen Werktag entsprechen diese den in Tabelle 6.2 angeführten Werten. Die Verteilung der Überfahrten über die Tageszeit ist in Abbildung 6.20 dargestellt.




Bild 6.20: Häufigkeitsverteilung der Überfahrten aus den Realdaten einer exemplarischen Kreuzung über die Tageszeit.




Bild 6.21: Zirkuläre Varianz $S(T)$ abhängig von diskreten Werten für die Umlaufdauer T für eine reale Kreuzung mit den Parametern auf makroskopischer Steuerungsebene aus Tabelle 6.2. Es ergeben sich die zwei relevanten Umlaufdauern $T_1 = 70$ s und $T_2 = 90$ s.

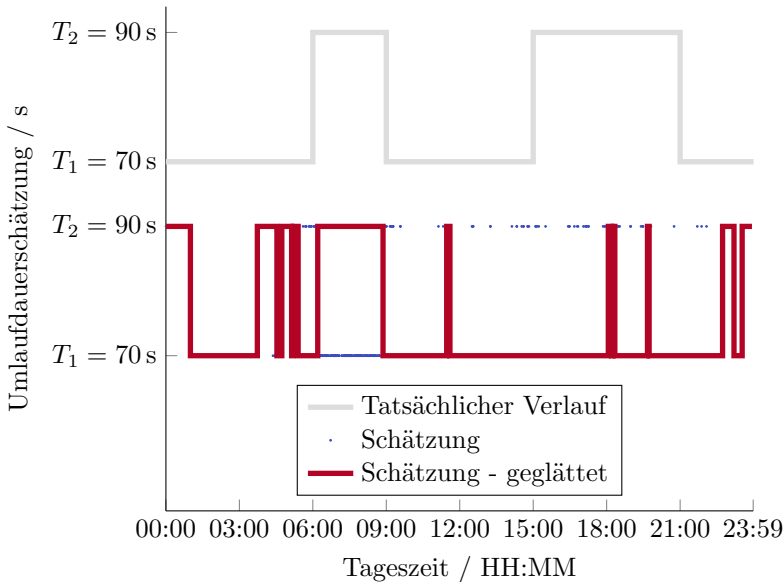


Bild 6.22: Schätzung der Umlaufdauer abhängig von der Tageszeit unter Verwendung des Hidden Markov Modells für eine reale Kreuzung. Das tatsächliche Programm der Lichtsignalanlage ist entsprechend Tabelle 6.2 in Grau dargestellt. Die einzelnen Grünbeobachtungen sind blau markiert den Umlaufdauern zugeordnet. Über einen gleitenden Medianfilter werden die Umlaufdauern abhängig von der Tageszeit ermittelt, entsprechend der roten Rechteckfunktion.

Die Umlaufdauern werden entsprechend dem in Abschnitt 6.3 vorgestellten Ansatz ermittelt. Wie in Abbildung 6.21 dargestellt, ergeben sich zwei signifikante Umlaufdauern $T_1 = 70\text{ s}$ und $T_2 = 90\text{ s}$. Abbildung 6.22 zeigt mit dem geschätzten Verlauf der Umlaufdauer abhängig von der Tageszeit das Ergebnis des gelernten HMM.

Signalgruppen an Kreuzungseinfahrten

Für die Evaluation der Methodik zur Bestimmung von Signalgruppen an Kreuzungseinfahrten, werden aus den Realdaten Paare von Kreuzungspfaden identifiziert, welche jeweils derselben Kreuzungseinfahrt zugeordnet sind. Damit ergeben sich Paare von Fahrtrichtungen ausgehend von einer Kreuzungseinfahrt. Die Voraussetzungen für die Auswahl der Paare an Kreuzungspfaden sind, dass jeweils mindestens fünf Überfahrten vorhanden sein müssen und für mindestens einen Kreuzungspfad eine ausreichende Anzahl an Haltepunkten zur automatisierten Ermittlung der Haltelinienposition vorhanden ist. Falls für einen Kreuzungspfad nicht genügend Haltepositionen vorhanden sind, wird die ermittelte Haltelinienposition des anderen Kreuzungspfades übertragen. Unter Anwendung dieser Vorbedingungen existieren in der vorliegenden Datenbank insgesamt 48 Paare von Kreuzungspfaden. Davon sind 17 Paare mit unterschiedlicher Signalgebung vorhanden und 31 Paare mit synchroner Signalgebung.

Für jeden Kreuzungspfad werden zunächst automatisiert die mittleren Kreuzungsüberfahrten und die Haltelinien ermittelt. Anhand dieser Informationen werden Schätzungen über den Grünbeginn und Grünbeobachtungen extrahiert. Damit wird die Umlaufdauer bestimmt und Änderungen der Parameter auf makroskopischer Steuerungsebene werden ermittelt. Zur Bestimmung der Signalgruppen wird das entwickelte Distanzmaß entsprechend Abschnitt 6.4 ermittelt. Auf Basis des Distanzmaßes und eines adaptiven Schwellwertparameters wird eine einfache lineare binäre Klassifikation für die Synchronität der Signalgebungen durchgeführt. Da der Schwellwert der Klassifikation adaptiv ist, wird eine ROC-Kurve erstellt. Die resultierende ROC-Kurve für den vorliegenden Testdatensatz ist in Abbildung 6.23 dargestellt. Das im Rahmen dieser Arbeit entwickelte Distanzmaß, das auf einem Bayes'schen Modellvergleich basiert, wird dabei verglichen mit den aus der Literatur bekannten Distanzmaßen *L1-Distanz*, *Kullback-Leibler-Divergenz*, *Kolmogorov-Smirnov Distanz* und *Earth Movers Distanz* wie in Abschnitt 2.2 definiert.




Bild 6.23: Receiver Operating Characteristic für die Bestimmung von Signalgruppen auf Basis von 48 beispielhaften Paaren von Fahrrichtungen. Im Vergleich zu den aus der Literatur bekannten Distanzmaßen liefert der im Rahmen dieser Arbeit entwickelte Ansatz über den Bayes'schen Modellvergleich das beste Ergebnis. Die bestmögliche Genauigkeit auf dem vorliegenden Testdatensatz beträgt 93.8%.

Tabelle 6.4: Ergebnis Signalgruppenbestimmung

		Klassifikation	
		gleich	ungleich
Referenz	gleich	29	2
	ungleich	1	16

Bei einer linearen binären Klassifikation mit variierenden Schwellwerten des eingeführten Distanzmaßes existiert ein bestimmter Wert, für den die bestmögliche Genauigkeit auf den Daten erreicht wird. Der vorliegende Datensatz für die Evaluierung wird mit einer bestmöglichen Genauigkeit von 93.8% und einem zugehörigen F-Maß von 0.951 klassifiziert. Der Schwellwert für das Distanzmaß ergibt sich dabei zu 0.37. Der zugehörige Punkt auf der ROC-Kurve ist in Abbildung 6.23 hellrot markiert. Tabelle 6.4 zeigt die Wahrheitsmatrix für die binäre Klassifikation am Arbeitspunkt mit der besten Genauigkeit.

Zur Analyse der benötigten Anzahl an Überfahrten ist in Abbildung 6.24 mit dem AUC-Wert die Fläche unterhalb der ROC-Kurve in Abhängigkeit von der verwendeten Anzahl an Überfahrten dargestellt. Dazu wurden aus den vorhandenen 48 Paaren von Kreuzungspfaden 32 Paare so ausgewählt, dass mindestens ein Pfad mit mehr als 60 Überfahrten vorhanden ist. Für jedes dieser Paare wurde eine bestimmte Anzahl an Überfahrten insgesamt 30-mal zufällig ausgewählt und die Methodik zur Erkennung von Signalgruppen angewendet. Die blauen Punkte in Abbildung 6.24 zeigen die AUC-Werte für die zufällige Auswahl an Überfahrten. Der rote Verlauf entspricht dem Mittel dieser Ergebnisse.




Bild 6.24: AUC in Abhängigkeit von der verwendeten Anzahl an Überfahrten. Insgesamt wurden 32 beispielhafte Paare von Fahrtrichtungen mit jeweils mindestens 60 Überfahrten verwendet. Aus diesen Überfahrten wurde die entsprechende Anzahl an Überfahrten jeweils 30-mal zufällig ausgewählt. Die blauen Punkte entsprechen den AUC-Werten der einzelnen Ergebnisse. Die rote Kurve zeigt den Verlauf des Mittelwerts der AUC-Werte.

6.7 Diskussion

Abbildung 6.22 zeigt das Ergebnis der Evaluation der vorgestellten Methodik zur Ermittlung von Programmwechseln von Lichtsignalanlagen mit realen Daten einer Kreuzung. Das Programm zwischen 6:00 und 9:00 Uhr mit der Umlaufdauer $T_2 = 90$ s, sowie das Programm zwischen 9:00 Uhr und 15:00 Uhr mit der Umlaufdauer $T_1 = 70$ s, werden weitestgehend korrekt detektiert. Allerdings wird das Programm zwischen 15:00 und 21:00 Uhr mit der Umlaufdauer $T_2 = 90$ s nicht erkannt. Der Grund hierfür liegt darin, dass entsprechend Abbildung 6.20 wenige Daten in diesem Zeitraum vorhanden sind. Trotz der Falscherkennung des Programms werden insgesamt 77.9% der geschätzten Grünbeobachtungen korrekt zugeordnet. Zur Bestimmung von Signalgruppen sollten die Eingangsdaten in einem Zeitfenster liegen, in dem die Umlaufzeit konstant bleibt. Aus den möglichen Zeitfenstern wird das Fenster mit der höchsten Anzahl an Beobachtungen gewählt. Für das gegebene Beispiel ergibt sich dieses Fenster zwischen 6:08 Uhr und 8:52 Uhr. In diesem Zeitfenster werden 97.2% der Beobachtungen der korrekten Umlaufdauer $T_2 = 90$ s zugeordnet.

Für die Bestimmung von Signalgruppen ist anhand der ROC-Kurven in Abbildung 6.23 ersichtlich, dass das neu eingeführte Distanzmaß für diese Anwendung performanter ist im Vergleich zu den aus der Literatur vorgestellten Maßen. Die Auswertung des AUC gegenüber der verwendeten Anzahl an Überfahrten in Abbildung 6.24 zeigt, dass mehr als 40 Überfahrten keine wesentliche Verbesserung des Ergebnisses erzielen.

7 Längsregelung an Kreuzungen mit Lichtsignalanlage

Fahrerassistenzsysteme, wie ACC, die den Fahrer mit einer automatisierten Längsregelung unterstützen, sind bereits in vielen Fahrzeugen als Sonderausstattung verfügbar [11, 12, 102]. Die Regelung berücksichtigt eine eingestellte Wunschgeschwindigkeit sowie einen gewünschten Abstand bzw. eine Zeitlücke zu einem Vorderfahrzeug. Aktuell verfügbare Systeme sind für Autobahnen und autobahnähnliche Straßen optimiert. Die fehlende Längsregelung an Kreuzungen mit Lichtsignalanlage wirkt sich in urbanen Gebieten negativ auf den Komfort aus, da manuelle Eingriffe in entsprechenden Situationen nötig sind. Im Rahmen dieser Arbeit wird ein prototypisches Komfortsystem zur automatisierten Längsregelung an Kreuzungen mit Lichtsignalanlage entwickelt. Dazu werden die ermittelten Kreuzungsinformationen über Vorfahrtsregel, Haltelinienposition und Signalgruppen verwendet. Ein essenzieller Bestandteil des Systems ist die rechtzeitige Detektion des relevanten Signals an Kreuzungen mit einer Lichtsignalanlage. Für diese Herausforderung wird eine neuartige Methode basierend auf der Information über Signalgruppen sowie der Abbiegeintention des Fahrers vorgestellt.

7.1 Anforderungen an das System

Zur Ermöglichung einer komfortablen Reaktion des Systems bei der Anfahrt an eine Kreuzung mit Lichtsignalanlage existieren unterschiedliche Anforderungen. Im Folgenden wird eine Auswahl an grundlegenden funktionalen Anforderungen hergeleitet.

Das System muss das Fahrzeug bei einem roten Lichtsignal vor der zugehörigen Haltelinie bis zum Stillstand automatisiert verzögern. Bei grünem Lichtsignal muss auf die eingestellte Wunschgeschwindigkeit bzw. Zeitlücke zu einem Vorderfahrzeug geregelt werden.

Für eine angenehme Verzögerung bei rotem Lichtsignal ist die Detektion des relevanten Lichtsignals in ausreichender Entfernung nötig. In Deutschland sind Lichtsignalanlagen bis zu einer zulässigen Höchstgeschwindigkeit von 70 km/h erlaubt. Bei einer komfortablen mittleren Verzögerung von 2 m/s^2 ergibt sich damit ein Bremsweg von 95 m. Inklusiv einem Puffer für Ungenauigkeiten muss ein System zum automatisierten Verzögern auf rote Lichtsignale das relevante Lichtsignal in einer Distanz von 100 m detektieren.

Neben einer zuverlässigen Detektion des relevanten Lichtsignals für eine komfortable Verzögerung muss das Fahrzeug bei rotem Lichtsignal vor der gültigen Haltelinie zum Stillstand kommen. Untersuchungen zum Verhalten menschlicher Fahrer an signalisierten Knotenpunkten [91] zeigen, dass die Distanz zur Haltelinie im Intervall $[0.63, 1.54] \text{ m}$ liegt. Das System soll daher derart ausgelegt werden, dass das Fahrzeug bei einem automatisierten Anhaltevorgang innerhalb eines Toleranzbereiches von $[0.5, 1.5] \text{ m}$ vor der Haltelinie zum Stillstand kommt.

Im Falle eines erkannten gelben Lichtsignals muss das Fahrzeug entsprechend der gültigen Verkehrsregeln komfortabel reagieren. Ist eine Überquerung der Haltelinie unter Einhaltung des gültigen Geschwindigkeitslimits innerhalb der Gelbphase möglich, soll eine Verzögerung unterdrückt werden. Falls eine Überquerung innerhalb der Gelbphase nicht möglich ist, muss das Fahrzeug vor der Haltelinie bis zum Stillstand verzögert werden. Vorderfahrzeuge, welche die Haltelinie in diesem Szenario noch überqueren, müssen als Regelobjekt ignoriert werden.

Befindet sich das Fahrzeug außerhalb von Kreuzungsbereichen, sind sämtliche Lichtquellen zu ignorieren, um eine Falschauslösung zu vermeiden. Baustellensituationen werden in diesem System nicht berücksichtigt und müssen getrennt betrachtet werden. Fehlauslösungen an Baustellen werden damit toleriert. Der

Fahrer ist für die Einhaltung der Verkehrsregeln in jeder Situation verantwortlich und muss das System dauerhaft überwachen.

Zusammenfassend ergeben sich folgende Anforderungen an das System:

1. Bei einem roten Lichtsignal muss das Fahrzeug vor der zugehörigen Haltelinie bis zum Stillstand automatisiert verzögert werden.
2. Bei einem grünen Lichtsignal muss das Fahrzeug auf die eingestellte Wunschgeschwindigkeit bzw. Zeitlücke zu einem Vorderfahrzeug geregelt werden.
3. Das relevante Lichtsignal muss in einer Entfernung von 100m detektiert werden um eine komfortable Verzögerung von 2m/s^2 im Mittel zu ermöglichen.
4. Das Fahrzeug muss bei rotem Lichtsignal mit einem Abstand im Intervall von $[0.5, 1.5]$ m vor der Haltelinie zum Stillstand kommen.
5. Das System muss bei einer Gelbphase so reagieren, dass die gültigen Verkehrsregeln während der gesamten Überfahrung der Kreuzung eingehalten werden.
6. Außerhalb von Kreuzungsbereichen darf das Fahrzeug trotz erkannter Lichtsignale nicht automatisiert verzögert werden.

Die genannten Anforderungen haben nicht den Anspruch einer vollständigen Spezifikation eines Fahrerassistenzsystems, sondern dienen lediglich als Grundlage zur Umsetzung eines prototypischen Systems für diese Arbeit.

7.2 Detektion des relevanten Lichtsignals

Die korrekte Detektion des relevanten Lichtsignals an Kreuzungen mit einer Lichtsignalanlage ist eine wichtige Teilfunktion zur Erfüllung der Anforderungen 1-3 des vorgestellten Systems sowie weiterer innerstädtischer Assistenzsysteme wie in Abschnitt 1.1 vorgestellt. Zur kamerabasierten Erkennung des

Signalzustandes von Lichtsignalanlagen existieren bereits mehrere Vorarbeiten [78, 79, 80, 81, 82, 59, 83, 84, 85]. Zusätzlich zum Signalzustand ist es ebenfalls möglich die relative Position der einzelnen erkannten Lichtsignale kamera-basiert zu schätzen [86]. Mit derartigen Systemen sind Ersterkennungsdistanzen bis zu 150m möglich [59], wodurch die nötige Distanz gemäß Anforderung 3 erreicht wird. Allerdings bleibt die Herausforderung der Auswahl des relevanten Signals an Kreuzungseinfahrten mit verschiedener Signalgebung für unterschiedliche Fahrtrichtungen. Besonders problematisch ist die Auswahl bei großen Abständen zur Haltelinie. Der Grund hierfür liegt darin, dass zum einen die Abbiegeintention des Fahrers in großer Entfernung zur Kreuzung unsicher ist und zum anderen eine Zuordnung einzelner Lichtsignale zu Fahrstreifen bzw. Fahrtrichtungen nur mit niedriger Genauigkeit erfolgt. Zusätzlich zur Detektion des relevanten Signals gibt es weitere Herausforderungen, wie die Identifikation von Falscherkennungen entsprechend Anforderung 6. Vor allem nachts existiert eine Vielzahl an Lichtquellen, die Lichtsignalen sehr ähnlich sind.

Zur Bewältigung der Herausforderungen bei der Erkennung von Lichtsignalen liefern digitale Karten wichtiges Vorwissen für das System. Vorfahrtsregeln an Kreuzungen sind eine wichtige Information zur Unterstützung einer kamerabasierten Erkennung von Lichtsignalen. Auf Basis des Verfahrens, welches in Kapitel 4 beschrieben wurde, ist es möglich Vorfahrtsregeln an Kreuzungen in einer automatisch aktualisierbaren digitalen Karte zu repräsentieren. Anhand dieser Karteninformation sowie der Fahrzeugposition können Detektionen von Lichtsignalen durch ein Kamerasystem plausibilisiert und ortsbasiert gefiltert werden. Bei Lichtsignalanlagen mit mehreren Signalgruppen ist das relevante Lichtsignal zu ermitteln, falls die Signalgruppen unterschiedliche Lichtsignale anhand von leuchtenden Pfeilen zeigen. Selbst für den Fall, dass die Intention des Fahrers bekannt ist, bleibt die Herausforderung der Detektion des relevanten Signals in großen Abständen zur Lichtsignalanlage. Aktuell verfügbare Kamerasysteme zur Detektion von Lichtsignalen erkennen leuchtende Pfeile bei Distanzen von etwa 30m. Bei höheren Distanzen gibt das System lediglich eine dreidimensionale relative Position für jedes einzelne Signal und dessen Signalzustand aus.

Eine einfache Möglichkeit das relevante Signal zu detektieren ist die Schätzung eines Fahrerschlauchs und die Auswahl des Signals, welches auf Basis einer orthogonalen Projektion die geringste Distanz zum Fahrerschlauch aufweist. Dieser Ansatz ist jedoch vor allem in hohen Distanzen fehleranfällig, da die Fahrstreifengeometrie und das Lenkverhalten des Fahrers großen Einfluss auf das Ergebnis haben. Ein weiterer Ansatz, welcher in [26] und [82] angewendet wurde, sieht vor, dass digitale Karten mit der globalen dreidimensionalen Position oder distinkten bildbasierten Merkmalen von einzelnen Signalgebern vorhanden sind. Zusätzlich wird die Zuordnung der einzelnen Signalgeber zu den Fahrtrichtungen manuell in der Karte durchgeführt. Durch die Fusion mit der geschätzten Relativposition aus der Kameraerkennung wird das relevante Signal erkannt. Nachteile dieses Ansatzes sind jedoch der hohe Speicheraufwand für die Kartenattribute und die hohen Anforderungen an die Genauigkeit der Eigenlokalisierung, da Positionsungenauigkeiten zu falschen Zuordnungen führen.

Im Rahmen dieser Arbeit wird ein weiterer Ansatz zur Erkennung des relevanten Signals vorgestellt. Dieser basiert auf Informationen über die Gruppierung einzelner möglicher Fahrtrichtungen in Bezug auf die Signalgebung. Diese Informationen werden entsprechend der Methodik aus Abschnitt 6.4 automatisiert generiert. Voraussetzung für die vorgestellte Methodik ist, dass die Informationen als zusätzliche Attribute einer digitalen Karte vorliegen, wie in Abbildung 7.1 für eine exemplarische Kreuzung dargestellt. Die Haltelinien werden dabei auf die mittleren Kreuzungspfade projiziert, welche entsprechend Kapitel 3 ermittelt werden. Jede Haltelinie ist durch einen Positionswert und eine Orientierung repräsentiert. Bei baulichen Veränderungen ermöglicht die automatisierte Erstellung eine Aktualisierung der Attribute über das Internet.

Auf Basis der vorhandenen Kartenattribute und der Fahrzeugposition werden falsch positiv erkannte Lichtsignale der Kamera gefiltert, falls sich das Fahrzeug nicht in der Nähe einer Lichtsignalanlage befindet. Zusätzlich werden die einzelnen erkannten Signale, entsprechend dem Versatz zur nächsten relevanten Haltelinie, ausgewählt. Dadurch werden falsche Detektionen zum Beispiel von Fußgängersignalen oder Lichtsignale nachfolgender Kreuzungen gefiltert.







Bild 7.1: Kreuzungsinformationen als Karteninformationen zur Verbesserung einer kamerabasierten Erkennung von Lichtsignalanlagen. Enthaltene Informationen sind Signalgruppen , Haltelinien  und Kreuzungsmittelpunkte . Bilder ©Google.

Der Versatz von Lichtsignal zu Haltelinie ist länderabhängig und wird auf Basis der ungenauen Eingangsgrößen

- Fahrzeugposition,
- Haltelinienposition
- und Entfernung des Lichtsignals

geschätzt. Da die Genauigkeit der kamerabasierten Entfernungsschätzung zum Lichtsignal sowie zur Haltelinie abhängig ist von der Entfernung zur Kreuzung, werden die Daten des vorliegenden Sensoraufbaus statistisch ausgewertet. Basierend auf dem Ergebnis wird ein Ausreißerfilter eingeführt, dessen Parameter abhängig vom Abstand zur Kreuzung bzw. zur Haltelinie sind. Im vorliegenden Aufbau ergibt sich eine symmetrische Verteilung des Versatzes der Lichtsignalposition zur Haltelinienposition, wobei die Varianz mit zunehmender Entfernung

größer wird. Da eine symmetrische Verteilung vorliegt, werden die Ausreißer nach den Regeln von Tukey anhand des dreifachen Interquartilsabstands erkannt [103]. Der Interquartilsabstand wird abhängig von der Entfernung bestimmt. Befindet sich das Fahrzeug in der Nähe einer Kreuzung und die Kamera erkennt zugehörige Lichtsignale, wird das System zur automatisierten Längsregelung an Kreuzungen mit Lichtsignalanlage aktiv. Zusätzlich zur Farbe eines Signalgebers schätzt das Kamerasystem dessen Position relativ zum Fahrzeug. Anhand der Querablage der einzelnen Signalgeber in Bezug auf den Fahrschlauch werden benachbarte Signale mit gleicher Signalgebung gruppiert. Aus dieser Gruppierung ergeben sich die beobachteten Signalgruppen. An einer Kreuzungseinfahrt entspricht die maximal mögliche Anzahl an Signalgruppen der Anzahl an möglichen Fahrtrichtungen. In Deutschland sind zwei oder drei mögliche Fahrtrichtungen an einer Kreuzungseinfahrt mit Lichtsignalen üblich. Im Folgenden wird die Methodik zur Auswahl des relevanten Lichtsignals unter Verwendung der vorliegenden Karteninformationen erläutert. Dabei werden die möglichen Beobachtungsszenarien unterschiedlicher Lichtsignalkombinationen für eine Kreuzungseinfahrt mit drei möglichen Fahrtrichtungen berücksichtigt. In diesen Szenarien wird dabei eine ideale Beobachtung der einzelnen Signalgruppen vorausgesetzt.


Eine beobachtete Signalgruppe Zeigen alle beobachteten Lichtsignale dasselbe Signal, wird dieses Signal als relevant ausgewählt.

Drei beobachtete Signalgruppen Werden drei unterschiedliche Gruppen von Signalen beobachtet, ist die Zuordnung der Signale zu den Fahrtrichtungen entsprechend der lateralen Position der Signale auch ohne weitere Karteninformation eindeutig. Ausschlaggebend für die Wahl des relevanten Signals ist die Intention des Fahrers hinsichtlich der gewünschten Fahrtrichtung, bzw. die gewählte Route beim hochautomatisierten Fahren. Zur Erkennung der Fahrerintention im manuellen Fahrmodus kann dabei beispielsweise vorausgesetzt werden, dass eine Route im Navigationssystem eingegeben wird. Alternativ ist es mög-

lich, auf Basis von Sensordaten wie der Geschwindigkeit und dem Zustand des Fahrtrichtungsanzeigers, die gewünschte Fahrtrichtung automatisch zu erkennen [24, 104, 105, 106].

Zwei beobachtete Signalgruppen Ein Beispiel für zwei beobachtete Signalgruppen wird in Abbildung 7.2 dargestellt. In diesem Szenario besteht die Kreuzungseinfahrt aus einer S-Kurve, weshalb der einfache Ansatz der Signalzuordnung mittels Fahrschlauch fehlschlägt. Bei zwei beobachteten Signalgruppen wird ebenfalls die Intention des Fahrers bzw. die gewählte Route im automatisierten Fahrmodus bestimmt. Wird das Fahrzeug bzw. der Fahrer einen Abbiegevorgang ausführen, ist die Zuordnung des relevanten Signals wiederum ohne weitere Karteninformation möglich, da je ein beobachtetes Signal für Linksabbieger sowie für Rechtsabbieger vorhanden ist. Falls die Kreuzung in gerader Richtung überquert wird, ist die Zuordnung ohne weitere Informationen nicht eindeutig möglich. In diesem Fall wird die Information über die Gruppierung der Signale aus der digitalen Karte hinzugezogen. Dadurch ist die Zuordnung des relevanten Signals für eine gerade Überquerung der Kreuzung wiederum eindeutig. Existiert beispielsweise eine separate Signalgebung für Linksabbieger und ist die Signalgebung für Geradeausfahrer und Rechtsabbieger synchron, so ist für eine gerade Überquerung das entsprechende rechte Signal bei lateraler Ordnung relevant. An der exemplarischen Kreuzungseinfahrt in Abbildung 7.2 sind zwei unterschiedliche Signalgruppen vorhanden. Falls die Kreuzung geradeaus überquert wird, gibt es für das relevante Signal zwei mögliche Optionen. Anhand der Information über die Gruppierung der Signale kann diese Mehrdeutigkeit aufgelöst werden, da nur eine der beiden möglichen Optionen der Signalverteilung über den Fahrtrichtungen möglich ist.

Die Methodik ist dabei nicht beschränkt auf Kreuzungseinfahrten mit drei möglichen Fahrtrichtungen. Existieren nur zwei mögliche Fahrtrichtungen, sind keine zusätzlichen Kartenattribute nötig zur Zuordnung des relevanten Signals. Sind mehr als drei mögliche Fahrtrichtungen vorhanden, ist die Methodik entsprechend erweiterbar.



(a) Relevantes Signal?



(b) Grün

Bild 7.2: Anfahrtssituation an eine Kreuzung mit Lichtsignalanlage. Ist beabsichtigt die Kreuzung geradeaus zu überqueren, werden Karteninformationen über Signalgruppen verwendet um das relevante Lichtsignal zu identifizieren.

Zur Evaluierung des Mehrwerts der Nutzung von Karteninformationen für das Teilsystem der kamerabasierten Erkennung des relevanten Lichtsignals wird der vorgestellte Ansatz mit einem einfachen Ansatz verglichen. Bei letzterem wird das relevante Signal ausgewählt, indem ein Fahrschlauch geschätzt wird und die einzelnen Signale orthogonal darauf projiziert werden. Das Signal mit der geringsten Distanz zum Fahrschlauch entspricht dem geschätzten relevanten Signal. Für den Vergleich wurden mit einem Versuchsträger insgesamt 344 Überfahrten an 38 Kreuzungen in München aufgezeichnet. Daraus ergeben sich 117 Minuten Fahrzeit in denen mindestens ein Lichtsignal durch das Kamerasystem detektiert wurde. Die Auswertung erfolgt auf einzelnen Szenen mit einem Rechenzyklus von 100 ms, deshalb wurden auf Basis der zusätzlich aufgezeichneten Videobilder insgesamt 70176 Einzelszenen mit dem korrekten relevanten Signal gelabelt. In den aufgezeichneten Daten sind neben den erkannten Lichtsignalen und deren relativer Position zum Fahrzeug auch die absolute Position, die Orientierung und der Lenkwinkel enthalten. Die vorgestellte Methodik benötigt des Weiteren die Intention des Fahrers. Diese wird im Rahmen der Evaluierung als gegeben vorausgesetzt. Für jede Kreuzungsüberfahrt wird deshalb die gewählte Fahrtrichtung in einem Nachbearbeitungsschritt ermittelt und zu jeder Einzelszene einer Kreuzungsüberfahrt abgelegt.

Tabelle 7.1 zeigt die Genauigkeit des Ansatzes ohne Karteninformation im Vergleich zum Ansatz mit Verwendung der generierten Karteninformationen. Die Ansätze werden mit verschiedenen Rahmenbedingungen evaluiert. Neben variierenden Bereichen für die Distanz d_H zur Haltelinie werden Lichtsignalanlagen mit einer oder mehreren Gruppen untersucht. Die Auswertung erfolgt auf Einzelszenen, wobei alle Szenen bis 500 ms nach dem Zeitpunkt eines Signalwechsels nicht in die Berechnung der Genauigkeit der Umschaltvorgänge einfließen. Der Grund hierfür liegt darin, dass das Kamerasystem eine Trägheit aufweist. Da diese unterhalb der durchschnittlichen menschlichen Reaktionszeit liegt, wird die Trägheit toleriert.

Die Ergebnisse zeigen eine Verbesserung durch die Karteninformationen unter sämtlichen Rahmenbedingungen um mindestens 1.5 % und durchschnittlich

2.9%. Der Unterschied ist dabei geringer, falls die Distanz zur Haltelinie kleiner ist. Dies liegt zum einen darin, dass die Positionsschätzung der Lichtsignale durch die Kamera besser ist. Zum anderen nimmt die Genauigkeit der Schätzung der Fahrstreifenkrümmung bei kleineren Distanzen zu. Bei Lichtsignalanlagen mit mehreren Signalgruppen an einer Kreuzungseinfahrt wird durch Karteninformationen eine noch höhere Verbesserung der Genauigkeit erreicht. Bei Kreuzungseinfahrten mit nur einer Signalgruppe bringt lediglich der longitudinale Filter anhand der Distanz zur Haltelinie einen Mehrwert, weshalb die Verbesserung der Genauigkeit durch Karteninformationen nur eingeschränkt möglich ist. Der größte Mehrwert der Karteninformation für alle Arten von Lichtsignalanlagen ergibt sich mit 4.8% bei Distanzen von $75\text{ m} < d_H < 100\text{ m}$. Mit 5.2% ergibt sich ebenfalls im selben Distanzbereich der größte Mehrwert bei Lichtsignalanlagen mit mehreren Signalgruppen. Die Unterschiede zwischen den beiden Methoden sind unter sämtlichen Rahmenbedingungen statistisch signifikant unter Anwendung des χ^2 -Vierfeldertests und einem α -Irrtumsniveau von 0.1%. Der Grund hierfür ist, dass die Stichproben mit mindestens 6728 Einzelszenen sehr groß sind.

Insgesamt wird nachgewiesen, dass Karteninformationen einen signifikanten Mehrwert für die Erkennung des relevanten Lichtsignals liefern. Dabei ist der Unterschied in der Genauigkeit bei Lichtsignalanlagen mit mehreren Signalgruppen und bei großen Distanzen von $75\text{ m} < d_H < 100\text{ m}$ zur Haltelinie am höchsten. Je nach Fahrzeuggeschwindigkeit ist die Auswahl des Manövers für komfortable Verzögerungen in diesem Distanzbereich nötig.

Tabelle 7.1: Genauigkeit einer kamerabasierten Erkennung von Lichtsignalen abhängig vom Abstand d_H zur Haltelinie und Anzahl der Signalgruppen

Rahmenbedingung	Genauigkeit			Einzel- szenen
	ohne Karte	mit Karte	Delta	
$d_H > 0\text{m}$	95.94 %	98.23 %	+2.29 %	67482
$0\text{m} < d_H < 100\text{m}$	96.89 %	99.03 %	+2.14 %	60754
$d_H > 100\text{m}$	87.72 %	91.26 %	+3.54 %	6728
$75\text{m} < d_H < 100\text{m}$	92.96 %	97.72 %	+4.76 %	7704
$50\text{m} < d_H < 75\text{m}$	97.55 %	99.39 %	+1.84 %	9275
$25\text{m} < d_H < 50\text{m}$	97.33 %	99.33 %	+2.00 %	12645
$0\text{m} < d_H < 25\text{m}$	97.62 %	99.16 %	+1.54 %	31130
Eine Signalgruppe $0\text{m} < d_H < 100\text{m}$	97.47 %	99.75 %	+2.28 %	9236
Mehrere Signalgruppen $0\text{m} < d_H < 100\text{m}$	96.78 %	98.90 %	+2.12 %	51518
Mehrere Signalgruppen $50\text{m} < d_H < 100\text{m}$	94.92 %	98.54 %	+3.62 %	15243
Mehrere Signalgruppen $75\text{m} < d_H < 100\text{m}$	92.61 %	97.79 %	+5.18 %	7060

7.3 Prototypische Umsetzung des Systems

Das System wurde in einen Versuchsträger als Erweiterung der bestehenden radarbasierten Abstandsregelautomatik integriert. Die Bestandteile des Systems sind ein kommerziell verfügbares kamerabasiertes System zur Detektion von Lichtsignalen, eine weitere Kamera mit einer prototypischen Implementierung für die Detektion von Haltelinien und eine digitale Karte für ausgewählte Kreuzungen. Die Karte enthält jeweils den Kreuzungsmittelpunkt, Haltelinienpositionen und -orientierungen sowie Signalgruppen für Fahrtrichtungen entsprechend Abbildung 7.1. Das in Abschnitt 7.2 beschriebene Teilsystem zur Detektion des relevanten Lichtsignals ist ebenfalls in den Versuchsträger integriert. Der erweiterte Funktionsumfang wird parallel zur Abstandsregelung in einem zyklischen Framework implementiert. Ergebnis des Algorithmus ist die Entscheidung, ob eine automatisierte Verzögerung eingeleitet werden soll und in welcher Distanz sich die Haltelinie bzw. das Bremsziel befindet. In jedem Zyklus liegen neben den Kartendaten ebenfalls die Geschwindigkeit, die globale Position auf Basis eines GPS-Systems und die Detektionen der einzelnen Lichtsignale mit deren Relativposition zum Fahrzeug vor.

Anfahrt an eine Kreuzung mit Lichtsignalanlage Basierend auf der aktuellen Position und der digitalen Karte wird zu Beginn eines jeden Zyklus ausgewertet, ob sich das Fahrzeug in der Nähe einer Kreuzung mit Lichtsignalanlage befindet und in Richtung dieser Kreuzung orientiert ist. In diesem Fall wird das kamerabasierte System zur Lichtsignalerkennung aktiviert. Durch die ortsbasierte Aktivierung werden Falscherkennungen außerhalb von Kreuzungsbereichen vermieden und damit Anforderung 6 aus Abschnitt 7.1 erfüllt. Zusätzlich wird die relevante Einfahrt der Kreuzung und die damit verknüpfte Haltelinienposition aus der Karte ermittelt.

Verzögerung bei rotem Lichtsignal Erkennt das System ein rotes Lichtsignal als relevant, wird eine automatisierte Verzögerung eingeleitet. Die kamera-

basierte Erkennung der Haltelinie liefert eine exakte Schätzung der Distanz mit einer Genauigkeit von 0.5m. Die Genauigkeit einer kamerabasierten Schätzung ist nötig, um Anforderung 4 des Systems zu erfüllen, da die ermittelten Haltelinienpositionen aus Flottendaten nur mit einer Genauigkeit von etwa 5m ermittelt werden. Ein Kamerasystem erkennt jedoch Haltelinien erst in Abständen von bis zu 20m. Für eine komfortable Verzögerung muss eine Bremsung bei Geschwindigkeiten größer 30km/h früher eingeleitet werden. Aus diesem Grund wird das Bremsziel in einer ersten Verzögerungsphase entsprechend der Haltelinienposition aus der digitalen Karte gewählt. Sobald die Haltelinie durch das Kamerasystem detektiert wird, ist eine exakte Positionsschätzung und damit eine exakte Zielbremsung in einer zweiten Verzögerungsphase möglich. In der ersten Phase ist zusätzlich zur Ungenauigkeit des Kartenattributs die Ungenauigkeit der eigenen Positionsschätzung mit einem Standard-GPS System von bis zu 7.8m in 95% der Messungen [67, S. 22] zu berücksichtigen. Damit wird die Distanz zur Haltelinie mit einer Ungenauigkeit von 12.8m geschätzt unter der Annahme unkorrelierter Fehler. In der ersten Anbremsphase wird das Bremsziel mit 5m vor der geschätzten Haltelinienposition gewählt. Befindet sich die Haltelinie um 12.8m näher als geschätzt, wird der Fehler etwa 20m vor der tatsächlichen Haltelinienposition durch die Kamera erkannt. Die Verschiebung des Bremspunktes um 7.8m wird durch eine verstärkte Verzögerung ausgeglichen. Ist die geschätzte Distanz zur Haltelinie in der Realität um 12.8m höher, wird der Fehler durch das Kamerasystem noch vor einem Stillstand erkannt und durch eine geringere Verzögerung ausgeglichen. Dadurch wird in beiden Extremfällen ein exaktes und komfortables Bremsmanöver sichergestellt. Die Anforderungen 1-4 des Systems sind damit erfüllt.

Reaktion bei gelbem Lichtsignal In Deutschland betragen die Gelbdauern von Lichtsignalanlagen in der Regel 3s bei einer zulässigen Höchstgeschwindigkeit von 50km/h, 4s bei 60km/h und 5s bei 70km/h (VwV-StVO §37, 17 IX.). In der digitalen Karte sind diese Dauern für jede Kreuzung hinterlegt. Schaltet die Anlage während einer Anfahrt an eine Kreuzung von einem grünen Signal

auf Gelb um, wird anhand der aktuellen Geschwindigkeit, geschätzter Distanz zur relevanten Haltelinie und bekannter Gelbdauer ermittelt, ob eine automatisierte Verzögerung bis zum Stillstand vor der Haltelinie möglich ist. In diesem Fall leitet das System eine Verzögerung ein. Falls die automatisierte Verzögerung nicht ausreichend ist, um vor der Haltelinie zum Stillstand zu kommen, überprüft der Algorithmus, ob bei konstanter Geschwindigkeit die Haltelinie innerhalb der Gelbphase überfahren wird. Für den Fall, dass aufgrund von Systemgrenzen keine der beiden Strategien zu einem regelkonformen Verhalten führt, wird eine Verzögerung eingeleitet und der Fahrer zur Übernahme der Situation aufgefordert. Durch diese Strategie wird Anforderung 5 erfüllt.

Reaktion auf ein Vorderfahrzeug Ein ACC-System regelt das Fahrzeug auf eine gewünschte Geschwindigkeit des Fahrers. Parallel dazu wird bei vorhandenem Vorderfahrzeug eine Zeitlücke zu diesem Fahrzeug aufrechterhalten. Das Zielobjekt für ein ACC-System entspricht dem Objekt, bzw. Vorderfahrzeug im eigenen Fahrschlauch mit der geringsten Zeitlücke und damit dem Objekt mit geringstem Abstand. Für das vorgestellte System ist diese vereinfachte Betrachtung nicht ausreichend. Bei gelbem Lichtsignal tritt häufig der Fall auf, dass ein potentiell Vorderfahrzeug die Haltelinie noch während der Gelbphase überquert, wobei für das eigene Fahrzeug eine Verzögerung eingeleitet werden muss. In diesem Fall hat die Haltelinie als Zielobjekt, trotz einer größeren Zeitlücke, Vorrang vor dem Vorderfahrzeug. Das vorgestellte System verwendet zur Lösung dieses Konflikts statt der Zeitlücke die Time-To-Collision (TTC) um das Zielobjekt auszuwählen.

Abbildung 7.3 zeigt eine technische Visualisierung des prototypischen Systems. Neben der aktuellen Geschwindigkeit, der eingestellten Wunschgeschwindigkeit, dem als relevant detektierten Signal und der Verzögerungsentscheidung des Systems werden die geschätzten Distanzen zur Haltelinie, basierend auf der aktuellen Position und der digitalen Karte sowie dem Kamerasystem, dargestellt.




Bild 7.3: Umsetzung eines Komfortsystems zur automatisierten Verzögerung bei roten Lichtsignalen. In der Situation werden sowohl das Lichtsignal, als auch die Haltelinie korrekt detektiert. Ein Bremsmanöver führt zu einem automatisierten Stopp vor der Haltelinie. Die geschätzte Distanz der Haltelinie basierend auf der aktuellen GPS-Positionierung unterscheidet sich in dieser Situation zur geschätzten Distanz basierend auf der detektierten Haltelinie im Bild um 3 m.

8 Zusammenfassung und Ausblick

Künftige Fahrerassistenzsysteme und hochautomatisierte Fahrfunktionen verwenden digitale Karten und stellen hohe Anforderungen an die Aktualität der enthaltenen Informationen. In der vorliegenden Arbeit wurden automatisierte Verfahren zur Inferenz von Kreuzungsinformationen aus Flottendaten eingeführt. Der Crowdsourcing Ansatz ermöglicht eine zeitnahe Detektion von baulichen Änderungen und damit eine Verbesserung der Aktualität digitaler Karten. Die Arbeit beschreibt Verfahren zur Ermittlung folgender Kreuzungsinformationen:

- Kreuzungstopologie und -geometrie,
- Vorfahrtsregel,
- Haltlinienposition,
- Gruppen von Kreuzungspfaden mit synchroner Lichtsignalgebung.

Zur Repräsentation einer Straßenkreuzung wird ein Modell vorgestellt, welches eine Kreuzung anhand eines Kreuzungsmittelpunkts sowie Einfahrten und Ausfahrten repräsentiert. Bisherige digitale Karten beinhalten keine explizite Modellierung von Straßenkreuzungen. Auf Basis des erarbeiteten Modells wurden Verfahren entwickelt, um die Topologie und Geometrie der Kreuzung aus Überfahrten automatisiert zu extrahieren. Dazu werden zunächst die Einfahrten und Ausfahrten über ein mehrstufiges Gruppierungsverfahren ermittelt und die Topologie basierend auf verknüpfenden Überfahrten zwischen Ein- und Ausfahrten bestimmt. Im Anschluss wird die Geometrie über mittlere Kreuzungspfade aus den Überfahrten extrahiert.

Aufbauend auf der erarbeiteten Kreuzungsrepräsentation wurde eine Methode zur Klassifikation der Vorfahrtsregel für jeden Kreuzungspfad eingeführt. Dabei werden aus sämtlichen Überfahrten, die für einen Kreuzungspfad vorliegen, statistische Merkmale extrahiert, beispielsweise die durchschnittliche Zeit eines Haltevorgangs. Im Vergleich zu bisherigen Arbeiten ergänzen neuartige Merkmale basierend auf der Umgebung bzw. den detektierten Vorderfahrzeugen die Klassifikation. Auf insgesamt 637 Kreuzungspfaden mit manuell erstellter Grundwahrheit der Vorfahrtsregel wurden überwachte maschinelle Lernverfahren angewendet, um ein Modell zur Bestimmung der Vorfahrtsregel zu erstellen. Ein Vergleich der Lernverfahren *Random Forest*, *SVM*, *Neuronales Netz* und *ELM* für die vorliegende Problemstellung hinsichtlich Klassifikationsgüte und Trainings-/Test-Zeit ergab, dass das Random Forest Verfahren die höchste Klassifikationsgüte erreicht. Bei einer binären Klassifikation, ob der Kreuzungspfad durch eine Lichtsignalanlage geregelt wird oder nicht, ergibt sich eine Richtig-Positiv-Rate von 90 % bei einer Falsch-Positiv-Rate von 5 %. Zusätzlich wurde die Klassifikationsgüte abhängig von der Anzahl an nötigen Überfahrten ermittelt. Die Auswertung zeigt, dass sich die Güte mit der Verwendung von mehr als 40 Überfahrten nicht mehr signifikant ändert.

An Kreuzungspfaden, die durch eine Lichtsignalanlage geregelt werden, führt die Arbeit außerdem Methoden zur Bestimmung der Haltlinienposition ein. Dazu vergleicht die Arbeit ein einfaches Verfahren anhand der Dichte von Haltepunkten, mit einem Verfahren auf Basis einer mikroskopischen Verkehrssimulation. Für das simulationsbasierte Verfahren wurde eine Simulation des Verkehrs vor einer Haltlinie an einer Lichtsignalanlage unter Variation des Verkehrsflusses als Parameter durchgeführt. Es ergeben sich unterschiedliche Verteilungen der Haltepunkte, welche mit der Verteilung der real gemessenen Haltepunkte des Kreuzungspfades verglichen werden. Die Minimierung eines Distanzmaßes zwischen den Verteilungen unter zusätzlicher Berücksichtigung der Haltlinienposition ergibt die Position der Haltlinie. Die Auswertung zeigt, dass die geschätzte Haltlinienposition mit mindestens 30 verwendeten Haltepunkten in einem Intervall von $[-3.5, 5]$ m um die wahre Haltlinienposition liegt, wobei der Median

des Fehlers bei 1 m liegt. Das Verfahren mit Verwendung einer mikroskopischen Verkehrssimulation zeigt keine signifikante Verbesserung der Genauigkeit, ist jedoch robuster gegenüber Ausreißern. Dieser Vorteil wirkt sich vor allem bei Kreuzungspfaden mit wenigen verfügbaren Haltepositionen aus.

Zusätzlich zur Haltelinienposition und den Vorfahrtsregeln wurden Methoden zur Bestimmung von Gruppen von Fahrtrichtungen mit synchroner Signalgebung an Kreuzungen mit Lichtsignalanlage eingeführt. Diese statische Karteninformation wird für die Inferenz des relevanten Signals bei einem kamerabasierten System zur Erkennung von Lichtsignalanlagen verwendet. Zur Ermittlung der Signalgruppen werden aus einzelnen Überfahrten Umschaltzeitpunkte des Lichtsignals über ein Warteschlangenmodell geschätzt und daraus die Umlaufzeit der Lichtsignalanlage ermittelt. Dabei wird unter Verwendung eines Hidden Markov Modells ebenfalls die zeitliche Änderung der Umlaufzeit durch Programmwechsel über den Verlauf eines Tages geschätzt. Aufbauend auf diesen Informationen wird für Zeitfenster mit konstanter Umlaufzeit die Wahrscheinlichkeitsdichte des grünen Signals über einen Umlauf geschätzt. Durch den Vergleich der Wahrscheinlichkeitsdichten unterschiedlicher Fahrtrichtungen an einer Kreuzungseinfahrt werden Gruppen mit synchroner Signalgebung ermittelt. Dazu wird ein problemspezifisches Distanzmaß mit einem Modellvergleich nach Bayes eingeführt. Zur Evaluierung der entwickelten Methodik wurden die Signalgruppen von 48 Paaren von Fahrtrichtungen ermittelt und mit einer manuell erstellten Grundwahrheit verglichen. Die Genauigkeit der Methode liegt bei 93.8%. Die Auswertung ergibt außerdem, dass die Verwendung von mehr als 40 Überfahrten das Ergebnis nicht signifikant verbessert.

Die ermittelten Parameter Kreuzungstopologie und -geometrie, Vorfahrtsregel, Haltelinie sowie Signalgruppen werden für einzelne Kreuzungen ermittelt und in einer digitalen Karte abgelegt. Diese Karte wird in einem Testfahrzeug mit Kamerasystem zur Erkennung von Lichtsignalen dazu verwendet, um die Inferenz des relevanten Signals zu verbessern und eine automatisierte Verzögerung an roten Lichtsignalen ohne Vorderfahrzeug zu ermöglichen. Zur Evaluierung wurden die Daten von 344 Kreuzungsüberfahrten mit einem Testfahrzeug aus-

gewertet. Im Vergleich zu einem Ansatz ohne der Verwendung digitaler Karten wird eine Verbesserung der Detektion um 4.8% bei Distanzen größer 100m erreicht. Für automatisierte Fahrzeuge im urbanen Bereich sowie für Assistenzsysteme mit automatisierter Verzögerung an roten Lichtsignalen ist eine große Distanz für die Ersterkennung des relevanten Signals wichtig. Für den Fall, dass sich ein Fahrzeug einer Ampel mit etwa 70km/h nähert und eine komfortable Verzögerung von 2 m/s^2 gefordert ist, muss das Lichtsignal zuverlässig in einer Entfernung von 95 m erkannt werden. Anhand dieses Beispiels wird aufgezeigt, dass die Verwendung von Informationen zusätzlich zur lokalen Sensorik eine Erhöhung des Komforts von automatisierten Fahrfunktionen im urbanen Bereich ermöglicht, da die Detektion des relevanten Signals in größeren Distanzen mit höherer Zuverlässigkeit möglich wird.

8.1 Offene Herausforderungen

Für die vorgestellten Methoden und Ansätze zur automatisierten Inferenz von Kreuzungsinformationen aus Flottendaten sowie zur Verbesserung der kamera-basierten Erkennung relevanter Lichtsignale existieren offene Herausforderungen über diese Arbeit hinaus.

Automatisierte Inferenz von Kreuzungsinformationen aus Flottendaten

Die größte Herausforderung für die Inferenz von Kreuzungsinformationen zur Verwendung in hochautomatisierten Fahrfunktionen ist das Erreichen der geforderten Zuverlässigkeit. Die Evaluationen im Rahmen dieser Arbeit zeigen, dass es nicht möglich ist, korrekte Informationen zu garantieren. Allerdings ist eine Garantie der Richtigkeit auch bei manuell erstellten bzw. überprüften digitalen Karten nicht möglich. Aus diesem Grund müssen Fahrfunktionen, die auf digitalen Karten aufbauen, mit Unsicherheiten in den Informationen rechnen und damit umgehen. Abhängig von der erreichten Zuverlässigkeit sind dabei sporadische Fehler auf Kosten des Komforts von automatisierten Fahrfunktionen

tolerierbar. Die Sicherheit des Systems muss jedoch trotz inkorrektter Karteninformationen gewährleistet werden.

Eine weitere Herausforderung ist die flächendeckende automatisierte Ermittlung von exakten Karteninformationen. Die Genauigkeit der Informationen ist abhängig von der Menge verfügbarer Daten und damit vom Ort bzw. dem Gebiet für welches die Informationen generiert werden. Eine Anwendung der vorgestellten Methodik in Flotten beispielsweise von Fahrzeugherstellern würde in wenig befahrenen Gebieten nur ungenaue Kartenattribute generieren bzw. Änderungen erst sehr spät erkennen. Die Relevanz der Informationen ist jedoch prinzipiell in stärker befahrenen Gebieten höher. Daher ist es denkbar, automatisierte Funktionen, die aktuelle Kartendaten benötigen, abhängig von der Verfügbarkeit aktueller und genauer digitaler Karten einzuführen.

Verbesserung der kamerabasierten Relevanzerkennung für Lichtsignale

Für den vorgestellten Ansatz zur Verbesserung der kamerabasierten Erkennung relevanter Lichtsignale treten abhängig vom Umfeld des Fahrzeugs falsch positive oder falsch negative, also fehlende, Detektionen auf. Beispiele für falsch negative Detektionen, hervorgerufen durch Verdeckungen vorausfahrender LKWs, sind in Abbildung 8.1 dargestellt. In Unterabbildung 8.1a wird das relevante grüne Signal für eine gerade Überquerung der Kreuzung verdeckt. Das System erkennt ausschließlich das rote Signal für Linksabbieger. Anhand der Information, dass für diese Kreuzungseinfahrt zwei Signalgruppen vorhanden sind, ist es nicht möglich, die Verdeckung zu erkennen und damit die Unsicherheit in dieser Situation auszudrücken. Die Information über unterschiedliche Signalgruppen beinhaltet lediglich den Hinweis, dass die Signalisierung unterschiedlich sein kann. Allerdings muss nicht zu jedem Zeitpunkt eine Differenz vorhanden sein. Bei der ausschließlichen Detektion eines roten Signals in dem gezeigten Fall besteht die Möglichkeit, dass für beide Signalgruppen Rot gültig ist oder dass sämtliche Signalgeber der relevanten Signalgruppe verdeckt sind. Ausschließ-

lich in Situationen, in denen die Anzahl verschiedener Signale der Anzahl an Signalgruppen entspricht, ist es möglich eine Verdeckung auszuschließen. Der Fall, dass ein rotes Signal als relevant erkannt wird wohingegen ein grünes Signal tatsächlich gültig ist, verursacht bei automatisierter Fahrt eine ungewollte Verzögerung bis die Verdeckung aufgelöst wird.


Unterabbildung 8.1b zeigt die Verdeckung des relevanten roten Lichtsignals. In diesem Fall wird fälschlicherweise das grüne Signal als relevant detektiert. Vor allem Situationen in denen das relevante Signal während des Umschaltvorgangs von Grün auf Rot durch einen vorausfahrenden LKW verdeckt wird, welcher die Kreuzung noch in derselben Freigabephase überquert, sind für ein automatisiertes System eine Herausforderung. Zur Vermeidung einer unkomfortablen Verzögerung muss die Verdeckung frühzeitig erkannt werden. Damit ist es möglich, die Verdeckung durch eine vorausschauende leichte Verzögerung aufzulösen.

Neben Verdeckungssituationen treten zusätzlich falsch positive Detektionen von roten Signalen auf. Beispielsweise werden durch das vorliegende System teilweise Fußgängersignale und weitere rote Lichtquellen überwiegend nachts fälschlicherweise als rotes Lichtsignal erkannt. Auf Basis der im Rahmen dieser Arbeit automatisiert extrahierten Kreuzungsinformationen ist es möglich, falsche Detektionen außerhalb des Bereichs von Kreuzungen mit einer Lichtsignalanlage zu filtern. Falsche Detektionen im Kreuzungsbereich bleiben jedoch eine offene Herausforderung.

Zur Erkennung von Verdeckungssituationen und falschen Detektionen werden in [26] dreidimensionale Positionen von Signalgebern sowie deren Zuordnung zu Fahrstreifen bzw. Fahrtrichtungen in einer digitalen Karte abgelegt. Über eine hochgenaue Lokalisierung in dieser Karte und der erkannten relativen Position von Lichtsignalen durch ein Kamerasystem wird das relevante Lichtsignal ermittelt. Die Karten werden mit einem speziell ausgerüsteten Testfahrzeug semi-automatisiert generiert. Für die Methode zur Bestimmung des relevanten Signals ist eine hochgenaue Lokalisierung erforderlich und die Kartendaten belegen im Vergleich zu Informationen über Signalgruppen deutlich mehr Speicherplatz.



(a) Verdeckung eines grünen Lichtsignals



(b) Verdeckung eines roten Lichtsignals

Bild 8.1: Verdeckungssituationen von Lichtsignalen durch LKWs.

8.2 Ausblick

Für die verbleibenden Herausforderungen sind weitere Arbeiten zur Inferenz von Kreuzungsinformationen aus Flottendaten sowie zur Detektion des relevanten Lichtsignals an Kreuzungen nötig. Zur Erhöhung der Verlässlichkeit von Karteninformationen sind hybride Ansätze denkbar, die eine initiale und regelmäßige manuelle Vermessung der Kartenattribute vorsehen. Durch die Inferenz aus Flottendaten werden bauliche Änderungen zeitnah erkannt und kurzfristige Updates der Attribute durchgeführt. Eine weitere Herausforderung ist die Erhöhung der Verfügbarkeit automatisiert erstellter Kartenattribute. Eine Möglichkeit ist die Weiterentwicklung der vorgestellten Methoden hinsichtlich der benötigten Datenmenge, für eine höhere Robustheit in wenig befahrenen Gebieten.

Neben der Inferenz von Kartenattributen aus Flottendaten ist die Erkennung des relevanten Lichtsignals ein weiterer möglicher Schwerpunkt künftiger Arbeiten. Neben der Detektion, dass eine Verdeckung von Lichtsignalen vorliegt, sollte zusätzlich an Strategien zur Auflösung der Situationen gearbeitet werden. Eine Möglichkeit zur Unterstützung der Inferenz bzw. zur Plausibilisierung des erkannten relevanten Signals ist die Einbeziehung des lokalen Fahrzeugumfeldes. Im Falle einer inkorrekten Inferenz des Signals durch Verdeckung ist es denkbar, Bewegungsinformationen der vorausfahrenden Objekte miteinzubeziehen. Unter der Prämisse, dass die Fahrer im Umfeld die gültigen Verkehrsregeln einhalten, ist es möglich bei bekannter Haltelinienposition aus dem Überfahrtsverhalten eine Schätzung des Signalzustandes abzuleiten.

Zusätzlich gibt es zahlreiche weitere Möglichkeiten der Verwendung von Flottendaten für Fahrerassistenzsysteme. Eine Möglichkeit besteht darin, aus den Daten Fahrmanöver automatisiert zu lernen, um damit eine Prädiktion durch maschinelles Lernen im Fahrzeug zu realisieren [107]. Des Weiteren ist es denkbar, sämtliche Attribute digitaler Karten zu lernen, welche durch Sensorik im Fahrzeug erfasst bzw. aus zeitlichen Verläufen der Daten abgeleitet werden können. Beispiele hierfür sind Schilder, Steigungen, bauliche Trennungen, Fahrstreifenmarkierungen und Kurvenradien [108].

Literaturverzeichnis

- [1] V. Blervaque, K. Mezger, L. Beuk, und J. Loewenau, „ADAS Horizon - How Digital Maps can contribute to Road Safety,” in *Advanced Microsystems for Automotive Applications 2006, ADAS Horizon - How Digital Maps can contribute to Road Safety*, Serie VDI-Book, J. Valldorf und W. Gessner, Hrsg. Berlin: Springer-Verlag, 2006, S. 427–436.
- [2] F. Klanner, C. Ruhhammer, A. Bartsch, R. Rasshofer, W. Huber, und S. Rauch, „Mehr Komfort und Sicherheit durch zunehmende Vernetzung,” *Elektronik automotive*, Vol. 16, Nr. 6, S. 26–31, 2013.
- [3] H. Winner, *Radarsensorik*, in *Handbuch Fahrerassistenzsysteme*. Wiesbaden: Springer Fachmedien, 2015, Kap. 17, S. 259–316.
- [4] M. Treiber, A. Hennecke, und D. Helbing, „Congested traffic states in empirical observations and microscopic simulations,” *Physical Review E*, Vol. 62, Nr. 2, S. 1805–1824, Aug. 2000.
- [5] G. K. Mitropoulos, I. S. Karanasiou, A. Hinsberger, F. Aguado-Agelet, H. Wieker, H.-J. Hilt, S. Mammari, und G. Noecker, „Wireless Local Danger Warning: Cooperative Foresighted Driving Using Intervehicle Communication,” *IEEE Transactions on Intelligent Transportation Systems*, Vol. 11, Nr. 3, S. 539–553, Sep. 2010.
- [6] J. A. Barria und S. Thajchayapong, „Detection and Classification of Traffic Anomalies Using Microscopic Traffic Variables,” *IEEE Transactions on Intelligent Transportation Systems*, Vol. 12, Nr. 3, S. 695–704, Sep. 2011.

- [7] D. Irschik und W. Stork, „Road surface classification for extended floating car data,” in *IEEE International Conference on Vehicular Electronics and Safety (ICVES)*. IEEE, Dez. 2014, S. 78–83.
- [8] F. Klanner und C. Ruhhammer, *Backendsysteme zur Erweiterung der Wahrnehmungsreichweite von Fahrerassistenzsystemen*, in *Handbuch Fahrerassistenzsysteme*. Wiesbaden: Springer Fachmedien, 2015, Kap. 29, S. 541–552.
- [9] R. Bill, *Grundlagen der Geo-Informationssysteme*. Wichmann, 2010.
- [10] C. Ruhhammer, A. Atanasov, F. Klanner, und C. Stiller, „Crowdsourcing als Enabler für verbesserte Assistenzsysteme: Ein generischer Ansatz zum Erlernen von Kreuzungsparametern,” in *9. Workshop Fahrerassistenzsysteme: FAS2014, Walting*. Uni-DAS e.V., Mar. 2014.
- [11] H. Winner, S. Witte, W. Uhler, und B. Lichtenberg, „Adaptive Cruise Control System Aspects and Development Trends,” SAE, Tech. Rep. 961010, Feb. 1996.
- [12] W. Prestl, T. Sauer, J. Steinle, und O. Tschernoster, „The BMW Active Cruise Control ACC,” SAE, Tech. Rep. 2000-01-0344, Mar. 2000.
- [13] M. Persson, F. Botling, E. Hesslow, und R. Johansson, „Stop and go controller for adaptive cruise control,” in *IEEE International Conference on Control Applications (CCA)*, Vol. 2. IEEE, 1999, S. 1692–1697.
- [14] P. Venhovens, K. Naab, und B. Adiprasito, „Stop and go cruise control,” *International Journal of Automotive Technology*, Vol. 1, Nr. 2, S. 61–69, Dez. 2000.
- [15] V. L. Neale, M. A. Perez, S. E. Lee, und Z. R. Doerzaph, „Investigation of Driver-Infrastructure and Driver-Vehicle Interfaces for an Intersection Violation Warning System,” *Journal of Intelligent Transportation Systems*, Juni 2007.

- [16] M. Maile und L. Delgrossi, „Cooperative intersection collision avoidance system for violations (CICAS-V) for avoidance of violation-based intersection crashes,” *Enhanced Safety Vehicles*, 2009.
- [17] J. A. Jang, H. S. Kim, und H. B. Cho, „Smart roadside system for driver assistance and safety warnings: framework and applications,” *Sensors (Basel, Switzerland)*, Vol. 11, Nr. 8, S. 7420–36, Jan. 2011.
- [18] I. Miller, M. Campbell, D. Huttenlocher, F.-R. Kline, A. Nathan, S. Lupashin, J. Catlin, B. Schimpf, P. Moran, N. Zych, E. Garcia, M. Kurdziel, und H. Fujishima, „Team Cornell’s Skynet: Robust perception and planning in an urban environment,” *Journal of Field Robotics*, Vol. 25, Nr. 8, S. 493–527, Aug. 2008.
- [19] T. Marita, M. Negru, R. Danescu, und S. Nedevschi, „Stop-line detection and localization method for intersection scenarios,” in *IEEE International Conference on Intelligent Computer Communication and Processing*. IEEE, Aug. 2011, S. 293–298.
- [20] J. K. Suhr und H. G. Jung, „Fast symbolic road marking and stop-line detection for vehicle localization,” in *2015 IEEE Intelligent Vehicles Symposium (IV)*. IEEE, Juni 2015, S. 186–191.
- [21] U. Franke, D. Gavrila, S. Gorzig, F. Lindner, F. Puetzold, und C. Wohler, „Autonomous driving goes downtown,” *IEEE Intelligent Systems*, Vol. 13, Nr. 6, S. 40–48, Nov. 1998.
- [22] F. Heimes und H.-H. Nagel, „Towards Active Machine-Vision-Based Driver Assistance for Urban Areas,” *International Journal of Computer Vision*, Vol. 50, Nr. 1, S. 5–34, 2002.
- [23] C. Urmson, J. Anhalt, D. Bagnell, C. Baker, R. Bittner, M. N. Clark, J. Dolan, D. Duggins, T. Galatali, C. Geyer, M. Gittleman, S. Harbaugh, M. Hebert, T. M. Howard, S. Kolski, A. Kelly, M. Likhachev, M. McNaughton, N. Miller, K. Peterson, B. Pilnick, R. Rajkumar, P. Rybski, B. Salesky,

- Y.-W. Seo, S. Singh, J. Snider, A. Stentz, W. R. Whittaker, Z. Wolkowicki, J. Ziglar, H. Bae, T. Brown, D. Demitrish, B. Litkouhi, J. Nickolaou, V. Sadekar, W. Zhang, J. Struble, M. Taylor, M. Darms, und D. Ferguson, „Autonomous driving in urban environments: Boss and the Urban Challenge,” *Journal of Field Robotics*, Vol. 25, Nr. 8, S. 425–466, Aug. 2008.
- [24] S. Lefèvre, C. Laugier, und J. Ibañez Guzmán, „Exploiting map information for driver intention estimation at road intersections,” in *IEEE Intelligent Vehicles Symposium (IV)*. IEEE, Juni 2011, S. 583–588.
- [25] 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 (ITSM)*, Vol. 5, Nr. 2, S. 10–21, Jan. 2013.
- [26] J. Ziegler, P. Bender, M. Schreiber, H. Lategahn, T. Strauss, C. Stiller, U. Franke, N. Appenrodt, C. G. Keller, E. Kaus, R. G. Herrtwich, C. Rabbe, D. Pfeiffer, F. Lindner, F. Stein, F. Erbs, M.ENZweiler, C. Knoppel, J. Hipp, M. Haueis, M. Trepte, C. Brenk, A. Tamke, M. Ghanaat, M. Braun, A. Joos, H. Fritz, H. Mock, M. Hein, und E. Zeeb, „Making Bertha Drive - An Autonomous Journey on a Historic Route,” *IEEE Intelligent Transportation Systems Magazine (ITSM)*, Vol. 6, Nr. 2, S. 8–20, Jan. 2014.
- [27] O. Pink, F. Moosmann, und A. Bachmann, „Visual features for vehicle localization and ego-motion estimation,” in *IEEE Intelligent Vehicles Symposium (IV)*. IEEE, Juni 2009, S. 254–260.
- [28] H. Lategahn, M. Schreiber, J. Ziegler, und C. Stiller, „Urban localization with camera and inertial measurement unit,” in *IEEE Intelligent Vehicles Symposium (IV)*. IEEE, Juni 2013, S. 719–724.

- [29] H. Lategahn und C. Stiller, „Vision-Only Localization,” *IEEE Transactions on Intelligent Transportation Systems*, Vol. 15, Nr. 3, S. 1246–1257, Juni 2014.
- [30] E. Musk, „Teslas Ansatz für den Vertrieb und Service für seine Autos,” 2012. [Online]. https://www.teslamotors.com/de_DE/blog/tesla-approach-distributing-and-servicing-cars (besucht am: 03.04.2016)
- [31] BMW Group, „BMW ConnectedDrive. Navigationskarten-Updates per Mobilfunk und integrierte Spritpreissuche.” 2014. [Online]. <https://www.press.bmwgroup.com/deutschland/article/detail/T0177750DE/bmw-connecteddrive-navigationskarten-updates-per-mobilfunk-und-integrierte-spritpreissuche> (besucht am: 03.04.2016)
- [32] AUDI AG, „Mit Audi immer auf dem neusten Stand: Online-Update für Navigationskarte,” 2014. [Online]. <https://www.audi-mediacyber.com/de/pressemitteilungen/mit-audi-immer-auf-dem-neuesten-stand-online-update-fuer-navigationskarte-458> (besucht am: 03.04.2016)
- [33] M. F. Goodchild, „Citizens as sensors: the world of volunteered geography,” *GeoJournal*, Vol. 69, Nr. 4, S. 211–221, 2007.
- [34] D. Sui, S. Elwood, und M. Goodchild, *Crowdsourcing Geographic Knowledge: Volunteered Geographic Information (VGI) in Theory and Practice*. Springer Science & Business Media, 2012.
- [35] C. Heipke, „Crowdsourcing geospatial data,” *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 65, Nr. 6, S. 550–557, Nov. 2010.
- [36] M. M. Haklay und P. Weber, „OpenStreetMap: User-Generated Street Maps,” *IEEE Pervasive Computing*, Vol. 7, Nr. 4, S. 12–18, Okt. 2008.
- [37] TomTom N.V., „TomTom Map Share.” [Online]. <http://www.tomtom.com/mapshare> (besucht am: 04.03.2016)

- [38] Waze Mobile, „Waze,” 2016. [Online]. <https://www.waze.com> (besucht am: 16.04.2016)
- [39] S. Rogers, P. Langley, C. Wilson, und P. Alto, „Mining GPS Data to Augment Road Models,” in *Proceedings of the fifth ACM SIGKDD international conference on Knowledge discovery and data mining*, 1999.
- [40] S. Schroedl, K. Wagstaff, S. Rogers, P. Langley, und C. Wilson, „Mining GPS Traces for Map Refinement,” *Data Mining and Knowledge Discovery*, Vol. 9, Nr. 1, S. 59–87, 2004.
- [41] S. Worrall und E. Nebot, „Automated process for generating digitised maps through GPS data compression,” *Australasian Conference on Robotics and Automation (ACRA)*, 2007.
- [42] S. Rauch, A. Savkin, T. Schaller, und P. Hecker, „Hochgenaue Fahrzeuglokalisierung und kollektives Erlernen hochgenauer digitaler Karten,” in *Automatisierungssysteme, Assistenzsysteme und eingebettete Systeme für Transportmittel (AAET)*. Braunschweig: ITS automotive nord, 2012.
- [43] K. Jo und M. Sunwoo, „Generation of a Precise Roadway Map for Autonomous Cars,” *IEEE Transactions on Intelligent Transportation Systems*, Vol. 15, Nr. 3, S. 925–937, Juni 2014.
- [44] R. Bruntrup, S. Edelkamp, S. Jabbar, und B. Scholz, „Incremental map generation with GPS traces,” in *Proceedings. 2005 IEEE Intelligent Transportation Systems, 2005*. IEEE, 2005, S. 413–418.
- [45] J. Davies, A. Beresford, und A. Hopper, „Scalable, Distributed, Real-Time Map Generation,” *IEEE Pervasive Computing*, Vol. 5, Nr. 4, S. 47–54, Okt. 2006.
- [46] T. Guo, K. Iwamura, und M. Koga, „Towards high accuracy road maps generation from massive GPS Traces data,” in *IEEE International Geoscience and Remote Sensing Symposium*. IEEE, 2007, S. 667–670.

-
- [47] L. Cao und J. Krumm, „From GPS traces to a routable road map,” in *ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems (GIS)*. New York, New York, USA: ACM Press, Nov. 2009, S. 3.
- [48] L. Zhang, F. Thiemann, und M. Sester, „Integration of GPS traces with road map,” in *Second International Workshop on Computational Transportation Science (IWCTS)*. New York, New York, USA: ACM Press, Nov. 2010, S. 17.
- [49] Y. Chen und J. Krumm, „Probabilistic modeling of traffic lanes from GPS traces,” in *SIGSPATIAL International Conference on Advances in Geographic Information Systems (GIS)*. New York, New York, USA: ACM Press, Nov. 2010, S. 81.
- [50] M. Ahmed und C. Wenk, „Constructing street networks from GPS trajectories,” in *Algorithms - ESA 2012, Constructing street networks from GPS trajectories*. Springer Berlin Heidelberg, 2012, S. 60–71.
- [51] S. Karagiorgou und D. Pfoser, „On vehicle tracking data-based road network generation,” in *International Conference on Advances in Geographic Information Systems (SIGSPATIAL)*. New York, New York, USA: ACM Press, Nov. 2012, S. 89–98.
- [52] J. Biagioni und J. Eriksson, „Map inference in the face of noise and disparity,” in *Proceedings of the 20th International Conference on Advances in Geographic Information Systems - SIGSPATIAL '12*. New York, New York, USA: ACM Press, Nov. 2012, S. 79–88.
- [53] Y. Wang, X. Liu, H. Wei, G. Forman, C. Chen, und Y. Zhu, „CrowdAtlas: Self-Updating Maps for Cloud and Personal Use,” in *Mobile systems, applications, and services (MobiSys)*. New York, New York, USA: ACM Press, Juni 2013, S. 27.
- [54] M. Schreiber, A.-M. Hellmund, und C. Stiller, „Multi-drive feature association for automated map generation using low-cost sensor data,” in

- IEEE Intelligent Vehicles Symposium (IV)*. IEEE, Juni 2015, S. 1140–1147.
- [55] P. Baier, H. Weinschrott, F. Durr, und K. Rothermel, „MapCorrect: Automatic correction and validation of road maps using public sensing,” in *Conference on Local Computer Networks (LCN)*. IEEE, Okt. 2011, S. 58–66.
- [56] C. A. Pribe und S. O. Rogers, „Learning to Associate Observed Driver Behavior with Traffic Controls,” *Transportation Research Record: Journal of the Transportation Research Board*, Nr. 1679, 1999.
- [57] R. Carisi, E. Giordano, G. Pau, und M. Gerla, „Enhancing in vehicle digital maps via GPS crowdsourcing,” in *IEEE International Conference on Wireless On-Demand Network Systems and Services (WONS)*. Bardonecchia, Italy: IEEE, Jan. 2011, S. 27–34.
- [58] S. Hu, L. Su, H. Liu, H. Wang, und T. Abdelzaher, „Smart Road: A Crowd-Sourced Traffic Regulator Detection and Identification System,” in *International Conference on Information processing in sensor networks (IPSN)*. New York, NY, USA: ACM Press, Apr. 2013.
- [59] N. Fairfield und C. Urmson, „Traffic light mapping and detection,” in *IEEE International Conference on Robotics and Automation (ICRA)*. IEEE, Mai 2011, S. 5421–5426.
- [60] X. X. Martin Ester, Hans-Peter Kriegel, Jörg S, „A density-based algorithm for discovering clusters in large spatial databases with noise,” in *International Conference on Knowledge Discovery and Data Mining (KDD)*. Portland, Oregon, USA: AAAI Press, 1996, S. 226–231.
- [61] J. Puzicha, J. Buhmann, Y. Rubner, und C. Tomasi, „Empirical evaluation of dissimilarity measures for color and texture,” in *IEEE International Conference on Computer Vision (ICCV)*, Vol. 2. IEEE, 1999, S. 1165–1172.

- [62] F. J. Massey, „The Kolmogorov-Smirnov Test for Goodness of Fit,” *Journal of the American Statistical Association*, Vol. 46, Nr. 253, S. 68–78, 1951.
- [63] S. Kullback und R. A. Leibler, „On Information and Sufficiency,” *The Annals of Mathematical Statistics*, Vol. 22, Nr. 1, S. 79–86, Mar. 1951.
- [64] Y. Rubner, C. Tomasi, und L. J. Guibas, „The Earth Mover’s Distance as a Metric for Image Retrieval,” *International Journal of Computer Vision*, Vol. 40, Nr. 2, S. 99–121, Nov. 2000.
- [65] K. Burnham und D. Anderson, *Model Selection and Multimodel Inference: A Practical Information-Theoretic Approach*, 2. Aufl. Springer-Verlag New York, 2002.
- [66] Y. Rubner, C. Tomasi, und L. Guibas, „A metric for distributions with applications to image databases,” in *IEEE International Conference on Computer Vision (ICCV)*. Narosa Publishing House, 1998, S. 59–66.
- [67] US Department of Defence, „GPS SPS Performance Standard,” Sep. 2008. [Online]. <http://www.navcen.uscg.gov/gps/geninfo/2008SPSPerformanceStandardFINAL.pdf> (besucht am: 19.03.2016)
- [68] R. Obe und L. Hsu, *PostGIS in Action*. Manning Publications, 2011.
- [69] R. G. Garrett, „The chi-square plot: a tool for multivariate outlier recognition,” *Journal of Geochemical Exploration*, Vol. 32, Nr. 1, S. 319–341, 1989.
- [70] K. Fukunaga und L. Hostetler, „The estimation of the gradient of a density function, with applications in pattern recognition,” *IEEE Transactions on Information Theory*, Vol. 21, Nr. 1, S. 32–40, 1975.
- [71] G.-B. Huang, Q.-Y. Zhu, und C.-K. Siew, „Extreme learning machine: Theory and applications,” *Neurocomputing*, Vol. 70, Nr. 1-3, S. 489–501, Dez. 2006.

- [72] T. Fawcett, „ROC Graphs: Notes and Practical Considerations for Researchers,” HP Laboratories, Palo Alto, CA, USA, Tech. Rep., 2003.
- [73] L. Breiman und Leo, „Random Forests,” *Machine Learning*, Vol. 45, Nr. 1, S. 5–32, 2001.
- [74] D. Krajzewicz, J. Erdmann, M. Behrisch, und L. Bieker, „Recent Development and Applications of SUMO - Simulation of Urban MObility,” *International Journal On Advances in Systems and Measurements*, Vol. 5, Nr. 3&4, S. 128–138, 2012.
- [75] C. Ruhhammer, N. Hirsenkorn, F. Klanner, und C. Stiller, „Crowdsourced intersection parameters: A generic approach for extraction and confidence estimation,” in *IEEE Intelligent Vehicles Symposium (IV)*. IEEE, Juni 2014, S. 581–587.
- [76] AUDI AG, „Audi travolution: Effizient durch die Stadt,” 2010. [Online]. <https://www.audi-mediacyber.com/de/pressemitteilungen/audi-travolution-effizient-durch-die-stadt-1152> (besucht am: 27. 10. 2015)
- [77] Q. Huang und R. Miller, „The Design of Reliable Protocols for Wireless Traffic Signal System,” Washington University, Tech. Rep., Feb. 2003.
- [78] F. Lindner, U. Kressel, und S. Kaelberer, „Robust recognition of traffic signals,” in *IEEE Intelligent Vehicles Symposium (IV)*. IEEE, 2004, S. 49–53.
- [79] R. de Charette und F. Nashashibi, „Real time visual traffic lights recognition based on Spot Light Detection and adaptive traffic lights templates,” in *IEEE Intelligent Vehicles Symposium (IV)*. IEEE, Juni 2009, S. 358–363.
- [80] J. Gong, Y. Jiang, G. Xiong, C. Guan, G. Tao, und H. Chen, „The recognition and tracking of traffic lights based on color segmentation and CAMSHIFT for intelligent vehicles,” in *IEEE Intelligent Vehicles Symposium (IV)*. IEEE, Juni 2010, S. 431–435.

- [81] D. Nienhuser, M. Drescher, und J. M. Zöllner, „Visual state estimation of traffic lights using hidden Markov models,” in *IEEE Intelligent Transportation Systems Conference (ITSC)*. IEEE, Sep. 2010, S. 1705–1710.
- [82] J. Levinson, J. Askeland, J. Dolson, und S. Thrun, „Traffic light mapping, localization, and state detection for autonomous vehicles,” in *IEEE International Conference on Robotics and Automation (ICRA)*. IEEE, Mai 2011, S. 5784–5791.
- [83] M. P. Philipsen, M. B. Jensen, A. Mogelmoose, T. B. Moeslund, und M. M. Trivedi, „Traffic Light Detection: A Learning Algorithm and Evaluations on Challenging Dataset,” in *IEEE Intelligent Transportation Systems Conference (ITSC)*. IEEE, Sep. 2015, S. 2341–2345.
- [84] V. John, K. Yoneda, Z. Liu, und S. Mita, „Saliency Map Generation by the Convolutional Neural Network for Real-Time Traffic Light Detection Using Template Matching,” *IEEE Transactions on Computational Imaging*, Vol. 1, Nr. 3, S. 159–173, Sep. 2015.
- [85] M. Weber, P. Wolf, und J. M. Zöllner, „DeepTLR: A single deep convolutional network for detection and classification of traffic lights,” in *IEEE Intelligent Vehicles Symposium (IV)*. IEEE, Juni 2016, S. 342–348.
- [86] M. Diaz-Cabrera, P. Cerri, und J. Sanchez-Medina, „Suspended traffic lights detection and distance estimation using color features,” in *IEEE Intelligent Transportation Systems Conference (ITSC)*. IEEE, Sep. 2012, S. 1315–1320.
- [87] C. Ruhhammer, M. Baumann, V. Protschky, H. Kloeden, F. Klanner, und C. Stiller, „Automated Intersection Mapping From Crowd Trajectory Data,” *IEEE Transactions on Intelligent Transportation Systems*, Vol. 18, Nr. 3, S. 666–677, 2017.
- [88] RiLSA, „Richtlinien für Lichtsignalanlagen - Lichtzeichenanlagen für den Straßenverkehr,” Forschungsgesellschaft für Straßen- und Verkehrswesen e.V, Tech. Rep., 2010.

- [89] D. Kobbeloer, *Dezentrale Steuerung von Lichtsignalanlagen in urbanen Verkehrsnetzen*. kassel university press GmbH, 2007.
- [90] R. Akcelik und M. Besley, „Queue Discharge Flow and Speed Models for Signalised Intersections,” in *The 15th International Symposium on Transportation and Traffic Theory (ISTTT)*, 2002, S. 99–118.
- [91] G. Hoffmann und S.-M. Nielsen, *Beschreibung von Verkehrsabläufen an signalisierten Knotenpunkten*. Bundesministerium für Verkehr, Abt. Straßenbau, 1994.
- [92] M. Kerper, C. Wewetzer, A. Sasse, und M. Mauve, „Learning Traffic Light Phase Schedules from Velocity Profiles in the Cloud,” in *IEEE International Conference on New Technologies, Mobility and Security (NT-MS)*. Istanbul, Turkey: IEEE, Mai 2012, S. 1–5.
- [93] V. Protschky, S. Feit, und C. Linnhoff-Popien, „On the Potential of Floating Car Data for Traffic Light Signal Reconstruction,” in *IEEE Vehicular Technology Conference (VTC Spring)*. IEEE, Mai 2015.
- [94] K. V. Mardia und P. E. Jupp, *Directional Statistics*. John Wiley & Sons, Inc., 1999.
- [95] B. Ajne, „A simple test for uniformity of a circular distribution,” *Biometrika*, Vol. 55, Nr. 2, S. 343–354, July 1968.
- [96] V. Protschky, C. Ruhhammer, und S. Feit, „Learning Traffic Light Parameters with Floating Car Data,” in *IEEE Intelligent Transportation Systems Conference (ITSC)*. IEEE, Sep. 2015, S. 2438–2443.
- [97] J. K. Kruschke, *Doing Bayesian Data Analysis: A Tutorial with R and BUGS*. Academic Press, 2010, Vol. 1.
- [98] A. Gelman, J. B. Carlin, H. S. Stern, D. B. Dunson, A. Vehtari, und D. B. Rubin, *Bayesian Data Analysis*. CRC Press, 2013, Vol. 3.
- [99] R. E. Kass und A. E. Raftery, „Bayes Factors,” *Journal of the american statistical association*, Vol. 90, Nr. 430, S. 773–795, 1995.

- [100] S. J. Russell und P. Norvig, *Künstliche Intelligenz : ein moderner Ansatz*. Pearson Studium, 2012.
- [101] J. A. Bilmes, „A Gentle Tutorial of the EM Algorithm and its Application to Parameter Estimation for Gaussian Mixture and Hidden Markov Models,” 1998.
- [102] G. Marsden, M. McDonald, und M. Brackstone, „Towards an understanding of adaptive cruise control,” *Transportation Research Part C: Emerging Technologies*, Vol. 9, Nr. 1, S. 33–51, Feb. 2001.
- [103] J. W. Tukey, *Exploratory Data Analysis*, 18. Aufl. Addison-Wesley, 1977.
- [104] G. S. Aoude, V. R. Desaraju, L. H. Stephens, und J. P. How, „Driver Behavior Classification at Intersections and Validation on Large Naturalistic Data Set,” *IEEE Transactions on Intelligent Transportation Systems*, Nr. 99, S. 1–13, 2012.
- [105] M. Liebner, M. Baumann, F. Klanner, und C. Stiller, „Driver intent inference at urban intersections using the intelligent driver model,” in *IEEE Intelligent Vehicles Symposium (IV)*. IEEE, Juni 2012, S. 1162–1167.
- [106] M. Liebner, „Fahrerabsichtserkennung und Risikobewertung für warnende Fahrerassistenzsysteme,” Dissertation, Karlsruher Institut für Technologie (KIT), 2015.
- [107] J. Jordan, C. Ruhhammer, H. Klöden, und M. Kleinsteuber, „Learning Driving Scene Prediction from Environmental Perception of Vehicle Fleet Data,” in *IEEE Intelligent Transportation Systems Conference (ITSC)*. IEEE, Sep. 2015, S. 547–552.
- [108] M. P. Schraut, „Umgebungserfassung auf Basis lernender digitaler Karten zur vorausschauenden Konditionierung von Fahrerassistenzsystemen,” Dissertation, Technische Universität München (TUM), 2000.

Schriftenreihe

Institut für Mess- und Regelungstechnik

Karlsruher Institut für Technologie

(1613-4214)

- 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 Klopferschall. 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
Gleiselektive 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 Fahrerassistentenanwendungen. 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
- Band 035** Ziegler, Julius
Optimale Trajektorienplanung für Automobile. 2017
ISBN 978-3-7315-0553-2

Band 036 Harms, Hannes
**Genauigkeitsuntersuchung von
binokularen Normalenvektoren für
die Umfeldwahrnehmung.** 2017
ISBN 978-3-7315-0628-7

Band 037 Ruhhammer, Christian
**Inferenz von Kreuzungsinformationen
aus Flottendaten.** 2017
ISBN 978-3-7315-0721-5

Künftige Fahrerassistenzsysteme und hochautomatisierte Fahrfunktionen basieren auf digitalen Karten. Damit werden hohe Anforderungen an die Korrektheit und Aktualität der enthaltenen Informationen gestellt. In der vorliegenden Arbeit werden dafür neuartige automatisierte Verfahren zur Extraktion aktueller Karteninformationen aus Flottendaten vorgestellt. Aufgrund der hohen Komplexität und Variabilität innerstädtischer Szenarien stellen die Umsetzung von Assistenzsystemen und das Erstellen von Karten im urbanen Bereich eine besondere Herausforderung dar. Die Arbeit richtet ihren Fokus auf die Inferenz von statischen Kreuzungsinformationen aus Flottendaten. Mittels maschinellen Lernens und statistischer Verfahren werden Kreuzungstopologie und -geometrie, Vorfahrtsregel, Haltelinienposition und statische Informationen über die Signalgebung an Kreuzungen mit einer Lichtsignalanlage ermittelt.

Ein automatisiertes Verteilen der generierten Informationen an Fahrzeuge über das Internet ermöglicht eine wesentliche Verbesserung der Aktualität digitaler Karten, beispielsweise durch eine zeitnahe Detektion von baulichen Änderungen. Als Anwendungsbeispiel wird ein System zur automatisierten Längsregelung an Kreuzungen mit Lichtsignalanlage entwickelt. Grundlage des Systems sind automatisiert ermittelte Kreuzungsinformationen aus Flottendaten. Der Mehrwert dieser Informationen zeigt sich in einer erweiterten Vorausschau und der damit einhergehenden Erhöhung des Komforts, sowie einer Verbesserung der Detektion des relevanten Lichtsignals und damit einer Erhöhung der Sicherheit.

ISSN 1613-4214

ISBN 978-3-7315-0721-5

Gedruckt auf FSC-zertifiziertem Papier

ISBN 978-3-7315-0721-5



9 783731 507215 >